

شناسایی تغییرات ساختمان‌ها بر مبنای تئوری منطق فازی و مبتنی بر یادگیری عمیق با استفاده از مدل رقومی سطح و تصاویر ارتوفتو

محسن عابدی^۱

محمد سعادت سرشت^۲

رضا شاه‌حسینی^۳

تاریخ دریافت مقاله: ۱۳۹۹/۱۱/۲۷

تاریخ پذیرش مقاله: ۱۴۰۰/۰۹/۰۸

چکیده

امروزه به‌روزرسانی اطلاعات در مناطق شهری اهمیت بالایی دارد، زیرا این اطلاعات، اساس بسیاری از کاربردها را فراهم می‌کند که شامل مطالعات تغییرات پوشش اراضی و مطالعات محیطی است. روش‌های متعددی برای شناسایی تغییرات با به‌کارگیری داده‌های سنجش از دوری توسعه داده شده‌اند و روش‌های جدیدی در حال ظهور هستند. در بسیاری از روش‌های شناسایی عوارض زمینی، این عوارض با استفاده از پیش‌دانشتهایی از جمله ساختار، بافت، خصوصیات بازتابی و غیره شناسایی می‌شوند. هدف از این تحقیق ارائه روشی جهت شناسایی تغییرات ساختمان‌ها در دو منطقه شهری و در بازه‌های زمانی ۵ ساله و ۳ ساله می‌باشد. در این تحقیق با توجه نوع داده‌های مورد استفاده و مناطق مورد مطالعه و تراکم ساختمان‌های شهری، روش شیء‌مبنا برای طبقه‌بندی عوارض و شناسایی ساختمان‌ها استفاده شده است. این روش شیء‌گر، قطعه‌بندی چندمقیاسه است که با استفاده از آن توصیف‌گرهای مناسب طیفی، بافتی و ساختاری استخراج و با استفاده از روش‌های فازی، طبقه‌بندی می‌شوند و پس از طبقه‌بندی در دو اپک و استخراج ساختمان‌های حاصل از طبقه‌بندی، تغییرات ارتفاعی آن‌ها محاسبه می‌شود. روش‌های شناسایی این تغییرات بر مبنای روش مبتنی بر یادگیری عمیق است و ارزیابی آن با استفاده از روش تفاضل DSM می‌باشد. در روش تفاضل DSM با استفاده از یک حد‌آستانه ارتفاعی تغییرات شناسایی می‌شوند، سپس در روش مبتنی بر یادگیری عمیق با استفاده از یک شبکه عصبی کانولوشن بار دیگر با در اختیار داشتن مشخصه‌های ارتفاعی و داده‌های واقعیت زمین ایجاد شده از شناسایی تغییرات در حالت تفاضلی، این تغییرات ارتفاعی آشکار می‌شوند و با تغییرات شناسایی شده در روش تفاضلی ارزیابی می‌شوند. نتایج آزمون‌ها نشان داد با توجه نوع داده مورد استفاده، منطقه مورد مطالعه و تراکم ساختمان‌های موجود، حدود ۹۶٪ ساختمان‌ها از تصاویر هوایی در گام اول شناسایی و استخراج شدند. همچنین در گام دوم شناسایی تغییرات ساختمانی به روش شبکه عصبی با صحت کلی ۹۰٪ انجام شده است.

واژه‌های کلیدی: قطعه‌بندی چندمقیاسه، خوشه‌بندی فازی، یادگیری عمیق، شبکه‌های عصبی کانولوشن.

۱- کارشناسی ارشد دانشکده مهندسی نقشه‌برداری و اطلاعات مکانی، پردیس دانشکده‌های فنی دانشگاه تهران mohsenabedi@ut.ac.ir

۲- دانشیار دانشکده مهندسی نقشه‌برداری و اطلاعات مکانی، پردیس دانشکده‌های فنی دانشگاه تهران msaadat@ut.ac.ir

۳- استادیار دانشکده مهندسی نقشه‌برداری و اطلاعات مکانی، پردیس دانشکده‌های فنی دانشگاه تهران (نویسنده مسئول) rshahosseini@ut.ac.ir

۱- مقدمه

تصاویر ماهواره‌ای با حدتفکیک بالا استفاده کند که امروزه نیاز به استفاده از این روش به مراتب بیشتر احساس می‌شود (sahebi, 2015).

برای شناسایی تغییرات عوارض در بازه‌های زمانی نیز روش‌های بسیار متنوعی ارائه شده است. مبنای اکثر این روش‌ها استفاده از روش‌های تفاضلی و آنالیز آن و در نهایت ایجاد یک حدآستانه مناسب است. همچنین با توجه به گسترش یادگیری ماشین^۴ و به تبع آن یادگیری عمیق^۵، شناسایی تغییرات عوارض زمین با استفاده از این روش‌ها رو به گسترش است. با رشد روزافزون منابع داده‌های سنجش از دوری و فتوگرامتری که داده‌هایی با حجم پردازشی بالا تولید می‌کنند، امکان پردازش و برنامه‌نویسی این نوع داده‌ها فقط با سیستم‌های پردازشی قوی و البته گران‌قیمت وجود دارد که دسترسی همگانی به این نوع سیستم‌ها وجود ندارد. این تحقیق با استفاده از پردازش داده‌ها با حجم محاسباتی بالا در فضاهای ابری رایگان این امکان همگانی را به وجود آورده است.

در این تحقیق با توجه به نوع داده‌های مورد مطالعه و حجم محاسباتی بالا برای پردازش آن‌ها در دو گام شناسایی ساختمان‌ها و شناسایی تغییرات آن‌ها، از روش خوشه‌بندی فازی برای شناسایی ساختمان‌ها با سرعت محاسباتی بالا و از روش یادگیری عمیق بر مبنای پردازش در محیط ابری keras و tensorflow با استفاده از کتابخانه‌های colab.google برای شناسایی تغییرات ساختمان‌ها استفاده شده است.

در این تحقیق در گام اول با توجه به نوع داده مورد استفاده و منطقه مورد مطالعه و تراکم ساختمان‌های شهری روش شیء‌مبنا با استفاده از تئوری منطق فازی برای طبقه‌بندی عوارض و شناسایی ساختمان‌ها استفاده شده است. در گام دوم نیز برای شناسایی تغییرات ساختمان‌ها، از روش مبتنی بر یادگیری عمیق بر مبنای داده‌های ارتفاعی و از روش تفاضل DSM برای ارزیابی روش یادگیری عمیق استفاده شده است. برای شناسایی ساختمان‌ها، ابتدا با استفاده از

امروزه به‌روزرسانی اطلاعات در مناطق شهری اهمیت بالایی دارد، زیرا این اطلاعات، اساس بسیاری از کاربردها را فراهم می‌کند که شامل مطالعات تغییرات پوشش کاربری و مطالعات محیطی است. داده‌های ماهواره‌ای سنجش از دور فرصتی برای به‌دست آوردن اطلاعات از مناطق شهری در دقت‌های مختلف فراهم می‌کند و به‌طور گسترده برای کاربرد شناسایی تغییرات استفاده می‌شود. شناسایی تغییرات^۱ به مجموعه‌ای از فعالیت‌ها برای تعریف تفاوت در وضعیت یک شیء یا پدیده که با مشاهده‌ی آن در طول زمان‌های مختلف صورت می‌گیرد، گفته می‌شود (SINGH, 1989). روش‌های متعددی برای شناسایی تغییرات با به‌کارگیری داده‌های سنجش از دوری توسعه داده شده‌اند و روش‌های جدیدی در حال ظهور هستند. به هر حال شناسایی صحیح عوارض زمینی از داده‌های سنجش از دور اغلب به‌علت اینکه چشم‌اندازهای شهری ترکیبات پیچیده از سطوح مختلف است، دشوار است (Mohammadzade & et al, 2017).

در این میان شناسایی تغییرات ساختمان‌ها که یکی از مهم‌ترین عوارض در مناطق شهری هستند اهمیت ویژه‌ای پیدا می‌کند. برای شناسایی تغییرات این نوع عارضه ابتدا باید به شناسایی آن در بازه‌های مختلف پرداخت و سپس نوع تغییرات به دست آمده را شناسایی کرد. روش‌های مختلفی برای شناسایی عوارض با استفاده از داده‌های فتوگرامتری و سنجش از دوری وجود دارد که می‌توان از میان آن‌ها به دو روش کلی پیکسل‌مبنا^۲ و شیء‌مبنا^۳ اشاره کرد. مبنای روش‌های پیکسل‌مبنا، پیکسل‌های تصویری‌اند در حالی که روش‌های شیء‌مبنا براساس واحدهایی به نام شیء تصویری استوارند که شامل مجموعه‌ای از پیکسل‌ها می‌شوند. روش طبقه‌بندی شیء‌مبنا تا حد وسیعی سنجش از دور را به حوزه‌هایی که منجر به تصمیم‌گیری می‌شوند، وارد می‌سازد و قادر است از پتانسیل اطلاعات نهفته در

1- Change Detection

2- Pixel Base

3- Object Base

4- Machine Learning

5- Deep Learning

۱-۱-۱- مروری بر تحقیقات صورت گرفته

در این بخش به مرور تحقیقات صورت گرفته در دو حوزه شناسایی ساختمان‌ها و شناسایی تغییرات آن‌ها می‌پردازیم.

