

Research Article

## Automatic Extraction of Urban Features from Very High-Resolution Digital Data Using Deep Neural Networks: A Case Study of Ahvaz City

Mostafa Kabolizadeh<sup>1\*</sup>, Kazem Rangzan<sup>1</sup>, Nazanin Ghanbari<sup>1</sup>

1- Department of RS and GIS, Faculty of Earth Sciences, Shahid Chamran University of Ahvaz, Ahvaz, Iran

**Keywords:** *Deep Learning, Urban Features Extraction, UNet, VGG-16, Digital Surface Model*

### 1- Introduction

Preparation of urban land coverage maps is essential for many urban plans. It is important to minimize time and costs in this process, which can be a challenge for city managers. Nowadays, satellite and aerial images are commonly employed to create these maps. Since 2014, deep learning techniques have been incorporated into remote sensing research and applied in diverse areas like land use/cover classification, scene classification, and target detection (Vetrivel et al., 2018). Deep learning is a new subject widely used for extracting surface features and classifying remote-sensing images (Chen et al., 2016). Deep Convolutional Neural Networks (DCNNs), with their unique architecture, can extract information from different levels of data. One type of these networks is Full Convolutional Network (FCN) models, which provide optimal output results at the pixel level with their encoder-decoder structure. The UNet model is one of these types of models that can extract high-level information from images (Ronneberger et al., 2015).

### 2- Materials and methods

The present study aims to provide an efficient method for the automatic extraction of urban features, which is done using new methods based on deep learning along with transfer learning methods on VHR aerial images. The city of Ahvaz was chosen as the study area in this research to extract features of its urban classes, such as buildings, green spaces, bare land, and roads, from relevant images. For this purpose, the UNet model, one of the most commonly used models for classifying and extracting features from urban scenes, has been utilized along with the pre-trained VGG-16 network. RGB image bands are used first to train this model, then a combination of RGB bands and an nDSM band are used, and their results are compared. The data was cut into 512x512 patches and divided into three categories: training, testing, and evaluation.

### 3- Results and discussions

Among the data, 60% were used for training, and the model training was done with 50 repetitions. After the model training with two datasets, they were used to predict urban damages on test images. The results of running the model on the data in this study show that the UNet network with the VGG-16 backbone using RGB+nDSM data performs better than the RGB data. Running the model with RGB data showed an OA index of 76.34%, F1 of 73.98%, and mIOU of 74.15%. Similarly, for RGB+nDSM data, the OA, F1, and mIOU indices were 88.14%, 82.52%, and 86.21%, respectively. It has also been determined that in the first case, the green space class and in the second case, the building class have been extracted more accurately.

### 4- Conclusion

This study used VHR aerial images and a digital surface model to create a land cover map and automatically extract features in the Ahvaz 4 region. Deep learning is one of the best methods available in this field, with

\* Corresponding author: m.kabolizade@scu.ac.ir

DOI: 10.22055/aag.2024.47110.2457

Received: 2024-06-09

Accepted: 2024-09-24

various types. The UNet model with VGG-16 backbone was chosen as the architecture for the research. The model was trained with 50 iterations. Based on the results obtained, it became clear that this model extracted classes in the presence of the DSM with a higher overall accuracy (88.14%) than RGB bands (76.34%). Since these maps are important in urban planning, their practical use is recommended for city managers.

## 5- References

- Chen, Y., Jiang, H., Li, C., Jia, X., Ghamisi, P., 2016. Deep feature extraction and classification of hyperspectral images based on convolutional neural networks. *IEEE transactions on geoscience and remote sensing* 54, 6232-6251. <https://doi.org/10.1109/TGRS.2016.2584107>
- Ronneberger, O., Fischer, P. and Brox, T., 2015. U-net: Convolutional networks for biomedical image segmentation. In *Medical image computing and computer-assisted intervention–MICCAI 2015: 18th international conference, Munich, Germany, October 5-9, 2015, proceedings, part III 18* (pp. 234-241). Springer International Publishing. [http://dx.doi.org/10.1007/978-3-319-24574-4\\_28](http://dx.doi.org/10.1007/978-3-319-24574-4_28)
- Vetrivel, A., Gerke, M., Kerle, N., Nex, F., Vosselman, G., 2018. Disaster damage detection through Synergistic use of deep learning and 3D point cloud features derived from very high-resolution oblique aerial images and multiple-kernel-learning. *ISPRS Journal of Photogrammetry And Remote Sensing* 140, 45-59. <https://doi.org/10.1016/j.isprsjprs.2017.03.001>

### HOW TO CITE THIS ARTICLE:

Kabolizadeh. M., Rangzan. K., Ghanbari., N., 2025. Automatic Extraction of Urban Features from Very High-Resolution Digital Data Using Deep Neural Networks: A Case Study of Ahvaz City. *Adv. Appl. Geol.* 14(4), 1058-1071.

