

متراکم سازی ابر نقاط حاصل از تداخل سنجی راداری مبتنی بر پراکنش گرهای دائمی در مناطق شهری

سجاد ساجدی زاده^۱، یاسر مقصودی^{۲*}

۱- دانشجوی دکتری گروه فتوگرامتری و سنجش از دور، دانشکده مهندسی نقشه برداری، دانشگاه صنعتی خواجه نصیرالدین طوسی
۲- دانشیار گروه فتوگرامتری و سنجش از دور، دانشکده مهندسی نقشه برداری، دانشگاه صنعتی خواجه نصیرالدین طوسی

تاریخ دریافت مقاله: ۱۴۰۱/۰۶/۳۱ تاریخ پذیرش مقاله: ۱۴۰۱/۱۲/۱۵

چکیده

ابر نقاط سه بعدی سهم قابل توجهی از مشاهدات هواپایه و فضاپایه در سالیان گذشته داشته‌اند. محدودیت‌ها و چالش‌های پردازشی این مشاهدات در مطالعات مختلف ماشین‌بینایی و سنجش‌از دور مورد بررسی قرار گرفته است. یکی از روش‌های تولید ابر نقاط سه بعدی بهره‌گیری از روش تداخل سنجی پراکنش گرهای دائمی به منظور تخمین ارتفاع عوارض مختلف است. با برآورد خطای ارتفاعی مدل توپوگرافی مورد استفاده در پردازش تداخل سنجی راداری پراکنش گرهای دائمی (فاز باقی مانده ارتفاعی)، ارتفاع هر پراکنش گر دائمی تخمین زده می‌شود. دقت ارتفاعی حاصل از این روش، با تغییر در روش انتخاب تصویر پایه و معیارهای انتخاب پراکنش گرهای دائمی بهبود پیدا کرد. به دلیل تراکم پائین و همچنین پهلو نگر بودن تصویر برداری سار، ابر نقاط حاصل از این روش، بیانگر هندسه کامل عوارض نخواهد بود. در این مقاله با هدف افزایش تراکم و تکمیل هندسه عارضه مورد نظر، از شبکه‌های یادگیری عمیق تکمیل کننده ابر نقاط سه بعدی استفاده شد. این شبکه‌ها با انجام فرآیند یادگیری، مستقیماً از فضای ابر نقاط غیرمتراکم به فضای ابر نقطه متراکم رسیده و با استخراج ساختار هندسی کلی عارضه مورد نظر، جزئیات را نیز تا حد مطلوبی حفظ می‌کنند. معیار هزینه این شبکه مبتنی بر فاصله چمفر بوده است که فاصله دو ابر نقطه سه بعدی ورودی غیرمتراکم و مرجع زمینی متراکم را اندازه گیری کرده و در عین افزایش تراکم نقاط خروجی شبکه، فاصله این دو فضا حداقل شود. به دلیل استفاده این شبکه در مطالعات ماشین‌بینایی، مجموعه داده‌های ابر نقطه سه بعدی هواپایه یا فضاپایه موجود نیست. در این مطالعه، ۲۷ تصویر ماهواره سنتینل-۱ در منطقه فیلا دلفیا آمریکا استفاده شد. به منظور آموزش شبکه در مناطق شهری، مجموعه داده‌ای شامل ۳۰۰۰۰ ساختمان در این مطالعه تولید شد. مقدار تابع زیان بدست آمده در فرآیند آموزش ۰/۰۴۸ و در فرآیند ارزیابی شبکه ۰/۰۴۸۲ بوده است. با ارزیابی مدل ارتفاعی سطح استخراج شده با داده‌های مرجع لیدار منطقه مورد مطالعه، میانگین خطای تخمین ارتفاع مطلق ۴/۶۷ متر بدست آمد که نزدیک به مقادیر دقت مطلق مدل‌های ارتفاعی سطح تجاری موجود در دنیاست.

کلیدواژه‌ها: تکمیل کننده ابر نقاط سه بعدی، تداخل سنجی راداری، پراکنش گرهای دائمی، مدل ارتفاعی سطح ساختمان.

* نویسنده مکاتبه کننده: تهران، خیابان ولیعصر، تقاطع میرداماد، دانشکده مهندسی نقشه برداری دانشگاه صنعتی خواجه نصیرالدین طوسی.

۱- مقدمه

در دو دهه اخیر تکنیک تداخل‌سنجی راداری^۱ (*InSAR*) برای نمایش، شناسایی و اندازه‌گیری تغییر شکل و جابه‌جایی سطح زمین مورد توجه قرار گرفته است. این تکنیک با پوشش‌های مکرر و وسیع، دقت قابل قبول و قدرت تفکیک بالای تصاویر رادار در مطالعه پدیده‌های زمین‌شناسی همچون زلزله، فرونشست^۲، زمین لغزش^۳، جابجایی سایت‌های زمین‌گرایی و تولید مدل رقومی ارتفاعی زمین^۴ (*DEM*) ابزار قدرتمند و مفیدی برای محققان محسوب می‌شود [۱، ۲، ۳ و ۴]. خصوصیات مانند فرکانس بالای مشاهدات مکانی و زمانی روش تداخل‌سنجی راداری، امکان برداشت در هر نوع شرایط آب و هوایی، برداشت پیوسته در سطح وسیع و دقت قابل قبول در مقایسه با سایر روش‌های مطالعه جابجایی سطح زمین (ترازیابی^۵ و شبکه ایستگاه‌های سیستم موقعیت‌یابی جهانی^۶ (*GPS*))، این تکنیک را به ابزاری کارآمد نسبت به روش‌های دیگر مطالعه جابجایی تبدیل کرده است. تکنیک تداخل‌سنجی راداری مبتنی بر پراکنش‌گرهای دائمی با بهره‌گیری از نقاط پراکنش‌گر دائمی^۷، ضمن غلبه بر محدودیت‌های تکنیک‌های سنتی، امکان پردازش سری زمانی بلندمدت را فراهم می‌نماید [۵]. نقاط پراکنش‌گر دائمی برخی از عوارض سطح زمین هستند که در طول چندین ماه و حتی سال ویژگی‌های بازپراکنشی نسبتاً پایداری دارند. ابعاد این عوارض از یک پیکسل کوچکتر بوده و از عدم همبستگی‌های مکانی و زمانی تصاویر سار کمتر تأثیر می‌پذیرند [۶]. شکل (۱) بیانگر رفتار فاز پیکسل‌های دارای پراکنش‌گر

دائمی در مقایسه با پیکسل‌هایی با اهداف توزیع یافته^۸ در طول زمان می‌باشد.

با توجه به شکل (۱) واضح است که پیکسل‌هایی که دارای پراکنش‌گر دائمی هستند، رفتار فاز یکنواخت و پایداری در طول زمان دارند. لذا از این ویژگی می‌توان به منظور برآورد جابجایی در طی سری زمانی با دقت مناسبی استفاده نمود. تکنیک پراکنش‌گرهای دائمی نخستین بار توسط فرتی و همکارانش (۲۰۰۰ و ۲۰۰۱) توسعه یافت و پس از آن به منظور بهبود عملکرد آن متناسب با داده‌ها و مناطق مختلف، الگوریتم‌هایی نظیر^۹ *SBAS*،^{۱۰} *STAMPS*،^{۱۱} *JPTA*،^{۱۲} *DEPSI*،^{۱۳} *QPS* و *SqueeSAR* ارائه شدند [۷، ۸، ۹، ۱۰، ۱۱، ۱۲ و ۱۳]. در تمامی روش‌های تداخل‌سنجی مبتنی بر پراکنش‌گرهای دائمی، با تخمین مولفه‌های مختلف مؤثر در فاز تداخل‌سنجی، می‌توان میزان جابجایی سطح زمین و یا تخمین ارتفاع عوارض و همچنین مطالعات اتمسفری انجام داد. در روش تداخل‌سنجی مبتنی بر پراکنش‌گرهای دائمی، با یک ابر نقطه در پردازش‌ها مواجه خواهیم بود. بنابراین می‌توان از زاویه پردازش‌های ابر نقاط سه‌بعدی نیز به نتایج روش‌های تداخل‌سنجی راداری پرداخت.