۱-۱-۱-۱- مروری بر تحقیقات صورت گرفته در حوزه

شناسایی ساختمان‌ها

Vakalopoulou و همکاران با استفاده از تصاویر چندطیفی با قدرت تفکیک مکانی بالا به آموزش شبکه عصبی بر مبنای یادگیری عمیق براساس ویژگی‌های طیفی، بافتی و ساختاری پرداختند و شناسایی اتوماتیک ساختمان‌ها توسط این شبکه عصبی انجام شد. در این تحقیق شناسایی ساختمان‌ها با استفاده از یک طبقه‌بندی نظارت‌شده به دقت بالای ۸۶٪ رسید (Vakalopoulou & et al, 2015). در یک تحقیق دیگر Meng و همکاران با استفاده از داده لایدار و تصاویر هوایی اقدام به جداسازی نقاط زمینی از نقاط غیرزمینی کردند و سپس با محاسبه شاخص NDVI و اعمال آن بر روی عوارض غیرزمینی فیلترشده، یک مدل اولیه ساختمانی را استخراج کردند. سپس با استفاده از الگوریتم‌های شگرها یک طبقه‌بندی بر روی عوارض باقیمانده اعمال شد و بدین ترتیب مدل ساختمان‌ها شناسایی گردید. در این تحقیق دقت کلی ۸۱٪ برای ساختمان‌های مسکونی و دقت کلی ۸۵٪ برای دیگر عوارض باقیمانده به دست آمد (Meng, & et al, 2012). در یک تحقیق دیگر نیز Nahhas و همکاران با تلفیق داده‌های لایدار و تصاویر ارتوفتو و با استفاده از یک تحلیل از نوع مبتنی بر شیء برای ایجاد عارضه و تلفیق آن در سطح ویژگی، ابعاد مبتنی بر روش رمزگذار خودکار برای تبدیل به ویژگی‌های سطح پایین فشرده را کاهش دادند و یک شبکه عصبی کانولوشن را برای تبدیل ویژگی فشرده به ویژگی‌های سطح بالا که برای طبقه‌بندی عوارض به ساختمان‌هاست ایجاد کردند. در این تحقیق دقت کلی ۸۶٪ برای منطقه کاری و دقت کلی ۷۸٪ برای منطقه آزمایشی به دست آمد. این روش پیشنهادی در مقایسه با روش svm دارای دقت بالاتری بود (Nahhas & et al, 2018).

بردار نرمال ارتفاعی عوارض زمینی از عوارض غیرزمینی جدا می‌شوند. سپس با استفاده از قطعه‌بندی چندمقیاسه که بر مبنای قطعه‌بندی شگرها است، توصیف‌گرهای مناسب طیفی، بافتی و ساختاری مربوط به عوارض ساختمانی استخراج می‌شوند. سپس این توصیف‌گرها بر مبنای تئوری منطق فازی طبقه‌بندی شده‌اند و عوارض ساختمانی در دو اپک زمانی ۵ ساله شناسایی می‌شوند. در گام دوم نیز از روش مبتنی بر یادگیری عمیق برای شناسایی تغییرات ساختمان‌ها و از روش تفاضل DSM برای ارزیابی تغییرات شناسایی شده ساختمان‌ها استفاده شده است. در روش تفاضل DSM با استفاده از ساختمان‌های استخراج شده در دو اپک و اعمال ماسک آن‌ها بر مدل رقومی سطح مربوطه، اختلاف دو مدل ارتفاعی ایجادشده از ساختمان‌ها مشخص می‌شود و با استفاده از یک حدآستانه ارتفاعی تغییرات ساختمان‌ها شناسایی می‌شود.

در روش مبتنی بر یادگیری عمیق، با استفاده از یک مدل شبکه عصبی کانولوشن^۱ و آموزش آن، تغییرات ساختمان‌ها در این بازه مشخص می‌شود. در این روش ابتدا با استفاده از مدل رقومی سطح ساختمان‌ها در دو اپک و در نظر گرفتن قسمتی از منطقه مشترک دو اپک، لایه‌های ورودی شبکه جهت آموزش ساخته می‌شوند؛ همچنین تغییرات صورت گرفته در روش تفاضلی نیز به‌عنوان لایه خروجی معرفی می‌شود. در نهایت با آموزش شبکه و معرفی کل منطقه مشترک در دو اپک برای لایه ورودی، این شبکه عصبی آموزش‌دیده اقدام به شناسایی تغییرات می‌کند. همین روند بار دیگر نیز با استفاده از اختلاف دو مدل ارتفاعی ساختمان‌ها اجرا می‌شود. به‌عبارت دیگر فقط یک لایه ورودی برای شبکه در نظر گرفته می‌شود و بقیه روند آن نیز مشابه قبل صورت می‌گیرد. در نهایت این تغییرات شناسایی شده ساختمان‌ها توسط این شبکه عصبی، با تغییرات شناسایی شده در روش تفاضل DSM مورد ارزیابی قرار می‌گیرد.

1- Convolution neural network

۱-۱-۲- مروری بر تحقیقات صورت گرفته در حوزه

شناسایی تغییرات ساختمان‌ها

Walter با قطعه‌بندی بر روی تصاویر ماهواره‌ای و محاسبه توصیف‌گرهای بافتی، طیفی و ساختاری و اعمال یک طبقه‌بندی شیء‌گرا بر روی این توصیف‌گرها اقدام به شناسایی انواع عوارض نظیر جاده‌ها، ساختمان‌ها و گیاهان کرد و در نهایت با مقایسه این عوارض با نقشه‌های رقومی منطقه تغییرات شناسایی شده را مشخص کرد. در این تحقیق درصد تغییرات ۶/۴ در نقشه‌های توپوگرافی با مقیاس ۱:۵۰۰۰۰ در سال در منطقه اروپای غربی مشخص گردید (Walter, 2004).

Awrangjeb با استفاده از داده‌لایدار و روش تحلیل اجزای متصل، تغییرات ساختمان‌ها را شناسایی کرد. آشکارسازی تغییرات صورت گرفته با استفاده از این الگوریتم تحلیلی براساس دسته‌بندی تغییرات بر مبنای تخریب یا نوسازی ساختمان‌ها و پارامترهایی نظیر مساحت، طول، عرض و ارتفاع و تخمین هر جز از آن‌ها بود. او در این تحقیق به خطای مربع باقیمانده‌ها با مقدار ۲/۲ در اپک اول و ۱/۹ در اپک دوم بر مبنای پیکسل رسید (Awrangjeb & et al, 2015).

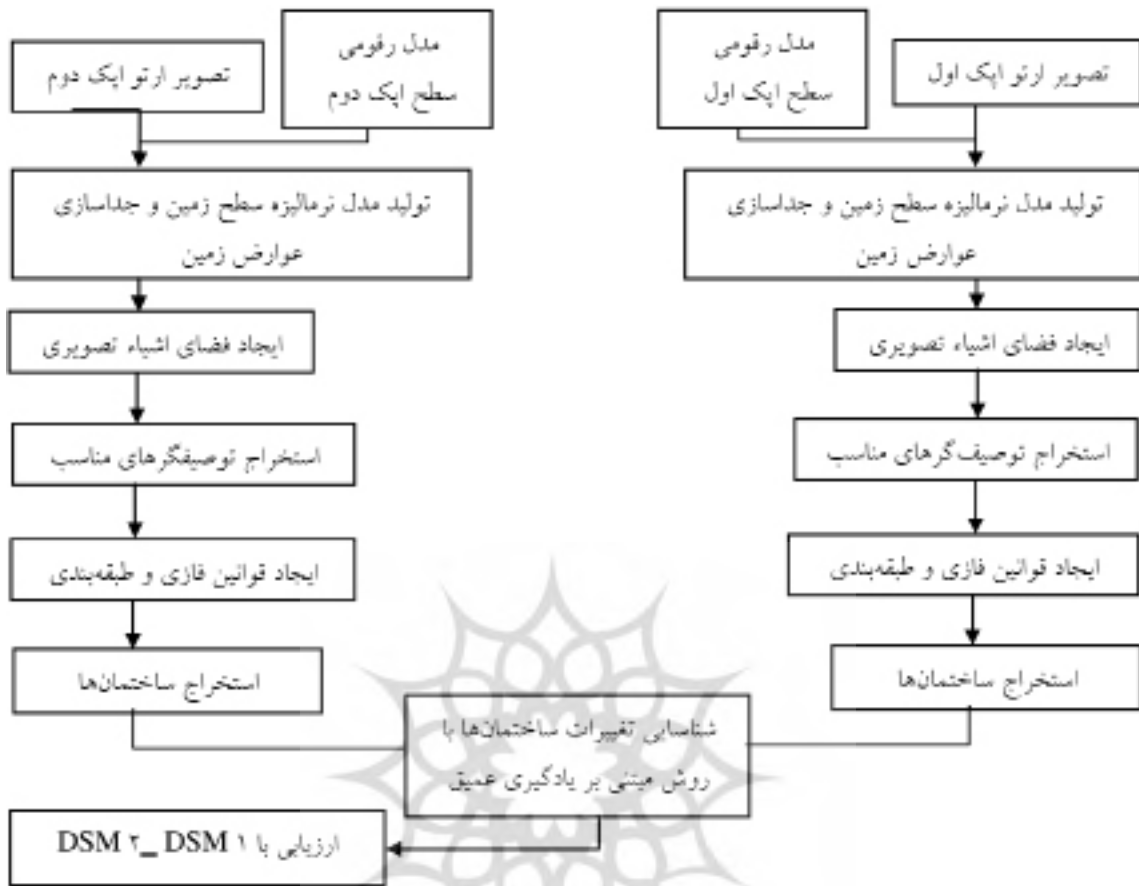
Zong با تلفیق داده‌های لایدار و تصاویر هوایی یک مدل اولیه آشکارسازی تغییرات ساختمان‌ها را با استفاده از یک تکنیک سلسله‌مراتبی در سطح پیکسل ایجاد کرد، سپس اصلاح نتایج اولیه آشکارسازی را با اعمال یک پردازش نهایی بر روی سایه‌ها و اندازه ساختمان‌های تغییر یافته اصلاح کرد. او در این تحقیق به دقت کلی ۹۹٪ و نرخ هشدار اشتباه ۰/۱٪ به دلیل استفاده از توابع خطی، چندجمله‌ای و گوسین در روش‌هایی مثل SVM رسید (Zong & et al, 2013).