DOI: 10.22055/aag.2024.47110.2457

URL: [https://aag.scu.ac.ir/article\\_19517.html](https://aag.scu.ac.ir/article_19517.html)

©2025 The author(s). This is an open access article distributed under the terms of the Creative Commons Attribution (CC BY 4.0), which permits unrestricted use, distribution, and reproduction in any medium, as long as the original authors and source are cited. No permission is required from the authors or the publishers

## استخراج اتوماتیک عوارض شهری از داده‌های رقومی با قدرت تفکیک خیلی بالا با استفاده از مدل شبکه عصبی عمیق (مطالعه موردی: شهر اهواز)

مصطفی کابلی زاده

گروه سنجش از دور و GIS دانشکده علوم زمین، دانشگاه شهید چمران اهواز

کاظم رنگزن

گروه سنجش از دور و GIS دانشکده علوم زمین، دانشگاه شهید چمران اهواز

نازنین قنبری

گروه سنجش از دور و GIS دانشکده علوم زمین، دانشگاه شهید چمران اهواز

\* [m.kabolizade@scu.ac.ir](mailto:m.kabolizade@scu.ac.ir)

تاریخ دریافت: ۱۴۰۳/۰۳/۲۰ تاریخ پذیرش: ۱۴۰۳/۰۷/۰۳

### چکیده

رشد و پیشرفت مداوم در شهرسازی و تغییرات سریع در سطح زمین، نیاز به بررسی مداوم این تغییرات را افزایش داده است. سنجش از دور را می‌توان یکی از مناسب‌ترین روش‌ها برای دستیابی به این هدف دانست. استفاده از روش‌های یادگیری عمیق جهت استخراج عوارض از تصاویر یک روش مرسوم در تهیه نقشه‌های پوشش زمین می‌باشد زیرا قابلیت تحلیل مفاهیم انتزاعی سطح بالا بوسیله آن فراهم می‌گردد. با این اقدام علاوه بر به حداقل رساندن نقش انسان در تولید اطلاعات، باعث کاهش زمان و هزینه می‌گردد. این تحقیق به بررسی استفاده مشترک از باندهای نوری (RGB) و مدل رقومی سطح (nDSM) برای تجزیه و تحلیل یک صحنه شهری می‌پردازد تا توسط آنها ویژگی‌های مهم تصویر را استخراج نماید. در این پژوهش جهت استخراج اتوماتیک عوارض شهری چون ساختمان، فضای سبز، زمین بایر و راه نمونه‌های آموزشی مناسبی از آنها تهیه گردید. از بین معماری‌های متنوع یادگیری عمیق، مدل UNet با توجه به ارائه نتایج با دقت بالاتر، به عنوان مدل اصلی تحقیق برگزیده شد. همچنین از مدل VGG-16 برای بهره‌گیری از تکنیک یادگیری انتقالی، به عنوان پیش‌شبکه استفاده شد. آموزش این شبکه یکبار با سه باند تصاویر هوایی (RGB) و در حالت دیگر با تلفیق باندهای تصاویر با مدل رقومی سطح (RGB+nDSM) صورت گرفت تا نتایج بدست آمده مورد مقایسه قرار گیرند و بهترین روش برای استخراج عوارض شهری معرفی گردد. نتایج نشان دادند که مدل VGG-16+UNet، استخراج کلاس‌ها را در حضور مدل رقومی سطح با صحت کلی بالاتری (۸۸/۱۴٪) نسبت به اجرای مدل با باندهای تصویر هوایی (۷۶/۳۴٪) انجام داده است. همچنین با توجه به این نتایج مشخص گردید که الگوریتم مورد استفاده این پژوهش و معماری آن می‌تواند در تهیه نقشه‌های شهری و کشف تغییرات موثر واقع شود.

**واژه‌های کلیدی:** یادگیری عمیق، استخراج عوارض شهری، UNet، VGG-16، مدل رقومی سطح

### ۱- مقدمه

این مسائل تحلیل مناطق شهری را دشوار می‌کند (Zhang et al., 2019). در نتیجه، نظارت بر مناطق شهری همیشه ضروری است. با توجه به اینکه اکثریت جمعیت جهان در شهرها زندگی می‌کنند، مسائل شهری توجه گسترده‌ای را در سراسر جهان به خود جلب کرده است (Wen et al., 2015). در محیط‌های شهری، جایی که بسیاری از زیرساخت‌ها، پوشش گیاهی و ساخت و سازها به طور مداوم در حال تغییر هستند، نظارت سیستماتیک و به روز رسانی نقشه‌ها حیاتی می‌باشد. در دهه‌های اخیر با پیشرفت فتوگرامتری و توسعه سنسورهای جمع‌آوری داده‌ها، وضوح و سرعت جمع‌آوری داده‌ها افزایش یافته

شهرنشینی جهانی در چند دهه گذشته شتاب چشمگیری داشته است. حدود ۶۸ درصد از جمعیت جهان تا سال ۲۰۵۰ در شهرها زندگی خواهند کرد (United Nations Department of Economic and Social Affairs, 2014). این رشد می‌تواند منجر به مشکلات زیست‌محیطی مختلفی، مانند مسائل اکولوژیکی، کیفیت پایین هوا، بدتر شدن وضعیت سلامت عمومی، تغییرات شدید در آب و هوا و آسیب پذیری مداوم در برابر بلایای طبیعی شود (Shinohara et al., 2020). با توجه به تنوع طیفی و ساختاری و پیچیدگی سطوح شهری،

