

Efficient Adaptive Local Thresholding for Improving Elevation Change Detection in Urban Environments Using Bi-temporal LiDAR Data

Vahid ahmadi and Ali Akbar matkan*

Remote Sensing & GIS Research Center, Faculty of Earth Sciences, Shahid Beheshti University, Tehran, Iran

a-matkan@sbu.ac.ir:* Corresponding Author

Abstract:

Three-dimensional changes in urban environments have become one of the most critical topics in urban environmental studies and structural change monitoring. As cities rapidly expand and the number of construction projects continues to increase, identifying and monitoring these changes have gained significant importance. Furthermore, the ability to simulate and predict urban changes can help urban planners and decision-makers make informed choices. In this regard, the use of three-dimensional data, such as LiDAR point clouds, is an effective method for accurately simulating and detecting three-dimensional changes at the urban level. The primary objective of this research is to develop an algorithm for identifying and analyzing elevation changes in urban areas using bi-temporal LiDAR data processing techniques. These elevation changes can result from various factors, such as the construction and demolition of buildings, changes in land use, or variations in vegetation cover. In this study, LiDAR point cloud data from the years ۲۰۱۴ and ۲۰۱۹, collected from the coastal region of Duck in North Carolina, were utilized. These datasets contain three-dimensional points with X, Y, and Z coordinates, along with intensity values recorded from the Earth's surface using a LiDAR sensor. To identify elevation changes, the distance between the two point clouds was computed. The relative distance between corresponding points was determined using Delaunay triangulation, which created an irregular triangular network from one set of points and measured the distance between this network and the corresponding points in the other dataset. Following this step, a local adaptive thresholding method was applied to detect elevation changes at various scales. This method has the advantage of identifying localized changes more effectively than global detection techniques, which may overlook smaller variations. In this research, the two point clouds were merged into a single dataset to analyze elevation changes in urban environments. This process resulted in a unified point cloud with higher density in unchanged areas. In contrast, in areas where elevation changes occurred, multiple elevation surfaces emerged, leading to an increase in elevation variance. This effect was particularly noticeable in cases where land use had changed or where buildings had been demolished and reconstructed. The variance differences were clearly visible, providing strong indicators of real changes in the urban landscape. In regions experiencing changes, the elevation variance of the combined point cloud increased significantly, highlighting structural modifications. Conversely, in areas without elevation changes, the elevation variance remained low. This method proved especially effective in detecting minor changes that are often overlooked by conventional global change detection methods. To evaluate the accuracy of the proposed approach, key performance metrics such as completeness, correctness, overall quality, and the F_1 score were computed. The results demonstrated that the proposed method performed exceptionally well in detecting elevation changes in urban areas. Specifically, in regions where changes in building heights or land use had occurred—such as the conversion of land into buildings or vegetation into urban structures—the

algorithm successfully identified changes with high precision. In particular, for two subsets of the study area where building demolition and construction activities took place, the completeness metric exceeded 98%, while accuracy in other metrics ranged between 86% and 98%. For the third subset, where vegetation was converted into residential land use, completeness was measured at 85%, with accuracy in other metrics ranging between 83% and 98%. The local adaptive thresholding method introduced in this study effectively identifies elevation changes in complex urban environments. This technique is particularly efficient in detecting small-scale, localized changes that global methods may overlook. The results of this research have significant implications for urban planning, infrastructure monitoring, and disaster management, as they can enhance decision-making processes in these domains. Future studies should focus on applying this method to various urban environments while considering its computational efficiency and scalability for processing large-scale datasets. The integration of advanced machine learning models with this approach could further improve change detection accuracy and automation, leading to more efficient monitoring of urban transformations.

Keywords: Adaptive Local Thresholding, Elevation Changes, Urban Environment, Bi-temporal LiDAR, Remote Sensing.

آستانه‌گذاری محلی تطبیقی برای بهبود تشخیص تغییرات ارتفاعی در محیط‌های شهری با استفاده از

داده‌های لایدار دوزمانه

وحید احمدی و علی اکبر متکان*

مرکز مطالعات سنجش از دور و GIS، دانشکده علوم زمین، دانشگاه شهید بهشتی، تهران، ایران

*نویسنده عهده دار مکاتبات: a-matkan@sbu.ac.ir

چکیده:

تغییرات سه‌بعدی در محیط‌های شهری یکی از مهم‌ترین موضوعات در مطالعات تغییرات محیط زیست شهری و پایش تغییرات ساختاری آن است. با توجه به رشد سریع شهرها و افزایش تعداد پروژه‌های ساخت‌وساز، شناسایی و پایش این تغییرات اهمیت زیادی پیدا کرده است. از سوی دیگر، امکان شبیه‌سازی و پیش‌بینی تغییرات شهری می‌تواند به برنامه‌ریزان شهری و مقامات مسئول در اتخاذ تصمیمات بهینه کمک کند. در این راستا، استفاده از داده‌های سه‌بعدی مانند ابر نقاط لایدار یکی از روش‌های مؤثر در شبیه‌سازی دقیق تغییرات سه‌بعدی در سطح شهر است. هدف این تحقیق توسعه الگوریتمی در زمینه شناسایی و تحلیل تغییرات ارتفاعی در مناطق شهری با استفاده از پردازش داده‌های لایدار دو زمانه می‌باشد. این تغییرات می‌توانند ناشی از عوامل مختلفی مانند ساخت و تخریب ساختمان‌ها، تغییرات کاربری اراضی و یا تغییرات در رشد پوشش گیاهی باشند. در این تحقیق، داده‌های ابر نقطه لایدار برای سال‌های ۲۰۱۴ و ۲۰۱۹ از منطقه ساحلی داک در کارولینای شمالی در اختیار قرار گرفت. این داده‌ها شامل نقاط سه‌بعدی با مولفه‌های X , Y , Z و شدت نور است که به‌وسیله سنجش‌گر لایدار از سطح زمین برداشت شده‌اند. در این مطالعه، برای شناسایی تغییرات ارتفاعی از محاسبه فاصله بین دو ابر نقطه استفاده شد. فاصله بین دو ابر نقطه با

استفاده از فاصله یک سری نقاط نسبت به شبکه نامنظم مثلثی ایجاد شده از سری دیگر نقاط بدست آمد. سپس روش آستانه‌گذاری محلی تطبیقی استفاده شد که قادر است تغییرات ارتفاعی در مقیاس‌های مختلف را شناسایی کند. در این تحقیق، ترکیب دو ابر نقطه در یک مجموعه داده برای شناسایی تغییرات ارتفاعی در مناطق شهری استفاده گردید. این روش موجب ایجاد ابر نقطه واحد با چگالی بالاتر در نواحی بدون تغییر گردیده در حالی که در نواحی دارای تغییرات ارتفاعی، سطح‌های ارتفاعی متفاوتی ایجاد شد که باعث افزایش واریانس ارتفاعی می‌شود. به‌ویژه در مواردی که کاربری زمین تغییر کرده و یا ساختمان‌ها تخریب و بازسازی شده‌اند، این تفاوت‌های واریانس به‌طور واضح قابل مشاهده بود. در مناطق دارای تغییر، مقدار واریانس ارتفاعی نقاط ترکیبی به‌طور قابل توجهی افزایش یافت که نشان‌دهنده تغییرات واقعی در سطح زمین بود. در مقابل، در مناطقی که تغییرات ارتفاعی نداشتند، واریانس ارتفاعی نقاط ترکیبی در محدوده پایین باقی ماند. این روش به‌ویژه برای شناسایی تغییرات کوچک که ممکن است در روش‌های سراسری نادیده گرفته شوند، مناسب است. برای ارزیابی دقت نتایج، معیارهایی چون کامل بودن، درستی، کیفیت کلی و امتیاز F^1 محاسبه شد. نتایج نشان داد که روش پیشنهادی در شناسایی تغییرات ارتفاعی در مناطق شهری، عملکرد بسیار خوبی داشته است. به‌طور خاص، در مناطقی که تغییرات در ارتفاعات ساختمان‌ها یا تغییرات کاربری زمین مانند تبدیل زمین به ساختمان یا درخت به ساختمان صورت گرفته بود، الگوریتم پیشنهادی قادر است که تغییرات را به درستی و دقت بالا شناسایی کند. به‌طور خاص، در دو زیرمجموعه اول از منطقه مورد مطالعه که تغییرات ارتفاعی در سطوح تخریب و یا ساخت ساختمان‌ها وجود داشت، دقت شناسایی تغییرات در معیار کامل بودن بیش از ۹۸ درصد بوده و در سایر معیارها، دقت بین ۸۶ تا ۹۸ درصد متغیر می‌باشد. در زیرمجموعه سوم از منطقه مورد مطالعه که پوشش گیاهی به کاربری مسکونی تبدیل شده بود، دقت شناسایی تغییرات در معیار کامل بودن ۸۵ درصد بوده و در سایر معیارها نیز دقت بین ۸۳ تا ۹۸ درصد متغیر است. روش آستانه‌گذاری محلی تطبیقی که در این تحقیق ارائه شد، قادر است به‌طور مؤثری تغییرات ارتفاعی در محیط‌های شهری پیچیده را شناسایی کند. این روش به‌ویژه در شناسایی تغییرات کوچک و محلی که ممکن است در روش‌های سراسری نادیده گرفته شوند، عملکرد مناسبی دارد. استفاده از نتایج این تحقیق در برنامه‌ریزی شهری، پایش تغییرات زیرساخت‌ها و مدیریت بلایا می‌تواند به بهبود تصمیم‌گیری‌ها کمک کند. پیشنهاد می‌شود که در پژوهش‌های آینده این روش در مناطق شهری مختلف آزمایش شده و به‌ویژه کارایی محاسباتی آن مورد توجه قرار گیرد.

واژگان کلیدی: آستانه‌گذاری محلی تطبیقی، تغییرات ارتفاع، محیط شهری، لایدار دو زمانه، سنجش از دور.

