

## بررسی کارایی شبکه یادگیری عمیق در شناسایی تغییرات اراضی با استفاده از

### تصاویر دو زمانه لندست-۸

سه‌ند طاهرمنش<sup>۱</sup>، بهنام اصغری بیرامی<sup>۲</sup>، مهدی مختارزاده<sup>۳\*</sup>

۱. دانشجوی کارشناسی ارشد سنجش از دور، دانشکده مهندسی نقشه برداری، دانشگاه صنعتی خواجه نصیرالدین طوسی، ایران

۲. دانشجوی دکتری سنجش از دور، دانشکده مهندسی نقشه برداری، دانشگاه صنعتی خواجه نصیرالدین طوسی، ایران

۳. دانشیار، گروه آموزشی فتوگرامتری و سنجش از دور، دانشکده مهندسی نقشه برداری، دانشگاه صنعتی خواجه نصیرالدین طوسی، ایران

\* پست الکترونیکی مسئول مکاتبات: M\_mokhtarzade@kntu.ac.ir

زیرنویس شود: [1] Commented

#### چکیده

علم سنجش از دور با به کارگیری تصاویر چند زمانه ماهواره‌ای، امکان پایش تغییرات در فواصل زمانی مختلف را فراهم کرده است. رویکرد پیکسل مینا در شناسایی تغییرات توانایی ارائه دقت بالا را ندارد و از این رو باید ویژگی‌های مکانی در کنار ویژگی‌های طیفی بکار روند. استفاده از روش‌های سستی تولید ویژگی مکانی مانند ماتریس هم رخداد با چالش‌هایی روبرو است. تولید این ویژگی‌ها علاوه بر این که وابسته به انتخاب کاربر است، به صورت ناخواسته باعث افزایش فضای ویژگی می‌گردد. تمرکز اصلی مقاله حاضر در به کارگیری ویژگی‌های طیفی-مکانی در راستای حل محدودیت روش‌های سستی در شناسایی تغییرات اراضی است. در این تحقیق، ویژگی‌های طیفی-مکانی توسط خود شبکه یادگیری عمیق پیشنهادی استخراج شده و در طبقه‌بندی بکار گرفته شده‌اند. تصاویر لندست-۸ ورودی شبکه بوده و فرایند استخراج ویژگی به صورت سلسله مراتبی صورت گرفته است. بر اساس ویژگی‌های طیفی-مکانی عمیق تولیدی از لایه‌های شبکه، خروجی شبکه تصاویر طبقه‌بندی شده‌ی قبل و بعد می‌باشد. در نهایت، بر اساس رویکرد پسا طبقه‌بندی نقشه تغییرات حاصل می‌گردد. از شبکه پیشنهادی جهت ارزیابی تغییرات شهر سه‌ند با استفاده از تصاویر سنجنده لندست-۸ در بین سال‌های ۲۰۱۳ تا ۲۰۲۱ استفاده شده است. برای اثبات قابلیت شبکه پیشنهادی در به کارگیری ویژگی و طبقه‌بندی دقیق تصاویر، نتایج حاصل شده با نتایج روش‌های جنگل تصادفی و شبکه عصبی مصنوعی مقایسه شده است. نتایج شناسایی تغییرات نشان داد که به کارگیری شبکه یادگیری عمیق پیشنهادی دقت کلی شناسایی تغییرات بایتری را به ترتیب به میزان ۱۳/۸۸٪ و ۱۲/۸۰٪ نسبت به شبکه عصبی مصنوعی و جنگل تصادفی افزایش می‌دهد. همچنین به کارگیری شبکه پیشنهادی دقت کلی نقشه ماهیت تغییرات را به ترتیب به میزان ۵۷/۸۱٪ و ۶۵/۷٪ در مقایسه با جنگل تصادفی و شبکه عصبی مصنوعی افزایش داده است. روش‌های جنگل تصادفی و شبکه عصبی مصنوعی علی‌رغم اینکه توانسته‌اند محل تغییرات را شناسایی کنند اما در ارائه نوع ماهیت تغییرات عملکرد نامناسبی ارائه کرده‌اند.

واژه‌های کلیدی: پایش تغییرات، یادگیری عمیق، شبکه عصبی کانولوشن، جنگل تصادفی، شبکه عصبی مصنوعی.

Deleted: می‌باشد

Deleted: بر اساس

## مقدمه

زمین منبع اصلی تأمین‌کننده نیازهای انسان محسوب می‌شود. استفاده از زمین اثرات قابل‌توجهی بر عملکرد سیستم‌های اجتماعی - اقتصادی و محیط‌زیستی دارد. به‌طور مثال استفاده نامطلوب و بدون برنامه‌ریزی از منابع طبیعی علاوه بر این‌که خود اکوسیستم را تحدید می‌کند، زندگی روزمره بشر را نیز تحت شعاع خود قرار می‌دهد (۱۲). افزایش جمعیت در دهه‌های اخیر، منجر به بروز تغییرات گسترده‌ای در محیط‌زیست شده است. تغییرات رخداد در راستای تأمین نیازها بوده است. ازجمله این تغییرات می‌توان به توسعه و گسترش بی‌رویه ساخت‌وسازها اشاره کرد. توسعه و گسترش ساخت‌وسازها که در بیشتر مواقع با از بین بردن زیستگاه حیوانات و تخریب منابع طبیعی همراه است، تهدید جدی برای محیط‌زیست قلمداد می‌گردد. در دست داشتن اطلاعات مکانی بهنگام از مناطق تغییر یافته کمک شایانی به مدیریت و حفظ محیط‌زیست می‌کند. در این راستا پایش تغییرات پوشش و کاربری اراضی زمین برای بهبود کیفیت برنامه‌ریزی‌های شهری و حفظ محیط‌زیست، امری ضروری و حیاتی است (۱۹). وجود تصاویر ماهواره‌ای که دربرگیرنده اطلاعات طبیعی عوارض سطح زمین می‌باشند، مطالعه و بررسی تغییرات در بازه‌های زمانی مختلف را نسبت به روش‌های میدانی آسان‌تر کرده است (۱۰). به‌کارگیری تصاویر ماهواره‌ای به‌عنوان یک روش مقرون‌به‌صرفه و سریع در شناسایی تغییرات عوارض زمین محسوب می‌گردد. تغییرات پوشش زمین به‌طور معمول تغییرات در اقلیم را منعکس می‌کند. بنابراین، تکنیک‌های تشخیص تغییرات مبتنی بر هوش مصنوعی می‌توانند روش‌های مؤثری را برای نظارت بر تغییرات فراهم کنند (۳). به‌طور کلی روش‌های کشف تغییرات به دو دسته کلی: تکنیک‌های نظارت‌نشده و نظارت‌شده تقسیم می‌گردند. روش‌های نظارت‌نشده بدون نیاز به داده‌های آموزشی، فرآیند شناسایی و تمایز بین عارضه‌ها را انجام می‌دهند. خروجی این روش‌ها فقط توانایی شناسایی محل وقوع تغییرات را دارند (۲۶). در مقابل روش‌های نظارت‌شده علاوه بر توانایی ارائه محل تغییرات، می‌توانند نوع تغییرات رخداد را نیز ارائه دهند (۲۸). یکی از معروف‌ترین و مشهورترین روش در تکنیک‌های نظارت‌شده رویکرد پسا طبقه‌بندی است. رویکردهای پسا طبقه‌بندی با استفاده از نمونه‌های آموزشی تصاویر چند زمانه به‌طور مستقل طبقه‌بندی می‌شوند. سپس با مقایسه نقشه‌های طبقه‌بندی‌شده، نقشه تغییرات نهایی تولید می‌گردد. با توجه به این‌که نمونه‌های آموزشی مستقلاً از تصاویر ورودی جمع‌آوری‌شده و طبقه‌بندی مجزا صورت می‌گیرد، حساسیت نتایج به اثرات متفاوت رادیومتریکی و اتمسفری در زمان تصویربرداری به شدت کاهش می‌یابد و قابلیت اطمینان بالایی نسبت به رویکرد اول دارند (۲۲ و ۲۳).

**Commented [۲۵]:** مزایای برخی قسمت‌ها نیاز به ویرایش دارد  
• عدم اشاره به مراجع جدید در متن: در این متن، اطلاعاتی از مراجع خارج شده است. ارجاع به مراجع به خواننده کمک می‌کند تا اطمینان حاصل کند که اطلاعاتی که ارائه شده‌اند، مبتنی بر تحقیقات گذشته و قابل اعتماد هستند.  
• تطبیق مقدمه با عنوان: مقدمه اطلاعات کلی ارائه داده است اما متن بر روی جزئیات و روش‌های مورد استفاده در تحقیقات تمرکز دارد. باید اطمینان حاصل شود که عنوان و مقدمه با هم همخوانی دارند و یکدیگر را پیگیری می‌کنند.

پایش تغییرات صرفاً با استفاده از ویژگی‌های طیفی موجب به وجود آمدن دقت‌های بالا نمی‌شود و نیاز داریم در کنار اطلاعات طیفی تصاویر از اطلاعات مکانی نیز استفاده کنیم. به‌طور مثال از روش‌هایی که اطلاعات مکانی را در نظر می‌گیرند می‌توان به ویژگی‌های استخراج‌شده از ماتریس هم‌رخداد و ویژگی‌های گابرو اشاره کرد. به‌عنوان نمونه از این تحقیقات: سپهری (۱۷) در تحقیقی به بررسی تغییرات اراضی و پوشش گیاهی دو شهر تفت و مهریز پرداختند. در این راستا از تصاویر ماهواره‌ی لندست-۵ و لندست-۸ استفاده‌شده است. در این پژوهش تغییرات با استفاده از شبکه عصبی مصنوعی شناسایی و مدل‌سازی گردید. میشرا (۱۴)، در تحقیقی به بررسی تغییرات کاربری و پوشش اراضی حوزه آبریز در منطقه‌ای از هیمالیا پرداخته است. ایشان در چهار دوره زمانی به پایش تغییرات رخداد پرداختند. تصاویر سنجنده‌های لندست-۵ و ستینل-۲ برای این منظور بکار گرفته شدند. طبقه‌بندی توسط الگوریتم بیشترین شباهت صورت گرفته و ماتریس تغییرات برای ارائه ماهیت تغییرات رخداد در طی این چهار دوره تولید گردید. زیویانگ (۳۰)، در شناسایی تغییرات رخداد در وهان چین، ویژگی‌های موجک گابور را بکار گرفت. ایشان برای در نظر گرفتن اطلاعات همسایگی از الگوریتم میدان تصادفی مارکوف استفاده کردند. بر این اساس تصاویر تفاضلی بر اساس الگوریتم پیشنهادی تولید و نقشه تغییرات باینری توسط خوشه‌بندی فازی تولید گردید. الگوریتم پیشنهادی ایشان نتایج شناسایی را نسبت به کارگیری معمول ویژگی‌های مکانی مستخرج از ماتریس هم‌رخداد بهبود داده است.

در بررسی این تحقیقات باید به چند مسئله اشاره کرد. مسئله اول، استفاده صرف از اطلاعات طیفی تصاویر به دلیل اینکه امکان وقوع نوسانات طیفی در عوارض با رفتار طیفی مشابه وجود دارد، منجر به نتایج غیردقیق می‌شوند. که این مسئله توسط محققین که صرفاً از اطلاعات طیفی استفاده کرده‌اند نادیده گرفته شده است. مسئله دوم، به‌کارگیری اطلاعات مکانی در کنار اطلاعات طیفی که انتظار می‌رود نتایج شناسایی را بهبود ببخشند، دارای دو چالش می‌باشد (۱۳). یک: استفاده همه اطلاعات در کنار هم به دلیل ایجاد همبستگی بالا، نه تنها دقت طبقه‌بندی را بهبود نمی‌دهد بلکه با کاهش دقت و ایجاد خطا همراه خواهد شد (۲۷). دوم: اطلاعات مکانی مستخرج بشدت به منطقه مورد مطالعاتی وابسته هستند. یعنی ممکن است یک ویژگی در یک منطقه دارای عملکرد مطلوبی باشد ولی در منطقه دیگر عملکرد ضعیفی داشته باشد. از طرف دیگر انتخاب ویژگی‌ها وابسته به کاربر می‌باشد (۷).

با پیشرفت سخت‌افزارهای کامپیوتری و توسعه‌ی هر چه بیشتر هوش مصنوعی در چند دهه اخیر، یادگیری عمیق به یک شاخه مطالعاتی جدید در اکثر زمینه‌های تحقیقاتی تبدیل گشته است. شبکه‌های یادگیری عمیق برخلاف روش‌های کلاسیک استخراج ویژگی، توانایی استخراج خودکار اطلاعات مکانی سطح بالا را دارند. در این صورت نقش کاربرد در تعیین و شناسایی ویژگی‌های مناسب کاسته می‌شود. علاوه بر این ویژگی‌های تولیدی دیگر به صحنه تصاویر وابسته نخواهند بود (۱۹). از این رو، یادگیری عمیق جایگزین مناسبی در به‌کارگیری اطلاعات طیفی و مکانی کنار یکدیگر می‌باشند. در این راستا تحقیقاتی نظیر: لیو (۱۱)، با استفاده از یک شبکه آموزش‌دیده با یک دیتاست بزرگ چارچوب جدیدی بر اساس ترکیب با یک شبکه عصبی بازگشتی برای استخراج منطقه شهری و تشخیص تغییرات پیشنهاد کردند. دقت کلی نقشه‌های شهری یک‌ساله آن تقریباً ۹۶ درصد در میان چهار شهر هدف (پکن، نیویورک، ملبورن و مونیخ) است. نکته‌ای که باید در نظر داشت، ساختار جدید معرفی‌شده از شبکه یادگیری عمیق نیازمند مجموعه تصاویر زیاد می‌باشد. داودت (۲)، با استفاده از تصاویر ستینل-۲ با استفاده از شبکه‌های یادگیری عمیق اقدام به شناسایی تغییرات شهری کردند. همچنین، ایشان تأثیر استفاده از تعداد مختلفی از کانال‌های طیفی را به‌عنوان ورودی شبکه‌ها مقایسه کردند. نتایج نشان داد؛ ساختار تلفیق سریع با اعمال ۴ کانال طیفی نظیر باند آبی، سبزی، قرمز و مادون‌قرمز نزدیک، بالاترین دقت را در میان تمامی حالت‌ها به خود اختصاص داده است. چن (۱)، در رویکردی با ترکیب دو ساختار از شبکه‌های یادگیری عمیق اقدام به شناسایی تغییرات در تصاویر با قدرت تفکیک مکانی بالا کردند. ترکیب شبکه عصبی کانولوشن با شبکه عصبی بازگشتی پیشنهادی ایشان در مقایسه با به‌کارگیری صرف شبکه عصبی کانولوشن، نتایج بهتری در شناسایی تغییرات ارائه داده است. انجام‌شده است.