دیگر مقایسه شد و به بالاترین دقت کلی (۰/۸۷/۸) دست یافتند. Yang و همکاران (۲۰۱۹) در مطالعه خود فرایند استخراج ویژگی های محلی و کلی از تصویر با قدرت تفکیک بالا را ارائه دادند. در این مطالعه، از ترکیب شبکه های باقیمانده (Residual) و ادغام هرمی (Pyramid pooling) استفاده شد. نتایج نشان دادند که مدل های بهره گرفته از ویژگی های عمیق، نسبت به مدل هایی که از ویژگی های دستی استفاده می کنند، خروجی بهتری ارائه می دهند. Sariturk و همکاران (۲۰۲۰) برای تقسیم بندی و استخراج عوارض از تصویر هوایی دو مدل SegNet و FCN را استفاده کردند. این دو معماری نتایج تقریباً مشابهی را در دقت خروجی نشان دادند. Pan و همکاران (۲۰۲۰) از مدل UNet برای تقسیم بندی تصویر Worldview از شهر گوانگژو چین استفاده کردند. این مدل دقت کلی ۸۶٪ را برای استخراج عوارض شهری بدست آورد. Zhang و همکاران (۲۰۲۰) شبکه HRNet را با شاخه های چند مقیاسی موازی برای کاهش از دست دادن اطلاعات مکانی معرفی کردند. معماری پیشنهادی نسبت به رویکردهای موجود پیشرفت های زیادی داد و بهترین نتایج را در مجموعه داده Potsdam برابر ۹۰/۰۷٪ بدست آوردند. McGlinchy و همکاران (۲۰۲۱) در یک محدوده مختلط شهری از شبکه UNet با رمزگذار ResNet-152 استفاده کردند و کلاس های شهری تصویر را استخراج نمودند. آنها در مطالعه خود ۴ باند آبی، سبز، قرمز و مادون قرمز بکار بردند و میانگین دقت ۸۰٪ را برای نتایج بدست آوردند. Abdollahi و همکاران (۲۰۲۱) دو شبکه یادگیری عمیق الهام گرفته از مدل UNet (MCG-UNet و BCL-UNet) برای تقسیم بندی عوارض از تصاویر هوایی، مانند ساختمان ها و جاده ها استفاده کردند. نتایج نشان داد که مدل MCG-UNet شاخص میانگین دقت F1 را به ترتیب ۱/۸۵٪ و ۱/۱۹٪ نسبت به مدل BCL-UNet برای جاده و ساختمان بهبود بخشید. Kaboli Zadeh و همکاران (۲۰۲۳) برای استخراج عوارض شهری تصاویر پهپاد شهر اهواز، از شبکه عصبی کانولوشن بر مبنای آشکارساز چندبند تک شات با پایه شبکه ResNet بهره بردند. نتایج نشان داد که این الگوریتم توانایی بالایی در تولید نقشه های بزرگ مقیاس شهری و تعیین تغییرات شهری دارد. در تصاویر سنجنش از دور، استخراج ویژگی های طیفی و مکانی از اهمیت بالایی برخوردار است. روش های مبتنی بر

است و دسترسی به تصاویر با وضوح بسیار بالا زمینه مناسبی برای تحقیقات در حوزه استخراج ویژگی ها از تصاویر را فراهم آورده است. با رشد و افزایش دسترسی به روش های یادگیری عمیق، استخراج عوارض از تصاویر سنجنش از دور با استفاده از شبکه های عصبی کانولوشنال عمیق (Deep Convolutional Neural Networks) به یکی از روش های اصلی این حوزه تبدیل شده است. این شبکه ها قادرند تا اطلاعات عمیق و مفید نهفته در سطوح مختلف داده ورودی را یاد بگیرند و در ارائه نتایج بهتر به کار بینند. نوعی شبکه کانولوشنی، تحت عنوان شبکه های کانولوشنی کامل (Full Convolutional Network: FCN) با ساختار رمزگذار-رمزگشای (Encoder-Decoder) خود فرایندهای نمونه برداری کاهشی و افزایشی را بر روی داده ورودی انجام می دهند و نتایج مناسبی را در سطح پیکسل بدست می آورند (Liu et al., 2018). در شبکه های FCN، تولید نقشه های ویژگی با استفاده از لایه های کانولوشن و پولینگ در بخش رمزگذار انجام می پذیرد. فرایند نمونه برداری کاهشی هم در این قسمت رخ می دهد. خروجی این قسمت تفکیک مکانی پایینی دارد و باید برای انجام بقیه فرایند و تکمیل آن وارد بخش رمزگشا شود. در رمزگشا لایه های کانولوشنی معکوس و فرایند نمونه برداری افزایشی، باعث بالا رفتن تفکیک مکانی نقشه های خروجی شده و نقشه هایی دقیقاً مشابه ابعاد داده ورودی تولید می شوند (Long et al., 2015). شبکه های UNet (Ronneberger et al., 2015)، SegNet (Chen et al., 2017) و DeepLabv3+ (Badrinarayanan et al., 2017) (et al., 2018) PSPNet (He et al., 2015) و HRNet (Sun et al., 2019) مثال هایی از این مدل شبکه ها می باشند. برای استفاده از این مدل ها به حجم زیادی از داده های آموزشی برچسب گذاری شده نیاز است. این مدل ها، ویژگی ها و اطلاعات معنایی را از داده های ورودی یاد می گیرد و در فرایند آموزش شبکه بکار می گیرند. در سال های اخیر مطالعات زیادی در زمینه استخراج عوارض شهری با استفاده از الگوریتم های یادگیری عمیق انجام شده است. Yu و همکاران (۲۰۱۸) یک شبکه عصبی عمیق برای تقسیم بندی معنایی چندین شی زمینی از تصاویر شهری با وضوح فضایی بالا به طور همزمان، پیشنهاد دادند. آنها از یک نسخه بهبود یافته از PSPNet را با ترکیب ساختار شبکه ResNet-v2 برای تقسیم بندی تصاویر با وضوح بسیار بالا استفاده کردند. نتایج آنها با روش های قبلی

است. برای آموزش این مدل ابتدا از باندهای RGB تصویر و سپس تلفیق باندهای RGB و یک باند nDSM استفاده می شود و نتایج آنها مورد مقایسه قرار می گیرند.