۱. مقدمه:

در دهه‌های اخیر، شناسایی تغییرات به‌صورت خودکار به موضوعی ضروری در علوم فتوگرامتری و سنجش از دور تبدیل شده است که در زمینه علوم زیست‌محیطی و پایش شهری پیشرفت‌های برجسته‌ای داشته است (Ku et al., ۲۰۲۱). از سوی دیگر پایش تغییرات ارتفاعی در محیط‌های شهری یکی از جنبه‌های حیاتی در مدیریت شهری، نظارت بر توسعه و ساخت‌وساز و همچنین واکنش به حوادث طبیعی از جمله زلزله، سیل و طوفان‌های سهمگین است (Krichen et al., ۲۰۲۴). شهرها به‌طور مداوم در حال رشد و تغییر هستند (Paes et al., ۲۰۲۳) و این تغییرات نه تنها بر جنبه‌های ساختاری و فیزیکی تأثیر می‌گذارند، بلکه می‌توانند منجر به تغییرات زیست‌محیطی و حتی اجتماعی نیز شوند (Smith, ۲۰۲۳). با این حال، به دلیل تنوع و پیچیدگی‌های موجود در بافت‌های شهری از جمله ترکیب ناهمگون ساختمان‌ها، خیابان‌ها، پوشش گیاهی و فضاهای باز، چالش‌های قابل توجهی در شناسایی دقیق و سریع این تغییرات با استفاده از داده‌های سنتی و روش‌های معمول تحلیل فضایی وجود دارد (Yu & Fang, ۲۰۲۳; Li et al., ۲۰۲۴).

با پیشرفت سریع دستگاه‌های سنجش سه‌بعدی، توانایی جمع‌آوری و ثبت داده‌های 3D با سرعت و هزینه نسبتاً پایین فراهم شده است. ابر نقاط مجموعه‌ای از نقاط مکانی نمونه‌برداری شده از سطوح اشیاء سه بعدی در فضاها یا اقلیدسی هستند که هر نقطه به سه مولفه x ، y و z در سیستم مختصات کارتزین اشاره دارد (Otepka et al., 2013; Rusu and Cousins, 2011) که به دلیل عدم تحریف‌های پرسپکتیو، در علوم زمین، بینایی رایانه‌ای و مهندسی عمران به‌شدت مورد استفاده قرار گرفته‌اند (Abellan et al., 2016).

در این بین داده‌های لایدار، به‌عنوان یک فناوری سنجش از دور فعال (Dong, & Chen, 2017; Wang & Menenti, 2021) مبتنی بر نور لیزری، در سال‌های اخیر به دلیل دقت و وضوح بالای خود، به یکی از ابزارهای مهم برای پایش تغییرات ارتفاعی و بررسی ساختارهای سه‌بعدی شهری تبدیل شده‌است (Yan et al., 2015; Stal et al., 2013; Stilla & Xu, 2023). این داده‌ها قابلیت برداشت دقیق اطلاعات سه‌بعدی از سطح زمین و عناصر موجود در محیط‌های شهری را دارند و به دلیل این ویژگی‌ها، در حوزه‌های مختلفی از جمله برنامه‌ریزی شهری، پایش محیط‌زیست و مدیریت بحران مورد استفاده قرار می‌گیرند (Candan & 2023; Uciechowska-Grakowicz et al., 2023; Kaçar, 2023). با این وجود، روش‌های سنتی برای تحلیل داده‌های لایدار، به‌ویژه روش‌های آستانه‌گذاری سراسری که از یک آستانه ثابت برای تمامی مناطق استفاده می‌کنند، در محیط‌های پیچیده و ناهمگون شهری به‌خوبی عمل نمی‌کنند (Xiao et al., 2023; Reyes et al., 2023). پیشرفت‌های اخیر در بینایی رایانه‌ای و یادگیری ماشین، شناسایی تغییرات مبتنی بر ابر نقاط را به مرحله خودکار و هوشمند سوق داده است (Tran et al., 2018; De Gelis et al., 2021; Ku et al., 2021).

آستانه‌گذاری سراسری به دلیل عدم توانایی در تطبیق با تغییرات محلی و پیچیدگی‌های موجود در محیط‌های شهری، اغلب منجر به افزایش نرخ خطاهای کاذب می‌شود (Xiao et al., 2023; Stilla & Xu, 2023). در چنین شرایطی، تشخیص تغییرات کوچک در مناطقی با پوشش گیاهی متراکم یا بافت‌های پیچیده شهری دشوار می‌شود. این محدودیت‌ها منجر به کاهش دقت تحلیل‌ها و ناتوانی در شناسایی تغییرات مهمی می‌شود که ممکن است در مناطق خاص رخ دهد. بنابراین، نیاز مبرمی به روش‌های آستانه‌گذاری محلی وجود دارد که بتوانند به‌طور خودکار و براساس ویژگی‌های مکانی هر منطقه، آستانه‌های مورد نظر را تنظیم کنند (Zhang et al., 2023). چنین روش‌هایی با در نظر گرفتن تفاوت‌های مکانی و ساختاری، می‌توانند دقت و صحت تشخیص تغییرات ارتفاعی را بهبود بخشند (Aljumaily et al., 2021). آستانه‌گذاری محلی این امکان را فراهم می‌کند که هر منطقه شهری براساس ویژگی‌های خود به‌طور مجزا تحلیل شود (Yang et al., 2021)، به‌طوری که تغییرات جزئی در مناطق مختلف که در روش‌های سراسری نادیده گرفته می‌شوند، به‌دقت شناسایی شوند (Stilla & Xu, 2023). در این پژوهش، یک روش نوین آستانه‌گذاری محلی تطبیقی برای تشخیص تغییرات ارتفاعی در محیط‌های شهری بالاخص بر اثر طوفان‌های سهمگین در مناطق ساحلی ارائه شده است که با استفاده از داده‌های لایدار دوزمانه، آستانه‌ها را به‌طور پویا و براساس ویژگی‌های محلی تنظیم می‌کند. هدف اصلی این پژوهش، بهبود دقت تشخیص تغییرات ارتفاعی با کاهش نرخ خطاهای کاذب و افزایش کارایی محاسباتی است. این روش بر روی مناطق مختلف از مجموعه داده شهری پیاده‌سازی و ارزیابی شده است تا کارایی آن در شرایط مختلف محیطی بررسی شود.

ساختار مقاله به این صورت است که ابتدا در بخش مرور ادبیات، به بررسی روش‌های موجود در زمینه تشخیص تغییرات ارتفاعی و چالش‌های آن‌ها پرداخته می‌شود. سپس در بخش روش‌شناسی، جزئیات کامل روش پیشنهادی شامل مراحل مختلف پردازش داده‌ها،

الگوریتم آستانه‌گذاری محلی تطبیقی و ابزارهای مورد استفاده شرح داده می‌شود. نتایج به‌دست‌آمده از پیاده‌سازی این روش در بخش نتایج ارائه شده است. در نهایت، در بخش بحث و نتیجه‌گیری، به تحلیل یافته‌ها و پیشنهادات برای پژوهش‌های آینده پرداخته خواهد شد.

۲. مروری بر ادبیات:

تغییر در زمینه‌های مختلف به تغییرات هندسی یا ویژگی‌های ساختاری از پدیده‌ها اشاره دارد که در طول زمان مشاهده می‌شوند (Singh, ۱۹۸۹). در مورد ابر نقاط، تغییر به تغییرات موقعیت و ساختار اشیاء یا تغییرات هندسی در اشکال، ابعاد یا مقادیر شدت بازتاب اشاره دارد. شناسایی تغییر هندسی در ابر نقاط به فرآیند بررسی تفاوت‌های فضایی یک پدیده در دو یا چند مقطع زمانی مختلف مربوط می‌شود (Qin & Gruen, ۲۰۱۴). این کار معمولاً برای کاربردهای نظارت بر محیط‌های شهری یا طبیعی انجام می‌شود که نیاز به شناسایی تغییرات جزئی دارند.

لایدار به‌عنوان یکی از تکنولوژی‌های پیشرفته سنجش از دور فعال، به‌طور گسترده در تشخیص تغییرات ارتفاعی مورد استفاده قرار گرفته است (Wang et al., ۲۰۱۸; Okyay et al., ۲۰۱۹; Stilla & Xu, ۲۰۲۳; Xiao et al., ۲۰۲۳). طی سالهای اخیر، شناسایی و پایش تغییرات ارتفاعی با استفاده از داده‌های لایدار در محیط‌های شهری یکی از زمینه‌های فعال در پژوهش‌های سنجش از دور و مدیریت شهری است (Stal et al., ۲۰۱۳; Wang et al., ۲۰۱۸). لایدار با تولید مدل‌های سه‌بعدی دقیق از سطح زمین و عوارض شهری، اطلاعات گسترده‌ای در مورد تغییرات ساختاری و ارتفاعی فراهم می‌آورد (Zhou et al., ۲۰۰۴). در دهه‌های اخیر، این فناوری به‌طور گسترده در زمینه‌های شهری مورد استفاده قرار گرفته است و روش‌های مختلفی برای تشخیص تغییرات و تحلیل داده‌های سه‌بعدی توسعه یافته‌اند که هر یک از این روش‌ها دارای نقاط قوت و محدودیت‌های خاص خود هستند (Wang et al., ۲۰۱۸; Stilla & Xu, ۲۰۲۳). در این بخش، به مرور کارهای پیشین در زمینه تشخیص تغییرات ارتفاعی و آستانه‌گذاری در محیط‌های شهری با استفاده از داده‌های لایدار پرداخته شده است.

انواع روش‌های شناسایی تغییرات ارتفاعی با لایدار عبارتند از: (۱) روش‌های مستقیم - مقایسه مستقیم فاصله بین ابر نقاط، فاصله ابر نقطه به سطح، فاصله ابر نقطه به خط و فاصله اقلیدسی (Lague et al., ۲۰۱۳; Basgall et al., ۲۰۱۶)، (۲) روش‌های غیر مستقیم - شناسایی تغییرات ارتفاعی با استفاده از مدل‌های استخراج شده از ابر نقاط (Stal et al., ۲۰۱۳; Liu et al., ۲۰۲۱)، (۳) روش‌های آماری و یادگیری ماشین - استفاده از مدل‌های آماری و یادگیری ماشین در شناسایی تغییرات، (۴) روش‌های ترکیبی. با توجه به ویژگی‌های الگوریتم پیشنهادی تحقیق، این مطالعه جزء روش‌های هیبرید متاثر از روش‌های مستقیم، روش غیر مستقیم و روش‌های آماری قرار خواهد گرفت.

