

روشی نوین در بهبود تضاریس لبه ساختمان‌ها بر روی تصاویر قائم

مژده ابراهیمی کیا^۱

علی حسینی نوه^۲

تاریخ دریافت مقاله: ۱۴۰۱/۰۴/۰۹

تاریخ پذیرش مقاله: ۱۴۰۱/۰۸/۱۰

چکیده

امروزه تصاویر قائم از محصولات پرکاربرد در حوزه اطلاعات مکانی هستند که غالباً از تصاویر هوایی یا ماهواره‌ای تهیه می‌شوند، به‌طوری که توجه به دقت و کیفیت تصاویر قائم به دلیل دارا بودن هم زمان اطلاعات هندسی و رادیومتریکی از اهمیت بالایی برخوردار است. عوامل متعددی در کیفیت تهیه این تصاویر تأثیرگذار هستند که در این میان ابرنقاط و مدل رقومی سطحی که از آن تهیه می‌شوند را می‌توان به‌عنوان مهم‌ترین موارد برشمرد. به سبب نقص ابرنقاط در لبه‌های ساختاری ساختمان‌ها تصاویر قائم حقیقی دارای اعوجاج‌ها و تضاریسی بر روی این لبه‌ها می‌باشند. این مشکل بر روی تصاویر قائم به‌دست آمده از تصاویری که با پهپادها در نواحی شهری اخذ می‌شوند به علت آنکه از ارتفاع پایین‌تری برخوردارند بیشتر است. در این حالت به سبب افزایش میزان جابه‌جایی‌های مسطحاتی ناشی از عوارض مرتفع با ارتفاع پرواز پایین نسبت به هواپیماهای باسرشتین لازم است تا ابرنقاط مربوطه بهبود یافته و از مدل رقومی سطحی دقیق‌تری برای انجام تصحیحات استفاده شود. علاوه بر این روش‌های تهیه ابرنقاط که بر مبنای تناظریابی میان تصاویر است به علت وجود نواحی پنهان و تغییرات رادیومتریکی میان تصاویر همپوشان قادر به تولید ابرنقاط کامل نبوده و دارای نقص‌هایی به‌ویژه بر روی لبه‌های عوارض هستند. در این مطالعه علاوه بر اینکه برای تکمیل ابرنقاط استفاده از شبکه یادگیری عمیق آموزش‌دیده در بهبود ابرنقاط جهت تهیه تصاویر قائم پیشنهاد شده است موفقیت نتایج حاصل از آن با جدیدترین روش پیشنهادی بهبود تصویر قائم حکایت از بهبود حدود ۶۲ و ۵۵ درصدی تضاریس نقاط واقع بر لبه‌های ساختاری و حفظ دقت مختصاتی آن‌ها دارد.

واژه‌های کلیدی: تصویر قائم (ارتوفتو)، ابرنقاط، تضاریس لبه

۱- دانشجوی دکترا فتوگرامتری، دانشکده مهندسی ژئودزی و ژئوماتیک دانشگاه خواجه نصیرالدین طوسی، تهران، ایران m.ebrahimikia@email.kntu.ac.ir

۲- استادیار دانشکده مهندسی ژئودزی و ژئوماتیک دانشگاه خواجه نصیرالدین طوسی، تهران، ایران (نویسنده مسئول) hosseininaveh@kntu.ac.ir

& Roncoroni, 2014; Boccardo, Dequal, Lingua, & Rinaudo, 2001;

Ebrahimikia & Hosseininaveh, 2022; Kato, Moskal, Schiess, Calhoun, & Swanson, 2010; Q. Wang et al., 2018; Wu, Jie, Yao, & Stilla, 2011). در اکثر این مطالعات سعی بر اضافه نمودن خطوط و یا نقاط لبه ساختمان‌ها به مدل ابرنقاط بوده است. به عنوان نمونه در روش (Q. Wang et al., 2018)، از تنها یک زوج تصویر برای شناسایی و تناظریابی پیکسل‌های هر یک از خطوط ساختاری سقف ساختمان‌ها و در نهایت به کارگیری مدل سه بعدی آن‌ها در ابرنقاط بهره گرفته شده است. در این روش به علت به کارگیری تنها یک زوج تصویر بسیاری از خطوط لبه مربوط به نواحی پنهان قابل بازسازی نیستند. در روش (Ebrahimikia & Hosseininaveh, 2022) با بهره گرفتن از همان ایده این بار بجای خطوط مستقیم نقاط لبه نواحی ساختاری منحنی شکل نیز استخراج و به مدل سه بعدی اضافه گردید و نتایج آن با نتایج دیگر روش‌ها از جمله به کارگیری روش (Line3D++ (Manhofer, 2020 در تهیه و بازسازی خطوط سه بعدی در تمامی تصاویر همپوشان مقایسه شد. گرچه بازسازی خطوط با استفاده از به کارگیری روش Line3D++ در بهبود مدل سه بعدی سطح به علت محاسبه خطوط از استحکام بالاتری برخوردار است اما برای بازسازی لبه‌های منحنی و بهبود آن در تصاویر قائم روش به کارگیری از نقاط لبه نتایج رضایت‌بخش‌تری داشته است (Ebrahimikia & Hosseininaveh, 2022).

بعد از انجام محاسبات اولیه و انجام پردازش‌های لازم با استفاده از الگوریتم SfM^۳ و تناظریابی میان تصاویر، ابرنقاط کم‌تراکم همزمان با پارامترهای داخلی و خارجی دوربین محاسبه می‌شوند در حالی که در ادامه الگوریتم SGM برای تولید ابرنقاط متراکم استفاده می‌گردد. از آنجا که ابرنقاط حاصل از روش‌های تناظریابی همچون روش SGM بر روی تصاویر همپوشان قادر به بازسازی ابرنقاط بر روی لبه عوارض به طور کامل و دقیق نیستند، لازم است تا برای تهیه مدل‌های رقومی سطحی دقیق و جلوگیری از تضاریس و اعوجاج بر روی لبه عوارض در تهیه تصاویر

۱- مقدمه

از پارامترهای بسیار مهم در کیفیت و دقت تصاویر قائم حقیقی مدل سطح زمین (DSM)^۱ است. این مدل معمولاً بر اساس ابرنقاط حاصل از لیدار و یا تناظریابی تصاویر تهیه می‌شود (Ebrahimikia & Hosseininaveh, 2022). ابرنقاط حاصل از هر دو روش در لبه عوارض کامل نبوده و در حالتی که از تصاویر برای تهیه آن‌ها استفاده شود دارای خطاهای اتفاقی نیز می‌باشند (Krauß & Reinartz, 2010). روش تناظریابی (Hirschmuller, 2008) SGM^۲ یکی از متداول‌ترین روش‌های تناظریابی است که نتایج تناظریابی حاصل از آن به علت زوایای دید متفاوت تصاویر ورودی دارای مقادیر اشتباه به خصوص بر روی لبه عوارض است (Y. Chen, Briese, Karel, & Pfeifer, 2014; Mohammadi, Samadzadegan, & Reinartz, 2016; Siddiqui, Teng, Awrangjeb, & Lu, 2019). در استفاده از تصاویر، این آشفتگی و نقص با به کارگیری تصاویر پهپاد از مناطق شهری که در ارتفاع پایین‌تری تصویربرداری می‌کند آشکارتر است به طوری که بسیاری از قسمت‌های ابرنقاط به سبب ضعف اطلاعات رادیومتریکی و یا قرار گرفتن در نواحی پنهان بدون نقطه باقی می‌مانند (Mohammadi et al., 2019; Noronha & Nevatia, 2001; Siddiqui et al., 2016).