## ۲- مواد و روش ها

### ۲-۱- منطقه مورد مطالعه و تصاویر هوایی

شهر اهواز یکی از بزرگترین شهرهای ایران می باشد. این شهر از لحاظ وسعت سومین شهر ایران به حساب می آید. طبق آخرین سرشماری مرکز آمار جمعیت این شهر حدود ۱۲۰۰۰۰ نفر برآورد گردید. جهت اجرای روش مورد استفاده، بخشی از منطقه ۴ شهری اهواز به عنوان منطقه مورد مطالعه انتخاب گردید. این منطقه در قسمت غربی شهر قرار گرفته است و شامل انواع کاربری های شهری مثل ساختمان، راه، فضای سبز، زمین بایر و ... می باشد. شکل ۱ منطقه مورد مطالعه این پژوهش را نشان می دهد.

جهت استخراج عوارض شهری، از تصویر رنگی هوایی و DSM متناظر آن در منطقه ۴ شهرستان اهواز استفاده گردید. قدرت تفکیک مکانی تصویر RGB و DSM به ترتیب ۰/۱ و ۰/۲۵ متر می باشد. داده های این مطالعه به علت محدودیت حافظه RAM به پیچ های (Patch)  $512 \times 512$  برش داده شد که از بین آنها ۶۰ درصد برای آموزش، ۲۰ درصد برای اعتبارسنجی و ۲۰ درصد برای آزمایش، بصورت تصادفی انتخاب شدند. شکل ۲ روند کلی انجام این پژوهش را نشان می دهد. برای اجرای فرایند، تعداد ۴ کلاس برای این منطقه در نظر گرفته شد که شامل ساختمان، فضای سبز، زمین بایر، راه هستند. شکل ۳ کلاس های مورد نظر و توزیع آنها را نشان می دهد.

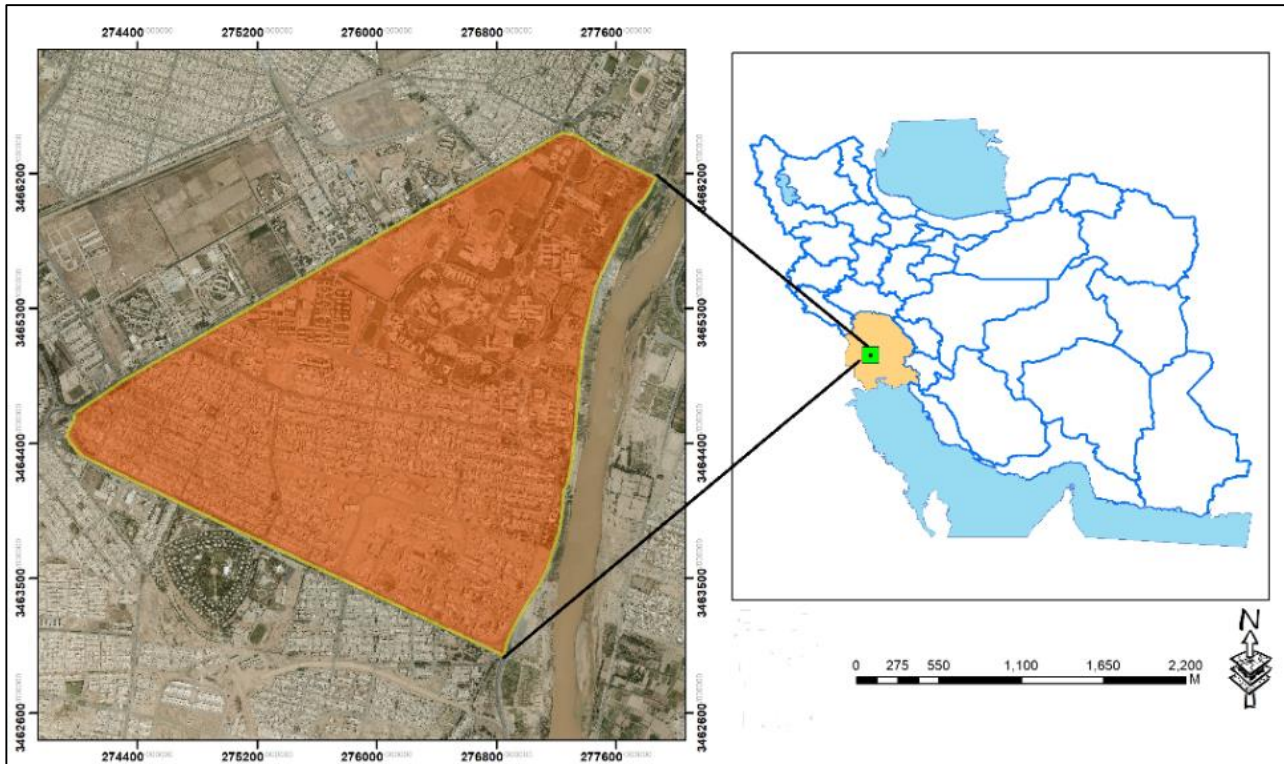
### ۲-۲- UNet مدل

مدل UNet توسط Ronnenberg و همکارانش در سال ۲۰۱۵ ارائه شد. این مدل دارای ساختاری U مانند می باشد (شکل ۴). ساختار این مدل رمزگذار-رمزگشا است که دارای سه بخش اصلی رمزگذار، رمزگشا و Bottleneck می باشد. بخش رمزگذار، مسیر انقباضی نام دارد و همانند یک شبکه عمیق CNN عمل می کند. هر بلوک این بخش، دارای دو کانولوشن  $3 \times 3$ ، تابع ReLU و پولینگ  $2 \times 2$  می باشد. این بخش جهت استخراج نقشه های ویژگی بکار می رود. بخش رمزگشا، مسیر انبساطی است و شامل یک لایه کانولوشن معکوس (Transposed convolution)  $2 \times 2$ ، دو کانولوشن  $3 \times 3$  و تابع

