

## استخراج مدل رقومی سطح با استفاده از تک تصویر ماهواره‌ای با حد تفکیک بالا و مدل رقومی جهانی *SRTM* بر مبنای یادگیری عمیق

حامد امینی امیرکلانی<sup>۱</sup>، حسین عارفی<sup>۲\*</sup>

۱- دانشجوی دکتری فتوگرامتری دانشکده مهندسی نقشه برداری و اطلاعات مکانی - پردیس دانشکده‌های فنی - دانشگاه تهران  
۲- استادیار دانشکده مهندسی نقشه برداری و اطلاعات مکانی، پردیس دانشکده‌های فنی، دانشگاه تهران

تاریخ دریافت مقاله: ۱۳۹۷/۱۱/۰۸ تاریخ پذیرش مقاله: ۱۳۹۸/۰۱/۲۱

### چکیده

مدل رقومی سطح (*DSM*) از جمله مهم‌ترین محصولات در حوزه فتوگرامتری و سنجش‌ازدور می‌باشد و کاربردهای متنوعی در این حوزه دارد. تکنیک‌های موجود به بیش از یک تصویر برای استخراج *DSM* نیاز دارند و در این مقاله سعی شده است امکان استخراج *DSM* از تک تصویر ماهواره‌ای آنالیز و بررسی شود. در این راستا، یک الگوریتم بر مبنای شبکه‌های عصبی کانولوشنی عمیق طراحی شد. در الگوریتم پیشنهادی ابتدا پیش پردازش‌هایی نظیر تقسیم تصاویر ماهواره به تصاویر کوچک‌تر، محلی‌سازی مقادیر ارتفاعی و تقویت داده‌های آموزشی برای آماده‌سازی داده‌ها برای ورود به شبکه انجام می‌شود. شبکه عصبی کانولوشنی (*CNN*) پیشنهادی دارای ساختاری کدگذار-کدگشا می‌باشد که در مرحله کدگذاری ویژگی‌های مختلف و کارآمد در مقیاس‌های متفاوت استخراج شده و در مرحله کدگشایی و با ارائه روندی کارآمد، ویژگی‌های تولیدشده برای تخمین مقادیر ارتفاعی با یکدیگر تلفیق می‌گردند. سپس با ارائه یک الگوریتم پیکسل‌های زمینی و غیرزمینی از هم تفکیک شده و مقادیر ارتفاعی عوارض غیرزمینی استخراج می‌شوند. با اضافه نمودن عوارض غیرزمینی به همراه اطلاعات ارتفاعی به مدل رقومی ارتفاعی ماموریت توپوگرافی رادار شاتل (*SRTM*) با ابعاد پیکسل زمینی ۳۰ متر، *DSM* نهایی بدست می‌آید. الگوریتم پیشنهادی با استفاده از تصاویر ماهواره‌ای و *DSM*‌های متناظر آن‌ها ارزیابی شد. با ارزیابی تصاویر ارتفاعی کوچک تخمین زده شده توسط شبکه *CNN* پیشنهادی به طور متوسط مقادیر ۰٫۹۲۱، ۰٫۲۲۱ و ۲٫۹۵۶ متر به ترتیب برای خطای میانگین نسبی ( $E_R$ )، خطای میانگین لگاریتم ( $E_L$ )، ریشه جذر میانگین مربعات ( $E_{RMSE}$ ) حاصل شد. همچنین با ارزیابی *DSM*‌های یکپارچه نهایی ایجاد شده به طور متوسط مقدار ۴٫۶۲۵ متر به ترتیب برای  $E_{RMSE}$  بدست آمد.

کلیدواژه‌ها: مدل سطحی رقومی، شبکه عصبی کانولوشنی، تک تصویر ماهواره‌ای، مدل رقومی ارتفاعی *SRTM*.

\*نویسنده مکاتبه کننده: تهران، امیرآباد شمالی، دانشکده فنی، دانشکده مهندسی نقشه برداری و اطلاعات مکانی

تلفن: ۰۲۳۳-۲۳۰۲۵۹

## ۱- مقدمه

فواصل متفاوتی نسبت به یک مشاهده کننده قرار دارند، می‌توانند تصویر یکسانی برای مشاهده‌کننده ایجاد نمایند. روش شکل از سایه روشن<sup>۷</sup> را می‌توان به عنوان یک روش استخراج بعد سوم از تک تصویر در نظر گرفت که دارای عملکردی قابل قبول است [۱۵]. این روش به صورت محدود برای استخراج مقادیر ارتفاعی از تصاویر ماهواره‌ای نیز استفاده شده است، اما بیشتر برای استخراج مدل‌های رقومی کلی برای مناطق وسیع با دقت کم کارایی داشته است [۱۶] و [۱۷]. چرا که تنها استفاده از خصوصیات سایه بدون در نظر گرفتن ویژگی‌های دیگر موجود در تصویر نمی‌تواند برای دستیابی به مدل‌های سه‌بعدی دقیق مناسب باشد.

انسان به صورت ذاتی از دوچشم جهت اخذ آنی تصویر و تعیین فاصله بهره می‌برد. درعین حال از توانایی تخمین ساختار محیط حتی از طریق دید تک‌چشمی و با استفاده از تک عکس نیز بهره‌مند است که ناشی از آموزش مغز در طول زمان و با بررسی و استنتاج اطلاعات مختلف تصویری می‌باشد. از این‌رو جهت حل مساله تخمین عمق از تک تصویر در حوزه پردازش تصویر و به‌صورت محاسباتی نیاز است که نحوه عملکرد سیستم بینایی انسان به‌صورت دقیق بررسی شده و دانش حاصل از این بررسی‌ها با استفاده از سخت‌افزارها و نرم‌افزارهای کامپیوتری پیاده‌سازی شود [۱۸]. قشر بصری چشم انسان از المان‌های هادی<sup>۸</sup> در دید استریو و تک‌چشمی<sup>۹</sup> برای تخمین عمق نسبی صحنه استفاده می‌نماید. در واقع زمانی که دید استریو در دسترس نباشد (برای مثال هنگام مشاهده یک تصویر و یا دچار نقص بینایی شدن) مستقیماً از المان‌های هادی تک‌چشمی برای استنتاج و تفسیر عمق از صحنه استفاده می‌شود [۱۹]. به‌طور کلی، در مغز انسان ساختار و هندسه یک صحنه از طریق تحلیل ویژگی‌های آن صحنه نظیر عوارض خطی، اندازه نسبی اشیاء، سایه و غیره در راستای پاسخ به این سؤال که کدام عارضه نزدیک‌تر بوده و یا در جلوی

استخراج مقادیر ارتفاعی از تصویر یکی از موضوعات پرچالش و حائز اهمیت است که منجر به تولید مدل سطحی زمین (DSM<sup>۱</sup>) به عنوان یکی از محصولات بسیار مهم در فتوگرامتری و سنجش از دور می‌گردد. DSM را می‌توان یکی از اجزای مهم جهت انجام پروژه‌های مختلفی نظیر کلاسه‌بندی [۱]، قطعه‌بندی [۲]، بازسازی سه‌بعدی [۳، ۴]، آنالیز صحنه [۵]، شناسایی تغییرات<sup>۲</sup> [۶] و به روزرسانی پایگاه‌های سیستم اطلاعات مکانی [۷] در حوزه فتوگرامتری و سنجش از دور دانست. همانطور که مشخص است، تصاویر رقومی معمولاً یک محیط سه‌بعدی را در دو بعد به نمایش درمی‌آورند. رایج‌ترین روش برای محاسبه مقادیر بعد سوم از تصاویر، بهره‌گیری از تکنیک استریو می‌باشد که از زوج تصویر اخذ شده در زوایای مختلف از یک صحنه برای انجام مثلث‌بندی و تعیین موقعیت سه‌بعدی پیکسل‌ها استفاده می‌نماید [۸]. گروهی دیگر از روش‌ها نظیر ساختار از حرکت<sup>۳</sup> و شکل از فوکوس<sup>۴</sup> از تصاویر تک منظر<sup>۵</sup> یا به عبارت دیگر تصاویر اخذ شده از یک موقعیت ثابت برای محاسبه بعد سوم بهره می‌برند [۹]. این روش‌ها تک تصویر نبوده و تنها موقعیت تصویر برداری ثابت شده است. در واقع از تصاویر اخذ شده از یک نقطه ثابت که حاوی تغییراتی در موقعیت اشیاء و یا فوکوس دوربین می‌باشند، برای استخراج بعد سوم استفاده می‌شود. بازایی اطلاعات سه‌بعدی تنها با استفاده از تک‌تصویر فرایندی بسیار پیچیده و از لحاظ ریاضیاتی بدوضع<sup>۶</sup> است [۱۰، ۱۱، ۱۲ و ۱۳]. در واقع تصویر کردن مقادیر درجه خاکستری یا رنگی به اطلاعات سه‌بعدی دارای یک ابهام ذاتی است؛ چرا که هیچ رابطه مستدل و دقیقی بین داده‌های رنگ و شدت هر پیکسل و ارتفاع آن از تصویر وجود ندارد [۱۴]. برای مثال تعدادی عارضه با شکل یکسان و اندازه‌های مختلف که در

<sup>1</sup> Digital Surface Model (DSM)

<sup>2</sup> Change detection

<sup>3</sup> Structure from motion

<sup>4</sup> Shape from focusing

<sup>5</sup> Single view

<sup>6</sup> Ill-posed

<sup>7</sup> Shape from shading

<sup>8</sup> Cue

<sup>9</sup> Monocular

بررسی تغییرات ارتفاعی ناشی از عوارضی نظیر ساختمان‌ها و درختان را فراهم نمی‌سازد. در تحقیق حاضر تلاش شده است که با ارائه یک شبکه عمیق قدرتمند، یک *DSM* با جزئیات بالا تنها با از تک‌تصویر ماهواره‌ای تخمین زده شود. در این راستا، ابتدا با استخراج ویژگی‌های سطح بالا<sup>۸</sup>، ساختار کلی منطقه بازسازی گشته و سپس با استفاده از ویژگی‌های سطح پایین<sup>۹</sup>، مقادیر ارتفاعی عوارض کوچک‌تر موجود و جزئیات در منطقه مطالعاتی تخمین زده می‌شوند. لازم به ذکر است که ویژگی‌های سطح پایین به ویژگی‌های استخراج شده از لایه‌های اولیه و کم‌عمق و ویژگی‌های سطح بالا به ویژگی‌های استخراج شده از لایه‌های عمیق در یک شبکه *CNN* گفته می‌شود. در نهایت با ارائه روندی کارآمد عوارض غیرزمینی و اطلاعات ارتفاعی آن‌ها استخراج شده و با بهره‌گیری از مدل رقومی ارتفاعی *SRTM*، یک *DSM* یکپارچه و دقیق برای تصویر ماهواره‌ای بدست آید. در ادامه ساختار مقاله به این صورت است که در بخش ۲ مروری بر مطالعات انجام‌شده در حوزه استخراج تخمین مقادیر ارتفاعی و عمق از تک‌تصویر ارائه شده است. سپس در بخش ۳ شرح مختصری از ساختار شبکه‌های عمیق *CNN* بیان شده و سپس روش پیشنهادی به‌طور کامل در بخش ۴ شرح داده شده است. در بخش ۵، روند پیشنهادی پیاده‌سازی گشته و مورد ارزیابی قرار می‌گیرد و در نهایت در بخش ۶ نتیجه‌گیری و پیشنهادات آتی ارائه می‌شوند.

## ۲- پیشنهادی تحقیق

تحقیقات صورت گرفته در زمینه استخراج بعد سوم را می‌توان در دو گروه روش‌های استخراج عمق از تک‌تصویر که مربوط به تصاویر در حوزه بینایی ماشین هستند و روش‌های تخمین ارتفاع از تک‌تصویر که مربوط به تصاویر در حوزه فتوگرامتری و سنجش از دور هستند، تقسیم نمود.

### ۲-۱- تخمین مقادیر عمق از تک‌تصویر

روش‌های استخراج بعد سوم عمدتاً در حوزه بینایی ماشین و جهت تخمین عمق از تصاویر اخذشده در

دیگر عوارض قرار گرفته است، استنتاج می‌گردد. بازسازی ساختار هندسی یک صحنه از تک‌تصویر نیز بسیار پرکاربرد بوده و می‌تواند در زمینه‌های مختلفی نظیر شناسایی مرز نواحی پنهان، قطعه‌بندی صفحات ارتفاعی و استفاده به‌عنوان قدم اول جهت دستیابی به نقشه کامل ارتفاعی مفید فایده باشد. به‌طورکلی، استفاده از ویژگی‌های خاص و یا محلی موجود در یک تصویر جهت تخمین بعد سوم بسیار ناکافی است و در کنار اطلاعات محلی نیاز به داشتن اطلاعاتی از ساختار کلی تصویر است. شبکه‌های عصبی کانوولوشنی (*CNN*)<sup>۱</sup> به‌عنوان گروهی از الگوریتم‌های یادگیری عمیق<sup>۲</sup>، دارای توانایی مهندسی ویژگی<sup>۳</sup> و استخراج اطلاعات در سطوح و مقیاس‌های مختلف از تصویر می‌باشند [۲۰]. به‌طوری‌که به‌تدریج ابعاد لایه‌های ویژگی کوچک شده و تعداد لایه‌های ویژگی استخراج‌شده افزایش می‌یابد [۲۰]. ایجاد یک ارتباط متوازن و دقیق بین خصوصیات محلی استخراج‌شده از لایه‌های کم‌عمق<sup>۴</sup> و خصوصیات کلی استخراج‌شده از لایه‌های عمیق<sup>۵</sup> یک صحنه می‌تواند به بازسازی هرچه بهتر مدل سه‌بعدی آن صحنه کمک شایان توجهی نماید [۲۱].