با توجه به کارایی روش‌های یادگیری عمیق در تحقیقات اخیر، هدف اصلی مقاله‌ی حاضر استفاده از روش‌های یادگیری عمیق به‌منظور پایش تغییرات اراضی در شهر سهند می‌باشد. که در این راستا از تصاویر دو زمانه ماهواره‌ی لندست-۸ استفاده‌شده است.

تصاویر قبل و بعد به صورت جداگانه وارد شبکه یادگیری عمیق پیشنهادی شده و فرایند استخراج و طبقه‌بندی ویژگی‌های طیفی- مکانی صورت می‌گیرد. سپس با مقایسه تصاویر طبقه‌بندی‌شده، نقشه تغییرات حاصل می‌گردد. برای اثبات قابلیت شبکه پیشنهادی در زمینه پایش تغییرات از دو روش دیگر؛ شبکه عصبی مصنوعی و جنگل تصادفی نیز در این تحقیق استفاده شده است. روش اول نماینده روش‌های جدید یادگیری عمیق بوده و دو روش دیگر نماینده روش‌های یادگیری ماشینی کلاسیک هستند (۲۱و۲). در این تحقیق به معماری شبکه‌ای رسیدیم که به دقت‌های بالاتری دست یافته است. نتایج نهایی به دست آمده نشان می‌دهد که شبکه یادگیری عمیق پیشنهادی توانسته با دقت بالایی تغییرات را نسبت به دو روش دیگر شناسایی کند.

روند کلی ادامه بخش‌های مقاله، به ترتیب در بخش اول به ارائه منطقه مورد مطالعاتی، داده‌های مورد استفاده و نوع پوشش‌های موجود در منطقه پرداخته می‌شود. در بخش دوم، روش تحقیق، فلوچارت رویکرد پیشنهادی ارائه شده و معماری شبکه پیشنهادی شرح داده می‌شود. در بخش سوم، نتایج، به همراه تحلیل نتایج حاصل از ارزیابی طبقه‌بندی تصاویر و نقشه‌های تغییرات ارائه شده است. در بخش چهارم، بحث و نتیجه‌گیری، به بررسی کلی نتایج روش‌ها پرداخته شده است. بخش آخر نیز به تقدیر و تشکر پرداخته است.

#### مواد و روش‌ها

##### منطقه مورد مطالعه و داده‌های مورد استفاده

در این تحقیق به منظور بررسی عملکرد شبکه پیشنهادی در پایش تغییرات، تصاویر ماهواره‌ای لندست-۸ از منطقه شهر سهند استفاده شده است. تصاویر این شهر از سامانه گوگل ارث انجین در زمان‌های ۱۰ جولای ۲۰۱۳ و ۱ آگوست ۲۰۲۱ جمع‌آوری شده‌اند. اکثر مطالعات تغییر کاربری/ پوشش اراضی شهری، داده‌های لندست را به دلیل منحصر به فرد بودن مجموعه داده به عنوان آرشیو دیجیتال بلندمدت با وضوح مکانی متوسط و وضوح طیفی نسبتاً مناسب، مورد استفاده قرار دادند (۵ و ۲۴). تصاویر ماهواره لندست-۸ دارای ۱۱ باند بوده که از بین این باندها باندهای شماره ۱ تا ۴ و ۸ در محدوده دید انسان قرار داشته و بقیه باندها خارج از محدوده مرئی می‌باشند. باندهای ۷ تا ۹ و باند ۱۰ دارای قدرت تفکیک مکانی ۳۰ متر بوده و باند ۸ این سنجنده، باند پانکروماتیک با قدرت تفکیک مکانی ۱۵ متر می‌باشد. شهر جدید سهند با طول جغرافیایی  $46^{\circ} 16' 19''$  شرقی و عرض جغرافیایی  $37^{\circ} 56' 41''$  شمالی، در استان آذربایجان شرقی واقع شده است. این شهر بنا به افزایش جمعیت شهر تبریز برای کنترل و مدیریت جمعیت در سال ۱۳۸۶ تأسیس گردید. این شهر در ۲۰ کیلومتری جنوب غربی شهر تبریز بوده که اخیراً با احداث بزرگراه تبریز-سهند، دسترسی شهروندان دو شهر آسان‌تر شده و این

**Commented [۲۵]:** 1. عدم توضیح دقیق در مورد فرایند جمع‌آوری داده‌ها از سامانه گوگل ارث انجین، از جمله روش‌های استفاده شده برای تصحیح رادیومتریکی و هم مرجع‌سازی.

2. عدم ارائه جزئیات کافی در مورد تقسیم‌بندی داده‌ها به مجموعه‌های آموزشی و آزمایشی، از جمله معیارهای استفاده شده برای این تقسیم‌بندی.

3. فقدان اطلاعات در مورد انتخاب و استفاده از الگوریتم گرم اشمیت برای بهبود تفکیک مکانی تصاویر، از جمله جزئیات فنی این روش.

4. عدم ارجاع به مآخذ و منابع مورد استفاده برای ارائه اطلاعات مربوط به شهر سهند و تغییرات زمین‌های بایر به کاربری شهری.

5. عدم بررسی و توضیح جزئیات مربوط به فیلتر اکثریت برای بهبود کیفیت نقشه‌های تغییرات، از جمله توضیحاتی در مورد نحوه اعمال این فیلتر.

6. فقدان توضیحات کافی در مورد معیارها و روش‌های ارزیابی کمی نقشه‌های تغییرات، از جمله معیارهایی که برای این ارزیابی استفاده شده‌اند.

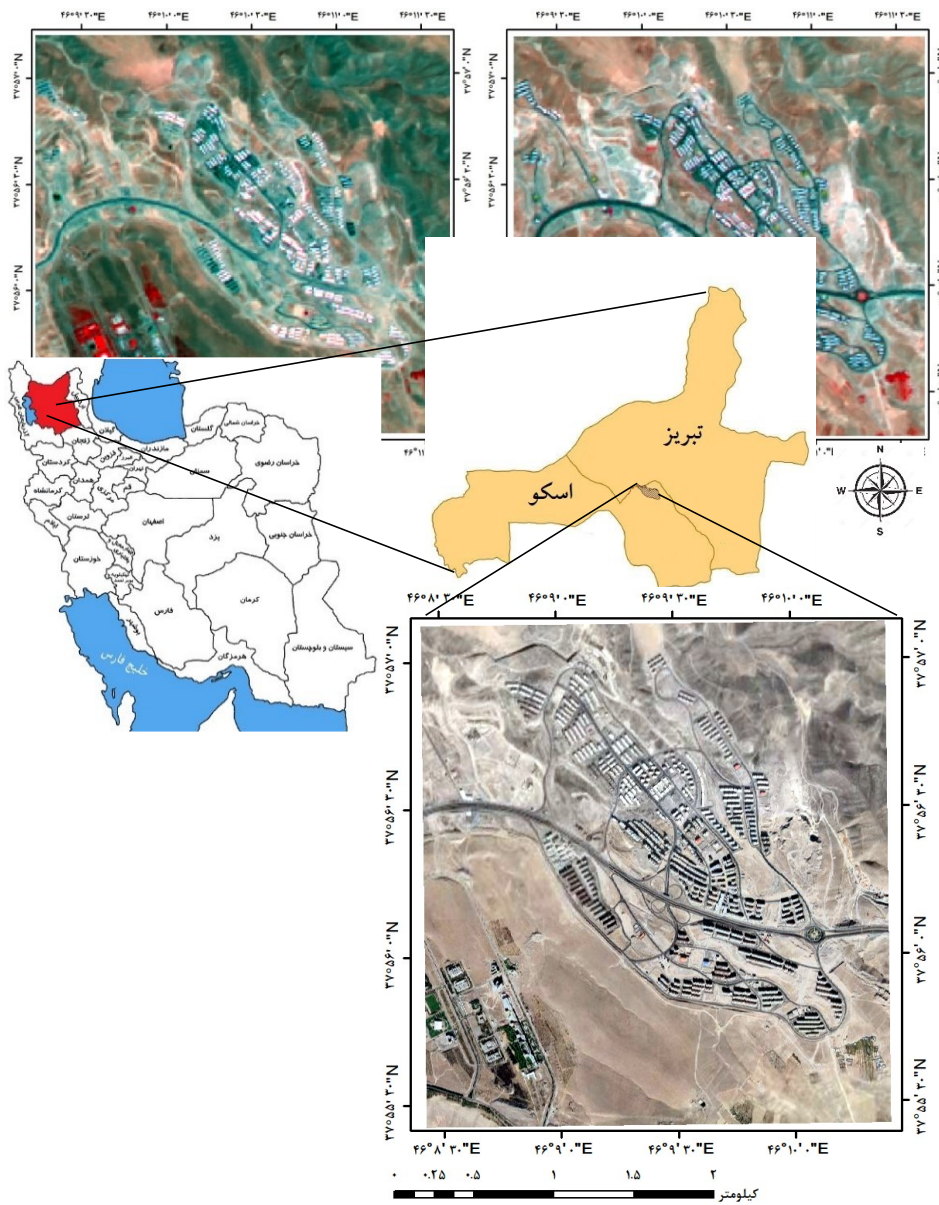
با توجه به موارد فوق، ارائه توضیحات دقیق‌تر و جامع‌تر در مورد روش‌ها و مواد، ارجاع به منابع مورد استفاده، بررسی چالش‌ها و محدودیت‌ها، و ارائه پیشنهادات و توصیه‌های مبتنی بر نتایج، می‌تواند کیفیت و قابلیت اطمینان پژوهش را افزایش دهد.

علاقمند درجه لازم است: **Commented [۲۵]**

مسئله باعث توسعه سریع شهر سهند در چند دهه اخیر گشته است. شکل ۱ موقعیت شهر سهند در تقسیمات کشوری را نشان می‌دهد.

شکل ۱- موقعیت شهر سهند در تقسیمات کشوری (تصویر از گوگل ارث اخذ شده است)

Fig. 1- The location of Sahand city within the country's divisions (The image is from Google Earth)



شکل ۲- از راست به چپ ترکیب رنگی کاذب تصویر اخذ شده در سال ۲۰۲۱ و ترکیب رنگی کاذب تصویر اخذ شده در سال ۲۰۱۳


سنجنده لندست-۸ از شهر سهند

Fig. 2- The images are from right to left, false color combinations of images taken in 2021 and 2013 Landsat-8 sensors from Sahand city, respectively

شهر سهند تغییرات زیادی داشته است که غالباً تغییرات در راستای تغییرات زمین‌های بایر به کاربری شهری بوده است. این منطقه در گذشته به صورت یک منطقه کاملاً بایری بوده که منطقه‌ای مناسب برای احداث شهر را فراهم کرده است. با مرور زمان کلاس‌های پوششی جدید مانند ساختمان، راه‌های ارتباطی و پوشش گیاهی نیز به کلاس بایر افزوده شدند. شکل ۲ ترکیب رنگی کاذب تصاویر جمع‌آوری شده از شهر سهند را نشان می‌دهد. در کل بر اساس نوع کلاس‌های موجود در این منطقه، ۴ کلاس موضوعی غالب شامل: ۱- راه‌های ارتباطی، ۲- خاک بایر، ۳- پوشش گیاهی، ۴- بلوک‌های ساختمانی، در نظر گرفته شده و تغییرات محتمل بین آن‌ها مورد مطالعه قرار گرفت.

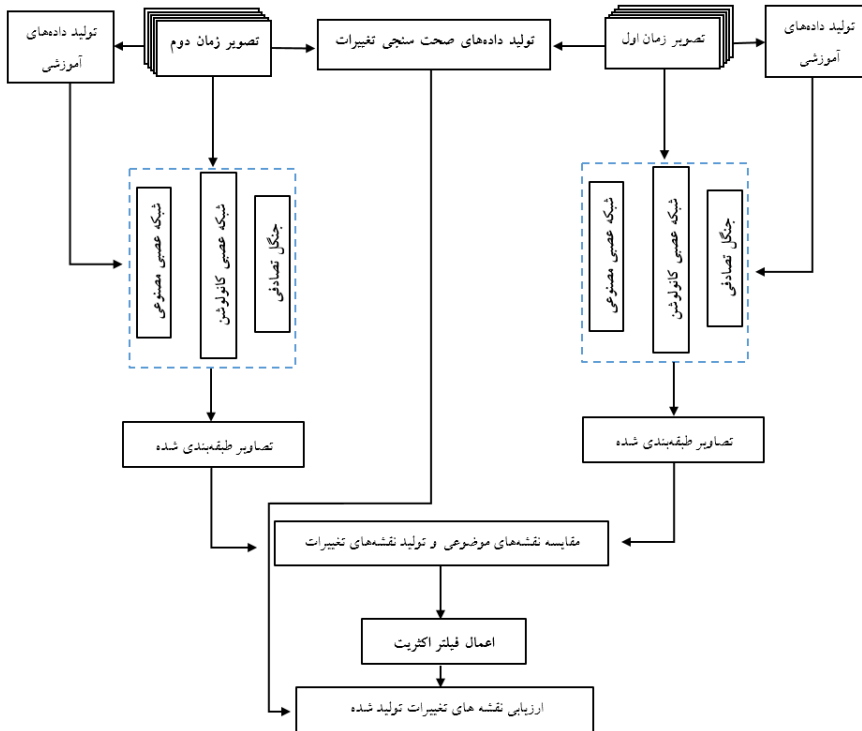
### روش تحقیق

در تحقیق حاضر، به منظور بررسی و پایش تغییرات رخداد در منطقه شهری شهر سهند، علاوه بر ارائه روش یادگیری عمیق پیشنهادی از الگوریتم‌های شبکه عصبی مصنوعی و جنگل تصادفی برای اثبات قابلیت شبکه پیشنهادی استفاده می‌شود. یادگیری عمیق پیشنهادی بر پایه شبکه‌های عصبی کانولوشن است. شبکه‌های عصبی کانولوشن، بر اساس تعداد لایه‌های تنظیم شده در ساختار خود، ویژگی‌ها را به صورت سلسله مراتبی از طریق اتصالات محلی و وزن مشترک استخراج می‌کنند. معماری این شبکه‌ها به دلیل داشتن توانایی استخراج ویژگی‌های طیفی - مکانی عمیق می‌توانند به عنوان طبقه‌بندی کننده یا استخراج کننده ویژگی برای تشخیص تغییرات استفاده شوند (۱۲). شکل ۳ معماری رایج این شبکه‌ها را نشان می‌دهد.



