

تلفیق الگوریتم‌های یادگیری عمیق و فیلترهای دوطرفه با هدف استخراج ساختمان از تک‌تصویر نوری هوایی

مهدی خوش‌برش ماسوله^۱، رضا شاه‌حسینی^{۲*}، عبدالرضا صفری^۳

۱- دانشجوی دکتری، دانشکده مهندسی نقشه‌برداری و اطلاعات مکانی، پردیس دانشکده‌های فنی، دانشگاه تهران

۲- استادیار دانشکده مهندسی نقشه‌برداری و اطلاعات مکانی، پردیس دانشکده‌های فنی، دانشگاه تهران

۳- استاد دانشکده مهندسی نقشه‌برداری و اطلاعات مکانی، پردیس دانشکده‌های فنی، دانشگاه تهران

تاریخ دریافت مقاله: ۱۳۹۷/۰۲/۳۱ تاریخ پذیرش مقاله: ۱۳۹۷/۰۸/۱۲

چکیده

مسئله استخراج ساختمان از تک‌تصویر نوری هوایی با قدرت تفکیک مکانی بالا، همواره به‌عنوان یکی از چالش‌های مهم در تهیه نقشه به‌شمار می‌آید. هدف از پژوهش حاضر، بهره‌گیری از قطعه‌بندی معنایی تک‌تصویر نوری هوایی بر پایه تلفیق شبکه‌های عصبی کانولوشنی عمیق و فیلترهای دوطرفه جهت استخراج ساختمان می‌باشد. به‌همین منظور، پس از انتخاب یک مجموعه داده مناسب از تصاویر نوری سه‌باندی، با در نظر گرفتن این‌که برای آموزش شبکه‌های عصبی عمیق نیاز است تا داده‌های آموزشی با تعداد زیاد انتخاب شوند و با توجه به محدودیت‌های سخت‌افزاری در این پژوهش، پس از چندین بار آزمایش، حداقل داده‌ای که بالاترین نرخ دقت آموزش را به دست می‌دهد انتخاب گردید؛ تا نتایج به‌دست آمده، از کمبود داده‌های آموزشی تأثیر منفی نپذیرد. در این پژوهش، با بهینه‌سازی شبکه عصبی عمیق سیگنت که از نوع شبکه‌های کدگذار-کدگشا می‌باشد، با استفاده از تابع بهینه‌سازی برآورد لحظه تطبیقی و به‌کارگیری فیلترهای دوطرفه با کرنل گوسین، فرآیند پردازش و استخراج ساختمان از تصاویر نوری صورت گرفته است. نتایج تحقیق بر روی مجموعه داده مربوط به تصاویر نوری هوایی از مناطق شهری واقع در شهر پوتسدام آلمان از مجموعه داده‌های دو بعدی برج‌سب‌دار انجمن بین‌المللی فتوگرامتری و سنجش‌ازدور نشان داد؛ به‌کارگیری تلفیقی شبکه عصبی عمیق بهینه‌سازی شده سیگنت و فیلترهای دو طرفه با کرنل گوسین قابلیت‌های بسیار مناسبی از نظر بهبود شناسایی مرز ساختمان در مقایسه با روش‌های مشابه از تصاویر نوری با قدرت تفکیک مکانی بالا دارد. همچنین نتایج حاصل از روش پیشنهادی تحقیق با معیارهای تمامیت و صحت برای سه منطقه تست به ترتیب ۹۵/۱۴ و ۹۲/۳۷ درصد برای منطقه تست شماره یک، ۹۱/۶۷ و ۹۰/۲۰ برای منطقه تست شماره دو، ۹۶/۱۴ و ۹۳/۹۸ برای منطقه تست شماره سه می‌باشد.

کلیدواژه‌ها: استخراج ساختمان، تک‌تصویر نوری هوایی، قطعه‌بندی معنایی، شبکه‌های عصبی کانولوشنی عمیق، فیلترهای دوطرفه

*نویسنده مکاتبه کننده: گروه فتوگرامتری و سنجش از دور، دانشکده مهندسی نقشه‌برداری و اطلاعات مکانی، پردیس دانشکده‌های فنی، دانشگاه تهران، تهران، ایران.

تلفن: ۰۲۱۶۱۱۱۴۵۲۷

Email: rshahosseini@ut.ac.ir

۱- مقدمه

استخراج ساختمان از تصاویر فتوگرامتری و سنجش از دور نقش مهمی در طیف وسیعی از کاربردهای برنامه‌ریزی شهری و مدیریت املاک و زمین دارد [۱ و ۲]. همچنین امروزه با به‌کارگیری الگوریتم‌های یادگیری عمیق گام مؤثری در استخراج خودکار و دقیق این عارضه مهم از تصاویر فتوگرامتری و سنجش از دور برداشته شده است، اما همواره استخراج ساختمان با ساختار هندسی پیچیده از تک تصویر نوری یک چالش محسوب می‌شود [۳].

پس از ارائه مدل موفق لی‌نت^۱ در سال ۱۹۹۳ به‌عنوان اولین نمونه شبکه عصبی کانولوشنی^۲ تا سال ۲۰۱۸ و معرفی شبکه عصبی دوئل^۳ به‌عنوان یکی از ده فناوری برتر سال توسط یکی از نشریه‌های مؤسسه فناوری ماساچوست^۴ ایالات متحده آمریکا، تحولات رو به رشدی در توسعه الگوریتم‌های یادگیری عمیق^۵ در حیطه فناوری هوش مصنوعی^۶ رخ داده است [۴]. شبکه‌های عصبی عمیق دارای بیش از دو لایه مخفی^۷ هستند، به‌همین علت به آن‌ها شبکه‌های عصبی عمیق می‌گویند [۵]. شبکه‌های عصبی عمیق اغلب مشتمل بر لایه ورودی، لایه مخفی و لایه خروجی هستند، اما لایه مخفی می‌تواند شامل چندلایه از ویژگی‌های سطح پایین (مثل لبه ساختمان) تا ویژگی‌های سطح بالا (مثل مدل هندسی ساختمان) باشد [۶]. مطالعات اخیر در حیطه پردازش تصاویر فتوگرامتری و سنجش از دور نشان می‌دهد، یادگیری بازنمایی‌های ویژگی^۸ با استفاده از شبکه عصبی کانولوشنی عمیق در زمینه‌های شناسایی و استخراج عوارض دارای نتایج مطلوب و قابل اعتمادی است [۷، ۸، ۹، ۱۰، ۱۱ و ۱۲]. محورهای مهم این مطالعات اغلب شامل: اهمیت آماده‌سازی صحیح داده‌ها در بهبود نتایج الگوریتم، استفاده از داده‌های آموزشی با تعداد بالا، استفاده از یادگیری نظارت‌نشده جهت

پیش‌آموزش، طراحی یا انتخاب معماری مناسب برای شبکه عصبی عمیق با توجه به هدف اصلی مسائل، استفاده از داده‌های کمکی نظیر مدل رقومی سطح حاصل از داده‌های لایدار و همچنین به‌کارگیری شبکه‌های عصبی کانولوشنی برای ادغام باندهای تصاویر چندطیفی سنجش از دور می‌باشد.

برای طبقه‌بندی تصویر، یک راه‌حل کارآمد جهت حل مشکل در تعمیم الگوریتم‌های مختلف یادگیری ماشین استفاده از یادگیری عمیق (شبکه‌های عصبی کانولوشنی عمیق) است [۱۳ و ۱۴]. شبکه‌های عصبی کانولوشنی عمیق دارای قدرت تعمیم‌پذیری بالایی است به نحوی که قابلیت‌هایی نظیر تشخیص و شناسایی اشیا [۱۵]، استخراج ویژگی^۹ [۱۶]، تجزیه و تحلیل صداها [۱۷] و طبقه‌بندی تصاویر [۱۸] را با درصد موفقیت بالایی انجام می‌دهد. بسیاری از تحقیقات صورت گرفته در زمینه طبقه‌بندی و استخراج اشیا از تصاویر فتوگرامتری و سنجش از دور با استفاده از الگوریتم‌های یادگیری عمیق، طی شش سال اخیر صورت گرفته است. جدول (۱) به مروری بر این مطالعات پرداخته است.

با توجه به جدول (۱)، همواره مهم‌ترین دغدغه در مبحث به‌کارگیری الگوریتم‌های یادگیری عمیق در پردازش تصاویر سنجش از دور با هدف استخراج یک شیء به‌خصوص مانند ساختمان و یا بهینه‌سازی نتایج حاصل از الگوریتم‌های یادگیری عمیق می‌باشد.

⁵ Deep Learning (DL)

⁶ Artificial Intelligence (AI)

⁷ Hidden Layer

⁸ Feature Visualization

⁹ Feature Extraction

¹ LeNet

² Convolutional Neural Networks (CNNs)

³ Dueling Neural Network (DNN)

⁴ The Massachusetts Institute of Technology (MIT)

جدول ۱: مروری بر پیشینه تحقیق

پژوهشگر (سال)	زبان برنامه‌نویسی (کتابخانه)	معماری شبکه عصبی عمیق	رهیافت تحقیق
نگوین ^۱ و همکاران (۲۰۱۳)	-	$C+S+C+$ $S+C+FCO$ (TF: Tanh)	ارائه اولین مدل موفق شبکه شش لایه عمیق جهت طبقه‌بندی تصاویر سنجش از دور در شش کلاس کاربری با دقتی در حدود ۷۵ تا ۹۱ درصد و بدون انجام هرگونه پیش‌پردازش بر روی داده‌های ورودی [۱۹]
شو ^۲ (۲۰۱۴)	C++	$C+P+C+C+FCO+FCO$ (TF: ReLU+ Logistic)	استفاده از شبکه‌های عصبی کانولوشنی با هدف استخراج ساختمان، راه و پهنه‌های آبی از تصاویر سنجش از دور با قدرت تفکیک مکانی بالا با دو رویکرد پیکسل‌مبنا و شی‌مبنا [۲۰]
علی دوست ^۳ و عارفی (۲۰۱۶)	متلب (مت-کانونت و کفی)	-	ارائه روشی نوین و مدل مبنا به‌منظور استخراج ساختمان‌ها و شناسایی خودکار مدل سقف آن‌ها از قبیل سقف مسطح، شیروانی، شیب‌دار و هرمی که در آن از شبکه‌های عصبی کانولوشنی با معماری عمیق به‌منظور یادگیری سلسله‌مراتبی ویژگی‌های استخراج شده از داده‌های لایدار و تصاویر ارتوفتو استفاده شده است [۲۱]
ماسی ^۴ و همکاران (۲۰۱۶)	متلب (مت-کانونت و کفی)	$C+P+C+P+C+P$ (TF: ReLU+ ReLU+Purelin)	ارائه یک شبکه عصبی کانولوشنی به نام PNN، برای ادغام باندهای تصاویر سنجش از دور با قدرت تفکیک مکانی بالا با معماری سه لایه با تمرکز بر ادغام باندهای تصاویر GeoEye-1، IKONOS و WorldView-2 [۲۲]
بیتنر ^۵ و همکاران (۲۰۱۷)	پایتون (کفی)	$C+C+P+C+C+P+$ $C+C+C+P+C+C+$ $C+P+C+C+C+P+$ $FCN+DP+FCN+$ $DP+C+Decn+SK+$ $Decn+SK+Decn+$ $SM+LS$ (TF: ReLU)	استخراج خودکار ساختمان از مدل رقومی سطح نرمال شده حاصل از زوج تصویر WorldView-2 با استفاده از شبکه عصبی تماماً کانولوشنی و بررسی قابلیت‌های معماری پیشنهادی در مقایسه با تلفیق شبکه عصبی تماماً کانولوشنی - میدان تصادفی شرطی و تلفیق شبکه عصبی چهار لایه - میدان تصادفی مارکوفی [۲۳]