ماموریت توپوگرافی رادار شاتل<sup>۶</sup> (*SRTM*) یک پروژه تحقیقاتی جهانی در سال ۲۰۰۰ برای بدست آوردن مدل ارتفاعی رقومی<sup>۷</sup> (*DEM*) از سطح زمین با دقت مناسب بین مدارهای ۶۰ درجه شمالی و ۵۶ درجه جنوبی است. قدرت تفکیک مکانی مدل‌های ارتفاعی *SRTM*، یک ثانیه قوسی یا ۳۰ متر است که ابتدا تنها امریکا به این قدرت تفکیک دسترسی داشت، اما امروزه امکان دانلود داده‌های ارتفاعی با دقت ۳۰ متر برای همه قابل دسترس است. به‌طورکلی، قدرت تفکیک ۳۰ متر می‌تواند یک ساختار کلی از ناهمواری‌های زمین در اختیار کاربر قرار داده و امکان

<sup>1</sup> Convolutional neural network

<sup>2</sup> Deep learning

<sup>3</sup> Feature engineering

<sup>4</sup> Shallow layers

<sup>5</sup> Deep layers

<sup>6</sup> Shuttle Radar Topography Mission

<sup>7</sup> Digital Elevation Model

<sup>8</sup> High-level

<sup>9</sup> Low-level

سلسله‌مراتبی، استخراج عمق در سه سطح محلی، میانی و کلی بوده است.

## ۲-۱-۲- روش‌های مبتنی بر یادگیری عمیق

در این روش‌ها به جای تولید ویژگی با شیوه‌های مختلف و به صورت دستی، با ارائه ساختارهای متنوع سعی شده است که ویژگی‌های مناسب و کارآمد در داخل شبکه تولید شوند. اساس روش‌های مبتنی بر یادگیری عمیق طراحی یک شبکه کانولوشنی و قراردادن لایه‌های مختلف شبکه جهت دستیابی به بهترین دقت می‌باشد. در این راستا، روش‌های مختلفی ارائه شده است که در ادامه به صورت مختصر به آن‌ها پرداخته می‌شود. ایجن و همکاران (۲۰۱۴)، روشی شامل دو بخش اصلی پیشنهاد نمودند. به طوری که ابتدا با استفاده از یک شبکه اولیه یک پیش‌بینی کلی از عمق صحنه بدست آمده و سپس با استفاده از یک شبکه بهبوددهنده مقادیر عمق به صورت محلی بهبود داده شدند [۱۱]. هر دو شبکه از تصویر اولیه به عنوان ورودی استفاده نموده و خروجی تخمین اولیه به عنوان ورودی تخمین دقیق نیز استفاده گشت. هدف طراحی شبکه بهبوددهنده، تنظیم پارامترهای تخمین اولیه با جزئیات محلی بوده است که این کار با طراحی شبکه‌ای با لایه‌های کانولوشن و یک لایه ادغام صورت پذیرفت. ژانگ و همکاران (۲۰۱۸)، یک شبکه سلسله‌مراتبی ارائه نمودند که در آن سعی شد ویژگی‌های محلی و جزئیات موجود در صحنه به صورت تدریجی در روند تخمین عمق و طی گذر از لایه‌های کدگشایی<sup>۳</sup> بازیابی شوند. در این راستا، از المان‌های مختلف هندسی در سطوح مختلف شبکه جهت تنظیم پارامترها طی روند آموزش استفاده شده است. از نرم  $L2$  به عنوان المان هندسی در سطح پیکسل، از نرم  $L1$  گرادیان، نرم  $L2$  گرادیان و گرادیان عملگر سو بل به عنوان المان هندسی در سطح ناحیه و از کوواریانس دوطرفه به عنوان تنظیم‌کننده ثبات کلی در شبکه استفاده شده است [۲۱]. هی و وانگ (۲۰۱۸) سعی نمودند که ابهام بین فاصله کانونی و تخمین عمق از تک‌تصویر را حل نمایند. در این راستا، الگوریتمی جهت تولید تصاویری با فاصله کانونی‌های متفاوت با

محیط‌های شهری بوده است. این روش‌ها را می‌توان در دو گروه روش‌های مبتنی بر مدل‌های گرافیکی و روش‌های مبتنی بر یادگیری عمیق تقسیم نمود.

## ۲-۱-۱- روش‌های مبتنی بر مدل‌های گرافیکی

در این روش‌ها تولید ویژگی‌های مناسب نقش مهمی در نتایج حاصله دارد. در این روش‌ها با ایجاد یک مجموعه داده آموزشی براساس ویژگی‌های مختلف تصویر و بهره‌گیری از الگوریتم‌های میدان تصادفی شرطی<sup>۱</sup> و مارکوفی<sup>۲</sup> مقادیر عمق از تصاویر رنگی استخراج می‌شوند. محققان روش‌های مختلفی را برای استخراج ویژگی از تک‌تصویر و استفاده از آن در تخمین مقادیر عمق مطرح نموده‌اند. به طوری که، ساکسنا و همکاران (۲۰۰۶)، از یک روش نظارت‌شده برای تخمین عمق استفاده نمودند. به طوری که، ابتدا تصویر به قطعات کوچک تقسیم شده و برای هر قطعه یک عمق محاسبه گردید. برای استخراج ویژگی در هر مقیاس از قطعات مجاور قطعه موردنظر نیز استفاده شد که این کار سبب در نظر گرفتن همسایگی نزدیک و همسایگی دور گردید. در نهایت برای هر قطعه یک بردار ویژگی تشکیل شد که حاوی اطلاعات کارآمدی برای تخمین عمق بود. از دو مدل احتمال گوسین و لاپلاسین میدان تصادفی مارکوفی برای مدل‌سازی با بهره‌گیری از بردارهای ویژگی تشکیل شده، استفاده شد که مدل لاپلاسین جواب بهتری داشت [۱۳، ۲۲]. لیو و همکاران (۲۰۱۴)، مساله استخراج عمق از تک‌تصویر را به صورت یک مساله بهینه‌سازی گسسته-پیوسته در نظر گرفتند و برای حل آن از الگوریتم میدان تصادفی شرطی استفاده نمودند. به طوری که متغیرهای پیوسته عمق را در سوپرپیکسل‌ها محاسبه کرده و متغیرهای گسسته رابطه بین سوپرپیکسل‌های همسایه را نشان دادند [۲۳]. ژو و همکاران (۲۰۱۵) یک مدل سلسله‌مراتبی برای استخراج عمق مطرح نمود. در این مدل از الگوریتم میدان تصادفی شرطی جهت تعیین رابطه بین لایه‌های مختلف در طی سلسله‌مراتب استفاده شد. منظور از تخمین عمق

<sup>1</sup> Conditional random field

<sup>2</sup> Markov random field

<sup>3</sup> Decoding

کدگذاری<sup>۵</sup> به آخرین لایه کدگشایی جهت بهبود عملکرد شبکه در لبه ساختمان‌ها بهره گرفته شد [۲۶]. قمیسی و همکاران (۲۰۱۸)، از یک شبکه عمیق مولد شرطی تقابلی<sup>۶</sup> که دارای یک معماری کدگذار-کدگشا به همراه اتصالات جهشی است برای شبیه‌سازی مقادیر ارتفاعی از تصاویر هوایی بهره برد. در ارزیابی‌ها مشخص شد که استفاده از DSM تولید شده در این روش می‌تواند در افزایش دقت کلاسه‌بندی عوارض بسیار کمک‌کننده باشد [۲۷]. امینی‌امیرکلانی و عارفی (۲۰۱۹)، روندی بر مبنای یادگیری عمیق برای استخراج مقادیر ارتفاعی از تک‌تصویر هوایی ارائه دادند که در آن ابتدا طی یک روند پیش‌پردازش، لبه‌های موجود در تصویر تقویت شدند. سپس یک شبکه CNN با ساختاری U ارائه گشت که در آن با بهره‌گیری از اتصالات جهشی سعی شد که از جزئیات موجود در لایه‌های کم‌عمق در روند تخمین ارتفاع دوباره استفاده شود. سپس با آموزش شبکه CNN مطرح شده، مقادیر ارتفاعی تصاویر ورودی محاسبه گشت. در نهایت با ارائه یک روند پس‌پردازش، تصاویر ارتفاعی تخمین زده شده به یکدیگر متصل شده و یک سطح ارتفاعی پیوسته ایجاد شد [۲۸]. امینی‌امیرکلانی و عارفی (۲۰۱۹)، با تغییر و بهبود روند اتصال تصاویر ارتفاعی تخمین زده شده (در مقایسه با روش مطرح شده در [۲۸]) سعی نمودند که مدل‌های ارتفاعی نهایی ایجاد شده، به شکل بهتری ناهمواری‌های سطح زمین را نمایش دهند. همچنین آن‌ها با بررسی سناریوهای متفاوت در پیاده‌سازی و بهره‌گیری از تصاویر متنوع زمینی، هوایی و ماهواره‌ای عملکرد شبکه را در شرایط مختلف آنالیز نمودند [۲۹].

### ۲-۳- نوآوری تحقیق

در تحقیق پیش‌رو نیز با ارائه یک شبکه عمیق CNN به تخمین مقادیر ارتفاعی پرداخته شده است. در شبکه پیشنهاد شده، برخلاف برخی شبکه‌ها که تنها در لایه آخر از اتصالات جهشی استفاده نموده‌اند [۲۶]، در تمامی سطوح کدگشایی استفاده بهره گرفته شد.

استفاده از تصاویر با فاصله کانونی ثابت پیشنهاد نمودند. سپس یک شبکه کدگذار-کدگشا با توانایی آموزش جهت تخمین عمق با رزولوشن مناسب از تک تصویر از طریق تلفیق اطلاعات سطوح میانی را ارائه نمودند. در نهایت با بهره‌گیری از اطلاعات فاصله کانونی مربوط به تصاویر تولیدشده با فواصل کانونی متغیر جهت بهبود تصاویر عمق تخمین زده شده، استفاده شد. لی و همکاران (۲۰۱۸)، یک چهارچوب عمیق بر اساس تورم کانولوشن و استفاده از ساختار شبکه ResNet ارائه نمود که توانایی توزیع احتمال در میان برجسب‌های عمق را دارد. در شبکه مذکور برای کاهش تعداد پارامترها، لایه‌های تماماً متصل حذف گشتند. اپراتور تورم کانولوشن امکان گسترش ناحیه پذیرش<sup>۱</sup> را بدون افزایش تعداد پارامترها فراهم می‌نماید. به علاوه با استفاده از این اپراتور نیاز به اپراتور ادغام<sup>۲</sup> بدون کاهش ابعاد زمینه پذیرش و از دست دادن رزولوشن مکانی، از بین می‌رود. برای استفاده از اطلاعات محلی نقشه‌های ویژگی لایه‌های میانی، این لایه‌ها مستقیماً به لایه نهایی نقشه ویژگی الحاق شدند [۲۴].

### ۲-۲- تخمین مقادیر ارتفاع از تک‌تصویر

در چند سال اخیر تحقیقات محدودی در زمینه استخراج مقادیر ارتفاعی از تک‌تصویر در حوزه فتوگرامتری و سنجش‌ازدور صورت گرفته است که تمام آن‌ها به دلیل قدرت بالای الگوریتم‌های یادگیری عمیق از این الگوریتم‌ها در این زمینه استفاده نموده‌اند. سربواستاوا و همکاران (۲۰۱۷)، از یک ساختار CNN برای کلاسه‌بندی و همین‌طور تخمین مدل رقومی سطحی نرمال شده ( $nDSM^3$ ) از تصاویر هوایی استفاده نمود [۲۵]. مو و همکاران (۲۰۱۸)، یک شبکه برای تخمین مقادیر ارتفاعی از تصاویر سنجش‌ازدور ارائه نمودند. در این روش از DSM حاصل از سنجنده لایدار و تصاویر سنجش‌ازدور جهت آموزش شبکه استفاده شده است. همچنین از یک اتصال جهشی<sup>۴</sup> بین یکی از لایه‌های کم‌عمق در

<sup>1</sup> Receptive field

<sup>2</sup> Pooling

<sup>3</sup> normalize Digital Surface Model

<sup>4</sup> Skip connection

<sup>5</sup> Encoding

<sup>6</sup> Conditional generative adversarial

چیزی جز ضرب نقطه‌ای بین ورودی و پارامترهای هر نورون و نهایتاً اعمال عملیات کانولوشن در هر لایه نیست و تا خروجی شبکه محاسبه شود. به منظور تنظیم پارامترهای شبکه، خروجی شبکه با استفاده از یک تابع اتلاف با داده مرجع مقایسه گشته و بدین ترتیب میزان خطا محاسبه می‌شود. در مرحله بعد بر اساس میزان خطای محاسبه شده مرحله پس‌انتشار آغاز می‌شود که در آن گرادیانت هر پارامتر با توجه به قانون زنجیره‌ای محاسبه شده و تمامی پارامترها با توجه به تأثیری که بر خطای ایجاد شده در شبکه دارند، تغییر می‌یابند. پس از چند تکرار جواب نهایی شبکه بدست آمده و شبکه پایان می‌یابد. در ادامه مؤلفه‌های اصلی *CNN* به صورت خلاصه توضیح داده شده‌اند.

**لایه کانولوشن:** لایه کانولوشن هسته اصلی تشکیل‌دهنده *CNN* است و هر لایه آن از تعدادی فیلتر یا کرنل ساخته شده که شامل وزن‌ها و یک بایاس می‌باشد. این عملگر اطلاعات و ویژگی‌های مختلفی از داده ورودی که می‌تواند تصویر ورودی و یا خروجی لایه قبل باشد، استخراج می‌نماید. مکانیزم اشتراک وزن در عملگرهای کانولوشن تعداد پارامترها را کاهش و سرعت آموزش را افزایش می‌دهد [۳۱].