یادگیری عمیق معمولاً ویژگی های طیفی و مکانی را استخراج می کنند و به ویژگی های هندسی توجه نمی کنند. برای بهره گیری از اطلاعات هندسی، می توان مدل های رقومی سطح (DSM) را با تصاویر طیفی ترکیب نمود. این ادغام می تواند به بهبود استخراج پوشش زمینی و افزایش دقت تفسیر داده های سنجش از دور کمک کند. Tuia و Volpi (۲۰۱۶) از یک شبکه CNN با تمام باندهای طیفی تصویر (R, G, B, NIR) و DSM بهره بردند. در این مطالعه، مدل پیشنهادی آنها با دو مدل استاندارد CNN مقایسه گردید و نتایج برتری مدل پیشنهادی را نشان دادند. Sang و Minh (۲۰۱۸) یک شبکه FCN با پیش شبکه ResNet-101 را برای استخراج عوارض تصویر هوایی بکار گرفتند که در این مدل با ورودی باندهای طیفی و مدل nDSM دقت کلی به ۹۱ درصد رسید. Dong و همکاران (۲۰۲۰) با الهام از مدل DenseU-Net، یک شبکه جدید به نام SiameseDenseU-Net را پیشنهاد دادند. این شبکه به طور همزمان از تصویر ارتوفتو واقعی و مدل رقومی سطح نرمال شده مربوطه به عنوان ورودی شبکه استفاده می کند. ویژگی های عمیق تصویر به صورت موازی توسط بلوک های نمونه برداری پایین استخراج می شوند. نتایج این مطالعه روی مجموعه داده Vaihingen نشان می دهد که SiameseDenseU-Net امتیاز F1 را به میزان ۸۱/۲٪ و ۷۶/۳٪ در مقایسه با مدل Hourglass-ShapeNetwork (HSN) و U-Net بهبود می بخشد. Du و همکاران (۲۰۲۱) از مدل DeepLabv3+ و تجزیه و تحلیل مبتنی بر شی (OBIA) برای استخراج عوارض شهری استفاده کردند. در این مطالعه استفاده از DSM باعث بهبود مناسبی در نتایج خروجی گردید. Yang و همکاران (۲۰۲۲) از شبکه ResNet-101 با ورودی باندهای RGB و nDSM برای استخراج عوارض شهری بهره بردند. مدل پیشنهادی آنها در مجموعه داده Postdam به دقت کلی ۸۶/۸۵ درصد دست یافت و اثربخشی این ادغام را برای صحنه های شهری نشان داد. هدف مطالعه حاضر ارائه یک روش کارآمد برای استخراج خودکار عوارض شهری است که برای این امر از روش های نوین مبتنی بر یادگیری عمیق در کنار روش های یادگیری انتقالی بر روی تصاویر با قدرت تفکیک بالای هوایی انجام می شود. برای این منظور از مدل UNet که یکی از پرکاربردترین مدل ها برای طبقه بندی و استخراج عارضه از صحنه های شهری است، به همراه پیش شبکه VGG-16 بهره گرفته شده

اتصال بین رمزگذار و رمزگشا توسط اتصالات پرش ( skip connection) برقرار می شود و اطلاعات کلی و محلی برای فرایند نمونه برداری را ارائه می دهد.

ReLU می باشد. ویژگی های استخراج شده از بخش رمزگذار، در این بخش برای ایجاد خروجی به اندازه ابعاد تصویر ورودی بکار می روند (Punn and Agarwal., 2021). Bottleneck محل اتصال این دو مسیر بوده و دارای دو کانولوشن  $3 \times 3$  است.



شکل ۱- منطقه مورد مطالعه

Fig. 1. Study area

فرایند استخراج ویژگی در قسمت های پایینی مدل انجام می شود، می توان وزن های این قسمت شبکه را با داده هایی مشابه داده اصلی که تعداد بیشتری دارند، بدست آورد اما قسمت های بالایی شبکه را با نمونه های آموزشی منطقه مورد نظر آموزش داد. این امر نیاز مدل به تعداد زیاد داده های برچسب دار را کاهش می دهد (Ahmadian et al., 2023). شبکه های ResNet (He et al., 2016)، VGG (Simonyan and Szegedy et al., 2014) و GoogLeNet (Zisserman., 2014) نمونه هایی از این شبکه های از پیش آموزش دیده شده هستند که در اصطلاح پیش شبکه (Backbone) نامیده می شوند. در محیط های شهری که انواع پدیده ها با ابعاد و مقیاس های مختلفی در تصویر وجود دارد، طراحی فرایند باید به گونه ای باشد که مانع از دست رفتن اطلاعات و جزئیات شود. استفاده از پیش شبکه باعث کمک به حفظ اطلاعات جزئی در فرایند