به طور معمول در تهیه تصاویر قائم در لبه عوارض مرتفع اعوجاج‌هایی مشاهده می‌شود که در نتیجه کمبود نقاط سه بعدی در ابرنقاطی است که از آن برای تشکیل مدل رقومی سطح استفاده می‌شود. تصویر قائم حقیقی با تکمیل ابرنقطه و با اضافه کردن یکسری نقاط متوالی عوارض لبه به آن بهبود می‌یابد (Ebrahimikia & Hosseininaveh, 2022; Q. Wang et al., 2018). قبل از درونیابی از ابرنقاط و تهیه مدل رقومی سطح زمین و سپس تهیه تصاویر قائم از آن لازم است تا ابرنقاط در نواحی دارای نقص تکمیل گردد (Widyaningrum, Lindenbergh, Gorte, & Zhou, 2018). در مطالعاتی تأثیر تکمیل نواحی لبه در ابرنقاط در تهیه تصویر قائم حقیقی مورد ارزیابی قرار گرفته است (Barazzetti, Brumana, Oreni, Previtali,

1- Digital Surface Model

2- Semi-Global Matching

3- Structure from Motion

قائم از روش‌های دیگر بازسازی نقاط برای این نواحی در تکمیل ابرنقاط استفاده شود. نتایج حاصل از روش‌هایی که تاکنون جهت اضافه نمودن نقاط به ابرنقاط پیشنهاد شده‌اند علاوه بر اینکه عاری از خطا نیستند می‌توانند کامل نبوده و دارای فضای خالی نیز باشند زیرا در بسیاری از موارد به علت اختلاف‌های رادیومتریکی و خطاهای هندسی بعضی قسمت‌ها از لبه‌ها همچنان بدون بازسازی باقی می‌مانند. نویزهای موجود که در این خطوط و بر روی ابرنقطه باقی می‌مانند و عدم تکمیل ابرنقاطی که در میانه عوارض دارای فضای خالی هستند سبب می‌شود تا این روش‌ها کارایی کاملی برای بهبود مدل‌های رقومی سطح نداشته باشند.

راه دیگری که برای تکمیل ابرنقاط پیشنهاد می‌شود تکمیل ابرنقطه در نواحی لبه به‌طور یکپارچه و بدون فضای خالی است و بنابراین در این مقاله راه‌حل جدیدی برای بهبود تهیه تصویر قائم با به‌کارگیری روش‌های یادگیری عمیق در تکمیل ابرنقاط بررسی و پیشنهاد شده است تا بتوان با به‌کارگیری آن ابرنقاط دیوارهای سقف هر ساختمان را تکمیل و به‌موجب آن مدل رقومی سطح و تصاویر قائم دقیق‌تر و بی‌نقص‌تری از نواحی شهری تهیه نمود.

یکی از روش‌های یادگیری عمیق در تکمیل ابرنقاط روش تکمیل ابرنقاط SnowflakeNet (Xiang et al., 2021) است که در این مطالعه مورد بررسی و آزمایش قرار گرفته است. با استفاده از این روش درحین تکمیل ابرنقاط، شکل کلی و جزئیات آن نیز به‌خوبی حفظ می‌شود.

در ادامه در بخش ۲ به مروری بر مطالعات گذشته در تکمیل ابرنقاط با استفاده از شبکه یادگیری عمیق، در بخش ۳ به داده، در بخش ۴ پیاده‌سازی و نتایج، در بخش ۵ بحث و در بخش ۶ به نتیجه‌گیری و پیشنهادها پرداخته می‌شود.

۲- مروری بر مطالعات گذشته در تکمیل ابرنقاط با استفاده از شبکه یادگیری عمیق

1- Voxels

2- Mesh

همچنین روش‌های بر مبنای و کسل محدودیت رزولوشن دارند زیرا با افزایش میزان رزولوشن، حافظه و هزینه محاسبات به‌شدت افزایش می‌یابد (Huang, Yu, Xu, Ni, & Le, 2020). با ظهور روش PointNet (Qi, Su, Mo, & Guibas, 2017) الگوریتم‌هایی که مستقیماً بر روی ابرنقاط نامنظم کار می‌کنند گسترش یافتند (Li, Zaheer, Zhang, Poczos, & Salakhutdinov, 2018; Yu, Li, Fu, Cohen-Or, & Heng, 2018; Yuan, Khot, Held, Mertz, & Hebert, 2018)

روش‌های پیشنهادی در مطالعات (Gkioxari, Malik, & Johnson, 2019; N. Wang et al., 2018) (Groueix, Fisher, Kim, Russell, & Aubry, 1802) از مش^۲ برای نمایش مدل ابرنقاط استفاده می‌کنند که نمایش جزئیات در آن‌ها به تعداد از پیش تعریف‌شده رئوس مرتبط است. روش‌های مبتنی بر ابرهای نقطه گرچه قادر به مدل‌سازی مدل‌های پیچیده‌تر هستند نوعاً تعداد نقاط ثابت خروجی از پیش تعیین‌شده‌ای دارند و بازسازی حاصل از این روش‌ها پربازده نبوده و محدود به توپولوژی خاصی از اشیاء هستند (Venkatesh et al., 2021).

اکثر روش‌های تکمیل ابرنقاط از مدل‌های encoder-decoder بهره‌جسته‌اند که معماری بسیاری نزدیکی به مدل‌های autoencoder دارند و با بررسی میزان همبستگی داده ناقص

برای تکمیل ابرنقاط می‌توان از دو روش سنتی و استفاده از روش‌های مبتنی بر شبکه‌های عصبی نام برد (Xu Wang,

(Sarmad, Lee, & Kim, 2019). این امر با به کارگیری یک تابع هزینه loss اضافی در این ترکیب بندی ها امکان پذیر می شود. لایه های GAN از یک تولید کننده و متمایز کننده تشکیل شده که در تبادل با decoder هستند و برای تولید نمونه ها و انتخاب آن هایی که قابل تشخیص در مقایسه با نمونه های آموزشی نیستند به کار می روند. در این روش ها نیز حتی با در نظر گرفتن قیدهایی همچنان جزئیات ساختار محلی اشکال حفظ نمی شوند (Chang et al., 2021). به هر حال اکثر این روش ها قادر به نمایش سطوح پیوسته با توپولوژی های متنوع نیستند (Venkatesh et al., 2021; Chibane et al., 2020) و نمی توانند ساختار و هندسه محلی ابرنقاط را همچون نواحی هموار و لبه ها را حفظ کنند (Xiang et al., 2021) و حتی موجب جابه جایی نقاط معلوم و ایجاد نویز می شوند (Huang et al., 2020).

همان طور که در ابتدا ذکر شد به کارگیری مدل ارتفاعی رقومی حاصل از ابرنقاط متراکم و دقیق در تهیه تصویر قائم دارای اهمیت بالایی است. ابرنقاط حاصل از تناظرایی تصاویر بعد از محاسبات SfM^۳ و SGM از پراکندگی نقاط و نویز به خصوص در نواحی لبه عوارض برخوردار است و در مطالعات اخیر پس از حذف نقاط نویز، ابرنقاط با استفاده از اضافه کردن خطوط به صورت نقاط متوالی بهبود داده می شود تا شکل گوشه ها و لبه عوارض در ابرنقطه حفظ شوند (Ebrahimikia & Hosseininaveh, 2022; Q. Wang et al., 2018). اخیراً (Xiang et al., 2021) برای اولین بار روش تکمیل ابرنقطه SnowflakeNet را بر اساس شبیه سازی تکثیر دانه های برف در فضای سه بعدی پیشنهاد داده است تا علاوه بر حفظ شکل کلی و تکمیل نواحی دارای نقص ابرنقاط، ساختار و هندسه محلی در لبه ها و گوشه ها و همچنین نواحی مسطح حفظ شوند. این روش بر اساس لایه های SPD^۴ و متمرکز بر decoding برای تکمیل ابرنقطه جزئی است و هر لایه از نقاط به نقاطی در لایه بعدی با خصوصیات محلی لایه قبلی که آن را به ارث می برد تقسیم می شود.