شکل ۳- معماری متداول شبکه عصبی کانولوشن

Fig. 3- Architecture of conventional neural networks



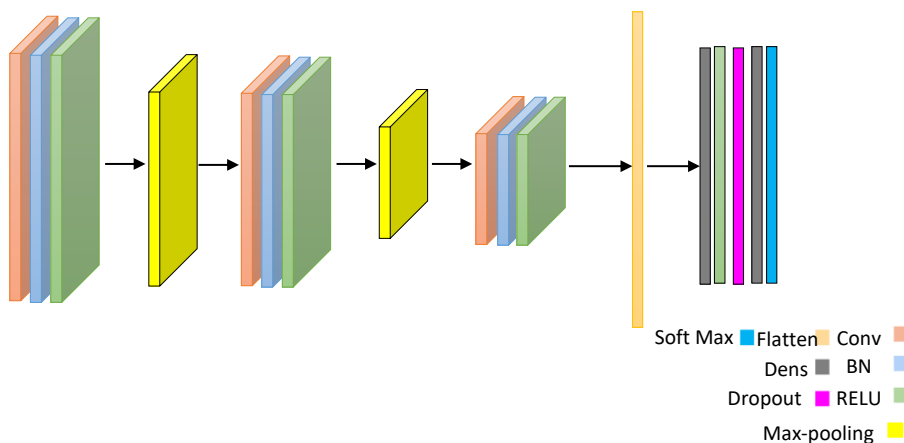
شکل ۴- فلوچارت روش پیشنهادی

Fig. 4- Flowchart of proposed method

در نگاه کلی انتظار می‌رود شبکه‌های شبکه عصبی کانولوشن به دلیل استخراج ویژگی‌های طیفی- مکانی عمیق، نتایجی با دقت بالاتری از روش‌ها کلاسیک ارائه دهند. روند روش پیشنهادی در شکل ۴ ارائه شده است. بر اساس فلوچارت پیشنهادی، با توجه به این‌که تصاویر از سامانه گوگل ارث انجین جمع‌آوری شده‌اند، پیش‌پردازش‌های نظیر هم مرجع‌سازی و تصحیحات رادیومتریکی توسط خود سامانه اعمال شده است. در ابتدا قدرت تفکیک مکانی تصاویر با الگوریتم گرم اشمیت بهبود پیدا می‌کند. در مرحله بعدی، داده‌های واقعیت زمینی جمع‌آوری می‌شوند. این داده‌ها به دو مجموعه داده‌های آموزشی و آزمایشی تقسیم می‌شوند. مرحله سوم، مرحله طبقه‌بندی تصاویر با داده‌های آموزشی است. با مقایسه تصاویر طبقه‌بندی شده، نقشه‌های تغییرات تولید می‌شوند. برای بهبود کیفیت نقشه‌های تغییرات به دست آمده از فیلتر اکثریت استفاده می‌شود. در انتها با کمک داده‌های آزمایشی ارزیابی کمی نقشه‌ها انجام می‌گیرد.

#### معماری شبکه پیشنهادی

در به‌کارگیری تصاویر لندست-۸، هرچقدر بتوان قدرت تفکیک مکانی تصاویر را بالاتر برد، انتظار می‌رود پیکسل‌های نسبتاً خالصی داشته باشیم. این امر طبقه‌بندی تصاویر را نسبت به حالت اولیه بهتر می‌کند. در نتیجه نتایج پایش تغییرات بهبود می‌یابد. در این راستا، فرآیند پین شارپ‌نینگ برای بهبود قدرت تفکیک مکانی باندها صورت گرفت. معماری مورد استفاده در تحقیق دارای سه لایه کانولوشن با تعداد فیلتر ۱۲۸-۶۴-۳۲، ۱۲۸ نرون در لایه پنهان، لایه حذف تصادفی با نرخ ۰/۳ می‌باشد. در شکل ۵ ساختار معماری شبکه پیشنهادی ارائه شده است.



شکل ۵- معماری شبکه عصبی کانولوشن پیشنهادی  
Fig. 5- Proposed convolution neural network architecture

در ادامه توضیحاتی در مورد شبکه عصبی کانولوشن ارائه شده است.

#### شبکه عصبی کانولوشن:

به‌طور کلی، شبکه‌های عصبی کانولوشن یک نوع خاص از شبکه‌های عصبی هستند که شامل سه لایه اساسی کانولوشن، ادغام حداکثری و کاملاً متصل هستند. در ادامه به تفکیک در مورد هر لایه و موارد مربوط به آن‌ها توضیح داده می‌شود.

لایه کانولوشن (Conv):

در این لایه، چند هسته کانولوشن قابل آموزش (که فیلتر نیز نامیده می‌شوند) به تصویر ورودی اعمال می‌شوند. هدف از وزن این هسته‌ها اتصال واحدها در یک نقشه ویژگی با لایه قبلی است. در نتیجه کانولوشن با اتصالات محلی ویژگی‌ها، شناسایی و رفتار آن‌ها به نقشه‌های ویژگی نگاشت می‌شوند. لایه کانولوشن از فیلترهایی استفاده می‌کند که عملیات کانولوشن را در هنگام پوشش ورودی نسبت به ابعادش اجرا می‌کند. خروجی حاصل شده از کانولوشن نقشه‌ی ویژگی نامیده می‌شوند. انباشت لایه‌های کانولوشن مختلف، عمق شبکه‌ها را افزایش می‌دهد که نقشه‌های استخراج شده را ساختاری تر می‌کند. لایه‌های اولیه ویژگی‌های سطح پایین برای مثال لبه‌ها را استخراج می‌کند، در حالی که، لایه‌های بعدی ویژگی‌های تولید شده به صورت شکل، قطعات یا اشیا هستند. اگر فرض کنید که  $ml$  نشان‌دهنده تعداد فیلترها کانولوشن در لایه  $l$  شبکه و آرایه  $x_{l-1}^n$  مربوط به  $n$  امین ورودی لایه  $l$  باشد. بردار ویژگی خروجی  $k$  ام لایه  $l$  که با  $z_l^k$  نشان داده می‌شود، می‌تواند طبق رابطه ۱ محاسبه شود (۲۴ و ۹۸).

$$z_l^k = \left[ \sum_{n=1}^{ml-1} w_l^{k,n} \otimes x_{l-1}^n \right] + b_l^k \quad [1]$$

که در آن  $b_l^k$  ماتریس بایاس،  $w_l^{k,n}$  فیلتری را نشان می‌دهد که نقشه ویژگی  $ml$  را در لایه قبلی  $(l-1)$  به نقشه ویژگی  $k$  ام در لایه  $l$  متصل می‌کند و  $\otimes$  عملگر کانولوشن را نشان می‌دهد. شکل ۶ نحوه عملکرد کرنل  $3 \times 3$  کانولوشن بر روی تصویر یا ویژگی ورودی





را نشان می‌دهد.

12	20	30	0	22
255	47	2	92	11
8	12	2	0	90
34	70	32	4	120
112	100	25	12	50

57	138	163
-188	81	-49
145	51	34

-1	-1	1
0	1	-1
0	1	1

شکل ۶- نحوه عملکرد کرنل  $3 \times 3$  کانولوشن دو بعدی

بر روی تصویر ورودی


Fig. 6 -  $3 \times 3$  convolution performs on two-dimensional the image

به‌طور معمول پس از عملیات کانولوشن، یک تابع فعال‌ساز غیرخطی بر روی هر المان از نتیجه کانولوشن اجرا می‌شود که طبق رابطه ۲ محاسبه شود.

$$y_i^k = f(z_i^k) \quad [۲]$$

لایه ادغام (pooling):

هدف از این مرحله جایگزینی خروجی شبکه در برخی موقعیت‌های خاص با خلاصه آماری مربوط به همسایگی این مکان است. ادغام، یک عمل نمونه‌گرفتنی است که معمولاً بعد از یک لایه کانولوشن اعمال می‌شود، که تا حدی منجر به ناوردایی مکانی و کاهش تعداد پارامترهای شبکه می‌شود. هر آنچه ثابت می‌ماند یک ناوردا است. در واقع ناوردایی عبارت است از تغییر نکردن کمیت‌ها در حین مراحل در لایه ادغام می‌توان از اپراتورهای مختلف استفاده کرد که پرکاربردترین آن‌ها ماکزیمم می‌باشند. نحوه عملکرد این توابع بر روی داده ورودی در شکل ۷ نشان داده شده است (۹۸ و ۲۴).



شکل ۷- نحوه عملکرد ادغام ماکزیمم

Fig7. - Max pooling layer

در میان این لایه‌ها در برخی موارد از لایه‌هایی نظر نرمال‌سازی بچ و حذف تصادفی نیز استفاده می‌شود. در ادامه توضیح مختصری از این دو لایه ارائه می‌گردد.

نرمال‌سازی بچ (Bath Normalization):

فعال‌وانفعالاتی که در لایه‌های اول صورت می‌گیرد باعث اعمال تغییرات در توزیع داده ورودی به شبکه می‌گردد و زمانی که عمق زیاد باشد، این تأثیرات به شدت زیاد می‌شوند که در لایه‌های بالاتر توزیع ورودی دستخوش تغییرات زیادی خواهد شد. به عبارت دیگر وزن‌ها و پارامترهای قبلی همه روی ورودی‌ای که به یک لایه در عمق  $X$  می‌رسد تأثیر می‌گذارند و این موضوع موجب بروز مشکلی می‌شود. نرمال‌سازی بچ برای حل این مشکل (به‌طور خاص کاهش این تغییر توزیع) ارائه شده است. با استفاده از نرمال‌سازی بچ شبکه حساسیت کمتری به مقاردهای اولیه وزن‌ها خواهد داشت و همین‌طور از نرخ یادگیری به مراتب بالاتری می‌توان استفاده کرد (۴).

حذف تصادفی (Dropout):


نام درست فارسی انتخاب شود: [5] Commented

حذف تصادفی یک روش تنظیم مدل، برای کاهش بیش برآزش در شبکه‌های عصبی است. پدیده بیش برآزش در واقع زمانی رخ می‌دهد که شبکه به خوبی توسط داده‌های آموزشی آموزش می‌بیند. درحالی‌که در ارزیابی با داده‌های آزمایشی، شبکه آموزش دیده نتایج ضعیف‌تری ارائه می‌دهد. به چنین شرایط پیش آمده، بیش برآزش گفته می‌شود. در روش حذف تصادفی هر بار که وزن‌ها بروز می‌شوند یک سری از آن‌ها را به صورت تصادفی از پروسه یادگیری حذف می‌شوند (۴).

تمام متصل (FC):

نام درست فارسی انتخاب شود: [6d] Commented

نقشه‌های ویژگی خروجی لایه قبلی مسطح شده و برای لایه‌های کاملاً متصل فراهم می‌شوند. این لایه‌ها برای استخراج اطلاعات سطح بالاتر با تغییر شکل نقشه‌های ویژگی به یک بردار  $n$  بعدی استفاده می‌شوند. لایه تمام متصل بر روی ورودی مسطح به طوری که هر ورودی به تمامی نرون‌ها متصل است عمل می‌کند. شکل ۸ ساختار این بخش را نشان می‌دهد. این بخش همان ساختار شبکه‌های عصبی مصنوعی معمول است که متشکل از لایه ورودی، لایه‌های پنهان و لایه خروجی می‌باشد (۹۸ و ۲۴).



شکل ۸- ساختار بخش لایه تمام متصل

Fig.8 - The fully connected layer

بیشینه هموار (softmax):

در آخرین لایه شبکه، به نام لایه طبقه‌بندی، نرون‌ها به طور خودکار در نقشه‌های ویژگی خروجی  $C$  که متناظر با تعداد کلاس‌ها هستند، جمع می‌شوند. سپس، با استفاده از یک تابع بیشینه هموار، خروجی لایه طبقه‌بندی  $L$  به خطاهای توزیع احتمال (نرمال شده) تبدیل می‌شود. به طور خاص، توزیع احتمال کلاس‌ها از طریق رابطه ۳ محاسبه می‌شود (۱۸).

$$p_c = \frac{\exp(y_L^c)}{\sum_{c'=1}^C \exp(y_L^{c'})} \quad [3]$$

که در آن احتمالات محاسبه شده در محدوده ۰ تا ۱ هستند و مجموع همه احتمالات برابر با ۱ است.

معیارهای ارزیابی

به بخش قبلی منتقل شود: [8d] Commented

یکی از بخش‌های مهم در تمامی فرایندهای سنجش از دوری، ارزیابی دقت نتایج حاصل شده می‌باشد. دقت طبقه‌بندی بیانگر سطح اعتماد به نقشه استخراج شده می‌باشد. پارامترهای متعددی با توجه به ماهیت نتایج مورد بررسی بکار گرفته شده‌اند. تمامی پارامترهای موجود از ماتریس ابهام محاسبه می‌شوند. از متداول‌ترین این پارامترهای می‌توان به دقت کلی اشاره کرد. دقت کلی طبق رابطه ۴ محاسبه می‌گردد.

$$O.A = \frac{\sum_{i=1}^C n_{ii}}{n} \quad [4]$$

که در رابطه بالا  $C$  تعداد کلاس‌ها،  $n$  تعداد پیکسل‌های معلوم در داده مرجع و  $n_{ii}$  اعضای قطر اصلی ماتریس ابهام می‌باشند. دقت کلی نمی‌تواند معیار خوبی برای ارزیابی باشد چراکه در این شاخص وابسته به ابعاد کلاس‌ها می‌باشد. یکی دیگر از پارامترهای شناخته شده ضریب کاپا است که به صورت دقیق‌تر نتایج را ارزیابی و محدودیت شاخص دقت کلی را برطرف می‌کند. طبق رابطه ۵ این شاخص محاسبه می‌گردد (۱۸).