### ۲-۲- یادگیری انتقالی (Transfer learning)

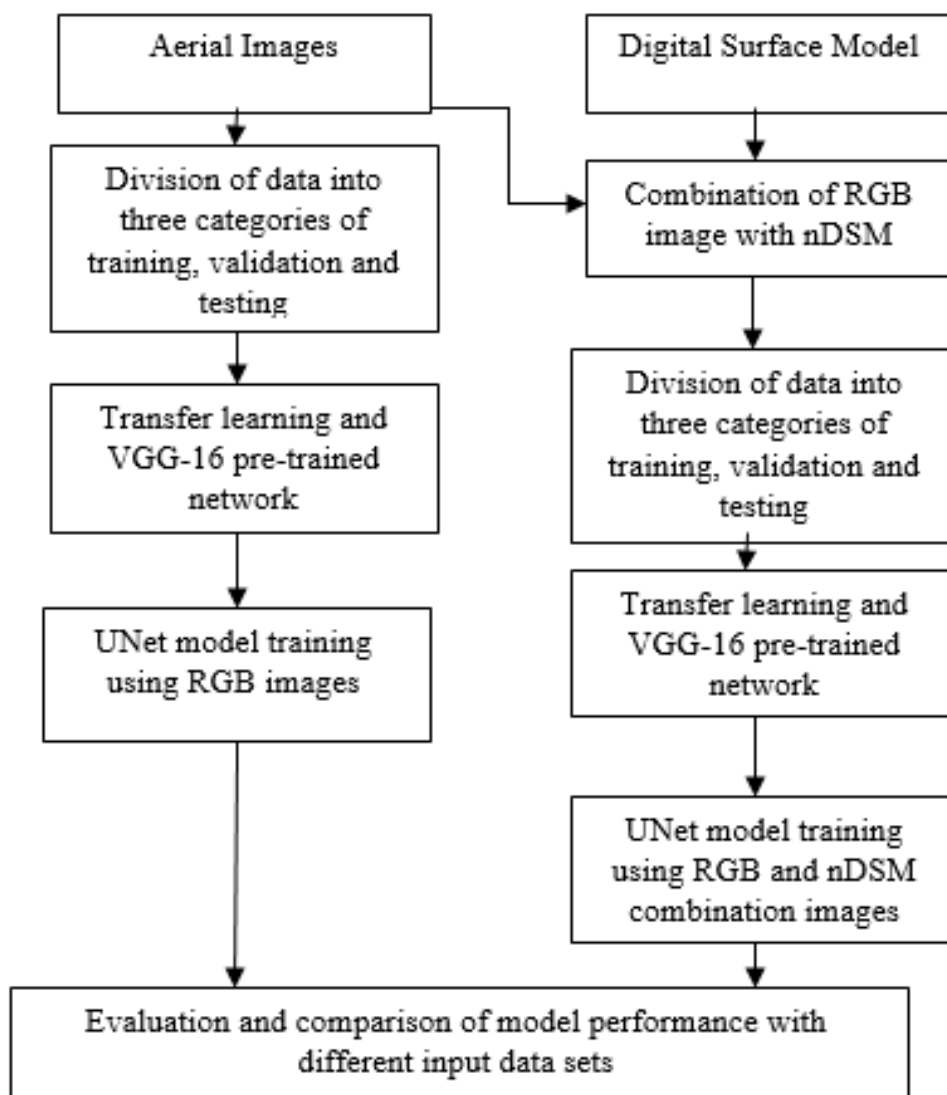
یادگیری انتقالی یک تکنیک پرکاربرد در یادگیری عمیق است که شامل استفاده از مدل های از پیش آموزش دیده بوده و به عنوان پایه ای برای وظایف مربوط به پردازش های بینایی کامپیوتری استفاده می شود. این روش به طور قابل توجهی زمان آموزش را کاهش داده و منجر به مدل های کارآمد می شود (Igloukov and Shvets., 2018). یادگیری انتقالی در واقع ذخیره و انتقال دانش حاصل از حل یک مساله و اعمال آن بر مسائل دیگر می باشد. در این فرایند اطلاعات مفید یک مساله به دیگری انتقال پیدا می کند (Chen et al., 2018). در این فرایند، ابتدا مدل مورد نظر توسط داده مشابه نمونه های آموزشی، آموزش داده شده و وزن های شبکه را ایجاد می کنند. در مرحله بعد نمونه های آموزشی منطقه مورد نظر، فرایند آموزش چند لایه بالایی مدل را انجام می دهند تا شبکه بتواند نتایج مناسبی در پیش بینی منطقه داشته باشد. در واقع چون

می شود. این مدل دارای ۱۶ لایه متشکل از ۱۳ لایه کانولوشن و ۳ لایه کاملاً متصل می باشد (شکل ۵). این لایه‌ها به صورت بلوک‌هایی سازمان‌دهی شده‌اند، که هر بلوک حاوی چندین لایه کانولوشن است که به دنبال آن یک لایه Max pooling برای نمونه‌برداری کاهش‌ی وجود دارد. VGG-16 از ترکیب این لایه‌های کانولوشن و ادغام برای درک ویژگی‌های بصری پیچیده در پیش‌بینی‌های دقیق استفاده می‌کند (Simonyan and Zisserman., 2014).

استخراج عوارض از تصویر می‌شود. در این مقاله از VGG-16 به عنوان پیش‌بینی شبکه مدل UNet استفاده شده است.