ورودی با داده کامل مرجع آموزش می بیند (Czerniawski, Ma, & Leite, 2021). در این مدل ها مقادیر ورودی encoder به فضای پنهان یا فضای نهفته منتقل می شوند و سپس توسط decoder بازسازی می شوند. میزان حجم و فشردگی داده نمایش داده شده مدل به ابعاد این فضا یا لایه bottleneck مرتبط است و از آنجا که این لایه میزان کاهش نمایش مدل را کنترل می کند تعیین صحیح آن منجر به تکمیل خروجی با کمترین میزان از دست دادن جزئیات همراه با کاهش نویز می شود (Czerniawski et al., 2021). تاکنون راه حل های بسیاری توسط محققین برای بهبود این شبکه ها در حفظ بیشتر جزئیات محلی پیشنهاد شده است. اغلب encoder سبب می شود تا Feather global که شامل اطلاعات و خصوصیات کلی است از داده ورودی استخراج شده و با به کارگیری skip connections; Dai, Diller, & Nießner, 2020; Dai, Ruizhongtai Qi, & Nießner, 2017; Hou, Dai, & Nießner, 2020; Liu, Sheng, Yang, Shao, & Hu, 2020; Xiaogang Wang, Ang Jr, & Lee, 2020; Zhang, Liu, Li, & Zang, 2019) ارتباط مستقیم لایه ها از encoder به decoder حفظ شود. این کار روشی برای حفظ ساختار محلی داده ورودی در خروجی شبکه است (Czerniawski et al., 2021). همچنین استفاده از روش های سلسله مراتبی در شبکه همچون مدل های پیرامید^۱ (Huang et al., 2020) و نمودارهای گراف (Tchamni, Kosaraju, Rezatofighi, Reid, & Savarese, 2019; Xiang et al., 2021) و نگاشت صفحات دوبعدی به فضای سه بعدی (Yang, Feng, Shen, & Tian, 2018) از لایه های ویژگی محلی سبب حفظ جزئیات هندسی ساختار داده با گذر از شمای کلی به شمای جزئی می شوند.

به جهت اینکه بسیاری از مسائل تکمیل داده دارای چندین مدل هستند به معنی اینکه برای تکمیل نواحی ناقص مدل های مختلفی را که سازگار با محتوای داده ورودی است را می توان پیشنهاد داد بعضی از محققین استفاده از GAN^۲ را به جای autoencoderهای متغیر برای دستیابی به یک نتیجه قطعی پیشنهاد داده اند (X. Chen, Chen, & Mitra, 2019) (Li et al., 2018).

3- Structure from Motion

4- Snowflake Point Deconvolution

1- Pyramid

2- Generative Adversarial Network


۳- روش تحقیق

به شبکه به عنوان ورودی معرفی می‌شوند. با استفاده از شبکه، نقاط مربوط به لبه‌های ساختاری تکمیل می‌شوند و سپس برای هر سقف استخراج و جهت اضافه شدن به ابرنقاط موجود آماده و میزان تراکم آن‌ها افزایش می‌یابد. ابرنقاط نهایی در تهیه مدل رقومی سطح نامنظم و سپس منظم استفاده شده و در تهیه تصویر قائم حقیقی با استفاده از پارامترهای دوربین و تصاویر بدون اعوجاج مورد استفاده قرار می‌گیرند (نگاره ۱).

۳-۱- آماده‌سازی و نرمال‌سازی ابرنقاط

با استفاده از الگوریتم α shape (Wei, 2008) بیرونی‌ترین نقاط از ابرنقاط هر سقف انتخاب می‌شوند. در این روش هر دو نقطه مجاور از نقاط پیرامونی ابرنقاط با محیط شدن

مراحل انجام روش پیشنهادی برای تهیه تصویر قائم حقیقی در نگاره ۱ نمایش داده شده است. مراحل روش متداول با رنگ آبی و مراحل روش پیشنهادی با رنگ زرد نمایش داده شده است. در روش متداول از SfM برای کالیبراسیون دوربین، برآورد پارامترهای توجیه داخلی و خارجی و تهیه تصاویر بدون اعوجاج و ابرنقاط با تراکم کم استفاده شده است و از SGM برای تهیه ابرنقاط مترکم استفاده گردیده است. در روش پیشنهادی از شبکه یادگیری عمیق SnowflakeNet آموزش‌دیده برای تکمیل ابرنقاط ناقص سقف ساختمان‌ها استفاده گردیده است. با فرض اینکه ابرنقاط مربوط به سقف هر ساختمان از پیش تعیین و حذف نویز شده و دارای لبه‌های ناقص است این نقاط



نگاره ۱: شمای کلی روش پیشنهادی

به کارگیری آن است. این الگوریتم دورترین نقاط از یکدیگر را در ابرنقطه ورودی به تدریج انتخاب می کند به طوری که در فاصله ای خارج از شعاع دایره های محاسبه شده واقع بر دیگر نقاط قرار گیرند و با تکرار مراحل و انتخاب نقاط به طور پیاپی تعداد نقاط مورد نظر انتخاب شوند. در ادامه برای معرفی به شبکه یادگیری عمیق این نقاط در بازه $0/5$ و $0/5$ - نرمال و همچنین نسبت به مختصات محلی مرکز هر داده مقداردهی می شوند.

۲-۳- تکمیل ابرنقاط با استفاده از شبکه یادگیری عمیق SnowflakeNet


این شبکه به صورت سلسله مراتبی تراکم ابرنقاط ورودی را افزایش می دهد به طوری که در هر مرحله نمونه هایی که اضافه می شوند را طوری جابه جا می کند که نه تنها به هندسه و الگوی نهایی نزدیک تر شوند بلکه با به کارگیری تبدیل گر جهشی^۱ اطلاعات هر مرحله به مرحله بعدی معرفی می شوند. تابع هزینه این شبکه برای هر مرحله براساس محاسبه فاصله میان نقاط ابرنقطه تهیه شده از همان مرحله با ابرنقاط داده آموزشی مرجع هست و توقف آموزش شبکه براساس تعداد تکرار یادگیری و تغییرات تابع هزینه می باشد. بعد از تکمیل ابرنقاط توسط شبکه آموزش دیده این نقاط می بایست به مختصات و مقیاس حقیقی تغییر یابند.

همان طور که در نگاره ۳ نمایش داده شده است مراحل شبکه SnowflakeNet از سه بخش تشکیل شده است (نگاره ۳): (۱) استخراج ویژگی، (۲) تولید ابرنقطه پایه و (۳) تولید نقاط که در ادامه به توضیح هر بخش پرداخته می شود.

بخش استخراج ویژگی:


با فرض آنکه ابرنقاط ورودی $P = \{p_j\}$ با اندازه $3 \times N$ می باشد که N تعداد نقاط و هر p_j یک نقطه در فضای سه بعدی است. عملگر استخراج ویژگی کمک می کند تا تابع کلی شکل با اندازه $1 \times C$ که شامل ساختار کلی و الگوی

هر یک از دایره ها با شعاع α مشخص می شوند و با اتصال این نقاط به یکدیگر چندضلعی بسته از محیط پیرامون شکل حاصل می شود. از آنجا که دایره ها به هر دو نقطه مجاور از مجموعه نقاط محیط می شوند، مقدار α معمولاً طوری در نظر گرفته می شود تا چندضلعی به دست آمده محیط بر تمامی نقاط ابرنقاط شود (نگاره ۲).