**لایه ادغام:** این لایه معمولاً بعد از لایه کانولوشن قرار می‌گیرد و از آن برای تغییر اندازه نقشه‌های ویژگی استفاده می‌شود. استفاده از تابع ماکزیمم در این لایه‌ها سبب همگرایی سریع‌تر، تعمیم بهتر و انتخاب ویژگی‌های نامتغیر بسیار عالی می‌شود [۳۲].

**لایه تماماً متصل<sup>۳</sup>:** این لایه‌ها معمولاً آخرین لایه‌های یک شبکه را تشکیل می‌دهند که یک نقشه ویژگی را به یک بردار ویژگی تبدیل می‌نماید. لایه‌های تماماً متصل همانند هم‌تایان خود در شبکه‌های عصبی مصنوعی سنتی عمل کرده و تقریباً ۹۰٪ پارامترهای یک شبکه *CNN* را شامل می‌شوند [۳۳]. مشکل بزرگ این نوع لایه‌ها این است که دارای تعداد بسیار زیادی پارامتر بوده و این امر هزینه پردازشی بسیار بالایی نیاز دارد [۳۳].

همچنین به جای استفاده از لایه‌های درون‌یابی در روند کدگشایی که سبب افزایش تعداد پارامترها و کاهش سرعت آموزش می‌گردد [۲۶، ۲۸ و ۲۹]، از اعمال چند کانولوشن با ابعاد متفاوت و سپس تجمیع آن‌ها بهره گرفته شد. در شبکه‌های مطرح شده در [۸۲ و ۲۹]، الگوریتم‌هایی برای اتصال تصاویر ارتفاعی تخمین زده شده و ایجاد مدل ارتفاعی پیوسته پیشنهاد شده است که این روش‌ها عمدتاً در مناطق کوچک با شیب ملایم عملکرد مناسبی داشته و در صورت وسعت بالا و ناهمواری زیاد منطقه مطالعاتی عملکرد ضعیفی دارند. چراکه محدوده کوچک تصاویر موردپذیرش در شبکه‌های *CNN* سبب می‌گردد که شیب سطح زمین در تصاویر مذکور به خوبی در شبکه مدل‌سازی نشود و شبکه نسبت به شیب کلی منطقه به درستی آموزش نبیند. به عبارت دیگر در محدوده‌های کوچک شیب کلی سطح زمین قابل تشخیص و مدل‌سازی دقیق نمی‌باشد. از این رو در این مقاله با ارائه رویکردی متفاوت و بهره‌گیری از مدل رقومی جهانی *SRTM* و همین‌طور ارائه روشی برای تفکیک نقاط زمینی و غیرزمینی در تصاویر تخمین زده شده سعی شد تا روندی کارآمد برای ایجاد مدل‌های رقومی ارتفاعی پیوسته حتی در صورت وسعت زیاد و ناهمواری شدید منطقه ارائه شود.

### ۳- شبکه‌های عمیق *CNN*

شبکه‌های *CNN* از مهم‌ترین و رایج‌ترین روش‌های یادگیری عمیق هستند و دارای الگوریتم‌های آموزشی پایدار می‌باشند که امکان یادگیری نمایش‌های تصویری را بدون نیاز به طراحی و تولید دستی ویژگی‌ها فراهم می‌نمایند. عملکرد این شبکه‌ها همانند تمام الگوریتم‌های شناسایی بسیار وابسته به داده‌های آموزشی است؛ اما به دلیل عملکرد موفق آن‌ها در مقابل داده‌های حجیم و بزرگ مقیاس نسبت به دیگر الگوریتم‌ها بسیار مورد توجه کارشناسان قرار گرفته است [۳۰]. در هر شبکه *CNN* دو مرحله پیش‌رونده<sup>۱</sup> و پس‌انتشار<sup>۲</sup> برای آموزش وجود دارد. در مرحله اول تصویر ورودی به شبکه تغذیه می‌شود و این عمل

<sup>1</sup> Feed forward

<sup>2</sup> Back propagation

<sup>3</sup> Fully connected

در مرحله کدگذاری به تدریج ابعاد ماتریس نقشه‌های ویژگی تولیدشده کاهش یافته و تعداد ویژگی‌های تولیدشده (عمق ماتریس) افزایش می‌یابد. افزایش عمق در شبکه‌های *CNN* با قرار دادن لایه‌های کانولوشن صورت می‌پذیرد. اما، بدون در نظر گرفتن راهکاری مناسب و تنها با قرار دادن لایه‌ها به صورت پیاپی، شبکه با مشکل صفر شدن گرادیان<sup>۶</sup> در مرحله پس‌انتشار و عدم افزایش دقت شبکه مواجه می‌گردد. در معماری *ResNet*، نگاشت باقیمانده جهت حل مساله صفر شدن تدریجی گرادیان ارائه شده است. اگر نگاشت  $H(x)$  در نظر گرفته شود، چند لایه پیاپی یک نگاشت  $F(x) = H(x) - x$  انجام داده و در نهایت با بهره‌گیری یک اتصال جهشی نتایج بدست آمده با مقدار  $x$  جمع می‌گردند  $(F(x) + x)$ . به عبارت دیگر در نگاشت باقیمانده، مقادیر خروجی پیش از نگاشت با نتایج خروجی نگاشت جمع می‌گردند [۳۸]. به این ترتیب امکان افزایش عمق و همراه افزایش دقت فراهم می‌شود. مرحله کدگذاری به تعدادی لایه تماماً متصل منتهی می‌شود که تعداد آن‌ها متناسب با اهداف مورد نظر جهت شناسایی تعیین می‌شوند. در نتیجه می‌توان گفت که شبکه‌هایی که تنها دارای مرحله کدگذاری هستند، برای اهدافی نظیر قطعه‌بندی و کلاسه‌بندی که منطقه را به تعدادی کلاس محدود تقسیم می‌نمایند، مناسب‌اند.

اهدافی نظیر تخمین مقادیر عمق و ارتفاعی که هر پیکسل مقداری مجزا داشته و هدف به تعدادی کلاس محدود نمی‌شود، از ساختار کدگشایی در شبکه استفاده می‌شود که در آن از روش‌هایی برای افزایش ابعاد نقشه‌های ویژگی استفاده می‌شود. از روش‌های رایج در این زمینه می‌توان به عملگرهای معکوس کانولوشن و ادغام اشاره کرد [۳۹ و ۴۰]. در این روش‌ها به دلیل استفاده از پیش‌فرض‌های اولیه عملکرد مناسبی در نهایت حاصل نمی‌شود. به طوری که در عملگر معکوس کانولوشن تنظیم پارامترهای عملگر شبکه برای دستیابی به جوابی مناسب دشوار است و سبب جابجایی در موقعیت و همین‌طور ساختار هندسی عوارض در تصویر می‌شود. در روش معکوس

**توابع غیرخطی:** توابع غیرخطی به منظور مدل‌سازی روند فعال‌سازی نورن‌هایی خاص و جدا نمودن داده‌هایی است که به صورت خطی قابل جداسازی نمی‌باشند. توابع سیگموئید، تانژانت هیپربولیک و واحد خطی اصلاح شده ( $ReLU^1$ ) از جمله توابع رایج در این زمینه می‌باشند که تابع *ReLU* کارآمدترین تابع در شبکه‌های *CNN* می‌باشد [۳۴]. نحوه عملکرد این تابع به این صورت است که با اعمال آن مقادیر منفی صفر شده و مقادیر مثبت را بدون تغییر نگه داشته می‌شوند. ساختار ساده آن سبب کاهش هزینه محاسباتی و افزایش چشمگیر سرعت همگرایی می‌شود [۳۵].

**لایه نرمال‌سازی دسته‌ای<sup>۲</sup>:** این لایه‌ها سبب یکسان‌سازی محدوده داده‌ها و افزایش سرعت پردازش می‌گردد. نرمال‌سازی دسته‌ای سبب می‌شود مقدار شیفت کوواریانس کاهش یابد و هر لایه مقداری مستقل‌تر عمل نماید. شیفت کوواریانس زمانی به وجود می‌آید که شبکه با مقادیر  $x$  و  $y$  آموزش می‌بیند و پراکندگی  $x$  تغییر می‌یابد و برای اصلاح آن باید از پراکندگی  $y$  استفاده نمود. نرمال‌سازی داده‌های با اطمینان حاصل کردن از این‌که هیچ مقداری در تابع فعال‌سازی مقداری بسیار بزرگ یا بسیار کوچک ندارد، سبب می‌شود که بتوان مقادیر بزرگ‌تری برای نرخ آموزش<sup>۳</sup> در نظر گرفت که منجر به افزایش سرعت همگرایی می‌گردد [۳۶].

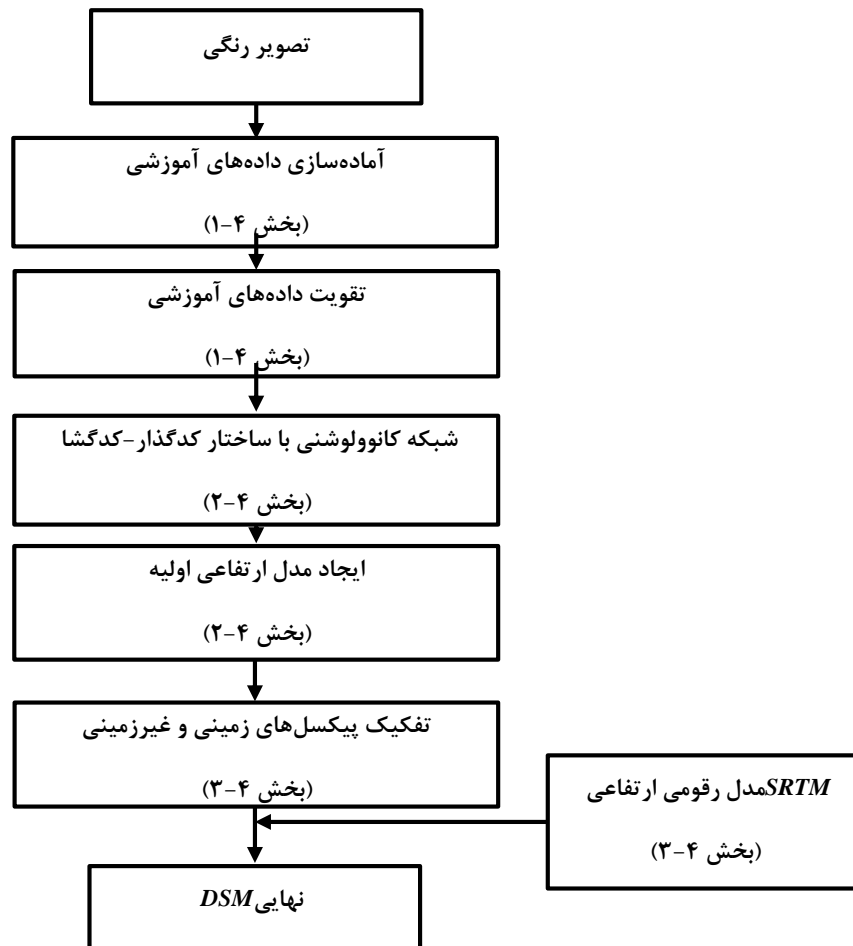
**لایه حذف تصادفی<sup>۴</sup>:** لایه حذف تصادفی به منظور جلوگیری از بیش‌برازش<sup>۵</sup> در شبکه‌های عصبی معرفی شد و نحوه کار آن به این صورت است که در هر مرحله از آموزش، هر نورون یا با احتمال  $1-p$  (از شبکه) بیرون انداخته شده و یا با احتمال  $p$  نگه داشته می‌شود، به طوری که نهایتاً یک شبکه کاهش داده شده باقی بماند [۳۷]. لازم به ذکر است که شبکه‌های *CNN* می‌توانند تنها دارای ساختار کدگذاری باشند و یا علاوه بر آن دارای ساختار کدگشایی نیز باشند.

<sup>1</sup> Rectified Linear Unit<sup>2</sup> Batch normalization<sup>3</sup> Learning rate<sup>4</sup> Drop out<sup>5</sup> Overfitting<sup>6</sup> Vanishing gradient

#### ۴- روش پیشنهادی

در این بخش روند پیشنهادی برای استخراج *DSM* از تک تصویر ماهواره‌ای به صورت کامل شرح داده شده است. در شکل (۱) مراحل روند پیشنهادی نشان داده شده است. ساختار کلی روش پیشنهادی به این صورت است که ابتدا پردازش‌هایی برای آماده‌سازی و تقویت داده‌های آموزشی صورت می‌پذیرد. سپس از داده‌های آموزشی برای آموزش شبکه *CNN* طراحی شده، استفاده می‌گردد. در مرحله بعد شبکه کانولوشنی آموزش دیده برای تخمین تصاویر ارتفاعی اولیه به کار گرفته شده و با ارائه یک الگوریتم، پیکسل‌های زمینی و غیرزمینی در تصاویر ارتفاعی تخمین زده شده از یکدیگر تفکیک می‌شوند. در نهایت با اضافه نمودن مقادیر ارتفاعی پیکسل‌های غیرزمینی در تصاویر ارتفاعی تخمین زده شده به مدل رقومی جهانی *SRTM*، مدل ارتفاعی نهایی بدست می‌آید.