#### ۲-۴- مدل VGG-16

مدل VGG-16 که توسط گروه Visual Geometry Group در دانشگاه آکسفورد توسعه داده شده است، به دلیل داشتن یک شبکه عصبی کانولوشن عمیق ساده و مؤثر در کارهایی مانند طبقه‌بندی تصاویر و تشخیص اشیاء بکار برده




شکل ۲- مراحل انجام پژوهش


Fig. 2. Research steps



شکل ۳- کلاس های محدوده مورد مطالعه و توزیع آنها  
Fig. 3. Classes of the study area and their distribution



شکل ۴- معماری UNet (Ronneberger et al., 2015)  
Fig. 4. UNet architecture (Ronneberger et al., 2015)



شکل ۵- معماری VGG-16 (Elharrouss et al., 2022)  
Fig. 5. VGG-16 architecture (Elharrouss et al., 2022)



## ۵-۲- معیارهای ارزیابی یادگیری

جهت ارزیابی مدل آموزش دیده از داده های تست استفاده می شود. برای این کار مجموعه داده تست که در فرایند آموزش مدل سهمی نداشتند به مدل آموزش دیده شده، جهت پیش بینی معرفی می گردند. مدل با توجه به وزن های بدست آورده از مرحله آموزش، فرایند پیش بینی را انجام می دهد. با مقایسه نتیجه بدست آمده از مدل با واقعیت زمینی، ارزیابی مدل صورت می گیرد. در این پژوهش از شاخص های ارزیابی صحت کلی (Overall Accuracy)، امتیاز F1 و mIOU (mean Intersection Over Union) استفاده شد که به صورت زیر بیان می شوند:

$$OA = \frac{TP + TN}{TP + TN + FP + FN} \quad (\text{رابطه ۱})$$

$$F1 = \frac{2TP}{2TP + FP + FN} \quad (\text{رابطه ۲})$$

$$mIOU = \frac{1}{K + 1} \sum_{i=0}^K \frac{TP}{FN + FP + TP} \quad (\text{رابطه ۳})$$


TP، FN و FP به ترتیب نشان دهنده پیکسل های مثبت واقعی، منفی واقعی، مثبت کاذب و منفی کاذب در نقشه پیش بینی هستند. K هم بیانگر تعداد کل پیکسل ها در هر کلاس است.

## ۳- بحث و نتایج

همانطور که پیشتر بیان گردید، هدف مطالعه حاضر به کارگیری روش های نوین یادگیری عمیق برای استخراج ویژگی ها در محیط شهری است. در این راستا مدل UNet به همراه پیش شبکه VGG-16 به عنوان روش اصلی کار انتخاب گردید. اجرای روش در دو حالت با دو ورودی متفاوت انجام شده است. در یک حالت تنها از باندهای RGB و در حالت دیگر باندهای RGB و nDSM همراه هم به عنوان ورودی به مدل معرفی می گردند. اولین گام در اجرای مدل، آماده سازی داده های آموزشی می باشد. لازمه اجرای فرایند استخراج عوارض از تصویر، تولید داده ماسک متناظر با تصویر می باشد. به این منظور، داده ماسک با استفاده از نرم افزار Arcmap به صورت دستی ایجاد و تهیه گردید. این داده در واقع داده حقیقت زمینی است که برای برچسب گذاری استفاده می گردد. ماسک تهیه شده براساس کلاس های ساختمان، فضای سبز، زمین بایر و جاده می باشد و فرمت رستر دارد. همانطور که ذکر شد، دو دسته

داده یعنی RGB و nDSM+RGB برای آموزش مدل در دو حالت مختلف در نظر گرفته شد. برش این تصاویر و داده ماسک تولید شده، به پیچ های با ابعاد مناسب یک مرحله اساسی و مهم کار می باشد. داده ها به پیچ های  $512 \times 512$  برش داده شد و پیچ هایی را که اطلاعات مفیدی نداشتند کنار گذاشته شد. این داده ها به سه دسته آموزش، اعتبارسنجی و آزمایش تقسیم گردیدند. هر چه مرحله آماده سازی و پیش پردازش داده ها با دقت و کیفیت بالاتری صورت گیرد، خروجی ایجاد شده هم کیفیت بالاتری خواهد داشت و آموزش مدل به صورت مناسبی انجام می شود. برای آموزش از مدل UNet که یک مدل رمزگذار-رمزگشا است، استفاده شد. تکنیک یادگیری انتقالی مرحله مهم در پیاده سازی معماری شبکه می باشد. به این صورت که معماری نهایی ترکیبی از مدل های UNet و VGG-16 خواهد بود. در مسیر انقباض معماری UNet، از معماری VGG-16 استفاده می شود. پس از آن، لایه های VGG-16 به مدل پایه UNet که از لایه های کانولوشنال و نمونه برداری افزایشی تشکیل شده است، الحاق می شوند. در نهایت مدل با دو مجموعه داده انتخابی آموزش داده شد. از محیط پردازشی Colab Google و فضای ابری موجود آن، برای اجرای مدل این پژوهش استفاده گردید. کدهای این مطالعه تماما با استفاده از کتابخانه Tensorflow و زبان برنامه نویسی Python 3.8 پیاده سازی گردیدند. پارامترهای مدل اجرا شده شامل تعداد تکرار برابر ۵۰، نرخ یادگیری  $0.0001$  و بهینه سازی Adam (Kingma and Ba, 2014) می باشند. در طول آموزش مدل، از دو تابع ضرر Dice loss (Sudre et al., 2017) و Focal loss (Mulyanto et al., 2020) با هم استفاده گردید تا خروجی شبکه را با پاسخ صحیح مقایسه کرده و این طور میزان خطا محاسبه گردد. پس از مرحله آموزش مدل با دو مجموعه داده، از آن ها برای پیش بینی عوارض شهری روی تصاویر تست استفاده شد. شکل ۶ نتیجه نهایی اعمال مدل را بر روی داده های تست دو مجموعه نشان می دهد. نتایج ارزیابی کمی اجرای مدل بر روی دو مجموعه داده در جدول ۱ ذکر شده است.