Moved down [1]: ۱۱

نتایج ۱۱

داشتن شناخت کافی از معیارهای ارزیابی، لازمه بررسی و آنالیز نتایج هر یک از روش‌ها می‌باشد. در این راستا در ادامه معیارهای ارزیابی به طور مختصر توضیح داده می‌شوند. ۱۱

$$K = \frac{n \sum_{i=1}^C (n_{ii}) - \sum_{i=1}^C (n_i \times n_{:i})}{n^2 - \sum_{i=1}^C (n_i \times n_{:i})} \quad [5]$$

که در رابطه بالا n تعداد پیکسل‌های معلوم در داده مرجع،  $n_{ii}$  اعضای قطر اصلی ماتریس ابهام، C تعداد کلاس‌ها،  $n_i$  مجموع عناصر سطر i ام و  $n_{:i}$  مجموع عناصر ستون i ام می‌باشند. این شاخص پیکسل‌های نادرست طبقه‌بندی‌شده را مدنظر قرار می‌دهد. در ارزیابی نتایج باینری از معیارهای دیگری برای بیان قابلیت روش استفاده می‌شود. بر این اساس با توجه به ماتریس خطای ارائه‌شده در جدول ۲، معیارهای F1، فراخوانی (recall) و صحت (precision) از این ماتریس استخراج می‌شوند.

جدول ۱. ماتریس خطا

Table 1. Error matrix

	Positive predicted class	Negative predicted class
Positive actual class	TP	FN
Negative actual class	FP	TN

صحت (precision):

وقتی که مدل نتیجه را مثبت پیش‌بینی می‌کند، این نتیجه تا چه اندازه درست است. زمانی که ارزش FP بالا باشد، معیار صحت معیار مناسبی خواهد بود. در واقع نسبت مقداری موارد صحیح و چه به‌صورت غلط، در آن کلاس طبقه‌بندی کرده است که طبق رابطه ۶ محاسبه می‌شود (۲۹).

$$Precision = \frac{TP}{TP + FP} \quad [6]$$

فراخوانی (recall):

در نقطه مقابل معیار صحت، ممکن است در مواقعی دقت تشخیص کلاس منفی حائز اهمیت باشد به‌عبارت‌دیگر ارزش FN بالا باشد، معیار فراخوانی معیار مناسبی خواهد بود. در واقع نسبت مقداری موارد صحیح طبقه‌بندی‌شده توسط الگوریتم از یک کلاس به تعداد موارد حاضر در کلاس مذکور که طبق رابطه ۷ محاسبه می‌گردد (۲۹).

$$Recall = \frac{TP}{TP + FN} \quad [7]$$

معیار F1:

معیار F1، یک معیار مناسب برای ارزیابی دقت است. این معیار، معیارهای صحت و فراخوانی را با هم در نظر می‌گیرد. طبق رابطه ۸ این معیار برآورد می‌شود (۲۹).

$$F1 = \frac{2 \times (Recall \times Precision)}{(Recall + Precision)} \quad [8]$$

نتایج در سه زیر بخش کلی مورد بررسی قرار می‌گیرند. در ابتدا نتایج حاصل از طبقه‌بندی تصاویر لندست-۸ ارائه و بررسی می‌شود. سپس نتایج حاصل از نقشه‌های تغییرات باینری و نقشه‌های ماهیت تغییرات که بر مبنای مقایسه تصاویر طبقه‌بندی‌شده به‌دست‌آمده‌اند مورد بررسی و آنالیز قرار می‌گیرند.

## نتایج

دانش شناخت کافی از معیارهای ارزیابی، لازمه بررسی و آنالیز نتایج هر یک از روش‌ها می‌باشد. در این راستا در ادامه معیارهای ارزیابی به‌طور مختصر توضیح داده می‌شوند:

## بررسی طبقه‌بندی تصاویر

تصاویر توسط سه روش عنوان‌شده به‌صورت جداگانه طبقه‌بندی می‌شوند. تصاویر طبقه‌بندی‌شده با کمک نمونه‌های آزمایشی و بر

## Moved (insertion) [1]

### Commented [۹۵]:

عدم ارائه توضیحات کافی درباره فرآیند و روش‌های استفاده شده برای پیش‌پردازش تصاویر. مثلاً، توضیحات بیشتری در مورد الگوریتم گرم آشمت و نحوه بهبود تفکیک مکانی تصاویر لازم است.

نبودن اطلاعات دقیق درباره انتخاب متعبرها استفاده از الگوریتم‌های ی بهینه‌سازی یادگیری hyperparameters optimisation. مثلاً، جزئیات مربوط به معماری شبکه‌های عصبی مورد استفاده و توضیحات درباره چگونگی آموزش و اجرای آن‌ها ارائه نشده است.

نبودن توضیحات کافی درباره میزان داده‌های آموزشی و آزمایشی مورد استفاده در روش‌های یادگیری ماشین، که می‌تواند تأثیر بزرگی بر نتایج نهایی داشته باشد. و اهمیت نسبی متغیرها نبودن اطلاعات کافی درباره فرآیند انتخاب و استفاده از پارامترهای مورد استفاده در الگوریتم‌های یادگیری عمیق و شبکه‌های عصبی.

برخی نتایج نیاز به پشتیبانی بیشتر دارند محدودیت‌ها و عوامل احتمالی خطای تحقیق مورد بررسی قرار نگرفته‌اند

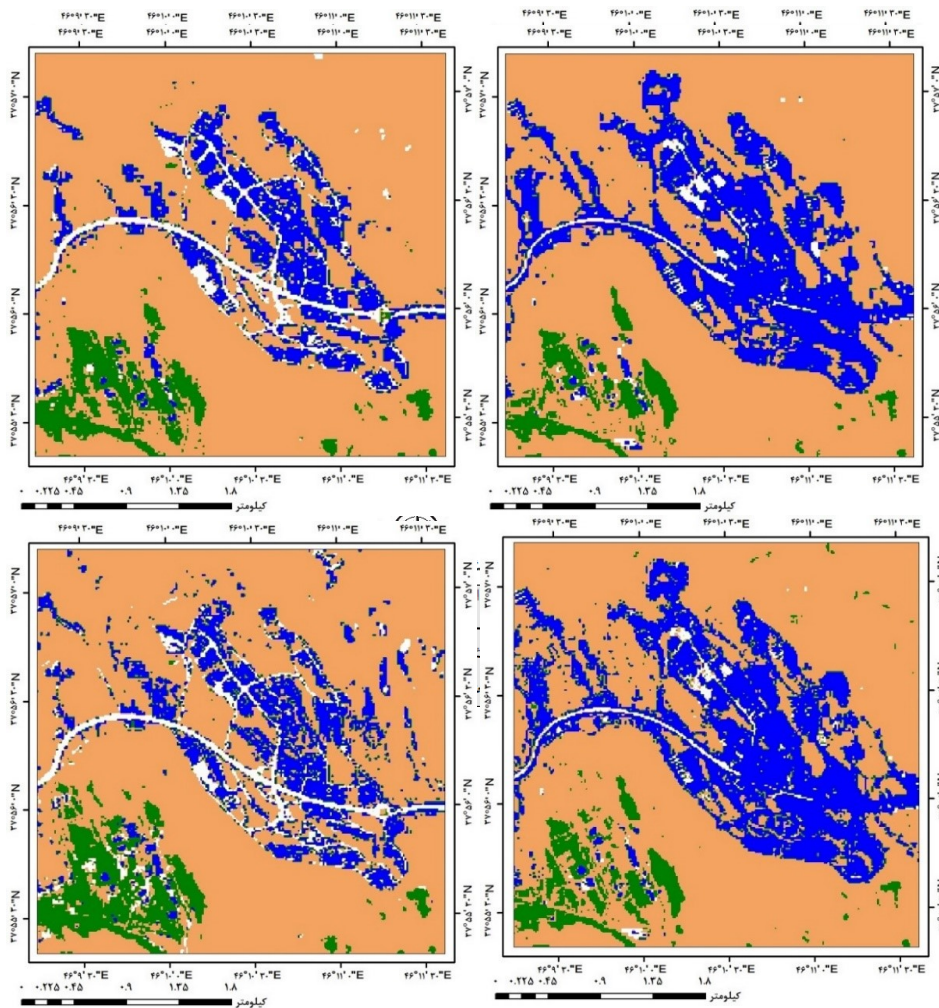
عدم بحث و بررسی در مورد چالش‌ها و محدودیت‌های ممکن در استفاده از شبکه‌های یادگیری عمیق برای تحلیل تصاویر ماهواره‌ای. زبان برخی قسمت‌ها نیاز به ویرایش دارد عدم ارائه پیشنهادات و توصیه‌های مبتنی بر نتایج به‌دست‌آمده برای استفاده‌های عملی و کاربردی در زمینه‌های مختلف مانند مدیریت شهری و حفاظت از محیط زیست.

اساس معیارهای دقت کلی و ضریب کاپا مورد ارزیابی کمی قرار می‌گیرند. نقشه طبقه‌بندی در چهار کلاس موضوعی؛ پوشش گیاهی، خاک بایر، راه ارتباطی و ساختمان تهیه شد. کلاس خاک بایر، که عارضه غالب منطقه می‌باشد، بارنگ قهوه‌ای روشن، کلاس راه ارتباطی بارنگ سفید، کلاس پوشش گیاهی بارنگ سبز و کلاس ساختمان بارنگ آبی نمایش داده شده است. جدول ۲ نتایج حاصل از ارزیابی تصاویر طبقه‌بندی شده توسط روش‌ها در دو سال ۲۰۱۳ و ۲۰۲۱ را نشان می‌دهد. بر اساس نتایج به دست آمده، بالاترین دقت طبقه‌بندی متعلق به شبکه یادگیری عمیق پیشنهادی می‌باشد. دقت‌های حاصله بالای ۹۰٪ هستند. در طرف دیگر، شبکه عصبی مصنوعی فقط توانسته است به میزان ۴٪ الی ۱۳٪ عملکرد بهتری از جنگل تصادفی ارائه دهد. به طور کلی دو روش جنگل تصادفی و شبکه عصبی مصنوعی نتایج ضعیف‌تری داشته‌اند. در شکل ۹ تصاویر طبقه‌بندی شده توسط سه روش نمایش داده شده‌اند.

جدول ۲. ضریب کاپا و دقت کلی طبقه‌بندی تصاویر اصل از سه روش مورد بررسی

Table 2. Kappa coefficient and overall accuracy of images for each classification method

معیارهای ارزیابی		تصاویر طبقه‌بندی شده حاصله از روش‌ها	
ضریب کاپا (درصد)	دقت کلی (درصد)		
۹۱/۵۱	۹۶/۷۵	شبکه یادگیری عمیق پیشنهادی	۲۰۱۳
۷۱/۶۴	۸۷/۹۲	شبکه عصبی مصنوعی	
۶۸/۷۲	۸۶/۸۳	جنگل تصادفی	
۹۲/۷۹	۹۷/۱	شبکه یادگیری عمیق پیشنهادی	۲۰۲۱
۸۷/۰۲	۹۴/۸۹	شبکه عصبی مصنوعی	
۷۷/۰۶	۹۰/۶۲	جنگل تصادفی	



شکل ۹- نقشه‌های موضوعی حاصل از طبقه‌بندی تصاویر؛ به ترتیب سطر اول مربوط به شبکه پیشنهادی، سطر دوم مربوط به شبکه عصبی

مصنوعی، سطر سوم مربوط به جنگل تصادفی - ستون راست مربوط به سال ۲۰۱۳، ستون چپ مربوط به سال ۲۰۲۱

Fig. 9 Classification of pre and post images: the first row represents the results of proposed network with 3 layers, the second row represents the results of artificial neural network, and the third row represents the results of random forest - the right column represents the results of 2013 image, and the left column represents the results of 2021 image.

دلیل رخ داد این رفتار را می‌توان این‌گونه بیان کرد که؛ اساس کار دو روش جنگل تصادفی و شبکه عصبی مصنوعی بر مبنای تک پیکسل می‌باشد. به این نحو که فرایند طبقه‌بندی به صورت پیکسل به پیکسل انجام می‌گیرد و اثر پیکسل‌های همسایه در روند طبقه‌بندی نادیده گرفته می‌شود. به‌طور مثال؛ اگر دو پیکسل کنار هم داشته باشیم که از یک عارضه واحد باشند ولی اختلاف درجات رقومی بالایی داشته باشند، برچسب‌های متفاوت به پیکسل‌ها داده می‌شود که در نهایت دقت طبقه‌بندی را پایین می‌آورد. در مقابل؛ شبکه یادگیری

Commented [۵]: نقشه باید legend داشته باشد

عمیق پیشنهادی با در نظر گرفتن پنجره‌ای در اطراف هر پیکسل، اثر پیکسل‌های کناری را در روند استخراج اطلاعات مکانی-طیفی عمیق و طبقه‌بندی پیکسل‌ها در نظر می‌گیرد. در نتیجه اثراتی نظیر شباهت طیفی و نوسانات پدید آمده در تصاویر را در روند طبقه‌بندی کاهش می‌دهد.

با بررسی بصری نقشه‌های حاصل از طبقه‌بندی توسط جنگل تصادفی و شبکه عصبی مصنوعی، در نواحی که کلاس ما خاک بایر باید باشد برچسب دهی کلاس ساختمان صورت گرفته است. دلیل این امر استفاده صرف از اطلاعات طیفی تصاویر بوده و با شباهت رفتار طیفی خاک بایر روشن به رفتار طیفی ساختمان در برچسب دهی اثر گذاشته و طبقه‌بندی به اشتباه صورت گرفته است. شبکه یادگیری عمیق پیشنهادی با در نظر گرفتن همسایگی پیکسل‌ها و استخراج اطلاعات مکانی-طیفی، نسبت به دو روش دیگر به خوبی کلاس ساختمان را از کلاس خاک بایر متمایز و تفکیک کرده است و برای هر دو زمان نتایج به مراتب بهتری در طبقه‌بندی تصاویر لندست-۸ ارائه داده است.

برای دست‌یابی به یک نقشه تغییرات دقیق، همواره باید طبقه‌بندی تصاویر با دقت و صحت بالایی انجام گیرد. نقشه تغییرات با مقایسه تصاویر طبقه‌بندی شده حاصل می‌گردد. در ادامه نقشه‌های تغییرات حاصل از شبکه یادگیری عمیق پیشنهادی، شبکه عصبی مصنوعی و جنگل تصادفی به همراه نتایج ارزیابی آن‌ها ارائه شده است.

#### بررسی نقشه‌های تغییرات باینری

نقشه‌های تغییرات بر اساس مقایسه پیکسل به پیکسل تصاویر طبقه‌بندی شده دو زمانه تولید می‌شوند. برای بهبود نقشه‌های تغییرات تولید شده، از فیلتر اکثریت با ابعاد پنجره ۵×۵ استفاده می‌گردد. جدول ۳ نتایج حاصل از ارزیابی نقشه‌های تغییرات باینری حاصل از سه روش را نشان می‌دهد.