نگاره ۲: نحوه برازش پلیگون محیط بر ابرنقاط با استفاده از الگوریتم α shape (Wei, 2008).

در این مطالعه، نقاط محیطی مربوط به هر ساختمان با به کارگیری الگوریتم مذکور مشخص می شوند. از آنجا که این نقاط، نقاط واقع بر لبه بیرونی و بالایی دیوارهای جان پناه پشت بام هستند و تراکم نقاط به دست آمده به طریق تناظریابی از روی تصاویر همپوشان از کف پشت بام تا این نقاط بسیار کم است؛ تعداد این نقاط در راستای عمودی با اضافه کردن نقاطی در فواصل یکسان افزایش می یابد. علاوه بر این مطابق با تعداد نقاط داده آموزشی به شبکه یادگیری عمیق لازم است تا تعداد نقاط در ابرنقاط مربوط به سقف ساختمان ها به این میزان (۲۰۴۸ نقطه) تغییر یابد. این مرحله توسط الگوریتم Poisson (Dunbar & Humphreys, 2006) disk sampling انجام می گیرد. این الگوریتم برای انتخاب رندوم و یکنواخت نقاط با حفظ حداقل فاصله برابر با شعاع دایره های تعریف شده توسط الگوریتم است. ورودی این الگوریتم ابرنقطه موجود و تعداد نقاط مطلوب حاصل از



نگاره ۳: مراحل الگوریتم SnowflakeNet (Xiang et al., 2021): (الف) ساختار کلی الگوریتم، (ب) جزئیات بخش تولید ابرنقطه پایه، (ج) جزئیات بخش SPD، N_c, N و تعداد نقاط و C و C' تعداد کانال‌های ویژگی نقطه و به ترتیب دارای مقادیر ۵۱۲ و ۱۲۸ هستند

محلی دقیق از شکل می‌باشد استخراج شود. این بخش از سه لایه همراه با تبدیل‌گر نقطه^۱ برای ادغام اطلاعات از ویژگی‌های محلی تا کلی نقطه و محتوای محلی شکل استفاده می‌کند.

بخش تولید نقاط:

بخش تولید نقاط از سه مرحله لایه‌های SPD تشکیل شده است که در هر مرحله ابرنقطه از مرحله قبل گرفته و با ضرایب افزایش نمونه‌برداری^۲ (r_1, r_2, r_3) به ابرنقاط P_1, P_2, P_3 و با ابعاد $N_1 \times 3, N_2 \times 3, N_3 \times 3$ تبدیل می‌شود. هدف از این لایه‌ها افزایش تعداد نقاط با تقسیم هر نقطه والد به چندین نقطه فرزند می‌باشد. الگوی محلی برای هر نقطه پایه با همکاری میان لایه‌های SPD توسعه می‌یابد به‌طوری که اطلاعات هندسی در نقاط والد و الگوهای محلی در تولید نقاط فرزند آشکار می‌شود. همچنین به جهت تسهیل در تولید پیاپی نقاط در این لایه‌ها از تبدیل‌گر جهشی برای اخذ و انتقال محتوای شکل و ارتباط مکانی میان نقاط والد و نقاط فرزند استفاده شده است.

بخش تولید ابرنقطه پایه:

هدف از عملگر تولید ابرنقطه پایه تولید ابرنقطه کم‌تراکم اما کامل P_0 با اندازه $N_0 \times 3$ است که اطلاعات هندسه و ساختار شکل خروجی نهایی را در خود دارد. همانطور که در نگاره ۳- ب نشان داده شده است در این مرحله با استفاده از تابع کلی شکل (f) ابتدا ویژگی‌های نقطه در هر دو بخش موجود و ناقص ابرنقطه توسط عملگر تقسیم نقطه مبنا (به‌طور کلی این عملگر به تولید ویژگی‌های نقاط تولیدشده می‌پردازد) تهیه می‌شود. سپس برای تولید ابرنقطه کم‌تراکم P_c با اندازه $N_c \times 3$ ، ویژگی‌های هر نقطه با اطلاعات تابع کلی شکل از طریق پرسپترون چند لایه^۲ ترکیب می‌شود. سپس P_c با ابرنقطه اولیه P به کمک عملگر ادغام ترکیب شده

3- Farthest Point Sampling (FPS)

4- up-Sampling

1- Point Transformer

2- Multi Layer Perceptron (MLP)

۳-۳- بهبود تراکم ابرنقاط تکمیل شده و بازگشت به

سیستم مختصات حقیقی

ابرنقاط تکمیل شده در سیستم مختصات نرمالی هستند که در بخش ۳-۱ توضیح داده شد؛ بنابراین برای استفاده در مراحل بعدی و تهیه مدل رقومی سطح لازم است تا به فضای حقیقی بازگردانده شوند. انتقال مختصات به مختصات حقیقی با استفاده از معکوس ضرایب افاین که پیش از این برای نرمال سازی میان مختصات حقیقی و فضای نرمال محاسبه شده بود صورت می گیرد. از آنجاکه تراکم نقاط در فضای حقیقی به مراتب کمتر از فضای نرمال است برای افزایش آن نقاط به صورت متوالی میان هر یک از نقاط درونیابی انجام می شود.

۳-۴- تهیه مدل رقومی سطح

بعد از آنکه ابرنقاط تکمیل شده به ابرنقاط موجود اضافه شدند از شبکه نامنظم مثلثی (TIN)^۱ برای ایجاد مدل رقومی سطح (DSM) استفاده می گردد و سپس از درونیابی میان اضلاع این شبکه مدل رقومی سطح رستری منظم DEM برای معرفی به الگوریتم ترمیم و تهیه تصویر قائم حقیقی استفاده می گردد.

۳-۵- ترمیم و تهیه تصویر قائم و موزاییک تصاویر قائم

در این مطالعه انجام ترمیم و تهیه تصویر قائم با استفاده از روش غیرمستقیم (Nielsen, 2004) صورت گرفته است به طوری که هر سلول از مدل رقومی سطح منظم با استفاده از روابط شرط هم خطی و به کارگیری پارامترهای توجیه داخلی و خارجی به پیکسل مربوطه بر روی تصویر بدون اعوجاج نگاشت می شود و مقدار درجه خاکستری از آن پیکسل اخذ و به سلول متناظر در تصویر قائم اختصاص داده می شود. به سبب وجود نواحی پنهان، بسیاری از نقاط زمینی مقدار درجه خاکستری یکسانی در فرآیند نگاشت بر روی تصویر اخذ می کنند که موجب ایجاد پدیده های دوگانگی

و کشیدگی می شوند. برای رفع این مسئله از تصاویر قائم همپوشان دیگر در موزاییک تصاویر قائم استفاده می گردد.

۴- داده ها

برای تصویربرداری از پهپاد فانتوم ۴ مجهز به دوربین DJI با فاصله کانونی ۸/۸ میلی متر از منطقه یزد استفاده شده است. در حین پرواز تعداد ۱۴۸ تصویر همراه با مختصات های زمینی مراکز تصویر جمع آوری شده است به طوری که ارتفاع متوسط سطح زمین حدود ۱۲۲۰ متر از سطح دریا، ارتفاع پرواز متوسط ۶۵ متر بالای زمین، میانگین ارتفاع ساختمان ها در این منطقه حدود ۶/۵ متر بالای زمین، پوشش طولی و عرضی میان تصاویر به ترتیب حدود ۸۰ و ۷۰ درصد، ابعاد پیکسل دوربین حدود ۲/۵ میکرومتر با ابعاد ۳۶۴۸×۴۸۶۴ پیکسل و ابعاد زمینی هر پیکسل (GSD) حدود ۱/۹ سانتیمتر بوده است (نگاره ۴-الف).