¹ Nguyen² Shu³ Alidoost⁴ Masi⁵ Bittner

<p>ارائه یک نمونه شبکه عصبی کانوولوشنی کارآمد بر اساس معماری کدگذار - کدگشا برای قطعه‌بندی تصویر به نام سیگنت با قابلیت قطعه‌بندی تصاویر مختلف و توانایی بالا در استخراج اشیا با جزئیات زیاد و پیچیده [۲۴]</p>	$C+BN+C+BN+P+ \\ C+BN+C+BN+P+ \\ C+BN+C+BN+C+ \\ BN+P+C+BN+C+ \\ BN+C+BN+P+C+ \\ BN+C+BN+C+BN+ \\ P+UP+ C+BN+C+ \\ BN+C+BN+UP+ \\ C+BN+C+BN+C+ \\ BN+UP+C+BN+C+ \\ BN+C+BN+UP+ \\ C+BN+C+BN+UP+ \\ C+BN+C+BN+SM \\ (TF: ReLU)$	<p>پایتون (کفی)</p>	<p>بدرینارایانان^۱ و همکاران (۲۰۱۷)</p>
<p>استخراج ساختمان از تصاویر هوآبرد با قدرت تفکیک مکانی بالا با ارائه معماری جدیدی بر اساس یادگیری عمیق و بهینه‌سازی نتایج به دست آمده با استفاده از فیلترهای هدایتی مبتنی بر ارتقاء کارایی شبکه عمیق رز نت با نام رز-یونت [۶]</p>	$Res-U-Net = EC+BD+DC \\ RN=C+BN+C+AD \\ EC=RN(1)+RN(2)+RN(3)+ \\ RN(4) \\ BD=BN+C+BN+C+AD \\ DC=UP+RN(4)+UP+ \\ RN(3)+UP+RN(2)+RN(1)+C \\ (TF: ReLU)$	<p>پایتون (تنسورفلو و کراس)</p>	<p>ژو و همکاران^۲ (۲۰۱۸)</p>
<p>قطعه‌بندی خودکار ساختمان در تصاویر هوایی با استفاده از شبکه‌های عصبی کانوولوشنی چند قیدی. این مدل بر پایه شبکه یونت بنا شده است و قیود به صورت چند مقیاس بین لایه‌های نمونه افزا به نحوی که به واقعیت زمینی مرتبط شود قرار می‌گیرد [۲۵]</p>	$C+BN+C+BN+MP+UP+ \\ SK+C+BN+C+BN \\ (TF: ReLU)$	<p>-</p>	<p>وو و همکاران^۳ (۲۰۱۸)</p>
<p>اختصارات معماری شبکه‌های عصبی عمیق: C: لایه کانوولوشنی؛ S: لایه نمونه‌بردار؛ FCO: لایه تماماً متصل؛ TF: تابع فعال‌ساز؛ P: لایه کاهش ابعاد؛ FCN: لایه تماماً کانوولوشنی؛ DP: لایه حذف تصادفی اتصالات شبکه؛ Decn: لایه معکوس کانوولوشنی؛ SK: لایه پُرش؛ SM: لایه تبدیل توزیع احتمال کلاس‌ها؛ LS: خطای شبکه؛ UP: لایه نمونه افزا؛ BN: لایه نرمال‌ساز خروجی‌ها؛ RN: شبکه باقی‌مانده؛ AD: لایه جمع باقی‌مانده‌ها؛ EC: شبکه کدگذار؛ BD: شبکه ارتباطی کدگذار و کدگشا؛ DC: شبکه کدگشا؛ MP: لایه کاهش ابعاد پیشینه</p>			

و منجر می‌شود تا نتایج هرچند ناخواسته دچار نقص شوند؛ به همین علت نوآوری‌های تحقیق حاضر در قالب دو عنوان مورد بحث است که عبارت‌اند از:

۱- بهینه‌سازی فرآیند آموزش معماری یادگیری عمیق در استخراج ساختمان از تصاویر نوری هوایی که در

برای حل مسئله استخراج ساختمان اغلب تحقیقات صرفاً با ادغام برخی روش‌های بهبوددهنده خودکار لبه (مانند فیلترهای هدایتی) در پس‌نتیجه الگوریتم یادگیری عمیق استفاده کرده‌اند، اما استفاده از روش‌های خودکار، خود عاملی برای عدم کنترل لازم بر روی نتایج می‌باشد

¹ Badrinarayanan

² Xu

³ Wu

فرآیند کار این نوع از شبکه‌های عصبی عمیق پرداخته شده است. پایه شبکه‌های عصبی مصنوعی اولیه، پرسپترون است که جزء شبکه‌های پیشرو به شمار می‌آید [۲۷]. شبکه‌های عصبی کانولوشنی نوع خاصی از شبکه‌های عصبی عمیق پیشرو^۳ هستند [۲۸]. از جمله ویژگی‌های این شبکه‌ها عبارت است از:

الف) وجود ارتباط محلی بین نورون‌ها، در شبکه‌های عصبی کانولوشنی به جای متصل بودن نورون‌ها به تمام نورون‌های قبل از خود، تنها به ناحیه‌ای کوچک از داده ورودی (تصویر چند بانندی) متصل است. نکته مهم در این شبکه‌ها این است که اتصالات علاوه بر اینکه طول و عرض (سطح تصویر) را پردازش می‌کنند، بُعد سوم یعنی باندهای تصویر را نیز مورد پردازش قرار می‌دهند، به همین دلیل این شبکه‌ها برای پردازش تصاویر چند طیفی بسیار مورد توجه هستند؛

ب) وجود وزن‌های مشترک در هر لایه، جهت کنترل تعداد پارامترهای مورد استفاده در لایه‌های کانولوشنی از وزن‌های مشترک در هر لایه استفاده می‌شود. در عمل بهره‌گیری از چنین ویژگی، موجب کاهش تعداد پارامترها در شبکه می‌شود؛

پ) بهره‌گیری از تعداد زیادی لایه مخفی؛ که موجب افزایش تولید ویژگی‌های جدید از پایین‌ترین سطح ویژگی مثل لبه‌ها تا بالاترین سطح ویژگی مثل مدل‌های هندسی می‌شود.

ت) به کارگیری لایه کاهش ابعاد^۴، استفاده از لایه کاهش ابعاد در بین لایه‌های کانولوشنی می‌تواند موجب کاهش اندازه مکانی (طول و عرض) داده‌های ورودی و در نهایت منجر به کاهش پارامترهای شبکه شود. استفاده از این لایه‌ها قابلیت کنترل بر بیش‌برازش داده‌ها را به شبکه می‌دهد [۲۹]. در شبکه‌های عصبی کانولوشنی عمیق مجموع داده‌های ورودی وزن‌دار در هر لایه از تابعی غیرخطی عبور می‌کند. خروجی این مرحله همان

بسیاری از روش‌ها این موضوع نادیده گرفته شده است (بخش ۲-۲).

۲- بهبود نتیجه یادگیری عمیق با یک پردازش مکمل کنترل‌شده که در این تحقیق فیلتر دو طرفه موردنظر است. فیلتر دو طرفه با قابلیت توأمان حذف نویز و بهبود لبه می‌تواند نقایص آموزش یادگیری عمیق ناشی از اشکالات دستگاهی و یا داده‌ها را به میزان قابل‌توجهی بهبود دهد (بخش ۳-۳) [۲۶]. این تحقیق با هدف استخراج ساختمان از تک تصویر نوری رنگی با تلفیق الگوریتم‌های یادگیری عمیق و فیلترهای دو طرفه نگارش یافته است. به همین منظور، در مرحله آماده‌سازی داده‌ها، مجموعه داده موردنظر به دو دسته داده‌های آموزشی و داده‌های تست تقسیم می‌شوند. در مرحله بعد، شبکه عمیق سگنت^۱ برای انجام فرآیند استخراج ساختمان آموزش داده می‌شود. لازم به ذکر است که در این مرحله برای بهینه‌سازی شبکه از تابع بهینه‌سازی برآورد لحظه تطبیقی^۲ استفاده شده است. در نهایت با استفاده از فیلتر دو طرفه با کرنل گوسین که دارای قابلیت‌های بسیار مناسبی جهت بهبود لبه‌های اشیا است. نتایج به دست آمده از شبکه عصبی عمیق بهینه‌سازی می‌شوند و پس از آن نتایج حاصل از روش پیشنهادی با نتایج شبکه عمیق سگنت قبل و بعد از اعمال فیلتر دو طرفه با بهره‌گیری از داده‌های واقعیت زمینی مورد ارزیابی قرار می‌گیرد.

۲- مبانی نظری

در این قسمت، ابتدا شبکه‌های عصبی کانولوشنی عمیق معرفی می‌شوند. سپس روند بهینه‌سازی شبکه‌های عصبی کانولوشنی عمیق بیان می‌شود و در نهایت فیلتر دو طرفه معرفی می‌گردد.

۲-۱- شبکه‌های عصبی کانولوشنی عمیق

با توجه به اهمیت زیاد شناخت تئوری شبکه‌های عصبی کانولوشنی در این تحقیق، در این قسمت به مرور کلی

⁴ Local Connectivity

⁵ Pooling

¹ SegNet

² Adaptive Moment Estimation (ADAM)

³ Deep Feedforward Networks

پایین می‌آید در نظر بگیریم، روش بهینه‌ساز برآورد لحظه تطبیقی همچون یک توپ سنگین است که با سطح اصطکاک دارد، به عبارت دیگر الگوریتم‌های بهینه‌ساز با هدف کمینه کردن تابع زیان، کار می‌کنند. روش برآورد لحظه تطبیقی در سطح خطا، مینیمم‌های صاف (در مقابل مینیمم‌های تیزتر) را در نظر می‌گیرد [۳۲].

بر مبنای محاسبات انجام‌شده در این تحقیق به کارگیری بهینه‌ساز برآورد لحظه تطبیقی نرخ همگرایی را بهبود می‌دهد. پارامترهای بهینه‌ساز برآورد لحظه تطبیقی مشتمل بر η نرخ یادگیری، β_1 ترم تأخیری میانگین گرادیان، β_2 ترم تأخیری میانگین مربعات گرادیان، θ بردار پارامترها، $f(\theta)$ تابع هدف تصادفی بر مبنای θ و پارامتر ε که جهت جلوگیری از میل به صفر کردن مقدار بردار پارامترها در هر مرحله به‌روزرسانی تعریف می‌شود. قانون به‌روزرسانی بردار پارامترها (وزن و بایاس شبکه) به صورت رابطه (۱) تعریف می‌شود.