با توجه به نوع داده مورد استفاده در تحقیقات صورت گرفته در حوزه شناسایی ساختمان‌ها و تغییرات آن‌ها، روش‌های بسیار متنوع و متفاوتی از آن‌ها ارائه شده است. این روش‌ها که متناسب با هدف تحقیق هر یک از افراد بوده، دارای ویژگی‌های بسیاری برای شناسایی ساختمان‌ها و آشکارسازی تغییرات آن‌ها بود ولی محدود به منطقه مورد

مطالعه و فقط متناسب با تراکم منطقه مورد نظر بود. به‌طور کلی تحقیقات بهتر است بیشتر بر روی بهبود مدل‌های پیشنهادی برای نقشه‌برداری و آزمایش ساختمان‌های بزرگ مقیاس انجام شود. در روش ارائه شده در این تحقیق، با توجه به روش طبقه‌بندی و شناسایی عوارض که بر مبنای تحلیل شیء‌گرا و تئوری منطق فازی است، می‌توان هر عارضه‌ای را با توجه به تابع تعلق آن به یک کلاس خاص به‌صورت عدم قطعیت طبقه‌بندی و شناسایی کرد. همچنین با توجه به آموزش قوی یادگیری عمیق در حوزه‌های شناسایی، می‌توان این روش را به‌عنوان یک روش مناسب برای شناسایی تغییرات ارائه کرد که در این تحقیق از آن استفاده شده است. با توجه به اینکه آموزش شبکه‌های عصبی نیازمند پردازنده‌های قوی است که اکثراً گران هستند به جهت حل این مشکل ما از سرویس‌های گوگل کولب که توانایی انجام حجم محاسباتی بالا را به‌صورت رایگان دارند، استفاده شده است. همچنین می‌توان انتظار داشت که شبکه عصبی طراحی شده در این تحقیق بتواند تغییرات صورت گرفته ساختمان‌ها را با توجه به نوع داده آن‌ها که همانند داده‌های این تحقیق باشد شناسایی کند.

۲- روش تحقیق

فلوچارت پیشنهادی روش تحقیق مطابق نگاره (۱) می‌باشد. همانطور که در نگاره (۱) دیده می‌شود ابتدا با تولید مدل نرمالیزه سطح زمین از ابر نقطه ارتفاعی عوارض زمینی از عوارض غیرزمینی جدا می‌شوند؛ سپس یک قطعه‌بندی بر روی عوارض غیرزمینی انجام شده و فضای اشیاء تصویری تشکیل می‌شود. در مرحله بعد توصیف‌گرهای بافتی، طیفی و ساختاری از این فضا استخراج می‌شوند، سپس با استفاده از قوانین فازی این توصیف‌گرها طبقه‌بندی و ساختمان‌ها از این طبقه‌بندی استخراج می‌گردند. این روش برای هر دو اپک زمانی اجرا می‌شود و ساختمان‌ها برای هر دوی این اپک‌ها استخراج و در نهایت تغییرات آن‌ها شناسایی می‌شود. شناسایی تغییرات ساختمان‌ها نیز براساس روش



نگاره ۱: فلوجارت روش تحقیق

مبتنی بر یادگیری عمیق صورت می‌گیرد و نتایج آن با روش رقومی سطح و مدل رقومی زمین^۱ است. تفاضل DSM ارزیابی می‌شود.

$$nDSM = DSM - DTM$$

رابطه (۱)

برای تولید مدل رقومی زمین از ابر نقطه ارتفاعی روش‌های متنوعی وجود دارد که براساس محاسبه شیب، برازش صفحه و روش‌های مبتنی بر شبکه نامنظم مثلثی (TIN) است. یکی از الگوریتم‌های مربوط به تولید مدل رقومی زمین از ابر نقطه ارتفاعی، الگوریتم^۲ CSF است. این الگوریتم بر مبنای برازش صفحه و معادلات ریاضی گرانس است. در این الگوریتم ابتدا ابرنقطه مورد نظر با توجه به عوارضی که روی سطح آن وجود دارد معکوس می‌شود سپس یک صفحه به این سطح معکوس شده برازش داده می‌شود. سپس با شناسایی نقاط گرهی از

۱-۲- شناسایی ساختمان‌ها

۱-۱-۲- استخراج عوارض زمینی از عوارض غیر زمینی با توجه به ویژگی‌های بافتی و طیفی مشابهی که میان عوارض زمینی و غیرزمینی وجود دارد مهم‌ترین پردازشی که در ابتدا باید برای شناسایی هر یک از این عوارض انجام داد جداسازی این عوارض از یکدیگر است. مهم‌ترین توصیف‌گری که با استفاده از آن می‌توان این پردازش را انجام داد مدل نرمالیزه سطح زمین است. توسط این توصیف‌گر می‌توان با استفاده از یک حدآستانه ارتفاعی عوارض زمینی را از عوارض غیر زمینی جدا کرد. با توجه به رابطه (۱) مدل نرمالیزه سطح زمین حاصل اختلاف مدل

1- DTM

2- Cloth Simulation Filter


۲-۱-۱-۱- الگوریتم قطعه‌بندی چندمقیاسه

قطعه‌بندی چندمقیاسه^۱ به صورت متوالی پیکسل‌ها یا اشیاء تصویری موجود را با هم ادغام می‌کند. از این رو یک الگوریتم طبقه‌بندی پائین به بالا بر پایه تکنیک ادغام نواحی دو به دو است. ادغام دو به دو محلی با سه دسته، بذرها^۲، کاندیدها^۳ و هدف^۴ از اشیای تصویری متمایز می‌شوند. روند قطعه‌بندی با یک رویکرد بهترین برازش دو جانبه، با یک شیء تصویری آغاز می‌شود که یک پیکسل است و در طول چندین حلقه و تکرار جفت‌ها تا جایی که به حد آستانه همگنی محلی برسند با هم ادغام می‌شوند. شاخص همگنی با ترکیبی از همگنی طیفی و همگنی ساختاری تعیین می‌شود. هدف ادغام دو به دو محلی پیدا کردن بهترین کاندیدها برای ادغام شونده محلی است. برای تمامی کاندیدهای ادغام، ساختارهای نتیجه بالقوه هدف با جزئیات با ساختار ورودی بذرها و کاندیدها مقایسه می‌شود (Ojaghi & et al, 2015). پارامترهای همگنی الگوریتم قطعه‌بندی چندمقیاسه، جهت اندازه‌گیری میزان همگنی یا ناهمگنی یک شیء است. این شاخص به صورت ترکیبی از ویژگی‌های شکل و رنگ شیء تصویری اولیه و به دست آمده از ادغام محاسبه می‌شود. همگنی رنگی بر پایه انحراف معیار رنگ‌های طیفی است و همگنی شکلی نیز بر پایه انحراف شکل فشرده یا نرم است (haj ahmadi, 2013).

۲-۱-۳- انتخاب توصیف‌گرهای مناسب

بعد از انجام قطعه‌بندی چندمقیاسه نوبت به انتخاب ویژگی‌های متناسب^۵ با طبقه‌بندی عوارض است. روش‌های متنوعی با توجه به نوع طبقه‌بندی صورت گرفته که می‌تواند به عنوان مثال بر مبنای روش‌های تصمیم‌گیری باشد وجود دارد. این ویژگی‌ها می‌توانند در سه دسته کلی توصیف‌گرهای طیفی، بافتی و ساختاری تقسیم‌بندی شوند.

این سطح برازش داده‌شده و تحلیل آن‌ها با نقاط ارتفاعی مربوطه، مکان تقریبی این نقاط گرهی شناسایی و یک سطح تقریبی از زمین تولید می‌شود. در نهایت می‌توان نقاط زمینی را از مقایسه ابرنقطه ارتفاعی و سطح تولید شده استخراج کرد (Zhang & et al, 2016). نگاره (۲) یک رویکرد کلی از این الگوریتم را نشان می‌دهد.



نگاره ۲: رویکرد کلی الگوریتم CSF

۲-۱-۲- تشکیل فضای اشیاء تصویری

پس از فیلتر کردن عوارض زمینی، منطقه مورد نظر شامل ساختمان‌ها، درختان و نوپز باقیمانده از این جداسازی می‌شود. با توجه به تراکم موجود در منطقه و پیچیدگی ساختاری میان درختان و ساختمان‌ها، طبقه‌بندی شیء‌گرا کارایی بیشتری نسبت به روش‌های پیکسل‌مبنا برای شناسایی ساختمان‌ها دارد. بنابراین روش استفاده شده برای شناسایی ساختمان‌ها، استفاده از طبقه‌بندی شیء‌گرا است. در روش‌های شیء‌گرا، طبقه‌بندی در سطح عارضه انجام می‌گیرد. عارضه‌های تصویری متناظر با موجودیت‌هایی از جهان واقعی هستند که در تصویر به صورت چند پیکسل کنار هم و با بعضی ویژگی‌های مشابه ظاهر می‌شوند (Blaschke & et al, 2001). می‌توان از قطعات تصویری که خروجی روش‌های مختلف قطعه‌بندی هستند به عنوان عارضه‌های تصویری استفاده کرد. بدین منظور برای تشکیل فضای اشیاء تصویری، ابتدا باید روی عوارض به دست آمده یک قطعه‌بندی انجام داد تا عوارض را به قطعات مختلف تقسیم کند. الگوریتم قطعه‌بندی چندمقیاسه برای این پردازش انتخاب شده است.