در مطالعات ماشین بینایی و بخصوص موضوعات پردازش ابر نقاط سه‌بعدی سنجنده‌های لیدار (هوایایه، زمینی و یا فضا‌های داخلی)، روش‌هایی ارائه شده است که بدنبال بهبود مشاهدات اولیه سنجنده‌های لیدار و رفع محدودیت‌های داده‌برداری این سنجنده‌هاست.

¹ Interferometric Synthetic Aperture RADAR

² Subsidence

³ Landslide

⁴ Digital Elevation Model

⁵ Leveling

⁶ Global Positioning System

⁷ Permanent Scatterers

⁸ Distributed Scatterers


⁹ Small BAseline Subset

¹⁰ STAnford Method for PSI

¹¹ Interferometric Point Target Analysis

¹² Delft Implementation for PSI

¹³ Quasi-PS



شکل ۱: رفتار فاز پیکسل زمانی که: الف) شامل پراکنش گر دائم باشد، ب) شامل پراکنش گرهای توزیع یافته باشد [۱۱].

شبکه‌های عصبی کانولوشنال ارائه شده است. از شناخته شده ترین این‌ها ساختارهای وکسل^۲ (شکل (۲)) هستند.


مزیت اصلی استفاده از ساختار وکسل برای نمایش ابر نقاط سه‌بعدی، لایه‌های شبکه‌های عصبی کانولوشنال مرسوم مورد استفاده برای تصاویر است که به‌طور کلی با کمی تغییر قابل استفاده خواهد بود. یکی از بزرگ‌ترین مشکلات ساختارهای منظم داده، محدودیت رزولوشن برای نمایش داده‌های سه‌بعدی است. بنابراین، تبدیل داده‌های نامنظم به ساختاری منظم، چالشی بین انتخاب رزولوشن خروجی شبکه و سطح جزئیات قابل دسترس و از دست دادن اطلاعات خواهد داشت. طراحی شبکه‌های عصبی همخوان با ساختار داده‌های نامنظم می‌تواند این مشکلات را برطرف کند.

بطور مثال به دلیل وجود درختان در مناطق شهری، برخی از مشاهدات لیدار از ساختمان‌ها دارای نقص می‌شود و نمی‌تواند بخوبی هندسه کامل این عوارض را نشان دهد. بدین منظور روش‌های مبتنی بر شبکه‌های یادگیری عمیق برای تکمیل این مشاهدات ناقص با اتکای بر داده‌های آموزشی که مستقیماً فضای مشاهدات محدود را به فضای مشاهدات کامل (از منظر هندسی) نگاشت می‌کند، ارائه شدند.

بطور معمول، شبکه‌های کانولوشنال به ساختار منظمی از داده‌ها نیاز دارند. بنابراین، شبکه‌های عصبی کانولوشنال نمی‌توانند بطور مستقیم بر روی داده‌های نقاط سه‌بعدی با ساختار نامنظم بکار برده شوند. بدین منظور راه‌حلی برای تبدیل این ساختار نامنظم به ساختاری منظم ارائه شده است. در این راه‌حل، چندین نمای دوبعدی از یک شیء سه‌بعدی تشکیل می‌شود. راه‌حل دیگر ایجاد ساختار منظم داده، (ابعاد داده ورودی را حفظ می‌کند) نمای حجمی است. در سالیان اخیر، انواع مختلف نماهای حجمی برای استفاده در

² Voxel

¹ Sparse



شکل ۲: تبدیل ابر نقاط به ساختار حجمی از وکسل‌ها

کننده^۳ ابر نقاط سه‌بعدی مورد استفاده قرار گرفته است. هدف از این مطالعه بهبود تراکم ابر نقاط حاصل از پردازش تداخلسنجی پراکنش‌گرهای دائمی تصاویر رایگان سنتینل-۱ و رسیدن به میزان تراکم مورد نیاز برای تولید مدل سه‌بعدی از ساختمان در مناطق شهری است. با توجه به پهلونگر بودن سار، همواره عوارض شهری و ساختمان‌ها از یک زاویه تصویربرداری خواهند شد؛ لذا می‌توان از قابلیت شبکه‌های یادگیری عمیق تکمیل‌کننده اشکال سه‌بعدی بهره‌برداری کرده تا سایر وجوه عوارض شهری نیز بازسازی شود. با استفاده از روش پیشنهادی این مقاله، می‌توان با استفاده از تصاویر رایگان سنتینل-۱ با قدرت تفکیک ۱۰ متر ساختمان‌های شهری را بازسازی کرد. در این مطالعه با استفاده از مکانیزم‌های پراکنش حاصل از هندسه عوارض شهری موجود در پراکنش‌گرهای دائمی تداخل‌سنجی راداری، هندسه اولیه و ناقصی از شکل و ساختار عارضه شهری بدست آمده و سپس به کمک شبکه تکمیل‌کننده ساختار سه‌بعدی یادگیری عمیق، هندسه کلی عارضه شهری استخراج می‌گردد. اعمال تغییر در فرآیند تداخل‌سنجی راداری با هدف رسیدن به دقت تخمین ارتفاعی بهتر و همچنین تولید آموزش شبکه یادگیری عمیق مکمل ابر نقاط سه‌بعدی (مورد استفاده در پژوهش‌های ماشین بینایی و برد کوتاه) بر روی داده‌های سنجش‌ازدوری و ارزیابی کمی

برای رفع این محدودیت، استفاده از ابر نقاط سه‌بعدی (دارای ساختار نامنظم) به‌عنوان ورودی مستقیم شبکه‌های عصبی، در شبکه یادگیری عمیق پوینت نت^۱ ارائه شد [۱۴]. دو جزء اصلی این شبکه عبارتند از: (۱) ماژول مقاوم به جایگشت نقاط و (۲) ماژول تبدیل مکانی سه‌بعدی. در مقایسه با شبکه‌های عصبی کانولوشنال سه‌بعدی که از آموزش ویژگی‌های سلسله‌مراتبی بهره می‌برند، آموزش ویژگی عمومی^۲ برای یک نقطه و یک بردار کلی برای تمامی نقاط در پوینت نت استفاده می‌شود. در شبکه پیشنهادی پوینت نت از اطلاعات همسایگی نقاط استفاده نمی‌شد و به‌منظور بهبود ویژگی‌های استخراج شده از شبکه، جانشین آن پوینت نت++ با هدف بهبود نتایج از طریق استفاده از اطلاعات همسایگی در انتهای سال ۲۰۱۷ معرفی شد [۱۵]. در این ساختار یادگیری عمیق، همسایگان کروی یک نقطه استخراج شده و ساختار پوینت نت بر روی هر بخش انتخابی به‌طور متوالی بکار برده می‌شود.

در این مقاله، دو موضوع پردازش تداخل‌سنجی پراکنش‌گرهای دائمی که در آن می‌توان به محصول ابر نقطه سه‌بعدی (معرف اطلاعات ارتفاعی عوارض زمینی) دست یافت به همراه روش یادگیری عمیق تکمیل

¹ PointNet

² Global

³ Shape Completion

پژوهش انجام شد. مدل آموزش یافته در این شبکه با معماری کدکننده خودکار می تواند ویژگی های هندسی کلی (Global) و جزئی (Detail) را آموزش دیده و فضای غیرمتراکم ابر نقاط سه بعدی را به ابر نقطه ای متراکم تبدیل کند. پس از طی مرحله متراکم سازی ابر نقاط، مدل ارتفاعی سطح استخراج شده و با مقایسه با مدل های ارتفاعی سطح موجود در منطقه مطالعاتی و داده های لیدار، ارزیابی دقت قابل حصول با روش پیشنهادی این پژوهش بدست آمده است.