$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{\hat{v}_t} + \varepsilon} \hat{m}_t \quad \text{رابطه (۱)}$$

در رابطه (۱) مقدار \hat{m}_t برآورد مقدار حرکت در لحظه اول (میانگین) و مقدار \hat{v}_t برآورد مقدار حرکت در لحظه دوم (توزیع غیر مرکزی واریانس) می‌باشد، که به صورت رابطه (۲) و (۳) محاسبه می‌شوند.

$$\hat{m}_t = \frac{m_t}{1 - \beta_1^t} \quad \text{رابطه (۲)}$$

$$\hat{v}_t = \frac{v_t}{1 - \beta_2^t} \quad \text{رابطه (۳)}$$

در عمل مقادیر \hat{m}_t و \hat{v}_t نقش تصحیح بایاس‌ها در بردار پارامترها را دارند. مقادیر m_t و v_t به ترتیب برابر میانگین گرادیان و میانگین مربعات گرادیان می‌باشند. که با استفاده از رابطه (۴) و (۵) تعریف می‌شوند.

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t \quad \text{رابطه (۴)}$$

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2 \quad \text{رابطه (۵)}$$

مقادیر پیشنهادی در یک پژوهش برای β_1 ، β_2 ، ε برابر با 0.9 ، 0.999 و 10^{-8} در نظر گرفته می‌شود که مقادیر مناسبی می‌باشند [۳۲].

ویژگی‌های استخراج‌شده از داده‌های ورودی می‌باشد. در این شبکه‌ها مجموعه‌ای از لایه‌های کانولوشنی در کنار تعداد لایه چگال با اتصال کامل، کار استخراج ویژگی و طبقه‌بندی را انجام می‌دهند و فرآیند به‌روزرسانی وزن‌ها نیز همانند دیگر شبکه‌های عصبی مبتنی بر قاعده بازگشتی می‌باشد. در شبکه‌های عصبی کانولوشنی مسئله کاهش سرعت آموزش شبکه از جمله موارد مهم بشمار می‌رود، که دلیل آن هم تغییر پارامترها در طول عبور از لایه‌های مختلف می‌باشد. از جمله راهکارهای مناسب جهت حل مشکل کند بودن سرعت آموزش استفاده از روش حذف تصادفی توصیه شده است. که در این روش نتیجه برخی از نورون‌ها به صورت تصادفی از فعالیت آموزش حذف می‌شود که موجب عدم وابستگی زیاد مدل به داده‌های آموزشی می‌شود.

۲-۲- بهینه‌سازی شبکه عصبی کانولوشنی عمیق با استفاده از الگوریتم برآورد لحظه تطبیقی

در شبکه‌های عصبی بهینه‌سازی پارامترهای وزن و بایاس شبکه از جمله موضوعات بسیار مورد اهمیت است. الگوریتم‌های یادگیری عمیق اغلب با به کارگیری روش‌های مختلف نظیر گرادیان نزولی، بهینه‌سازی می‌شود. هدف روش‌های بهینه‌سازی، بهبود عملکرد آموزش یادگیری الگوریتم (همگرایی) به واسطه آزمون و خطای شبکه در طی فرآیند یادگیری است. همچنین جهت به‌روزرسانی پارامترهای شبکه نظیر وزن و بایاس نیز مورد استفاده قرار می‌گیرند. لازم به ذکر است که فرآیند انجام بهینه‌سازی در هر بار دوره تکرار مشتمل بر: (۱) محاسبه خطای مدل طراحی‌شده؛ (۲) محاسبه گرادیان‌ها (g_t)؛ (۳) اعمال روش بهینه‌سازی جهت به‌روزرسانی پارامترهای مدل با استفاده از گرادیان‌ها؛ (۴) انتقال مقادیر اولیه وزن‌ها با توجه به نرخ یادگیری و الگوریتم مورد استفاده جهت بررسی وضعیت بهینه‌سازی مدل می‌باشد [۳۰].

الگوریتم برآورد لحظه تطبیقی، روشی بر مبنای گرادیان جهت بهینه‌سازی پارامترهای مدل است [۳۱]. اگر مقدار حرکت را همانند یک توپی که از یک سطح شیب‌دار به

لحظه تطبیقی استفاده شده است. فرآیند پیاده‌سازی این الگوریتم با زبان متلب توسط تابع زیر صورت گرفته است.

در این پژوهش، جهت بهینه‌سازی پارامترها و فرآیند آموزش و تست مدل عمیق سیگنت از الگوریتم برآورد

الگوریتم برآورد لحظه تطبیقی

Function $[w, state] = adam(teta, state, grad, opts, lr)$

1. if nargin == 0 % Returns the default solver options
2. $w = struct('beta1', 0.9, 'beta2', 0.999, 'eps', 1e-8);$
3. return;
4. end
5. if isequal(state, 0) % start off with state = 0 so as to get default state
6. $state = struct('m', 0, 'v', 0, 't', 0);$
7. end
8. $state.m = opts.beta1 * state.m + (1 - opts.beta1) * grad;$ % update first moment vector `m`
9. $state.v = opts.beta2 * state.v + (1 - opts.beta2) * grad.^2;$ % update second moment vector `v`
10. $state.t = state.t + 1;$ % update the time step
11. $lr_t = lr * (((1 - opts.beta2^{state.t})^{0.5}) / (1 - opts.beta1^{state.t}));$ % biased estimates of first and second moment vectors
12. $teta_t+1 = teta_t - lr_t * state.m. / (state.v.^{0.5} + opts.eps);$ % Update teta

وزن‌ها فقط بر اساس فاصله‌ی اقلیدسی تعیین نمی‌شوند، بلکه تفاوت‌های رادیومتریکی نیز در آن تأثیرگذار است. این فیلتر با تنظیم کردن وزن‌های پیکسل‌های همسایه در یک حلقه به‌صورت سامانمند، لبه‌های تیز تصاویر را حفظ می‌کند [۳۳ و ۳۴]. فیلتر دو طرفه به‌صورت رابطه (۶) و رابطه تبدیل نرمال به‌صورت رابطه (۷) تعریف می‌شود.

$$Im^{filtered} = \frac{1}{W_p} \sum_{x_i \in \Omega} Im(x_i) f_r(|Im(x_i) - Im(x)|) g_s(|x_i - x|) \quad \text{رابطه (۶)}$$

$$W_p = \sum_{x_i \in \Omega} f_r(|Im(x_i) - Im(x)|) g_s(|x_i - x|) \quad \text{رابطه (۷)}$$

در این تحقیق از فیلتر دو طرفه برای بهینه‌سازی خروجی پردازش با الگوریتم یادگیری عمیق استفاده شده است. با توجه به شکل (۱) با فرض ثابت بودن ابعاد کرنل (در این تحقیق از ابعاد ۹×۹ استفاده شده است)، با اعمال مقادیر مختلف بر روی نتیجه به دست آمده از پردازش الگوریتم یادگیری عمیق پیشنهادی تحقیق، مقدار بهینه برای تابع گوسین در حیطه مکان (g_s) برابر ۸ و مقدار بهینه برای تابع گوسین در حیطه دامنه (f_r) برابر ۰٫۰۵،

۲-۳- فیلترهای دو طرفه

فیلتر دو طرفه^۱ یک فیلتر غیرخطی ملایم ساز با حفظ لبه و کاهش نویز برای تصاویر است. در این فیلتر، میزان شدت هر پیکسل با میانگین وزن‌دار پیکسل‌های همسایه جایگزین می‌شود که این وزن می‌تواند بر اساس توزیع نرمال گوسین باشد. نکته مهم در این فیلتر آن است که

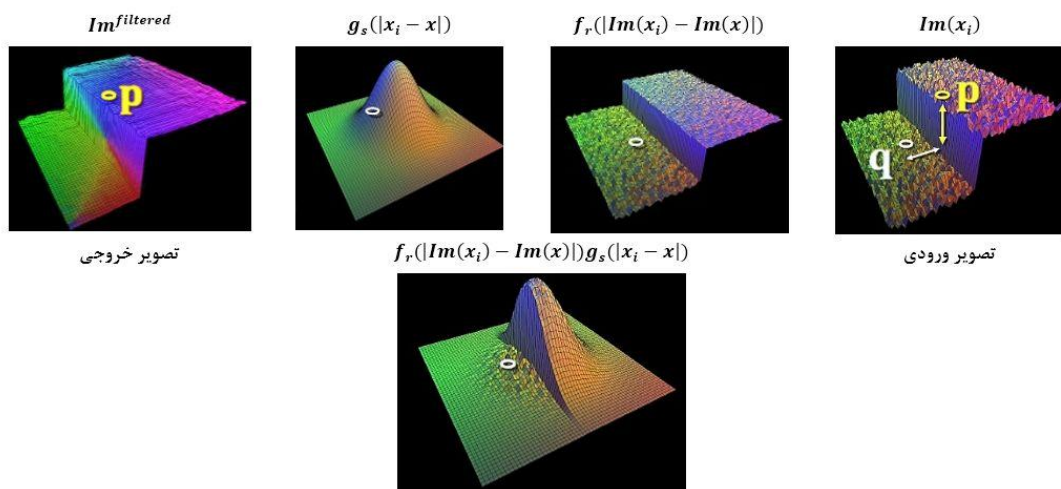
در رابطه (۶) و (۷)، Im ، W_p ، $Im^{filtered}$ ، f_r و g_s به ترتیب برابر تصویر فیلتر شده، تبدیل نرمال، تصویر ورودی، مختصات مرکزی فیلتر، کرنل به مرکزیت x تابع کرنل برای نرم کردن تفاوت‌های شدت نقاط، تابع کرنل برای نرم کردن موقعیت نقاط، لازم به ذکر است که در تحقیق حاضر از تابع گوسین به عنوان تابع کرنل f_r و g_s استفاده شده است [۳۵]. شکل (۱) جزئیات تأثیر فیلتر دو طرفه بر روی یک تصویر را نشان می‌دهد.

¹ Bilateral Filter (BF)

موردنظر به‌عنوان ورودی، محاسبه فاصله گوسی بر اساس موقعیت مرکز فیلتر بر روی تصویر (X, Y) ، استخراج ناحیه محلی بر مبنای تبدیل نرمال و در نهایت فیلتر کردن تصویر بر اساس مقادیر محاسبه‌شده با تلفیق در حیطه مکان و دامنه می‌باشد.

بهترین نتایج را برای بهبود لبه‌های ساختمان‌های استخراج‌شده ارائه می‌دهند. لازم به ذکر است که افزایش ابعاد کرنل موجب پدید آمدن آثار مخرب روی تصویر می‌شود و همچنین اگر ابعاد کرنل کوچک انتخاب شود نتیجه مطلوب نخواهد بود [۳۶].