1- Multi Resolution Segmentation

2- Seed

3- Candidate

4- Target

جدول ۱: توصیف‌گرهای استفاده‌شده

توصیف‌گرهای ساختاری		
بردار نرمال ارتفاعی	ndsm	$nDSM = DSM - DTM$
توضیح پیکسل‌ها در فضا	تراکم ^۱	میانگین قطرهای بزرگ و کوچک بیضی برازش داده شده به شیء
مستطیلی شکل	قالب مستطیلی ^۲	تفاوت میان یک مستطیل مرجع با شیء بر مبنای اندازه‌گیری مساحت و محیط این مستطیل
توصیف‌گرهای بافتی		
بافت	GLCM-homogeneity	$\sum_{i=0}^n \sum_{j=0}^m \frac{1}{1 + (i - j)^2} \times h_c(i, j)$
رنگ	باندهای طیفی تصویر ارتو	درجات خاکستری باندهای قرمز و سبز
میانگین ^۳	باند طیفی قرمز تصویر ارتو	میانگین درجات خاکستری پیکسل‌های درون شیء

پارامتر فازی توسط بزدک صورت گرفت. الگوریتم حاصل، خوشه‌های داده‌ها را در یک فضای چندبعدی شناسایی می‌کند. این خوشه‌ها به‌طور مفروض تقریباً هم‌اندازه هستند. هر خوشه با مرکز آن خوشه نمایش داده می‌شود. در این الگوریتم یک نوع فاصله به‌عنوان معیار تشابه بین مرکز خوشه و سایر داده‌ها استفاده می‌شود (Bezdek & et al, 1984). در این تحقیق از توابع فازی s شکل و z شکل با توجه به قوانین فازی ارائه شده در (Sameen & et al, 2017) بر مبنای کاهش و یا افزایش درجه عضویت هر یک از توصیف‌گرهای استفاده‌شده در حالت فازی استفاده شده است.

در این تحقیق با توجه به مناطق مورد مطالعه و شباهت این مناطق از لحاظ بافتی و ساختاری با منطقه مورد مطالعه در (Sameen & et al, 2017) از توصیف‌گرهای جدول (۱) جهت شناسایی عوارض ساختمانی استفاده شده است.

۲-۱-۴- طبقه‌بندی توصیف‌گرها با استفاده از روش فازی

پس از انتخاب توصیف‌گرهای بهینه نوبت به طبقه‌بندی این توصیف‌گرها بر مبنای شناسایی عوارض براساس روش‌های طبقه‌بندی شیء گرا می‌رسد. یکی از این روش‌ها، روش طبقه‌بندی مبتنی بر تئوری منطق فازی می‌باشد.

۲-۲- شناسایی تغییرات ساختمان‌ها

گام بعدی پس از شناسایی ساختمان‌ها، شناسایی تغییرات آن‌ها است. برای شناسایی تغییرات ساختمان‌ها از روش مبتنی بر یادگیری عمیق استفاده شده است. همچنین از روش تفاضل DSM برای ارزیابی روش مبتنی بر یادگیری عمیق استفاده شده است.

۲-۲-۱- شناسایی تغییرات ساختمان‌ها با استفاده از روش

تفاضلی

مبنای روش تفاضلی، اختلاف‌گیری از مدل‌های ایجاد شده عوارض مورد در بازه‌های زمانی متفاوت و اعمال یک

۲-۱-۴-۱- الگوریتم خوشه‌بندی فازی FCM

نخستین نسخه‌ی این الگوریتم که از الگوریتم K-Means استخراج شده است، در سال ۱۹۷۳ توسط دودا و هارت ارائه شد که یک خوشه‌بندی دقیق ارائه می‌داد (Duda & et al, 1973). از آنجا که برخی داده‌ها به خوشه‌های متعدد وابستگی داشتند، امکان قرار دادن آن‌ها در یک خوشه وجود نداشت، بر همین اساس دان نسخه‌ی فازی این الگوریتم را ارائه داد (Dunn, 1973). الگوریتم بارها مورد بازبینی قرار گرفت تا در نهایت ارائه‌ی نسخه‌ی نهایی الگوریتم و نیز معرفی

- 1- Density
- 2- Rectangular Fit
- 3- Mean
- 4- Feature Selection

۲-۲-۲- شناسایی تغییرات ساختمان‌ها با استفاده از روش مبتنی بر یادگیری عمیق

در این روش برای شناسایی تغییرات ساختمان‌ها از شبکه عصبی کانولوشن یک بعدی برای پیش‌بینی تغییرات صورت‌گرفته در ساختمان‌ها استفاده شده است. ماهیت این نوع شبکه عصبی که پیکسل‌مبناست استفاده از بردار یک‌بعدی به جای تصاویر دو بعدی است.

۲-۲-۱- شبکه‌های عصبی کانولوشن

شبکه‌های عصبی کانولوشن یکی از مهم‌ترین روش‌های یادگیری عمیق هستند که در آن‌ها چندین لایه با روشی قدرتمند آموزش می‌بینند (LeCun & et al, 1998). این روش بسیار کارآمد بوده و یکی از رایج‌ترین روش‌ها در کاربردهای مختلف بینایی کامپیوتر است. به‌طور کلی یک شبکه CNN از سه لایه اصلی تشکیل می‌شود که عبارتند از: لایه کانولوشن، لایه Pooling و لایه تماماً متصل (LeCun et al, 1998).

در هر شبکه عصبی کانولوشن دو مرحله برای آموزش وجود دارد. مرحله پیش‌خور^۱ و مرحله پس‌انتشار^۲. در مرحله اول تصویر ورودی به شبکه تغذیه می‌شود و این عمل چیزی جز ضرب نقطه‌ای بین ورودی و پارامترهای هر نورون و نهایتاً اعمال عملیات کانولوشن در هر لایه نیست. سپس خروجی شبکه محاسبه می‌شود. در این جا به منظور تنظیم پارامترهای شبکه و یا به عبارت دیگر همان آموزش شبکه، از نتیجه خروجی جهت محاسبه میزان خطای شبکه^۳ استفاده می‌شود. برای اینکار خروجی شبکه را با استفاده از یک تابع خطا با پاسخ صحیح مقایسه کرده و اینطور میزان خطا محاسبه می‌شود. در مرحله بعدی براساس میزان خطای محاسبه شده مرحله پس‌انتشار آغاز می‌شود. در این مرحله گرادیانت هر پارامتر با توجه به قانده زنجیرهای^۴ محاسبه می‌شود و تمامی پارامترها با توجه به تأثیری که بر

حدآستانه مناسب است. تغییراتی که در ساختمان‌ها وجود دارند معمولاً به دو دسته دو بعدی و سه بعدی تقسیم‌بندی می‌شوند. تغییرات دو بعدی شامل تغییرات مسطحاتی و تغییرات سه بعدی شامل تغییرات مسطحاتی و تغییرات ارتفاعی هستند.

برای شناسایی تغییرات مسطحاتی می‌توان ساختمان‌های استخراج شده در اپک اول را به موقعیت‌های متناظر خود در اپک دوم منتقل کرد و در صورت عدم وجود، برچسب تخریب به آن‌ها زده شود و در غیر این صورت تغییرات صورت نگرفته است. همچنین، ساختمان‌های استخراجی در اپک دوم به موقعیت متناظر خود در اپک اول منتقل می‌شوند و در صورت وجود نداشتن برچسب ساخت زده می‌شود. برای شناسایی تغییرات ارتفاعی، معمولاً سه نوع تقسیم‌بندی وجود دارد:

۱- تغییر در ارتفاع ساختمان‌ها، به‌عنوان مثال تبدیل ساختمان یک طبقه به دو طبقه و یا برعکس و به این معنی است که ساختمان از نظر مسطحاتی تغییری نداشته و با گذشت زمان فقط ارتفاع آن دچار تغییر شده است که این نوع تغییر ارتفاعی می‌تواند مثبت و یا منفی باشد.

۲- ساخت ساختمان جدید و ایجاد ارتفاع جدید در آن منطقه و به این معناست که تغییر مسطحاتی در آن منطقه صورت گرفته و در اثر این تغییر، به دلیل ساخت ساختمان جدید، تغییر ارتفاعی نیز ایجاد شده است که این نوع تغییر ارتفاعی همواره مثبت است.

۳- تخریب ساختمان نیز علاوه بر تغییر مسطحاتی باعث تغییر ارتفاعی در آن منطقه می‌شود که این نوع تغییر ارتفاعی همواره منفی است (رشیدی و دیگران، ۱۳۹۵).

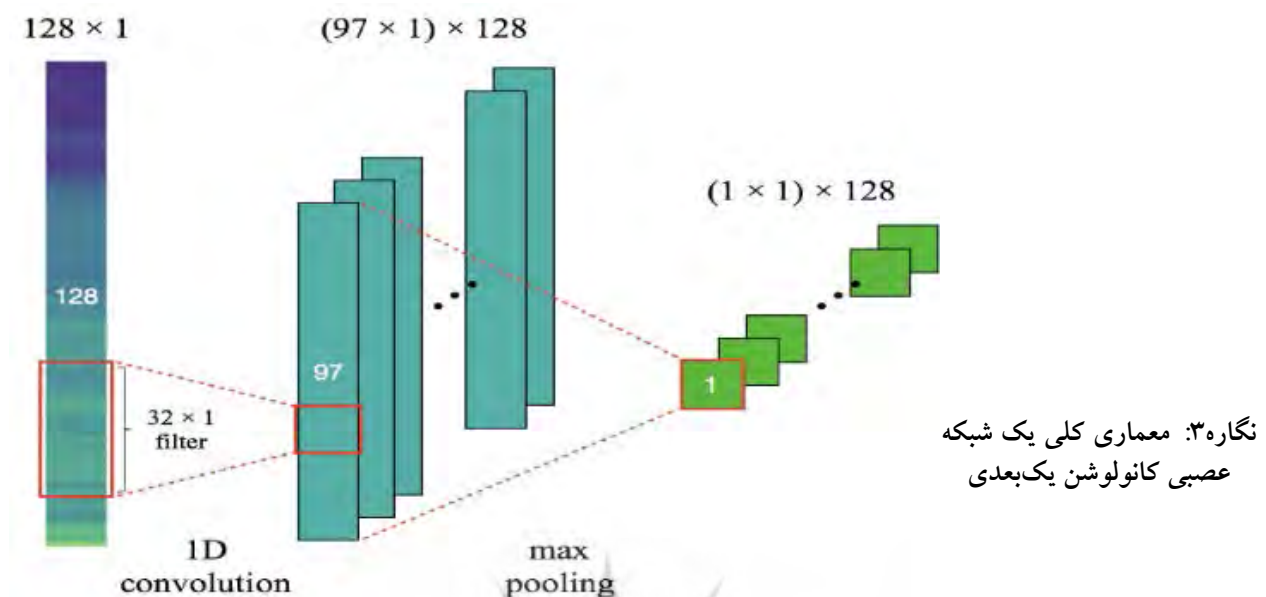
با توجه به داده مورد مطالعه و روش مورد استفاده در این تحقیق از روش تفاضلی برای اختلاف‌گیری از مدل‌های ایجادشده از عوارض ساختمانی در دو بازه زمانی استفاده شده است. این مدل‌ها شامل مدل ارتفاعی ساختمان‌ها و ماسک ایجاد شده از ساختمان‌ها در مرحله شناسایی عوارض ساختمانی در دو اپک تصویربرداری است.