همچنین آستانه‌گذاری یکی از رایج‌ترین روش‌ها برای شناسایی تغییرات در داده‌های سه‌بعدی است که بر اساس مقایسه مقادیر مولفه‌های مختلف نظیر فاصله، ارتفاع یا ویژگی‌های دیگر انجام می‌شود. آستانه‌گذاری با توجه به مزایایی از قبیل سادگی و سهولت در پیاده‌سازی و همچنین قابلیت اعمال در طیف وسیعی از داده‌ها به شناسایی تغییرات مشروط به وجود یک معیار آستانه خاص می‌پردازد.

در مطالعه‌ای با رویکرد روش‌های مستقیم (تخمین تغییر مبتنی بر فاصله)، تفاوت‌ها بر اساس فاصله اقلیدسی نقاط دارای موقعیت مکانی نزدیک به هم شناسایی می‌شوند (Stilla & Xu, ۲۰۲۳). در این مطالعه نقاط بیشتر از یک حد آستانه ثابت به عنوان نقاط دارای تغییر و باقی نقاط به عنوان عدم تغییر برچسب گذاری شده‌اند.

در مطالعه‌ای دیگر با هدف تشخیص تغییر و تعیین نوع تغییر از طریق تحلیل هندسی داده‌های ابر نقاط، یک نقشه تفاوت شکل بین مدل‌های ارتفاعی رقومی در دو دوره زمانی مختلف ایجاد می‌شود. با تعریف حد آستانه ثابت نواحی با تفاوت ارتفاعی کوچک به عنوان مناطق بدون تغییر در نظر گرفته می‌شوند و از تقسیم بندی حذف می‌شوند. سپس خواص شیء برای تعیین انواع تغییرات اعمال می‌شود. نتایج تجربی نشان می‌دهد که طرح پیشنهادی به دقت ۸۰ درصد می‌رسد. بیشتر خطاهای این مطالعه در عوارضی با تغییرات ارتفاعی کوچک یا پوشش گیاهی در حال رشد رخ داده است (Teo & Shih, ۲۰۱۳).

در پژوهشی دیگر، رویکرد شناسایی عوارض ساختمانی در محیط شهری مورد بررسی قرار گرفته که در این مطالعه نیز مقایسه مدل‌های ارتفاعی رقومی جهت تعیین مناطق تغییر استفاده شده است. نتایج نشان می‌دهد که روش پیشنهادی می‌تواند با استفاده از تصاویر و داده‌های لایدار به طور موثر تغییرات ساختمان بزرگتر از ۵۰ مترمربع را در یک منطقه شهری تشخیص دهد. علاوه بر این، اکثر تغییرات پوشش گیاهی توسط واریانس پیشنهادی توزیع نرمال حذف می‌شوند (Du et al., ۲۰۱۶).

۱-۲. آستانه‌گذاری سراسری^۱

مطالعات اولیه در زمینه پایش تغییرات ارتفاعی برای تحلیل داده‌های لایدار عمدتاً بر اساس روش‌های حد آستانه ثابت و سراسری صورت گرفته است (Sun et al., ۲۰۲۰; Okyay et al., ۲۰۱۹). در این روش به عنوان یکی از روش‌های رایج، یک حد آستانه برای کل داده تعیین می‌شود و تغییرات ارتفاعی در نقاطی که از این آستانه فراتر رفته‌اند، شناسایی می‌شوند (Yu et al., ۲۰۰۴; Sithole & Vosselman, ۲۰۰۴). اگرچه این روش در محیط‌های همگن و ساده عملکرد مناسبی دارد، اما در محیط‌های پیچیده و ناهمگون شهری مانند مناطقی با پوشش گیاهی متراکم یا بافت‌های ساختاری متنوع، به دلیل یکسان بودن آستانه برای همه مناطق، عملکرد ضعیفی خواهند داشت (Wang et al., ۲۰۲۰).

مطالعات مختلفی نشان داده‌اند که روش‌های سراسری، به‌ویژه در محیط شهرها که دارای تنوع زیادی در عناصر محیطی هستند، منجر به خطاهای کاذب می‌شوند (Weng, ۲۰۱۲; Niemeyer et al., ۲۰۱۴; Hermosilla et al., ۲۰۱۱). برای مثال، در مناطقی با تراکم بالای ساختمان‌ها، تغییرات جزئی ممکن است نادیده گرفته شود، در حالی که در مناطقی با پوشش گیاهی، تغییرات کوچک به اشتباه به عنوان تغییرات ارتفاعی ثبت می‌شوند (Okay et al., ۲۰۱۹; Du et al., ۲۰۱۶). این محدودیت‌ها باعث شده است که پژوهشگران به سمت روش‌های تعیین حد آستانه محلی حرکت کنند.

۲-۲. آستانه‌گذاری محلی تطبیقی^۲

با توجه به ناکارآمدی روش‌های سراسری، روش‌های آستانه‌گذاری محلی و الگوریتم‌های تطبیقی به عنوان راه‌حل‌های جایگزین مطرح شده‌اند. در این روش‌ها، به جای استفاده از یک آستانه ثابت برای کل داده، آستانه‌های محلی به صورت تطبیقی بر اساس شرایط و ویژگی‌های خاص هر ناحیه و سایر خصوصیات ساختاری تنظیم می‌شوند. این روش‌ها به‌ویژه در محیط‌های شهری که دارای ناهمگنی زیادی هستند، بسیار کارآمدتر عمل می‌کنند. به عنوان مثال، در نواحی با تراکم ساختمانی بالا، آستانه‌های متفاوتی نسبت به نواحی دارای پوشش گیاهی یا تراکم کمتر عوارض شهری مورد نیاز بوده و در شناسایی تغییرات کوچک عملکرد مناسبی خواهد داشت.

^۱ Global Thresholding

^۲ Adaptive Local Thresholding

لیو و همکاران در سال ۲۰۲۱ در مطالعه‌ای با استفاده از حد آستانه محلی نسبت به شناسایی تغییرات سه‌بعدی بر روی داده‌های لایدار اقدام کردند (Liu et al., ۲۰۲۱). در این تحقیق حد آستانه بر اساس میانگین فاصله همسایگی و چگالی محلی نقاط محاسبه گردیده که نتایج نشان‌دهنده بهبود فرایند شناسایی تغییرات نسبت به روش‌های آستانه گذاری سراسری می‌باشد. محدودیت این روش، تاثیر چگالی‌های متفاوت نقاط در نواحی مختلف می‌باشد (Liu et al., ۲۰۲۱). اگر چه بررسی مطالعات بیشتر در این حوزه نشان می‌دهد که روش‌های یادگیری ماشین قادر به بهبود تاثیر چگالی متفاوت نقاط در نواحی مختلفی از پردازش ابر نقاط می‌باشند اما همچنان در مقایسه نتایج حاصل از کلیه روش‌ها، مناطق با تراکم بالاتر نتایج با دقت بالاتری را نسبت به نواحی با تراکم پایین‌تر خواهد داشت (De Gelis et al., ۲۰۲۱).

در مطالعه‌ای دیگر، برای شناسایی تغییرات توپوگرافی از حد آستانه استفاده شده است. این آستانه‌ها براساس اصول آماری t -test تعریف شده که برای مقایسه میانگین‌های دو مجموعه داده استفاده می‌شوند. با محاسبه t -Statistic، تفاوت‌های بین دو مدل ارتفاعی رقومی بررسی شده و سطوح معناداری مختلفی مانند ۶۸٪ و ۹۵٪ برای تعیین تغییرات توپوگرافی اعمال می‌شوند (Zhao et al., ۲۰۲۴).

مطالعات بالا نشان داده‌اند که استفاده از روش‌های آستانه‌گذاری محلی تطبیقی، دقت تشخیص تغییرات را به طور چشمگیری افزایش می‌دهد و موجب کاهش خطاهای کاذب در محیط‌های شهری می‌گردد. یکی از چالش‌های اصلی در این حوزه، تنظیم آستانه‌های محلی تطبیقی مناسب برای تشخیص تغییرات در داده‌های چندزمانه و ارائه نتایجی است که در شرایط واقعی شهری قابل اعتماد باشند. بطوریکه تعیین نوع ویژگی‌های محلی که به درستی بتواند تغییرات ارتفاعی را شناسایی نموده و از نظر حجم محاسبات و عملیات پردازش داده‌ها، قابل انجام و مرقوم به صرفه باشد، از نکات قابل توجه در این حوزه می‌باشد. استفاده از روش‌های آماری ساده و کاربردی (واریانس‌های ابر نقاط و نقاط تلفیقی) به‌عنوان معیاری برای تعیین آستانه تغییرات به صورت محلی، به‌عنوان یک نوآوری کلیدی در این پژوهش به شمار می‌آید و می‌تواند در کاهش پیچیدگی محاسبات و افزایش کارایی الگوریتم پیشنهادی در شناسایی تغییرات کوچک موفقیت‌آمیز عمل نماید.

۳. داده‌ها و روش تحقیق:

۳-۱. داده‌های مورد استفاده:

داده‌های مورد استفاده تحقیق توسط مرکز تخصصی فنی مشترک لایدار هیدروگرافی هواپرد^۳ جمع‌آوری شده است. داده‌ها شامل داده‌های هیدروگرافی و توپوگرافی است که پهنه‌های خشکی و همچنین مناطق ساحلی با عمق کم را به تصویر می‌کشد. سنسور مورد استفاده، سنسور نقشه‌برداری و تصویربرداری منطقه ساحلی لایدار^۴ می‌باشد که دارای دقت عمودی ۱۰ سانتی‌متر هستند. داده‌های توپوگرافی دارای دقت ۱۹.۶ سانتی‌متر با سطح اطمینان ۹۵٪ (۱۰ سانتی‌متر RMSE) می‌باشند. همچنین دقت افقی ۱۰۰ سانتی‌متر که برای داده‌های توپوگرافی با سطح اطمینان ۹۵٪ می‌باشد. لازم به ذکر است که فاصله تقریبی نقاط ۰.۷۳ متر می‌باشد. در این مطالعه، از داده لایدار هوایی که در سال‌های ۲۰۱۴ و ۲۰۱۹ برداشت گردیده‌اند^۵، استفاده شده است.