ادغام، پس از دوبرابر شدن ابعاد ماتریس ورودی پیکسل‌های بدست آمده از تصویر به صورت قراردادی مقدار گرفته و مابقی صفر می‌شوند [۴۱]. در واقع حدود ۷۵ درصد از پیکسل‌های به وجود آمده صفر هستند که نشان از بیهوده بودن حجم زیادی از محاسبات می‌باشد که برای از بین بردن مقادیر از عملگر کانولوشن و اعمال آن به تصویر استفاده می‌شود. برای جلوگیری از انتخاب قراردادی پیکسل برای مقداردهی، از ساختارهای متقارن در شبکه‌های عمیق استفاده می‌شود. به این صورت که به ازای هر عملگر ادغام در مرحله کدگذاری یک عملگر معکوس ادغام در مرحله کدگشایی استفاده می‌شود. مکان‌هایی که طی اعمال عملگر ادغام انتخاب شده‌اند، در مرحله معکوس ادغام برای مقداردهی استفاده می‌شوند [۳۹].



شکل ۱: روند کلی الگوریتم پیشنهادی



و سپس وارد شبکه شوند. از طرفی، اگر تصویر کل منطقه مطالعاتی با انجام درون‌یابی به ابعاد مورد پذیرش در شبکه تبدیل شوند، اطلاعات زیادی از دست رفته و تصویر نامفهومی حاصل می‌شود که امکان بازیابی مقادیر ارتفاعی را از بین می‌برد. در نتیجه تصاویر ماهواره‌ای باید به تصاویر کوچک‌تری تقسیم شوند. به عبارت دیگر، به ازای هر تصویر متناسب با ابعاد آن، تعدادی تصویر کوچک‌تر ایجاد گشته و سپس با درون‌یابی، تصاویری با ابعاد مورد پذیرش در شبکه *CNN* تولید و مقادیر ارتفاعی آن‌ها محاسبه می‌شوند. در شکل (۲) نحوه تقسیم تصویر مطابق با ابعاد مورد قبول در شبکه آورده شده است.



شکل ۲: روند تقسیم تصاویر رقومی که محدوده زیادی را پوشش می‌دهند به تصاویر کوچک‌تر متناسب با ابعاد مورد قبول در شبکه *CNN*

ندارد. در نتیجه می‌توان گفت که میزان تعمیم‌پذیری شبکه کاهش می‌یابد. جهت حل این مسأله مقادیر ارتفاعی در هر تصویر بریده شده با کسر از کمینه ارتفاع در آن منطقه به صورت محلی درآمد. این کار سبب می‌شود که مقادیر ارتفاعی ساختمان‌هایی دارای ساختار یکسان بوده و تغییرات ارتفاعی یکسانی در منطقه ایجاد می‌نمایند، به خوبی توسط شبکه شناسایی شده و مقادیر ارتفاعی آن‌ها تخمین زده شوند. در شبکه‌های عمیق *CNN* میلیون‌ها پارامتر وجود دارد که آموزش آن نیاز به مجموعه بزرگی از داده‌های آموزشی دارد تا مساله واگرا نشود. اما در اغلب موارد داده‌های آموزشی محدود بوده و برای جلوگیری از واگرا

در راستای شرح کامل روند پیشنهادی، در بخش ۴-۱، روندی برای پیش‌پردازش و آماده‌سازی داده‌ها برای ورود به شبکه ارائه می‌شود. در بخش ۴-۲، اجزای شبکه *CNN* پیشنهادی برای استخراج مقادیر ارتفاعی از تک تصویر به طور کامل توضیح داده می‌شود. در نهایت در بخش ۴-۳، روند پیشنهادی برای ایجاد *DSM* نهایی تشریح شده است.

#### ۴-۱- پیش‌پردازش و آماده‌سازی داده‌ها

از آنجاکه تصاویر فتوگرامتری و سنجش‌ازدور معمولاً منطقه وسیعی را پوشش داده و ابعادی بزرگی دارند، نمی‌توان این ابعاد از تصویر را به صورت مستقیم به شبکه‌های *CNN* وارد کرد. از این رو این تصاویر باید مطابق ابعاد ورودی مورد قبول در شبکه درون‌یابی شده

استفاده از داده‌های ارتفاعی با محدوده متغیر سبب عدم همگرایی مناسب شبکه می‌شود. به طوری که شبکه آموزش دیده نمی‌تواند مقادیر ارتفاعی را برای مناطقی که دارای محدوده ارتفاعی متفاوتی نسبت به داده‌های استفاده شده در روند آموزش می‌باشند را به خوبی تخمین بزند. برای مثال، دو ساختمان یکسان در دو منطقه با ارتفاع‌های ۲۰۰۰ متر و ۱۰ متر نسبت به سطح دریا، می‌توانند سبب تغییرات مقادیر ارتفاعی یکسانی در محیط باشند، اما شبکه عملکرد یکسانی در قبال آن‌ها ندارد. در واقع شبکه آموزش دیده با استفاده از داده‌های ارتفاعی منطقه با ارتفاع ۲۰۰۰ متر، دیگر قابلیت تخمین ارتفاع در منطقه با ارتفاع ۱۰ متر را

کدگشا<sup>۲</sup> است که پس از استخراج ویژگی در روند کدگذاری، یک روند کدگشایی برای بزرگ کردن ابعاد نقشه‌های ویژگی و به تدریج تبدیل آن‌ها به تصویر ارتفاعی را شامل می‌شوند. در شکل (۳) ساختار شبکه پیشنهادی نشان داده شده است.

#### ۴-۲-۱- مرحله کدگذاری

در مرحله کدگذاری به دلیل قدرت بالای شبکه عمیق باقیمانده (*ResNet*) از ساختار این شبکه بهره گرفته شده است. ساختار به کاررفته در مرحله کدگذاری دارای دو تفاوت عمده نسبت به شبکه استفاده *ResNet* است. تفاوت اول، حذف لایه تماماً متصل موجود در شبکه‌های *ResNet* است پارامترهای مربوط به لایه‌های تماماً متصل تقریباً ۹۰٪ پارامترهای یک شبکه *CNN* را شامل می‌شوند و در نتیجه حجم بسیار زیادی از محاسبات در شبکه‌های عمیق مربوط به استفاده از این لایه‌ها است. از این رو عدم استفاده از این لایه‌ها سبب کاهش چشمگیر حجم محاسبات و افزایش سرعت پردازش می‌گردند. از آن جا هدف تخمین مقادیر ارتفاعی برای هر پیکسل در تصویر است، اعمال مرحله کدگشایی بر روی ماتریس ویژگی مناسب‌تر از اعمال آن بر روی بردار ویژگی حاصل از لایه‌های تماماً متصل است.

تفاوت دوم مربوط به اضافه نمودن لایه کانولوشن به لایه‌های کم‌عمق در شبکه *ResNet* است. عملکرد بهتر در تخمین مقادیر ارتفاعی مربوط به عوارض کوچک ملزوم به داشتن اطلاعات محلی و جزئیات بیشتر است. لایه‌های کم‌عمق در شبکه‌های *CNN* حاوی اطلاعات محلی و ویژگی‌های دارای جزئیات بیشتر می‌باشند. از این رو استخراج ویژگی‌های بیشتر در لایه‌های کم‌عمق شبکه‌های *CNN* می‌تواند سبب بهبود عملکرد تخمین مقادیر ارتفاعی شود.

شدن شبکه از روش‌های تقویت داده<sup>۱</sup> استفاده می‌شود. به‌طور کلی تکنیک‌های تقویت داده با ایجاد مجموعه داده‌ای بزرگ‌تر با تولید داده‌های جدید و کاربردی به‌عنوان یک تنظیم‌کننده عمل نموده و روند همگرایی را سریع‌تر می‌نمایند؛ به‌طوری‌که سبب جلوگیری از بیش‌برازش داده‌ها شده و امکان عمومی‌سازی نتایج را بیشتر می‌نماید. این روش به‌صورت کلی شامل اعمال تبدیلاتی بر روی داده‌های یا ویژگی‌های و یا هر دو می‌باشد. رایج‌ترین روش افزایش مجازی داده در فضای داده‌ها صورت گرفته و نمونه‌های جدید با اعمال تبدیلات مختلفی نظیر انتقال، چرخش، مقیاس‌گذاری، تغییر فضای رنگی، برش و ... بر روی داده‌های موجود بدست می‌آیند. در تخمین ارتفاع از تک‌تصویر از روش‌های زیر جهت تقویت داده بهره گرفته شده است. دوران: تصاویر ورودی و داده‌های ارتفاعی مطابق عددی دلخواه به‌صورت تصادفی دوران می‌یابند.

انتقال: داده‌های ورودی و هدف به‌صورت تصادفی بریده‌شده و به ابعاد ورودی شبکه تغییر ابعاد داده می‌شود.

رنگ: باندهای تصویر رنگی ورودی و به‌صورت تصادفی در عددی دلخواه ضرب می‌شوند.

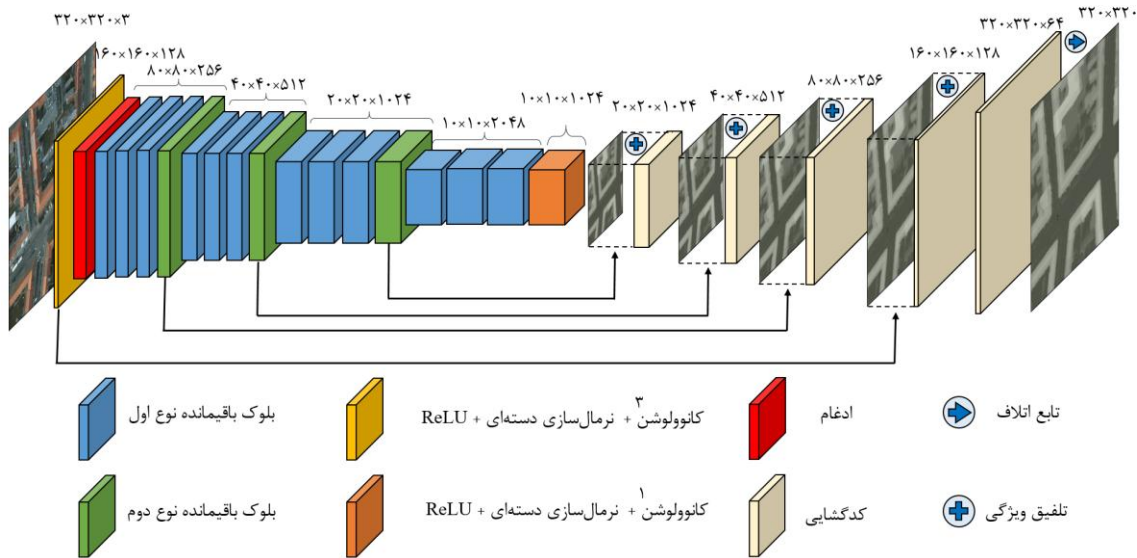
تصویر کردن: داده‌های ورودی و هدف به‌صورت افقی و عمودی و با احتمال ۰/۵ تصویر می‌شوند.

#### ۴-۲- شبکه *CNN* پیشنهادی

از آن جا که هدف رسیدن به تصویر ارتفاعی بوده و هر یک از پیکسل‌های تصویر ارتفاعی باید مقداری مجزا داشته باشد نمی‌توان با شبکه‌های رایج *CNN* که در نهایت به لایه‌های تماماً متصل می‌رسند به جواب مطلوب رسید. به‌عبارت‌دیگر، شبکه‌های رایج در کاربردهای شناسایی و کلاسه‌بندی که تصویر را به تعداد محدودی برچسب تقسیم می‌نمایند، عملکرد مناسبی در زمینه مطرح شده ندارند. از این رو شبکه *CNN* پیشنهادی دارای یک ساختار عمیق کدگذار-

<sup>2</sup> Encoder-decoder

<sup>1</sup> Data augmentation



شکل ۳: شبکه عمیق کدگذار-کدگشای پیشنهادی


ماتریس ویژگی نیز می‌گردد. در شکل (۴) دو بلوک نوع اول و دوم نمایش داده شده‌اند. در مرحله سوم نیز با اعمال سه بلوک از نوع دوم و یک بلوک از نوع اول، ویژگی‌های مختلفی استخراج می‌گردد (۴۰×۴۰×۵۱۲). در مرحله چهارم نیز به همین ترتیب، ضمن کاهش ابعاد ماتریس (۲۰×۲۰) و افزایش عمق (۱۰۲۴)، ویژگی‌های کلی‌تر موجود در سطوح بالاتر و قدرت تفکیک کمتر استخراج می‌شوند. در نهایت و پس از گذر از مرحله پنجم نقشه ویژگی با ابعاد ۱۰×۱۰×۲۰۴۸ حاصل می‌شود. لازم به ذکر است که در تمامی لایه‌ها تابع  $ReLU$  اعمال شده است؛ چراکه این تابع سبب افزایش چشمگیر سرعت همگرایی گرادینان تصادفی نسبت به توابع تانژانت هیپربولیک<sup>۱</sup> و سیگموئید<sup>۲</sup> می‌شود. به‌علاوه پیاده‌سازی بسیار ساده‌ای دارد تنها با یک آستانه‌گذاری بر روی یک ماتریس صورت می‌گیرد.

به‌طور کلی، ساختار شبکه در مرحله کدگذاری به این صورت است که ابتدا در صورتی که تصویر ورودی  $۳۲۰ \times ۳۲۰ \times ۳$  باشد، با اعمال یک لایه کانولوشن و سپس نرمال‌سازی لایه‌ها لایه‌های اصلی تشکیل‌دهنده شکل با جزئیات بالا شناسایی شده و یک ماتریس  $۱۶۰ \times ۱۶۰ \times ۱۲۸$  ایجاد می‌شود. در مرحله دوم، با اعمال یک لایه ادغام، سه بلوک باقیمانده نوع دوم و یک بلوک باقیمانده نوع اول ماتریس ویژگی با ابعاد  $۸۰ \times ۸۰ \times ۲۵۶$  تولید می‌شود.