1- Feed Forward

2- Backpropagation

3- Loss Function

4- Chain Rule



تصاویر پهپاد تهیه شده است و مربوط به سال‌های ۱۳۹۰ و ۱۳۹۵ می‌باشد. منطقه مورد مطالعه دوم نیز از شهر عقدا در استان یزد استخراج شده است که همانند منطقه مورد مطالعه اول مدل رقومی سطح و تصویر ارتو آن با استفاده از پردازش تصاویر پهپاد تهیه شده استاین داده‌ها مربوط به سال‌های ۱۳۹۴ و ۱۳۹۷ است. این داده‌ها از پردازش ابرنقطه به‌دست‌آمده از تصاویر پهپاد استخراج شده‌اند. به این صورت که مدل رستری تصاویر ارتوفتو از ابرنقطه رنگی و مدل رستری ارتفاعی از ابرنقطه ارتفاعی استخراج شده است. جدول (۲) مشخصات داده‌های مورد مطالعه ما را نشان می‌دهد.

خطای ایجاد شده در شبکه دارند تغییر پیدا می‌کنند. بعد از به‌روزروری شدن پارامترها مرحله بعدی پیش‌خور شروع می‌شود. بعد از تکرار تعداد مناسبی از این مراحل آموزش شبکه پایان می‌یابد. در این تحقیق با توجه به شناسایی تغییرات ساختمان‌ها در دو اپک متوالی، از شبکه عصبی کانولوشن یک‌بعدی استفاده شده است. دلیل استفاده از این نوع شبکه عصبی، خاصیت این شبکه برای استفاده در سری‌های زمانی و استخراج ویژگی‌های عمیق در بعد زمان و ارتباط بین داده‌ها می‌باشد. نگاره (۳) یک معماری کلی از شبکه عصبی کانولوشن یک‌بعدی را نشان می‌دهد (Lim, Park, Lee, & Han, 2018).

۳-۱- شناسایی ساختمان‌ها

برای شناسایی ساختمان‌ها با توجه به روش تحقیق مورد نظر ابتدا با استفاده از ابر نقطه ارتفاعی و الگوریتم CSF نقاط مربوط به عوارض زمینی از عوارض غیرزمینی

۳- پیاده‌سازی و نتایج تجربی

در این تحقیق از دو منطقه مطالعاتی استفاده شده است. منطقه مورد مطالعه اول از شهر مشهد استخراج شده است که مدل رقومی سطح و تصویر ارتو با استفاده از پردازش


جدول ۲: مشخصات داده‌های مورد مطالعه

مجموعه داده	سیستم تصویر	Pixel Size	سطح مبنای ارتفاعی	وسعت منطقه (km ²)
منطقه مطالعاتی مشهد	UTM,ZONE ۴۰N	۱۰cm	WGS۸۴	۰/۵۲۴
منطقه مطالعاتی عقدا	UTM,ZONE ۳۹N	۲۰cm	WGS۸۴	۰/۵۲۷




نگاره ۴: الف) مدل ارتو منطقه مشهد ب) مدل ارتو منطقه عقدا ج) مدل رقومی سطح منطقه مشهد
 د) مدل رقومی سطح منطقه عقدا

جدا شدند. نگاره (۵) جداسازی نقاط زمینی از عوارض غیرزمینی را توسط این الگوریتم نشان می‌دهد. اختیار داشتن مدل رقومی سطح موجود از منطقه، بردار نرمال ارتفاعی محاسبه می‌شود. نگاره (۶)، مدل رقومی زمین تولیدشده و نگاره (۷)، مدل ارتفاعی نرمالیزه سطح زمین را نشان می‌دهد.




نگاره ۵: جداسازی نقاط زمینی از عوارض غیرزمینی توسط CSF در مرحله بعد با استفاده از ابر نقطه زمینی استخراج شده از الگوریتم CSF اقدام به تولید مدل رقومی زمین از این ابر نقطه زمینی شده است. پس از تولید مدل رقومی زمین از ابر نقطه ارتفاعی توسط الگوریتم CSF، با توجه به در



نگاره ۶: MTD تولید شده توسط FSC


فصلنامه علمی - پژوهشی اطلاعات جغرافیایی (SIR)
 شناسایی تغییرات ساختمان‌ها بر مبنای تئوری منطق فازی و ... / ۵۳

پارامترهای این قطعه‌بندی که شامل مقیاس^۱، نرمی^۲ و فشردگی^۳ است روش‌های متفاوتی وجود دارد که معمولاً از روش‌های آزمون و خطا برای به دست آوردن مقادیر بهینه این پارامترها استفاده می‌شود. برای این کار قطعه‌بندی در چند سطح صورت می‌گیرد و با مقایسه این چند سطح با یکدیگر مقادیر بهینه این پارامترها تعیین می‌شوند. در این تحقیق مقدار ۱۵۰ برای پارامتر مقیاس، مقدار ۰/۵ برای پارامتر نرمی و مقدار ۰/۳ برای پارامتر فشردگی تعیین شد. نگاره (۹)، قطعه‌بندی به روش چندمقیاسه را نشان می‌دهد.



نگاره ۷: مدل ارتفاعی نرمالیزه سطح زمین

پس از تولید مدل نرمالیزه سطح زمین می‌توان با استفاده از یک حدآستانه ارتفاعی خیابان‌ها را که بیشترین شباهت طیفی و بافتی را به ساختمان‌ها دارند فیلتر کرد. برای انتخاب این حدآستانه، کم‌ارتفاع‌ترین ساختمان در هر منطقه مشخص گردید و حدآستانه یک متر برای جداسازی عوارض زمینی که عمدتاً خیابان بودند انتخاب گردید. این کار به طبقه‌بندی دقیق‌تر عوارض که فقط غیرزمینی هستند و شناسایی بهتر این عوارض که اکثراً ساختمان هستند کمک بسیاری می‌کند. نگاره (۸)، اعمال حدآستانه ارتفاعی و فیلتر شدن عوارض زمینی را نشان می‌دهد. عوارض باقیمانده نیز عمدتاً شامل درختان و ساختمان‌ها می‌باشد.



نگاره ۹: قطعه‌بندی تصویر به روش چندمقیاسه

همانطور که در نگاره (۹) دیده می‌شود این مدل قطعه‌بندی به خوبی تراکم پیچیده‌ای را که میان درختان و ساختمان‌ها وجود داشته متمایز کرده‌است. در نهایت فضای اشیاء تصویری توسط این قطعه‌بندی تشکیل می‌شود. مرحله بعد استخراج توصیف‌گرهای مناسب از این قطعه‌بندی و طبقه‌بندی آن‌ها با استفاده از تئوری منطق فازی است. همانطور که در بخش دوم این تحقیق بیان شد این توصیف‌گرها در سه دسته توصیف‌گرهای بافتی، طیفی و ساختاری تقسیم‌بندی می‌شوند و با اختصاص یک تابع درجه عضویت به حالت فازی تبدیل می‌گردند و با توجه به دانش تجربی و مطالعات قبلی، قوانینی بر روی آن‌ها اعمال می‌گردد. این قوانین با توجه به تابع درجه عضویت توصیف‌گرها به صورت زیر بیان می‌شوند (Sameen & et al, 2017).



نگاره ۸: فیلتر شدن عوارض زمینی

مرحله بعد از فیلتر شدن عوارض زمینی تشکیل فضای اشیاء تصویری است که برای آن از الگوریتم قطعه‌بندی چندمقیاسه استفاده شده است. برای به دست آوردن

- اگر nDSM بالا و باند R بالا باشد، آنگاه شیء ساختمان است.
 - اگر nDSM بالا و Density بالا و باند G پایین و Rectangular

1- Scale
 2- Shape
 3- Compactness

۲-۳- شناسایی تغییرات ساختمان‌ها

۲-۳-۱- شناسایی تغییرات ساختمان‌ها با استفاده از روش تفاضل DSMها

پس از شناسایی ساختمان‌ها در دو اپک تغییرات آن‌ها شناسایی شده است. برای شناسایی تغییرات ساختمان‌ها با استفاده از روش تفاضلی ابتدا در دو اپک مورد نظر ساختمان‌های جدا شده از بقیه عوارض بر روی بردار نرمال ارتفاعی ماسک شده‌اند. بنابراین در مدل نرمالیزه سطح زمین فقط مدل ارتفاعی نرمالیزه ساختمان‌ها باقی می‌ماند. با محاسبه اختلاف این دو مدل جدید ایجاد شده از یکدیگر تغییرات ساختمان‌هایی که در این بازه دچار اختلاف ارتفاع شده‌اند مشخص می‌شود. این حالت برای ساختمان‌هایی که دچار اختلاف ارتفاع بیشتر ۳ متر شده‌اند محاسبه شده است. حد آستانه انتخاب شده بر مبنای نوسازی و یا تخریب حداقل یک طبقه از ساختمان‌ها که ارتفاع مورد نظر هر طبقه حدود ۳ متر می‌باشد انتخاب شده است. در نگاره (۱۱) مدل شناسایی تغییرات این ساختمان‌ها برای دو منطقه مورد مطالعه نمایش داده شده است.