۳-۲. منطقه مورد مطالعه:

^۳ Joint Airborne Lidar Bathymetry Technical Center of Expertise (JALBTCX)

^۴ Coastal Zone Mapping and Imaging Lidar (CZMIL)

^۵ <https://coast.noaa.gov/digitalcoast/data/coastallidar.html>

در این مطالعه از داده‌های لایدار شامل ابر نقاط سه‌بعدی از منطقه ساحلی داک در کارولینای شمالی استفاده گردیده که برای ارزیابی تغییرات محیطی متأثر از طوفان‌های سهمگین در محدوده شهرهای ساحلی مناسب می‌باشند (شکل ۱). فایل لایدار حاوی مختصات سه‌بعدی نقاط (X, Y, Z) و سایر ویژگی‌های مرتبط مانند شدت بازتاب لیزر است. از ویژگی‌های ساختاری این منطقه، وجود ساختمان‌های متعدد با کاربری مسکونی با میانگین مساحت حدود ۲۰۰ متر و با سقف‌های شیبانی در فاصله نزدیک از خط ساحل را می‌توان ذکر نمود. با فاصله گرفتن از خط ساحلی، ساختمان‌ها و تاسیسات بزرگتری با کاربری تجاری یا صنعتی به همراه افزایش تراکم پوشش گیاهی مشاهده می‌گردد. در فاصله‌ای نه چندان دورتر پوشش گیاهی پرتراکم بدون هیچگونه سازه ساختمانی دیده می‌شود.



(شکل ۱) منطقه مورد مطالعه تحقیق

۳-۳. پیش‌پردازش داده‌ها:

قبل از اجرای الگوریتم پیشنهادی، داده‌های لایدار نیاز به پیش‌پردازش و حذف نویز از مجموعه داده دارند تا برای تحلیل‌های بعدی آماده شوند. در این مطالعه، از یک رویکرد ترکیبی فیلتر هدایت‌شده و الگوریتم خوشه‌بندی چگالی‌مبنا برای حذف نویزهای ارتفاعی و نقاط پرت از داده‌های ابر نقاط لایدار استفاده شد. فیلتر هدایت‌شده به دلیل ساختار تطبیقی خود، قادر است نویزهای ارتفاعی را به طور مؤثری کاهش داده و در عین حال لبه‌ها و ویژگی‌های مهم داده‌ها را حفظ کند (Stular, & Lozic, ۲۰۲۰). این فیلتر با استفاده از اطلاعات محلی مانند میانگین و کوواریانس نقاط همسایه، به طور خودکار مولفه‌های فیلترینگ را تنظیم می‌کند، تا یک تعادل بهینه بین حذف نویز و حفظ جزئیات ایجاد کند. همچنین برای حذف نویز نقاط پرت در ابر نقاط از الگوریتم خوشه‌بندی چگالی‌مبنا استفاده شده است. این الگوریتم یک الگوریتم یادگیری ماشین^۶ است که خوشه‌ها را به عنوان مناطقی با تراکم بالا از مجموعه نقاط شناسایی نموده و نقاطی که در مناطقی با تراکم کم قرار دارند را به عنوان نویز پرت^۷ شناسایی می‌کند (Zhao et al., ۲۰۲۴).

۳-۴. الگوریتم پیشنهادی و آستانه‌گذاری محلی تطبیقی:

الگوریتم پیشنهادی تحقیق برای تشخیص و تحلیل تغییرات ارتفاع در داده‌های دو زمانه ابرنقاط لایدار در محدوده شهری طراحی شده است. این فرآیند شامل آماده‌سازی ابرنقاط، استخراج ویژگی‌ها و تشخیص تغییرات با استفاده از هندسه محاسباتی و تحلیل

^۶ Machine Learning

^۷ Outliers

مکانی است. شایان ذکر است با توجه به تاکید بر شناسایی ساختمان‌ها در محیط‌های شهری، فقط نقاط مربوط به بازگشت نهایی برای کاهش افزونگی مورد پردازش قرار می‌گیرند.


۱) محاسبه فاصله نقطه هدف (P) در سری اول داده نسبت به مثلث ایجاد شده از نقاط سری دوم

الف) انتخاب آخرین نقاط برگشتی: در ابتدا آخرین نقاط برگشتی از مجموعه ابر نقاط در هر دو سری (۲۰۱۹ و ۲۰۱۴) برای پردازش‌های بعدی انتخاب می‌شود.

ب) حذف نقاط تکراری و نزدیک به هم: به منظور ساخت شبکه نامنظم مثلثی و عدم مواجهه با خطاهای احتمالی، در یک مرحله فیلترینگ مکانی، نقاط تکراری یا نقاط نزدیک به هم در یک آستانه فاصله حداقلی (۰.۱۵ متر) حذف می‌شوند. قابل ذکر است در تمامی مراحل این تحقیق از حالت استوانه‌ای برای شناسایی و انتخاب نقاط همسایگی در شعاع ۲ استفاده می‌شود.

پ) استخراج شبکه نامنظم مثلثی: برای محاسبه فاصله نقطه P از مجموعه نقاط ۲۰۱۹، نیاز به تولید شبکه نامنظم مثلثی از نزدیکترین نقاط ۲۰۱۴ واقع در همسایگی نقطه P به شعاع ۲ خواهد بود. لذا شبکه نامنظم مثلثی از نزدیکترین نقاط محلی ۲۰۱۴ استخراج گردید.

ت) محاسبه فاصله نقطه از مثلث: برای هر نقطه P_1 از نقاط ۲۰۱۹، حداقل فاصله تا شبکه نامنظم مثلثی تشکیل شده توسط نزدیکترین نقاط همسایگی ۲۰۱۴ محاسبه می‌شود. قابل ذکر است فاصله با استفاده از تابع $PTTD^A$ و بر اساس فاصله نقطه P_1 از تصویر نقطه P_1 (P_1') محاسبه گردیده است. در صورت عدم فرارگیری تصویر نقطه P_2 درون مثلث (P_2')، فاصله نقطه P_2 از نزدیکترین لبه مثلث (P_2'') محاسبه شده و به عنوان یک ویژگی توصیفی برای نقطه P_2 ذخیره خواهد شد. همچنین در صورت عدم موفقیت در تشکیل شبکه نامنظم مثلثی به دلیل تعداد نقاط، یک مکانیزم جایگزین فاصله تا نزدیکترین نقطه را محاسبه می‌کند (شکل ۲).



(شکل ۲) چگونگی محاسبه فاصله نقطه از مثلث

۲) محاسبه حد آستانه محلی تطبیقی

ج) محاسبه میانگین فاصله برای هر نقطه P در سری نقاط ۲۰۱۹ از مجموعه نقاط ۲۰۱۴ واقع در همسایگی ۲ از نقطه P: برای بدست آوردن حد آستانه محلی تطبیقی، فاصله نقطه هدف (P) از سری نقاط ۲۰۱۹ نسبت به مجموعه نقاط ۲۰۱۴ واقع در همسایگی به شعاع ۲ از نقطه هدف محاسبه می‌شود و به عنوان یک ویژگی توصیفی برای نقطه P از سری نقاط ۲۰۱۹ ذخیره می‌شود.

^A Point To Triangular Distance

چ) ترکیب ابرنقاط: ابر نقاط سال ۲۰۱۴ با ابرنقاط سال ۲۰۱۹ ادغام می‌شوند.

ح) محاسبه واریانس ارتفاعی محلی نقاط: برای هر نقطه P از مجموعه نقاط ۲۰۱۹، واریانس ارتفاعی محلی نقاط واقع در همسایگی نقطه P به شعاع r برای مجموعه نقاط سال ۲۰۱۴، سال ۲۰۱۹ و همچنین مجموعه ترکیبی آنها (۲۰۱۹ + ۲۰۱۴) استخراج می‌شود و به عنوان ویژگی‌های توصیفی برای نقطه P ذخیره خواهد شد.

۳) تشخیص نقاط دارای تغییرات ارتفاعی

خ) محاسبه شاخص تغییرات:

$$\text{Index Change} = 2 * \text{Var_Both} - (\text{Var}^{2019} + \text{Var}^{2014}) \quad \text{رابطه (۱)}$$

Var^{2014} : واریانس ارتفاعی نقاط ۲۰۱۴ در شعاع همسایگی r از نقطه P

Var^{2019} : واریانس ارتفاعی نقاط ۲۰۱۹ در شعاع همسایگی r از نقطه P

Var_Both : واریانس ارتفاعی نقاط ترکیبی در شعاع همسایگی r از نقطه P

د) حد آستانه محلی:

در این بخش با استفاده از شاخص تغییرات بدست آمده از مرحله قبل و میانگین فاصله نقطه هدف (P) از نقاط ۲۰۱۴ واقع در همسایگی به شعاع r از نقطه P، حد آستانه تغییرات ارتفاعی محاسبه می‌گردد:

$$\text{Threshold} = \mu_{Pt+1} * \text{Index Change} \quad \text{رابطه (۲)}$$


μ_{Pt+1} : میانگین فاصله اقلیدسی نقطه هدف از نقاط ۲۰۱۴ در شعاع همسایگی r

ذ) شناسایی تغییرات ارتفاعی:

به نقاطی که فاصله محاسبه شده آن‌ها از حد آستانه محلی (dp) بیشتر باشد، برچسب تغییر ارتفاع اختصاص داده می‌شود و در غیر اینصورت نقطه هدف به عنوان نقطه بدون تغییرات ارتفاعی شناخته خواهد شد.

$$\text{If } dp > \text{Threshold Then } P = \text{Change} \quad \text{رابطه (۳)}$$

$$\text{Else } P \neq \text{Change}$$



(شکل ۳) فلوچارت روش تحقیق

۳-۵. تحلیل حساسیت الگوریتم پیشنهادی به تغییرات شعاع همسایگی (۲):

یکی از عوامل کلیدی و تاثیرگذار بر عملکرد الگوریتم پیشنهادی، شعاع همسایگی است که مستقیماً بر محاسبات فاصله، واریانس و حد آستانه تأثیر می‌گذارد. با توجه به دقت مکانی برداشت ابر نقاط و همچنین میانگین فاصله ۵۰ سانتیمتری نقاط از یکدیگر در هر یک از داده‌های سری زمانی، تأثیر تغییر مقدار شعاع همسایگی از ۱.۵ تا ۷ متر بر دقت شناسایی تغییرات ارزیابی گردید.