بلوک باقیمانده نوع اول شامل دو شاخه کانولوشنی است که در شاخه اول آن طی اعمال سه مرحله کانولوشن به‌صورت پیاپی تمامی ویژگی‌های موجود در تصویر استخراج گشته و در شاخه دوم تنها یک مرحله کانولوشن به ماتریس‌ها اعمال، نتایج آن‌ها با یکدیگر تلفیق شده خروجی حاصل می‌گردد. به‌طور کلی سعی می‌گردد در بلوک باقیمانده نوع دوم، شاخه اول مشابه بلوک قبلی بوده، ولی در شاخه دوم آن هیچ تابع و لایه‌ای وجود ندارد. اعمال یک بلوک از نوع دوم به شبکه سبب افزایش عمق شبکه، استخراج خصوصیات بیشتر و حفظ ابعاد ماتریس ویژگی می‌گردد. در حالی که اعمال بلوک نوع اول هم‌زمان سبب کاهش ابعاد

<sup>1</sup> Hyperbolic

<sup>2</sup> Sigmoid



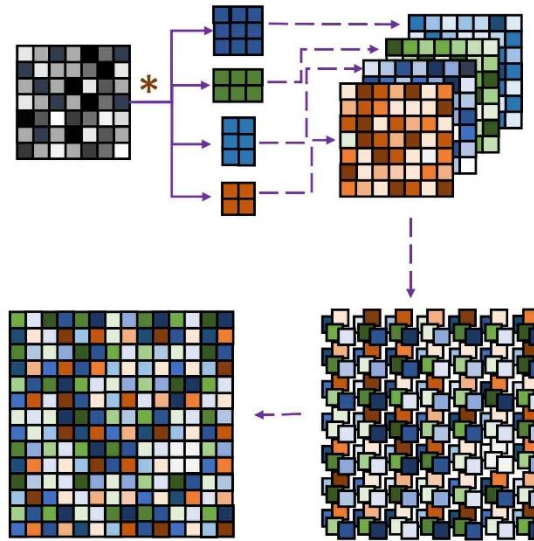
شکل ۴: ساختار بلوک‌های باقیمانده استفاده شده در مرحله کدگذاری، (الف) بلوک نوع اول، (ب) بلوک نوع دوم

کانوولوشن با ابعاد کوچک و همین‌طور عدم ایجاد ماتریس‌های بزرگ در طی روند پردازش که بیشتر پیکسل‌های آن‌ها دارای مقدار صفر می‌باشند، حجم محاسبات در شبکه کاهش یافته و سرعت پردازش افزایش می‌یابد. نحوه کنار هم قرار دادن نتایج حاصل از اعمال چهار کانوولوشن مطرح‌شده در شکل (۵) آورده شده است.

همان‌طور که در ابتدای این بخش ذکر شد، بازیابی هندسه دقیق و ساختار عوارض موجود در منطقه تنها با استفاده از نقشه‌های ویژگی حاصل از کدگذاری قابل دستیابی نمی‌باشد. در شبکه‌های عمیق ویژگی‌های سطح پایین و محلی از لایه‌های کم‌عمق قابل استخراج هستند [۴۲]. از این‌رو، ساختاری جهت استفاده و بهره‌برداری دوباره از ویژگی‌های تولیدشده در مرحله کدگذاری برای بهبود نتایج بزرگ کردن نقشه‌های ویژگی در مرحله کدگذاری ارائه شده است. در این راستا، ابتدا به هر یک از ماتریس‌های نقشه ویژگی موردنظر در مرحله کدگذاری و همین‌طور ماتریس نقشه ویژگی در کدگذاری که باید اندازه آن افزایش یابد، یک عملگر کانوولوشن با اندازه کرنل  $1 \times 1$  اعمال می‌شود.

#### ۴-۲-۲- کدگذاری

در مسأله تخمین ارتفاع، بازیابی شکل هندسی عوارض نیز مسأله‌ای مهم و در عین حال دشوار است. چراکه نقشه‌های ویژگی تولیدشده در طی روند کدگذاری و گذر از چندین مرحله کوچک‌سازی دارای ابعاد بسیار کوچک می‌باشند. به‌طوری‌که ساختارهای هندسی موجود در منطقه و محل دقیق قرارگیری آن‌ها در تصاویر قابل تشخیص نمی‌باشد. در شبکه عمیق پیشنهادی ابعاد نقشه‌های ویژگی پس از گذر از مرحله کدگذاری  $1/32$  ابعاد تصویر ورودی می‌باشد که این امر نشان از عدم وجود اطلاعات کافی در آن‌ها جهت بازیابی جزئیات دارد. در این مقاله از ساختاری کاملاً کانوولوشن مبنای افزایش ابعاد نقشه‌های ویژگی استفاده شد [۱۴]. در این ساختار از اتصال نتایج اعمال چهار کانوولوشن متفاوت، تصویری با ابعاد بزرگ‌تر ایجاد می‌گردد. به‌طوری‌که به ترتیب چهار کانوولوشن با ابعاد  $3 \times 3$ ،  $3 \times 2$ ،  $2 \times 3$  و  $2 \times 2$  به تصویر اعمال شده و با تعیین دقیق مقادیر لایه‌گذاری با صفر، چهار ماتریس با ابعادی برابر با ابعاد تصویر ورودی ایجاد می‌شود. در نهایت با کنار هم قرار دادن این چهار ماتریس، ماتریسی با ابعاد دوبرابر ماتریس تصویر ورودی ایجاد می‌شود [۱۴]. در این روش به دلیل اعمال عملگرهای




شکل ۵: نحوه دو برابر کردن ابعاد نقشه‌های ویژگی در طی مرحله کدگشایی

اعمال شده بر روی  $\omega_p$  و  $Q_l$  می‌باشند.  $\omega_d$  ماتریس وزن روند ارائه شده برای دو برابر کردن ابعاد نقشه‌های ویژگی می‌باشد.  $\oplus$  نشان دهنده عملگر تجمیع و  $\otimes$  نشان دهنده عملگر افزایش ابعاد نقشه‌های ویژگی می‌باشند. در شکل (۶) ساختار کلی پیشنهاد شده برای هر مرحله از کدگشایی که شامل افزایش ابعاد نقشه‌های ویژگی با در نظر گرفتن ویژگی‌های تولید شده در مرحله کدگذاری می‌باشد، نمایش داده شده است.

در نهایت روند مطرح شده در شکل (۶) جهت دو برابر کردن ابعاد نقشه‌های ویژگی به کار گرفته شد. ساختار ارائه شده برای تلفیق نقشه‌های ویژگی مراحل کدگذاری و کدگشایی در رابطه (۱) ارائه شده است.

رابطه (۱)  $P_{l+1} = ((P_l * \omega_p) \oplus (Q_l * \omega_q)) \otimes \omega_d$ ، که  $Q_l$  نقشه‌های ویژگی فراخوانده شده از مرحله کدگذاری و  $P_l$  نقشه ویژگی بدست آمده از مرحله قبل کدگشایی است.  $\omega_p$  و  $\omega_q$  به ترتیب عملگرهای



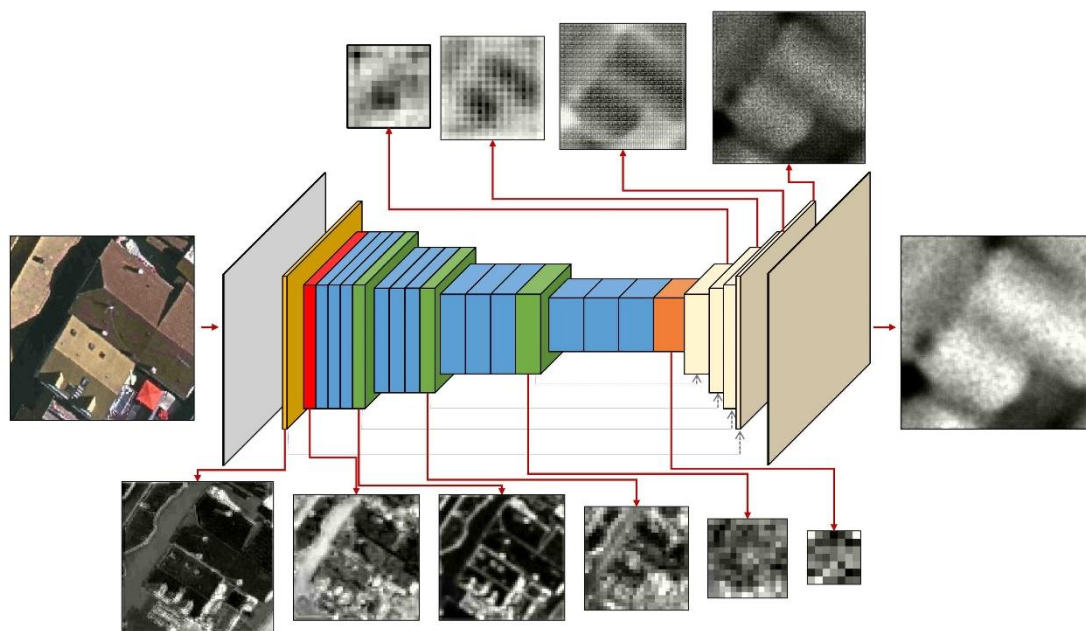
شکل ۶: ساختار پیشنهاد شده برای کدگشایی

نمایش داده شده است. همان‌طور که مشخص است، هر چه در مرحله کدگذاری به جلو حرکت می‌کنیم، ابعاد نقشه‌های ویژگی کوچک‌تر شده و صحنه از لحاظ

در ادامه برای درک بهتر روند کار در مراحل کدگذاری و کدگشایی، در شکل (۷) از هر یک از مراحل کدگذاری و کدگشایی یک ویژگی یا نقشه ویژگی

با این تفاوت که در مرحله کدگذاری تصاویر دارای ماهیت تصویر رنگی بوده و به نوعی تأثیر گرفته و نمایش دهنده خصوصیات تصویر رنگی ورودی می‌باشند، درحالی که در مرحله کدگشایی و به‌مرور پس از گذر از لایه‌های طراحی شده، نقشه‌های ویژگی ساختار ارتفاعی منطقه مورد را نشان می‌دهند.

بصری نامفهوم‌تر می‌شود. به‌طوری که لایه‌های آخر در مرحله کدگذاری تقریباً قابل تفسیر نمی‌باشند. اما در مرحله کدگشایی معکوس این فرایند صورت می‌پذیرد. به این ترتیب ابتدا نقشه‌های ویژگی ابعاد کوچکی داشته و از لحاظ بصری نامفهوم می‌باشند، اما هرچه قدر به انتهای بخش کدگشایی نزدیک می‌شویم، صحنه واضح‌تر شده و جزئیات بیشتری به آن اضافه می‌شود.

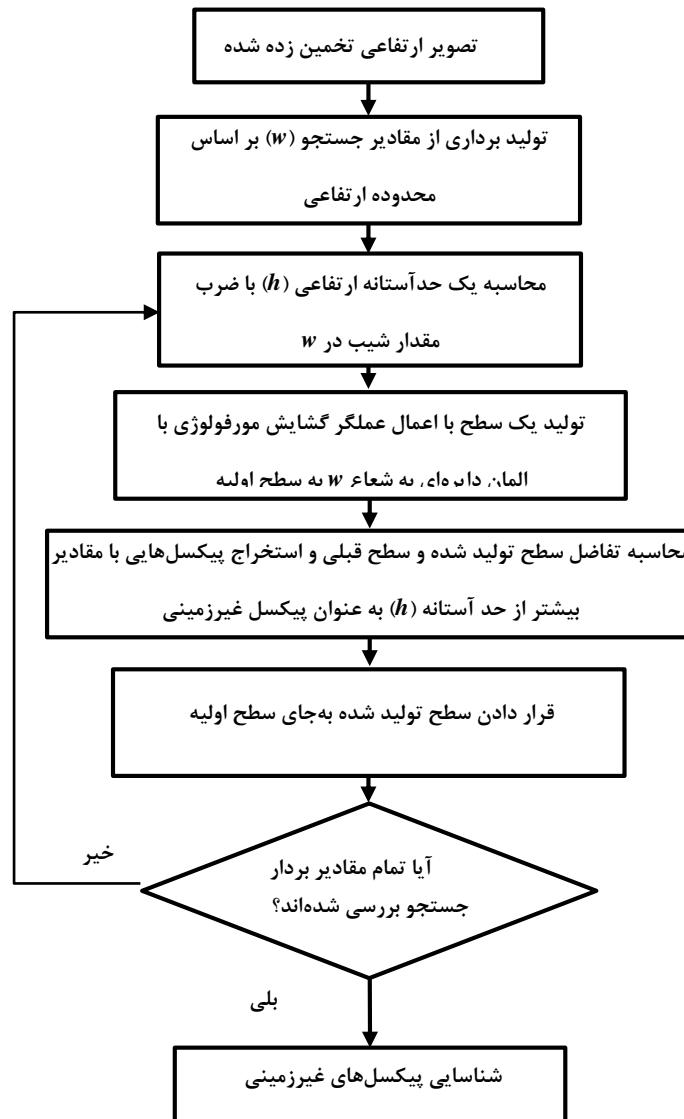


شکل ۷: روند کلی اجرای شبکه کدگذار-کدگشا به همراه نمونه‌های نقشه‌های ایجاد شده در هر مرحله

شده جدا گشته و سپس با افزودن مقادیر ارتفاعی مربوط به عوارض غیرزمینی به مدل رقومی ارتفاعی *SRTM*، مدل ارتفاعی نهایی استخراج می‌گردد. الگوریتم پیشنهادی برای استخراج عوارض غیرزمینی از تصاویر ارتفاعی تخمین زده شده در شکل (۸) آورده شده است. در روش پیشنهادی، ابتدا بر اساس محدوده مقادیر تصویر ارتفاعی تخمین زده شده، یک بردار جستجو ( $w$ ) تشکیل می‌شود. سپس یک حدآستانه ( $h$ ) برای شیب در نظر گرفته می‌شود؛ به این معنا که پیکسل‌هایی که دارای شیب بیشتری در یک فاصله مشخص نسبت به مقدار تعیین شده باشند، به عنوان پیکسل غیرزمینی در نظر گرفته می‌شوند.