۲-۳-۲- شناسایی تغییرات ساختمان‌ها مبتنی بر روش یادگیری عمیق

در این روش برای شناسایی تغییرات ساختمان‌ها از شبکه عصبی کانولوشن یک بعدی برای پیش‌بینی تغییرات

Fit بالا باشد، آنگاه شیء ساختمان است.

- اگر nDSM بالا و GLCM-HOM بالا و Rectangular Fit بالا باشد، آنگاه شیء ساختمان است.

- اگر nDSM بالا و Mean باند R بالا و Rectangular Fit بالا باشد، آنگاه شیء ساختمان است.

- اگر nDSM بالا و باند R پایین باشد، آنگاه شیء درخت است.

- اگر nDSM بالا و Density بالا و باند G بالا و Rectangular Fit پایین باشد، آنگاه شیء درخت است.

- اگر nDSM بالا و GLCM-HOM بالا و Rectangular Fit پایین باشد، آنگاه شیء درخت است.

- اگر nDSM بالا و Mean باند R پایین و Rectangular Fit پایین باشد، آنگاه شیء درخت است.

با اعمال این قوانین بر روی توصیف‌گرها و طبقه‌بندی آن‌ها بدین صورت عوارض غیر زمینی باقیمانده به دو عارضه درخت و ساختمان تقسیم می‌شوند و اینگونه درختان نیز با این روش فیلتر می‌شوند و از عوارض باقیمانده فقط ساختمان‌ها و البته تعدادی نویز باقی می‌مانند. منشاء بروز اینگونه نویزها می‌تواند خطای محاسبه استخراج DEM از DSM و یا وجود تیرهای چراغ برق در منطقه باشد. برای حذف اینگونه نویزها می‌توان از فیلتر مساحت استفاده کرد. همین منوال برای اپک دوم نیز اجرا شده است. در نگاره (۱۰)، طبقه‌بندی حاصل از جداسازی درختان و ساختمان‌ها در مناطق مورد مطالعه نشان داده شده است.



نگاره ۱۰: الف) طبقه‌بندی عوارض غیرزمینی در منطقه مشهد، ب) طبقه‌بندی عوارض غیرزمینی در منطقه عقدا



نگاره ۱۱: الف) مدل شناسایی تغییرات ساختمان‌ها در منطقه مشهد، ب) مدل شناسایی تغییرات ساختمان‌ها در منطقه عقدا

جدول ۳: مشخصات مدل استفاده شده یادگیری عمیق


در این تحقیق Model: sequential_1

Layer(type)	Output Shape	Param#
Conv1d_1(Conv1D)	(None,2,50)	200
Activation_1(Activation)	(None,2,50)	0
Batch_normalization_1(batch)	(None,2,50)	200
Dropout_1(dropout)	(None,2,50)	0
Conv1d_2(Conv1D)	(None,2,50)	7550
Activation_2(Activation)	(None,2,50)	0
Batch_normalization_2(batch)	(None,2,50)	200
Dropout_2(dropout)	(None,2,50)	0
Conv1d_3(Conv1D)	(None,2,50)	7550
Activation_3(Activation)	(None,2,50)	0
Batch_normalization_3(batch)	(None,2,50)	200
Dropout_3(dropout)	(None,2,50)	0
Flatten_1(flatten)	(None,100)	0
Dense_1(dense)	(None,200)	20200
Activation_4(Activation)	(None,200)	0
Batch_normalization_4(batch)	(None,200)	800
Dropout_4(dropout)	(None,200)	0
Dense_2(dense)	(None,200)	40200
Activation_5(Activation)	(None,200)	0
Batch_normalization_5(batch)	(None,200)	800
Dropout_5(dropout)	(None,200)	0
(Dense_3(dense	(None,2)	402
Total params: 78,302		
Trainable params: 77,202		
Non-trainable params: 1,100		

صورت گرفته در ساختمان‌ها استفاده شده است. ماهیت این نوع شبکه عصبی که پیکسل مبناست استفاده از بردار یک بعدی به جای تصاویر دو بعدی است. تابع خطای استفاده شده در این مدل categorical-crossentropy و تابع بهینه‌ساز آن Adam است. در جدول (۳) مشخصات مدل استفاده شده در این تحقیق مشخص شده است.

در این تحقیق از این شبکه در دو حالت استفاده شده است. حالت اول استفاده از مدل رقومی سطح زمین (DSM) دو اپک برای شناسایی تغییرات ساختمان‌ها و حالت دوم استفاده از اختلاف بین مدل‌های رقومی سطح زمین مربوط به دو اپک (DDSM) یا به عبارت دیگر اختلاف DSM دو اپک، بدون در نظر گرفتن حد آستانه ارتفاعی به عنوان لایه ورودی به شبکه است. شبکه عصبی استفاده شده شامل دو مرحله آموزش و پیش‌بینی است.

در مرحله آموزش مطابق نگاره (۱۲) برای حالت اول، قسمتی از مدل رقومی سطح (DSM) مشترک در دو اپک به عنوان لایه ورودی و مطابق نگاره (۱۳) برای حالت دوم از DDSM برای لایه ورودی شبکه استفاده شده است. همچنین مطابق نگاره (۱۴) برای لایه خروجی نیز یک نقشه واقعیت زمینی که شامل مناطق تغییر یافته و عدم تغییر است در نظر گرفته شده است. این نقشه واقعیت زمینی از روش تفاضل DSM مربوط به شناسایی تغییرات ساختمان‌ها استخراج شده است.




ب



الف

نگاره ۱۲: الف) قسمتی از مدل DSM در منطقه مشهد، ب) قسمتی از مدل DSM در منطقه عقدا



ب



الف

نگاره ۱۳: الف) قسمتی از DDSM محاسبه شده از دو اپک در منطقه مشهد، ب) قسمتی از DDSM محاسبه شده از دو اپک در منطقه عقدا



ب

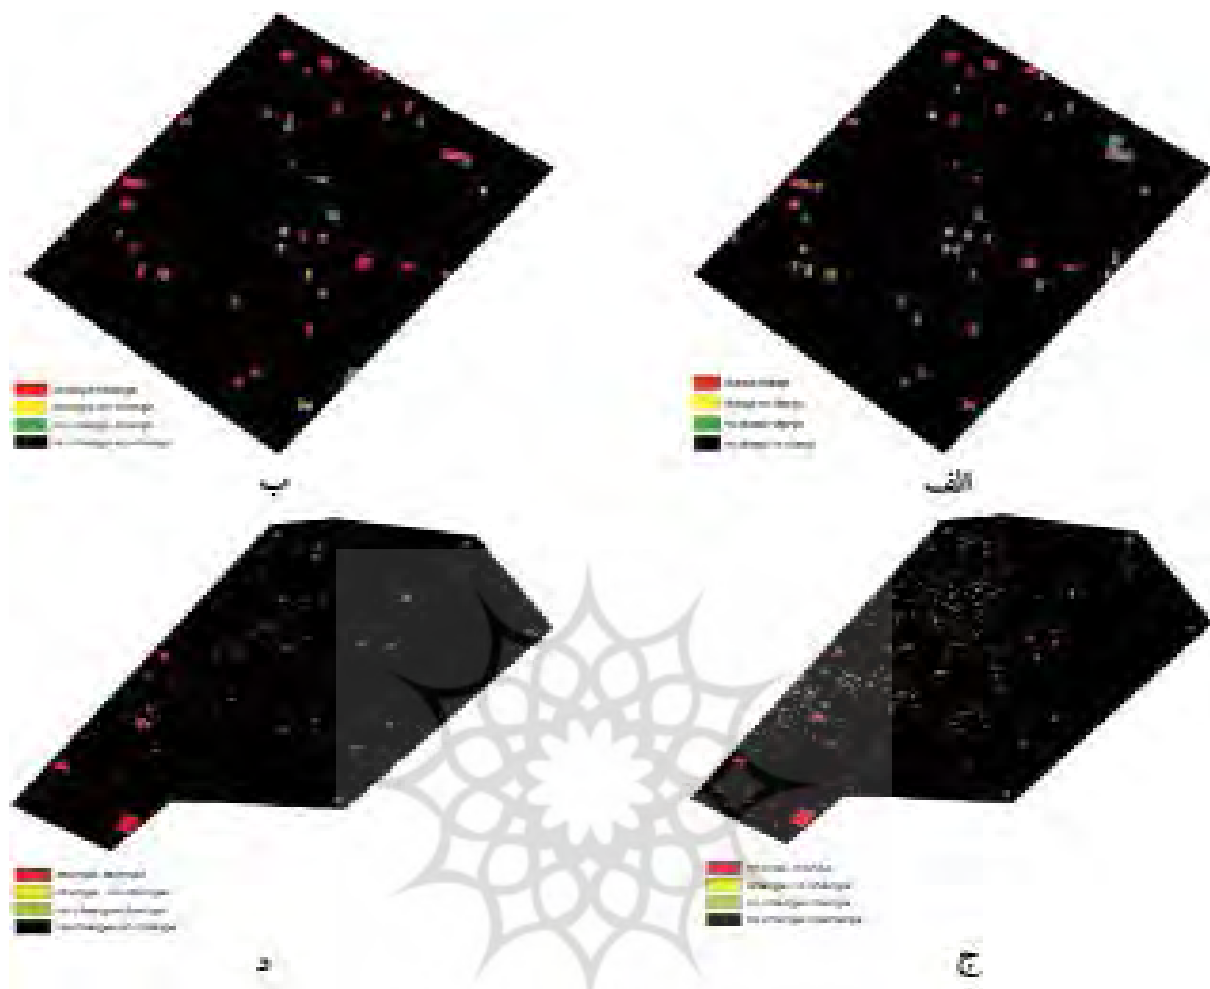


الف

نگاره ۱۴: الف) واقعیت زمین ایجاد شده برای آموزش شبکه در منطقه مشهد، ب) واقعیت زمین ایجاد شده برای آموزش شبکه در منطقه عقدا

دارای پیش‌بینی ضعیف‌تری در مقایسه با تک لایه ورودی DDSM می‌باشد که دلیل آن پیکسل مبنا بودن روند آموزش شبکه و همچنین آموزش بهتر شبکه در حالت استفاده از DDSM به دلیل تک‌لایه بودن ورودی شبکه در این حالت است.