۳-۶. ارزیابی دقت نتایج الگوریتم پیشنهادی:

در ادامه، به منظور ارزیابی کمی دقت نتایج تغییراتی سه‌بعدی در محیط شهری که توسط الگوریتم پیشنهادی تحقیق شناسایی گردیده است، از معیارهای کامل بودن^۹، درستی^{۱۰}، کیفیت^{۱۱} و $Score-F_1$ استفاده می‌گردد. چهار حالت ممکن برای هر نقطه وجود دارد:

True Positive (TP): نقطه‌ای که تغییر کرده و توسط الگوریتم نیز به درستی به‌عنوان تغییر شناسایی شده است.

False Positive (FP): نقطه‌ای که تغییر نکرده، اما توسط الگوریتم به اشتباه به‌عنوان تغییر شناسایی شده است.

False Negative (FN): نقطه‌ای که تغییر کرده، اما توسط الگوریتم شناسایی نشده است.

True Negative (TN): نقطه‌ای که تغییر نکرده و به درستی توسط الگوریتم شناسایی نشده است.

معیار کامل بودن: درصد نقاط تغییر یافته‌ای که به درستی شناسایی شده‌اند:

$$\text{Completeness} = \frac{TP}{TP+FN} \quad \text{رابطه (۴)}$$

معیار درستی: درصد نقاط شناسایی شده به‌عنوان تغییر که واقعاً تغییر کرده‌اند که قابلیت اطمینان تشخیص تغییرات سه‌بعدی را تخمین می‌زند:

^۹ Completeness

^{۱۰} Correctness

^{۱۱} Quality

$$\text{Correctness} = \frac{TP}{TP+FP} \quad \text{رابطه (۵)}$$

کیفیت کلی: نسبت نقاط درست‌شناسایی شده به کل نقاط بررسی شده:

$$\text{Quality} = \frac{TP}{TP+FN+FP} \quad \text{رابطه (۶)}$$

Score-F1: این معیار بیانگر ترکیب هارمونیک کامل بودن و درستی است:

$$\text{Score - F1} = \frac{2 \times \text{Completeness} \times \text{Correctness}}{\text{Completeness} + \text{Correctness}} \quad \text{رابطه (۷)}$$

به منظور ارزیابی دقت نقاط، مناطق دارای تغییر به صورت دستی از نواحی مشخص شده در لایه تفاضل دو مدل رقومی زمین واقعی^{۱۲} بدست آمده از ابر نقاط سه‌بعدی در سال‌های ۲۰۱۴ و ۲۰۱۹ ترسیم گردیده است تا بتوانیم محدوده ساختمان‌های دارای تغییر، حذف شده و یا ایجاد شده را جهت ارزیابی دقت کمی نتایج تحقیق ترسیم نماییم. با توجه به محدوده عوارض تغییر یافته در طول زمان، معیارهای کمی کامل بودن، درستی، کیفیت کلی و ترکیب هارمونیک برای هر ۳ بخش از محدوده ارزیابی نتایج محاسبه و مورد مقایسه قرار گرفته است.

۴. نتایج تحقیق:

در این تحقیق، شاخص تغییرات بر اساس واریانس ارتفاعی نقاط واقع در همسایگی از نقطه هدف (P) به شعاع r محاسبه می‌گردد. با فرض قرارگیری نقطه P در کاربری مشابه با نقاط پیرامونی، متغیر عددی واریانس ارتفاعی نقطه P در کاربری ساختمان و یا زمین هموار اعم از چمنزار، آسفالت و یا زمین خاکی با توجه به سطوح مسطح مقدار عددی پایینی را به خود خواهند گرفت. در صورتی که نقاط در کاربری پوشش گیاهی با توجه به سیگنال بازگشتی از قسمت‌های مختلف درخت، واریانس ارتفاعی بالاتری را نسبت به سطوح مسطح دریافت خواهد نمود.

در این پژوهش، ایده نوآورانه جهت شناسایی تغییرات ارتفاعی با بهره‌گیری از ترکیب ابر نقاط در سری زمانی مطرح گردید. در نواحی بدون تغییر، ابر نقاط ترکیبی موجب تولید ابر نقطه مشابه با روند هر دو سری ابر نقطه گردیده با این تفاوت که چگالی نقاط در واحد سطح افزایش خواهد یافت. این در حالی است که نواحی دارای تغییر ارتفاعی، شاهد ایجاد دو سطح در ارتفاع‌های متفاوت خواهیم بود که بسته به نوع تغییر اعم از اضافه و یا حذف یک ساختمان و یا تغییر کاربری از درخت به ساختمان و بالعکس حالات متفاوتی ایجاد می‌کند (شکل ۴). در هر صورت وجود نقاط در ابر نقطه واحد که دارای سطوح ارتفاعی متفاوتی باشند، منجر به تولید مقدار عددی واریانس ارتفاعی بالا خواهد شد.



(شکل ۴) تاثیر ترکیب دو ابر نقطه و ایجاد ابر نقطه واحد (a) شکل سمت راست ابر نقاط ترکیبی (b) عکس هوایی ۲۰۱۴ (c) عکس هوایی ۲۰۱۹ در شکل ابر نقاط، دو ساختمان سمت چپ جدید می‌باشند اما ابر نقاط سه ساختمان سمت راست، با نقاط سه ساختمان قدیمی ترکیب شده و ابر نقطه با سطوح ارتفاعی متفاوتی برای هر نقطه برداشت شده ایجاد خواهند نمود.

مطابق جدول ۱ در مناطقی با عدم تغییر کاربری (مانند ساختمان و یا زمین) علاوه بر نزدیک بودن مقدار عددی واریانس ارتفاعی در زمان‌های ۲۰۱۴ و ۲۰۱۹، مقدار عدد واریانس ارتفاعی در مجموعه نقاط ترکیبی (۲۰۱۹+۲۰۱۴) مقدار عددی یکسانی همانند واریانس ارتفاعی نقاط در سال ۲۰۱۴ و ۲۰۱۹، اخذ نموده است.


این در صورتی است که در صورت تغییر کاربری همراه با تغییرات ارتفاعی و یا تغییرات ارتفاعی جدید بدون تغییر کاربری (افزایش تعداد طبقات یک ساختمان و یا رشد قابل توجه پوشش گیاهی)، مقدار واریانس نقاط ترکیبی با مقدار واریانس هر یک از مجموعه ابر نقاط دارای اختلاف قابل توجهی خواهد بود که شناسایی تغییرات کاربری را تسهیل می‌نماید. برای نمونه واریانس نقاط ۲۰۱۴، واریانس نقاط ۲۰۱۹ و همچنین واریانس نقاط ترکیبی برای بخشی از سطح زمین بایر که دارای تغییرات ارتفاعی نبوده به ترتیب ۰.۰۰۱۲، ۰.۰۰۲۵ و ۰.۰۰۷۸ می‌باشد. این در صورتی است که در منطقه‌ای دیگر که دارای تغییر کاربری زمین به ساختمان بوده مقادیر عددی واریانس به ترتیب ۰.۰۰۰۰۴۷، ۰.۰۰۰۰۷۳ و ۴۱.۴ محاسبه گردیده است که افزایش مقدار عددی واریانس نقاط ترکیبی قابل توجه می‌باشد.


مباحث مطرح شده بالا در مواردی که نقطه هدف (P) در بخش لبه عوارض مانند لبه ساختمان‌ها قرار می‌گیرد و بخشی از نقاط در محدوده سقف ساختمان و بخشی دیگر بر روی سطح زمین قرار می‌گیرند می‌تواند حالات پیچیده‌تری را ایجاد نماید.

(جدول ۱) تغییرات متغیر واریانس بر اساس تغییر و یا عدم تغییر کاربری زمین

واریانس	عدم تغییر ارتفاعی		تغییرات ارتفاعی بدون تغییر کاربری		تغییرات ارتفاعی همراه با تغییر کاربری					
	ساختمان	زمین	ساختمان	درخت	زمین به درخت	زهین به ساختمان	درخت به زمین	درخت به ساختمان	ساختمان تخریبی	ساختمان به زمین
Var _{۲۰۱۴}	نسبتاً پایین	پایین	پایین	متوسط	پایین	پایین	متوسط	متوسط	پایین	پایین
Var _{۲۰۱۹}	نسبتاً پایین	پایین	پایین	متوسط	متوسط	پایین	پایین	پایین	بالا	پایین
Var_Both	نسبتاً پایین	پایین	بسیار بالا	نسبتاً بالا	بسیار بالا	بسیار بالا	بسیار بالا	بسیار بالا	بسیار بالا	بسیار بالا

با توجه به اهمیت شعاع همسایگی و تاثیر آن بر نتایج تحقیق، تحلیل حساسیت بر الگوریتم پیشنهادی بر اساس مولفه شعاع همسایگی از مقدار عددی ۱.۵ تا ۷ متر با دامنه تغییرات ۲ واحد مورد بررسی قرار گرفته است. در شکل ۵ تاثیر تحلیل حساسیت متغیر شعاع همسایگی بر نتایج تغییرات ارتفاعی الگوریتم پیشنهادی نشان می‌دهد که شعاع ۳ متر بهترین نتیجه را از هر دو بعد تعداد نقاط درست شناسایی شده و زمان پردازش ابر نقاط ایجاد نموده است که این شعاع به عنوان شعاع همسایگی انتخاب گردید.







(شکل ۵) نتایج تحلیل حساسیت الگوریتم پیشنهادی بر اساس متغیر شعاع همسایگی نقاط

در ادامه برای نمایش نتایج تحقیق به عنوان نمونه سه زیرمجموعه از محدوده شهر انتخاب شدند که دارای تغییرات محسوس ارتفاعی بوده و همچنین شرایط محیطی متفاوتی داشته باشند.

زیرمجموعه اول) این بخش از محدوده شهری در فاصله نزدیکتر از ۹۰ متر از خط ساحل قرار گرفته و تعدادی ساختمان کوچک در تصویر سال ۲۰۱۴ قابل مشاهده می باشد که در تصویر سال ۲۰۱۹، آثاری از آنها وجود نداشته و یک تعداد ساختمان های منظم و یکدست در این محدوده ساخته شده است. به نظر می رسد ساختمان های کوچک بر اثر طوفان های شدید بوقوع پیوسته در منطقه، تخریب شده و توسط ساختمان های جدید بازسازی شده اند.