#### ۴-۳- ایجاد *DSM* نهایی

تصاویر ماهواره‌ای معمولاً مناطق وسیعی با ناهمواری‌های زیاد را پوشش می‌دهند که این سبب می‌شوند که اتصال تصاویر ارتفاعی تخمین زده شده تنها با استفاده از تصحیح جهش‌های ارتفاعی در نواحی اتصال کارآمد نباشد. چراکه مدل‌سازی ناهمواری‌ها در این سطح تنها از طریق آموزش با بهره‌گیری از برش‌های کوچک امکان‌پذیر نمی‌باشد. از این‌رو، در این بخش روشی جهت استفاده از مدل رقومی ارتفاعی *SRTM* برای ایجاد *DSM* نهایی، ارائه شده است. ساختار کلی روش پیشنهادی به این صورت است که ابتدا عوارض غیرزمینی از تصاویر ارتفاعی تخمین زده



شکل ۸: فلوجارت روش پیشنهادی برای شناسایی عوارض غیرزمینی

شناسایی می‌شوند. حال سطح تولید شده جایگزین سطح قبلی شده و این روند تا بررسی تمامی مقادیر بردار جستجو تشکیل داده شده ادامه می‌یابد. پس از شناسایی عوارض غیرزمینی و حذف پیکسل‌های مرتبط با آن‌ها و سپس اعمال درون‌یابی، *DTM* مربوط به آن منطقه بدست می‌آید. سپس با محاسبه تفاضل تصویر ارتفاعی اولیه و *DTM* بدست آمده عوارض غیرزمینی به همراه مقادیر ارتفاعی استخراج می‌شوند. درنهایت، پس از کنار هم قرار دادن تصاویر مربوط به عوارض

با ضرب شیب معین شده در بردار مقادیر جستجو، یک حدآستانه ارتفاعی متناسب با هر بردار جستجو تعیین می‌شود. حال با اعمال عملگر گشایش<sup>۱</sup> مورفولوژی به ازای هر مقدار بردار جستجو و با المان ساختاری دایره شکل به شعاع *w* یک سطح ایجاد می‌شود. با محاسبه تفاضل سطح تولید شده از سطح اولیه و اعمال حدآستانه تعیین شده *h*، پیکسل‌های غیرزمینی

<sup>۱</sup> Dilation

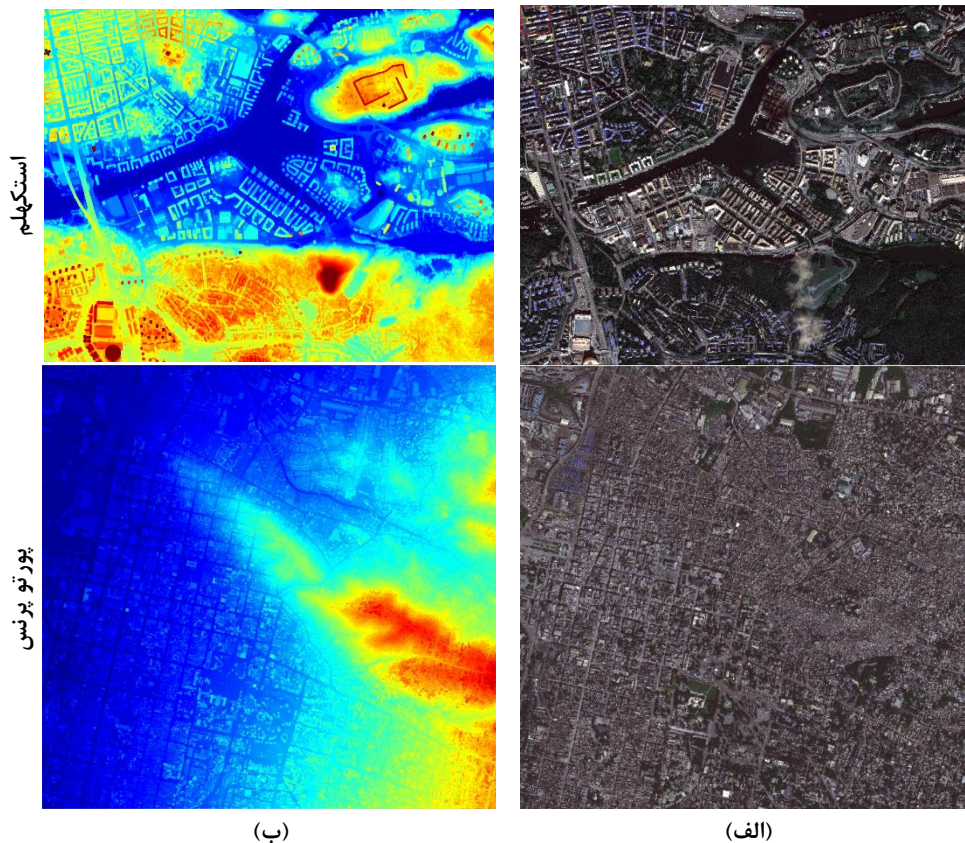


پانکروماتیک با قدرت تفکیک ۰/۴۶ متر و تصویر چندطیفی با قدرت تفکیک ۱/۸۴ متر می‌باشد. مدل ارتفاعی توسط *Vricon* تهیه شده است و دارای اندازه پیکسل زمینی برابر با ۰/۵ متر می‌باشد. مجموعه داده پورتو پرنس شامل یک تصویر ماهواره‌ای و *DSM* متناظر آن می‌باشد. تصویر ماهواره‌ای مربوط به سنجنده *QuickBird* دارای قدرت تفکیک مکانی ۰/۶۱ متر در باند پانکروماتیک و ۲/۴ متر در باند چند طیفی می‌باشد. *DSM* منطقه پورتو پرنس توسط سنجنده لایدار تهیه شده است و دارای قدرت تفکیک مکانی یک‌متر می‌باشد. از روش *Gram-Schmidt* که یکی از روش‌های *Pan-sharpening* است، برای بدست آوردن تصویر سه بانده با قدرت تفکیک بالا استفاده شد. در شکل (۹) نواحی مطالعاتی نشان داده شده‌اند.

غیرزمینی و اضافه نمودن آن به مدل رقومی ارتفاعی *SRTM*، مدل ارتفاعی نهایی حاصل می‌شوند. لازم به ذکر است که از آنجا که ابعاد پیکسل مدل رقومی ارتفاعی *SRTM* ۳۰ متر می‌باشد، با استفاده از درون‌یابی *Bilinear* ابعاد پیکسل آن با تصویر ماهواره‌ای مورد مطالعه یکسان‌سازی می‌شود.

#### ۵- پیاده‌سازی و ارزیابی نتایج

به‌منظور پیاده‌سازی روند پیشنهادی از تصاویر ماهواره‌ای و *DSM* مربوط به شهرهای استکهلم (سوئد) و پورتو پرنس (هائیتی) استفاده شده است. مجموعه داده استکهلم شامل یک تصویر ماهواره‌ای و *DSM* متناظر آن می‌باشد که توسط *Digital Globe* فراهم شده است. تصویر ماهواره‌ای توسط سنجنده *Worldview 2* اخذ شده است که دارای باند



شکل ۹: نواحی مطالعاتی، (الف) تصویر ماهواره‌ای، (ب) *DSM*



برای مرحله کدگذاری و همین‌طور اعمال عملگر معکوس کانولوشن [۳۹] به‌جای روند پیشنهادی در مرحله کدگشایی نشان داده شده و با نتایج روند پیشنهادی مقایسه شده‌اند.

برای ارزیابی کمی نتایج معیارهای مختلفی شامل، خطای میانگین نسبی  $(E_R)$  [۱۱]، خطای میانگین لگاریتم  $(E_L)$  [۱۱] و ریشه جذر میانگین مربعات  $(E_{RMSE})$  [۲۳] ارائه شده‌اند که در ادامه روابط آن‌ها آورده شده است (رابطه ۲، ۳، ۴).

$$E_R = \frac{1}{N} \sum_{i=1}^n \frac{|g_i - d_i|}{g_i}, \quad \text{رابطه (۲)}$$

$$E_L = \frac{1}{N} \sum_{i=1}^n \left| \log_{10}^{g_i} - \log_{10}^{d_i} \right| \quad \text{رابطه (۳)}$$

$$E_{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^n (g_i - d_i)^2}, \quad \text{رابطه (۴)}$$

که  $d_i$  مقدار ارتفاع مربوط به پیکسل  $i$  داده‌های مرجع،  $g_i$  ارتفاع متناظر تخمین زده شده و  $N$  مشخص‌کننده تعداد پیکسل‌های تصویر است. در جدول (۱) نتایج حاصل از ارزیابی تصاویر ارتفاعی تخمین زده شده مربوط به موارد ذکر شده در شکل (۱۰) آورده شده‌اند. در این جدول مدت زمان تقریبی آموزش هر یک از روش‌ها ( $T_t$ ) و همین‌طور مدت زمان تخمین تصویر ارتفاعی ( $T_p$ ) توسط شبکه پیشنهادی آورده شده است. لازم به ذکر است که  $T_p$  مربوط به مدت زمان تخمین هر تصویر ارتفاعی متناسب با تصویر ورودی شبکه با ابعاد  $۳۲۰ \times ۳۲۰$  می‌باشد.

برای پیاده‌سازی روش پیشنهادی از یک کامپیوتر با پردازنده *Core i7* و کارت گرافیک *NVIDIA GeForce GTX 1080 Ti* استفاده شد که دارای ۱۱ گیگابایت حافظه  $GPU^1$  می‌باشد. مطابق بخش ۴-۱، ابتدا فرایند آماده‌سازی بر روی تصاویر و داده‌های ارتفاعی برای ورودی به شبکه اعمال می‌شود. به‌طوری‌که هر یک از تصاویر موردنظر جهت پیاده‌سازی در ابعاد  $۳۲۰ \times ۳۲۰$  بریده می‌شوند تا مناسب جهت ورود به شبکه عمیق باشند. همچنین مقادیر ارتفاعی متناظر با هر تصویر ورودی، از کمینه ارتفاعی خود کم گشته و تصاویر ارتفاعی که حاوی تغییرات ارتفاعی محلی می‌باشند را حاصل می‌نماید. درنهایت و پس از تنظیم پارامترهای شبکه عمیق، شبکه آموزش می‌بیند. درواقع با این کار محدوده تغییرات ارتفاعی محدود گشته و روند همگرایی شبکه تسریع می‌گردد. از آنجاکه این مجموعه داده‌ها شامل یک تصویر ماهواره‌ای و یک مدل ارتفاعی که منطقه وسیع شهری را پوشش می‌دهد، حدوداً یک سوم ( $۱/۳$ ) از داده‌ها به‌عنوان داده آموزشی و مابقی داده‌ها برای ارزیابی مورد استفاده قرار گرفتند. تعداد داده‌های آموزشی پس از اعمال تبدیلات مربوط به روند تقویت داده به حدود ۴۴ هزار عدد برای ناحیه پورتوپرنس و ۳۸ هزار عدد برای استکهلم می‌رسد. تعداد اپک‌ها<sup>۲</sup>، ابعاد دسته‌ها<sup>۳</sup>، روند کاهش وزن<sup>۴</sup>، نرخ یادگیری<sup>۵</sup> و تکانه<sup>۶</sup> برای تمامی شبکه‌ها در هر دو ناحیه به ترتیب ۲۰، ۱۶،  $۳ \times 10^{-4}$  و  $۵ \times 10^{-3}$  در نظر گرفته شد. در شکل (۱۰) چند نمونه از تصاویر ارتفاعی تخمین زده شده در این نواحی نشان داده شده‌اند. برای ارزیابی بهتر نتایج حاصل از استفاده از شبکه‌های عمیق دیگر نظیر *AlexNet*، *VGG* [۲۰] و *GoogleNet* [۴۳]

<sup>1</sup> Graphics Processing Unit


<sup>2</sup> Epoch

<sup>3</sup> Batch size

<sup>4</sup> Weight decay

<sup>5</sup> Learning rate

<sup>6</sup> Momentum



شکل ۱۰: نتایج حاصل از تخمین مقادیر ارتفاعی از تک تصویر توسط شبکه پیشنهادی، (الف) تصویر ورودی، (ب) AlexNet، (ج) VGG، (د) GoogleNet، (ه) ResNet، (و) شبکه پیشنهادی، (ز) مقادیر ارتفاعی مرجع.