فرآیند پیاده‌سازی فیلتر دو طرفه بر اساس شبه کد زیر، مشتمل بر تعریف پارامترهای فیلتر دو طرفه و تصویر



شکل ۱: اعمال فیلتر دو طرفه روی تصویر (p) و (q) متناظر با همان مختصات مرکزی فیلتر x در رابطه (۶) می‌باشند [۳۶]

الگوریتم فیلتر دو طرفه

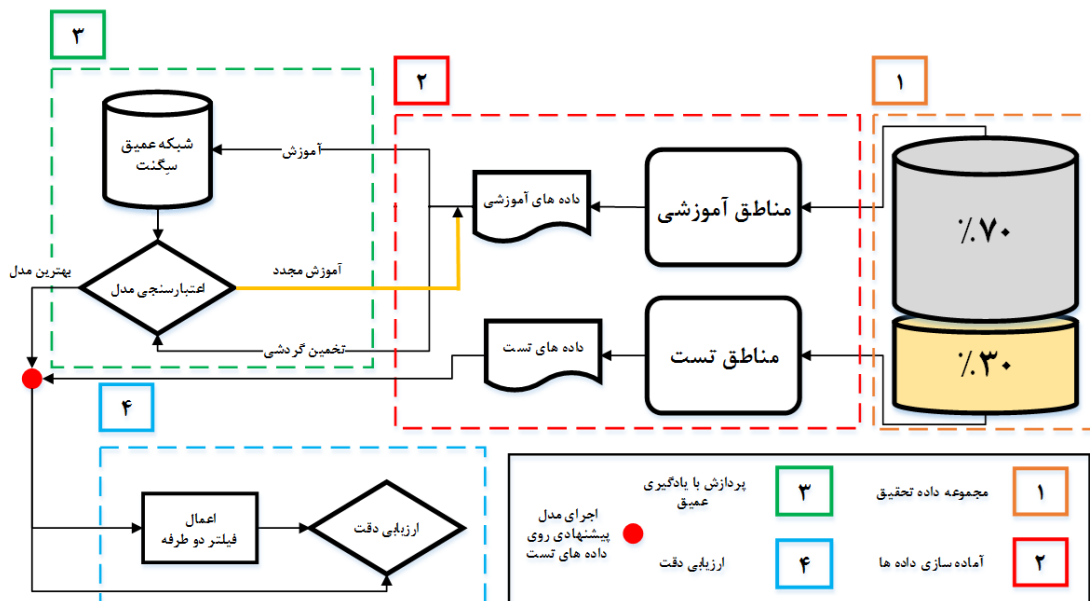
```
Bilateral_Filter (Im, w_p, g_s, f_r) % Bilateral filter Parameters
1. Obtain [X,Y] = meshgrid(-w_p: w_p, -w_p: w_p) % Pre-compute Gaussian Distance Weights
2. G = exp(-(X.^2+Y.^2)/(2* g_s ^2)) %Compute the Gaussian Distance Weights
3. dim = size(Im) % Apply Bilateral Filter
4. B = zeros(dim)
5. Repeat for i = 1:dim (1)
6. Repeat for j = 1: dim (2)
7. iMin = max (i- w_p,1) % Extract Local Region
8. iMax = min(i+ w_p,dim(1))
9. jMin = max(j- w_p,1)
10. jMax = min(j+ w_p,dim(2))
11. I = Im (iMin:iMax,jMin:jMax)
12. H = exp (-(I- Im (i,j)).^2/(2* f_r ^2))
13. F = H.*G((iMin:iMax)-i+ w_p +1,(jMin:jMax)-j+ w_p +1) % Calculate Bilateral Filter Response
14. B(i,j) = sum(F(:).*I(:))/sum(F(:))
15. end
16. end
```

۳- روش تحقیق

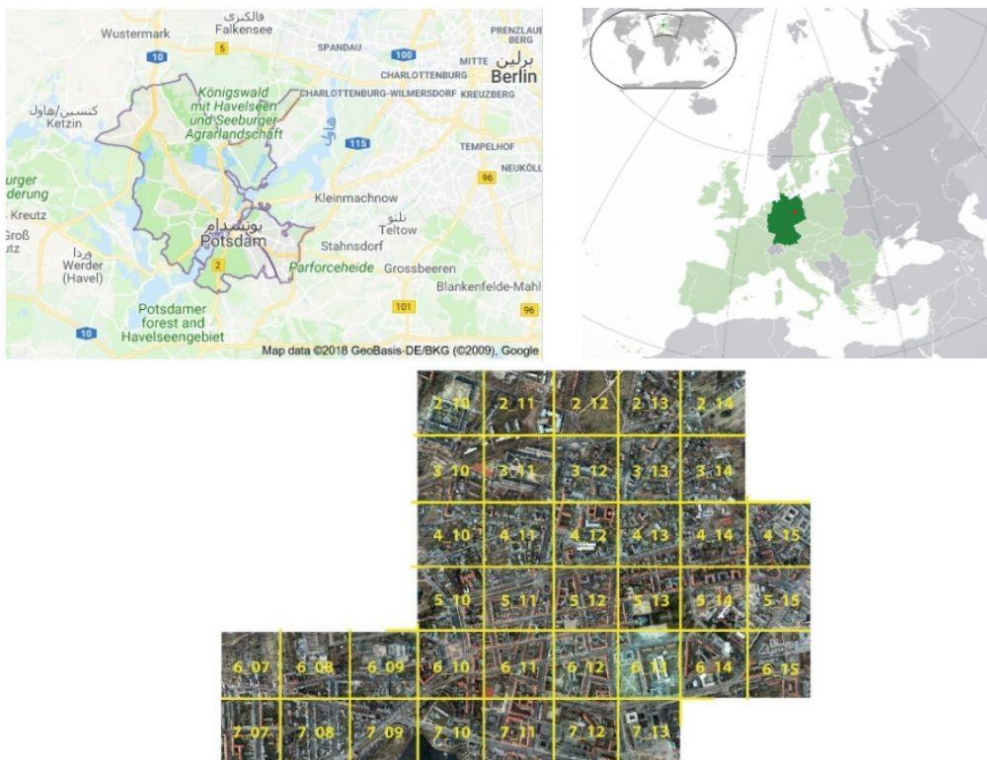
با توجه به شکل (۲)، این تحقیق در چهار مرحله پیاده‌سازی و مورد ارزیابی قرار گرفته است. مرحله اول، شامل تهیه مجموعه تصاویر نوری رنگی هوآبرد با قدرت تفکیک مکانی بالا است. مرحله دوم، شامل آماده‌سازی، تقسیم و استخراج نمونه‌های آموزشی و تست برای اجرای بهتر مدل مورد نظر می‌باشد. مرحله سوم، شامل طراحی و بهینه‌سازی شبکه عصبی عمیق سیگنت است که با استفاده از نمونه‌های آموزشی مرحله قبل، آموزش می‌بیند و پس از انجام مرحله اعتبارسنجی، با استفاده از داده‌های تست ارزیابی می‌شود. در مرحله چهارم نتیجه به دست آمده از روش پیشنهادی با نتایج حاصل از روش‌های $Res-U-Net+GF$ [۶]، الگوریتم پایه سیگنت $CNN+RF+CRF$ [۳۷] و $CNN+RF$ [۹]، FCN [۲۴]، با استفاده از نقشه‌های واقعیت زمینی و برمبنای معیارهای ارزیابی دقت مورد بررسی قرار می‌گیرند.

۳-۱- مجموعه داده تحقیق

شکل (۳) مجموعه داده مورد استفاده در این تحقیق مربوط به تصاویر نوری رنگی هوآبرد با قدرت تفکیک مکانی بالا از مناطق شهری واقع در شهر پوتسدام آلمان از مجموعه داده‌های دو بعدی برچسب‌دار انجمن بین‌المللی فتوگرامتری و سنجش از دور^۱ را نشان می‌دهد [۳۸]. تصاویر مورد استفاده شامل سه باند قرمز، سبز و آبی با قدرت تفکیک مکانی ۵ سانتی‌متر می‌باشد. این مجموعه داده شامل ۳۸ تصویر قائم که هرکدام از این تصاویر دارای ابعاد 6000×6000 پیکسل به همراه داده‌های واقعیت زمینی برچسب دار می‌باشد. از این داده‌های در چندین تحقیق اخیر در حیطه یادگیری عمیق برای آموزش و تست الگوریتم‌های مختلف استفاده شده است [۶، ۳۹، ۴۰ و ۴۱].



شکل ۲: الگوریتم پیشنهادی تحقیق



شکل ۳: منطقه مورد مطالعه (شکل بالا از راست به چپ: موقعیت کشور آلمان (سبز پررنگ) در میان کشورهای اتحادیه اروپا (سبز کم‌رنگ) و سایر کشورهای هم‌جوار (خاکستری) [۴۲ و ۴۳]، موقعیت شهر پوتسدام در میان شهرهای مجاور؛ شکل پایین: ترتیب بلوک‌های عکس‌برداری از شهر پوتسدام)

۳-۲- آماده‌سازی داده‌ها

با توجه به حجم بالای تصاویر و عدم امکان پردازش تمامی این مجموعه داده به علت محدودیت‌های سخت‌افزاری، در این تحقیق از هشت بلوک (جدول (۲)) برای آموزش شبکه که ده درصد از این داده‌ها برای اعتبارسنجی مدل مورد استفاده قرار می‌گیرد و از سه بلوک برای تست شبکه استفاده شده است. این بلوک‌ها با در نظر گرفتن اینکه در برگیرنده مناطق ساختمانی

بیشتر و متنوع‌تری (از نظر هندسه و نوع سقف) باشد در نظر گرفته شده است. همچنین جهت بهبود عملکرد شبکه، هر یک از بلوک‌ها به تصاویری با ابعاد 128×128 تقسیم می‌شوند. علاوه بر آن، مناطق ساختمان و غیرساختمان در واقعیت زمینی به وسیله ماسک‌کردن ساختمان‌ها از سایر کلاس‌ها جدا شدند و سپس مورد استفاده قرار گرفتند.

جدول ۲: تعداد و شماره بلوک‌های مناطق آموزشی و تست

تعداد	شماره بلوک‌ها (ردیف)	
۸ بلوک	۱۰ و ۱۲ (۳) - ۱۰ و ۱۱ (۴) ۱۱ و ۱۲ (۵) - ۰۸ و ۰۹ (۶)	مناطق آموزشی
۳ بلوک	۱۰ (۲) - ۰۸ (۶) - ۱۱ (۷)	مناطق تست


گرافیک *GeForce GTX 550 Ti* صورت گرفته است. شکل (۵) معماری شبکه سیگنت و فرآیند پردازش و قطعه‌بندی تصویر را نشان می‌دهد. در این معماری با حذف لایه تماماً متصل در سراسر شبکه و استفاده از لایه‌های کانوولوشنی (آبی)، و بهره‌گیری از لایه‌های کدگذار و کدگشا فرآیند قطعه‌بندی تصویر انجام می‌شود. در این شبکه جهت بهبود نتایج مرحله کدگذاری از لایه نرمال‌ساز خروجی‌ها^۱ استفاده شده است، همچنین تابع فعال‌ساز در این شبکه تابع رلو می‌باشد. بهره‌گیری از لایه‌های نمونه افزا در مقابل لایه‌های کاهش ابعاد، نیز ایده دیگر این معماری می‌باشد.