سرشکنی بلوک با بهره گیری از ۹ نقطه کنترل زمینی (۵ نقطه کنترل و ۴ نقطه چک) که به طور همگن در سراسر بلوک پخش شده اند انجام شده است (نگاره ۴-ب).



نگاره ۴: بلوک تصاویر و پهپاد مورد استفاده


محاسبات SfM از طریق نرم افزار ورژن ۱,۷,۱ (Agisoft, 2021) صورت گرفت و بدین وسیله ابرنقاط با تراکم کم و پارامترهای توجیه داخلی و خارجی دوربین با استفاده از نقاط کنترل محاسبه شدند. با استفاده از این مقادیر تصاویر بدون اعوجاج محاسبه شده و از آن ها برای تهیه ابرنقطه متراکم با استفاده از فرآیند SGM استفاده شد؛ سپس یکی از تصاویر با ساختمان هایی که با شماره های ۱ تا ۴ مشخص شده است برای انجام آزمایش ها و تهیه تصاویر قائم انتخاب شد (نگاره ۵).

1- Triangulated Irregular Network



نگاره ۵: تصویر موردنظر جهت تهیه تصویر قائم و ساختمان‌های انتخاب شده جهت ارزیابی روش‌های تهیه تصویر قائم

برای استفاده شبکه آموزش دیده Snowflakenet بر روی داده واقعی لازم است تا ابرنقاط سقف ساختمان‌ها طوری تهیه گردند که بیشترین شباهت را با داده‌های آموزشی (مکعب مستطیل پنج وجه) داشته باشند. به این ترتیب ابتدا می‌بایست تنها ابرنقاط صحیح و بدون نقاط نویز از تنها سقف و اشیای واقع بر روی آن در اختیار قرار گیرد. در نگاره ۷، نمونه‌ای از این ابرنقاط ساختمان نمایش داده شده است.



نگاره ۷: نمونه‌ای از ابرنقاط سقف ساختمان


همان‌طور که در نگاره ۷ دیده می‌شود بخش‌هایی از دیواره لبه ساختمان ناقص هستند. برای تکمیل این ابرنقطه توسط شبکه از پیش آموزش دیده لازم است تا آن به فرم استاندارد و مشابه ابرهای نقاطی که شبکه با آن آموزش

۵- پیاده‌سازی و نتایج

۵-۱- استفاده از شبکه یادگیری عمیق در تکمیل ابرنقاط

شبکه snowflakenet بر روی ۸۰۰۰ فایل ابرنقاط با اشکال چندوجهی قائم‌الزاویه سه‌بعدی در ۷۷ اپک آموزش داده شد و سپس به تعداد ۳۰ مرتبه بر روی ۱۰۰۰۰ فایل ابرنقاط با اشکال چندوجهی قائم‌الزاویه سه‌بعدی باز (بدون ضلع بالایی) (نگاره ۶) آموزش دید. شبکه آموزش دیده نهایی بر روی ۱۰۰ داده ابرنقاط تست و ارزیابی شد که در این آزمایش مقدار متوسط تابع هزینه ChamferDistance برای هر مرحله از تکمیل ابرنقاط معادل ۰/۰۰۷۲، ۰/۰۰۷۹۱، ۰/۰۰۷۹۱ و ۰/۰۰۷۹۱ به دست آمده است.


نگاره ۶، نمونه‌ای از ارزیابی شبکه آموزش دیده بر روی داده تست را نشان می‌دهد که در آن ابرنقطه ناقص (۶- الف) به ابرنقاط (۶- ب) تکمیل شده است.




(الف)

(ب)

نگاره ۶: (الف) نمونه‌ای از تکمیل ابرنقاط ناقص، (ب) ابرنقاط کامل




(الف)



(ب)

نگاره ۹: (الف) ساخت دیواره لبه و کاهش مجموعه نقاط به تعداد ۲۰۴۸ نقطه، (ب) ابرنقاط کامل حاصل از شبکه

مدل ابرنقاط کامل شده با استفاده از ضرایب معادله افاین که پیش‌تر از ارتباط میان ابرنقاط ناقص در مختصات واقعی با ابرنقاط نرمالایز شده به‌دست‌آمده به مختصات واقعی تبدیل شدند. نگاره ۱۰ پر شدن قسمت‌های خالی دیواره سقف را توسط ابرنقاط کامل شده نمایش می‌دهد.



(الف)



(ب)


نگاره ۱۰: پر شدن نواحی خالی در دیواره با اضافه کردن ابرنقاط تکمیل‌شده: (الف) ابرنقاط ناقص اولیه، (ب) ابرنقاط نهایی تکمیل‌شده

دیده است تبدیل شود. بنابراین لازم است تا ابرنقاطی تنها از سطح صاف بدون عوارض سقف ساختمان و دیوارهای جان‌پناه بدون وجود عوارض دیگر همانند لوله‌ها و دودکش‌ها و به تعداد ۲۰۴۸ نقطه تهیه شوند. بدین منظور با تعریف میانه ارتفاع برای هر یک از ابرنقاط، کلیه نقاط قرارگرفته با ارتفاع بیشتر از ارتفاع سقف از جمله اشیاء و دیواره‌ها کشف و بر روی سقف نگاشت می‌شوند.

نقاط محیطی سطح به‌دست‌آمده با الگوریتم α shape شناسایی و ارتفاع آن‌ها با ارتفاعشان از ابرنقطه اولیه جایگزین می‌شود (نگاره ۸-الف). با فرض توزیع نرمال ارتفاع نقاط لبه و با به دست آوردن مقدار ارتفاع میانی، نقاط با انحراف معیار بزرگ کشف و حذف می‌شوند (نگاره ۸-ب).




(الف)



(ب)

نگاره ۸: حذف نقاط اضافه دیواره سقف، (الف) دیواره‌ها دارای نقاط اضافی و نویز، (ب) دیواره‌ها بعد از حذف نقاط اضافی و نویز

سپس جهت ساخت نقاط دیواره هر لبه، نقاطی به‌طور عمودی به فواصل منظم ۱۰ سانتیمتر از کف سقف تا انتهای هر نقطه لبه اضافه گردید. در ادامه تعداد کل نقاط با الگوریتم Poisson disk sampling به تعداد ۲۰۴۸ نقطه با توزیع یکنواخت کاهش پیدا کرد و بعد از نرمال و مقارن شدن داده در بازه مشابه داده‌های آموزشی (۰/۵ و -۰/۵) به شبکه از پیش آموزش‌دیده snowflakenet معرفی شد (نگاره ۹). نگاره ۹: (ب) ابرنقاط کامل شده حاصل از شبکه را نمایش می‌دهد.



