

A Fully Convolutional Neural Network-Based Approach for Detecting Simultaneously Roads and Buildings in Aerial Imagery

Nacer Farajzadeh.^{1*} and Hiwa Ebrahimzadeh.²

1. Associate Prof., Faculty of IT and Computer Engineering Dep., Azarbaijan Shahid Madani University, Tabriz, Iran
2. M.Sc. Student, Faculty of IT and Computer Engineering Dep., Azarbaijan Shahid Madani University, Tabriz, Iran

Abstract

The development of automatic road and building detection systems in aerial imagery are always faced with challenges such as the appearance of buildings, illumination changes, imaging angles, and the density of roads and buildings in urban areas, to name a few. In recent years, employing multi-layered approach in artificial neural networks, known as deep neural networks, has attracted many researchers in this field (and the other fields alike), achieving stunning results. However, the use of fully connected layers in this approach, significantly increases the average processing time and results in an overfitted model. In addition, in most of these methods, a single-class approach has been considered. That is, detecting the roads and the buildings from natural scenes is not possible at the same time, and therefore, it is necessary to build separate binary models for each of them. The main goal of this research is to design a new architecture by which the produced model can be able to simultaneously detect roads and buildings from natural scenes, and thus minimizing the complexity of the classification process. In addition, in the proposed architecture, excluding all fully connected layers from the traditional multi-layered architectures is considered in order to reduce the average processing time. The results of the experiments performed on the Massachusetts dataset, show that the proposed architecture performs 38% faster than the other deep neural network-based methods, and also increases the accuracy by an average of 2%.

Keywords: Deep learning, Artificial neural networks, Convolutional neural networks, Aerial imagery, Road detection, Building detection, Natural scene detection, Artificial intelligence.

* Correspondence Address: Faculty of IT & Computer Engineering, Azarbaijan Shahid Madani University, Tabriz, Post Code: 5375171379. Tel: +98 930 814 9600
Email: n.farajzadeh@azaruniv.ac.ir
https://doi.org/ 10.52547/gisj.13.2.39



نسخه از دور

GIS ایران



سنجش از دور و GIS ایران / سال سیزدهم، شماره دوم، تابستان ۱۴۰۰
Iranian Remote Sensing & GIS / Vol.13, No. 2, Summer 2021

۶۰-۳۹

مقاله پژوهشی

راهکاری مبتنی بر شبکه‌های عصبی کاملاً کانولوشنی برای تشخیص هم‌زمان جاده‌ها و ساختمان‌ها در تصاویر هوایی

ناصر فرج‌زاده^{۱*} و هیوا ابراهیم‌زاده^۲

۱. دانشیار دانشکده فناوری اطلاعات و مهندسی کامپیوتر، دانشگاه شهید مدنی آذربایجان، تبریز، ایران

۲. دانشجوی کارشناسی ارشد دانشکده فناوری اطلاعات و مهندسی کامپیوتر، دانشگاه شهید مدنی

آذربایجان، تبریز، ایران

تاریخ پذیرش مقاله: ۱۳۹۹/۰۸/۰۵

تاریخ دریافت مقاله: ۱۳۹۸/۱۰/۱۸

چکیده

توسعه سیستم‌های خودکار تشخیص جاده و ساختمان در تصاویر هوایی همواره با چالش‌های مهمی مانند متفاوت بودن ظاهر ساختمان‌ها، تغییرات روشنایی، زاویه تصویربرداری و فشرده و چگال بودن جاده‌ها و ساختمان‌ها در نواحی شهری روبه‌روست. در چند سال اخیر، استفاده از شبکه‌های عصبی مصنوعی چندلایه (شبکه‌های عصبی عمیق) مورد توجه بسیاری از پژوهشگران این حوزه (و حوزه‌های مشابه) قرار گرفته و نتایج خیره‌کننده‌ای با به‌کارگیری آنها حاصل شده است. با وجود این، به دلیل استفاده از لایه‌های کاملاً متصل در راهکارهای داده‌شده، میانگین مدت زمان پردازش هنوز بسیار زیاد است و مدل ساخته‌شده نیز به سرعت دچار پدیده بیش‌برازش می‌شود. علاوه بر این، در بیشتر روش‌های پیشنهادی، برای تفسیر تصاویر هوایی بر اساس چنین راهکاری از رویکرد تک‌کلاس استفاده شده است. به عبارتی، تشخیص جاده‌ها و ساختمان‌ها از عوارض طبیعی به‌طور هم‌زمان امکان‌پذیر نیست و لازم است مدل‌های جداگانه‌ای برای تشخیص هر یک از آنها ایجاد شود. هدف اصلی، در این پژوهش، طراحی معماری جدیدی است که مدل ساخته‌شده با استفاده از آن بتواند، هم‌زمان، جاده‌ها و ساختمان‌ها را از عوارض طبیعی تشخیص دهد و به این ترتیب، پیچیدگی عمل طبقه‌بندی را به حداقل برساند. همچنین، در طراحی معماری پیشنهادی، حذف لایه‌های کاملاً متصل از معماری چندلایه‌ای مرسوم و در نتیجه، کاهش میانگین مدت زمان پردازش مورد توجه قرار گرفته است. نتایج آزمایش‌های انجام‌گرفته روی بانک تصاویر هوایی ماساچوست نشان می‌دهد عملکرد معماری پیشنهادی ۲۸٪ سریع‌تر از دیگر روش‌های مبتنی بر شبکه‌های عصبی چندلایه بوده است و دقت تشخیص را به‌طور میانگین، ۲٪ افزایش می‌دهد.

کلیدواژه‌ها: یادگیری عمیق، شبکه‌های عصبی مصنوعی، شبکه‌های عصبی کانولوشنی، تصاویر هوایی، شناسایی جاده، شناسایی ساختمان، شناسایی عوارض طبیعی، هوش مصنوعی.

* نویسنده مکاتبه‌کننده: تهران، تبریز، ۳۵ کیلومتری جاده تبریز-مراغه، دانشگاه شهید مدنی آذربایجان، دانشکده فناوری اطلاعات و مهندسی کامپیوتر، کد پستی: ۵۳۷۵۱۷۱۳۲۹

تلفن: ۰۹۳۰۸۱۴۹۶۰۰

۱- مقدمه

همواره مورد توجه پژوهشگران بوده است. در اغلب روش‌های مطرح‌شده برای خودکارسازی تفسیر تصاویر هوایی، استفاده از راهکارهای مبتنی بر ویژگی‌های محلی مورد توجه قرار گرفته است (فرج‌زاده و هاشم‌زاده ۱۳۹۸). در این راهکارها، معمولاً با استفاده از یک روش استخراج ویژگی مهندسی‌شده و یک الگوریتم یادگیری، برای ایجاد مدل طبقه‌بندی‌کننده - تشخیص‌دهنده اقدام می‌شود. به‌رغم آنکه این راهکارها نتایج درخور توجهی دارند، متأسفانه نیاز به مهیا بودن دانش پیشین درباره‌ی ظاهر شیء یا نحوه‌ی توزیع مقادیر پیکسل‌ها در هر کلاس یکی از نقاط ضعف آنها به‌شمار می‌رود.

در سال‌های اخیر، به‌لطف پیشرفت‌های چشمگیر در عرصه‌ی تولید GPUهایی با توان پردازشی بسیار بالا، استفاده از معماری چندلایه در شبکه‌های عصبی مصنوعی طرفداران بسیاری پیدا کرده و به‌کارگیری آنها در حوزه‌های گوناگون هوش مصنوعی باعث شده است نتایج خیره‌کننده‌ای حاصل شود (Liu et al., 2017). دلیل اصلی موفقیت چنین شبکه‌هایی توانایی استخراج خودکار ویژگی‌ها با استفاده از ساختار چندلایه‌ای آنهاست. باین‌حال، چنین شبکه‌هایی با دو چالش اصلی مواجه‌اند (Cheng et al., 2018): ۱. مدت زمان ساخت مدل با استفاده از این شبکه‌ها (حتی با بهره‌گیری از GPU) بسیار طولانی است؛ ۲. مدل ساخته‌شده همواره در معرض دچار شدن به پدیده‌ی بیش‌برازش^۵ است و از همین‌رو، باید داده‌های بسیار زیادی برای آموزش آنها فراهم شود. شایان ذکر است که خاستگاه هر دو چالش مطرح‌شده وجود تعداد بسیار زیاد نرون‌ها^۶ و ارتباط بین آنها در این معماری است که به معماری کاملاً متصل^۷ نیز معروف است.

«تفسیر تصاویر هوایی» به فرایند بررسی این تصاویر به‌منظور شناسایی اشیا و تعیین ویژگی‌های متفاوت اشیا شناسایی‌شده گفته می‌شود. شروع این فرایند به جنگ جهانی اول و زمانی بازمی‌گردد که عکس‌های گرفته‌شده با استفاده از هواپیماها به‌منظور شناسایی اهداف بررسی می‌شدند (Mayer, 1999). در ادبیات بینایی ماشین، تفسیر خودکار تصاویر هوایی معمولاً با عنوان برچسب‌گذاری پیکسل‌ها (با کلاس‌های مورد نظر) مطرح می‌شود. از این‌رو، هدف از تفسیر تصاویر هوایی تقطیع معنایی کامل آنها به قطعاتی مانند ساختمان، جاده، درختان، فضای سبز و آب (Kluckner & Bischof, 2009) و یا طبقه‌بندی دودویی تصاویر به دو کلاس خاص، مثل نواحی ساخت بشر و منابع طبیعی، است (فرج‌زاده و هاشم‌زاده، ۱۳۹۸).

تقطیع معنایی تصاویر هوایی اغلب با چندین چالش همچون تغییر در ظاهر شیء ناشی از تغییر در زاویه دید، انسداد، شلوغی پس‌زمینه، تغییرات روشنایی، سایه و چگالی بالای جاده‌ها و ساختمان‌ها در نواحی شهری روبه‌روست. برای بررسی این چالش‌ها، مطالعه‌ی موضوع شناسایی اشیا جغرافیایی، به‌صورت گسترده، از سال ۱۹۸۰ آغاز شده است. وضوح و کیفیت پایین تصاویر ماهواره‌ای اولیه، مانند لندست^۱، امکان شناسایی و تشخیص اشیا ساخت بشر از عوارض طبیعی را به پژوهشگران نمی‌داد؛ بنابراین، پژوهشگران اغلب روی استخراج ویژگی‌هایی از نواحی این تصاویر متمرکز شده بودند. با پیشرفت تکنولوژی سنسور از راه دور و پدید آمدن ماهواره‌هایی با قابلیت ثبت تصاویر با وضوح بالا، مانند کوئیک‌برد^۲، اسپات-۵^۳ و ایکونوس^۴، تصاویر ماهواره‌ای با اطلاعات بافتی و مکانی بیشتری برای پژوهشگران فراهم شد (Cheng & Han, 2016).

به‌دلیل اینکه استخراج اشیا مورد نظر در تصاویر هوایی به‌دست انسان کاری بسیار پرهزینه است، دادن راهکاری که بتواند حجم انبوهی از تصاویر هوایی را در مدت زمان اندک و به‌صورت خودکار برچسب‌گذاری کند

1. Landsat
2. Quickbird
3. Spot-5
4. Ikonos
5. Overfitting
6. Neurons
7. Fully Connected

در طراحی معماری پیشنهادی از هیچ لایه کاملاً متصلی استفاده نشده است.