به دلیل هزینه محاسباتی بالا در به‌کارگیری یک تصویر با ابعاد بزرگ به‌صورت یکجا در فرآیند آموزش، موضوع تقسیم‌بندی داده آموزشی و ارائه یک برنامه تغذیه از داده آموزشی برای آموزش الگوریتم یادگیری عمیق بسیار مورد اهمیت است. به همین منظور با تست‌های جزئی توان پردازش سیستم مورد استفاده آزمایش گردید و در نهایت تقسیم‌بندی داده‌ها با ابعاد سطحی 128×128 فرآیند را تسریع بخشید و روند پیاده‌سازی را سهل‌تر ساخت. شکل (۴) سلسله‌مراتب استخراج ویژگی در لایه‌های کانوولوشن و لایه کاهش ابعاد بر روی یک قطعه تصویر رنگی با ابعاد $3 \times 128 \times 128$ را نشان می‌دهد. شکل (۴) روند پردازش بر روی تصویر ورودی با استفاده از لایه کانوولوشنی و لایه کاهش ابعاد را نشان می‌دهد. در لایه کانوولوشنی با جاروب کردن تصویر در هر باند توسط فیلتر با ابعاد مشخص (با توجه به جدول (۳) در این تحقیق ابعاد فیلترها 3×3 است) و سپس استفاده از لایه کاهش ابعاد تصویر کاهش می‌یابد (همان‌طور که مشخص است همه لایه‌ها به یکدیگر متصل نیستند) و در یک بردار ویژگی جدید جمع می‌شوند. این روند با توجه به عمق شبکه (تعداد لایه‌های مخفی) ادامه می‌یابد.

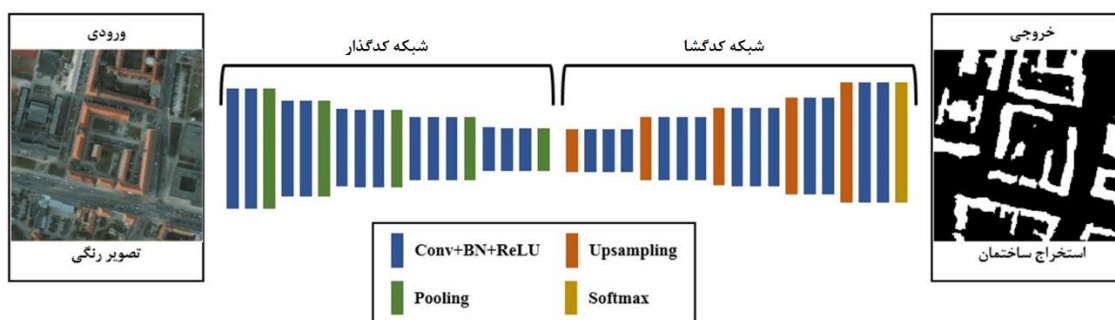
۳-۳- پردازش با الگوریتم‌های یادگیری عمیق

در این تحقیق برای انجام فرآیند استخراج ساختمان از تصاویر هوآبرد با قدرت تفکیک مکانی بالا از معماری سیگنت استفاده شده است [۲۴]. علت استفاده از این معماری، قابلیت بالای استخراج لبه‌ها و همچنین تشخیص اشیا با جزئیات پیچیده و سازگاری با تصاویر رنگی به‌عنوان ورودی شبکه است [۴۴ و ۴۵]. این معماری عمیق در محیط نرم‌افزار متلب ۲۰۱۷ و با استفاده از جعبه‌ابزار مت-کانو-نت طراحی و بر روی مجموعه داده تحقیق اجرا شده است. کلیه فرآیند پردازش اعم از آموزش و تست مدل و اعمال فیلتر دو طرفه، در این تحقیق مبتنی بر پردازش بر روی کارت

^۱ Batch Normalisation (BN)



شکل ۴: فرآیند سلسله مراتبی استخراج ویژگی با استفاده از شبکه های عصبی کانولوشنی عمیق





شکل ۵: معماری شبکه سگنت (نتیجه داده تست سه، بدون اعمال فیلتر دو طرفه)

تا شبکه در تعداد تکرار زیاد آموزش داده شود و پارامترهای آن با استفاده از بهینه‌ساز برآورد لحظه تطبیقی تنظیم گردد. شکل (۶) تغییرات دقت را بر روی مجموعه داده تحقیق با افزایش تعداد تکرار نشان می‌دهد. بهترین مدل در تکرار ۷۹ به دست آمده است. پس از استخراج ساختمان با استفاده از شبکه عصبی عمیق سیگنت، لازم است تا فیلتر دو طرفه به نتیجه اعمال شود تا خروجی موردنظر تحقیق به دست آید، که به آن *SegNet+BF* می‌گوییم. مجموعه نتایج به دست آمده بر روی سه تصویر تست با نتایج روش‌های *Res-U-CNN+RF* و *Net+GF*، الگوریتم پایه *SegNet*، *FCN*، *CNN+RF* و *CNN+RF+CRF* مورد مقایسه و ارزیابی قرار گرفته است. شکل (۷) نتیجه این مقایسه را به صورت بصری نمایش می‌دهد.

در هر یک از قسمت‌های این شبکه فرآیند کار به این صورت است که بردارهای ویژگی استخراج شده از لایه‌ی قبل، به پنجره‌های مجزا از هم تقسیم می‌شوند و بیشترین مقدار موجود در این پنجره محاسبه شده و به‌عنوان مقدار در بردار ویژگی جدید انتخاب می‌شود. لایه‌های نمونه افزایشی شبکه‌های تماماً کانولوشنی یادگیری را با معکوس کانولوشن از بردار ویژگی ورودی انجام می‌دهند و سپس به بردار ویژگی کدگذاری شده اضافه می‌شوند و خروجی لایه کدگشا را تولید می‌کنند. این بردار خروجی از شاخص کاهش ابعاد بیشینه^۱ (که شامل لایه نمونه افزایشی نیز می‌شود) در لایه کدگذار متناظر است.

در جدول (۳) جزئیات مربوط به پارامترهای هر یک از لایه‌ها در این شبکه عمیق، نشان داده شده است. برای رسیدن به دقت بالا و همگرا شدن شبکه، لازم است

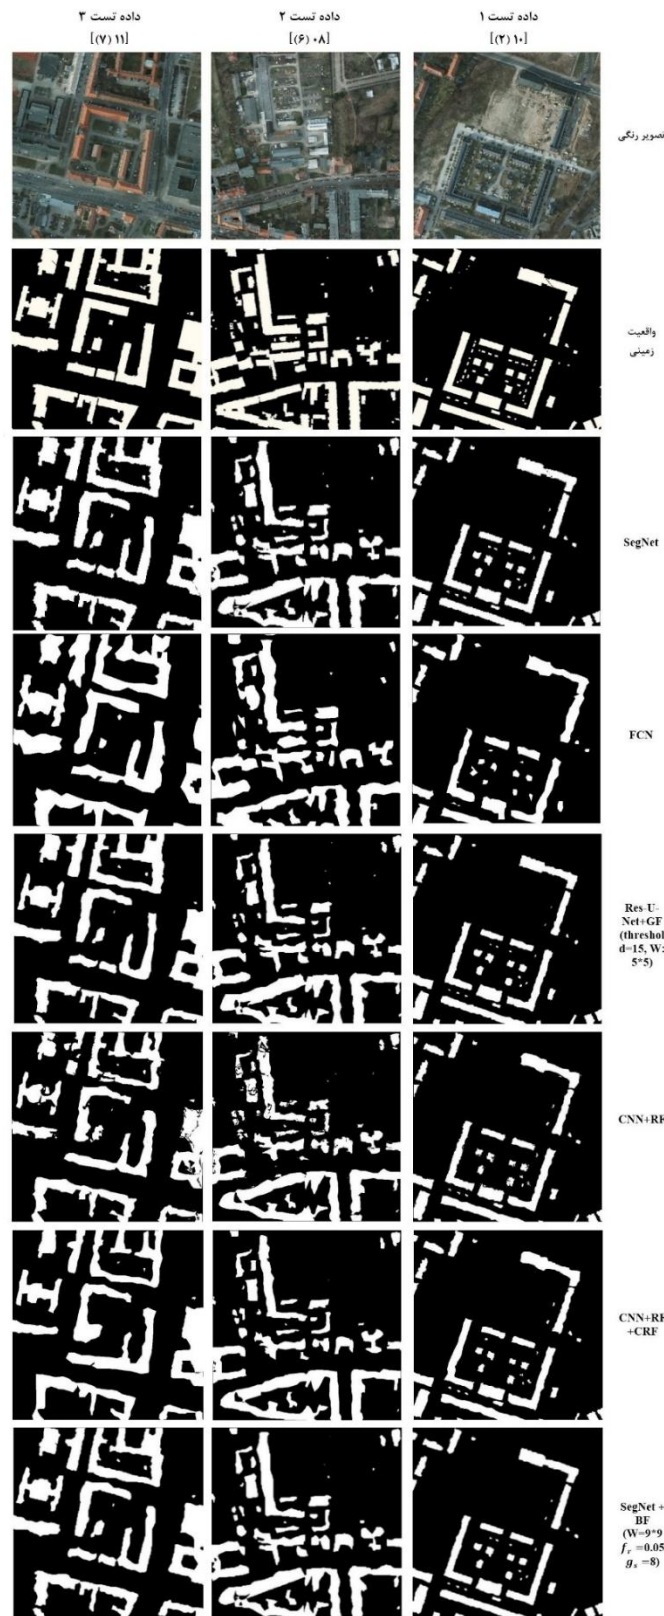


شکل ۶: منحنی تکرار بر روی مجموعه داده تحقیق با استفاده از روش پیشنهادی، محور افقی: تعداد تکرار، محور عمودی: اختلاف اندازه‌گیری‌ها. شکل راست: خطای آموزش و خطای اعتبارسنجی در ۷۹ تکرار (بهترین مدل برای مجموعه داده تحقیق)، شکل چپ: منحنی دقت آموزش مدل