۲-۱- منطقه مورد مطالعه و داده ها

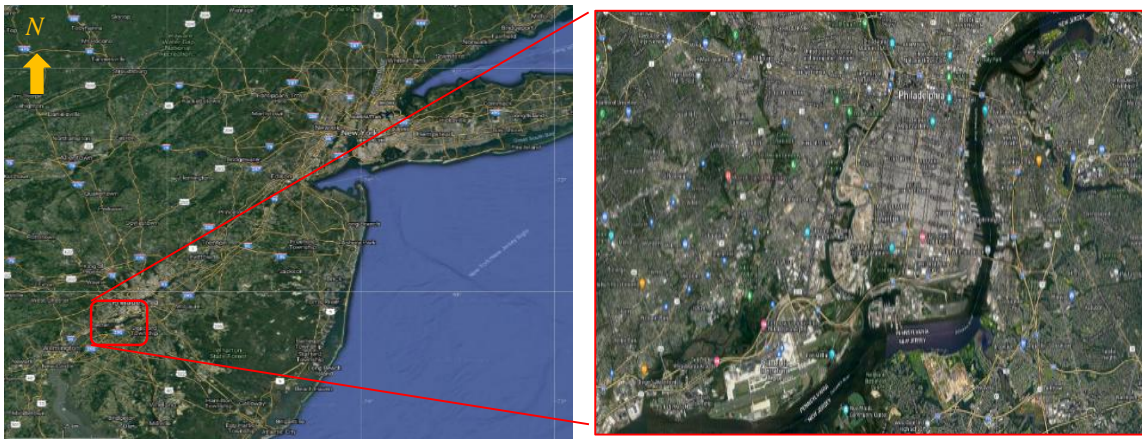
منطقه مورد مطالعه این پژوهش به دلیل نیاز به داده های لیدار در منطقه شهری به منظور ارزیابی نتایج حاصل از پژوهش، منطقه فیلادلفیا آمریکا (شکل ۳) انتخاب شده است. شهر فیلادلفیا در شرق کشور آمریکا واقع شده است و در معماری شهرسازی این شهر انواع ساختمان های با معماری کلاسیک، مدرن، برج ها، ورزشگاه ها و مناطق صنعتی و سوله ها وجود دارد.

و کیفی دقت مدل سه بعدی بدست آمده، از نوآوری های این مطالعه است.

۲- روش تحقیق

در این پژوهش، ابر نقاط حاصل از تخمین مؤلفه فاز باقی مانده (تصحیح فاز مدل ارتفاعی مورد استفاده در پردازش تداخل سنجی) پراکنش گرهای دائمی، بعنوان یک فضای ابر نقطه غیرمتراکم در منطقه شهری از تصاویر ماهواره سنتینل-۱ بدست آمده است. این ابر نقطه به دلیل تراکم پائین نقاط با هدف تولید مدل ارتفاعی سطح بایستی به تراکم بالاتری برسد و از لحاظ کمی نیز دقت ارتفاعی مطلوبی برای تخمین ارتفاع ساختمان داشته باشد.

به منظور افزایش تراکم ابر نقطه حاصل، با استفاده از شبکه یادگیری عمیق تکمیل کننده ابر نقاط سه بعدی (Point Completion Network) و تولید مجموعه داده ۳۰۰۰۰ تایی از ساختمان های منطقه شهری، فرآیند آموزش این شبکه با مجموعه داده تولید شده در این



شکل ۳: منطقه مورد مطالعه، شهر فیلادلفیا، ایالت پنسیلوانیا آمریکا

پردازش های تداخل سنجی راداری استفاده شده است. مشخصات تصاویر مورد استفاده در جدول (۱) آورده شده است.

داده های مورد استفاده در این مطالعه از ماهواره سنتینل-۱ اتحادیه اروپا بوده است. ۲۷ تصویر از تاریخ ۱۰ اکتبر ۲۰۱۹ تا ۲۰ ژانویه ۲۰۲۱ انتخاب شدند. در این پژوهش از نرم افزار گاما و اسنپ به منظور انجام

جدول ۱: مشخصات تصاویر مورد استفاده در پردازش تداخل سنجی

قطبش	قدرت تفکیک سمت (متر)	قدرت تفکیک برد (متر)	هندسه تصویر	گذر ماهواره	زاویه فرود (درجه)	مد تصویربرداری	فرکانس تکرار پالس (هرتز)	فرکانس SAR (گیگاهرتز)
عمودی-افقی	۱۳٫۹۲	۲٫۳۳	برد مایل	نزولی	۳۹٫۱۵۳	تداخل سنجی (IW)	۴۸۶٫۴۸	۵٫۴۰۵

شاخص پراکنندگی^۱ و مقادیر همدوسی در طول سری زمانی در نظر گرفته می‌شود. معیار شاخص پراکنندگی نسبت انحراف معیار تغییرات فاز هر نقطه را به میانگین مقادیر فاز آن در نظر گرفته و مقادیر حداقلی این شاخص برای انتخاب پراکنش گر دائمی استفاده می‌شود.

۲-۲-۳- تخمین مولفه‌های فاز اتمسفر، ارتفاعی و جابجایی

پس از تخمین فاز تداخل سنجی با ایجاد یک گرید متراکم و منظم، مقادیر فاز تداخل سنجی بر روی این نقاط محاسبه شد. در گام بعد بایستی فاز مؤلفه مدار و توپوگرافی تخمین زده شود و از مقادیر فاز تداخل سنجی بدست آمده در مرحله قبل کم شود. بدین منظور با استفاده از مدل ارتفاعی مأموریت توپوگرافی رادار شاتل (SRTM)، مقادیر ارتفاع هریک از نقاط پراکنش گر دائمی بدست آمده است. برای حذف اثرات اتمسفری (شکل (۴))، ابتدا با انجام یک فیلترینگ مکانی و حذف بایاس ایجاد شده بر روی نقطه رفرنس انتخابی، تأثیر نویز بر رگرسیون زمانی به منظور تخمین مؤلفه اتمسفری کاهش یافت. به منظور دقیق تر کردن فرآیند واپیچش^۲، مقدار تخمین زده شده فاز واپیچش از مقادیر فاز تداخل سنجی کاسته تا فاز باقی مانده دقیق تر واپیچش شود.

۲-۲-۲- پردازش تداخل سنجی پراکنش گرهای دائمی

در روش تداخل سنجی راداری پراکنش گرهای دائمی با استفاده از چند تصویر سار از یک منطقه با زوایای فرود یکسان و گذر مشابه ماهواره، با تشکیل یک شبکه می‌توانیم مولفه‌های فاز موجود در سری زمانی مورد مطالعه را تخمین بزنیم. در فرآیند انتخاب تصویر پایه در پردازش‌های مرسوم تداخل سنجی راداری پراکنش گرهای دائمی، هدف به حداکثر رساندن همدوسی (Coherence) در شبکه تداخل نماهای تشکیل شده است.

۲-۲-۱- انتخاب تصویر پایه


به دلیل ماهیت اکثر پردازش‌های تداخل سنجی راداری پراکنش گرهای دائمی مرسوم برای تخمین صحیح مؤلفه فاز جابجایی سطح زمین، این روش انتخاب تصویر پایه، سعی در به حداکثر رساندن مقدار همدوسی در شبکه به منظور صحت تخمین دارد. در پژوهش حاضر به دلیل نیاز به رسیدن به دقت‌های بالاتر در تخمین مؤلفه فاز باقی مانده ارتفاعی و وابستگی دقت تخمین این مؤلفه به خط مبناهای مکانی، معادله بهینه‌سازی انتخاب تصویر پایه با هدف به حداکثر رساندن خط مبناهای مکانی شبکه در عین حفظ حداقل مقادیر همدوسی در شبکه به میزان ۰٫۴ حل شده است.