در ادامه، ادبیات و پیشینه پژوهش مرور می‌شود. در بخش سوم، جزئیات معماری پیشنهادی توضیح داده می‌شود. در بخش چهارم، درباره نتایج آزمایش‌های انجام گرفته برای ارزیابی معماری پیشنهادی بحث می‌شود و در بخش پنجم هم، یافته‌های پژوهش و مسیرهای ممکن برای توسعه و مطالعه بیشتر مطرح می‌شود.

۲- پژوهش‌های پیشین

تجزیه و تحلیل تصاویر هوایی برای تفسیر آنها، به دلیل گستردگی تفاوت در شکل ظاهری سازه‌های دست بشر و مشکلات تصویربرداری، به صورت ذاتی چالش برانگیز است. علاوه بر این، حجم انبوهی از تصاویر گردآوری شده از طریق ابزارهایی مانند پهپادها، که با هزینه اندک در اختیار بیشتر سازمان‌های ذی‌نفع قرار می‌گیرد، سختی‌های این مسئله را دوچندان کرده است (فرج‌زاده و هاشم‌زاده، ۱۳۹۸). از آن‌جا که تجزیه و تحلیل این تصاویر نقش بسیار مهمی در طیف گسترده‌ای از برنامه‌های کاربردی ایفا می‌کند، مطرح کردن راهکاری کارآمد برای تشخیص خودکار جاده‌ها و ساختمان‌ها از عوارض طبیعی توجه بسیاری از پژوهشگران را، در سال‌های اخیر، به خود جلب کرده است.

بر اساس دسته‌بندی بیان‌شده در پژوهش چنگ و هان^۱ (۲۰۱۶)، روش‌های مرسوم توسعه یافته برای تشخیص خودکار اشیا در تصاویر هوایی در چهار گروه دسته‌بندی می‌شوند: ۱. روش‌های تشخیص شیء بر اساس مطابقت الگو (Lefèvre & Weber, 2007; Leninisha & Vani, 2015; Lin et al., 2015); ۲. روش‌های تشخیص شیء بر اساس دانش (Akçay & Aksoy, 2010; Clinton et al., 2010; Liu et al., 2013; Ok et al., 2013);

برای غلبه بر چالش‌های یادشده در معماری کاملاً متصل، معماری جدیدی با نام معماری کانولوشنی^۱ معرفی شده که در آن تغییراتی در ارتباطات مابین نورون‌ها و ماهیت لایه‌ها داده شده است. این معماری در کاربردهای گوناگونی، به ویژه بینایی ماشین، کارایی بسیار مطلوبی از خود نشان داده و تبدیل به یکی از رایج‌ترین معماری‌ها شده است (Aggarwal, 2018).

در زمینه تشخیص سازه‌های ساخت بشر مانند جاده‌ها و ساختمان‌ها، در تصاویر هوایی با استفاده از شبکه‌های عصبی کانولوشنی، پژوهش‌های متعددی انجام شده است (Mnih, 2013; Saito et al., 2016; Hui et al., 2018). هر یک از این روش‌ها سعی در عرضه معماری جدیدی، با رویکرد کاهش میانگین زمان پردازش و تا حدی افزایش دقت تشخیص، داشته است. اما اغلب آنها، حتی با توسل به معماری کانولوشنی هم، هزینه بسیار زیاد محاسباتی دارند و دلیل آن وجود دست‌کم یک لایه کاملاً متصل است که معمولاً در انتهای معماری گنجانده می‌شود. همچنین، در بیشتر روش‌ها تشخیص هم‌زمان جاده‌ها و ساختمان‌ها از عوارض طبیعی، با استفاده از یک مدل واحد، مقدور نیست و برای تشخیص جاده‌ها و یا ساختمان‌ها، باید مدل‌های جداگانه‌ای ساخته شوند. این موضوع نیز باعث افزایش پیچیدگی مسئله تشخیص خودکار سازه‌های ساخت بشر در تصاویر هوایی شده است.

در پژوهش پیش رو، با هدف تشخیص هم‌زمان جاده‌ها و ساختمان‌ها از عوارض طبیعی و در نتیجه، به حداقل رساندن میزان پیچیدگی مسئله تشخیص خودکار سازه‌های ساخت بشر در تصاویر هوایی، معماری جدیدی پیشنهاد می‌شود. چنین رویکردی با توجه به پرهزینه بودن سخت‌افزار مورد نیاز و زمان بر بودن ساخت مدل‌های جداگانه برای هر کلاس، همواره مورد توجه پژوهشگران حوزه بینایی ماشین بوده است. همچنین با هدف کاهش مدت زمان ساخت مدل و افزایش میانگین سرعت تشخیص و جلوگیری از بروز پدیده بیش‌برازش،

1. Convolutional Neural Networks
2. Cheng & Han

۳. روش‌های تشخیص شیء طبق آنالیز تصویر مبتنی بر شیء (Hay et al., 2003; Walker & Blaschke, 2008; Feizizadeh et al., 2014; Goodin et al., 2016; Contreras et al., 2015; Song et al., 2004;)؛ ۴. روش‌های تشخیص شیء بر اساس یادگیری ماشین (Das et al., 2011; Ari et al., 2014; Li et al., 2015; Wang et al., 2015). شایان ذکر است که این چهار دسته ضرورتاً از هم جدا نیستند و در برخی پژوهش‌ها، ترکیبی از روش‌های گوناگون استفاده شده است (Wang et al., 2013; Yokoya & Iwasaki, 2015; Zhao et al., 2015; Chen et al., 2018).

با پیشرفت الگوریتم‌های یادگیری ماشین و نمایش‌دهنده‌های قدرتمند ویژگی‌ها، بسیاری از پژوهش‌های اخیر تشخیص شیء در تصاویر هوایی را نکته‌ای در طبقه‌بندی شمرده و پیشرفت چشمگیری در آن به دست آورده‌اند (فرج‌زاده و هاشم‌زاده، ۱۳۹۸).
تشخیص شیء ممکن است با استفاده از یک طبقه‌بند^۱ و با یادگیری تغییرات در ظاهر و دید شیء از مجموعه داده‌ای آموزشی در چارچوبی با نظارت ضعیف، نیمه‌نظارتی یا کاملاً نظارتی صورت گیرد. ورودی طبقه‌بند (مدل) مجموعه‌ای از نواحی با نمایش ویژگی‌های مورد نظر و خروجی آن شامل برچسب‌های (شیء یا غیرشیء) پیش‌بینی شده از طریق مدل است.
با توجه به پیشرفت چشمگیری که در حوزه شبکه‌های عصبی چندلایه از سوی هینتون و سالاخودینوف^۲ (۲۰۰۶) صورت گرفت، مسئله بازنمایی ویژگی‌ها در تصاویر، به صورت خودکار، وارد عصر تازه‌ای شد؛ به طوری که در این روش، با بهره‌گیری از ساختار چندلایه‌ای از نورون‌ها، استخراج خودکار ویژگی‌ها امکان پذیر شد. به عبارتی، مسئولیت استخراج ویژگی‌ها، بدون توجه به ماهیت مسئله مفروض، به ساختار شبکه عصبی چندلایه انتقال یافت. این درحالی بود که در روش‌های مرسوم پیشین، با اتکا به دانش قبلی درباره ماهیت مسئله مفروض، یکی از روش‌های استخراج ویژگی مانند HOG^۳ (Tuermer et al., 2013)، BOW^۴ (Sun et al., 2012; Bai et al., 2014)


این معماری، در مقایسه با روش‌های مرسوم مبتنی بر استخراج مهندسی شده ویژگی‌ها، به دقت بسیار خوب دست یافته است اما، به دلیل استفاده از لایه‌ای کاملاً متصل در معماری پیشنهادی، مدت زمان آموزش شبکه بسیار طولانی است و تشخیص با سرعت پایینی انجام می‌شود که مناسب کاربردهای بلادرنگ^۵ و یا پردازش حجم انبوهی از تصاویر هوایی نیست.

اندازه تصویر تولیدشده در این روش نیز، که حاوی برچسب جاده‌ها و یا عوارض طبیعی است، به دلیل استفاده از لایه‌هایی مانند لایه ادغام^۱ در معماری شبکه، کوچک‌تر از تصویر ورودی می‌شود. علاوه بر این، حاشیه‌های جاده‌ها و ساختمان‌ها، در تصویر تولیدشده، صاف و متراکم نیستند و کیفیت مطلوبی ندارند (شکل ۱). برای جبران این مشکل، مینه پیشنهاد داد از نورون‌های بیشتری در لایه کاملاً متصل استفاده شود. با این حال، نتایج چندان رضایت‌بخش نبود و افزایش تعداد نورون‌ها سبب افزایش مدت زمان پردازش شد.

1. Classifier
2. Hinton & Salakhutdinov
3. Histogram of Oriented Gradients
4. Bag-of-Words
5. Hand Crafted
6. Engineered
7. Mnih
8. Principal Component Analysis
9. Real-time
10. Pooling



(ب)



(الف)

شکل ۱. نمونه‌ای از تولید قطعات برچسب‌دار شده به روش مینه (۲۰۱۳). ملاحظه می‌شود که چگونه مرز نواحی برچسب‌دار شده متراکم نیست و پیوستگی مطلوبی ندارند: برچسب محور جاده‌ها (الف)؛ برچسب ساختمان‌ها (ب)

محاسبه و استفاده می‌شود که انتظار می‌رود نتایج مشابهی برای قطعه مفروض تولید کنند. با این رویکرد، حجم محاسبات لازم کاهش می‌یابد. این معماری، با اینکه نواحی ساختمان‌ها را به خوبی شناسایی می‌کند، پیوستگی و فشردگی اشکال ساختمان‌ها را که ممکن است باعث ایجاد خطوط نامنظم شوند، تضمین نمی‌کند. از این‌رو، در پژوهش یادشده، از یک گام پس‌پردازش برای کاهش نواحی نامساعد استفاده شده است (Achanta et al., 2012).

برای غلبه بر مشکل تعداد نورون‌ها و اتصالات مورد نظر در معماری شبکه، ماجیوری^۴ و همکارانش (۲۰۱۷) استفاده از معماری کاملاً کانولوشنی را برای تشخیص سازه‌های ساخت بشر در تصاویر هوایی پیشنهاد دادند. به دلیل حذف لایه کاملاً متصل در این معماری، انتظار می‌رود که قدرت تعمیم این شبکه کاهش پیدا کند. به همین منظور، آن‌ها نخست مدل کاملاً کانولوشنی خود را با استفاده از داده‌های گردآمده طی پروژه^۵ اوپن‌استریت‌مپ آموزش دادند و سپس وزن‌های آن را براساس داده‌های آموزشی مورد نظر، تنظیم کردند.