^۱ Max-pooling

جدول ۳: جزئیات معماری شبکه سگنت پیشنهادی در این تحقیق

داده ورودی	ابعاد کرنل	گام	بردار ویژگی
<i>Conv1_1+BN1_1+ReLU1_1</i>	۳×۳	۱	۶۴
<i>Conv1_2+BN1_2+ReLU1_2</i>	۳×۳	۱	۶۴
<i>Pool1 (Max_Pooling)</i>	۲×۲	۲	
<i>Conv2_1+BN2_1+ReLU2_1</i>	۳×۳	۱	۱۲۸
<i>Conv2_2+BN2_2+ReLU2_2</i>	۳×۳	۱	۱۲۸
<i>Pool2 (Max_Pooling)</i>	۲×۲	۲	
<i>Conv3_1+BN3_1+ReLU3_1</i>	۳×۳	۱	۲۵۶
<i>Conv3_2+BN3_2+ReLU3_2</i>	۳×۳	۱	۲۵۶
<i>Conv3_3+BN3_3+ReLU3_3</i>	۳×۳	۱	۲۵۶
<i>Pool3 (Max_Pooling)</i>	۲×۲	۲	
<i>Conv4_1+BN4_1+ReLU4_1</i>	۳×۳	۱	۵۱۲
<i>Conv4_2+BN4_2+ReLU4_2</i>	۳×۳	۱	۵۱۲
<i>Conv4_3+BN4_3+ReLU4_3</i>	۳×۳	۱	۵۱۲
<i>Pool4 (Max_Pooling)</i>	۲×۲	۲	
<i>Conv5_1+BN5_1+ReLU5_1</i>	۳×۳	۱	۱۰۲۴
<i>Conv5_2+BN5_2+ReLU5_2</i>	۳×۳	۱	۱۰۲۴
<i>Conv5_3+BN5_3+ReLU5_3</i>	۳×۳	۱	۱۰۲۴
<i>Pool5 (Max_Pooling)</i>	۲×۲	۲	
<i>Upsample1</i>	۲×۲	۲	
<i>De(Conv5_3+BN5_3+ReLU5_3)</i>	۳×۳	۱	۱۰۲۴
<i>De(Conv5_2+BN5_2+ReLU5_2)</i>	۳×۳	۱	۱۰۲۴
<i>De(Conv5_1+BN5_1+ReLU5_1)</i>	۳×۳	۱	۵۱۲
<i>Upsample2</i>	۲×۲	۲	
<i>De(Conv4_3+BN4_3+ReLU4_3)</i>	۳×۳	۱	۵۱۲
<i>De(Conv4_2+BN4_2+ReLU4_2)</i>	۳×۳	۱	۵۱۲
<i>De(Conv4_1+BN4_1+ReLU4_1)</i>	۳×۳	۱	۲۵۶
<i>Upsample3</i>	۲×۲	۲	
<i>De(Conv3_3+BN3_3+ReLU3_3)</i>	۳×۳	۱	۲۵۶
<i>De(Conv3_2+BN3_2+ReLU3_2)</i>	۳×۳	۱	۲۵۶
<i>De(Conv3_1+BN3_1+ReLU3_1)</i>	۳×۳	۱	۱۲۸
<i>Upsample4</i>	۲×۲	۲	
<i>De(Conv2_2+BN2_2+ReLU2_2)</i>	۳×۳	۱	۱۲۸
<i>De(Conv2_1+BN2_1+ReLU2_1)</i>	۳×۳	۱	۶۴
<i>Upsample5</i>	۲×۲	۲	
<i>De(Conv1_2+BN1_2+ReLU1_2)</i>	۳×۳	۱	۶۴
<i>De(Conv1_1+BN1_1+ReLU1_1)</i>	۳×۳	۱	۲
<i>Softmax+Loss</i>			



شکل ۷: نتایج بصری تحقیق و مقایسه آن با سایر روش‌ها

۳-۴- ارزیابی عددی نتایج

پس از استخراج ساختمان‌ها از داده‌های تست موردنظر با استفاده از روش پیشنهادی تحقیق، در مرحله لازم است تا نتیجه به دست آمده با داده‌های مرجع (واقعیت زمینی) مقایسه شوند تا دقت نهایی خروجی‌های به دست آمده مورد تایید قرار گیرد. فرآیند ارزیابی دقت و صحت نتایج تحقیق با داده‌های مرجع با ایجاد ماتریس خطا برای تعداد اشیا ساختمانی استخراج شده صحیح و ناصحیح بررسی می‌شود. کلاس‌های ماتریس خطا برای

این ارزیابی شامل دو کلاس ساختمان و غیرساختمان می‌باشد. مقادیر هر درایه این ماتریس مبتنی بر تعداد پیکسل‌های برچسب خورده می‌باشد. جدول (۴) ساختار کلی ماتریس خطا را نشان می‌دهد. در این جدول، TP تعداد پیکسل‌های ساختمانی که ساختمان، FP تعداد پیکسل‌های ساختمانی که غیرساختمان، FN تعداد پیکسل‌های غیرساختمانی که ساختمان، TN تعداد پیکسل‌های غیرساختمانی که غیرساختمان تشخیص داده شده‌اند، می‌باشند.

جدول ۴: ماتریس خطا

	ساختمان	غیرساختمان
ساختمان	TP	FP
غیرساختمان	FN	TN

بر اساس ماتریس خطا، معیارهای تمامیت^۱، صحت^۲، $F_{measure}$ و IoU جهت تحلیل کمی قطعات استخراج شده به صورت رابطه (۸) تا رابطه (۱۱) تعریف می‌شوند [۷ و ۲۳].

در رابطه (۱۰) جهت ساده‌تر کردن محاسبات مقدار β را برابر با یک در نظر می‌گیریم [۲۸]. در رابطه (۱۱) مقادیر

n_{gt} و n_{pred} به ترتیب مقادیر پیکسل‌های پیش‌بینی شده با شبکه عصبی پیشنهادی و واقعیت زمینی می‌باشند. نتایج این ارزیابی عددی در جدول (۵) ارائه شده است. در جدول (۵)، بهترین مقادیر به صورت برجسته نشان داده شده است.

$$Completeness = \frac{TP}{TP + FN} \quad \text{رابطه (۸)}$$

$$Correctness = \frac{TP}{TP + FP} \quad \text{رابطه (۹)}$$

$$F_{measure} = \frac{(1 + \beta^2)TP}{(1 + \beta^2)TP + \beta^2 FN + FP} \quad \text{رابطه (۱۰)}$$

$$IoU = \frac{TP}{n_{pred} + n_{gt}} \quad \text{رابطه (۱۱)}$$

² Correctness

¹ Completeness

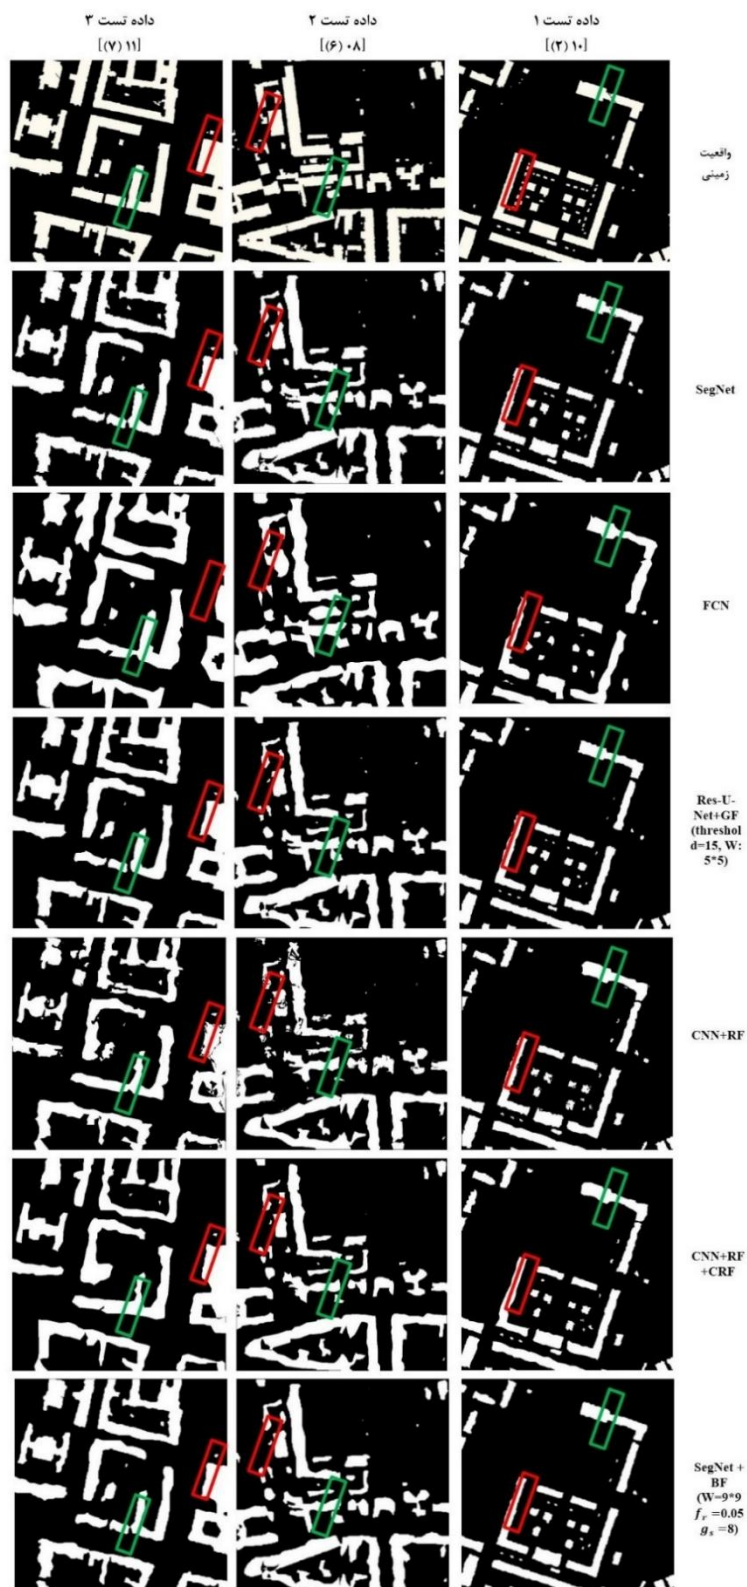
جدول ۵: نتایج استخراج ساختمان از سه منطقه تست با استفاده از روش پیشنهادی تحقیق در مقایسه با سایر روش‌ها (بر حسب %).

<i>IoU</i>	<i>F_{measure}</i>	صحت	تمامیت		
۵۱٫۱۳	۸۹٫۸۶	۸۹٫۸۴	۹۰٫۱۱	<i>SegNet</i>	داده تست ۱ [۱۰ (۲)]
۵۰٫۷۷	۸۹٫۶۰	۸۹٫۷۲	۸۹٫۹۳	<i>FCN</i>	
۵۵٫۸۱	۹۱٫۲۸	۹۱٫۱۳	۹۳٫۹۷	<i>Res-U-Net+GF</i>	
۵۲٫۳۵	۸۹٫۶۷	۸۹٫۸۵	۹۱٫۴۰	<i>CNN+RF</i>	
۵۲٫۴۲	۸۹٫۸۰	۸۹٫۹۸	۹۱٫۴۸	<i>CNN+RF+CRF</i>	
۵۷٫۶۷	۹۱٫۴۹	۹۲٫۳۷	۹۵٫۱۴	<i>SegNet + BF</i>	
۴۶٫۲۱	۸۶٫۴۵	۸۷٫۱۵	۸۹٫۶۷	<i>SegNet</i>	داده تست ۲ [۰۸ (۶)]
۴۶٫۱۱	۸۶٫۰۲	۸۶٫۶۹	۸۹٫۴۰	<i>FCN</i>	
۴۹٫۳۹	۸۹٫۲۸	۸۹٫۸۴	۹۱٫۲۲	<i>Res-U-Net+GF</i>	
۴۳٫۱۲	۸۵٫۴۱	۸۶٫۲۷	۸۹٫۰۴	<i>CNN+RF</i>	
۴۵٫۵۷	۸۶٫۱۹	۸۶٫۵۶	۸۹٫۲۲	<i>CNN+RF+CRF</i>	
۴۹٫۷۰	۸۹٫۴۴	۹۰٫۰۲	۹۱٫۶۷	<i>SegNet + BF</i>	
۵۳٫۱۴	۹۰٫۷۵	۹۱٫۰۴	۹۳٫۱۴	<i>SegNet</i>	داده تست ۳ [۱۱ (۷)]
۵۲٫۵۵	۹۰٫۲۱	۹۰٫۵۰	۹۲٫۹۰	<i>FCN</i>	
۵۸٫۰۰	۹۱٫۶۷	۹۳٫۳۳	۹۵٫۷۱	<i>Res-U-Net+GF</i>	
۵۲٫۱۸	۹۰٫۲۹	۹۰٫۳۴	۹۲٫۹۵	<i>CNN+RF</i>	
۵۲٫۶۶	۹۰٫۴۱	۹۰٫۶۵	۹۳٫۴۹	<i>CNN+RF+CRF</i>	
۵۸٫۳۴	۹۲٫۵۷	۹۳٫۹۸	۹۶٫۱۴	<i>SegNet + BF</i>	