هدف از انتخاب این بخش، ارزیابی الگوریتم پیشنهادی تحقیق در خصوص شناسایی حذف و یا ایجاد ساختمان های جدید در محدوده شهری متأثر از پدیده های طبیعی از جمله طوفان های شدید خواهد بود. همانگونه که در شکل ۶ مشاهده می گردد ۳ ساختمان کوچک تخریب شده و چندین ساختمان همشکل و در یک راستا ایجاد شده است. در شناسایی تغییرات ارتفاعی، ساختمان حذف و اضافه شده به درستی تشخیص داده شده اند. همچنین دو ساختمان تخریب شده و در جایگزین آنها، ساختمان های بزرگتری ایجاد شده که تغییرات ارتفاعی قسمت های قدیمی و جدید ساختمان به درستی مشخص گردیده اند.





(شکل ۶) تصاویر مربوط به شناسایی تغییرات سه بعدی در بخش یک (a) عکس هوایی ۲۰۱۴، (b) عکس هوایی ۲۰۱۹، (c) مدل ارتفاعی رقومی ۲۰۱۴، (d) مدل ارتفاعی رقومی ۲۰۱۹، (e) اختلاف دو مدل ارتفاعی (DEM ۲۰۱۹ – DEM ۲۰۱۴)، (f) فاصله ابر نقاط ۲۰۱۹ از لایه TIN نقاط ۲۰۱۴، (g) نقاط شناسایی شده به عنوان تغییر به همراه عکس هوایی ۲۰۱۴، (h) نقاط شناسایی شده به عنوان تغییر به همراه عکس هوایی ۲۰۱۹

وضعیت کلی نقاط و مقادیر معیارهای ارزیابی دقت نتایج تحقیق در زیرمجموعه اول منطقه مورد مطالعه به شرح ذیل می‌باشد:

$$TP = ۸۹۸۵$$

$$FP = ۱۳۹۷$$

$$FN = ۱۲۱$$

$$TN = ۹۰۵۳$$

$$Completeness = \frac{۸۹۸۵}{۸۹۸۵+۱۲۱} = ۰.۹۸$$


$$Correctness = \frac{۸۹۸۵}{۸۹۸۵+۱۳۹۷} = ۰.۸۷$$

$$Quality = \frac{۸۹۸۵}{۸۹۸۵+۱۲۱+۱۳۹۷} = ۰.۸۶$$

$$Score - F1 = \frac{۲ * ۰.۹۸ * ۰.۸۷}{۰.۹۸ + ۰.۸۷} = ۰.۹۲$$

زیرمجموعه دوم) در این بخش از محدوده شهری نیز رویکرد تخریب یک ساختمان و همچنین ساخت یک ساختمان بزرگ و تغییرات شناسایی شده متاثر از حذف، اضافه و یا تغییرات ارتفاعی آنها مورد بررسی قرار گرفته است. همانگونه که در شکل مشاهده می‌گردد، ساختمان‌هایی در این محدوده تخریب شده‌اند و به شکل زمین مسطح تغییر یافته‌اند. همچنین در بخش مرکزی تصویر یک ساختمان دیگر تخریب شده و جایگزین آن یک ساختمان بزرگتر ایجاد شده است (شکل ۷).





(شکل ۷) تصاویر مربوط به شناسایی تغییرات سه بعدی در بخش دو (a) عکس هوایی ۲۰۱۴، (b) عکس هوایی ۲۰۱۹، (c) مدل ارتفاعی رقومی ۲۰۱۴، (d) مدل ارتفاعی رقومی ۲۰۱۹، (e) اختلاف دو مدل ارتفاعی (DEM ۲۰۱۹ - DEM ۲۰۱۴)، (f) فاصله ابر نقاط ۲۰۱۹ از لایه TIN نقاط ۲۰۱۴، (g) نقاط شناسایی شده به عنوان تغییر به همراه عکس هوایی ۲۰۱۴، (h) نقاط شناسایی شده به عنوان تغییر به همراه عکس هوایی ۲۰۱۹

وضعیت کلی نقاط و مقادیر معیارهای ارزیابی دقت نتایج تحقیق در زیرمجموعه دوم منطقه مورد مطالعه به شرح ذیل می‌باشد:

$$TP = 4474$$

$$FP = 210$$

$$FN = 21$$

$$TN = 4239$$

$$Completeness = \frac{4474}{4474+21} = 0.995$$


$$Correctness = \frac{4474}{4474+210} = 0.96$$

$$Quality = \frac{4474}{4474+21+210} = 0.95$$

$$Score - F1 = \frac{2 \times 0.995 \times 0.96}{0.995 + 0.96} = 0.98$$

زیرمجموعه سوم) در این بخش از محدوده شهری، توجه به تغییرات پوشش گیاهی و حذف و یا تغییر آن به کاربری مسکونی و تاثیر پوشش گیاهی متراکم در شناسایی تغییرات ارتفاعی مورد ارزیابی قرار گرفته است. در عکس هوایی ۲۰۱۴ شاهد پوشش گیاهی متراکمی از درختان هستیم. در تصویر مربوط به ۲۰۱۹، پوشش گیاهی این بخش از شهر به صورت کامل حذف شده و دو ساختمان در این ناحیه ایجاد گردیده است.

نتایج دریافتی از این بخش نشان می‌دهد اگرچه وجود نقاط متعدد پراکنده بیانگر تغییرات وسیع ارتفاعی در سطح محدوده می‌باشد اما ساختمان‌ها در این بخش از منطقه به صورت کامل و با ابر نقاط متراکم مشابه با دو بخش قبلی شناخته نشده‌اند. چگالی ابر نقاط در این محدوده کمتر از دو محدوده قبلی می‌باشد که در نتیجه محدوده قرارگیری ساختمان‌ها در این بخش در مقایسه با دو بخش قبلی، به درستی تعیین نشده و تعداد نقاط نامنظمی به رنگ قرمز نشان‌دهنده وجود عارضه‌ای با ارتفاع متفاوت از پوشش گیاهی می‌باشند و مرز ساختمان به درستی ترسیم نگردیده است (شکل ۸).





(شکل ۸) تصاویر مربوط به شناسایی تغییرات سه بعدی در بخش سه (a) عکس هوایی ۲۰۱۴، (b) عکس هوایی ۲۰۱۹، (c) مدل ارتفاعی رقومی ۲۰۱۴، (d) مدل ارتفاعی رقومی ۲۰۱۹، (e) اختلاف دو مدل ارتفاعی (DEM ۲۰۱۹ – DEM ۲۰۱۴)، (f) فاصله ابر نقاط ۲۰۱۹ از لایه TIN نقاط ۲۰۱۴، (g) نقاط شناسایی شده به عنوان تغییر به همراه عکس هوایی ۲۰۱۴، (h) نقاط شناسایی شده به عنوان تغییر به همراه عکس هوایی ۲۰۱۹

وضعیت کلی نقاط و مقادیر معیارهای ارزیابی دقت نتایج تحقیق در زیرمجموعه سوم منطقه مورد مطالعه به شرح ذیل می‌باشد:

$$TP = 3380$$

$$FP = 63$$

$$FN = 619$$

$$TN = 1007$$

$$Completeness = \frac{3380}{3380 + 619} = 0.85$$

$$Correctness = \frac{3380}{3380 + 63} = 0.98$$

$$Quality = \frac{3380}{3380 + 619 + 63} = 0.83$$

$$Score - F1 = \frac{2 * 0.85 * 0.98}{0.85 + 0.98} = 0.91$$

در بررسی نتایج در هر سه زیرمجموعه منطقه مورد مطالعه، معیار کامل بودن از محدوده عددی ۰.۸۵ تا ۰.۹۹۵ بدست آمده است. برای دو بخش از داده‌ها، این معیار بالای ۹۸ درصد بوده که نشان می‌دهد الگوریتم پیشنهادی تحقیق توانسته است بیشتر نقاط دارای تغییر واقعی را شناسایی نماید.

معیار درستی نیز از محدوده عددی ۰.۸۷ تا ۰.۹۸ بدست آمده است. با توجه به اینکه این معیار میزان صحت و اطمینان نقاط شناسایی شده به عنوان تغییر را بیان می‌نماید، می‌توان نتیجه گرفت که علاوه بر درصد بالای کامل بودن نقاط شناسایی شده به عنوان تغییر، میزان اطمینان به این نتایج نیز از درصد بالایی برخوردار است.

معیار کیفیت کلی نتایج نیز در محدوده ۰.۸۳ تا ۰.۹۵ قرار دارد که این مولفه، ترکیبی از معیار کامل بودن نتایج شناسایی و اطمینان به آنها می‌باشد. معیار $F1$ که یک ترکیب هارمونیک از کامل بودن و درستی نتایج تحقیق است، با توجه به مقادیر عددی بالا در این معیار نیز نشان‌دهنده عملکرد متعادل و قابل قبول الگوریتم در شناسایی تغییرات است.

بایستی متذکر شویم که الگوریتم پیشنهادی تحقیق در بخش تغییرات کاربری زمین به ساختمان و یا تخریب و بازسازی ساختمان به خوبی قادر به تشخیص تغییرات ارتفاعی بوده و دقت بالای ۹۸ درصد در معیار کامل بودن نتایج شناسایی صحیح این نوع تغییرات کاربری را نشان می‌دهد. در حالی که در تغییر کاربری پوشش گیاهی متراکم به ساختمان دقت پایین‌تری نشان داده بطوریکه در این بخش نیز دقت ۸۵ درصد در معیار کامل بودن شناسایی صحیح و با اطمینان نقاط توسط الگوریتم پیشنهادی تحقیق تخمین زده می‌شود.