نقطه‌ضعف دیگر راهکار پیشنهادی مینه ناتوانی مدل ایجادشده در تشخیص هم‌زمان جاده‌ها و ساختمان‌ها از عوارض طبیعی است. به عبارتی، مدل ایجادشونده فقط می‌تواند جاده را از عوارض طبیعی تشخیص دهد و برای تشخیص ساختمان از عوارض طبیعی، باید مدل دیگری ساخته شود. سایتو^۱ و همکارانش (۲۰۱۶) در پژوهشی به این موضوع توجه کردند. آنها با پیشنهاد معماری جدیدی، سعی کردند مدلی بسازند که بتواند هم‌زمان جاده‌ها و ساختمان‌ها را از عوارض طبیعی تشخیص دهد و در خروجی شبکه، برچسب‌های متناظر را تولید کند. متأسفانه راهکار پیشنهادی این پژوهشگران نیز، به دلیل استفاده از لایه‌های کاملاً متصل در معماری، تمامی مشکلات پژوهش مینه (۲۰۱۳) را داراست.

الشیحی^۲ و همکاران (۲۰۱۷) در پژوهش خود از رویکردی مشابه با مینه (۲۰۱۳) بهره برده‌اند. روش پیشنهادی یک معماری کانولوشنی مبتنی بر قطعه برای استخراج ساختمان‌ها از تصاویر هوایی با رزولوشن بالاست. در شبکه کانولوشنی پیشنهادی، لایه کاملاً متصل با لایه «انتخاب میانگین سراسری» (GAP)^۳ جایگزین شده است. با بهره‌گیری از روش GAP، به‌جای استفاده از تمامی نقشه‌های لایه قبلی در محاسبات، فقط میانگین نقشه‌هایی در لایه قبلی

1. Saito
2. Alshehhi
3. Global Average Pooling
4. Maggiori
5. OpenStreetMap (www.openstreetmap.org)

مدت زمان برای ساخت مدل و میانگین زمان تشخیص می‌شود؛ ۲. در مرز نواحی برچسب‌گذاری‌شده، نواحی غیرواقعی تولید می‌شوند؛ و ۳. مطرح‌کردن معماری‌ای که بتواند هم‌زمان جاده، ساختمان و عوارض طبیعی را از هم تشخیص دهد چالش‌برانگیز است و ساخت چنین مدل چندکلاسی باعث کاهش کارایی تشخیص شبکه می‌شود.

در این پژوهش، با انگیزه کاهش زمان پردازش، افزایش دقت تشخیص و تولید نقشه خروجی دقیق از جاده‌ها و ساختمان‌های تشخیص‌داده‌شده، قصد داریم شبکه عصبی کاملاً کانوولوشنی را مطرح کنیم که به‌صورت خودکار، تصاویر ورودی را هم‌زمان در سه برچسب جاده، ساختمان و پس‌زمینه طبقه‌بندی کند. علاوه‌براین، فاز آموزش در معماری پیشنهادی، برخلاف پژوهش‌های مشابه مانند هیوتی و همکارانش (۲۰۱۸) که از شبکه‌های پیش‌آموزش‌دیده همچون یو-نت و اِکسپشن برای غلبه بر کاهش کارایی شبکه استفاده کرده‌اند، تک‌مرحله‌ای است و صرفاً با استفاده از داده‌های مربوط به عوارض زمین ساخته می‌شود.

۳- روش پیشنهادی

در این بخش، روش پیشنهادی برای تشخیص جاده‌ها و ساختمان‌ها از عوارض طبیعی بیان می‌شود. این روش از شبکه عصبی چندلایه‌ای با معماری کاملاً کانوولوشنی بهره می‌برد. نخست، چارچوب کلی شبکه‌های عصبی کانوولوشنی بررسی و سپس معماری روش پیشنهادی، به‌همراه جزئیات لازم، مطرح می‌شود.

یکی از نقاط ضعف این معماری ناتوانی آن در تشخیص هم‌زمان جاده و ساختمان در تصاویر است و بیشتر تلاش نویسندگان این مقاله معطوف به تشخیص دقیق ساختمان‌ها در تصاویر هوایی شده است. همچنین استفاده از راهکار دومرحله‌ای پیش‌آموزش و سپس، ساخت مدل نهایی باعث افزایش پیچیدگی آن شده است.

پنونیون^۱ و همکارانش (۲۰۱۷)، با تمرکز بر استخراج جاده، معماری کاملاً کانوولوشنی را پیشنهاد کردند که در آن، به‌جای استفاده از تابع نگاشت مرسوم ReLU^۲، از تابع نگاشت دیگری به نام ELU^۳ استفاده شده است. به‌تازگی بسیاری از پژوهشگران به این تابع توجه داشته‌اند. این تابع نگاشت، برخلاف ReLU، دچار مشکل پاسخ‌ندادن نورون‌های دارای مقادیر منفی نمی‌شود. این محققان، برای افزایش دقت خروجی، از ویژگی ظاهری جاده‌ها و روش CRF^۴ (Chen et al., 2014) استفاده کرده‌اند. در پژوهشی دیگر هیوتی^۵ و همکارانش (۲۰۱۸)، با استفاده از معماری یو-نت^۶ (Ronneberger et al., 2015) و ترکیب آن با معماری اِکسپشن^۷ (Chollet, 2017) و تنظیم وزن‌های شبکه با داده‌های تصاویر هوایی، اقدام به تشخیص ساختمان‌ها کردند. نوآوری اصلی این شیوه ترکیب ماژول‌های از پیش آموزش‌دیده با یکدیگر است. اما به‌دلیل استفاده از معماری پیچیده یو-نت و ترکیب آن با اِکسپشن، مدت زمان پردازشی و نیز حافظه مورد نیاز این روش بسیار زیاد است.

با مرور پژوهش‌های انجام‌گرفته در تشخیص جاده‌ها و ساختمان‌ها در تصاویر هوایی، می‌توان به این نتیجه رسید که روش‌های مبتنی بر استخراج ویژگی‌های مهندسی‌شده به‌همراه یک الگوریتم یادگیری، به‌دلیل وابسته‌بودن به دانش پیشین در زمینه عوارض مورد مطالعه، کارایی کمتری در مقایسه با روش‌های مبتنی بر شبکه‌های چندلایه دارند. در مقابل، روش‌های مبتنی بر شبکه‌های چندلایه سه ضعف مهم دارند: ۱. وجود لایه‌ای کاملاً متصل در معماری باعث افزایش بسیار


1. Panboonyuen
2. Rectified Linear Unit
3. Exponential linear unit
4. Conditional Random Field
5. Hui
6. U-Net
7. Xception

۳-۱- معماری عمومی شبکه‌های عصبی کانولوشنی

نمای معماری عمومی شبکه‌های عصبی کانولوشنی، با تأکید بر کاربرد آنها در تشخیص جاده، ساختمان و عوارض طبیعی از همدیگر، در شکل ۲ نمایش داده شده است. به‌طور کلی، هر شبکه عصبی کانولوشنی مجموعه‌ای از سه لایه کانولوشن، ادغام و به‌تمامی متصل است که هریک از این لایه‌ها وظایف متفاوتی انجام می‌دهد. معمولاً چیدمان لایه‌ها به‌صورتی است که پس از هر لایه کانولوشنی، یک لایه ادغام قرار می‌گیرد و در انتها، تعدادی لایه کاملاً متصل وجود دارند که وظیفه آنها در معماری عمل طبقه‌بندی است.

لایه ادغام: در این لایه، عمل نمونه‌برداری و کاهش ابعاد ماتریس‌های نگاشت ویژگی انجام می‌شود. این کار معمولاً با استفاده از توابع از پیش تعریف‌شده‌ای، همچون تابع میانگین^۵ و تابع بیشینه^۶، انجام می‌شود. دلیل استفاده از چنین لایه‌ای افزایش مقاومت شبکه در مقابل تغییرات مکانی^۷ ورودی‌هاست (Nogueira et al., 2017).

لایه کاملاً متصل: در این لایه، تمامی نورون‌های لایه پیشین به کل نورون‌های این لایه وصل می‌شوند. وظیفه این لایه تولید بردار احتمالات رخداد هریک از کلاس‌ها (دسته‌ها) در خروجی است. برای انتخاب یکی



شکل ۲. معماری عمومی یک شبکه عصبی کانولوشنی برای تشخیص جاده و ساختمان از عوارض طبیعی

از چند کلاس براساس احتمالات رخداد، از یک تابع نگاشت استفاده می‌شود. معمول‌ترین تابع نگاشت مورد استفاده در این لایه، سافت‌مکس^۸ نام دارد (Ibid.). معمولاً در این لایه از راهکار حذف تصادفی^۹ برای کاهش تعداد اتصالات و نیز جلوگیری از بروز پدیده بیش‌برازش در زمان آموزش استفاده می‌شود.


1. Feature Map
2. Kernel
3. Activation function
4. Hyperbolic tangent
5. Average pooling
6. Max pooling
7. Spatial invariance
8. Softmax
9. Dropout

لایه کانولوشن: این لایه معمولاً از دو عملگر کانولوشن و نگاشت غیرخطی تشکیل شده است. با اعمال عملگر کانولوشن روی تصویر ورودی، یک (یا چندین) تصویر (ماتریس) کوچک‌تر به نام «نقشه ویژگی»^۱ ایجاد می‌شود. هر درایه ماتریس نقشه ویژگی از ضرب نقطه‌ای عناصر محلی (مشخص‌شده با نقطه‌چین زرد در قطعه ورودی، شکل ۲) با مجموعه‌ای از وزن‌ها که با نام فیلتر یا هسته^۲ شناخته می‌شوند، حاصل می‌شود. سپس با استفاده از تابعی^۳ غیرخطی مانند ReLU یا tanh^۴، مقادیر هریک از درایه‌ها به مقدار جدیدی نگاشت می‌شود. دلیل استفاده از چنین نگاشت غیرخطی‌ای افزایش قابلیت یادگیری و قدرت تعمیم شبکه برای ورودی‌های پیچیده است (Aggarwal, 2018).

۲-۳- معماری پیشنهادی

برچسب‌گذاری: فرض می‌شود که مجموعه‌ای از N تصویر هوایی $A = (A^{(1)}, \dots, A^{(N)})$ و تصاویر برچسب‌دار متناظرشان $L = (\bar{L}^{(1)}, \dots, \bar{L}^{(N)})$ در دسترس است. همچنین، فرض می‌شود که تصاویر هوایی $m \times m$ و دارای C کانال^۱ هستند و $\bar{L}^{(n)}$ تصویر برچسب متناظر تصویر $A^{(n)}$ برابر تصویر n ام است که از لحاظ اندازه، با تصویر $A^{(n)}$ برابر است. برچسب‌گذاری دودویی تصویر $\bar{L}^{(n)}$ با مقدار ۰ و ۱ خواهد بود که عدد ۱ نشان‌دهنده وجود و ۰ نشان‌دهنده فقدان شیء کلاس مد نظر است. با توجه به اینکه هدف از این پژوهش تشخیص هم‌زمان جاده و ساختمان از عوارض طبیعی است، تصویر برچسب‌دار شامل سه نقشه جاده، ساختمان و پس‌زمینه (عوارض طبیعی) خواهد بود. بنابراین، در تصویر برچسب‌دار شده، هر پیکسل یک بردار سه‌مؤلفه‌ای است. شکل ۳ نمونه‌ای از چنین فرموله‌سازی را نشان می‌دهد.