۳-۵- آنالیز کیفیت نتایج

در این قسمت جهت بررسی قابلیت‌های الگوریتم پژوهش در مقایسه با الگوریتم‌های مشابه در حل مسئله استخراج ساختمان از داده‌های تست تحقیق دو محدوده سبز و قرمز برای آنالیز کیفیت در هر تصویر مطابق شکل (۸) انتخاب شد. با توجه به شکل (۸)، محدوده سبز رنگ برای به چالش کشیدن الگوریتم در مورد، وجود فاصله‌های بسیار کوچک بین ساختمان‌ها و تشخیص یا عدم تشخیص این فواصل توسط الگوریتم پیشنهادی انتخاب شد. در داده تست یک، اگرچه مرز بسیار باریک بین دو ساختمان با استفاده از روش پیشنهادی تحقیق از بین رفته است اما هندسه ساختمان نسبت به سایر روش‌ها دارای نتیجه قابل قبول تری می‌باشد. در این تست روش سیگنت نتیجه بهتری در شناسایی مرز داشته اما

هندسه ساختمان به‌خوبی قابل تشخیص نیست و در مورد سایر روش‌ها نیز خروجی‌ها به‌مراتب ضعیف هستند. در داده تست دو نیز این مسئله وجود دارد، اما الگوریتم پیشنهادی تنها مرز بین دو ساختمان کوچک را نتوانسته است تشخیص دهد که نسبت به نتیجه داده تست یک شرایط بهتر است. همچنین با توجه به نتایج سایر روش‌ها می‌توان گفت استفاده از آن‌ها، نتیجه ضعیف‌تری داشته است. در داده تست سه، الگوریتم تا حد زیادی این مرز کوچک را تشخیص داده و پس از اعمال فیلتر دو طرفه نیز همچنان این مرز مشخص بوده و نتیجه مناسب‌تری ارائه شده است و دلیل آن‌هم می‌تواند وجود بیشتر ساختمان‌هایی با سقف قرمز در داده‌های آموزشی باشد.



شکل ۸: انتخاب محدوده‌های آزمایشی برای آنالیز کیفیت نتایج الگوریتم پیشنهادی

۴- نتیجه‌گیری

مسئله استخراج ساختمان از تک‌تصویر نوری رنگی با قدرت تفکیک مکانی بالا، همواره به‌عنوان یکی از چالش‌های مهم در تهیه نقشه به شمار می‌آید. این موضوع از این جهت دارای اهمیت است که دسترسی بسیاری از کشورها به داده‌های نوری به‌مراتب بیشتر و آسان‌تر است و می‌توانند فرآیند تهیه نقشه را با منبع داده‌ای نسبتاً ارزان و با پوشش کامل از مناطق مختلف در اختیار داشته باشند. علاوه بر آن به‌کارگیری داده‌های تلفیقی مثل لایدار و یا سایر منابع اطلاعات هندسی موجب افزایش حجم داده و به وجود آمده پدیده کلان داده می‌شود که پردازش داده‌ها برای تهیه نقشه دچار مشکلات بسیاری خواهد بود. در این تحقیق، با به‌کارگیری تلفیقی الگوریتم‌های یادگیری عمیق و فیلترهای دو طرفه مسئله استخراج ساختمان از تصاویر نوری با قدرت تفکیک مکانی بالا مورد بررسی و آزمایش قرار گرفت. مدل شبکه عصبی عمیق مورد استفاده در این تحقیق معماری سیگنت می‌باشد که با استفاده از تابع بهینه‌سازی برآورد لحظه تطبیقی فرآیند آموزش و تست بهینه‌سازی گردید و پس از آموزش شبکه عصبی عمیق با استفاده از مجموعه داده آموزشی از شهر پوتسدام آلمان با بهره‌گیری از سه بلوک تصویری تست شد. برای ارزیابی دقت نتایج تحقیق از چهار معیار تمامیت، صحت، F_{measure} و IoU استفاده شد. نتایج حاصل از این ارزیابی نشان داد، به‌کارگیری فیلتر دو طرفه با پارامترهای بهینه‌سازی شده تجربی با ابعاد کرنل گوسین 9×9 و مقادیر 0.5 و 8 به ترتیب برای پارامترهای f_r و g_s نتایج را تا حد بسیار زیادی بهبود می‌دهد و مرز ساختمان‌ها به میزان قابل توجهی قابل شناسایی است. به نحوی که برای داده‌های تست شماره یک تا سه، مقادیر تمامیت، صحت، F_{measure} و IoU به ترتیب برابر 95.14 ، 92.37 ، 91.49 و 57.67 برای داده تست یک، 91.67 ، 90.02 ، 89.44 و 49.70 برای داده تست دو و 96.14 ، 93.98 ، 92.57 و 58.34 برای داده تست سه است. در بین داده‌های تست، داده تست شماره دو،

در مجموع با توجه به نتایج به دست آمده پیرامون تشخیص فواصل کوچک بین ساختمان‌ها که مسئله مهمی در تهیه نقشه می‌باشد، الگوریتم پیشنهادی تحقیق در این امر موفق عمل می‌کند اما به دلیل وجود پوشش‌های گیاهی نظیر درختان کوچک و چمن‌ها در میان این ساختمان موجب کاهش دقت این الگوریتم شده است. به‌علاوه روش‌های مشابه به دلیل ساختاری که دارند اغلب نیازمند منابع داده بیشتر هستند که همین عامل باعث کاهش دقت آن‌ها می‌شود.

محدوده قرمز رنگ در شکل (۸)، جهت بررسی قابلیت الگوریتم در تشخیص ساختمان‌های بسیار کوچک و همچنین تشخیص لبه ساختمان‌ها در محدوده‌های پرتراکم می‌باشد. در داده تست یک، تعدادی از ساختمان‌ها با وسعت بسیار کم تشخیص داده نشده‌اند، اما نه همه آن‌ها بلکه اکثر آن‌هایی که در کنار ساختمان‌های بلند هستند و یا پوشش‌های گیاهی آن‌ها را احاطه کرده‌اند. اما در همین محدوده شاهد عملکرد مناسب الگوریتم پیشنهادی پژوهش پس از اعمال فیلتر دو طرفه در محدوده لبه ساختمان‌ها هستیم. در میان سایر روش‌های مشابه نیز روش $Res-U-Net+GF$ دارای نتایج نسبتاً مناسبی بوده است. در داده تست دو، ساختمان‌های کوچک تشخیص داده شده‌اند اما همه جزئیات آن مشخص نیست. این نمونه از جمله اندک ساختمان‌هایی است که به دلیل پیچیدگی هندسی ساختمان و وسعت کم آن به‌خوبی تشخیص داده نشده است، همچنین مشخص است که لبه ساختمان‌ها بهبود زیادی پیدا کرده است. در نهایت در داده تست سه، مسئله عدم تشخیص ساختمان‌های کوچک به حداقل می‌رسد و تنها بعد از اعمال فیلتر یک پیکسل در محدوده قرمز رنگ غیرقابل تشخیص می‌شود و لبه ساختمان دارای بهبود می‌شود که در مقایسه با سایر الگوریتم‌ها، روش $CNN+RF+CRF$ تا حدودی توانسته است به نتایج روش پیشنهادی نزدیک شود و عملکرد مناسبی داشته است.

در حدود ۵ درصد افزایش دقت کلی گزارش شده است [۶] و [۴۰]. در این پژوهش با بهینه‌سازی معماری سگنت با الگوریتم برآورد لحظه تطبیقی و به‌کارگیری فیلتر دو طرفه، نتایج حاکی از افزایش بیش از ۸ درصد دقت کلی را برای این مجموعه داده می‌دهد. اما الگوریتم $SegNet+BF$ که در این تحقیق ارائه شد با بهینه‌سازی پارامترهای الگوریتم سگنت و با استفاده از فیلتر دو طرفه موجب شد تا نتایج استخراج ساختمان به اندازه مناسبی بهبود یابد. بعلاوه با مقایسه نتایج روش پیشنهادی تحقیق با روش‌های $Res-U-Net+GF$ ، الگوریتم پایه $SegNet$ ، FCN ، $CNN+RF$ و $CNN+RF+CRF$ می‌توان نتیجه گرفت که الگوریتم $SegNet+BF$ که در این تحقیق بحث شد، دارای قابلیت‌های بهتری نسبت به روش‌های مشابه در حل مسئله استخراج ساختمان از تصاویر نوری هوایی دارد.

کمترین مقادیر دقت و صحت را به خود اختصاص داده است که علت آن به این صورت تحلیل می‌شود که این منطقه تست، به دلیل وجود ساختمان‌های بسیار کوچک و با مرز بسیار کم نسبت به ساختمان‌های مجاور به‌خوبی تشخیص داده نشده‌اند، اما پیچیدگی‌های هندسی به میزان قابل توجهی در دقت الگوریتم پیشنهادی تحقیق مؤثر نبوده است که این نشان از توان بالای این الگوریتم در حل مسئله استخراج ساختمان دارد. الگوریتم سگنت در حل مسئله استخراج اشیا با جزئیات زیاد در مقایسه با معماری‌های $DeepLab-LargeFOV$ ، FCN ، FCN ، $DeepLab-LargeFOV-denseCRF$ ، $learn\ deconv$ و $DeconvNet$ تا حد زیادی موفق عمل کرده است [۴۵]. از طرفی در پژوهش‌هایی که با هدف استخراج ساختمان صورت گرفته است، از معماری سگنت به‌عنوان یکی از الگوریتم‌های مرجع جهت مقایسه نتایج استفاده شده است که معمولاً نتیجه این مقایسه‌ها