(الف) (ب)

نگاره ۱۰: تأثیر اضافه نمودن نقاط لبه سقف در بهبود درونیابی و تولید مدل رقومی سطح (اضافه شدن مثلث‌های کوچک‌تر): (الف) مدل رقومی سطح اولیه، (ب) مدل رقومی سطح تکمیل‌شده با اضافه شدن نقاط لبه بیرونی دیوار جان‌پناه



(الف) (ب)

نگاره ۱۱: تأثیر به‌کارگیری روش پیشنهادی در تصویر قائم: (الف) تصویر قائم تهیه‌شده بروش متداول، (ب) تصویر قائم تهیه‌شده به روش پیشنهادی


در ادامه تأثیر به‌کارگیری روش پیشنهادی بر روی چهار ساختمان نگاره ۵ در تهیه تصویر قائم در مقایسه با روش‌های برگزیده پیشین (Ebrahimikia & Hosseininaveh, 2022)، روش تهیه تصویر قائم بطریق متداول و روش تهیه تصویر قائم با اضافه نمودن دستی نقاط بررسی‌شده است. همان‌طور که مشخص است اگرچه در روش پیشین اعوجاج‌های لبه برای تمامی ساختمان‌ها تا حدود زیادی نسبت به روش متداول کاهش‌یافته است اما این میزان

۵-۲- انجام تصحیحات بر روی ابرنقاط تکمیل‌شده:

تغییر مقیاس ابرنقاط تکمیل‌شده به مقیاس واقعی موجب کاهش بیشتر تراکم نقاط آن در فضای حقیقی می‌شود در ادامه نقاط دیواره‌های دور سقف از ابرنقاط تکمیل‌شده خروجی شبکه جدا و بعد از افزایش تراکم نقاط به روش درونیابی به ابرنقاط حذف‌نویز شده موجود برای تهیه مدل ارتفاعی رقومی و تهیه تصویر قائم اضافه می‌گردند (نگاره ۱۰ - ب).


نگاره ۱۱ مدل رقومی سطحی حاصل از ابرنقاط قبل و بعد از تکمیل با روش پیشنهادی را نشان می‌دهد در نگاره ۱۳ تصویر قائم حاصل از این مدل ارتفاعی را نشان می‌دهد. همان‌طور که در نگاره ۱۲ مشاهده می‌شود اضافه شدن ابرنقاط لبه سقف سبب فرم‌دهی واقعی‌تر این نواحی در DSM شده است.

تأثیر اضافه شدن نقاط لبه به ابرنقاط موجود سبب کوچک شدن مثلث‌های مدل سطحی و دقیق‌تر شدن درونیابی در این نواحی می‌شود (نگاره ۱۲) همچنین در تصویر قائم حاصل نیز تأثیر به‌کارگیری نقاط لبه در تهیه DSM با کاهش اثر اعوجاج‌ها مشاهده می‌شود (نگاره ۱۳).



(الف) (ب)


نگاره ۱۲: تأثیر اضافه نمودن نقاط لبه سقف در تشکیل مدل ارتفاعی رقومی: (الف) مدل رقومی سطح اولیه، (ب) مدل رقومی سطح تکمیل‌شده با اضافه شدن نقاط لبه از طریق روش پیشنهادی



نگاره ۱۴: تصویر قائم تهیه شده با استفاده از روش‌های (الف) روش متداول، (ب) روش برگزیده پیشین (Ebrahimikia & Hosseiniaveh, 2022)، (ج) روش پیشنهادی و (د) روش بر اساس اضافه نمودن دستی نقاط لبه به ابرنقاط هر یک از ساختمان‌های ۱ تا ۴ از نگاره ۵.

استفاده از انتخاب خط اتصال ۱ بهینه این مشکل در موزاییک تصاویر قائم حل شده است (نگاره ۱۵)
نگاره ۱۶ نتایج کمی اعمال الگوریتم‌ها در کاهش اعوجاج‌ها در یک ضلع مستقیم از هر ساختمان را نشان می‌دهد به‌طوری که هرچقدر نقاط لبه انطباق بیشتری با

اعوجاج در روش پیشنهادی از بهبود قابل توجهی برخوردار شده به‌طوری که به تصاویر قائم حاصل از به‌کارگیری اضافه نمودن نقاط لبه به‌طور دستی بسیار شباهت دارد (نگاره ۱۴).
نواحی پنهان در تصاویر سبب ایجاد خطای کشیدگی و پدیده دوگانگی می‌شوند که این تأثیر در ساختمان‌های ۲ و ۳ به‌وضوح دیده می‌شود با انتخاب دیگر تصاویر قائم با




نگاره ۱۵: تأثیر استفاده از هر یک از روش‌ها در تهیه موزاییک تصاویر قائم: (الف) روش متداول، (ب) روش برگزیده پیشین (Ebrahimikia & Hosseininaveh, 2022)، (ج) روش پیشنهادی و (د) روش بر اساس اضافه نمودن دستی نقاط لبه به ابرنقاط

نقاط اشتباه به‌طور تکراری حذف شدند. این فرآیند تا زمانی که انحراف معیار به مقدار $0/5$ برسد یا تعداد نقاط باقیمانده ثابت باقی بماند ادامه یافت و در نهایت نقاط باقیمانده به‌عنوان نقاطی که بیشترین تطابق را با خط مستقیم داشتند حفظ شدند (نقاط قرمز رنگ در نمودارهای نگاره ۱۶).

از آنجا که ممکن است اضافه کردن نقاط سه‌بعدی لبه به ابرنقاط جهت تشکیل مدل رقومی سطح در هریک از روش‌های تهیه تصویر قائم صحت موقعیت مکانی این نواحی را به سبب خطاهای محاسباتی موجود تحت تأثیر قرار دهد آزمایش دیگری انجام شد که در آن تغییرات مکانی خطوط لبه بر روی تصاویر قائم بررسی می‌شود. همچنین تصاویر قائمی که از اضافه نمودن نقاط به طریق دستی به ابرنقاط محاسبه شده‌اند (نگاره ۱۶ ستون د) به‌عنوان تصاویر مرجع در نظر گرفته شدند. بدین منظور میزان فاصله میان هر پیکسل از لبه انتخاب شده (نگاره ۱۶ ستون و) در هریک از تصاویر قائم ساختمان‌های ۱ تا ۴ که با هر یک از روش‌های متداول، روش برگزیده پیشین (Ebrahimikia &

خطوط مستقیم داشته باشند تعداد نقاط نویزی کاهش بیشتری داشته است. برای انجام این آزمایش، تصویر نقاط لبه با اعمال الگوریتم Canny (Canny, 1986) بر روی تصاویر قائم محاسبه شد سپس نقاط لبه مرتبط با خط مدنظر برای هریک از ساختمان‌ها انتخاب و استخراج شدند. جهت تعیین لبه‌ها به‌وسیله اپراتور Canny علاوه بر درجات خاکستری پیکسل‌ها، حداقل و حداکثر مقادیر حد آستانه و ابعاد کرنل سوبل می‌بایست معلوم باشند. مقدار حداقل حد آستانه در حدود $0/4$ حد آستانه حداکثری است که بر اساس آزمایش و خطا مقدار بهینه آن تعیین می‌شود. ابعاد کرنل سوبل نیز که برای محاسبه مقادیر تغییرات درجات خاکستری استفاده می‌شود در این آزمایش برابر با سه مقداردهی شد.