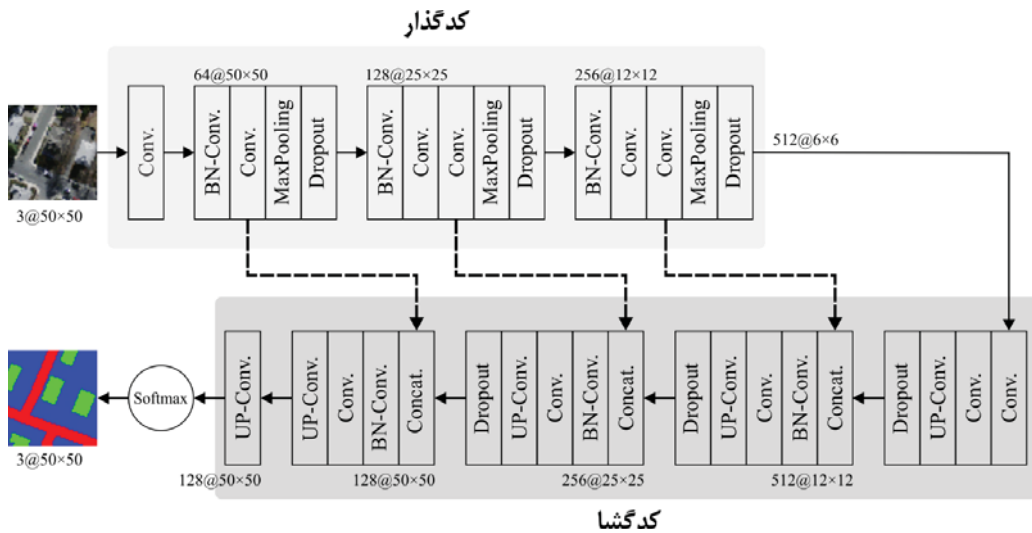
معماری: در معماری پیشنهادی به منظور حذف لایه‌های کاملاً متصل، با الهام از پژوهش لانگ^۲ و همکارانش (۲۰۱۵)، شبکه‌ای کاملاً کانوولوشنی طراحی می‌شود. در حقیقت، شبکه عصبی کاملاً کانوولوشنی یک شبکه عصبی کانوولوشنی معمولی است که آخرین لایه (کاملاً متصل) آن با یک لایه کانوولوشنی 1×1 جایگزین شده است. این لایه نقش دریافت‌کننده بزرگ سیگنال (تصویر) را ایفا می‌کند و ایده اصلی استفاده از آن، در معماری، رسیدن به چارچوبی سراسری از سیگنال (تصویر) ورودی است که در آن بتوان مکان تقریبی اشیاء در تصویر را شناسایی کرد. برخلاف شبکه عصبی کانوولوشنی معمولی، با استفاده از این رویکرد، علاوه بر طبقه‌بندی اشیاء می‌توان عمل تقطیع تصویر را نیز انجام داد.



شکل ۳. فرموله‌سازی چندکلاسی برای تشخیص هم‌زمان جاده و ساختمان از عوارض طبیعی

۱. در بیشتر کاربردهای بینایی ماشین، تصاویر معمولاً با سه کانال رنگی قرمز، سبز و آبی نشان داده می‌شوند. شایان ذکر است که این کانال‌های رنگی نباید با رنگ‌های استفاده‌شده برای برچسب‌گذاری پیکسل‌ها اشتباه گرفته شوند (شکل‌های ۳ و ۴).

2. Long



شکل ۴. معماری پیشنهادی کاملاً کانولوشنی برای تشخیص هم‌زمان جاده و ساختمان از عوارض طبیعی. ورودی شبکه قطعه‌ای تصویر 50×50 با ۳ کانال رنگی ($3 \times 50 \times 50$) و خروجی آن نیز تصویری هم‌اندازه با تصویر ورودی است. پیکسل با برچسب قرمز معرف نقطه‌ای روی جاده، پیکسل دارای برچسب سبز معرف نقطه‌ای روی ساختمان و پیکسل با برچسب آبی معرف نقطه‌ای روی عوارض طبیعی است

برای فائق آمدن بر این مشکل، می‌توان از شبکه‌های کاملاً کانولوشنی با معماری کدگذار-کدگشا استفاده کرد (Seeliger et al., 2018). بخش کدگذار به تدریج ابعاد فضایی نقشه‌های ویژگی را با استفاده از لایه‌های ادغام، کاهش می‌دهد و در مقابل، بخش کدگشا جزئیات اشیا و ابعاد فضایی را که در نقشه‌های ویژگی مستترند، به‌مرور، بازیابی می‌کند.

بازیابی با استفاده از راهکار درون‌یابی مقادیر پیکسل‌های همسایه صورت می‌گیرد. این کار «ترانزاده کانولوشن»^۴ یا «نمونه‌سازی»^۵ نامیده می‌شود. همچنین، با هدف کمک به بازیابی بهتر جزئیات در بخش کدگشا، معمولاً اتصال‌های میان‌بری از بخش کدگذار به بخش کدگشا وجود دارند (این اتصالات، در شکل ۴، با پیکان‌های نقطه‌چین مشخص شده‌اند). به عبارتی، اتصالات میان‌بر نتایج حاصل از بخش کدگذار (به‌دست‌آمده از طریق لایه‌های ادغام و لایه‌های کانولوشن) را به‌منزله پشتیبان

به‌طور کلی، معماری این نوع شبکه‌ها از دو بخش کدگذار^۱ و کدگشا^۲ تشکیل شده است. هر بخش نیز بلوک‌هایی از لایه‌های کانولوشنی و ادغام را دربر می‌گیرد. شکل ۴ نمای معماری پیشنهادی را نشان می‌دهد. در این شکل، ورودی هر بلوک (یا خروجی بلوک قبلی) با نماد $m \times m \times c$ نشان داده شده که c و $m \times m$ به ترتیب نمایانگر تعداد نقشه‌های ویژگی (ماتریس‌ها) و ابعاد آنهاست.

۳-۳- کدگذاری و کدگشایی

یکی از مزایای استفاده از لایه‌های ادغام افزایش میدان دید^۳ و در نتیجه، افزایش میزان تجمیع اطلاعات در شبکه است. در مقابل، استفاده از این لایه باعث از بین رفتن اطلاعات مکانی پیکسل‌ها می‌شود و این در حالی است که در کاربرد حال حاضر، داشتن اطلاعات مکانی دقیق پیکسل‌ها برای ساخت نقشه برچسب ضروری است و اطلاعات مکانی (مختصات) هریک از آنها باید حفظ شود.

1. Encode
2. Decode
3. Receptive Fields
4. Transpose Convolution
5. Up-sampling

روی این ورودی‌ها اعمال می‌شود. خروجی این لایه ۵۱۲ نقشهٔ ویژگی با ابعاد $\frac{m}{8} \times \frac{m}{8}$ است. همانند لایهٔ نخست، لایهٔ دوم این بلوک نیز لایه‌ای کانولوشنی است.

وظیفهٔ لایهٔ سوم^{۱۰} بازسازی نقشه‌های ویژگی است که با نمونه‌سازی مبتنی بر درون‌یابی پیکسل‌های همسایه انجام می‌شود (Long et al., 2015). این عملیات با فیلترهای 3×3 و گام ۲ روی داده‌های به‌دست‌آمده از لایهٔ قبل صورت می‌گیرد. خروجی این لایه نقشه‌های ویژگی با ابعاد $\frac{m}{4} \times \frac{m}{4}$ است. در ادامه، عملیات حذف تصادفی روی نتایج لایهٔ سوم اعمال می‌شود.

بلوک دوم از بخش کدگشا شامل پنج لایه است. در لایهٔ اول^{۱۱} از این بلوک، نتایج بخش کدگذار با نتایج حاصل از بلوک‌های بخش کدگشا، با هدف افزایش بهبود نتایج، ادغام می‌شوند. سپس در لایهٔ دوم، نرمال‌سازی دسته‌ای و بعد، عملیات کانولوشن روی ورودی‌ها اعمال می‌شود. در لایهٔ سوم نیز، عملیات کانولوشن روی نتایج به‌دست‌آمده از لایهٔ پیشین اجرا می‌شود.

در لایهٔ چهارم بار دیگر عملیات بازسازی، به‌منظور افزایش ابعاد نقشه‌های ویژگی، اعمال می‌شود و لایهٔ پنجم عملیات حذف تصادفی را روی نتایج لایهٔ قبل اعمال می‌کند. خروجی این بلوک ۲۵۶ نقشهٔ ویژگی با ابعاد $\frac{m}{4} \times \frac{m}{4}$ است.

معماری بلوک سوم مشابه با معماری بلوک دوم است و همان لایه‌ها، با عملکردی مشابه، روی داده‌ها اعمال می‌شوند. خروجی بلوک سوم ۲۵۶ نقشهٔ ویژگی با ابعاد $m \times m$ است. با اینکه ابعاد خروجی (طول و عرض) این بلوک با ابعاد تصویر ورودی برابر است؛ برای

برای افزایش دقت بازسازی^۱، به بلوک‌های بخش کدگشا ارسال می‌کنند (Ronneberger et al., 2015).

بخش کدگذار: این بخش شامل چهار بلوک است. در بلوک نخست، فقط یک لایهٔ کانولوشن^۲ وجود دارد که تصویر با سه کانال رنگی و ابعاد $m \times m$ را به‌منزلهٔ ورودی، دریافت می‌کند و عملیات کانولوشن را با فیلترهای 3×3 ، با گام‌هایی^۳ به‌طول ۱، روی تصاویر اعمال می‌کند. خروجی این بلوک ۶۴ نقشهٔ ویژگی با ابعاد $m \times m$ خواهد بود (Mnih, 2013).

بلوک دوم شامل چهار لایه است. در لایهٔ نخست^۴ این بلوک، ابتدا نرمال‌سازی دسته‌ای^۵ انجام می‌شود. در ادامه، عملیات کانولوشن با فیلتر 3×3 با گامی^۶ برابر با ۱، بدون گسترش مرز^۷، صورت می‌گیرد. توضیح اینکه نرمال‌سازی دسته‌ای با هدف افزایش سرعت آموزش در نتیجهٔ کاهش تغییرات در لایهٔ قبلی (Ioffe & Szegedy, 2015) انجام می‌گیرد. خروجی این لایه ۱۲۸ نقشهٔ ویژگی با ابعاد $m \times m$ است (Mnih, 2013). لایهٔ دوم در این بلوک لایه‌ای کانولوشنی، با پارامترها و ابعاد خروجی مشابه با لایهٔ کانولوشنی قبلی است. در لایهٔ سوم^۸، عملیات ادغام براساس بیشترین مقدار برای کاهش ابعاد نقشه‌های ویژگی به $\frac{m}{4} \times \frac{m}{4}$ روی خروجی لایهٔ قبل اعمال می‌شود. در آخرین لایه از این بلوک، از راهکار حذف تصادفی^۹ برای جلوگیری از بیش‌برازش استفاده شده است. در این راهکار، تعدادی از خروجی‌های یک لایه (در زمان آموزش شبکه) به‌صورت تصادفی انتخاب می‌شوند و از آنها به‌منزلهٔ ورودی لایهٔ بعدی استفاده نمی‌شود.