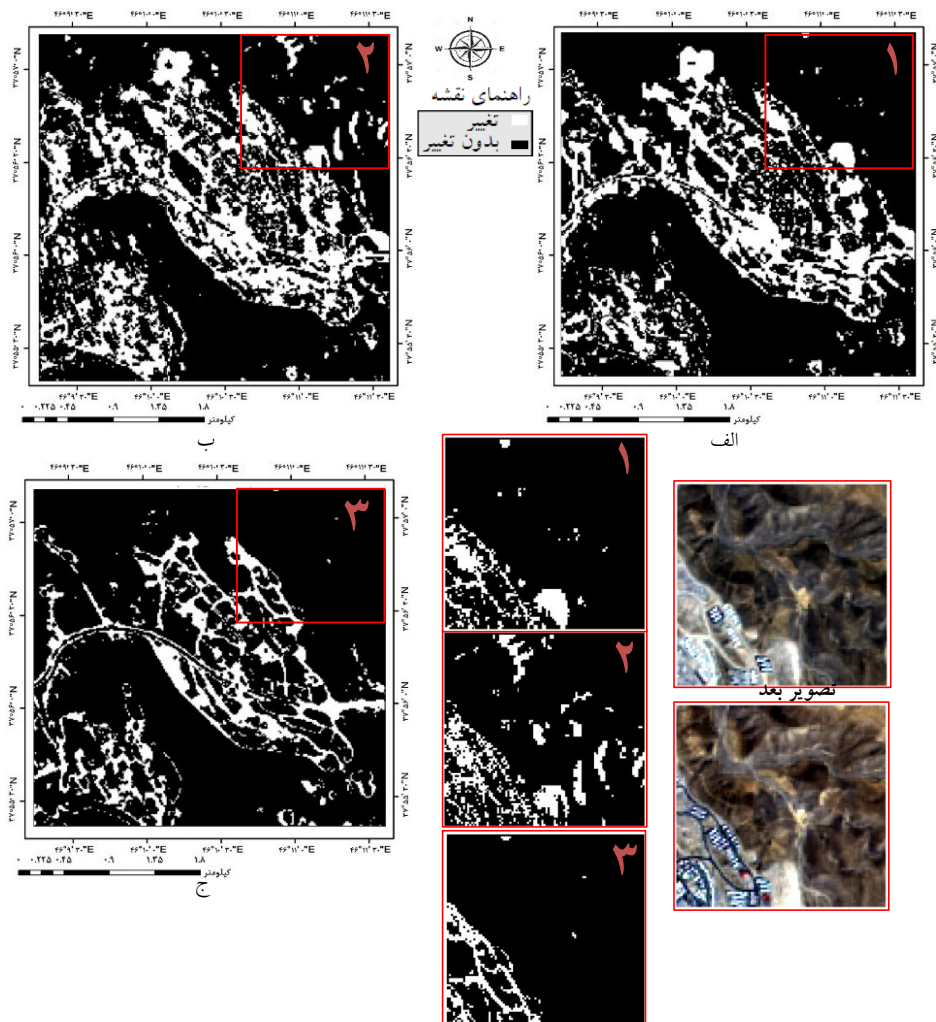
جدول ۳. ارزیابی نقشه‌های تغییرات باینری حاصل شده توسط سه روش پیاده‌سازی شده

Table 3. Accuracy evaluation of three methods for generating binary change maps

معیارهای ارزیابی				نقشه تغییرات حاصله از روش‌ها
دقت کلی (درصد)	ف ۱ (درصد)	فراخوانی (درصد)	صحت (درصد)	
۸۸	۸۶/۴۸	۷۷/۲۸	۹۸/۱۶	شبکه یادگیری عمیق پیشنهادی
۷۴/۱۲	۷۶/۲۰	۶۶/۷۱	۸۸/۸۲	شبکه عصبی مصنوعی
۷۵/۲۰	۷۷/۶۷	۶۹/۴۶	۸۸	جنگل تصادفی

همان‌طور که انتظار می‌رفت، نقشه تغییرات حاصل از شبکه یادگیری عمیق پیشنهادی نتایج بهتری داشته باشد. شبکه پیشنهادی با دقت کلی برابر ۸۸٪، ضریب اف ۱ (F1) برابر ۸۶/۴۸٪، فراخوانی برابر ۷۷/۲۸٪ و صحت برابر ۹۸/۱۶٪ بالاترین امتیاز را در تمام چهار معیار عددی به دست آورده است. دومین جایگاه متعلق به جنگل تصادفی می‌باشد که به طور متوسط ۵ الی ۱۰ درصد نتایج بهتری از شبکه عصبی مصنوعی ارائه داده است. نقشه‌های تغییرات به دست آمده در شکل ۱۰ ارائه شده‌اند. کادر قرمز رنگ مشخص شده بیانگر ناحیه کاندیدی است که توسط جنگل تصادفی و شبکه عصبی مصنوعی در طبقه‌بندی به اشتباه برچسب غیر از خاک بایر داده شده است. در نتیجه نقشه تغییرات باینری تولیدی توسط این دو روش از دقت مناسبی برخوردار نیست. از آنجایی که شبکه پیشنهادی دربرگیرنده اطلاعات طیفی-مکانی می‌باشد نسبت به روش دیگر که صرفاً پیکسل را اساس آنالیز خود قرار داده‌اند خطای کمتر و نتایج بهتری در شناسایی تغییرات دارد. در ناحیه عنوان شده شبکه پیشنهادی تغییرات را با انسجام بهتری و با نویز کمتر ارائه داده است.

تبدیل وضعیت از چه به چه؟ [11]: Commented



تصویر قبل

شکل ۱۰- نقشه‌های تغییرات حاصله به ترتیب؛ الف) شبکه عصبی مصنوعی ب) جنگل تصادفی ج) شبکه یادگیری عمیق پیشنهادی  
 Fig. 10- Produced binary change maps; a) Artificial neural networks b) Random forests c) Proposed deep learning networks

نقشه‌های تغییرات باینری فقط محل وقوع تغییرات را نشان می‌دهند. در نتیجه هیچ اطلاعاتی مبنی بر تغییر نوع پوشش کاربری اراضی زمین ارائه نمی‌دهند. در ادامه نقشه‌های ماهیت تغییرات که اطلاعاتی در زمینه تغییر نوع کلاس‌ها در گذر زمان ارائه می‌دهند به همراه ارزیابی آن‌ها ارائه می‌شود.

#### بررسی نقشه‌های ماهیت تغییرات

با در نظر داشتن چهار کلاس موضوعی پوشش گیاهی، خاک بایر، راه ارتباطی و ساختمان در منطقه و با بررسی تغییرات واقعی در منطقه، ۱۰ کلاس بین ۴ کلاس موضوعی در طرح شناسایی تغییرات به صورت: راه ارتباطی-به-راه ارتباطی، راه ارتباطی-به-ساختمان،

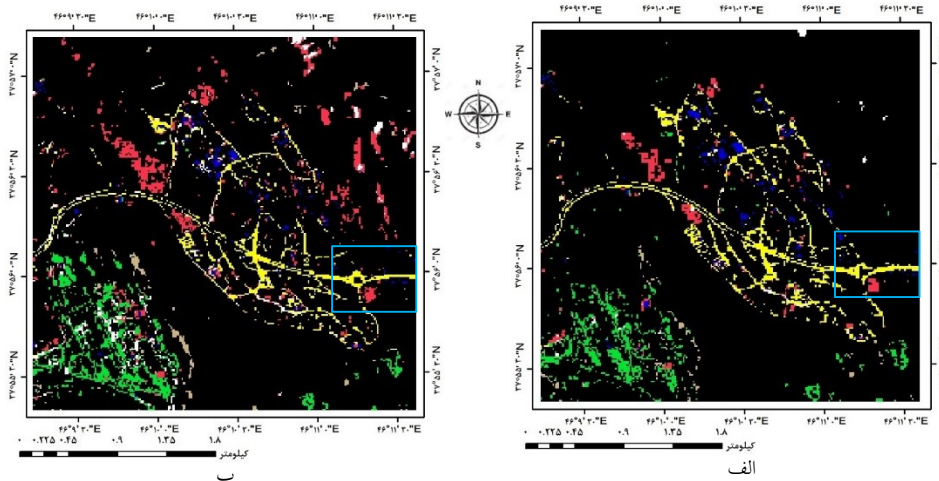
خاک بایر-به-راه ارتباطی، خاک بایر-به- خاک بایر، خاک بایر-به- پوشش گیاهی، خاک بایر-به-ساختمان، پوشش گیاهی-به-خاک بایر، پوشش گیاهی-به-پوشش گیاهی، ساختمان-به- راه ارتباطی، ساختمان-به-ساختمان در نظر گرفته شد. برای سادگی کلاس‌هایی که تغییرات ماهیتی نداشته‌اند به کلاس بدون تغییر اختصاص داده شده است. که در نهایت ۷ کلاس موضوعی تغییر حاصل گردد. شکل ۱۱ نقشه‌های ماهیت تغییرات حاصل شده را نشان می‌دهد. در جدول ۴، نتایج حاصل از ارزیابی نقشه‌های ماهیت تغییرات حاصل از سه روش ارائه شده است. از آنجایی که تصاویر طبقه‌بندی شده توسط شبکه پیشنهادی به واقعیت نزدیک‌تر بودند، نقشه ماهیت تغییرات حاصله نوع تغییرات واقعی رخداد در طی زمان را ارائه می‌دهد. بر اساس نتایج به دست آمده، دقت نقشه ماهیت تغییرات حاصل از شبکه یادگیری عمیق پیشنهادی در مقایسه با نقشه‌های تغییرات حاصل از جنگل تصادفی و شبکه عصبی مصنوعی به ترتیب به میزان ۶۵٪/۷ و ۵۷٪/۸۱ دقت بالاتری داشته است. با اختلاف فراوان شبکه یادگیری عمیق پیشنهادی نسبت به جنگل تصادفی و شبکه عصبی مصنوعی صحت بالایی در پایش تغییرات کاربری اراضی زمین داشته است.

جدول ۴. ارزیابی نقشه‌های ماهیت تغییرات حاصل شده توسط سه روش پیاده‌سازی شده

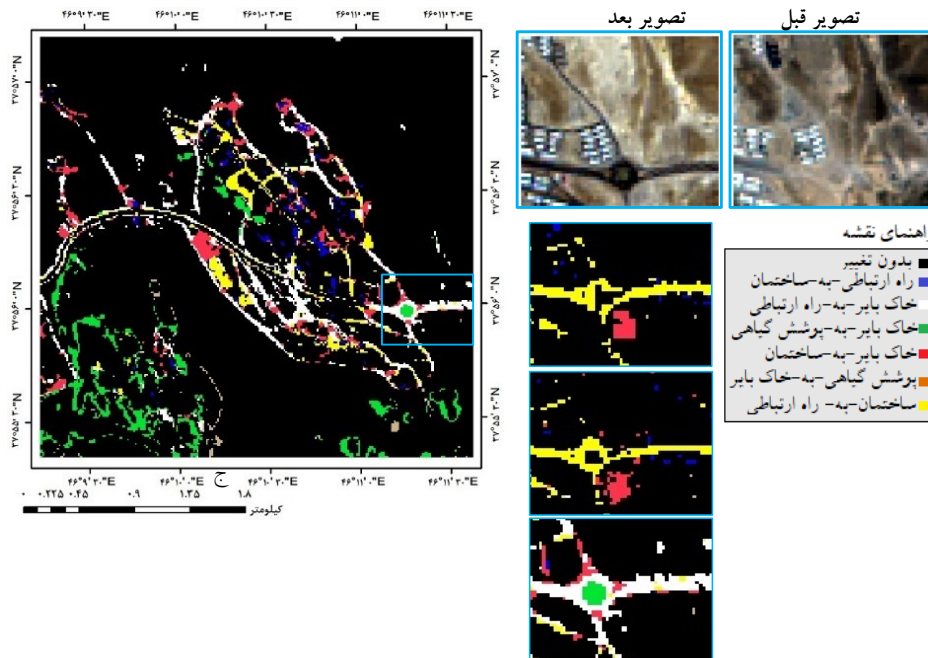
Table 4. Accuracy evaluation of three methods for generating from-to change maps

معیارهای ارزیابی	نقشه تغییرات حاصله از روش‌ها	
ضرب کاپا	دقت	
۹۱٪/۲۸	٪۹۲/۹۷	شبکه یادگیری عمیق پیشنهادی
۱۳٪/۵	٪۲۷/۲۷	شبکه عصبی مصنوعی
۱۷٪/۷	٪۳۵/۱۶	جنگل تصادفی

در نقشه ماهیت تغییرات حاصل از شبکه پیشنهادی کلاس تغییر کاربری خاک بایر-به-راه ارتباطی به درستی شناسایی شده است. کادر آبی رنگ بیان‌کننده بخشی از این تغییر می‌باشد. در حالی که توسط دو روش دیگر به دلیل طبقه‌بندی نادرست کلاس ساختمان در تصویر سال ۲۰۱۳ به اشتباه کلاس ساختمان-به-راه ارتباطی تشخیص داده شده است. دلیل کم‌دقت بودن این دو روش در مقایسه با شبکه پیشنهادی، عدم در نظر گرفتن اطلاعات مکانی در فرآیند طبقه‌بندی می‌باشد. این مسئله در تولید نقشه ماهیت تغییرات حساسیت بالاتری را نشان می‌دهد. روش‌هایی که اطلاعات مکانی-طیفی را مانند شبکه پیشنهادی در روند طبقه‌بندی درمی‌گیرد، می‌توان انتظار داشت که دقت بالاتری در شناسایی تغییرات ارائه دهد.