۲-۲-۲- تشکیل تداخل نماها و انتخاب پراکنش گرهای دائمی

به منظور انتخاب نقاط پراکنش گرهای دائمی، دو معیار

¹ Dispersion index

² unwrapping

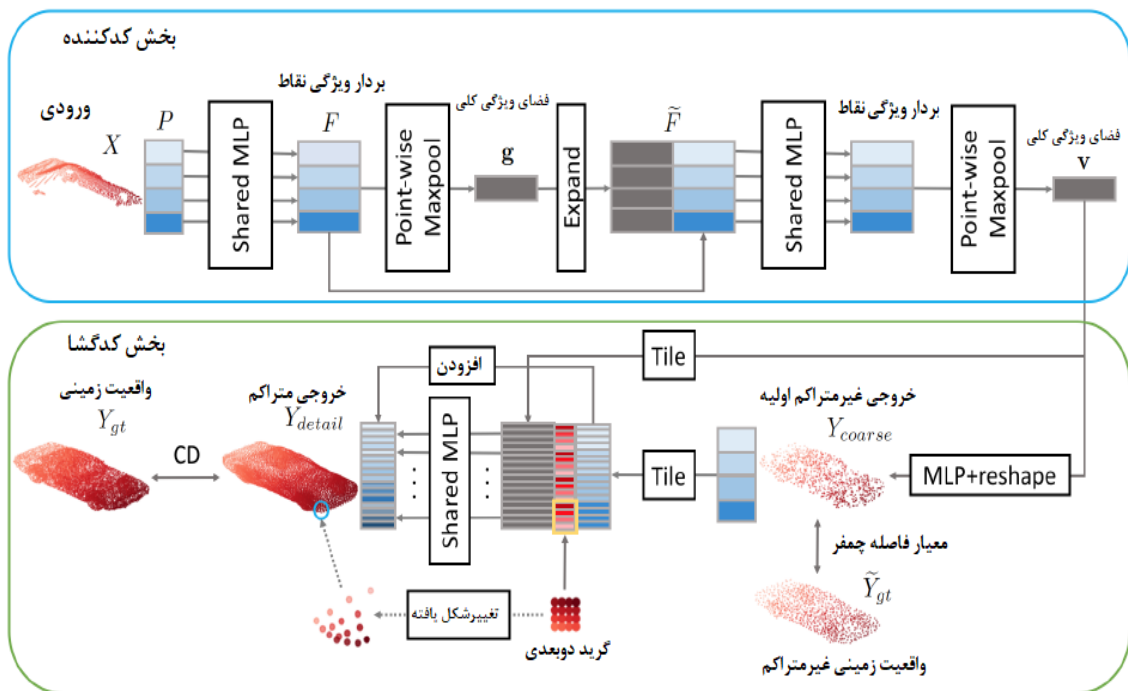


شکل ۴: تخمین مؤلفه اتمسفری دو زوج تداخل نمای موجود در شبکه تداخل سنجی

۲-۳- شبکه یادگیری عمیق تکمیل کننده ابر نقاط سه بعدی

در شکل (۵) ساختار کلی لایه های شبکه عصبی یادگیری عمیق در حوزه تکمیل ابر نقاط سه بعدی آورده شده است. دو بخش کلی کدکننده و کدگشا به ترتیب وظیفه استخراج ویژگی از ابر نقاط سه بعدی و تبدیل این بردار ویژگی به مدل سه بعدی از شیء مورد انتظار را دارد. X یک مجموعه نقطه سه بعدی از سطح یک شیء است که می تواند نتیجه مشاهده یکباره یا

چندباره یک سنجنده باشد. Y یک مجموعه نقاط سه بعدی متراکم با نمونه برداری منظم از مناطق مشاهده شده و مشاهده نشده توسط سنجنده خواهد بود. در واقع مسئله تکمیل شیء براساس پیش بینی Y با مشاهده X است. با در نظر گرفتن این فرآیند، X لزوماً زیرمجموعه ای از Y نبوده و ارتباط صریحی نیز بین نقاط X و Y برقرار نیست. در این مسئله، آموزش یک شبکه عصبی برای پیش بینی مستقیم نقاط Y (مدل سه بعدی ساختمان) از نقاط اولیه X مطرح است.



شکل ۵: شبکه یادگیری عمیق تکمیل کننده ابر نقاط سه بعدی [۲۲]

شد:

رابطه (۳)

$$L(Y_{coarse}, Y_{detail}, Y_{gt}) = d_1(Y_{coarse}, Y_{gt}) + \alpha d_2(Y_{detail}, Y_{gt})$$

در رابطه (۳)، تابع دارای دو جمله d_1 و d_2 و یک بیشینه پارامتر α است. جمله اول بیانگر فاصله بین Y_{coarse} و داده نمونه برداری شده (کاهش یافته) زمینی Y_{gt} است که از یک اندازه هستند. جمله دوم فاصله بین Y_{detail} و نقاط زمینی کامل Y_{gt} است [۲۲].

بخش کدکننده شبکه متشکل از دو لایه متصل پوینت نت است. در بخش اول قسمت کدکننده، هر نقطه با سه مؤلفه مختصاتی به لایه عصبی چند پرسپترون^۶ (این بخش شامل دو لایه خطی با فعالساز رلو^۷ ($ReLU$) است) وارد شده و و یک بردار ویژگی fi تشکیل می شود. خروجی لایه عصبی چند پرسپترون، یک ماتریس F خواهد بود که هر سطر آن بردار ویژگی های نقاط ورودی است. برای مقاوم شدن مدل نسبت به جایگشت یک تابع مکس پول^۸ استفاده خواهد شد تا اطلاعات ترتیب و توالی را از بین برده و مدل آموزش یافته نسبت به جابجایی نقاط مقاوم باشد. با اعمال تابع مکس پول بر روی ماتریس F ، یک فضای ویژگی g بدست خواهد آمد که معرف ویژگی کلی هندسه شی مورد نظر خواهد بود. در بخش دوم قسمت کدکننده، ماتریس F و بردار g بعنوان ورودی وارد فرآیند مشابه پردازشی خواهند شد که نتیجه آن یک بردار ویژگی v خواهد بود که هم ویژگی های هندسی کلی شی مورد نظر و هم اطلاعات جزئیات هندسی آن را در خود خواهد داشت. بخش کدگشا با ورود بردار ویژگی v یک ابر نقطه گسسته تولید خواهد کرد و با افزودن یک لایه گرید دو بعدی متراکم به این فضای گسسته اولیه، سعی در متراکم سازی ابر نقطه گسسته

در این شبکه، L تابع زیان بین نقاط مرجع زمینی و خروجی کدگشا محاسبه می شود تا کل شبکه از طریق یک پروجکشن^۲ آموزش داده شود. در واقع این شبکه تبدیل از یک فضا را به فضای دیگر یاد می گیرد. در ادامه بطور خلاصه طراحی کدکننده، کدگشا و تابع زیان این شبکه تشریح شده است. قسمت کدکننده شبکه مسئول تخلیص اطلاعات هندسی ابر نقاط اولیه به یک بردار ویژگی است. کدکننده بایستی نسبت به جایگشت و تلورانس نسبت به نویز مقاوم باشد و بتواند هر تعداد نقطه را بعنوان ورودی شبکه بپذیرد. این ساختار در شبکه تکمیل کننده ابر نقاط سه بعدی توسط ونتاؤ و همکاران ارائه شده است [۱۷]. بخش کدگشا شبکه، وظیفه تولید ابر نقاط خروجی از روی بردار ویژگی بدست آمده از بخش کدکننده را بر عهده دارد. استفاده از کدگشا کاملاً متصل^۳ و مبتنی بر چندلایه^۴ کدگشا، برای پیش بینی یک مجموعه نقاط پراکنده که بیانگر هندسه کلی یک شی است، بخوبی عمل می کند [۱۷]. تابع زیان فاصله بین نقاط مرجع زمینی و ابر نقاط خروجی شبکه را محاسبه می کند. به دلیل بی نظمی هر دو مجموعه نقاط، تابع زیان بایستی نسبت به جایگشت نقاط مقاوم باشد. دو کاندید برای توابع مقاوم به جایگشت که عبارتند از: معیار فاصله چمفر و معیار فاصله ارث موور^۵. روابط این دو فاصله و ویژگی های آن ها در رابطه (۱) آورده شده است [۱۹].