بلوک سوم و چهارم، هر دو، شامل پنج لایه‌اند که شباهت بسیاری به بلوک دوم دارند. تنها تفاوت این بلوک‌ها با بلوک دوم در تعداد و ابعاد لایه‌های کانولوشنی است. خروجی بلوک سوم و چهارم به‌ترتیب ۲۵۶ و ۵۱۲ نقشهٔ ویژگی، با ابعاد به‌ترتیب $\frac{m}{4} \times \frac{m}{4}$ و $\frac{m}{8} \times \frac{m}{8}$ است.

بخش کدگشا: این بخش نیز شامل چهار بلوک می‌شود. نخستین بلوک این بخش از چهار لایه تشکیل شده است. لایهٔ اول یک لایهٔ کانولوشن است که ورودی آن همان خروجی بخش کدگذار است و عملیات کانولوشن با فیلتر 3×3 و گام ۱، بدون گسترش مرز،

1. Reconstruction
2. Conv.
3. Stride
4. BN-Conv.
5. Batch Normalization (BN)
6. Stride
7. Padding
8. MaxPooling
9. Dropout
10. UP-Conv.
11. Concat.

بهبود دقت و کیفیت برچسب‌گذاری، دو بلوک دیگر نیز در معماری پیشنهادی لحاظ شده است.

می‌شود. این داده‌ها را مینه (۲۰۱۳) گردآوری کرده و در اختیار عموم پژوهشگران قرار داده است. اندازه تمامی تصاویر گردآمده ۱۵۰۰×۱۵۰۰ پیکسل و وضوح آنها ۱ مترمربع بر پیکسل (پیکسل‌های یک‌متری) است. هر تصویر تقریباً ۲.۲۵ کیلومترمربع از شهر بوستون را پوشش می‌دهد. تعداد تصاویر برداشت‌شده از جاده‌ها و ساختمان‌ها به ترتیب برابر با ۱۱۷۱ و ۱۵۱ است.

از آن‌جا که هدف، در معماری پیشنهادی، تشخیص هم‌زمان جاده و ساختمان و عوارض طبیعی است؛ مجموعه تصاویر جاده‌ها و ساختمان‌ها باید با هم ادغام شوند (Saito et al., 2016). اختلاف تعداد تصاویر در این دو مجموعه چالشی در برابر ادغام شمرده می‌شود. برای حل این چالش، می‌توان مجموعه تصاویر ساختمان‌ها را به‌منزله مینا در نظر گرفت و تصاویر جاده متناظر با پایگاه داده ساختمان‌ها را انتخاب کرد (Ibid.). به این ترتیب، از ۱۱۷۱ تصویر جاده، ۱۵۱ تصویر انتخاب می‌شوند که همتای آنها در مجموعه تصاویر ساختمان‌ها موجود است. در جدول ۱، جزئیات شیوه تقسیم‌بندی بانک تصاویر برای انجام دادن آزمایش‌ها ارائه شده است. شکل ۵ نیز نمونه‌هایی از تصاویر و برچسب متناظرشان را که به‌صورت دستی ایجاد شده‌اند (Mnih, 2013)، نشان می‌دهد.

در لایه نخست بلوک چهارم، ابتدا نتایج لایه‌های قبلی با نقشه‌های به‌دست‌آمده از قسمت کدگذار ترکیب می‌شوند و سپس در لایه‌های بعدی، عملیات کانولوشن روی داده‌ها اعمال می‌شود. لایه آخر لایه بازسازی با گام ۱ است. نتایج حاصل، به‌منزله ورودی آخرین بلوک، به یک لایه کانولوشن با اندازه فیلتر ۱×۱ و سه نقشه ویزگی داده می‌شوند تا بازسازی نهایی انجام شود. در آخرین گام، از یک تابع نگاشت برای به‌دست‌آوردن نتیجه نهایی و برچسب‌های پیش‌بینی شده استفاده می‌شود.

۴- آزمایش‌ها


برای ارزیابی کارایی روش پیشنهادی، آزمایش‌های متعددی روی مجموعه‌ای از تصاویر هوایی انجام شده و کارایی روش پیشنهادی نیز، با دیگر روش‌های مشابه، مقایسه شده است. در این بخش، نحوه انجام شدن آزمایش‌ها و نتایج تجربی به‌دست‌آمده بیان می‌شود.

۴-۱- بانک تصاویر

در راستای ارزیابی معماری پیشنهادی، از بانک تصاویر هوایی جاده‌ها و ساختمان‌های ماساچوست^۱ استفاده

جدول ۱. جزئیات تقسیم‌بندی بانک تصاویر ماساچوست

نام مجموعه	تعداد تصاویر آموزشی	تعداد تصاویر آزمایشی	تعداد تصاویر اعتبارسنجی
جاده	۱۱۰۸	۴۹	۱۴
ساختمان	۱۳۷	۱۰	۴
جاده و ساختمان	۱۳۷	۱۰	۴



شکل ۵. نمونه‌ای از تصاویر جاده‌ها و ساختمان‌های شهر بوستون در بانک تصاویر هوایی ماساچوست. تصویر هوایی (الف)؛ برچسب جاده‌ها (ب)؛ برچسب ساختمان‌ها (پ)؛ برچسب جاده‌ها و ساختمان‌ها (ت)

1. Massachusetts

۴-۲- سخت‌افزار

در طول فرایند آموزش شبکه، وزن‌ها با استفاده از الگوریتم بهینه‌ساز RMSprop^۴ (Aggarwal, 2018) به‌روز می‌شوند. مقادیر ابرپارامترها (نرخ یادگیری، نرخ حذف تصادفی و کاهش نرخ یادگیری)، در هر به‌روزرسانی، براساس مقادیر پیش‌فرض پیشنهادی در کتابخانه Keras انتخاب شده‌اند؛ نرخ یادگیری برابر با 10^{-3} ، نرخ حذف تصادفی برابر با ۰.۵ و کاهش نرخ یادگیری برابر با 10^{-5} در نظر گرفته می‌شوند.

برای انجام‌دادن آزمایش‌ها، از سیستمی رایانه‌ای با پردازنده Intel Xeon E5 2620 V4، شانزده گیگابایت حافظه اصلی و پردازنده گرافیکی GTX 1070 با هشت گیگابایت حافظه استفاده شده است. زبان برنامه‌نویسی به‌کاررفته پایتون و کتابخانه استفاده‌شده برای یادگیری عمیق Keras^۱ است.

۴-۳- تنظیمات

مطابق با پژوهش‌های مشابه (Miikkulainen et al., 2019)، تابع نگاشت به‌کاررفته در تمامی لایه‌ها ReLU است. مزیت اصلی این تابع، بر دیگر توابع نگاشت، جلوگیری از فعال‌شدن هم‌زمان همه نورون‌هاست و نتایج تجربی بسیاری بیان می‌کند استفاده از این تابع عملکرد شبکه را، در مقایسه با توابع دیگر، بهبود چشمگیری می‌بخشد (Eckle & Schmidt-Hieber, 2019). اندازه فیلتر ادغام 2×2 در نظر گرفته شده و از تابع هزینه آنتروپی متقاطع^۲ به‌همراه تابع نگاشت سافت‌مکس در لایه خروجی استفاده شده است (Kozma et al., 2018). تابع سافت‌مکس: این تابع نگاشت طبق رابطه (۱) تعریف می‌شود.

$$p_k(i, j) = \frac{\exp(a_k(i, j))}{\sum_{k=1}^K \exp(a_k(i, j))} \quad (۱)$$

در رابطه (۱)، $a_k(i, j)$ مقدار پیکسل در موقعیت (i, j) کانال k ام نقشه و ویژگی تولیدشده در آخرین لایه کانولوشن است. K تعداد کلاس‌ها و $p_k(i, j)$ احتمال محاسبه‌شده در موقعیت (i, j) کانال k است.

تابع آنتروپی متقاطع: این تابع انحراف و تغییر $p_k(i, j)$ از مقدار درست آن در تصویر را براساس رابطه (۲) محاسبه می‌کند.

$$L = -\sum_{i=1}^h \sum_{j=1}^w \sum_{k=1}^K l_k(i, j) \ln(p_k(i, j)) \quad (۲)$$

در رابطه (۲)، w و h به‌ترتیب عرض و طول تصویر، $l_k(i, j)$ مقدار پیکسل در موقعیت (i, j) کانال k ام تصویر برچسب مناسبت^۳ و $p_k(i, j)$ هم مقدار پیکسل (i, j) کانال k ام تصویر برچسب پیش‌بینی شده هستند.

۴-۴- معیارهای ارزیابی سیستم

دقت^۵ (رابطه (۳)) و صحت^۶ (رابطه (۴)) جزء معیارهای رایج برای ارزیابی نتایج تشخیص جاده و ساختمان در تصاویر هوایی محسوب می‌شوند. در روابط (۳) و (۴)، TP ^۷ و FP ^۸ و FN ^۹ به‌ترتیب نمایانگر مثبت‌های صحیح، مثبت‌های کاذب و منفی‌های کاذب‌اند. در تشخیص جاده یا ساختمان در تصاویر هوایی، «دقت» عبارت است از نسبت پیکسل‌های درست جاده یا ساختمان در تصاویر برچسب به تعداد پیکسل‌های تشخیص‌داده‌شده به‌منزله جاده یا ساختمان در تصاویر پیش‌بینی شده و «صحت» عبارت است از نسبت کل پیکسل‌های تشخیص‌داده‌شده به پیکسل‌های صحیح.

$$\mathcal{P} = \frac{TP}{TP+FP} \quad (۳)$$

$$\mathcal{R} = \frac{TP}{TP+FN} \quad (۴)$$

در پژوهش‌های مینه^{۱۰} (۲۰۱۳) و سایتو و همکاران (۲۰۱۶)، به‌جای استفاده از دقت و صحت برای ارزیابی نتایج آزمایش‌ها، عبارت دقت سست^{۱۱} و صحت سست^{۱۱}

1. <https://keras.io/>
2. Cross entropy
3. Ground truth
4. Root Mean Square Propagation
5. Precision
6. Recall
7. True Positive
8. False Positive
9. False Negative
10. Relaxed precision
11. Relaxed recall

با توجه به اینکه راهکار پیشنهادی مبتنی بر استفاده از بلوک‌بندی تصویر ورودی به مجموعه‌ای از قطعات است؛ بنابراین، لازم است اندازه مناسب قطعات در معماری پیشنهادی پیدا شود. به همین منظور، آزمایش‌های گوناگونی با اندازه قطعات متفاوت (۳۰ × ۳۰، ۴۰ × ۴۰، ۵۰ × ۵۰، ۶۰ × ۶۰ و ۷۰ × ۷۰) انجام شده است. توضیح اینکه بلوک‌بندی تصاویر به‌روشنی غیرهم‌پوشانی انجام می‌گیرد؛ به‌این ترتیب، قطعات ایجاد شده هیچ بخش مشترکی با هم ندارند. جدول ۲ نتایج به‌دست‌آمده از این آزمایش‌ها را نشان می‌دهد. در این جدول، بهترین نتایج در هر ستون با قلم ضخیم مشخص شده‌اند. همچنین، منحنی‌های دقت-صحت متناظر نیز در شکل ۶ نشان داده شده‌اند.