شکل ۱۱- نقشه‌های ماهیت تغییرات حاصله به ترتیب؛ الف) شبکه عصبی مصنوعی ب) جنگل تصادفی ج) شبکه یادگیری عمیق پیشنهادی  
 Fig. 11- Produced the from-to change maps: a) Artificial neural network b) Random forest c) Proposed deep learning network

بر اساس نقشه ماهیت تغییرات تولیدشده توسط شبکه پیشنهادی، در محدوده زمانی ۱۰ جولای ۲۰۱۳ تا ۱ آگوست ۲۰۲۱ در منطقه مورد مطالعه، در حدود ۱۰۹۳۰۲۷۵ مترمربع از اراضی منطقه، اراضی بدون تغییر شناسایی شدند. عمده این اراضی، مربوط به پستی و بلندی‌های خاکی منطقه می‌باشد که دست‌نخورده باقی مانده‌اند. به‌طور کلی با بررسی نقشه ماهیت تغییرات، سه نوع تغییر کلی در گذر زمان مشاهده می‌شود که بیشترین تغییر را اراضی خاک بایر داشته است. در حدود ۵۵۴۴۰۰ مترمربع از اراضی خاک بایر به راه ارتباطی تبدیل شده است. این تغییرات در راستای اسفالت راه‌های خاکی و همچنین احداث راه ارتباطی جدید بوده است. تبدیل اراضی خاک بایر به راه‌های ارتباطی در راستای محل و نقل راحت‌تر شهروندان شهر سهند بوده که حاکی از افزایش جمعیت شهر است. دومین تغییرات گسترده رخداد در حدود ۳۰۶۹۰۰ مترمربع از اراضی خاک بایر به پوشش گیاهی بوده است که با توجه به این که مناطق جنوبی شامل باغات و زمین‌های کشاورزی بوده به نظر می‌رسد با افزایش جمعیت، افزایش نیاز به مواد غذایی باعث احیای این مناطق طی دهه‌های اخیر شده است. سومین تغییرات گسترده رخداد در حدود ۲۵۲۲۵۰ مترمربع از اراضی خاک بایر به بلوک‌های ساختمانی بوده است. با افزایش جمعیت شهر تبریز، مهاجرت به سوی شهرهایی نظیر شهر سهند افزایش می‌یابد. در نتیجه احداث ساختمان‌ها به‌منظور اسکان مهاجران طی ۸ سال صورت گرفته است.

#### بحث و نتیجه‌گیری

توسعه و گستر بی‌رویه مناطق شهری یکی از عوامل تحدیدکننده محیط‌زیست می‌باشد. رشد بدن برنامه‌ریزی مشکلاتی نظیر کاهش سطح آب‌های زیرزمینی، فرسایش خاک، آلودگی هوا را به دنبال خواهد داشت. با پایش تغییرات در مناطق شهری، فعل و انفعالات انسان با منابع طبیعی قابل درک‌تر خواهد بود.

**Commented [125]:** قالب تقسیم طبق راهنمای نویسندگان تنظیم شود  
 یکی از مقالات لخبیر را مشاهده نمایید

**Commented [125]:** ۱. عدم ارجاع به منابع و مآخذ مورد استفاده جدید و مقایسه نتایج آن برای ارائه اطلاعات در بخش نتیجه‌گیری، که می‌تواند قابلیت اعتماد مطلب را کاهش دهد.

۲. فقدان توضیحات کافی در مورد روش‌های استفاده شده برای تحلیل تغییرات در مناطق شهری، که می‌تواند باعث کاهش قابلیت تکرار و اعتبار پژوهش گردد.

۳. عدم ارائه داده‌های کمی برای مقایسه دقت و کارایی روش‌های مورد استفاده در تحلیل تغییرات، که می‌تواند ارزش علمی مطلب را کاهش دهد.

۴. عدم بررسی دقیق و جامع محدودیت‌ها و چالش‌های موجود در استفاده از شبکه‌های یادگیری عمیق برای تحلیل تغییرات، که می‌تواند اطلاعات کافی به مخاطب ارائه ندهد.

۵. عدم ارائه پیشنهادات و راهکارهای مبتنی بر نتایج به‌دست‌آمده، که می‌تواند ارزش کاربردی مطلب را کاهش دهد و از جلب توجه ارگان‌های مرتبط با موضوع مانع شود.

۶. عدم ارائه پیشنهادات و راهکارهای مبتنی بر نتایج به‌دست‌آمده، که می‌تواند ارزش کاربردی مطلب را کاهش دهد  
 با رفع این ایرادات، دقت و اعتبار مطلب افزایش یافته و ارزش علمی آن بهبود یافته خواهد شد.

در این تحقیق تغییرات برای دست‌یابی به نقشه تغییرات رخ داده بین سال‌های ۲۰۱۳ تا ۲۰۲۱ شهر سهند، از تصاویر ماهواره‌ای لندست-۸ استفاده گردید. با توجه به ساختار منطقه مورد مطالعه، کاربری غالب منطقه را زمین‌های بایر تشکیل داده‌اند که منطقه مناسبی برای توسعه شهری قلمداد می‌شود. اساس شناسایی تغییرات در این پژوهش بر مبنای رویکرد پساتبیه‌بندی بوده، بدین نحو که در ابتدا تصاویر به صورت جداگانه طبقه‌بندی شده و با مقایسه تصاویر طبقه‌بندی شده، نقشه تغییرات حاصل می‌گردد. بر اساس این رویکرد دستیابی به دقت بالا در کشف تغییرات منوط به طبقه‌بندی دقیق تصاویر می‌باشد. تا حتی‌الامکان نقشه تغییرات به دست‌آمده نزدیک به واقعیت باشد. در پژوهشی مشابه رحمانی (۱۵) با استفاده از تصاویر ماهواره لندست به بررسی تغییر کاربری اراضی استان قم پرداخته‌اند، اشکالاتی وجود دارد. به عنوان نمونه در این تحقیق از دو روش طبقه‌بندی حداکثر احتمال و کمترین فاصله استفاده شده است. مبنای طبقه‌بندی این دو روش تک پیکسل بوده و به دلیل عدم توانایی در تفکیک کلاس شهری با زمین‌های نمکی و کلاس زمین بایر با زمین‌های ماسه، تصاویر طبقه‌بندی شده دارای خطا بوده و از اعتبار نتایج کاسته می‌شود. سپهری (۱۷) بررسی تغییرات کاربری/پوشش اراضی شهرهای تفت و مهریز را با استفاده از تصاویر ماهواره لندست انجام داد. در این پژوهش تغییرات با استفاده از شبکه عصبی شناسایی گردید. عمده تمرکز پژوهش بر روی بررسی تغییرات پوشش گیاهی بوده است.

برای پوشش محدودیت‌های تحقیقات مشابه، در تحقیق حاضر شبکه یادگیری عمیق پیشنهاد گردید که به واسطه لایه‌های کانولوشن اطلاعات طیفی-مکانی عمیق را از تصاویر ورودی استخراج کرده و در روند طبقه‌بندی بکار می‌گیرد. وجود اطلاعات مکانی قابلیت تمایز عوارض با رفتار طیفی مشابه را فراهم می‌کند. دو روش دیگر جنگل تصادفی و شبکه عصبی مصنوعی نیز، در جهت اثبات قابلیت شبکه پیشنهادی، برای شناسایی تغییرات در این تحقیق استفاده شد. نتایج طبقه‌بندی تصاویر سال‌های ۲۰۱۳ و ۲۰۲۱ نشان داد، در صورت به‌کارگیری شبکه یادگیری عمیق پیشنهادی به‌طور متوسط دقت کلی و ضریب کاپا در مقایسه با دو روش دیگر به ترتیب به میزان ۷٪ و ۱۸/۵٪ افزایش می‌یابد. نقشه‌های تغییرات در دو فرم نقشه تغییرات باینری و نقشه ماهیت تغییرات تولید شدند. شبکه پیشنهادی به‌طور متوسط ۱۴٪ نسبت به دو روش دیگر دقت بهتری در پایش موقعیت تغییرات رخداد ارائه داده است. از طرفی نقشه ماهیت تغییرات به دست‌آمده توسط شبکه پیشنهادی به‌طور متوسط ۵۶٪ دقت بهتری در مقایسه با نقشه‌های ماهیت تغییرات حاصل از دو روش دیگر ارائه داده است. در نتیجه دو روش دیگر که صرفاً اطلاعات طیفی را بکار گرفته‌اند، نتایجی با دقت پایین ارائه داده و در نتیجه بررسی و آنالیز نقشه‌های ماهیت تغییرات تولیدی برای پی بردن به نوع تغییرات واقعی رخداد در منطقه مناسب نمی‌باشند. نتایج پایش تغییرات رخداد در شهر سهند با نتایج تحقیق صادقی (۱۶) مطابقت دارد. نتایج نقشه ماهیت تغییرات به دست‌آمده از شبکه یادگیری عمیق پیشنهادی، رشد مثبت در کلاس‌های راه ارتباطی، پوشش گیاهی و ساختمان را نشان می‌دهد که با افزایش جمعیت تغییر کاربری خاک بایر به کلاس‌های متناظر عنوان شده منطقی می‌باشد. همچنین عمده نواحی که طی ۸ سال تغییری نداشته‌اند مربوط به کلاس خاک بایری است. دلیل این امر را می‌توان این‌گونه بیان کرد که این مناطق، پستی و بلندی زیادی داشته و مناسب برای شهرسازی نبوده‌اند. در نتیجه توجه چندانی برای تغییر کاربری این نواحی از سوی ارگان‌های دولتی صورت نگرفته است.

یکی از چالش‌های اصلی در بکارگیری شبکه‌های یادگیری عمیق، طراحی یک معماری مناسب برای رسیدن به خروجی مطلوب می‌باشد. عوامل متعددی در نحوه عملکرد شبکه تأثیرگذار هستند. به‌طور مثال می‌توان به تعداد لایه‌های بکارگرفته شده در داخل شبکه اشاره کرد. شاید بتوان یکی از کاستی‌های تحقیق حاضر را ابعاد ثابت پنجره کرنل در کل لایه‌های کانولوشن متصور شد. طراحی یک معماری مناسب علاوه بر این که با آزمون و خطا حاصل می‌شود به شدت به تجربه فرد متخصص وابسته است. پیشنهاد می‌گردد در تحقیقات آتی دو جنبه اصلی برای بررسی کارایی شبکه یادگیری عمیق در نظر گرفته شود. جنبه اول، اعمال ویژگی‌های دیگر نظیر شاخص‌های طیفی به‌عنوان ورودی همراه با باندهای تصاویر به شبکه می‌باشد. جنبه دوم، استفاده از ساختار شبکه عصبی عمیق‌تر در روند تصمیم‌گیری برای برچسب‌گذاری پیکسل‌ها خواهد بود.

## تقدیر و تشکر

این مقاله حاصل پایان‌نامه با عنوان بررسی شناسایی تغییرات از تصاویر چند زمانه لندست با استفاده از پیچ‌های چندگانه در روش‌های یادگیری عمیق در مقطع کارشناسی ارشد در سال ۱۴۰۰ است که با حمایت دانشکاه صنعتی خواجه‌نصیرالدین طوسی اجرا شده است.

#### منابع مورد استفاده

1. Chen H, Wu C, Du B, Zhang L, Wang L. 2020. Change Detection in Multisource VHR Images via Deep Siamese Convolutional Multiple-Layers Recurrent Neural Network. *IEEE Transactions on Geoscience and Remote Sensing*, 58(4): 2848-2864. doi: 10.1109/TGRS.2019.2956756.
2. Daudt RC, Le Saux B, Boulch A, Gousseau Y. 2018. Urban change detection for multispectral earth observation using convolutional neural networks. *International Geoscience and Remote Sensing Symposium (IGARSS)*, 2018-July: 2115-2118. doi: 10.1109/IGARSS.2018.8518015.
3. Erenner A. 2013. Classification method, spectral diversity, band combination and accuracy assessment evaluation for urban feature detection. *International Journal of Applied Earth Observation and Geoinformation*, 21(1): 397-408. doi: 10.1016/J.JAG.2011.12.008.
4. Estoque RC, Murayama Y. 2015. Classification and change detection of built-up lands from Landsat-7 ETM+ and Landsat-8 OLI/TIRS imageries: A comparative assessment of various spectral indices. *Ecological Indicators*, 56: 205-217. doi: 10.1016/J.ECOLIND.2015.03.037.
5. Garbin C, Zhu X, Marques O. 2020. Dropout vs. batch normalization: an empirical study of their impact to deep learning. *Multimedia Tools and Applications*, 79(19): 12777-12815. doi: 10.1007/s11042-019-08453-9.
6. Gislason PO, Benediktsson JA, Sveinsson JR. 2006. Random Forests for land cover classification. *Pattern Recognition Letters*, 27(4): 294-300. doi: 10.1016/J.PATREC.2005.08.011.
7. Ji M, Liu L, Du R, Buchroithner MF. 2019. A Comparative Study of Texture and Convolutional Neural Network Features for Detecting Collapsed Buildings After Earthquakes Using Pre- and Post-Event Satellite Imagery. *Remote Sensing* 2019, Vol 11, Page 1202, 11(10): 1202-1202. doi: 10.3390/RS11101202.
8. Krizhevsky A, Sutskever I, Hinton GE. 2012. ImageNet Classification with Deep Convolutional Neural Networks. In: Pereira F, Burges CJC, Bottou L, Weinberger KQ (eds). Curran Associates, Inc.
9. Li S, Song W, Fang L, Chen Y, Ghamisi P, Benediktsson JA. 2019. Deep learning for hyperspectral image classification: An overview. *IEEE Transactions on Geoscience and Remote Sensing*, 57(9): 6690-6709. doi: 10.1109/TGRS.2019.2907932.
10. Liu S, Marinelli D, Bruzzone L, Bovolo F. 2019. A review of change detection in multitemporal hyperspectral images: Current techniques, applications, and challenges. *IEEE Geoscience and Remote Sensing Magazine*, 7(2): 140-158. doi: 10.1109/MGRS.2019.2898520.
11. Lyu H, Lu H, Mou L, Li W, Wright J, Li X, Li X, Zhu XX, Wang J, Yu L, Gong P. 2018. Long-Term Annual Mapping of Four Cities on Different Continents by Applying a Deep Information Learning Method to Landsat Data. *Remote Sensing* 2018, Vol 10, Page 471, 10(3): 471-471. doi: 10.3390/RS10030471.
12. Ma L, Liu Y, Zhang X, Ye Y, Yin G, Johnson BA. 2019. Deep learning in remote sensing applications: A meta-analysis and review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 152: 166-177. doi: 10.1016/J.ISPRSJPRS.2019.04.015.
13. Mhangara P, Odindi J. 2013. Potential of texture-based classification in urban landscapes using multispectral aerial photos. *South African Journal of Science*, 109(3-4): 1-8. doi: 10.1590/sajs.2013/1273.
14. Mishra PK, Rai A, Rai SC. 2020. Land use and land cover change detection using geospatial techniques in the Sikkim Himalaya, India. *The Egyptian Journal of Remote Sensing and Space Science*, 23(2): 133-143. doi: 10.1016/J.EJRS.2019.02.001.
15. Rohani N, Moradi Faraj A, Mojaradi B, Rajaei T, Jabbari E. 2021. Investigation of land use change in Qom province along with climatic parameters using satellite remote sensing technology. *Journal of RS and GIS for Natural Resources*, 12(4): 28-46. <http://dori.net/dor/20.1001.1.26767082.1400.12.4.2.9>
16. Sadeghi V, Enayati H, Ebadi H. 2016. Improving changedetection in urban areas byselectingthe optimal spectral and spatial features based on genetic algorithm. *Scientific- Research Quarterly of Geographical Data (SEPEHR)*, 24(96): 135-152. (In Persian). doi: 10.22131/sepehr.2016.18949.