رابطه (۱)

$$CD(S_1, S_2) = \frac{1}{|S_1|} \sum_{x \in S_1} \min \|x - y\|_2 + \frac{1}{|S_2|} \sum_{x \in S_2} \min \|y - x\|_2$$

رابطه (۲)

$$EMD(S, S) = \min_{\varnothing: S_1 \rightarrow S_2} \frac{1}{|S_1|} \sum_{x \in S_1} \|x - \varnothing(x)\|_2$$

در نتیجه تابع زیان به صورت رابطه (۳) تعریف خواهد

¹ Ground Truth

² Back Projection

³ Fully-Connected Decoder

⁴ Folding-based

⁵ Earth Mover

⁶ MLP (Multi-Layer Perceptron)

⁷ Rectified Linear Unit

⁸ Max Pool

می‌شود. در پایان نیز مدل ارتفاعی سطح بدست آمده و با داده‌های لیدار منطقه مطالعاتی ارزیابی خواهند شد.

۳-۱- ارائه نتایج

در شکل (۶)، ابر نقاط حاصل از پردازش تداخل‌سنجی تصاویر سنتینل-۱ در منطقه فیلادلفیا آورده شده است. همانطور که در شکل (۶) نشان داده شده است، پراکنش‌گرهای دائمی در مناطق شهری در حد بسیار مطلوبی می‌توانند ساختار عوارض شهری را تمایز دهند. این موضوع به مکانیزم پراکنش دوپهلوی^۳ از گوشه‌های عوارض شهری مرتبط است. مطابق شاخص سمت چپ تصویر، ارتفاعات بدست آمده برای پراکنش‌گرها مطابق رنگ‌بندی مشخص شده ارائه شده است.

در شکل (۷) تراکم ابر نقاط حاصل از پردازش تداخل‌سنجی راداری پراکنش‌گرهای دائمی تصاویر سنتینل-۱ فرودگاه شهر فیلادلفیا در مقایسه تراکم داده لیدار این منطقه آورده شده است.

پس از متراکم‌سازی ابر نقاط سه‌بعدی تداخل‌سنجی راداری پراکنش‌گرهای دائمی با استفاده از شبکه یادگیری عمیق تکمیل‌کننده ابر نقاط، تراکم ابر نقطه عوارض شهری با تمرکز بر ساختمان‌های شهری افزایش می‌یابد. در شکل (۸) مقایسه این دو فضای ابر نقطه نشان داده شده است.

پس از استخراج ابر نقطه متراکم، مدل ارتفاعی سطح با استفاده از روش ارائه شده در بخش ۴-۲ تولید شده است. در شکل (۹)، مدل ارتفاعی سطح تولید شده از منطقه مورد مطالعه نشان داده شده است:

با اتکای بر معیارهای فاصله تعریف شده در بخش فوق خواهد داشت. این فرآیند تا رسیدن به مقدار حد‌آستانه فاصله تعریف شده ادامه پیدا می‌کند تا پارامترهای آموزش این شبکه به مقادیر مناسب برسند [۲۲].

۲-۴- تشکیل مدل ارتفاعی سطح

برای تولید مدل ارتفاعی سطح از ابر نقاط، از الگوریتم باینینگ محلی^۱ به منظور پیاده‌سازی یک شبکه بر روی فضای ابر نقطه سه‌بعدی استفاده شده و تخصیص ارتفاع به نقاط شبکه ایجاد شده صورت می‌پذیرد. برای این منظور با تشکیل یک دایره جستجو در هر نقطه از شبکه، مقادیر ارتفاعی هر نقطه با محاسبه میانگین مقادیر موجود در شعاع جستجو بدست می‌آید. در صورتیکه در دایره جستجو (با شعاع مشخص شده)، به نقطه‌ای از شبکه مقدار ارتفاعی اختصاص نیابد، مقدار تهی جایگزین شده و در انتها با استفاده از الگوریتم درونیابی مبتنی بر وزندهی معکوس فاصله (IDW)^۲ از هر نقطه، مناطق دارای گپ پر خواهند شد. قدرت تفکیک شبکه به تراکم ابر نقاط سه‌بعدی وابسته خواهد بود. اگر قدرت تفکیک شبکه تخصیص ارتفاع، خیلی زیاد باشد (فاصله رؤوس شبکه از یکدیگر خیلی کم باشد) مناطق دارای گپ زیاد خواهد شد و اگر قدرت تفکیک شبکه کم باشد (فاصله رؤوس شبکه از یکدیگر زیاد شود) جزئیات عارضه موردنظر از دست خواهد رفت.


۳- نتایج

در این بخش نتایج حاصل از پردازش‌های تداخل‌سنجی راداری پراکنش‌گرهای دائمی و تخمین مؤلفه فاز باقی‌مانده ارتفاعی حاصل تصحیح ارتفاع مدل ارتفاعی *SRTM* بکار رفته در پردازش‌های تداخل‌سنجی راداری پراکنش‌گرهای دائمی ارائه شده و سپس روند متراکم‌سازی ابر نقطه حاصل با استفاده از شبکه یادگیری عمیق تکمیل‌کننده ابر نقاط سه‌بعدی ارائه


¹ Local Binning

² Inverse Distance Weight

³ Double bounce scattering mechanism




شکل ۶: ابر نقطه سه بعدی حاصل از پردازش تداخل سنجی راداری پراکنش گرهای دائمی تصاویر سنتینل-۱



شکل ۷: مقایسه تراکم ابر نقاط: الف) ابر نقطه لیدار از فرودگاه شهر ب) ابر نقطه تداخل سنجی راداری پراکنش گرهای دائمی از فرودگاه شهر (تصاویر در سیستم مختصات نرمال شده نمایش داده شده اند)




(الف)



(ب)

شکل ۸: مقادیر ارتفاع ابر نقاط غیرمتراکم و متراکم خروجی شبکه یادگیری عمیق: الف) ابر نقطه تداخل‌سنجی راداری پراکنش‌گرهای دائم غیرمتراکم (ب) ابر نقطه تداخل‌سنجی راداری پراکنش‌گرهای دائمی متراکم از ساختمان‌های شهری خروجی شبکه یادگیری عمیق (ارتفاعات مطابق رنگ‌بندی شاخص سمت چپ تصویر آورده شده است - واحد: متر)




شکل ۹: مدل ارتفاعی سطح تولید شده (ارتفاعات مطابق شاخص سمت راست تصاویر بصورت رنگ‌بندی ارائه شده است)

۴- نتایج و ارزیابی

به منظور ارزیابی نتایج بدست آمده، از دو مرجع ارتفاعی موجود در منابع رایگان استفاده شده است. داده مرجع ارتفاعی اولیه داده‌های لیدار هوایی تهیه شده در سال ۲۰۱۸ از شهر فیلادلفیا است که در تارنمای شهرداری این شهر به منظور انجام امور مطالعاتی قرار گرفته است. داده مرجع ارتفاعی دوم، مدل ارتفاعی سطح کوپرنیکوس (*Copernicus*) متعلق به سازمان فضایی اروپاست. این



داده ارتفاعی از محصول ارتفاعی ورلد دم (*WorldDEM*) تهیه شده از ماهواره‌های تندم ایکس (*TanDEM-X*) بازنمونه برداری شده و با قدرت تفکیک ۳۰ متر بطور رایگان در اختیار پژوهشگران قرار دارد. در این بخش ابتدا با ترسیم ابر نقاط حاصل از روش پیشنهادی این پژوهش در مقایسه با مرجع ارتفاعی لیدار (شکل (۱۰))، به گزارش پارامترهای آماری حاصل از ارزیابی خروجی این پژوهش پرداخته شد.