بررسی نتایج جدول ۲ نشان می‌دهد استفاده از قطعاتی با ابعاد ۵۰×۵۰ و ۶۰×۶۰، در روش پیشنهادی، کارایی بهتری در مقایسه با دیگر ابعاد دارد. در این میان، با توجه به اینکه کارایی روش پیشنهادی با قطعاتی با ابعاد ۵۰×۵۰ اغلب بیشتر از قطعات دارای ابعاد ۶۰×۶۰ است، می‌توان نتیجه گرفت اندازه مناسب قطعه‌بندی، در روش پیشنهادی برای تصاویر هوایی ماساچوست با تراکم ۱ مترمربع بر پیکسل، ۵۰×۵۰ است.

به‌کار رفته است. «دقت سست» به بخشی از پیکسل‌های شناسایی شده در تصویر پیش‌بینی شده گفته می‌شود که در شعاع ρ پیکسل برجسته قرار دارند و «صحت سست» به بخشی از پیکسل‌های صحیح اطلاق می‌شود که در شعاع ρ پیکسل شناسایی شده‌اند. طبق پژوهش مینه (۲۰۱۳)، مقدار ρ در تمامی آزمایش‌ها برابر با ۳ پیکسل در نظر گرفته شده است. یکی از شیوه‌های رایج برای ارزیابی کارایی تشخیص نیز استفاده از منحنی دقت-صحت است که رابطه بین دقت و صحت را برای آستانه‌های متفاوت، نشان می‌دهد (Mnih, 2013). به‌عبارتی، برای رسم این منحنی، نقاط گوناگون به‌منزله مجموعه‌ای از مقادیر دقت و صحت با آستانه $t \in [0,1]$ محاسبه می‌شوند. سپس این منحنی با نقطه سربه‌سر^۱، که در آن مقدار دقت و صحت با هم برابرند، خلاصه می‌شود. در این پژوهش نیز، از نقطه سربه‌سر به‌منزله معیاری برای ارزیابی و مقایسه کارایی روش پیشنهادی استفاده می‌شود.

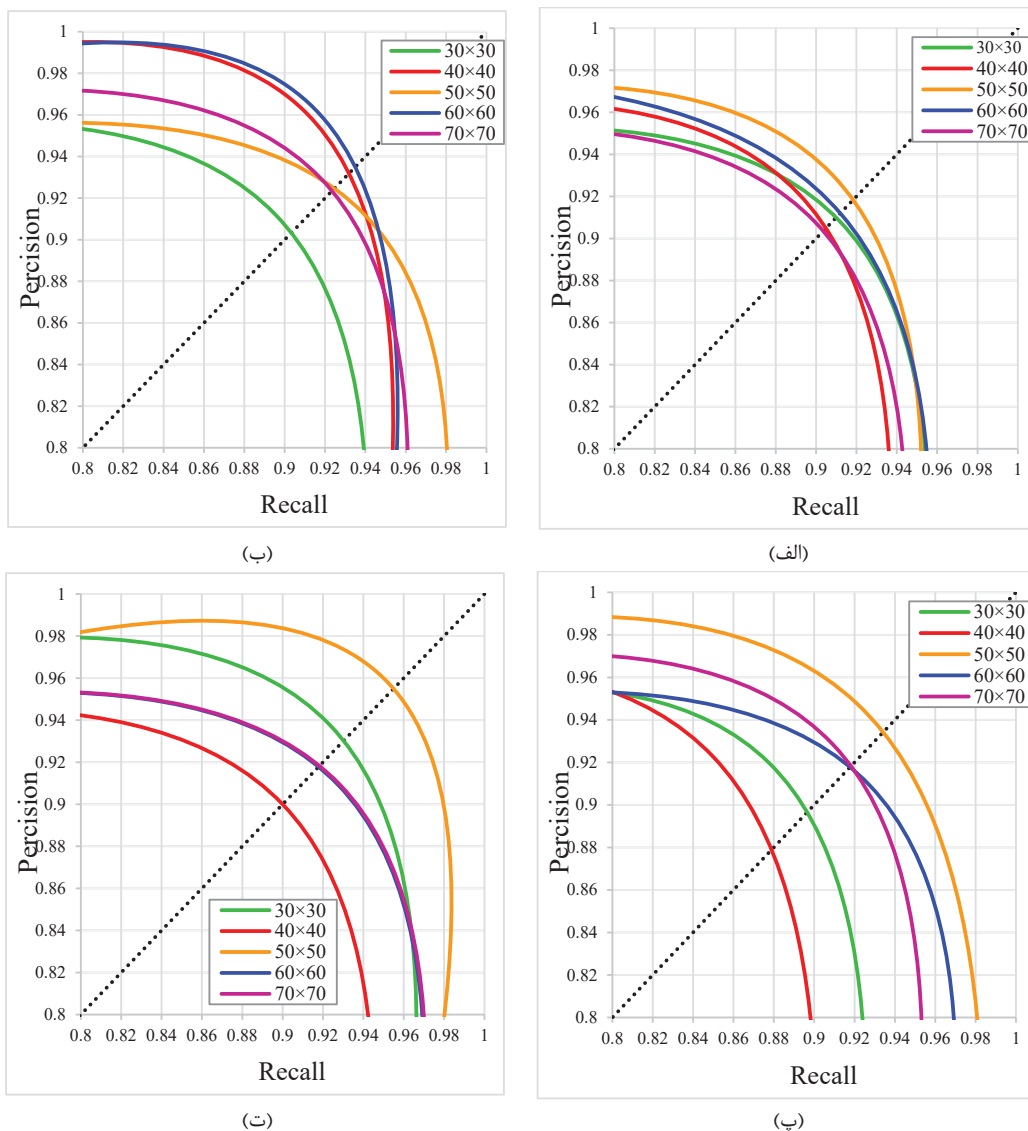
۵-۴- نتایج

برای نشان‌دادن کارایی روش پیشنهادی و مقایسه آن با کارهای انجام‌شده پیشین، شبکه یک‌بار به‌صورت مجزا (تک‌کلاس) با مجموعه تصاویر جاده، یک‌بار به‌صورت مجزا (تک‌کلاس) با مجموعه تصاویر ساختمان و بار دیگر، به‌صورت یک‌جا (چندکلاس) با مجموعه تصاویر جاده و ساختمان ارزیابی می‌شود (جدول ۱).

جدول ۲. ارزیابی دقت (P)، صحت (R) و نقطه سربه‌سر (B) روش پیشنهادی برای تشخیص جاده و ساختمان از عوارض طبیعی، با در نظر گرفتن ابعاد گوناگون قطعه‌بندی

اندازه قطعه‌ها	چندکلاس						تک‌کلاس					
	ساختمان			جاده			ساختمان			جاده		
	B	R	P	B	R	P	B	R	P	B	R	P
۳۰ × ۳۰	۸۶.۶	۸۷.۳	۸۵.۲	۸۷.۹	۸۷.۸	۸۲.۶	۹۰.۳	۸۹.۵	۹۱.۲	۹۰.۱	۸۹.۱	۹۰.۹
۴۰ × ۴۰	۹۲.۴	۸۸.۳	۹۳.۹	۹۱.۶	۹۲.۳	۹۲.۰	۹۳.۲	۹۰.۹	۹۳.۰	۹۴.۰	۹۱.۱	۹۱.۲
۵۰ × ۵۰	۹۳.۲	۹۲.۳	۹۶.۶	۹۳.۵	۹۲.۱	۹۴.۸	۹۵.۶	۹۴.۰	۹۶.۲	۹۴.۹	۹۰.۸	۹۳.۱
۶۰ × ۶۰	۹۱.۷	۹۱.۶	۹۶.۳	۹۱.۹	۹۲.۸	۹۰.۹	۹۳.۵	۹۱.۳	۹۶.۶	۹۴.۲	۹۱.۲	۹۱.۱
۷۰ × ۷۰	۹۱.۹	۹۰.۱	۹۵.۹	۹۱.۹	۹۰.۹	۹۲.۹	۹۲.۳	۹۱.۸	۹۳.۰	۹۲.۳	۹۰.۰	۹۰.۸

1. Breakeven Point



شکل ۶. منحنی‌های دقت- صحت حاصل از روش پیشنهادی به‌ازای اندازه‌ی قطعات متفاوت: جاده- تک‌کلاس (الف)؛ ساختمان- تک‌کلاس (ب)؛ جاده- چندکلاس (پ)؛ ساختمان- چندکلاس (ت)

منحنی‌های دقت- صحت حاصل می‌شود این است که میانگین درصد دقت بیشتر از میانگین درصد صحت است (۲۰٫۸٪ بزرگ‌تر، با در نظر گرفتن قطعات دارای ابعاد ۵۰×۵۰) و این نشان می‌دهد که کیفیت شناسایی جاده‌ها و ساختمان‌ها از عوارض طبیعی مطلوب است. بررسی نقاط سربه‌سر در حالت تک‌کلاس و چندکلاس نیز نشان می‌دهد کارایی معماری، در حالت

همچنین، ملاحظه می‌شود که دقت بازشناسایی ساختمان، در هر دو حالت تک‌کلاس و چندکلاس، بیشتر از دقت تشخیص جاده است. دلیل این موضوع را می‌توان ابعاد بزرگ‌تر ساختمان‌ها در تصاویر دانست که باعث افزایش قدرت تفکیک‌پذیری آنها از عوارض طبیعی (مانند چمن‌زارها، درخت‌ها، رودخانه‌ها) می‌شود. نکته مهم دیگری که از بررسی این جدول و

۴-۵- مقایسه با سایر روش‌ها

در این بخش، کارایی روش پیشنهادی با دیگر روش‌های شناخته‌شده تشخیص جاده و ساختمان، در تصاویر هوایی، مقایسه و ارزیابی می‌شود. ملاک انتخاب روش‌های مورد مقایسه، نخست، بانک تصاویر هوایی است که در همگی آنها، به‌طور مشترک، از بانک تصاویر ماساچوست استفاده شده است و دوم اینکه تمامی این روش‌ها از معماری کانولوشنی استفاده کرده‌اند.

در بیشتر روش‌ها، به‌دلیل ناتوانی در تشخیص هم‌زمان جاده و ساختمان از عوارض طبیعی، نتایج با در نظر گرفتن فقط یک کلاس (جاده یا ساختمان و عوارض طبیعی) مطرح شده است. باید اشاره کرد که در برخی از این پژوهش‌ها، از نقطه سربه‌سر به‌منزله معیار ارزیابی استفاده نشده است؛ در این‌گونه موارد، معیارهای دقت و صحت گزارش شده مد نظر قرار گرفته‌اند.

شایان ذکر است که برای مقایسه عادلانه مدت زمان آموزش معماری پیشنهادی با روش‌های دیگر، پژوهشگران این مقاله تمامی الگوریتم‌های مورد مقایسه را روی سخت‌افزاری یکسان (رک. بخش ۴-۲) اجرا کرده و نتایج را در جدول ۳ گزارش داده‌اند^۱.