17. Sepehri A, Jamali AA, Hasanzadeh M. 2019. Analysis and comparison of land use/land cover changes using artificial neural network (Case study: lands of Taft and Mehriz). *Journal of RS and GIS for Natural Resources*, 10(4): 91-105. (In Persian).
18. Sharifi O, Mokhtarzadeh M, Asghari Beirami B. 2021. A new deep learning approach for classification of hyperspectral images: feature and decision level fusion of spectral and spatial features in multiscale CNN. *Geocarto International 2021* Pages 1-26. doi: 10.1080/10106049.2021.1882006.
19. Shi W, Zhang M, Zhang R, Chen S, Zhan Z. 2020. Change Detection Based on Artificial Intelligence: State-of-the-Art and Challenges. *Remote Sensing 2020*, Vol 12, Page 1688, 12(10): 1688-1688. doi: 10.3390/RS12101688.
20. Tewkesbury AP, Comber AJ, Tate NJ, Lamb A, Fisher PF. 2015. A critical synthesis of remotely sensed optical image change detection techniques. *Remote Sensing of Environment*, 160: 1-14. doi: 10.1016/J.RSE.2015.01.006.
21. Viana CM, Oliveira S, Oliveira SC, Rocha J. 2019. Land Use/Land Cover Change Detection and Urban Sprawl Analysis. *Spatial Modeling in GIS and R for Earth and Environmental Sciences*: 621-651. doi: 10.1016/B978-0-12-815226-3.00029-6.
22. Wang W, Li W, Zhang C, Zhang W. 2018. Improving Object-Based Land Use/Cover Classification from Medium Resolution Imagery by Markov Chain Geostatistical Post-Classification. *Land 2018*, Vol 7, Page 31, 7(1): 31-31. doi: 10.3390/LAND7010031.
23. Wu C, Du B, Cui X, Zhang L. 2017. A post-classification change detection method based on iterative slow feature analysis and Bayesian soft fusion. *Remote Sensing of Environment*, 199: 241-255. doi: 10.1016/J.RSE.2017.07.009.
24. Yamashita R, Nishio M, Do RKG, Togashi K. 2018. Convolutional neural networks: an overview and application in radiology. *Insights into Imaging*, 9(4): 611-629. doi: 10.1007/S13244-018-0639-9/FIGURES/15.
25. Yang L, Xian G, Klaver JM, Deal B. 2003. Urban land-cover change detection through sub-pixel imperviousness mapping using remotely sensed data. *Photogrammetric Engineering and Remote Sensing*, 69(9): 1003-1010. doi: 10.14358/PERS.69.9.1003.
26. Ye S, Chen D. 2015. An unsupervised urban change detection procedure by using luminance and saturation for multispectral remotely sensed images. *Photogrammetric Engineering and Remote Sensing*, 81(8): 637-645. doi: 10.14358/PERS.81.8.637.
27. Zhang J, Cheng T, Shi L, Wang W, Niu Z, Guo W, Ma X. 2022a. Combining spectral and texture features of UAV hyperspectral images for leaf nitrogen content monitoring in winter wheat. *International Journal of Remote Sensing*: 1-22. doi: 10.1080/01431161.2021.2019847.
28. Zhang P, Gong M, Zhang H, Liu J, Ban Y. 2019. Unsupervised Difference Representation Learning for Detecting Multiple Types of Changes in Multitemporal Remote Sensing Images. *IEEE Transactions on Geoscience and Remote Sensing*, 57(4): 2277-2289. doi: 10.1109/TGRS.2018.2872509.
29. Zhang X, He L, Qin K, Dang Q, Si H, Tang X, Jiao L. 2022b. SMD-Net: Siamese Multi-Scale Difference-Enhancement Network for Change Detection in Remote Sensing. *Remote Sensing 2022*, Vol 14, Page 1580, 14(7): 1580-1580. doi: 10.3390/RS14071580.
30. ZhiYong L, Liu T, Benediktsson JA, Falco N. 2021. Land Cover Change Detection Techniques: Very-High-Resolution Optical Images: A Review. *IEEE Geoscience and Remote Sensing Magazine*: 2-21. doi: 10.1109/MGRS.2021.3088865.

## Analyzing the Efficiency of the Deep Neural Network in Detecting Urban Changes Using Bi-temporal Landsat-8 Images.

### Abstract

Satellite remote sensing images are widely used to monitor the earth's surface phenomena changes at various periods. For accurate change detection, spatial features can be used as the complement information of spectral features. Hand-craft spatial features such as the co-occurrence matrix features are inefficient in detecting the changes due to the complex structure of satellite images. In the present study, a deep learning-based model is proposed as the alternative to address the problems of classical change detection methods. Deep neural networks are mainly developed for images and hierarchically extracting spatial-spectral features. In this study, Landsat-8 images between 2013 and 2021 were used to evaluate the changes in Sahand city using the proposed deep network. Pre- and post-classified Landsat-8 images are produced using a deep neural network in the first stage. In the second stage, for producing the change maps, the post-classification approach is used in that change maps are produced based on the difference of classified images. Finally, the majority voting technique eliminates the noises in change maps. The proposed method results are compared with those obtained by two classical machine learning methods, random forest, and artificial neural networks. According to the change detection results, the proposed deep learning network improves detection accuracy by 13.88% and 12.80% compared with artificial neural networks and random forests. Compared to the random forest and artificial neural networks, the proposed network has improved the overall accuracy of the from-to-change maps by 57.81% and 65.7%, respectively. Final results demonstrate that although Random forest and artificial neural networks have been able to identify the location of changes, they perform poorly in detecting the from-to changes.

**Keywords:** Change detection, deep learning, convolutional neural network, random forest, artificial neural network

## بررسی کارایی شبکه یادگیری عمیق در شناسایی تغییرات اراضی با استفاده از

### تصاویر دو زمانه لندست-۸

چکیده مبسوط (حداقل ۱۰۰۰ کلمه)

طرح مسئله: با افزایش جمعیت، بشر در راستای تأمین نیازهای خود اقدام به بهره‌برداری از طبیعت کرده است. این گونه فعالیت‌ها منجر به تخریب محیط زیست گردیده است. در نتیجه پایش تغییرات برای حفاظت از طبیعت و مدیریت بهتر فعالیت‌های انسانی امری ضروری است. آنالیز و بررسی تغییرات به صورت میدانی کاری دشوار بوده و در برخی موارد به علت عدم دسترسی به اطلاعات نقشه‌برداری از منطقه، عملاً غیرممکن است. علم سنجش‌ازدور با استفاده از تصاویر چند زمانه ماهواره‌ای اخذ شده از منطقه، امکان پایش تغییرات رخداد در فواصل زمانی مختلف را فراهم کرده است. از این رو سرعت پایش تغییرات نسبت به قبل بهبود چشم‌گیری داشته است. به طور کلی روش‌های شناسایی تغییرات به دو دسته: روش‌های نظارت‌شده و روش‌های نظارت‌نشده تقسیم می‌گردند. روش‌های نظارت‌شده بر اساس به‌کارگیری داده‌های واقعیت زمینی برای آموزش الگوریتم‌های طراحی‌شده، قابلیت بالایی در شناسایی تغییرات دارند. بررسی نتایج تحقیقات نشان داد، استفاده از ویژگی‌های طیفی تصاویر امکان دستیابی به دقت بالا در شناسایی تغییرات را فراهم نکرده است. دستیابی به دقت بالا در شناسایی تغییرات نیازمند به‌کارگیری ویژگی‌های مکانی در کنار ویژگی‌های طیفی است. روش‌های رایج و متداول، ویژگی‌های مکانی را از طریق ماتریس هم‌رخداد تولید کرده و در روند شناسایی تغییرات بکار می‌گیرند. هر یک از این ویژگی‌ها دارای روابط منحصر به فرد بوده و بر اساس این روابط ویژگی‌های مکانی از ماتریس هم‌رخداد استخراج می‌شوند. به‌کارگیری تمامی ویژگی‌های تولید شده باعث افزایش نامطلوب فضای ویژگی می‌شود که نه تنها دقت را بهبود نمی‌دهد بلکه منجر به کاهش دقت نیز می‌گردد. از سوی دیگر تولید این ویژگی‌ها وابسته به انتخاب نوع ویژگی توسط کاربر بوده و همواره متناظر با منطقه مورد مطالعه می‌باشند. این امکان وجود دارد که ویژگی‌های

تولید شده، از ساختار مناسبی برخوردار نباشند و نتوان در فرایند شناسایی تغییرات بکار گرفت.

هدف: برای دست‌یابی به نقشه ماهیت تغییرات، یکی از رایج‌ترین رویکردها، رویکرد پساتبیه‌بندی بوده که برای شناسایی تغییرات در این تحقیق اتخاذ شده است. در این رویکرد برای دستیابی به دقت بالا در شناسایی تغییرات، باید نقشه‌های طبه‌بندی شده دقت بالایی داشته باشند. در نتیجه باید در ابتدا دقت نقشه‌های طبه‌بندی شده را بالا برد. به‌کارگیری ویژگی‌های مکانی در کنار ویژگی‌های طیفی امکان بهبود دقت تصاویر طبه‌بندی شده را فراهم می‌کند. با توجه به محدودیت روش‌های قبل در به‌کارگیری ویژگی‌های مکانی در کنار ویژگی‌های طیفی تصاویر، هدف این تحقیق در راستای برآمدن بر محدودیت روش‌های قبلی مبنی بر استخراج خودکار ویژگی‌های مکانی از تصاویر ورودی است. تمرکز اصلی مقاله حاضر تولید خودکار ویژگی‌های مکانی - طیفی عمیق از طریق شبکه عصبی کانولوشن پیشنهادی و طبه‌بندی آن‌ها به کلاس‌های موردنظر می‌باشد. برای اثبات قابلیت شبکه پیشنهادی، خروجی تصاویر طبه‌بندی شده حاصل از شبکه پیشنهادی با خروجی روش‌های جنگل تصادفی و شبکه عصبی مصنوعی مقایسه گردیده است.

روش تحقیق: با توجه به اینکه تصاویر از سامانه گوگل ارث انجین تهیه شده‌اند، پیش‌پردازش‌های ضروری نظیر هم‌مرج سازی توسط خود سامانه بر روی تصاویر اعمال گردیده است و نیازی به این‌گونه پیش‌پردازش در این تحقیق نیست. با توجه به این‌که قدر تفکیک مکانی باند پانکروماتیک سنجنده لندست-۸ برابر ۱۵ متر و ۸ باند طیفی دیگر قدرت تفکیک مکانی ۳۰ متر می‌باشد، با استفاده از روش گرم اشमित قدرت تفکیک مکانی ۸ بانندی طیفی ۳۰ متر به ۱۵ متر بهبود پیدا می‌کند. این فرایند به فرایند پن شارپنینگ معروف می‌باشد. از تصاویر پن شارپ شده به‌صورت جداگانه داده‌های واقعت زمینی را جمع‌آوری می‌گردند. با توجه به رویکرد پساتبیه‌بندی اتخاذ شده در این تحقیق، تصاویر در دو شاخه جداگانه وارد شبکه پیشنهادی شده و طبه‌بندی بر اساس استخراج ویژگی‌های مکانی عمیق توسط لایه‌های شبکه پیشنهادی صورت می‌گیرد. از دو روش جنگل تصادفی و شبکه عصبی مصنوعی برای ارزیابی روش پیشنهادی بکار گرفته شد. با مقایسه پیکسل به پیکسل نقشه‌های طبه‌بندی شده، نقشه‌های تغییرات در دو حالت کلی نقشه تغییرات باینری و نقشه ماهیت تغییرات از منطقه حاصل گردیده‌اند.

نتایج و بحث: با استفاده از نمونه‌های آزمایشی نقشه‌های طبه‌بندی شده ارزیابی شدند. نتایج ارزیابی نشان داد معماری شبکه پیشنهادی که به ترتیب تعداد فیلترها: ۱۲۸-۶۴-۳۲ به همراه لایه نرمال‌سازی بیچ و ۱۲۸ نرون در لایه اتصال کامل، بالاترین دقت کلی و ضریب کاپا برای ساله‌های ۲۰۱۳ و ۲۰۲۱ را داشته است. به‌طور متوسط در دو سال دقت بالای ۹۲٪ را ارائه داده است. در مقایسه شبکه پیشنهادی با شبکه عصبی مصنوعی، دقت کلی و ضریب کاپا به ترتیب ۸۸٪ و ۲۴٪ در سال ۲۰۱۳، ۲۲٪ و ۵۷٪ در سال ۲۰۲۱ افزایش پیدا کرده و در مقایسه با جنگل تصادفی دقت کلی و ضریب کاپا به ترتیب ۹۲٪ و ۲۷٪ در سال ۲۰۱۳، ۶۴٪ و ۱۵٪ در سال ۲۰۲۱ افزایش پیدا کرده است. دلیل رخ داد این رفتار را می‌توان این‌گونه بیان کرد که: اساس کار دو روش جنگل تصادفی و شبکه عصبی مصنوعی بر مبنای تک پیکسل می‌باشد. به این نحو که فرایند طبه‌بندی به‌صورت پیکسل به پیکسل انجام می‌گیرد و اثر پیکسل‌های همسایه در روند طبه‌بندی نادیده گرفته می‌شود. به‌طور مثال: اگر دو پیکسل کنار هم داشته باشیم که از یک عارضه واحد باشند ولی اختلاف درجات رقمی بالایی داشته باشند، برچسب‌های متفاوت به پیکسل‌ها داده می‌شود که در نهایت دقت طبه‌بندی را پایین می‌آورد. در مقابل؛ شبکه یادگیری عمیق پیشنهادی با در نظر گرفتن پنجره‌ای در اطراف هر پیکسل، اثر پیکسل‌های کناری را در روند استخراج اطلاعات مکانی - طیفی عمیق و طبه‌بندی پیکسل‌ها در نظر می‌گیرد. در نتیجه اثراتی نظیر شباهت طیفی و نوسانات پدید آمده در تصاویر را در روند طبه‌بندی کاهش می‌دهد. نقشه تغییرات باینری حاصل از شبکه یادگیری عمیق پیشنهادی با دقت کلی برابر ۸۸٪، ضریب F1 برابر ۸۶٪/۴۸ و فراخوانی برابر ۷۷٪/۲۸ بالاترین امتیاز را در تمام چهار معیار عددی به دست آورده است. دومین جایگاه متعلق به جنگل تصادفی می‌باشد که به‌طور متوسط ۵ الی ۱۰ درصد در میان سه معیار دقت کلی، ضریب F1 و فراخوانی نتایج بهتری از شبکه عصبی مصنوعی ارائه داده است. ارزیابی دقت نقشه ماهیت تغییرات حاصل از سه روش نشان داد، نقشه ماهیت تغییرات حاصل از شبکه یادگیری عمیق پیشنهادی در مقایسه با نقشه‌های تغییرات حاصل از جنگل تصادفی و شبکه عصبی مصنوعی به ترتیب به میزان ۶۵٪/۷ و ۵۷٪/۸۱ افزایش دقت داشته است. در نتیجه شبکه پیشنهادی عملکرد بالایی در ارائه صحیح ماهیت تغییرات داشته است. در حالی‌که دو روش دیگر ناموفق در ارائه صحیح ماهیت