در این تحقیق، رویکردی مبتنی بر محاسبه فاصله یک ابرنقطه از مثلث‌های ایجادشده در مجموعه دیگر ابرنقاط ارائه شد. برخلاف روش ارائه‌شده در مقاله (Liu et al., ۲۰۲۱) که بر مقایسه نقطه‌محور و استفاده از آستانه‌های تطبیقی بر اساس چگالی محلی ابرنقاط متکی است، روش پیشنهادی ما از آستانه‌گذاری بر پایه واریانس داده‌ها در یک شعاع همسایگی مشخص استفاده می‌کند. این ویژگی سبب می‌شود که الگوریتم پیشنهادی وابستگی کمتری به تغییرات چگالی ابرنقاط در نواحی مختلف داشته باشد. همچنین استفاده از مثلث‌بندی در محاسبه فاصله بین دو ابر نقطه، پایداری بالاتری نسبت به محاسبه مستقیم فاصله دو ابر نقطه خواهد داشت. نتایج به‌دست‌آمده نشان می‌دهد که روش پیشنهادی از نظر درستی و کامل بودن عملکرد مطلوبی دارد. در دو مجموعه داده، مقدار کامل بودن بیش از ۹۸ درصد برآورد شده است که نسبت به روش مقاله مرجع، که در برخی شرایط دچار افت عملکرد در نواحی کم‌چگالی می‌شود، بهبود قابل توجهی نشان می‌دهد. در زیرمجموعه دیگر، مقدار کامل بودن ۸۵ درصد بوده است که نشان‌دهنده تأثیر ویژگی‌های داده‌های ورودی در تغییرات کاربری از پوشش گیاهی به ساختمان بر عملکرد الگوریتم پیشنهادی است. به‌طور کلی، نتایج نشان می‌دهد که روش پیشنهادی می‌تواند در سناریوهای با چگالی متغیر نقاط، عملکرد پایداری نسبت به روش‌های وابسته به چگالی داشته باشد (Liu et al., ۲۰۲۱).

نتایج این تحقیق همچنین با مقاله (De Gelis et al., ۲۰۲۱) که تحت عنوان "Change Detection in Urban Point Clouds: An Experimental Comparison with Simulated ۳D Datasets" در آن مقاله، روش‌های مختلفی از جمله فاصله نقطه به نقطه^{۱۳}، مقایسه چندمقیاسی مدل به مدل در ابر نقطه‌ای^{۱۴}، تفاضل مدل‌های سطح دیجیتال^{۱۵} و یک مدل جنگل تصادفی^{۱۶} با ویژگی پایداری برای شناسایی تغییرات در ابر نقاط شهری مورد بررسی قرار گرفته‌اند. نتایج نشان می‌دهد که برخی از این روش‌ها، به‌ویژه روش فاصله نقطه به نقطه (دارای دقت معیار کامل بودن از ۵۰ تا ۶۲ درصد و حساسیت بالا به تغییر چگالی) و روش مقایسه چندمقیاسی مدل به مدل در ابر نقطه‌ای (دارای دقت معیار کامل بودن از ۳۳ تا ۶۰ درصد و وابسته به تراکم نقاط)، در نواحی با چگالی کم ابر نقاط دچار افت دقت شده‌اند. همچنین، روش جنگل تصادفی با ویژگی پایداری عملکرد بهتری نسبت به روش‌های سنتی داشته است اما همچنان وابسته به تراکم داده‌های آموزشی و تنظیمات آستانه‌ای خاصی بوده است.

در مقایسه با روش‌های مورد بررسی در مقاله (De Gelis et al., ۲۰۲۱)، روش پیشنهادی ما به دلیل استفاده از فاصله‌سنجی مبتنی بر مثلث‌بندی و آستانه‌گذاری بر اساس واریانس داده‌ها، از تغییرات چگالی ابر نقاط تأثیر نمی‌پذیرد و عملکرد پایداری نسبت به روش‌های وابسته به چگالی داشته است. همان‌طور که در مقاله مرجع نشان داده شده، روش‌هایی مانند تفاضل مدل‌های سطح دیجیتال در نواحی دارای تراکم پایین‌تر دقت کمتری داشته‌اند، زیرا فرآیند درون‌یابی باعث از دست رفتن جزئیات شده است. در مقابل، روش پیشنهادی به دلیل محاسبه مستقیم فاصله نقاط از سطوح مثلثی، توانسته است در نواحی کم‌چگالی نیز عملکرد پایداری ارائه دهد. همچنین، روش پیشنهادی در برخی موارد عملکرد بهتری نسبت به جنگل تصادفی داشته است، زیرا نیازی به داده‌های آموزشی گسترده و تنظیمات آستانه‌ای خاص ندارد.

۵. بحث:

^{۱۳} Cloud-to-Cloud Distance (C²C)

^{۱۴} Multiscale Model-to-Model Cloud Comparison (M³C²)

^{۱۵} Differencing of Digital Surface Models (DSMd)

^{۱۶} Random Forest

داده‌های مورد استفاده در این مطالعه، ابر نقاط برداشت شده در سال‌های ۲۰۱۴ و ۲۰۱۹ می‌باشد. با توجه به عدم دسترسی به مشاهدات میدانی، نواحی تغییر در حیطه ساخت و ساز ساختمانی با استفاده از True DEM استخراج گردیده است. از سوی دیگر محدوده فصلی برداشت داده‌ها یکسان نبوده بطوریکه تغییرات پوشش گیاهی در عکس هوایی بدلیل تغییرات فصل قابل تشخیص می‌باشد. لذا در بخش نتایج، اطلاعات بدست آمده در محدوده‌های تغییرات ساختمانی بوده و از بیان تغییرات در محدوده‌های پوشش گیاهی و رشد درختان بدلیل عدم داده‌های مرجع جهت اعتبار سنجی نتایج اجتناب گردید.

در تحلیل حساسیت الگوریتم پیشنهادی بر اساس متغیر شعاع همسایگی، افزایش شعاع موجب افزایش تصاعدی زمان پردازش داده‌ها خواهد شد. اگرچه افزایش شعاع همسایگی در شناسایی تغییرات عمده اعم از شناسایی ساختمان‌های جدید و یا ساختمان‌های تخریب شده تاثیر چندانی نداشته است اما در نواحی با تغییرات ارتفاعی کمتر اعم از تغییرات پوشش گیاهی متاثر از رشد گیاهان و یا تغییرات فصلی آنها، تاثیرگذار می‌باشد. با افزایش شعاع همسایگی نقاط بیشتری به عنوان نواحی دارای تغییر انتخاب می‌شوند که موجب افزایش نقاط نادرست و کاهش کارایی الگوریتم پیشنهادی تحقیق خواهد شد.

مقایسه نتایج در بخش‌های مختلف بیانگر این موضوع است که الگوریتم پیشنهادی تحقیق در نواحی که تغییرات کاربری از پوشش گیاهی به ساختمان است، قادر به تشخیص درست نقاط دارای تغییر نمی‌باشد. با توجه به ماهیت ساختاری پوشش گیاهی و بازگشت-های متعدد نور لیزر از قسمت‌های مختلف گیاه موجب می‌گردد نقاط همسایگی ثبت شده از گیاهان، دارای نوسانات ارتفاعی متعددی باشند. نقاط متعلق به پدیده درخت در صورت تشکیل شبکه نامنظم مثلی، تشکیل یک سطح ناهموار می‌دهند و مقایسه ارتفاع نقاط در سری زمانی دیگر با سطح مثلث‌بندی ایجاد شده به منظور شناسایی نقاط دارای تغییر امری دشوار بوده و نواحی دارای تغییر از سطوح درختان را با خطا همراه خواهد نمود.

در ادامه در جدول ۲ به مقایسه نتایج آماری الگوریتم پیشنهادی با نتایج مقالات مرجع خواهیم پرداخت:

(جدول ۲) مقایسه آماری نتایج الگوریتم پیشنهادی با نتایج مطالعات پیشین

روش	معیار کامل بودن	تاثیر چگالی نقاط
الگوریتم پیشنهادی	۸۵ تا ۹۸ درصد	حساسیت پایین به تغییر چگالی
C ² C (De Gelis et al., ۲۰۲۱)	۵۰ تا ۶۲ درصد	حساسیت بالا به تغییر چگالی
M ² C ² (De Gelis et al., ۲۰۲۱)	۳۳ تا ۶۰ درصد	وابسته به تراکم نقاط، کاهش دقت در نواحی کم چگالی
RF (De Gelis et al., ۲۰۲۱)	۶۴ تا ۷۱ درصد	نسبتاً مقاوم به تغییرات چگالی، نیازمند داده‌های آموزشی زیاد
C ² C (Liu et al., ۲۰۲۱)	۹۰ تا ۹۴ درصد	حساسیت بالا به تغییر چگالی

۵. نتیجه‌گیری:

شناسایی تغییرات ارتفاعی در محیط شهری با بهره‌گیری از آستانه‌گذاری محلی تطبیقی که در این پژوهش ارائه شد، نشان داد که می‌تواند به‌طور قابل توجهی دقت تشخیص تغییرات ارتفاع را در محیط‌های پیچیده شهری افزایش دهد. این روش نوآورانه با تطبیق آستانه تغییرات بر اساس ویژگی‌های محلی، قادر است تغییرات کوچک و محلی را که در روش‌های سراسری نادیده گرفته می‌شوند، تشخیص دهد. نتایج نشان دادند که استفاده از شبکه نامنظم مثلی در مدل‌سازی سطوح زمین و سقف ساختمان‌ها ایده مطلوبی بوده و منجر به شناسایی دقیق با معیار کامل بودن و صحت بالا می‌شود. این در صورتی است که استفاده از شبکه نامنظم مثلی در سطوح پوششی درختان به منظور تغییرات کاربری باید در دوره‌های فصلی مشابه در زمان برداشت دو ابر نقطه مورد بررسی قرار گیرند. از این رو، این روش می‌تواند در کاربردهای مختلفی مانند برنامه‌ریزی شهری، پایش تغییرات زیرساخت‌ها و مدیریت بلایا مورد استفاده

قرار گیرد. با توجه به افزایش سرعت پردازش سری زمانی ابر نقاط، این پژوهش می‌تواند به‌عنوان یک گام مهم در جهت بهبود تکنیک‌های تشخیص تغییرات ارتفاعی در محیط‌های شهری بر اثر حوادث طبیعی از جمله طوفان در نواحی ساحلی مورد استفاده قرار گیرد و زمینه‌ساز توسعه روش‌های دقیق‌تر و کارآمدتر در پایش شهری و مدیریت بلایا باشد.