بر روی نقاط لبه‌ای که برای هر ساختمان انتخاب و استخراج شدند خط مستقیمی بروش کمترین مربعات برازش داده و فاصله تمامی نقاط از آن محاسبه شد سپس با در نظر گرفتن سطح اطمینان ۹۹ درصد نقاطی که خطایشان از $2/5$ برابر انحراف معیار به‌دست آمده بیشتر بود به‌عنوان




نگاره ۱۶: میزان اثرگذاری هر یک از روش‌های تهیه تصویر قائم در کاهش اعوجاج نقاط لبه (کاهش نقاط نویزی) در هریک از ساختمان‌های ۱ تا ۴، (الف) روش متداول، (ب) روش برگزیده پیشین (Ebrahimikia & Hosseininaveh, 2022)، (ج) روش پیشنهادی (د) روش بر اساس اضافه نمودن دستی نقاط لبه به ابرنقاط، (ه) لبه انتخابی در هر ساختمان

و دقت مدل ارتفاعی رقومی به‌طور مستقیم بر روی تصویر قائم حاصل از آن تأثیرگذار است استفاده از مدل ارتفاعی رقومی صحیح‌تر موجب بهبود این تصاویر می‌شود (نگاره ۱۳). در مقایسه با روش‌های پیشین، در روش پیشنهادی این ابرنقاط توسط روش یادگیری عمیق تکمیل می‌شود و مقایسه کمی و کیفی در نگاره‌ها ۱۴ و ۱۶ نتایج بهتری در کاهش اعوجاج در اکثر ساختمان‌های مورد آزمایش نشان می‌دهد. تعیین و محاسبه کامل‌تر و یکپارچه‌تر فرم سقف هر ساختمان بجای پاره‌خط‌های متعدد و لحاظ شدن بیرونی‌ترین لبه‌ها در ساختار الگوریتم ازجمله دلایل برتری روش پیشنهادی نسبت به روش‌های پیشین است. هرچند با توجه به اتفاقی بودن نتایج حاصل از شبکه‌های هوش مصنوعی این روند یکسان نبوده و در بعضی اشکال دقت

(Hosseininaveh, 2022) و روش پیشنهادی به‌دست آمده‌اند با موقعیت متناظر آن در تصاویر مرجع محاسبه شده است به‌طوری که محورهای افقی نمایانگر موقعیت پیکسل‌ها و محور قائم بیانگر فاصله این پیکسل‌ها از موقعیت نظیرشان روی تصویر قائم مرجع است (نگاره ۱۷).

۶- بحث

کمبود نقاط لبه ساختاری هر سقف که حدفاصل میان اختلاف‌های ارتفاعی شدید میان سطوح است سبب بیشترین میزان اعوجاج بر روی لبه سقف‌ها و اطراف آن می‌شود. اضافه نمودن این نقاط با الگوریتم‌های تشخیص و بازسازی خطوط لبه به ابرنقاط موجب بهبود مدل ارتفاعی رقومی حاصل از آن می‌شود (نگاره ۱۲). از آنجاکه کیفیت



نگاره ۱۷: نمودارهای نمایش اختلاف مکانی میان لبه انتخاب شده روی هر یک از تصاویر قائم در ساختمان‌های ۱ تا ۴ نسبت به همان لبه روی تصویر قائمی که ابرنقاط آن به طریق دستی با اضافه نمودن نقاط بهبود داده شده‌اند (محورهای افقی موقعیت نقاط لبه و محورهای عمودی فاصله دو لبه متناظر را نشان می‌دهند): (الف) روش متداول، (ب) روش برگزیده پیشین (Ebrahimikia & Hosseininaveh, 2022) و (ج) روش پیشنهادی

بالاتر و در بعضی دیگر خطاهای ناگهانی را موجب می‌شود (نگاره ۱۷). به طور مثال میزان خطای مکانی در ساختمان ۱ از نگاره ۱۷ دارای خطای بزرگ ناگهانی است که به طور واضح ناشی از بروز خطا در محاسبه لبه ساختاری و اضافه نشدن لبه در موقعیت صحیح در تهیه ابرنقاط و DSM است؛ اما میزان کاهش نقاط نویز و کاهش میزان خطای مکانی در تمامی ساختمان‌ها در روش پیشنهادی مشاهده می‌شود (نگاره‌های ۱۶ و ۱۷). به لحاظ وجود نواحی پنهان در تصاویر بخش‌هایی از تصاویر قائم ساختمان‌های ۲ و ۳ دارای کشیدگی و دوگانگی هستند که جهت جبران آن از تصاویر قائم همپوشان مجاور برای جبران و تصحیح این نواحی در موزاییک تصویری استفاده شده است (نگاره ۱۵).

نکاتی که می‌تواند سبب بهبود الگوریتم پیشنهادی شود شامل موارد زیر است:

- ۱- بهبود شبکه یادگیری عمیق در افزایش دقت نتایج، سرعت بیشتر در یادگیری و حفظ جزئیات هندسی اشکال.
- ۲- افزایش داده‌های آموزشی به انواع حالت‌های سقف‌ها با دیواره‌های منحنی.

۸- منابع و مآخذ

- 1- Agisoft, 2021. Agisoft PhotoScan User Manual: Professional Edition, Version 1.7. Agisoft LLC, St Petersburg, Russia. 187 pages.
- 2- Barazzetti, L., Brumana, R., Oreni, D., Previtali, M., & Roncoroni, F. (2014). True-orthophoto generation from UAV images: implementation of a combined photogrammetric and computer vision approach. *ISPRS Annals of Photogrammetry, Remote Sensing & Spatial Information Sciences*, 2(5).
- 3- Boccardo, P., Dequal, S., Lingua, A., & Rinaudo, F. (2001). True digital orthophoto for architectural and archaeological applications. *INTERNATIONAL ARCHIVES OF PHOTOGRAMMETRY AND REMOTE SENSING*, 34(5/W1), 50-55.
- 4- Canny, J. (1986). A computational approach to edge detection. *IEEE transactions on pattern analysis and machine intelligence*(6), 679-698.
- 5- Chang, Y., Jung, C., & Xu, Y. (2021). FinerPCN: High fidelity point cloud completion network using pointwise convolution. *Neurocomputing*, 460, 266-276.
- 6- Chen, X., Chen, B., & Mitra, N. J. (2019). Unpaired point cloud completion on real scans using adversarial training. *arXiv preprint arXiv:1904.00069*.
- 7- Chen, Y., Briese, C., Karel, W., & Pfeifer, N. (2014). True orthophoto generation using multi-view aerial images. *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 40(3), 67.
- 8- Chibane, J., Mir, A., & Pons-Moll, G. (2020). Neural unsigned distance fields for implicit function learning. *arXiv preprint arXiv:2010.13938*.
- 9- Czerniawski, T., Ma, J. W., & Leite, F. (2021).

آموزش شبکه عمیق مورد استفاده تنها بر روی سقف‌هایی با اشکال منظم و مستقیم صورت گرفته است و بنابراین قادر به بازسازی خطوط لبه منحنی در ساختمان ۳ نبوده است. گرچه انتخاب تصاویر قائم و محل قرارگیری عوارض در آن‌ها نسبت به مراکز تصویر می‌تواند اثر کمبود نقاط را با کم شدن نیاز به انجام تصحیحات خطای ناشی از ارتفاع کاهش دهد اما استفاده از الگوریتم‌های به کار رفته در تهیه تصاویر قائم در موزاییک آن‌ها نیز مؤثر است. همان‌طور که در نگاره ۱۵ مشاهده می‌شود به‌غیر از لبه‌های مستقیم که از اعوجاج کمتری در روش پیشنهادی برخوردارند شکل نواحی منحنی به‌خوبی حفظ نشده‌اند که با افزایش آموزش شبکه به این‌گونه فرم‌های ساختاری می‌توان به بهبود آن امیدوار بود.

۷- نتیجه‌گیری و پیشنهادها

در این مطالعه روش جدیدی در بهبود تضاريس لبه‌های تصویر قائم حقیقی با به‌کارگیری شبکه یادگیری عمیق در تکمیل ابرنقاط تعریف شد و بر روی چندین ساختمان از یک تصویر هوایی منتخب آزمایش و با نتایج حاصل از روش‌های پیشین مقایسه شد. در مقایسه با روش پیشین میزان اعوجاج بر روی لبه انتخابی از ۴ ساختمان به‌طور میانگین به میزان ۶۲ درصد و نسبت به روش متداول به‌طور میانگین به میزان ۸۱ درصد کاهش داشته است. همچنین علاوه بر کاهش میزان اعوجاج، با بررسی مقادیر انحراف معیار حاصل از نمودارهای نگاره ۱۷، خطای موقعیت لبه بر روی تصاویر قائم حاصل از روش پیشنهادی نسبت به تصاویر قائم حاصل از روش پیشین به‌طور میانگین میزان ۵۵ درصد و نسبت به روش متداول حدود ۶۱ درصد کاهش داشته است و به‌طور میانگین کمتر از یک پیکسل است. علیرغم کاهش میزان اعوجاج روی لبه ساختاری انتخابی با استفاده از روش پیشنهادی این مقدار در نواحی منحنی و همچنین گوشه‌های سقف‌ها به علت نوع آموزش شبکه و خطای خروجی شبکه افزایشی است.

photos: na.