جدول ۱: نتایج ارزیابی حاصل از تخمین مقادیر ارتفاعی

$T_p$ (m)	$T_t$ (h)	$ERMSE$ (m)	$EL$	$Er$	روش	
۰٫۵۶۲	۹	۷٫۱۰۷	۰٫۳۸۱	۴٫۲۶۹	Alex Net	استکهلم
۱٫۳۰۳	۲۱	۶٫۷۰۵	۰٫۳۶۵	۳٫۳۰۴	VGG	
۱٫۰۶۵	۱۷	۶٫۹۶۸	۰٫۳۵۸	۲٫۷۰۰	Google Net	
۱٫۷۱۰	۲۴	۶٫۱۵۲	۰٫۳۲۲	۲٫۴۳۹	Res Net	
۱٫۴۳۷	۲۷	۴٫۰۰۶	۰٫۲۵۲	۱٫۴۵۳	شبکه پیشنهادی	
۰٫۵۶۲	۹	۳٫۴۸۵	۰٫۲۱۳	۰٫۷۳۱	Alex Net	پورتو پرنس
۱٫۳۰۳	۲۵	۳٫۵۴۶	۰٫۲۱۵	۰٫۶۳۰	VGG	
۱٫۰۶۵	۲۰	۳٫۱۹۵	۰٫۲۲۴	۰٫۶۴۵	Google Net	
۱٫۷۱۰	۳۱	۲٫۸۷۶	۰٫۱۹۸	۰٫۵۲۳	Res Net	
۱٫۴۳۷	۲۷	۲٫۱۲۹	۰٫۱۹۱	۰٫۳۹۰	شبکه پیشنهادی	

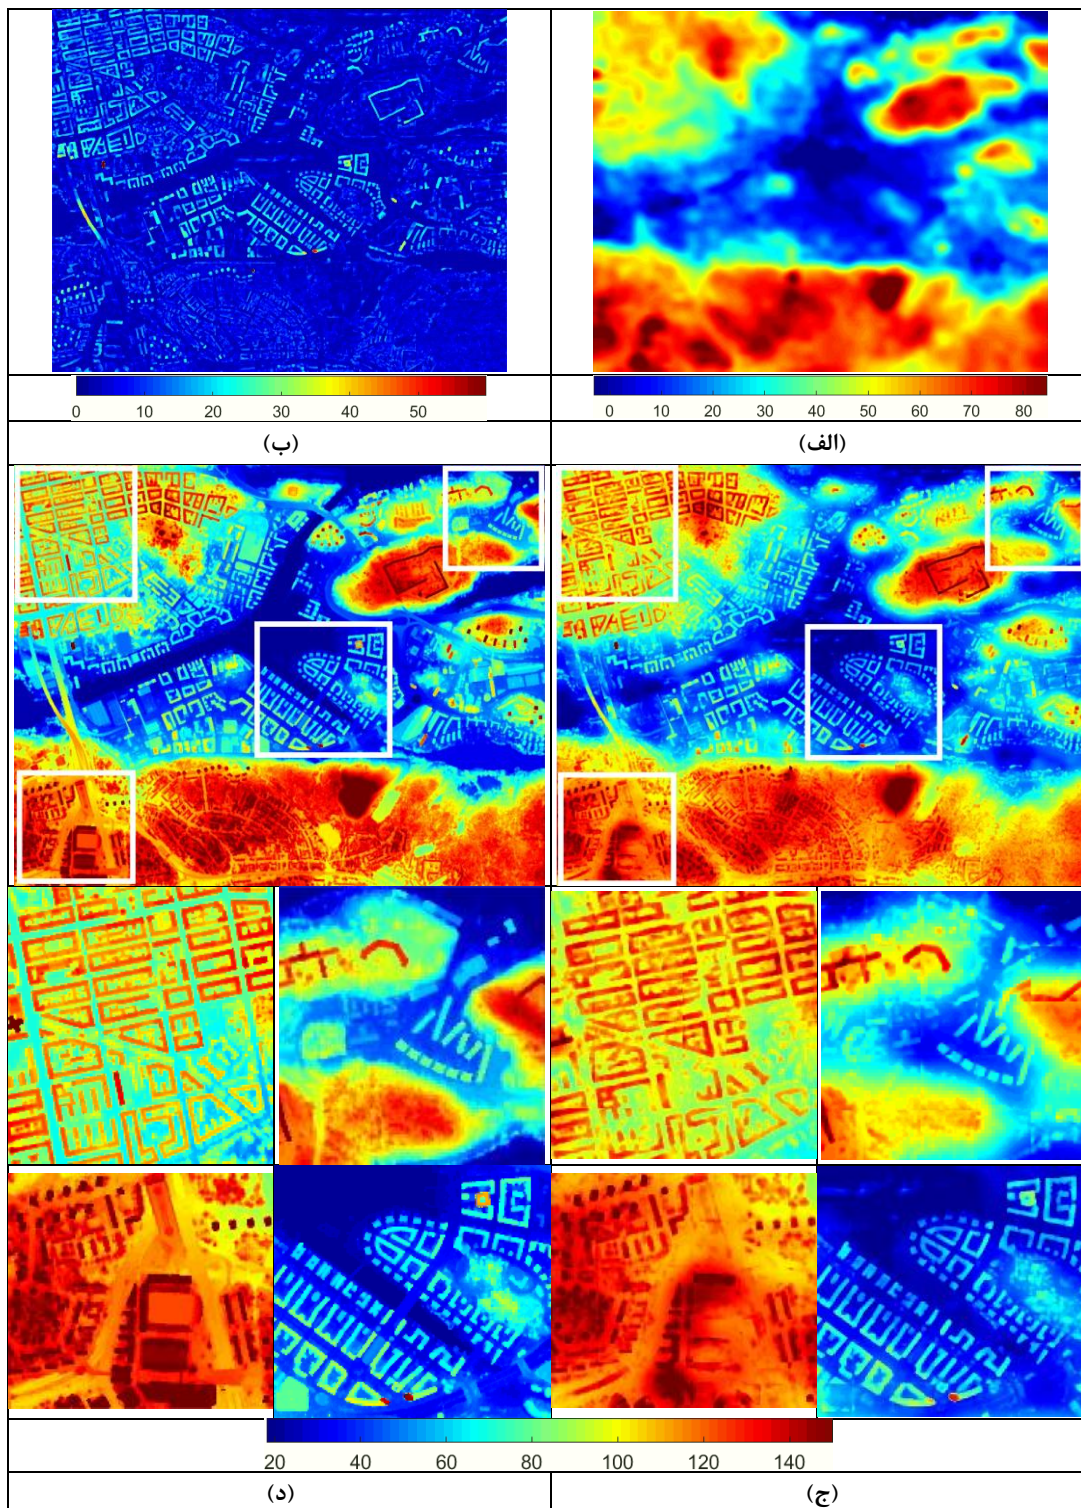
نشان داده شده‌اند. جهت آنالیز بصری بهتر برخی قسمت‌های مدل‌های استخراج شده نهایی با بزرگنمایی نمایش داده شده‌اند.

سپس DSM نهایی بدست آمده بار دیگر با استفاده از معیار  $ERMSE$  ارزیابی شدند که برای ناحیه استکهلم مقدار ۵٫۷۹۶ و برای ناحیه پورتو پرنس مقدار ۳٫۸۵۵ بدست آمد. همان‌طور که انتظار می‌رفت، دقت نتایج کاهش یافت که ناشی از دقت نسبتاً پایین مدل رقومی ارتفاعی  $SRTM$  است. چراکه ابعاد پیکسل زمینی در مدل‌های رقومی  $SRTM$  ۳۰ متر می‌باشد که عدد بزرگی در مقایسه با خطای الگوریتم پیشنهادی در قطعات کوچک تصویری (جدول (۱)) می‌باشد. باین‌حال DSM نهایی بدست آمده چه از لحاظ ساختار کلی که شامل پستی بلندی‌های کلی سطح زمین و چه از لحاظ هندسه و ساختار عوارض موجود در مناطق مطالعاتی دارای کیفیت مناسبی می‌باشند. درواقع به نوعی با ترکیب مدل‌های رقومی ارتفاعی  $SRTM$  که حاوی اطلاعات بسیار کلی ارتفاعی بوده و اطلاعات ارتفاعی جزئی‌تر مربوط عوارضی نظیر ساختمان‌ها و درختان را شامل نمی‌شوند.


همان‌طور که در جدول (۱) مشاهده می‌شود، شبکه پیشنهادی باعث کاهش خطا، بهبود عملکرد و تخمین مقادیر ارتفاعی با دقت بیشتر شده است. همچنین مقایسه کیفی نتایج در شکل (۱۰) نشان از بهبود عملکرد شبکه پیشنهادی در بازسازی بهتر عوارض به‌ویژه در لبه‌ها و همچنین بازیابی جزئیات بیشتر در هر دو ناحیه مطالعاتی دارد.

همان‌طور که در بخش ۴-۳ بیان شد، پس از تخمین مقادیر ارتفاعی از تصاویر کوچک بدست آمده، با استفاده از الگوریتم پیشنهادی پیکسل‌های زمینی از غیرزمینی جدا می‌شوند. در این راستا، مقدار شیب و حدآستانه ارتفاعی در الگوریتم پیشنهادی به ترتیب ۳۰ درجه و ۱ متر در نظر گرفته شده‌اند. پس از شناسایی پیکسل‌های غیرزمینی و کنارهم قرار دادن نتایج حاصل شده، یک تصویر یکپارچه که تنها حاوی اطلاعات ارتفاعی عوارض غیرزمینی استخراج شده‌اند، بدست می‌آید. سپس با اضافه نمودن تصویر بدست آمده به مدل رقومی ارتفاعی  $SRTM$ ، نتیجه نهایی حاصل می‌شود. در شکل (۱۱ و ۱۲) نتایج نهایی استخراج DSM برای نواحی مطالعاتی استکهلم و پورتو پرنس





شکل ۱: نتایج حاصل از اتصال تصاویر ارتفاعی و ایجاد یک مدل ارتفاعی پیوسته با استفاده از مدل ارتفاعی *SRTM* در ناحیه استکهلم، (الف) مدل رقومی ارتفاعی *SRTM*، (ب) مقادیر ارتفاعی عوارض غیرزمینی استخراج شده، (ج) مدل ارتفاعی تخمین زده شده نهایی، (د) مدل ارتفاعی مرجع.




شکل ۱۲: نتایج حاصل از اتصال تصاویر ارتفاعی و ایجاد یک مدل ارتفاعی پیوسته با استفاده از مدل ارتفاعی *SRTM* در ناحیه پورتو پرنس، (الف) مدل رقومی ارتفاعی *SRTM*، (ب) مقادیر ارتفاعی عوارض غیرزمینی استخراج شده، (ج) مدل ارتفاعی تخمین زده شده نهایی، (د) مدل ارتفاعی مرجع.



خاکستری ثبت شده می‌گردد که این عوامل به صورت مستقیم بر روی دقت نتایج تاثیرگذارند. عامل دوم که اهمیت بیشتری نیز دارد، تفاوت ساختاری شهرهای پورتوپرنس و استکهلم است. در واقع شهر استکهلم شهری با خانه‌های غیرمتراکم و پوشش گیاهی زیاد است که در آن خانه‌ها عمدتاً دارای سقف‌های شیروانی بوده با فاصله از یکدیگر قرار دارند. در حالی که شهر پرتو پرنس، شهری با تراکم بسیار بالا و ساختمان‌های به هم پیوسته است که عمدتاً دارای سقف‌های مسطح می‌باشد. به‌طور کلی این دوشهر شباهت ساختاری و هندسی بسیار کمی با یکدیگر دارند و این عامل نیز سبب عملکرد ضعیف در تخمین ساختار کلی ساختمان‌ها می‌گردد که در شکل (۱۳) نیز مشهود است. برای بهبود نتایج باید کتابخانه آموزشی با استفاده از داده‌های مربوط به شهرهایی که دارای شباهت ساختاری با منطقه تست می‌باشند، تقویت شده و تا حد امکان سعی شود که تصاویر مورد استفاده برای تست مشابه تصاویر مورد استفاده در روند آموزش باشند.

با مقادیر تخمین زده شده ارتفاعی از تک تصویر ماهواره‌ای که شامل اطلاعات جزئی‌تری نظیر شکل هندسی و ارتفاع عوارض شهری می‌باشند، سعی شد که یک *DSM* دقیق بدست آید. در انتها برای ارزیابی میزان تعمیم‌پذیری شبکه طراحی شده برای تخمین مقادیر ارتفاعی یک آزمون پرجالش در نظر گرفته شد. در این آزمون شبکه آموزش داده شده با استفاده از داده‌های پورتوپرنس برای تخمین مقادیر ارتفاعی در شهر استکهلم مورد استفاده قرار می‌گیرد. در ارزیابی‌ها، مقادیر  $ER$ ،  $EL$  و  $ERMSE$  بدست آمد که کاهش شدید دقت را نشان می‌دهد. البته این امر قابل پیش‌بینی بوده و از دو منظر می‌تواند مورد بررسی قرار گیرد. اولین دلیل کاهش دقت را می‌توان ناشی از تفاوت سنجنده‌های اخذ کننده تصویر در ناحیه دانست. در واقع تصویر شهر استکهلم با استفاده از ماهواره *Worldview 2* و تصویر شهر پورتوپرنس با استفاده از ماهواره *QuickBird* اخذ شده است. این عامل سبب ایجاد تفاوت‌های بسیاری در هندسه و مقادیر درجه



شکل ۱۳: نتایج حاصل از تخمین مقادیر ارتفاعی شهر استکهلم با استفاده از شبکه آموزش دیده توسط داده‌های مربوط به شهر پورتوپرنس، (الف) تصویر ورودی، (ب) تصویر ارتفاعی تخمین زده شده، (ج) تصویر ارتفاعی مرجع.