مراجع

۱. Abellan, A., Derron, M.-H., Jaboyedoff, M. (۲۰۱۶). Use of ۳D point clouds in geohazards special issue: current challenges and future trends. *Remote Sens.* ۸ (۲), ۱۳۰.
۲. Aljumaily, H., Laefer, D. F., Cuadra, D., & Velasco, M. (۲۰۲۱). Voxel change: Big data-based change detection for aerial urban LiDAR of unequal densities. *Journal of surveying engineering*, ۱۴۷(۴), ۰۴۰۲۱۰۲۳.
۳. Basgall, P.L., Kruse, F.A., Olsen, R.C. (۲۰۱۴). Comparison of lidar and stereo photogrammetric point clouds for change detection. In: Turner, M.D., Kamerman, G.W., Thomas, L.M.W., Spillar, E.J. (Eds.), *Laser Radar Technology and Applications XIX; and Atmospheric Propagation XI*. vol. ۹۰۸۰, International Society for Optics and Photonics, SPIE, pp. ۲۱۴–۲۲۷.
۴. Bonczak, B., & Kontokosta, C. E. (۲۰۱۹). Large-scale parameterization of ۳D building morphology in complex urban landscapes using aerial LiDAR and city administrative data. *Computers, Environment and Urban Systems*, ۷۳, ۱۲۶–۱۴۲.
۵. Candan, L., & Kaçar, E. (۲۰۲۳). Methodology of real-time ۳D point cloud mapping with UAV lidar. *International Journal of Engineering and Geosciences*, ۸(۳), ۳۰۱–۳۰۹.
۶. De Gelis, I., Lefevre, S., Corpetti, T. (۲۰۲۱). ۳D urban change detection with point cloud siamese networks. *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.* ۴۳, ۸۷۹–۸۸۶.
۷. Dong, P., & Chen, Q. (۲۰۱۷). *LiDAR remote sensing and applications*. CRC Press.
۸. Du, S., Zhang, Y., Qin, R., Yang, Z., Zou, Z., Tang, Y., & Fan, C. (۲۰۱۶). Building change detection using old aerial images and new LiDAR data. *Remote Sensing*, ۸(۱۲), ۱۰۳۰.
۹. Hermosilla, T., Ruiz, L. A., Recio, J. A., & Estornell, J. (۲۰۱۱). Evaluation of automatic building detection approaches combining high resolution images and LiDAR data. *Remote Sensing*, ۳(۶), ۱۱۸۸–۱۲۱۰.
۱۰. Krichen, M., Abdalzaher, M. S., Elwekeil, M., & Fouda, M. M. (۲۰۲۴). Managing natural disasters: An analysis of technological advancements, opportunities, and challenges. *Internet of Things and Cyber-Physical Systems*, ۴, ۹۹–۱۰۹.
۱۱. Ku, T., Galanakis, S., Boom, B., Veltkamp, R.C., Bangera, D., Gangisetty, S., Stagakis, N., Arvanitis, G., Moustakas, K. (۲۰۲۱). SHREC ۲۰۲۱: ۳D point cloud change detection for street scenes. *Comput. Graph.* ۹۹, ۱۹۲–۲۰۰.
۱۲. Lague, D., Brodu, N., Leroux, J. (۲۰۱۳). Accurate ۳D comparison of complex topography with terrestrial laser scanner: Application to the Rangitikei canyon (NZ). *ISPRS Journal Photogramm. Remote Sens.* ۸۲, ۱۰–۲۶.

13. Li, Z., Chen, B., Wu, S., Su, M., Chen, J. M., & Xu, B. (2024). Deep learning for urban land use category classification: A review and experimental assessment. *Remote Sensing of Environment*, 311, 114290.
14. Liu, D., Li, D., Wang, M., & Wang, Z. (2021). 3D change detection using adaptive thresholds based on local point cloud density. *ISPRS International Journal of Geo-Information*, 10(3), 127.
15. Niemeyer, J., Rottensteiner, F., & Soergel, U. (2014). Contextual classification of lidar data and building object detection in urban areas. *ISPRS journal of photogrammetry and remote sensing*, 87, 102-110.
16. Okay, U., Telling, J., Glennie, C. L., & Dietrich, W. E. (2019). Airborne lidar change detection: An overview of Earth sciences applications. *Earth-Science Reviews*, 198, 102929.
17. Otepka, J., Ghuffar, S., Waldhauser, C., Hochreiter, R., Pfeifer, N. (2013). Georeferenced point clouds: A survey of features and point cloud management. *ISPRS Int. Journals Geo-Inf.* 2(4), 1038-1060.
18. Paes, V. D. C., Pessoa, C. H. M., Pagliusi, R. P., Barbosa, C. E., Argôlo, M., de Lima, Y. O., ... & de Souza, J. M. (2023). Analyzing the challenges for future smart and Sustainable Cities. *Sustainability*, 15(10), 7996.
19. Qin, R., Gruen, A. (2014). 3D change detection at street level using mobile laser scanning point clouds and terrestrial images. *ISPRS J. Photogramm. Remote Sens.* 90, 23-30.
20. Reyes, M. F., Xie, Y., Yuan, X., d'Angelo, P., Kurz, F., Cerra, D., & Tian, J. (2023). A 2D/3D multimodal data simulation approach with applications on urban semantic segmentation, building extraction and change detection. *ISPRS Journal of Photogrammetry and Remote Sensing*, 200, 74-97.
21. Rusu, R.B., Cousins, S. (2011). 3D is here: Point cloud library (pcl). In: 2011 IEEE International Conference on Robotics and Automation. IEEE, pp. 1-4.
22. Singh, A. (1989). Review article digital change detection techniques using remotely-sensed data. *Int. J. Remote Sens.* 10(6), 989-1003.
23. Sithole, G., & Vosselman, G. (2004). Experimental comparison of filter algorithms for bare-Earth extraction from airborne laser scanning point clouds. *ISPRS journal of photogrammetry and remote sensing*, 69(1-2), 80-101.
24. Smith, D. M. (Ed.). (2023). *Living under apartheid: aspects of urbanization and social change in South Africa*. Taylor & Francis.
25. Stal, C., Tack, F., De Maeyer, P., De Wulf, A., & Goossens, R. (2013). Airborne photogrammetry and lidar for DSM extraction and 3D change detection over an urban area—a comparative study. *International Journal of Remote Sensing*, 34(4), 1087-1110.
26. Stilla, U., & Xu, Y. (2023). Change detection of urban objects using 3D point clouds: A review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 197, 228-250.
27. Stular, B., & Lozić, E. (2020). Comparison of filters for archaeology-specific ground extraction from airborne LiDAR point clouds. *Remote Sensing*, 12(18), 3020.

28. Sun, T., Qi, J., & Huang, H. (2020). Discovering forest height changes based on spaceborne lidar data of ICESat-1 in 2000 and ICESat-2 in 2019: A case study in the Beijing-Tianjin-Hebei region of China. *Forest Ecosystems*, 7, 1-12.
29. Teo, T. A., & Shih, T. Y. (2013). Lidar-based change detection and change-type determination in urban areas. *International journal of remote sensing*, 34(3), 968-981.
30. Tran, T.H.G., Ressler, C., Pfeifer, N. (2018). Integrated change detection and classification in urban areas based on airborne laser scanning point clouds. *Sensors* 18(7), 2248.
31. Uciechowska-Grakowicz, A., Herrera-Granados, O., Biernat, S., & Bac-Bronowicz, J. (2023). Usage of Airborne LiDAR Data and High-Resolution Remote Sensing Images in Implementing the Smart City Concept. *Remote Sensing*, 15(24), 5776.
32. Wang, K., Wang, T., & Liu, X. (2018). A review: Individual tree species classification using integrated airborne LiDAR and optical imagery with a focus on the urban environment. *Forests*, 10(1), 1.
33. Wang, R., Peethambaran, J., & Chen, D. (2018). Lidar point clouds to 3-D urban models: A review. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 11(7), 606-627.
34. Wang, Y., Jiang, T., Liu, J., Li, X., & Liang, C. (2020). Hierarchical instance recognition of individual roadside trees in environmentally complex urban areas from UAV laser scanning point clouds. *ISPRS International Journal of Geo-Information*, 9(10), 595.
35. Wang, Z., & Menenti, M. (2021). Challenges and opportunities in Lidar remote sensing. *Frontiers in Remote Sensing*, 2, 641723.
36. Weng, Q. (2012). Remote sensing of impervious surfaces in the urban areas: Requirements, methods, and trends. *Remote Sensing of Environment*, 117, 34-49.
37. Xiao, W., Cao, H., Tang, M., Zhang, Z., & Chen, N. (2023). 3D urban object change detection from aerial and terrestrial point clouds: A review. *International Journal of Applied Earth Observation and Geoinformation*, 118, 103258.
38. Yan, W. Y., Shaker, A., & El-Ashmawy, N. (2015). Urban land cover classification using airborne LiDAR data: A review. *Remote sensing of environment*, 158, 295-310.
39. Yang, W., Liu, Y., He, H., Lin, H., Qiu, G., & Guo, L. (2021). Airborne LiDAR and photogrammetric point cloud fusion for extraction of urban tree metrics according to street network segmentation. *IEEE Access*, 9, 97834-97842.
40. Yu, D., & Fang, C. (2023). Urban remote sensing with spatial big data: a review and renewed perspective of urban studies in recent decades. *Remote Sensing*, 15(5), 1307.
41. Yu, X., Hyypä, J., Kaartinen, H., & Maltamo, M. (2004). Automatic detection of harvested trees and determination of forest growth using airborne laser scanning. *Remote sensing of Environment*, 90(4), 451-462.
42. Zhang, L., Zhang, Z., Zhang, J., Qiao, X., Zhang, Z., Yang, B., & Dong, Z. (2023). Object-based 3D building change detection using point-level change indicators. *International Journal of Applied Earth Observation and Geoinformation*, 118, 103293.
43. Zhao, F. H., Zhu, A. X., & Qin, C. Z. (2024). Spatial distribution pattern analysis using variograms over geographic and feature space. *Geo-spatial Information Science*, 1-15.

۴۴. Zhou, G., Song, C., Simmers, J., & Cheng, P. (۲۰۰۴). Urban ۳D GIS from LiDAR and digital aerial images. Computers & geosciences, ۳۰(۴), ۳۴۵-۳۵۳.

نسخه پیش انتشار