پس از مرحله آموزش نوبت به پیش‌بینی تغییرات صورت گرفته با استفاده از این شبکه عصبی آموزش داده شده می‌رسد. این شبکه عصبی آموزش داده شده فقط مناطق دارای تغییر را مشخص کرده است. مطابق نگاره (۱۵) روند پیش‌بینی با استفاده از دو لایه ورودی مدل رقومی سطح



نگاره ۱۵: الف) شناسایی تغییرات صورت گرفته با استفاده از DSM مربوط به هر اپک در منطقه مشهد، ب) شناسایی تغییرات صورت گرفته با استفاده از DDSM محاسبه شده از دو اپک در منطقه مشهد، ج) شناسایی تغییرات صورت گرفته با استفاده از DSM مربوط به هر اپک در منطقه عقدا، د) شناسایی تغییرات صورت گرفته با استفاده از DDSM محاسبه شده از دو اپک در منطقه عقدا

۴- ارزیابی

۴-۱- ارزیابی حاصل از شناسایی ساختمان‌ها

طبقه‌بندی عوارض در اپک‌های اول و دوم محاسبه شده است. صحت کلی طبقه‌بندی برای اپک اول در منطقه مشهد ۹۴/۶٪ می‌باشد که نشان از دقت بالای طبقه‌بندی با استفاده از روش‌های شیء‌گرا نسبت به روش‌های پیکسل مینا دارد. برای اپک اول در منطقه عقدا نیز صحت کلی طبقه‌بندی مقدار ۹۵/۵٪ محاسبه شد که با توجه به روش طبقه‌بندی یکسانی که برای دو اپک انجام شد دقت بالایی را شامل می‌شود. همچنین این روش دقت کلی به مراتب بیشتری را در مقایسه با روش (Nahhas & et al, 2018) که دقت کلی آن ۸۶٪ است دارد. سایر پارامترهای طبقه‌بندی نیز در جدول

برای ارزیابی نتایج به دست آمده ابتدا باید صحت طبقه‌بندی انجام شده را محاسبه کرد. با توجه شیوه طبقه‌بندی که شیء‌گرا بوده باید برای محاسبه ارزیابی آن به جای استفاده از تک پیکسل‌ها به عنوان داده نمونه از گروهی از پیکسل‌ها استفاده کرد (MacLean & et al, 2012). در این روش تحقیق از روش پلیگون مینا و بر مبنای مساحت گروهی از پیکسل‌ها، صحت طبقه‌بندی ساختمان‌ها در دو اپک محاسبه شده است. در جدول‌های (۵ و ۴) ماتریس ابهام برای نتایج

جدول ۴: ماتریس ابهام حاصل از طبقه‌بندی برای اپک اول در منطقه مشهد

	نمونه مرجع (m ^۲)	ساختمان	درخت	جمع
نمونه طبقه‌بندی شده (m ^۲)	ساختمان	۱۳۱۸/۱۴	۵۰/۹۸	۱۳۶۹/۱۲
	درخت	۶۱/۱۸۰	۶۵۱/۶۷	۷۱۲/۸۵
	جمع	۱۳۷۹/۳۲	۷۰۲/۶۵	۲۰۸۱/۹۷

جدول ۵: ماتریس ابهام حاصل از طبقه‌بندی برای اپک اول در منطقه عقدا

	نمونه مرجع (m ^۲)	ساختمان	درخت	جمع
نمونه طبقه‌بندی شده (m ^۲)	ساختمان	۱۲۵۰/۵	۵/۶۴	۱۲۵۶/۱۴
	درخت	۸۴/۳۵	۶۳۳/۱۵	۷۱۷/۵
	جمع	۱۳۴۴/۸۵	۶۳۸/۷۹	۱۹۷۳/۶۴

۷ آورده شده است که نشان از روش طبقه‌بندی بهینه برای این نوع مدل داده و شناسایی عوارض خصوصاً عوارض ساختمانی است. با توجه به جدول (۶) عوارض ساختمانی شناسایی شده دارای دقت بالاتری نسبت به سایر عوارض غیر ساختمانی که غالب آن‌ها درختانند است که دلیل آن‌ها روند پردازش داده‌ها بر مبنای شناسایی ساختمان‌ها از دیگر عوارض موجود است. هر چه دقت شناسایی ساختمان‌ها در گام اول بالاتر باشد دقت تغییرات رصد شده نیز بالاتر خواهد بود.

۴-۲-۴-۲-۱-۲-۴ روش تفاضل DSM پس از ارزیابی طبقه‌بندی برای شناسایی ساختمان‌ها نوبت به ارزیابی تغییرات ساختمان‌ها می‌رسد. با توجه به روش تحقیق برای شناسایی تغییرات ساختمان‌ها در حالت تفاضل DSM که هم تغییرات مدل رقومی سطح آن‌ها و هم مدل ساختمان‌های به وجود آمده و یا تخریب شده محاسبه شدند در منطقه مشهد تعداد ۴۵ ساختمان و در منطقه عقدا تعداد ۳۱ ساختمان شامل تغییرات ارتفاعی شده‌اند. برای اطمینان بیشتر از این ارزیابی از تصاویر چندزمانه گوگل‌ارت نیز استفاده شد که همین آمار را نشان می‌دهد.

جدول ۶: پارامترهای حاصل از طبقه‌بندی برای اپک‌های اول در مناطق مشهد و عقدا

	صحت ^۲	تمامیت ^۱	F-Score
منطقه مشهد			
ساختمان	٪۹۶	٪۹۶	٪۹۶
درخت	٪۹۱	٪۹۳	٪۹۲
Kappa	۰/۸۸		
منطقه عقدا			
ساختمان	٪۹۹	٪۹۸	٪۹۷
درخت	٪۸۸	٪۹۱	٪۹۳
Kappa	۰/۹۰		

۴-۲-۴-۲-۲-۲ روش مبتنی بر یادگیری عمیق برای ارزیابی تغییرات ساختمان‌ها با استفاده از روش یادگیری عمیق با توجه به نقشه واقعیت زمینی استفاده شده در آموزش شبکه در حالت استفاده از مدل رقومی سطح مربوط به هر اپک برای لایه ورودی و استفاده از DDSM دو اپک برای لایه ورودی در حالت دیگر این نتایج به دست آمد.

نتایج جدول‌های (۷ و ۸) نشان‌دهنده این است که اولاً نتایج نشان داده شده با استفاده از روش یادگیری عمیق

1- Recall
2- Precision

با توجه به تحقیقات صورت گرفته و مرور آن‌ها در بخش مقدمه و ارزیابی انجام شده با استفاده از روش تحقیق در مناطق مورد مطالعه، این روش تحقیق علاوه بر مستقل بودن از داده‌های مورد مطالعه نتایج به مراتب با دقت بالاتر را در مقایسه با سایر روش‌های مورد استفاده در حوزه شناسایی ساختمان و شناسایی تغییرات آن‌ها نشان داده است. به عنوان نمونه نتایج به دست آمده از روش پیشنهادی این تحقیق که بر مبنای روش فازی است در مقایسه با (Nahhas & et al, 2018) که روش آن بر مبنای شبکه عصبی کانولوشن دوبعدی در حوزه شناسایی ساختمان است دارای دقت به نسبت بالاتری است.

۵- نتیجه گیری

در این تحقیق ابتدا مقدمه‌ای بر ضرورت نیاز استخراج عوارض و شناسایی تغییرات آن‌ها به خصوص عوارض شهری مانند ساختمان‌ها ارائه شد که بر اساس آن با توجه به حجم بالای محاسباتی در داده‌های نوین سنجش از دوری و فتوگرامتری و هزینه‌بر بودن سیستم‌های محاسباتی برای پردازش آن‌ها، یک روش جدید در این تحقیق برای حل این مشکل ارائه شد. سپس مروری بر روش‌های صورت گرفته برای استخراج ساختمان‌ها و شناسایی تغییرات آن‌ها انجام شد. سپس با توجه به تراکم دیتای مورد مطالعه و پیچیدگی بافتی میان عوارض آن روش‌های شیء‌گرا به جای روش‌های پیکسل‌مبنا برای شناسایی عوارض انتخاب شد و یک قطعه‌بندی چندمقیاسه بر روی دیتاهای مورد مطالعه صورت گرفت و با استخراج توصیف‌گرهای مناسب طیفی، بافتی و ساختاری یک طبقه‌بندی فازی برای استخراج ساختمان‌ها صورت گرفت. برای شناسایی تغییرات ساختمان‌ها از روش مبتنی بر یادگیری عمیق استفاده شد و این روش با روش تفاضل dsm مورد ارزیابی قرار گرفت. در روش تفاضل dsm با توجه به شناسایی ساختمان‌ها در مراحل قبل مدل رقومی سطح آن‌ها محاسبه و با اختلاف‌گیری دو اپک مورد نظر تغییرات ارتفاعی ساختمان‌ها شناسایی گردید.