شکل ۱۰: مقایسه ابر نقاط حاصل از تداخل‌سنجی راداری پراکنش‌گرهای دائمی و روش پیشنهادی این پژوهش (نقاط رنگ آبی) در مقایسه با ابر نقاط لیدار هوایی از ساختار پشت بام ساختمان (نقاط زرد رنگ)

نقاط سه‌بعدی ساختمان بر حسب متر و محور افقی بیانگر شماره نقاط حاصل از متراکم سازی ابر نقاط سه‌بعدی است (در هر نقطه ارتفاع بدست آمده از تداخل‌سنجی راداری با مقدار متناظر ارتفاع همان نقطه در داده مرجع لیدار مقایسه شده است).

به منظور ارائه تصویر دقیق‌تر از دقت روش پیشنهادی در شکل (۱۱) مقایسه این دو ابر نقطه در قالب شکل‌های زیر ارائه شده است. به منظور مقایسه بصری ابر نقاط بدست آمده و داده‌های مرجع لیدار، ابر نقاط سه‌بعدی بصورت دو بعدی ارائه شده و نمای صفحه $X-Z$ از ابر نقاط در شکل (۱۱) زیر آورده شده است. محور عمودی، ارتفاع ابر






شکل ۱۱: مقایسه ابر نقاط حاصل از تداخل سنجی راداری پراکنش گرهای دائمی و روش پیشنهادی این پژوهش (نقاط آبی رنگ) در مقایسه با ابر نقاط لیدار هوایی از ساختار پشت بام ساختمان (نقاط قرمز رنگ)

روی مجموعه داده (۳۰۰۰۰ ساختمان) در شکل (۱۲) آورده شده است. نمودار آبی رنگ وضعیت مقدار تابع زیان که میزان فاصله بین داده متراکم شده و داده مرجع زمینی در حین آموزش شبکه در صد اپک را نشان می دهد (محور افقی تعداد اپک های یادگیری و محور عمودی مقادیر تابع زیان است). نمودار قرمز رنگ مقادیر تابع زیان بر روی دویست ساختمان انتخاب شده برای فرآیند ارزیابی شبکه را نشان می دهد.

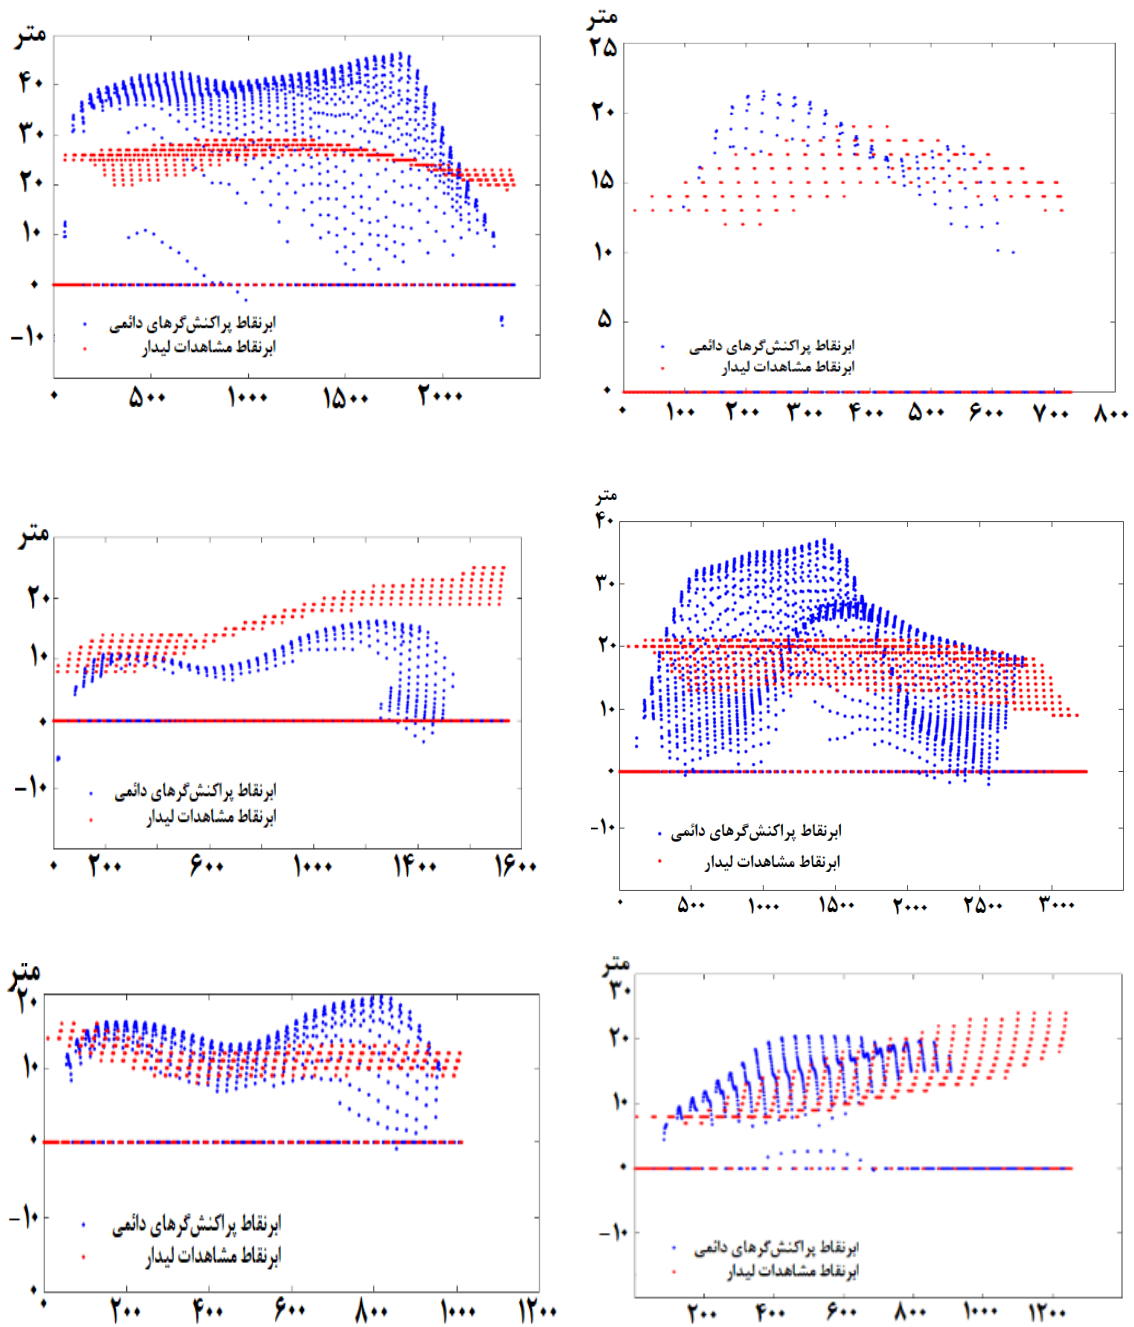
به منظور ارزیابی دقت حاصل از روش پیشنهادی مقاله، دویست ساختمان بعنوان داده تست انتخاب شد. برای استخراج پارامترهای آماری نتایج بدست آمده نسبت به مرجع لیدار در همان منطقه، بایستی ساختار نامنظم دو ابر نقطه، به ساختار منظم جهت ارزیابی دقت حاصله تبدیل شود. بدین منظور دو مجموعه ابر نقطه را به مدل ارتفاعی سطح تبدیل شد تا بتوان در منطقه مورد مطالعه پارامترهای آماری را استخراج کرد. مقادیر تابع زیان در فرآیند آموزش و تست شبکه یادگیری عمیق بر



شکل ۱۲: مقادیر تابع زیان شبکه یادگیری عمیق بر روی داده های آموزشی حین یادگیری (خط آبی رنگ) و مقادیر تابع زیان بر روی داده های تست در یکصد اپک (خط قرمز رنگ)

در شکل (۱۳) مقایسه ابر نقاط حاصل از روش پیشنهادی در مقایسه با مدل ارتفاعی کوپرنیکوس آورده شده است.