تغییرات رخ داده بوده‌اند. بر اساس نقشه ماهیت تغییرات تولیدشده توسط شبکه پیشنهادی، در محدوده زمانی ۱۰ جولای ۲۰۱۳ تا ۱ آگوست ۲۰۲۱ در منطقه مورد مطالعه، در حدود ۱۰۹۳۰۲۷۵ مترمربع از اراضی منطقه، اراضی بدون تغییر شناسایی شدند. عمده این اراضی، مربوط به پستی‌وبلندی‌های خاکی منطقه می‌باشد که دست‌نخورده باقی مانده‌اند. به‌طور کلی با بررسی نقشه ماهیت تغییرات، سه نوع تغییر کلی در گذر زمان مشاهده می‌شود که بیشترین تغییر را اراضی خاک بایر داشته است. در حدود ۵۵۴۴۰۰ مترمربع از اراضی خاک بایر به راه ارتباطی تبدیل شده است. این تغییرات در راستای اسفالت راه‌های خاکی و همچنین احداث راه ارتباطی جدید بوده است. تبدیل اراضی خاک بایر به راه‌های ارتباطی در راستای محل و نقل راحت‌تر شهروندان شهر سهند بوده که حاکی از افزایش جمعیت شهر است. دومین تغییرات گسترده رخداد در حدود ۳۰۶۹۰۰ مترمربع از اراضی خاک بایر به پوشش گیاهی بوده است که با توجه به این‌که مناطق جنوبی شامل باغات و زمین‌های کشاورزی بوده به نظر می‌رسد با افزایش جمعیت، افزایش نیاز به مواد غذایی باعث احیای این مناطق طی دهه‌های اخیر شده است. سومین تغییرات گسترده رخ داده در حدود ۲۵۴۲۵۰ مترمربع از اراضی خاک بایر به بلوک‌های ساختمانی بوده است. با افزایش جمعیت شهر تبریز، مهاجرت به سوی شهرهایی نظیر شهر سهند افزایش می‌یابد. در نتیجه احداث ساختمان‌ها به منظور اسکان مهاجران طی ۸ سال صورت گرفته است.

نتیجه‌گیری: همان‌طور که انتظار می‌رفت، استفاده صرف از اطلاعات طیفی تصاویر نتایج چندان دقیق را ارائه نخواهد داد. به‌کارگیری ویژگی‌های مکانی در کنار ویژگی‌های طیفی، تکنیک مناسبی برای بهبود دقت نتایج طبقه‌بندی کلاس‌ها با رفتار طیفی مشابه می‌باشد. از این رو در این تحقیق با توجه به قابلیت شبکه‌های یادگیری عمیق در استخراج خودکار ویژگی‌های طیفی-مکانی، شبکه عصبی کانولوشن پیشنهادی در این تحقیق بکار گرفته شد. شبکه پیشنهادی ویژگی‌های طیفی-مکانی را به صورت خودکار استخراج کرده و در طبقه‌بندی شرکت می‌دهد. نقشه‌های شناسایی تغییرات در دو حالت باینری و از-به بر اساس رویکرد بساطیقه‌بندی تولید گشته‌اند. شبکه پیشنهادی توانایی بالایی در تفکیک عوارض با رفتار طیفی مشابه داشته و دقت بالایی در طبقه‌بندی تصاویر نسبت به تکنیک‌های شبکه عصبی مصنوعی و جنگل تصادفی ارائه داده است. نتایج طبقه‌بندی تصاویر سال‌های ۲۰۱۳ و ۲۰۲۱ نشان داد، در صورت به‌کارگیری شبکه یادگیری عمیق پیشنهادی به‌طور متوسط دقت کلی و ضریب کاپا در مقایسه با دو روش دیگر به ترتیب به میزان ۷٪ و ۱۸/۵٪ افزایش می‌یابد. نقشه‌های تغییرات در دو فرم نقشه تغییرات باینری و نقشه ماهیت تغییرات تولید شدند. شبکه پیشنهادی به‌طور متوسط ۱۴٪ نسبت به دو روش دیگر دقت بهتری در پایش موقعیت تغییرات رخداد ارائه داده است. از طرفی نقشه ماهیت تغییرات به‌دست‌آمده توسط شبکه پیشنهادی به‌طور متوسط ۵۶٪ دقت بهتری در مقایسه با نقشه‌های ماهیت تغییرات حاصل از دو روش دیگر ارائه داده است. نتایج نقشه ماهیت تغییرات به‌دست‌آمده از شبکه یادگیری عمیق پیشنهادی، رشد مثبت در کلاس‌های راه ارتباطی، پوشش گیاهی و ساختمان را نشان می‌دهد که با افزایش جمعیت تغییر کاربری خاک بایر به کلاس‌های مناظر عنوان‌شده منطقی می‌باشند. همچنین عمده نواحی که طی ۸ سال تغییری نداشته‌اند مربوط به کلاس خاک بایری است. دلیل این امر را می‌توان این‌گونه بیان کرد که این مناطق، پستی‌وبلندی زیادی داشته و مناسب برای شهرسازی نبوده‌اند. در نتیجه توجه چندانی برای تغییر کاربری این نواحی از سوی ارقان‌های دولتی صورت نگرفته است.

واژگان کلیدی: پایش تغییرات، طبقه‌بندی تصاویر، شبکه عصبی کانولوشن، ویژگی‌های مکانی (بافت)، جنگل تصادفی، شبکه عصبی مصنوعی

## Analyzing the Efficiency of the Deep Neural Network in Detecting Urban Changes Using Bi-temporal Landsat-8 Images.

### Abstract

**Statement of the Problem:** With the increase of the human population, human intervention in nature to meet their needs has increased. Thus, monitoring change is crucial for conserving nature and better managing human activities. Multi-temporal remote sensing images provide low-cost but efficient tools to monitor the earth's surface changes. By using remote sensing change detection techniques, change monitoring has become faster. Generally, the change detection methods can be divided into two main groups: supervised and unsupervised methods. Supervised methods that rely on labeled samples commonly have outstanding performance in

**Commented [14]:** the proofreading issues in the text:

1. "Bi-temporal" should be "bi-temporal" for consistency in hyphenation.
2. In the statement of the problem, "increase of the human population" could be rephrased to "increase in the human population" for clarity.
3. The phrase "Multi-temporal" should be hyphenated as "Multi-temporal" for consistency.
4. In the purpose section, "post-classification technique" should be hyphenated as "post-classification technique" for consistency.
5. "Deep spatial-spectral" should be hyphenated as "deep spatial-spectral" for consistency.
6. In the methodology section, "Gram-Schmidt" should be hyphenated as "Gram-Schmidt" for consistency.
7. "Convolution neural network" should be "convolutional neural network" for accuracy.
8. In the results and discussion section, "artificial neural network" should be hyphenated as "artificial neural network" for consistency.
9. In the conclusion section, "deep convolution neural networks" should be "deep convolutional neural networks" for accuracy.
10. "Spatial features (texture)" should be hyphenated as "Spatial features (texture)" for consistency.
11. The keyword "Random forest" should be capitalized as "Random Forest" for consistency with other keywords. These adjustments help maintain consistency and accuracy throughout the text.

**Deleted:** چکیده مبسوط (حداقل ۱۰۰۰ کلمه)

detecting changes, especially in urban areas. According to the literature, spectral features are insufficient to detect changes with high accuracy. To address this issue, spatial features are also incorporated into change detection algorithms. Extracted features from gray-level co-occurrence matrices (GLCM features) are the common spatial features widely used in remote sensing image classification. Although hand-craft features such as GLCM features can improve classification accuracy, they have limitations. First, they are scene-dependent, meaning their performance relies on the underlying scene. Second, produced hand-craft features commonly have a high dimensionality that reduces the performance of statistical classifiers due to the curse of dimensionality phenomena. As the third issue, the parameter tuning of the classical spatial feature generation method is scene-dependent, reducing the applicability of these methods. Deep learning methods are proposed in the literature to address these issues.

**Purpose:** Post-classification technique is one of the most common ways to obtain a from-to map of changes. Classified maps must be highly accurate in this approach to achieve high accuracy in identifying changes. By combining spatial and spectral features, it is possible to improve the accuracy of the classification. Due to the limitations of previous techniques that use spatial features and spectral information of images, this study focuses on the automatic extraction of spectral-spatial features from input images with a deep learning method. The primary purpose of this paper is to automate the production of deep spatial-spectral features and classify them into desired classes using the convolutional neural network. The output of the classified images obtained from the proposed network was compared to those obtained from the random forest and artificial neural network methods to verify the effectiveness of the proposed network.

**Methodology:** Because the images were obtained from the Google Earth Engine system, the necessary preprocessing, such as co-registration, has already been performed on the images. Such preprocessing is not required for this study. The panchromatic band on Landsat-8 has a spatial resolution of 15 meters, and the other eight spectral bands have a spatial resolution of 30 meters. The Gram-Schmidt method can improve the spatial resolution of the eight spectral bands to 15 meters. The next step is to collect ground truth data from pan-sharpened images. The images are entered into two separate branches of the proposed convolution neural network as part of the proposed post-classification approach of this study, and the classification is done by considering the images' joint spatial and spectral characteristics. Two classical machine learning approaches, random forest, and artificial neural network, were used to evaluate the proposed method. The final change maps are created by pixel-by-pixel comparison of the classified maps. This study investigates two modes of change: the binary change map and the from-to-change map.

**Results and discussion:** Classified maps are evaluated using test samples. According to the evaluation results, the proposed network, consisting of 128-64-32 filters and 128 neurons in the fully connected layer, has the highest overall accuracy and Kappa coefficient in the classification of 2013 and 2021 images. During those two years, an average of 92 percent accuracy is achieved. When comparing the proposed network to an artificial neural network, the overall accuracy and Kappa coefficient increased by 8.83 percent and 24.87 percent in 2013, respectively, by 2.21 percent and 5.77 percent in 2021. Compared to the random forest, the overall accuracy and Kappa coefficient increased by 9.92 percent and 27.79 percent in 2013, respectively, and by 6.48 percent and 15.73 percent in 2021. This behavior can be explained as follows: Random forests and artificial neural networks are based on single pixels. Using this approach, the classification process is carried out pixel by pixel, ignoring the influence of the neighbor's pixels. When two pixels are adjacent and have a high numerical degree difference but are from the same complex, different labels are assigned to the pixels, resulting in a decreased accuracy in classification. Contrary to this, the proposed deep learning network considers the effect of adjacent pixels in the process of extracting deep spatial-spectral information and classifying pixels by taking into account a window around each pixel. Consequently, it reduces effects such as spectral similarity and fluctuations in images. The binary change map obtained from the proposed deep learning network has the highest score in all four accuracy criteria, with an overall accuracy of 88 percent, and F1 coefficient of 86.48 percent, and a recall of 77.28 percent. A random forest comes in second, with an average accuracy of 5 to 10% based on the three criteria of overall accuracy, F1 coefficient, and recall better than the artificial neural network. The accuracy evaluation of the from-to-change map obtained from the three methods revealed that the deep learning network's from-to-change map was 65.7 percent and 57.81 percent more accurate than those of the random forest and artificial neural networks. As a result, the proposed network can detect the from-to changes more accurately than the other two methods. From the from-to-change map produced by the proposed network between July 10, 2013, and August 1, 2021, approximately 10930275 square meters of the area's land were identified as unchanged. In most cases, these lands are located in the lowlands and highlands of the region, which have remained relatively untouched. It is generally possible to



observe three types of changes over time based on the from-to-change map. The most significant changes have occurred in barren lands. There are about 554,400 square meters of barren land that have been turned into a road. Changes were made in conjunction with the asphaltting of dirt roads as well as the construction of a new communication road. A transformation of barren land into communication routes in line with the city's location and easier transportation indicates an increase in the number of inhabitants. The second major change occurred in about 306,900 square meters from barren land to vegetation. Since the southern regions contain gardens and agricultural lands, it appears that these areas have been revitalized in recent decades as a result of the increasing population and the growing demand for food. A third major change resulted in the conversion of approximately 254,250 square meters of barren land into building blocks. The population growth in Tabriz will lead to an increase in migration to cities such as Sahand. Consequently, buildings for the accommodation of immigrants have been constructed in less than eight years.

**Conclusion:** As one might expect, using spectral information in images alone will not produce accurate results. In order to improve the accuracy of classification results with similar spectral behavior, spatial features can be used in conjunction with spectral features. In contrast to traditional spatial feature generation methods, which have some limitations, deep convolution neural networks are used in this study to fully explore the spatial and spectral characteristics of remote sensing images. Change detection maps in the two modes of binary and from-to are produced based on the post-classification strategy. To conclude, the proposed network has a higher ability to discriminate the different pixels with similar spectral behavior and, therefore, has higher accuracy than spectral-based random forest and neural network techniques. Comparing the classification results of 2013 and 2021 to those obtained using the two other methods, the proposed deep learning network showed a 7% improvement in overall accuracy and an 18.5% improvement in the kappa coefficient. In terms of monitoring changes in the location of an event, the proposed network provided an average accuracy of 14% greater than the other two methods. As compared to the maps of the nature of changes obtained by the other two methods, the map obtained by the proposed network showed an average improvement of 56% in accuracy. According to the map, the proposed deep learning network resulted in positive growth in communication roads, vegetation, and building classes, which is logical given that barren land is being converted into corresponding classes as the population grows. Moreover, most of the areas that have not changed in 8 years are associated with barren soils. These areas were not suitable for urban development due to their low and high altitudes. Consequently, government bodies have not paid much attention to changing their use of these areas.

**Keywords:** Change detection, Image classification, convolutional neural network, Spatial features (texture), Random forest, Artificial neural network