دارای دقت بالایی در حالت کانولوشن یک بعدی است ثانیاً در حالت دوم با توجه به اینکه از DDSM استفاده شده است بسیاری از مناطقی که در دو اپک عدم تغییرات ارتفاعی را دارا بودند حذف شده‌اند و آموزش شبکه مناسب‌تر صورت گرفته و دارای دقت بالاتری است. سایر پارامترهای طبقه‌بندی نیز برای دو حالت در این جدول‌ها آورده شده است که آموزش بهتر شبکه و پیش‌بینی دقیق‌تر آن را در حالت استفاده از DDSM نشان می‌دهد.

جدول ۷: پارامترهای حاصل از طبقه‌بندی با استفاده از شبکه عصبی برای دو حالت استفاده شده به منظور شناسایی

تغییرات در منطقه مشهد

F-Score	تمامیت	صحت	
استفاده از مدل رقومی سطح مربوط به هر اپک			
٪۸۳	٪۸۶	٪۷۹	تغییر
٪۷۹	٪۸۲	٪۸۰	عدم تغییر
Kappa		۰/۷۲	
استفاده از DDSM			
٪۸۴	٪۸۵	٪۸۲	تغییر
٪۹۹	٪۹۹	٪۹۹	عدم تغییر
Kappa		۰/۸۳	

جدول ۸: پارامترهای حاصل از طبقه‌بندی با استفاده از شبکه عصبی برای دو حالت استفاده شده به منظور شناسایی

تغییرات در منطقه عقدا

F-Score	تمامیت	صحت	
استفاده از مدل رقومی سطح مربوط به هر اپک			
٪۸۲	٪۹۹	٪۹۷	تغییر
٪۹۸	٪۹۹	٪۹۸	عدم تغییر
Kappa		۰/۸۱	
استفاده از DDSM			
٪۹۹	٪۹۷	٪۹۹	تغییر
٪۹۹	٪۹۹	٪۹۹	عدم تغییر
Kappa		۰/۹۸	

۶- منابع و مآخذ

- ۱- رشیدی، پ؛ راستی، ح، ۱۳۹۶، شناسایی تغییرات ساختمان‌ها با استفاده از داده های لیزر اسکنر هوایی، همایش ملی ژئوماتیک، ۲۴
 - 2- Awrangjeb, M., Fraser, C. S., & Lu, G. (2015). BUILDING CHANGE DETECTION FROM LIDAR POINT CLOUD DATA BASED ON CONNECTED COMPONENT ANALYSIS. *ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences*, II-3/W5(3W5), 393-400. <https://doi.org/10.5194/isprannals-II-3-W5-393-2015>
 - 2- Bezdek, J. C., Ehrlich, R., & Full, W. (1984). FCM: The fuzzy c-means clustering algorithm. *Computers & Geosciences*, 10(2-3), 191-203. [https://doi.org/10.1016/0098-3004\(84\)90020-7](https://doi.org/10.1016/0098-3004(84)90020-7)
 - 3- Blaschke, T., & Hay, G. J. (2001). Object-oriented image analysis and scale-space: theory and methods for modeling and evaluating multiscale landscape structure. *International Archives of Photogrammetry and Remote Sensing*, 34(4), 22-29.
 - 4- Duda, R. O., & Hart, P. E. (1973). *Pattern Classification and Scene Analysis*. Wiley. Retrieved from <https://books.google.com.br/books?id=POMGRAAACAAJ>
 - 5- Dunn, J. C. (1973). A Fuzzy Relative of the ISODATA Process and Its Use in Detecting Compact Well-Separated Clusters. *Journal of Cybernetics*, 3(3), 32-57. <https://doi.org/10.1080/01969727308546046>
 - 6- haj ahmadi, S. (2013). Using satellite imagery and digital maps to change detection in urban areas. K. N. Toosi University of Technology.
 - 7- LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278-2323. <https://doi.org/10.1109/5.726791>
 - 8- Lim, H., Park, J., Lee, K., & Han, Y. (2018). RARE SOUND EVENT DETECTION USING 1D CONVOLUTIONAL RECURRENT NEURAL NETWORKS.
 - 9- MacLean, M., & Congalton, R. (2012). Map accuracy assessment issues when using an object-oriented approach. *American Society for Photogrammetry and*
- همچنین با اختلاف‌گیری از مدل ساختمان‌ها در دو اپک، ساختمان‌هایی که در این بازه به وجود آمده و یا تخریب شده بودند نیز شناسایی شدند. در روش مبتنی بر یادگیری عمیق نیز از یک شبکه عصبی کانولوشن یک‌بعدی استفاده شد. در این شبکه از دو حالت برای آموزش و پیش‌بینی تغییرات استفاده گردید. در حالت اول مدل رقومی سطح مربوط به ساختمان‌ها در دو اپک برای لایه ورودی ساختمان‌ها و در حالت دوم DDSM آن‌ها به عنوان تک لایه ورودی شبکه معرفی شدند و با توجه به واقعیت زمین ایجاد شده برای مناطق دارای تغییر و عدم تغییر که از حالت تفاضلی شناسایی تغییرات ساختمان‌ها به دست آمده بود شبکه مورد نظر آموزش داده شد. پس از آموزش شبکه با استفاده از این دو حالت پیش‌بینی تغییرات نیز با این شبکه آموزش دیده انجام شد که در حالت استفاده از DDSM نتایج به مراتب بهتری را نشان داد. در قسمت ارزیابی نیز صحت کلی و سایر پارامترهای طبقه‌بندی بر مبنای روش‌های پلیگون‌مبنا محاسبه شد و صحت کلی بالای ۹۰٪ برای هر دو اپک به دست آمد که نشان از روش طبقه‌بندی مناسب برای این نوع عوارض با این تنوع تراکم را دارد. همچنین برای ارزیابی شناسایی تغییرات ساختمان‌ها با استفاده از روش تفاضلی از تصاویر گوگل‌ارث نیز استفاده شد که همان آمار مربوط به روش محاسبه‌شده برای شناسایی تغییرات ساختمان‌ها را نشان می‌دهد. در روش مبتنی بر یادگیری عمیق برای شناسایی تغییرات ساختمان‌ها نیز نتایج حاصل از این روش با روش تفاضل dsmها مورد ارزیابی قرار گرفت که نتایج این ارزیابی برای حالت استفاده از DDSM نسبت به استفاده از مدل رقومی سطح هر یک از اپک‌ها، دارای معیارهای به مراتب بهتری بودند که نشان می‌دهد شناسایی تغییرات با استفاده از این حالت روند دقیق‌تری را دارد. همچنین می‌توان نتیجه گرفت که شبکه طراحی شده برای شناسایی تغییرات ساختمان‌ها می‌تواند بدون نیاز به انتخاب حد‌آستانه، تغییرات ساختمان‌هایی را که نوع داده آن‌ها همانند داده استفاده‌شده در این تحقیق است شناسایی کند.

- 18- Walter, V. (2004). Object-based classification of remote sensing data for change detection. *ISPRS Journal of Photogrammetry and Remote Sensing*, 58(3-4), 225-238. <https://doi.org/10.1016/j.isprsjprs.2003.09.007>
- 19- Zhang, W., Qi, J., Wan, P., Wang, H., Xie, D., Wang, X., & Yan, G. (2016). An easy-to-use airborne LiDAR data filtering method based on cloth simulation. *Remote Sensing*, 8(6), 501. <https://doi.org/10.3390/rs8060501>
- 20- Zong, K., Sowmya, A., & Trinder, J. (2013). Kernel partial least squares based hierarchical building change detection using high resolution aerial images and lidar data. In *2013 International Conference on Digital Image Computing: Techniques and Applications, DICTA 2013* (pp. 1-7). IEEE. <https://doi.org/10.1109/DICTA.2013.6691502>
- Remote Sensing Annual Conference 2012, ASPRS 2012, 369-373.
- 10- Meng, X., Currit, N., Wang, L., & Yang, X. (2012). Detect Residential Buildings from Lidar and Aerial Photographs through Object-Oriented Land-Use Classification. *Photogrammetric Engineering & Remote Sensing*, 78, 35-44. <https://doi.org/10.14358/PERS.78.1.35>
- 11- Mohammadzade, A., Varesi, A., & Janalipour, M. (2017). Presentation of a Method for Detecting Urban Growth using Spectral- Spatial Variation Indicators and Remote Sensing Data. *Journal of Geomatics Science and Technology*, 6(4). Retrieved from <http://jgst.issge.ir/article-1-574-fa.html>
- 12- Nahhas, F. H., Shafri, H. Z. M., Sameen, M. I., Pradhan, B., & Mansor, S. (2018). Deep Learning Approach for Building Detection Using LiDAR-Orthophoto Fusion. *Journal of Sensors*, 2018, 1-12. <https://doi.org/10.1155/2018/7212307>
- 13- Ojaghi, S., Ebadi, H., Ahmadi, F., & Teymoori, M. (2015). high resolution images classification with object based method.
- 14- sahebi, mahmoodreza. (2015). change detection in semi urban areas with optical temporal Satellite Images Based on Object based Analysis and svm. K. N. Toosi University of Technology.
- 15- Sameen, M. I., & Pradhan, B. (2017). A Two-Stage Optimization Strategy for Fuzzy Object-Based Analysis Using Airborne LiDAR and High-Resolution Orthophotos for Urban Road Extraction. *Journal of Sensors*, 2017, 1-17. <https://doi.org/10.1155/2017/6431519>
- 16- SINGH, A. (1989). Review Article Digital change detection techniques using remotely-sensed data. *International Journal of Remote Sensing*, 10(6), 989-1003. <https://doi.org/10.1080/01431168908903939>
- 17- Vakalopoulou, M., Karantzalos, K., Komodakis, N., & Paragios, N. (2015). Building detection in very high resolution multispectral data with deep learning features. In *2015 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)* (Vol. 2015-Novem, pp. 1873-1876). IEEE. <https://doi.org/10.1109/IGARSS.2015.7326158>



پروہشگاہ علوم انسانی و مطالعات فرہنگی
پرتال جامع علوم انسانی