با مطالعه ستون رویکرد در جدول ۳، می‌توان به این نتیجه رسید که هیچ‌یک از روش‌های مورد مقایسه هم‌زمان از رویکرد چندکلاس و کاملاً کانولوشنی برای تشخیص بهره نبرده است. در حقیقت، در معماری پیشنهادی، با ترکیب رویکرد چندکلاس و معماری کاملاً کانولوشنی، مدل یکپارچه‌ای به‌دست آمده که هم‌زمان قادر به تشخیص جاده و ساختمان از عوارض طبیعی است. نتیجه مستقیم این معماری کاهش پیچیدگی مسئله تشخیص و نیز کاهش مدت زمان آموزش و ساخت مدل یکپارچه با یک‌بار آموزش است و این درحالی است که در روش‌های تک‌کلاس، لازم است یک مدل مجزا برای هر کلاس ساخته شود.

چندکلاس، اندکی کمتر از حالت تک‌کلاس است؛ ۱.۴٪ کاهش در تشخیص جاده و ۲.۴٪ کاهش در تشخیص ساختمان. دلیل چنین کاهش را می‌توان در دو عامل جستجو کرد. نخست اینکه تعداد تصاویر آموزشی در این آزمایش، به‌نسبت تعداد تصاویر آموزشی در حالت تک‌کلاس، به‌دلیل یکسان‌سازی، کاهش چشمگیری داشته و در نتیجه، قدرت یادگیری شبکه کاهش یافته است. دوم اینکه فرموله‌سازی مسئله به‌شکل چندکلاسی باعث می‌شود احتمال قرارگیری پیکسل‌های یک کلاس در کلاس‌های دیگر افزایش پیدا کند (Nogueira et al., 2017).


شکل ۷ نمونه‌ای از نتایج به‌دست‌آمده از تشخیص جاده‌ها و ساختمان‌ها در روش پیشنهادی را نشان می‌دهد. طبق شکل ۷-الف، به‌دلیل مساحت کمی که جاده‌ها در کل تصویر اشغال کرده‌اند، معماری پیشنهادی در فاز کدگشایی و حین بازسازی نقشه‌های ویژگی، اندکی از اطلاعات مربوط به جاده‌ها را از دست داده و در مواقعی، به‌اشتباه، عوارض طبیعی و ساختمان‌ها را به‌منزله جاده شناسایی کرده است. اما چنانکه شکل ۷-ب نشان می‌دهد، این مشکل به‌ندرت در تشخیص ساختمان‌ها رخ داده است. شکل‌های ۷-پ و ۷-ت نیز عملکرد روش پیشنهادی را در تشخیص هم‌زمان جاده‌ها و ساختمان‌ها از عوارض طبیعی نشان می‌دهند. نکته مهم در این شکل‌ها آن است که، حتی با توجه به استفاده از معماری یکپارچه، قابلیت تشخیص هم‌زمان جاده و ساختمان به‌شکل مطلوبی حفظ شده و سیستم، فقط در تراکم شدید و حضور سایه، دچار اشتباه شده است.

نکته درخور توجه دیگری که در نتایج نشان‌داده‌شده در شکل ۷ وجود دارد عبارت است از اینکه مرزهای نواحی برچسب‌دار شده در روش پیشنهادی چگال‌اند و پیوستگی بسیار مطلوبی دارند (برای مقایسه، رک. شکل ۱). دلیل چنین خروجی مطلوبی را می‌توان در آرایش مناسب لایه‌های بخش کدگشایی معماری پیشنهادی دانست که با آزمایش‌های متعددی، حاصل شده است.


۱. در بیشتر موارد، در مکاتبه با نویسندگان مقالات مورد نظر، کدهای الگوریتم‌های مورد مقایسه در اختیار پژوهشگران این مقاله قرار گرفته است. در مواردی که این کدها در دسترس نبود، پژوهشگران این مقاله آنها را اعمال کرده‌اند.




(الف)



(ب)



(پ)



(ت)

شکل ۷. نمونه‌ای از عملکرد روش پیشنهادی در تشخیص جاده‌ها و ساختمان‌های بانک تصاویر هوایی ماساچوست: تشخیص جاده‌ها (تک‌کلاس) (الف)؛ تشخیص ساختمان‌ها (تک‌کلاس) (ب)؛ تشخیص جاده‌ها و ساختمان‌ها (چندکلاس) (پ و ت)

۵- نتیجه‌گیری و محورهای مطالعه و توسعه بیشتر

تا کنون پژوهش‌های بسیاری، به منظور خودکارسازی تشخیص جاده‌ها و ساختمان‌ها در تصاویر هوایی، صورت گرفته است. در پژوهش‌های اخیر، با توجه به نتایج خیره‌کننده به دست آمده از طریق شبکه‌های عصبی کانولوشنی در حوزه بینایی ماشین، استفاده از این شبکه‌ها بیشتر مورد توجه قرار گرفته اما در اغلب این کارها، از رویکرد تشخیص مجزای جاده‌ها و ساختمان‌ها استفاده شده است. به عبارتی، مدل‌های مجزایی برای تشخیص جاده و ساختمان از عوارض طبیعی ساخته می‌شوند. همچنین، رویکرد اصلی در این پژوهش‌ها استفاده از معماری‌های کانولوشنی با یک یا چند لایه کاملاً متصل است. در این پژوهش، با هدف کاهش پیچیدگی مدل و افزایش سرعت ساخت آن، شبکه‌ای کاملاً کانولوشنی مورد توجه قرار گرفت که قادر به تشخیص هم‌زمان جاده و ساختمان است. روش پیشنهادی، با اندازه قطعات متفاوت، روی بانک تصاویر هوایی ماساچوست آزموده شد و نتایج نشان داد این روش، با قطعات به ابعاد 50×50 ، کارایی بهتری دارد. مقایسه و ارزیابی معماری پیشنهادی با سایر معماری‌ها نیز حاکی از این بود که پیچیدگی معماری پیشنهادی به طور مطلوبی کم است و مدت زمان ساخت مدل براساس آن تقریباً ۳۸٪ کمتر از دیگر معماری‌های

با مطالعه مدت زمان ساخت مدل، این نتیجه به دست می‌آید که زمان صرف شده برای این کار، براساس معماری پیشنهادی، تقریباً برابر با سایر معماری‌های کاملاً کانولوشنی است و این نشان می‌دهد طراحی معماری پیشنهادی باعث به وجود آمدن هزینه محاسباتی معناداری نشده است.

مقایسه مدت زمان ساخت مدل با استفاده از معماری پیشنهادی با رویکردهای چندکلاسی، که از لایه کاملاً متصل بهره می‌برند (Saito et al., 2017; Alshehhi et al., 2016)، نشان می‌دهد زمان ساخت مدل با معماری پیشنهادی تقریباً ۳۸٪ از شیوه سایتو و همکاران (۲۰۱۶) و ۳۶٪ از روش آلشچی و همکاران (۲۰۱۷) سریع تر است.

مقایسه نقطه سربه‌سر روش‌های مطرح شده در دو پژوهش سطرهای پیشین نیز نشان می‌دهد که معماری پیشنهادی تقریباً ۲٪ این معیار را افزایش داده است. علاوه بر این، مقایسه دقت و صحت معماری پیشنهادی، با در نظر گرفتن فقط یک کلاس، نیز نشان می‌دهد روش پیشنهادی، با وجود استفاده از رویکرد چندکلاسی، دقت و صحت روش مورد اشاره در تحقیق پنبونیون و همکاران (۲۰۱۷) را به ترتیب ۷.۲٪ و ۱.۴٪ افزایش داده و دقت آن، در تشخیص جاده، فقط ۱.۱٪ کمتر از معماری مورد نظر پژوهش هوئی و همکاران (۲۰۱۸) است.

جدول ۳. مقایسه کارایی روش پیشنهادی با دیگر روش‌های مبتنی بر معماری کانولوشنی، در تشخیص ساختمان‌ها و جاده‌ها از عوارض طبیعی، با استفاده از بانک تصاویر ماساچوست

رویکرد	زمان (ساعت)	جاده و ساختمان		ساختمان			جاده			سال	پژوهش
		B	R	P	B	R	P				
تک کلاس- کانولوشنی با لایه کاملاً متصل	۱۰۸	-	۹۲.۰	-	-	۹۰.۰	-	-	۲۰۱۳	مینه، ۲۰۱۳	
چند کلاس- کانولوشنی با لایه کاملاً متصل	۱۰۱	۹۳.۳	۹۴.۳	-	-	۹۰.۰	-	-	۲۰۱۶	سایتو و دیگران، ۲۰۱۶	
تک کلاس- کاملاً کانولوشنی	۶۵	-	-	-	-	-	۸۹.۴	۸۵.۸	۲۰۱۷	پنبونیون و دیگران، ۲۰۱۷	
چند کلاس- کانولوشنی با لایه کاملاً متصل	۹۸	۹۳.۲	-	-	-	-	-	-	۲۰۱۷	آلشچی و دیگران، ۲۰۱۷	
تک کلاس- کاملاً کانولوشنی	۵۹	-	-	-	-	-	-	۹۴.۲	۲۰۱۸	هوئی و دیگران، ۲۰۱۸	
چند کلاس- کاملاً کانولوشنی	۶۳	۹۵.۱	۹۵.۶	۹۴.۰	۹۶.۲	۹۴.۹	۹۰.۸	۹۳.۱		روش پیشنهادی	