پیشنهادی به ترتیب مقادیر ۱/۸۴۹، ۰/۴۱۸ و ۵/۳۹۶ برای معیارهای  $E_L$ ،  $E_R$  و  $ER_{MSE}$  در ناحیه استکهلم و همینطور به ترتیب مقادیر ۰/۷۶۳، ۰/۲۳۶ و ۳/۸۵۵ برای معیارهای  $E_L$ ،  $E_R$  و  $ER_{MSE}$  در ناحیه پورتو پرنس حاصل شد. با این‌که در این تحقیق به دلیل محدود بودن مجموعه داده، تنها از دو تصویر ماهواره‌ای به همراه مدل‌های رقومی دقیق برای پیاده‌سازی الگوریتم پیشنهادی استفاده شد، نتایج حاصل از تخمین مقادیر ارتفاعی (جدول (۱)) نویدبخش دستیابی به دقت‌های بالا در صورت آموزش شبکه پیشنهادی با استفاده از مجموعه‌ای غنی از تصاویر ماهواره‌ای که پوشش‌های متنوع سطح زمین را پوشش می‌دهند، است. همچنین، دسترسی آسان و رایگان بودن مدل‌های رقومی ارتفاعی  $SRTM$  سبب می‌شود که عملکرد روند پیشنهادی در استخراج  $DSM$  نهایی هیچ محدودیتی نداشته باشد. به‌طورکلی، در این تحقیق نشان داده شد که استخراج  $DSM$  از تک تصویر ماهواره‌ای با بهره‌گیری از توانایی شبکه‌های عمیق  $CNN$  امکان‌پذیر است. با توجه به تلاش صورت گرفته در این مقاله، همچنان شبکه پیشنهادی در زمینه تخمین ارتفاع عوارض کوچک و مدل‌سازی تغییرات ارتفاعی کم دچار مشکل است و رفع این مساله نیاز به ارائه روشی جهت استخراج ویژگی‌های کارآمدتر به ویژه در لایه‌های کم‌عمق است که برای تحقیقات آتی پیشنهاد می‌شود.

## ۶- نتیجه‌گیری

در این مقاله سعی شد تا امکان استخراج اطلاعات سه‌بعدی و تخمین  $DSM$  از تک تصویر ماهواره‌ای مورد بررسی و آنالیز قرار گیرد. در این راستا، با استفاده از مفاهیم یادگیری عمیق، یک شبکه  $CNN$  طراحی شد که پس از آموزش توسط تصاویر ماهواره‌ای و  $DSM$ ‌های متناظر آن‌ها، توانایی بالایی در زمینه تخمین مقادیر ارتفاعی از تک‌تصویر داشت. برای استفاده از شبکه پیشنهادی، ابتدا پیش‌پردازش‌های برای آماده‌سازی داده‌های آموزشی صورت گرفت. شبکه پیشنهادی دارای ساختاری کدگذار-کدگشا می‌باشد که در مرحله کدگذاری، ویژگی‌های متفاوت و قدرتمندی در مقیاس‌های متفاوت از تصویر ورودی استخراج شده و در روند کدگشایی به تدریج ویژگی‌های استخراج شده با هم تلفیق شده و به مقادیر ارتفاعی تبدیل می‌شوند. پس از محاسبه مقادیر ارتفاعی برای تصاویر بریده شده، با ارائه یک الگوریتم پیکسل‌های زمینی و غیرزمین از هم تفکیک شدند. سپس مقادیر ارتفاعی مربوط به عوارض غیرزمینی شناسایی شده، استخراج و تصاویر حاصل شده به یکدیگر متصل می‌شوند تا یک سطح پیوسته ایجاد نمایند. در نهایت با افزودن سطح حاصل شده که حاوی مقادیر ارتفاعی مربوط به عوارض غیرزمینی است به مدل رقومی ارتفاعی  $SRTM$  با قدرت تفکیک مکانی ۳۰ متر،  $DSM$  نهایی منطقه بدست آمد. الگوریتم پیشنهادی با استفاده از تصویر ماهواره‌ای مربوط به دو شهر استکهلم و پورتو پرنس پیاده‌سازی و ارزیابی شد.  $DSM$  نهایی حاصل شده الگوریتم

## مراجع

- [1] F. Rottensteiner, "Advanced methods for automated object extraction from LiDAR in urban areas," in *Geoscience and Remote Sensing Symposium (IGARSS), IEEE International*, pp. 5402-5405, 2012.
- [2] J. Schiewe, "Segmentation of high-resolution remotely sensed data-concepts, applications and problems," *International Archives of Photogrammetry Remote Sensing and Spatial Information Sciences*, vol. 34, pp. 380-385, 2002.
- [3] F. Rottensteiner and C. Brieze, *Automatic generation of building models from LIDAR data and the integration of aerial images: na*, 2003.

- [4] F. Lafarge, X. Descombes, J. Zerubia, and M. Pierrot-Deseilligny, "Structural approach for building reconstruction from a single DSM," *IEEE Transactions on pattern analysis and machine intelligence*, vol. 32, pp. 135-147, 2010.
- [5] I. V. Florinsky, "Combined analysis of digital terrain models and remotely sensed data in landscape investigations," *Progress in Physical Geography*, vol. 22, pp. 33-60, 1998.
- [6] H. Murakami, K. Nakagawa, H. Hasegawa, T. Shibata, and E. Iwanami, "Change detection of buildings using an airborne laser scanner," *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 54, pp. 148-152, 1999.
- [7] B. P. Olsen, T. Knudsen, and P. Frederiksen, "Digital change detection for map database update," *International Archives of Photogrammetry Remote Sensing and Spatial Information Sciences*, vol. 34, pp. 357-364, 2002.
- [8] F. H. Sinz, J. Q. Candela, G. H. Bakır, C. E. Rasmussen, and M. O. Franz, "Learning depth from stereo," in *Joint Pattern Recognition Symposium*, pp. 245-252, 2004.
- [9] J. Skilling and S. Gull, "Algorithms and applications," in *Maximum-entropy and Bayesian methods in inverse problems*, ed: Springer, pp. 83-132, 1985.
- [10] D. Eigen and R. Fergus, "Predicting depth, surface normals and semantic labels with a common multi-scale convolutional architecture," in *Proceedings of the IEEE International Conference on Computer Vision*, pp. 2650-2658, 2015.
- [11] D. Eigen, C. Puhrsch, and R. Fergus, "Depth map prediction from a single image using a multi-scale deep network," *Advances in neural information processing systems*, pp. 2366-2374, 2014.
- [12] F. Liu, C. Shen, G. Lin, and I. Reid, "Learning depth from single monocular images using deep convolutional neural fields," *IEEE transactions on pattern analysis and machine intelligence*, vol. 38, pp. 2024-2039, 2016.
- [13] A. Saxena, S. H. Chung, and A. Y. Ng, "3-d depth reconstruction from a single still image," *International journal of computer vision*, vol. 76, pp. 53-69, 2008.
- [14] I. Laina, C. Rupprecht, V. Belagiannis, F. Tombari, and N. Navab, "Deeper depth prediction with fully convolutional residual networks," *3D Vision (3DV), 2016 Fourth International Conference on*, pp. 239-248, 2016.
- [15] Z.-m. Yang and H.-d. Zhao, "A New RBF Reflection Model for Shape from Shading," *3D Research*, vol. 8, p. 33, 2017.
- [16] M. A. Rajabi and J. R. Blais, "Improvement of digital terrain model interpolation using SFS techniques with single satellite imagery," *International Conference on Computational Science*, pp. 164-173, 2002.
- [17] M. A. Rajabi and J. R. Blais, "Optimization of DTM interpolation using SFS with single satellite imagery," *The Journal of Supercomputing*, vol. 28, pp. 193-213, 2004.
- [18] J. Schennings, "Deep Convolutional Neural Networks for Real-Time Single Frame Monocular Depth Estimation," ed, 2017.
- [19] I. P. Howard, "Perceiving in depth, Vol. 3: Other mechanisms of depth perception," 2012.
- [20] K. Simonyan and A. Zisserman, "Very deep convolutional networks for large-scale image recognition," *arXiv preprint arXiv:1409.1556*, 2014.
- [21] Z. Zhang, C. Xu, J. Yang, Y. Tai, and L. Chen, "Deep hierarchical guidance and regularization learning for end-to-end depth estimation," *Pattern Recognition*, vol. 83, pp. 430-442, 2018.
- [22] B. Li, Y. Dai, and M. He, "Monocular Depth Estimation with Hierarchical Fusion of



- Dilated CNNs and Soft-Weighted-Sum Inference*, "Pattern Recognition, 2018.
- [23] A. Saxena, S. H. Chung, and A. Y. Ng, "Learning depth from single monocular images," *Advances in neural information processing systems*, pp. 1161-1168, 2006.
- [24] M. Liu, M. Salzmann, and X. He, "Discrete-continuous depth estimation from a single image," *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 716-723, 2014.
- [25] S. Srivastava, M. Volpi, and D. Tuia, "Joint height estimation and semantic labeling of monocular aerial images with CNNs," *Geoscience and Remote Sensing Symposium (IGARSS), IEEE International*, pp. 5173-5176, 2017.
- [26] L. Mou and X. X. Zhu, "IM2HEIGHT: Height estimation from single monocular imagery via fully residual convolutional-deconvolutional network," *arXiv preprint arXiv:1802.10249*, 2018.
- [27] P. Ghamisi and N. Yokoya, "IMG2DSM: Height Simulation From Single Imagery Using Conditional Generative Adversarial Net," *IEEE Geoscience and Remote Sensing Letters*, vol. 15, pp. 794-798, 2018.
- [28] H. A. Amirkolaei and H. Arefi, "Height estimation from single aerial images using a deep convolutional encoder-decoder network," *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 149, pp. 50-66, 2019.
- [29] H. A. Amirkolaei and H. Arefi, "Convolutional neural network architecture for digital surface model estimation from single remote sensing image," *Journal of Applied Remote Sensing*, vol. 13, p. 016522, 2019.
- [30] A. Garcia-Garcia, S. Orts-Escolano, S. Oprea, V. Villena-Martinez, and J. Garcia-Rodriguez, "A review on deep learning techniques applied to semantic segmentation," *arXiv preprint arXiv:1704.06857*, 2017.
- [31] M. Lin, Q. Chen, and S. Yan, "Network in network," *arXiv preprint arXiv:1312.4400*, 2013.
- [32] Y.-L. Boureau, J. Ponce, and Y. LeCun, "A theoretical analysis of feature pooling in visual recognition," *Proceedings of the 27th international conference on machine learning (ICML-10)*, pp. 111-118, 2010.
- [33] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "Imagenet classification with deep convolutional neural networks," *Advances in neural information processing systems*, pp. 1097-1105, 2012.
- [34] Y. LeCun, Y. Bengio, and G. Hinton, "Deep learning," *Nature*, vol. 521, pp. 436-444, 2015.
- [35] R. H. Hahnloser, R. Sarpeshkar, M. A. Mahowald, R. J. Douglas, and H. S. Seung, "Digital selection and analogue amplification coexist in a cortex-inspired silicon circuit," *Nature*, vol. 405, p. 947, 2000.
- [36] S. Ioffe and C. Szegedy, "Batch normalization: Accelerating deep network training by reducing internal covariate shift," *arXiv preprint arXiv:1502.03167*, 2015.
- [37] S. Wager, S. Wang, and P. S. Liang, "Dropout training as adaptive regularization," *Advances in neural information processing systems*, pp. 351-359, 2013.
- [38] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 770-778, 2016.
- [39] J. Long, E. Shelhamer, and T. Darrell, "Fully convolutional networks for semantic segmentation," *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 3431-3440, 2015.
- [40] H. Noh, S. Hong, and B. Han, "Learning deconvolution network for semantic

*segmentation," Proceedings of the IEEE international conference on computer vision, pp. 1520-1528, 2015.*

[41]A. Dosovitskiy, J. T. Springenberg, and T. Brox, "Learning to generate chairs with convolutional neural networks," *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 1538-154, 2015.

[42]M. D. Zeiler and R. Fergus, "Visualizing and understanding convolutional networks," in *European conference on computer vision*, pp. 818-833, 2014

[43]C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, et al., "Going deeper with convolutions," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2015, pp. 1-9



## **Digital surface model extraction with high details using single high resolution satellite image and SRTM global DEM based on deep learning**

Hamed Amini Amirkolae<sup>1</sup>, Hossein Arefi<sup>2\*</sup>

1- PHD student, School of Surveying and Geospatial Eng., College of Eng., University of Tehran, Tehran, Iran  
2- School of Surveying and Geospatial Eng., College of Eng., University of Tehran, Tehran, Iran

### **Abstract**

The digital surface model (DSM) is an important product in the field of photogrammetry and remote sensing and has variety of applications in this field. Existed techniques require more than one image for DSM extraction and in this paper it is tried to investigate and analyze the probability of DSM extraction from a single satellite image. In this regard, an algorithm based on deep convolutional neural networks (CNN) is designed. In the proposed subject, firstly, some preprocessing such as dividing the satellite image into smaller images, localizing the height values and data augmentation are applied in order to prepare data to enter the network. The proposed CNN network has an encoder-decoder structure in which, different and effective features in different scales are extracted in the encoder stage and the generated features are fused to estimate height values by presenting an effective procedure in the decoding stage. Subsequently, the ground and non-ground pixels are separated and height values of the non-ground objects are extracted. The final DSM is obtained by adding the non-ground pixels with height information to the SRTM digital elevation model (DEM) with 30 meter pixel size. The proposed algorithm is evaluated using the satellite images and their corresponding DSMs. Analyzing the estimated small height images using the proposed CNN indicated 0.921, 0.221 and 2.956m on average for relative mean error ( $E_R$ ), logarithm mean error ( $E_L$ ) and root mean squared error ( $E_{RMSE}$ ), respectively. Moreover, analyzing the final seamless DSMs indicated 4.625 on average for  $E_{RMSE}$ .

**Key words:** Digital Surface Model, Convolutional Neural Network, single satellite image, SRTM DEM.