برای ارزیابی مدل ارتفاعی سطح حاصل از متراکم سازی ابر نقاط سه بعدی، دو مدل سطح از نظر پارامترهای آماری بصورت کمی ارزیابی شدند. نتایج این ارزیابی در جدول (۲) آورده شده است.



شکل ۱۳: مقایسه ابر نقاط حاصل از تداخل سنجی راداری پراکنش گرهای دائمی و روش پیشنهادی این پژوهش (نقاط آبی رنگ) در مقایسه با مدل ارتفاعی سطح (نقاط قرمز رنگ)

جدول ۲: مولفه‌های ارزیابی با داده لیدار

مقدار میانگین مطلق خطا	انحراف معیار خطا	جذر کمترین مربعات خطا
۴٫۶۷ متر	۸٫۸ متر	۹٫۱۱ متر

ابر نقاط تداخل سنجی نیز قابل مشاهده است. به‌منظور ارزیابی نتایج با مدل ارتفاعی سطح کوپرنیکوس، با تشکیل مدل ارتفاعی سطح از داده‌های متراکم ابر نقاط روش پیشنهادی و مقایسه با این مدل ارتفاعی سطح مقادیر آماری ارزیابی انجام شده در جدول (۳) ارائه شده است.

همانطور که در شکل‌های (۱۱) و (۱۳) مشخص است، ابر نقاط سه‌بعدی حاصل از تداخل‌سنجی راداری پراکنش‌گرهای دائمی تا حد خوبی توانسته‌اند ساختار هندسی ساختمان‌ها را در مقایسه با داده‌های لیدار نشان دهند. بسیاری از تغییرات هندسی که اغلب در ساختار هندسی پشت‌بام‌ها اتفاق افتاده است بخوبی در

جدول ۳: مولفه‌های ارزیابی با داده مدل ارتفاعی سطح کوپرنیکوس

مقدار میانگین مطلق خطا	انحراف معیار خطا	جذر کمترین مربعات خطا
۸٫۹۲ متر	۱۰٫۰۲ متر	۱۱٫۹۱ متر

از روش پیشنهادی این پژوهش را بیان کند. دقت‌های بدست آمده در مقایسه با مدل‌های ارتفاعی سطح رایگان موجود در دنیا از عارضه ساختمان در مناطق شهری بهتر بوده و قابلیت روش پیشنهادی برای رسیدن به یک مدل ارتفاعی سطح در منطقه شهری را نشان می‌دهد.

در مقایسه با مطالعات صورت گرفته در حوزه تولید مدل ارتفاعی با استفاده از تصاویر ماهواره‌ای سنتینل-۱، دقت حاصل از روش پیشنهادی این مقاله نسبت به دقت‌های گزارش شده در این حوزه جایگاه مطلوبی دارد. در مقاله برون در سال ۲۰۲۱ نتایج مطالعات تولید مدل ارتفاعی از داده‌های ماهواره‌ی سنتینل-۱ در جدول (۴) آورده شده است که جایگاه نسبی دقت بدست آمده در این پژوهش را نسبت به مطالعات نزدیک به موضوع این مقاله را مشخص می‌کند.

به دلیل تفاوت بین قدرت تفکیک مدل ارتفاعی سطح کوپرنیکوس و مدل ارتفاعی سطح بدست آمده از ابر نقاط روش پیشنهادی، مقادیر مولفه‌های آماری ارزیابی انجام شده، مقادیر بزرگتری نسبت به ارزیابی صورت گرفته با داده‌های لیدار هستند. این موضوع علاوه بر ارتباط با قدرت تفکیک پائین مدل ارتفاعی سطح مرجع مورد استفاده، به تفاوت دقت مسطحاتی و ارتفاعی این داده نیز مرتبط است. با اینکه مطابق با آخرین بررسی‌های علمی بر روی مدل‌های ارتفاعی رایگان موجود در دنیا، مدل ارتفاعی سطح کوپرنیکوس از دقت بسیار بهتری برخوردار است اما نسبت به داده‌های لیدار قابل مقایسه نخواهد بود. از طرفی داده‌های لیدار نیز دارای بخش‌های گپ در ساختار ساختمان‌هاست که عملاً در ارزیابی صورت گرفته تأثیر خود را داشته است. بنابراین ارزیابی همزمان با این دو مرجع ارتفاعی موجود توانسته است از لحاظ کیفی و کمی دقت قابل حصول

جدول ۴: نتایج مطالعات تولید مدل ارتفاعی سطح از داده‌های سنتینل-۱

نویسندگان	هدف، منطقه مطالعاتی	محدوده ارتفاع منطقه (متر)	تعداد تصاویر	فاصله زمانی تصاویر (روز)	داده ارزیابی	معیارهای ارزیابی (متر)
احمدآبادی و دیگران (۲۰۲۰) [۲۱]	تغییرات سطح، اردستان (۶ کیلومتر مربع)	۹۳۰ - ۹۹۰	۲	۱۲	۱۱۰ نقطه کنترل زمینی	$RMSE = ۲,۴۲$
آتالای و سفرسیک (۲۰۱۸) [۲۲]	توپوگرافی، زونگولک ترکیه	۰ - ۵۴۰	۲	۱۲	مدل ارتفاعی سطح فتوگرامتری	$Std = ۴,۲ - ۵,۲$
دبیری و دیگران (۲۰۲۰) [۲۳]	تغییرات سطح، دره هیتاردالور ایسلند	۸۹ - ۷۴۳	۶	۶	مدل ارتفاعی آرکتیک (۲ متر)	$RMSE = ۳۰ و ۳۷ و ۴۶$
قنادی و دیگران (۲۰۲۰) [۲۴]	شهرهای تهران و جم، ایران	۵۷۹ - ۸۳۰	۲	۱۸۰-۲۴	مدل ارتفاعی (۱ متر)	$RMSE = ۲۴,۳ و ۲۳,۱ و ۲۰,۱$
یانگ و دیگران (۲۰۱۸) [۲۵]	دشت کویر ایران	-	۲	۶	تداخل‌نمای مرجع	$RMSE = ۲۸$

۵- نتیجه‌گیری و پیشنهادها

نتایج این تحقیق نشان داد با استفاده از داده‌های رایگان ماهواره‌ی سنتینل-۱ و بکارگیری قابلیت‌های شبکه‌ی یادگیری عمیق، می‌توان از خروجی‌های گسسته و غیرمتراکم تداخل‌سنجی راداری به محصول مدل ارتفاعی سطح دست یافت. در این پژوهش با ارائه یک راه‌حل جدید و تلفیقی از روش‌های مرسوم تداخل‌سنجی راداری مبتنی بر پراکنش‌گرهای دائمی و هوش مصنوعی، یک محصول کاربردی مدل ارتفاعی سطح به‌منظور استفاده در مطالعات و مدیریت شهری، استفاده در تحلیل‌های ارتباطات مخابراتی در مناطق شهری با ساختمان‌های بلند تولید شده است. این روش در مناطق مختلف شهری ارزیابی شد و دقت‌های قابل حصول از این روش در مقایسه با داده‌های لیدار ۴/۶۷ متر و در مقایسه با داده‌های مدل ارتفاعی سطح

کوپرنیکوس ۸/۹۲ متر بدست آمد.

در این مطالعه با توجه به استفاده از داده‌های رایگان سنتینل-۱، محدودیت‌هایی در قدرت تفکیک مکانی مشاهدات وجود داشت. در تحقیقات آتی می‌توان با بهبود قدرت تفکیک داده‌های ورودی، تاثیر آن بر دقت تخمین ارتفاعی عوارض مختلف را ارزیابی نمود. پیشنهاد می‌گردد در مطالعات آتی، کاربرد این روش در بازسازی سه بعدی ساختمان‌ها با سطح جزئیات مختلف ارزیابی گردد. در این پژوهش، متراکم‌سازی ابر نقاط ساختمان‌ها، مد نظر و بررسی قرار گرفته است. قابلیت روش ارائه شده در این پژوهش در متراکم‌سازی ابر نقاط سایر عوارض شهری مثل پل‌ها، ورزشگاه‌ها و مخازن نفتی نیز می‌تواند در آینده مورد مطالعه پژوهشگران قرار گیرد.