مراجع

- [1] K. Chen, K. Fu, X. Gao, M. Yan, X. Sun, and H. Zhang, "Building extraction from remote sensing images with deep learning in a supervised manner," 2017 IEEE International Geoscience and Remote Sensing Symposium (IGARSS), Jul. 2017.
- [2] Z. Huang, G. Cheng, H. Wang, H. Li, L. Shi, and C. Pan, "Building extraction from multi-source remote sensing images via deep deconvolution neural networks," 2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS), Jul. 2016.
- [3] S. Saito and Y. Aoki, "Building and road detection from large aerial imagery," *Image Processing: Machine Vision Applications VIII*, Feb. 2015.
- [4] MIT Technology Review, 2018 [Online]. Available: <https://www.technologyreview.com/Lists/technologies/2018/>.
- [5] X. X. Zhu, D. Tuia, L. Mou, G. Xia, L. Zhang, F. Xu, and F. Fraundorfer, "Deep Learning in Remote Sensing: A Review," *IEEE geoscience and remote sensing magazine*, in press, Oct. 2017.
- [6] Y. Xu, L. Wu, Z. Xie, and Z. Chen, "Building Extraction in Very High Resolution Remote Sensing Imagery Using Deep Learning and Guided Filters," *Remote Sensing*, vol. 10, no. 1, p. 144, Jan. 2018.
- [7] E. Maggiori, Y. Tarabalka, G. Charpiat, and P. Alliez, "Convolutional Neural Networks for Large-Scale Remote-Sensing Image Classification," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 55, no. 2, pp. 645–657, Feb. 2017.
- [8] M. Radovic, O. Adarkwa, and Q. Wang, "Object Recognition in Aerial Images Using Convolutional Neural Networks," *Journal of Imaging*, vol. 3, no. 4, p. 21, Jun. 2017.
- [9] Y. Long, Y. Gong, Z. Xiao, and Q. Liu, "Accurate Object Localization in Remote Sensing Images Based on Convolutional Neural Networks," *IEEE Transactions on*

- Geoscience and Remote Sensing*, vol. 55, no. 5, pp. 2486–2498, May 2017.
- [10] M. Vakalopoulou, K. Karantzas, N. Komodakis, and N. Paragios, "Building detection in very high resolution multispectral data with deep learning features," *2015 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, Jul. 2015.
- [11] S. Saito, T. Yamashita, and Y. Aoki, "Multiple Object Extraction from Aerial Imagery with Convolutional Neural Networks," *Journal of Imaging Science and Technology*, vol. 60, no. 1, pp. 104021–104029, Jan. 2016.
- [12] Z. Zhong, J. Li, W. Cui, and H. Jiang, "Fully convolutional networks for building and road extraction: Preliminary results," *2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, Jul. 2016.
- [13] Y. Lecun, L. Bottou, Y. Bengio, and P. Haffner, "Gradient-based learning applied to document recognition," *Proceedings of the IEEE*, vol. 86, no. 11, pp. 2278–2324, 1998.
- [14] M. Långkvist, A. Kiselev, M. Alirezaie, and A. Loufî, "Classification and Segmentation of Satellite Orthoimagery Using Convolutional Neural Networks," *Remote Sensing*, vol. 8, no. 4, p. 329, Apr. 2016.
- [15] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "ImageNet classification with deep convolutional neural networks," *Communications of the ACM*, vol. 60, no. 6, pp. 84–90, May 2017.
- [16] T. Bluche, H. Ney, and C. Kermorvant, "Feature Extraction with Convolutional Neural Networks for Handwritten Word Recognition," *2013 12th International Conference on Document Analysis and Recognition*, Aug. 2013.
- [17] K. Noda, N. Hashimoto, K. Nakadai, and T. Ogata, "Sound source separation for robot audition using deep learning," *2015 IEEE-RAS 15th International Conference on Humanoid Robots (Humanoids)*, Nov. 2015.
- [18] G. Fu, C. Liu, R. Zhou, T. Sun, and Q. Zhang, "Classification for High Resolution Remote Sensing Imagery Using a Fully Convolutional Network," *Remote Sensing*, vol. 9, no. 12, p. 498, May 2017.
- [19] T. Nguyen, J. Han, and D.-C. Park, "Satellite image classification using convolutional learning," *American Institute of Physics*, pp.2237-2240, Oct 2013.
- [20] Y. Shu, "Deep Convolutional Neural Networks for Object Extraction from High Spatial Resolution Remotely Sensed Imagery," *Thesis (PhD)*, University of Waterloo, 2014.
- [21] F. Alidoost and H. Arefi, "Knowledge Based 3D Building Model Recognition Using Convolutional Neural Networks From LiDAR and Aerial Imageries," *ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, vol. XLI-B3, pp. 833–840, Jun. 2016.
- [22] G. Masi, D. Cozzolino, L. Verdoliva, and G. Scarpa, "Pansharpening by Convolutional Neural Networks," *Remote Sensing*, vol. 8, no. 7, p. 594, Jul. 2016.
- [23] K. Bittner, S. Cui, and P. Reinartz, "Building Extraction from Remote Sensing Data using fully Convolutional Networks," *ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, vol. XLII-1/W1, pp. 481–486, May 2017.
- [24] V. Badrinarayanan, A. Kendall, and R. Cipolla, "SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 39, no. 12, pp. 2481–2495, Dec. 2017.
- [25] G. Wu, X. Shao, Z. Guo, Q. Chen, W. Yuan, X. Shi, Y. Xu, and R. Shibasaki, "Automatic Building Segmentation of Aerial Imagery Using Multi-Constraint Fully Convolutional Networks," *Remote Sensing*, vol. 10, no. 3, p. 407, Mar. 2018.

- [26] G. Goyal, "Impact & Analysis of Improved Bilateral Filter on TEM Images," *International Journal of Science and Research (IJSR)*, vol. 3, Issue 6, Jun. 2014.
- [27] R. Hecht-Nielsen, "Theory of the backpropagation neural network," in *International Joint Conference on Neural Networks (IJCNN)*, 1989.
- [28] Y. Chen, H. Jiang, C. Li, X. Jia, and P. Ghamisi, "Deep feature extraction and classification of hyperspectral images based on convolutional neural networks," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 54, no. 10, pp. 6232–6251, 2016.
- [29] N. Kussul, M. Lavreniuk, S. Skakun, and A. Shelestov, "Deep Learning Classification of Land Cover and Crop Types Using Remote Sensing Data," *IEEE Geoscience and Remote Sensing Letters*, vol. 14, no. 5, pp. 778–782, May 2017.
- [30] S. Muruganandham, "Semantic Segmentation of Satellite Images using Deep Learning," *Thesis (M.Sc)*, Czech Technical University in Prague, Aug. 2016.
- [31] M. Anthimopoulos, S. Christodoulidis, L. Ebner, A. Christe, and S. Mougiakakou, "Lung Pattern Classification for Interstitial Lung Diseases Using a Deep Convolutional Neural Network," *IEEE Transactions on Medical Imaging*, vol. 35, no. 5, pp. 1207–1216, May 2016.
- [32] D. P. Kingma, and J.L. Ba, "Adam: A method for stochastic optimization," *arXiv preprint arXiv: 1412.6980*, 2014.
- [33] H. Adldoost, "Optimization of Image Fusion using Guided Filtering," *Thesis (M.Sc)*, Kharazmi University, Sep. 2015.
- [34] Shutao Li, Xudong Kang, and Jianwen Hu, "Image Fusion With Guided Filtering," *IEEE Transactions on Image Processing*, vol. 22, no. 7, pp. 2864–2875, Jul. 2013.
- [35] F. Durand and J. Dorsey, "Fast bilateral filtering for the display of high-dynamic-range images," *Proceedings of the 29th annual conference on Computer graphics and interactive techniques - SIGGRAPH '02*, 2002.
- [36] S. Paris, "A gentle introduction to bilateral filtering and its applications," *ACM SIGGRAPH 2007 courses on - SIGGRAPH '07*, 2007.
- [37] S. Paisitkriangkrai, J. Sherrah, P. Janney, and A. Van-Den Hengel, "Effective semantic pixel labelling with convolutional networks and Conditional Random Fields," *2015 IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, Jun. 2015.
- [38] *International Society for Photogrammetry and Remote Sensing (ISPRS) and BSF Swissphoto: WG3 Potsdam overhead data.* <http://www2.isprs.org/commissions/comm3/wg4/tests.html>.
- [39] P. Kaiser, J. D. Wegner, A. Lucchi, M. Jaggi, T. Hofmann, and K. Schindler, "Learning Aerial Image Segmentation From Online Maps," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 55, no. 11, pp. 6054–6068, Nov. 2017.
- [40] N. Audebert, A. Boulch, H. Randrianarivo, B. Le Saux, M. Ferecatu, S. Lefevre, and R. Marlet, "Deep learning for urban remote sensing," *2017 Joint Urban Remote Sensing Event (JURSE)*, Mar. 2017.
- [41] M. Volpi and D. Tuia, "Dense Semantic Labeling of Subdecimeter Resolution Images With Convolutional Neural Networks," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 55, no. 2, pp. 881–893, Feb. 2017.
- [42] <https://en.wikipedia.org/wiki/Germay>
- [43] <https://en.wikipedia.org/wiki/Potsdm>
- [44] T. Panboonyuen, P. Vateekul, K. Jitkajornwanich, S. Lawawirojwong, and P. Srestasathiern, "Road Segmentation on Remotely-Sensed Images Using Deep Convolutional Neural Networks with Landscape Metrics and Conditional Random Fields," Jun. 2017.

- [45] V. Badrinarayanan, A. Handa, R. Cipolla, "Segnet: A deep convolutional encoder-decoder architecture for robust semantic pixel-wise labelling," *arXiv preprint arXiv:1505.07293*, 2015.



Integration of Deep Learning Algorithms and Bilateral Filters with Mono Optical Aerial the Purpose of Building Extraction from Imagery

Mahdi Khoshboresh Masouleh¹, Reza Shah-Hosseini^{2*}, Abdol Reza Safari³

1- PhD Student., School of Surveying & Geospatial Engineering, College of Engineering, University of Tehran, Tehran, Iran.

2- Assistant Professor., School of Surveying & Geospatial Engineering, College of Engineering, University of Tehran, Tehran, Iran.

3- Professor., School of Surveying & Geospatial Engineering, College of Engineering, University of Tehran, Tehran, Iran.

Abstract

The problem of extracting the building from mono optical aerial imagery with high spatial resolution is always considered as an important challenge to prepare the maps. The goal of the current research is to take advantage of the semantic segmentation of mono optical aerial imagery to extract the building which is realized based on the combination of deep convolutional neural networks (DCNN) and bilateral filters (BF). For this purpose, considering the hardware limitations of the current research and the fact that it is necessary to select a large number of training data to train deep convolutional neural networks, after selecting an appropriate dataset from three-band optical images, the minimum data that obtains the highest training accuracy was selected to avoid getting weak results due to the lack of training data. In this research, by optimizing the SegNet deep neural network which is an encoder-decoder network, the processing task and therefore extracting the building from optical images are done using the adaptive moment estimation (ADAM) optimization and BF with a Gaussian kernel. This method is implemented on a dataset related to the mono optical aerial imagery of urban regions located in Potsdam, Germany, the two-dimensional tagged datasets of international society for photogrammetry and remote sensing (ISPRS). The results show that compared to similar methods, the combinational use of the SegNet optimized deep neural network and BF with a Gaussian kernel provides very appropriate capabilities to improve the detection of building boundary in the optical images with high spatial resolution. Also, the results of the proposed method show that the values of the integrity and validity criteria are 95.14 and 92.37 respectively for the test area 1, 91.67 and 90.2 respectively for the test area 2, and 96.14 and 93.98 respectively for the test area 3.

Key words: building extraction, mono optical aerial imagery, semantic segmentation, deep convolutional neural networks, bilateral filters.

Correspondence Address. Photogrammetry & Remote Sensing Group, School of Surveying & Geospatial Engineering, College of Engineering, University of Tehran, Tehran, Iran.

Tel: +98 21 61114527

Email: rshahosseini@ut.ac.ir