20- Krauss, T., & Reinartz, P. (2010). Urban object detection using a fusion approach of dense urban digital surface models and VHR optical satellite stereo data.

21- Li, C.-L., Zaheer, M., Zhang, Y., Poczós, B., & Salakhutdinov, R. (2018). Point cloud gan. arXiv preprint arXiv:1810.05795.

22- Liu, M., Sheng, L., Yang, S., Shao, J., & Hu, S.-M. (2020). Morphing and sampling network for dense point cloud completion. Paper presented at the Proceedings of the AAAI conference on artificial intelligence.

23- Mohammadi, H., Samadzadegan, F., & Reinartz, P. (2019). 2D/3D information fusion for building extraction from high-resolution satellite stereo images using kernel graph cuts. *International Journal of Remote Sensing*, 40(15), 5835-5860. doi:10.1080/01431161.2019.1584417

24- Nielsen, M. Ø. (2004). True orthophoto generation: Informatik og Matematisk Modellering, Danmarks Tekniske Universitet.

25- Noronha, S., & Nevatia, R. (2001). Detection and modeling of buildings from multiple aerial images. *IEEE transactions on pattern analysis and machine intelligence*, 23(5), 501-518.

26- Qi, C. R., Su, H., Mo, K., & Guibas, L. J. (2017). Pointnet: Deep learning on point sets for 3d classification and segmentation. Paper presented at the Proceedings of the IEEE conference on computer vision and pattern recognition.

27- Qin, C., You, H., Wang, L., Kuo, C.-C. J., & Fu, Y. (2019). Pointdan: A multi-scale 3d domain adaption network for point cloud representation. arXiv preprint arXiv:1911.02744.

28- Sarmad, M., Lee, H. J., & Kim, Y. M. (2019). Rl-gan-net: A reinforcement learning agent controlled gan network for real-time point cloud shape completion. Paper presented at the Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition.

29- Siddiqui, F. U., Teng, S. W., Awrangjeb, M., & Lu, G. (2016). A Robust Gradient Based Method for Building Extraction from LiDAR and Photogrammetric Imagery. *Sensors*, 16, 1110.

Automated building change detection with amodal completion of point clouds. *Automation in Construction*, 124, 103568.

10- Dai, A., Diller, C., & Nießner, M. (2020). Sg-nn: Sparse generative neural networks for self-supervised scene completion of rgb-d scans. Paper presented at the Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition.

11- Dai, A., Ruizhongtai Qi, C., & Nießner, M. (2017). Shape completion using 3d-encoder-predictor cnns and shape synthesis. Paper presented at the Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition.

12- Dunbar, D., & Humphreys, G. (2006). A spatial data structure for fast Poisson-disk sample generation. *ACM Transactions on Graphics (TOG)*, 25(3), 503-508.

13- Ebrahimikia, M., & Hosseininaveh, A. (2022). True Orthophoto Generation Based on Unmanned Aerial Vehicle Images Using Reconstructed Edge Points. *The Photogrammetric Record*.

14- Gkioxari, G., Malik, J., & Johnson, J. (2019). Mesh r-cnn. Paper presented at the Proceedings of the IEEE/CVF International Conference on Computer Vision.

15- Groueix, T., Fisher, M., Kim, V., Russell, B., & Aubry, M. (2020). AtlasNet: A Papier-Mâché Approach to Learning 3D Surface Generation. arXiv 2018. arXiv preprint arXiv:1802.05384.

16- Hirschmuller, H. (2008). Stereo processing by semiglobal matching and mutual information. *IEEE Trans Pattern Anal Mach Intell*, 30(2), 328-341. doi:10.1109/TPAMI.2007.1166

17- Hou, J., Dai, A., & Nießner, M. (2020). Revealnet: Seeing behind objects in rgb-d scans. Paper presented at the Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition.

18- Huang, Z., Yu, Y., Xu, J., Ni, F., & Le, X. (2020). Pf-net: Point fractal network for 3d point cloud completion. Paper presented at the Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition.

19- Kato, A., Moskal, L., Schiess, P., Calhoun, D., & Swanson, M. E. (2010). True orthophoto creation through fusion of LiDAR derived digital surface model and aerial

Skip-Transformer. arXiv preprint arXiv:2108.04444.

40- Yang, Y., Feng, C., Shen, Y., & Tian, D. (2018). Foldingnet: Point cloud auto-encoder via deep grid deformation. Paper presented at the Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition.

41- Yu, L., Li, X., Fu, C.-W., Cohen-Or, D., & Heng, P.-A. (2018). Pu-net: Point cloud upsampling network. Paper presented at the Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition.

42- Yuan, W., Khot, T., Held, D., Mertz, C., & Hebert, M. (2018). Pcn: Point completion network. Paper presented at the 2018 International Conference on 3D Vision (3DV).

43- Zhang, Y., Liu, Z., Li, X., & Zang, Y. (2019). Data-Driven Point cloud objects completion. *Sensors*, 19(7), 1514.

30- Tchapmi, L. P., Kosaraju, V., Rezafofighi, H., Reid, I., & Savarese, S. (2019). Topnet: Structural point cloud decoder. Paper presented at the Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition.

31- Venkatesh, R., Karmali, T., Sharma, S., Ghosh, A., Jeni, L. A., Babu, R. V., & Singh, M. (2021). Deep Implicit Surface Point Prediction Networks. arXiv preprint arXiv:2106.05779.

32- Wang, N., Zhang, Y., Li, Z., Fu, Y., Liu, W., & Jiang, Y.-G. (2018). Pixel2mesh: Generating 3d mesh models from single rgb images. Paper presented at the Proceedings of the European Conference on Computer Vision (ECCV).

33- Wang, Q., Yan, L., Sun, Y., Cui, X., Mortimer, H., & Li, Y. (2018). True orthophoto generation using line segment matches. *The Photogrammetric Record*, 33(161), 113-130.

34- Wang, X., Ang Jr, M. H., & Lee, G. H. (2020). Cascaded refinement network for point cloud completion. Paper presented at the Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition.

35- Wang, X., Jin, Y., Cen, Y., Wang, T., & Li, Y. (2021). Attention Models for Point Clouds in Deep Learning: A Survey. arXiv preprint arXiv:2102.10788.

36- Wei, S. (2008). Building boundary extraction based on lidar point clouds data. *Proceedings of the International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 37, 157-161.

37- Widyaningrum, E., Lindenbergh, R., Gorte, B., & Zhou, K. (2018). Extraction of building roof edges from LiDAR data to optimize the digital surface model for true orthophoto generation. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 42, 2.

38- Wu, J., Jie, S., Yao, W., & Stilla, U. (2011). Building boundary improvement for true orthophoto generation by fusing airborne LiDAR data. Paper presented at the Urban Remote Sensing Event (JURSE), 2011 Joint.

39- Xiang, P., Wen, X., Liu, Y.-S., Cao, Y.-P., Wan, P., Zheng, W., & Han, Z. (2021). SnowflakeNet: Point Cloud Completion by Snowflake Point Deconvolution with