- Constraints**, IEEE Transactions on Geoscience and Remote Sensing, 52(10), PP. 6627-6638.
- Bai, X., Zhang, H. & Zhou, J., 2014, **VHR Object Detection Based on Structural Feature Extraction and Query Expansion**, IEEE Transactions on Geoscience and Remote Sensing, 52(10), PP. 6508-6520.
- Chen, L.-C., Papandreou, G., Kokkinos, I., Murphy, K. & Yuille, A., 2014, **Semantic Image Segmentation with Deep Convolutional Nets and Fully Connected Crfs**.
- Chen, L., Zhu, Q., Xie, X., Hu, H. & Zeng, H., 2018, **Road Extraction from VHR Remote-Sensing Imagery via Object Segmentation Constrained by Gabor Features**, ISPRS Int. J. Geo-Inf., 7(9), P. 362.
- Cheng, G. & Han, J., 2016, **A Survey on Object Detection in Optical Remote Sensing Images**, ISPRS Journal of Photogrammetry and Remote Sensing, 117, PP. 11-28.
- Cheng, Y., Wang, D., Zhou, P. & Zhang, T., 2018, **Model Compression and Acceleration for Deep Neural Networks: The Principles, Progress, and Challenges**, IEEE Signal Processing Magazine, 35(1), PP. 126-136.
- Chollet, F., 2017, **Xception: Deep Learning with Depthwise Separable Convolutions**, Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition.
- Clinton, N., Holt, A., Scarborough, J., Yan, L. & Gong, P., 2010, **Accuracy Assessment Measures for Object-Based Image Segmentation Goodness**, Photogramm. Eng. Remote Sens., 76(3), PP. 289-299.
- Contreras, D., Blaschke, T., Tiede, D., Gilje, M.J.C. & Science, G.I., 2016, **Monitoring Recovery after Earthquakes through the Integration of Remote sensing, GIS, and Ground Observations: The Case of L'Aquila (Italy)**, Cartography and Geographic Information Science, 43(2), PP. 115-133.
- چندکلاسی است. علاوه بر این، نشان داده شد که بهبود دقت مدل ساخته شده در مقایسه با مدل های چندکلاسی، ۲٪ بیشتر است.
- یافته‌ها و نتایج این پژوهش نویسندگان را بر آن داشته است به موارد زیر به صورت نقشه راه پژوهش‌های آتی خود، با هدف بهبود دقت و تسریع تشخیص اشیا در تصاویر هوایی، توجه داشته باشند:
- بررسی کارآیی توابع نگاشت متفاوت و پیشنهاد تابع نگاشت جدیدی متناسب با مسئله مفروض؛
 - استفاده از قطعه‌بندی با در نظر گرفتن هم‌پوشانی، برای جلوگیری از حذف اطلاعات لبه در تصاویر.
- ۶- منابع
- فرج‌زاده، ن.، هاشم‌زاده، م.، ۱۳۹۸، **تشخیص سازه‌های ساخت بشر در تصاویر هوایی با استفاده از ویژگی‌های آماری مبتنی بر رنگ و یادگیری ماشین**، سنجش از دور و GIS ایران، سال یازدهم، شماره ۳، صص. ۴۲-۲۱.
- Achanta, R., Shaji, A., Smith, K., Lucchi, A., Fua, P. & Süsstrunk, S., 2012, **SLIC Superpixels Compared to State-of-the-Art Superpixel Methods**, IEEE Transactions on Pattern Analysis and Machine Intelligence, 34(11), PP. 2274-2282.
- Aggarwal, C.C., 2018, **Neural Networks and Deep Learning**, Springer.
- Akçay, H.G. & Aksoy, S., 2010, **Building Detection Using Directional Spatial Constraints**, Geoscience and Remote Sensing Symposium (IGARSS), 2010 IEEE International, IEEE.
- Alshehhi, R., Marpu, P.R., Woon, W.L., Dalla Mura, M. & Sensing, R., 2017, **Simultaneous Extraction of Roads and Buildings in Remote Sensing Imagery with Convolutional Neural Networks**, ISPRS Journal of Photogrammetry and Remote Sensing, 130, PP. 139-149.
- Arı, Ç., Aksoy, S. & Sensing, R., 2014, **Detection of Compound Structures Using a Gaussian Mixture Model with Spectral and Spatial**

- Das, S., Mirnalinee, T., Varghese, K. & Sensing, R., 2011, **Use of Salient Features for the Design of a Multistage Framework to Extract Roads from High-Resolution Multispectral Satellite Images**, IEEE Transactions on Geoscience and Remote Sensing, 49(10), PP. 3906-3931.
- Eckle, K. & Schmidt-Hieber, J., 2019, **A Comparison of Deep Networks with ReLU Activation Function and Linear Spline-Type Methods**, Neural Networks, 110, PP. 232-242.
- Feizizadeh, B., Tiede, D., Rezaei Moghaddam, M.H. & Blaschke, T., 2014, **Systematic Evaluation of Fuzzy Operators for Object-Based Landslide Mapping**, South-Eastern European Journal of Earth Observation and Geomatics, 3(2s), PP. 219-222.
- Goodin, D.G., Anibas, K.L. & Bezymennyi, M., 2015, **Mapping Land Cover and Land Use from Object-Based Classification: An Example from a Complex Agricultural Landscape**, International Journal of Remote Sensing, 36(18), PP. 4702-4723.
- Grabner, H., Nguyen, T.T., Gruber, B. & Bischof, H., 2008, **On-Line Boosting-Based Car Detection from Aerial Images**, ISPRS Journal of Photogrammetry and Remote Sensing, 63(3), PP. 382-396.
- Hay, G.J., Blaschke, T., Marceau, D.J., Bouchard A., 2003, **A Comparison of Three Image-Object Methods for the Multiscale Analysis of Landscape Structure**, ISPRS Journal of Photogrammetry and Remote Sensing, 57(5-6), PP. 327-345.
- Hinton, G.E. & Salakhutdinov, R.R., 2006, **Reducing the Dimensionality of Data with Neural Networks**, Science, 313(5786), PP. 504-507.
- Hui, J., Du, M., Ye, X., Qin, Q. & Sui, J., 2018, **Effective Building Extraction From High-Resolution Remote Sensing Images With Multitask Driven Deep Neural Network**, IEEE Geoscience and Remote Sensing Letters, 16(5), PP. 786-790.
- Ioffe, S. & Szegedy, C., 2015, **Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift**.
- Kluckner, S. & Bischof, H., 2009, **Semantic Classification by Covariance Descriptors within a Randomized Forest**, Computer Vision Workshops (ICCV Workshops), 2009 IEEE 12th International Conference on, IEEE.
- Kluckner, S., Mauthner, T., Roth, P.M. & Bischof, H., 2009, **Semantic Classification in Aerial Imagery by Integrating Appearance and Height Information**, Asian Conference on Computer Vision, Springer.
- Kozma, R., Alippi, C., Choe, Y. & Morabito, F.C., 2018, **Artificial Intelligence in the Age of Neural Networks and Brain Computing**, Academic Press.
- Lefèvre, S. & Weber, J., 2007, **Automatic Building Extraction in VHR Images Using Advanced Morphological Operators**, Urban Remote Sensing Joint Event, 2007, IEEE.
- Leitloff, J., Hinz, S. & Stilla, U., 2010, **Vehicle Detection in Very High Resolution Satellite Images of City Areas**, IEEE Transactions on Geoscience and Remote Sensing, 48(7), PP. 2795-2806.
- Leninisha, S. & Vani, K., 2015, **Water Flow Based Geometric Active Deformable Model for Road Network**, ISPRS Journal of Photogrammetry and Remote Sensing, 102, PP. 140-147.
- Li, E., Femiani, J., Xu, S., Zhang, X. & Wonka, P., 2015, **Robust Rooftop Extraction from Visible Band Images Using Higher Order CRF**, IEEE Transactions on Geoscience and Remote Sensing, 53(8), PP. 4483-4495.
- Lin, Y., He, H., Yin, Z. & Chen, F., 2015, **Rotation-Invariant Object Detection in Remote Sensing Images Based on Radial-Gradient Angle**, IEEE Geoscience and Remote Sensing Letters, 12(4), PP. 746-750.
- Liu, G., Sun, X., Fu, K. & Wang, H., 2013, **Aircraft Recognition in High-Resolution Satellite Images Using Coarse-to-Fine**

- Shape Prior**, IEEE Geoscience and Remote Sensing Letters, 1(3), PP. 573-577.
- Liu, W., Wang, Z., Liu, X., Zeng, N., Liu, Y. & Alsaadi, F.E., 2017, **A Survey of Deep Neural Network Architectures and their Applications**, Neurocomputing, 234, PP.11-26.
- Long, J., Shelhamer, E. & Darrell, T., 2015, **Fully Convolutional Networks for Semantic Segmentation**, Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition.
- Maggiori, E., Tarabalka, Y., Charpiat, G. & Alliez, P., 2017, **Convolutional Neural Networks for Large-Scale Remote-Sensing Image Classification**, IEEE Transactions on Geoscience and Remote Sensing, 55(2), PP. 645-657.
- Mayer, H., 1999, **Automatic Object Extraction from Aerial Imagery—A Survey Focusing on Buildings**, Computer Vision and Image Understanding, 74(2), PP. 138-149.
- Miikkulainen, R., Liang, J., Meyerson, E., Rawal, A., Fink, D., Francon, O., Raju, B., Shahrzad, H., Navruzyan, A. & Duffy, N., 2019, **Evolving Deep Neural Networks**, Artificial Intelligence in the Age of Neural Networks and Brain Computing, Elsevier, PP. 293-312.
- Minh, V., 2013, **Machine Learning for Aerial Image Labeling**, University of Toronto (Canada).
- Nogueira, K., Penatti O.A.B. & dos Santos, J.A., 2017, **Towards Better Exploiting Convolutional Neural Networks for Remote Sensing Scene Classification**, Pattern Recognition, 61, PP. 539-556.
- Ok, A.O., Senaras, C. & Yuksel, B., 2013, **Automated Detection of Arbitrarily Shaped Buildings in Complex Environments from Monocular VHR Optical Satellite Imagery**, IEEE Transactions on Geoscience and Remote Sensing, 51(3), PP. 1701-1717.
- Panboonyuen, T., Jitkajornwanich, K., Lawawirojwong, S., Srestasathien, P. & Vateekul, P., 2017, **Road Segmentation of Remotely Sensed Images Using Deep Convolutional Neural Networks with Landscape Metrics and Conditional Random Fields**, Remote Sensing, 9(7), P. 680.
- Ronneberger, O., Fischer, P. & Brox, T., 2015, **U-net: Convolutional Networks for Biomedical Image Segmentation**, International Conference on Medical Image Computing and Computer-Assisted Intervention, Springer.
- Saito, S., Yamashita, T. & Aoki, Y., 2016, **Multiple Object Extraction from Aerial Imagery with Convolutional Neural Networks**, Journal of Imaging Science and Technology, 60(1).
- Seeliger, K., Fritsche, M., Güçlü, U., Schoenmakers, S., Schoffelen, J.-M., Bosch, S. & van Gerven, M.J.N., 2018, **Convolutional Neural Network-Based Encoding and Decoding of Visual Object Recognition in Space and Time**, NeuroImage, 180, PP. 253-266.
- Song, M., Civco, D. & Sensing, R., 2004, **Road Extraction Using SVM and Image Segmentation**, American Society for Photogrammetry and Remote Sensing, 70(12), PP. 1365-1371.
- Sun, H., Sun, X., Wang, H., Li, Y. & Li, X., 2012, **Automatic Target Detection in High-Resolution Remote Sensing Images Using Spatial Sparse Coding Bag-of-Words Model**, IEEE Geoscience and Remote Sensing Letters, 9(1), PP. 109-113.
- Tuermer, S., Kurz, F., Reinartz, P. & Stilla, U., 2013, **Airborne Vehicle Detection in Dense Urban Areas Using HoG Features and Disparity Maps**, IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 6(6), PP. 2327-2337.
- Walker, J. & Blaschke, T., 2008, **Object Based Land Cover Classification for the Phoenix Metropolitan Area: Optimization vs. Transportability**, International Journal of Remote Sensing, 29(7), PP. 2021-2040.

- Wang, H., Nie, F., Huang, H. & Ding, C., 2013, **Heterogeneous Visual Features Fusion via Sparse Multimodal Machine**, Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition.
- Wang, J., Song, J., Chen, M. & Yang, Z., 2015, **Road Network Extraction: A Neural-Dynamic Framework Based on Deep Learning and a Finite State Machine**, International Journal of Remote Sensing, 36(12), PP. 3144-3169.
- Yokoya, N. & Iwasaki, A., 2015, **Object Detection Based on Sparse Representation and Hough Voting for Optical Remote Sensing Imagery**, IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 8(5), PP. 2053-2062.
- Zhao, Y.-Q. & Yang, J., 2015, **Hyperspectral Image Denoising via Sparse Representation and Low-Rank Constraint**, IEEE Transactions on Geoscience and Remote Sensing, 53(1), PP. 296-308.