مراجع

- [1] Maghsoudi, Y., van der Meer, F., Hecker, C., Perissin, D., & Saepuloh, A. "Using PS-InSAR to detect surface deformation in geothermal areas of West Java in Indonesia". *International Journal of Applied Earth Observation and Geoinformation*, 2017.
- [2] Graham, L. C. "Synthetic interferometer radar for topographic mapping". *Proceedings of the IEEE*, 62(6), 763-768, 1974.
- [3] Tadono, T., Ishida, H., Oda, F., Naito, S., Minakawa, K., & Iwamoto, H. "Precise global DEM generation by ALOS PRISM". *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 2(4), 71, 2014.
- [4] Ferretti, A., Prati, C., & Rocca, F. "Permanent scatterers in SAR interferometry". *IEEE Transactions on Geoscience and Remote Sensing*, 39(1), 8-20, 2001.
- [5] Maghsoudi, Y., & Mahdavi, S. "The Principles of Radar Remote Sensing". K. N. Toosi University of Technology, [In Persian], 2015.
- [6] Hooper, A., Segall, P., & Zebker, H. "Persistent scatterer interferometric synthetic aperture radar for crustal deformation analysis, with application to Volcán Alcedo, Galápagos". *Journal of Geophysical Research: Solid Earth*, 112(B7), 2007.
- [7] Berardino, P., Fornaro, G., Lanari, R., & Sansosti, E. "A new algorithm for surface deformation monitoring based on small baseline differential SAR interferograms". *IEEE Transactions on Geoscience and Remote Sensing*, 40(11), 2375-2383, 2002.
- [8] Hooper, A., Zebker, H., Segall, P., & Kampes, B. "A new method for measuring deformation on volcanoes and other natural terrains using InSAR persistent scatterers". *Geophysical research letters*, 31, 2004.
- [9] Werner, C., Wegmuller, U., Strozzi, T., & Wiesmann, A. "A. Interferometric point target analysis for deformation mapping". *Geoscience and Remote Sensing Symposium. IGARSS'03. Proceedings*, 2003.
- [10] Kampes, B. M. "Displacement parameter estimation using permanent scatterer interferometry". TU Delft, Delft University of Technology, 2005.
- [11] Perissin, D., & Wang, T. "Repeat-pass SAR interferometry with partially coherent targets". *IEEE Transactions on Geoscience and Remote Sensing*, 50(1), 271-280, 2012.
- [12] Ferretti, A., Fumagalli, A., Novali, F., Prati, C., Rocca, F., & Rucci, A. "A new algorithm for processing interferometric data-stacks: SqueeSAR". *IEEE Transactions on Geoscience and Remote Sensing*, 49(9), 3460-3470, 2011.
- [13] Cireşan, D., Meier, U., Schmidhuber, J., 2012. "Multi-Column Deep Neural Networks for Image Classification". In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 3642-3649, 2012.
- [14] Qi, Charles R and Su, Hao and Mo, Kaichun and Guibas, Leonidas J. "PointNet: Deep Learning on Point Sets for 3D Classification and Segmentation". *Computer Vision and Pattern Recognition (CVPR)*, 2017.
- [15] C. R. Qi, L. Yi, H. Su, and L. J. Guibas. "Pointnet++: Deep hierarchical feature learning on point sets in a metric space". In *Advances in Neural Information Processing Systems*, pages 5105-5114, 2017.
- [16] P. Achlioptas, O. Diamanti, I. Mitliagkas, and L. Guibas. "Learning representations and generative models for 3d point clouds". *arXiv preprint arXiv:1707.02392*, 2017.
- [17] W. Yuan, T. Khot, D. Held, C. Mertz, M.

- Hebert, "PCN: Point Completion Network". In *Proc. 3D Vision (3DV)*, Verona, Italy, 5–8 September 2018; pp. 728–737, 2018.
- [18] Y. Yang, C. Feng, Y. Shen, and D. Tian. "Foldingnet Point Completion Network. Interpretable unsupervised learning on 3d point clouds". *arXiv preprint arXiv:1712.07262*, 2017.
- [19] H. Fan, H. Su, and L. Guibas. "A point set generation network for 3d object reconstruction from a single image". In *Conference on Computer Vision and Pattern Recognition (CVPR)*, volume 38, 2017.
- [20] A. Braun. "Retrieval of Digital Elevation Models from Sentinel-1 radar data-open applications, techniques, and limitations". *Open Geosciences*, De Gruyter, 2021.
- [21] Ahmadabadi A, Karam A, Saffari A, Yazdanpanah M. "Estimation of surface and elevation displacement of Ardestan sand dunes using radar interferometry and spectral indices." *Quant Geomorphol Res.* 2020; 5(8):1-17, 2020.
- [22] Atalay C, Sefercik UG. "Comparison of Sentinel-1 and ALOS AW3D30 DSM potentials in a mountainous topography". *Young Professionals Conference on Remote Sensing*; 7–8 June 2018, Aachen, Germany: Institute of Electrical and Electronics Engineers (IEEE), 2018.
- [23] Dabiri Z, Hölbling D, Abad L, Helgason JK, Sæmundsson Þ, Tiede D. "Assessment of landslide-induced geomorphological changes in Hítardalur Valley, Iceland, using Sentinel-1 and Sentinel-2 data." *Appl Sci.* 10:5848. 2020.
- [24] Ghannadi MA, Alebooye S, Izadi M, Moradi A. "A method for Sentinel-1 DEM outlier removal using 2-D Kalman filter". *Geocarto Int.* 2020.
- [25] Yang H, Chen C, Chen S, Xi F, Liu Z. "Radar interferometry using two images with different resolutions. *IEEE Radar Conference (RadarConf)*, 2019.



The Densification of the point cloud from PS-InSAR Method in Urban Area

Sajad Sajedizadeh ¹, Yaser Maghsoudi Mehrani ^{2*}

1- PhD Student of Remote Sensing in Department of Photogrammetry and Remote Sensing, Faculty of Geodesy and Geomatics Engineering, K. N. Toosi University of Technology

2- Associate Professor in Department of Photogrammetry and Remote Sensing, Faculty of Geodesy and Geomatics Engineering, K. N. Toosi University of Technology

Abstract

3D point Clouds have made a significant contribution to airborne and spaceborne observations in recent years. The sensor limitations and processing challenges of these observations have been investigated in several studies. We generated 3D point clouds using the persistent scatterers interferometric SAR method in order to estimate the obstacles heights. By estimating the height error of the topographic model used in PS-InSAR processing, the permanent scatterer's heights were estimated. The height accuracy was improved by making changes in master image selection. Due to the low density as well as SAR side-looking geometry, the derived 3D point clouds do not represent the complete geometry of complications. In this article, the shape completion deep learning neural network was used to increase the point density and complete the shape geometry. By performing learning steps, these networks directly map non-dense and incomplete shape to dense and complete shape geometry. The global features of the incomplete shapes were determined while retaining the details to an optimal extent. The cost criterion of this network is based on the Chamfer Distance, which measures the distance between the non-dense input and dense output point clouds. The PS-InSAR processing was done on 27 images of the Sentinel-1 satellite in Philadelphia city, USA. This output obtained from PS-InSAR will be able to estimate the height of various urban complications. We prepared 30000 individual building datasets for training the network in the urban areas. The amount of obtained loss was 0.048 in the training process and 0.0482 in the network evaluation process. By evaluating the surface elevation model extracted by lidar reference data of the studied area, the average absolute height estimation error was 4.67 meters which is quite near the worldwide amounts.

Key words: 3D Point Cloud Completion, Interferometric SAR, Permanent Scatterers, Elevation Model.