همانطور که در جدول ۱ آمده است، شبکه UNet با پیش شبکه VGG-16 با استفاده از داده های RGB+nDSM نتیجه بهتری نسبت به داده های RGB نشان می دهد. اجرای مدل با داده های RGB، شاخص OA برابر  $0.76/34$ ، F1 برابر  $0.73/98$  و mIOU برابر  $0.74/15$  را نشان داد. هم چنین برای داده های



شکل ۶- نقشه های پوشش زمینی مدل VGG-16+UNet برای دو مجموعه داده، (a) داده واقعیت زمینی، (b) نتیجه مدل با ورودی باندهای RGB تصویر و (c) نتیجه مدل با ورودی باندهای RGB و nDSM

Fig. 6. VGG-16+UNet model land cover maps for two datasets, (a) ground truth data, (b) model result with image RGB bands input and (c) model result with RGB and nDSM bands input

کلاس بندی تصاویر تست را نشان می دهد. این نمودار بیانگر این است که در اجرای مدل با داده های RGB+nDSM، کلاس ساختمان های تصویر نسبت به داده RGB، بخوبی استخراج گردید زیرا اختلاف ارتفاع عوارض سطح زمین با حضور nDSM بطور واضحی نمایان می شود. همچنین مدل UNet با داده RGB کلاس پوشش گیاهی را نسبت به کلاس های دیگر تصویر با دقت بالاتری استخراج نمود، زیرا در این حالت فقط اطلاعات

RGB+nDSM شاخص های OA، F1 و mIOU به ترتیب ۸۸/۱۴٪، ۸۲/۵۲٪ و ۸۶/۲۱٪ بدست آمد. با تاثیر داده ارتفاعی، بهبود قابل توجهی در نتایج نهایی استخراج عوارض صورت گرفت. این الگوریتم در یک منطقه شهری نسبتاً متراکم پیاده سازی گردید و نتایج خروجی قابلیت آن را بخوبی نشان داد. شکل ۷، نمودار میانگین امتیاز F1 کلاس های مختلف در

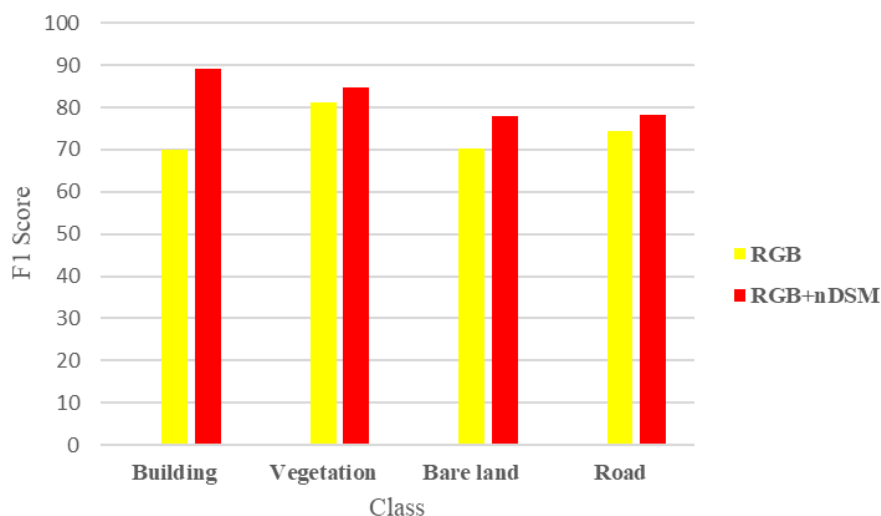
کلاس ساختمان را با کمترین دقت بدست آورده است. نتایج در حالت کلی نشان از بهبود دقت در رویکرد دوم دارد. نتایج اجرای این مدل با مدل های دیگر یادگیری عمیق که در این حوزه بکار می روند مورد مقایسه قرار گرفت. Du و همکاران (۲۰۲۰) در استخراج ویژگی های شهری با ورودی nDSM و اجرای مدل DeepLabV3+ به دقت کلی ۸۷٪ برای مجموعه داده Potsdam و Vaihingen و ۸۳٪ برای مجموعه داده Yang و همکاران (۲۰۲۲) در مطالعه خود از شبکه ResNet-101 با ورودی باندهای RGB و nDSM برای استخراج عوارض شهری بهره بردند. مدل پیشنهادی آنها در مجموعه داده Postdam دقت کلی ۸۶٪ را بدست آورد. بنابراین مطالعه حاضر با استفاده از مدل UNet در مقایسه با مطالعات مشابه خود، ویژگی های شهری را با دقت بالاتری استخراج نموده است.

بافتی پیکسل های تصویر RGB برای استخراج عارضه استفاده می شود. در حضور nDSM، کلاس پوشش گیاهی با دقت کمتر از کلاس ساختمان استخراج گردید. با وجود تاثیر اطلاعات هندسی و افزایش مقدار F1 این کلاس از ۸۱٪ به ۸۴٪ در رتبه دوم به لحاظ دقت جای گرفته است. به طور خلاصه می توان بیان کرد که کلاس ساختمان به اطلاعات هندسی و کلاس پوشش گیاهی به اطلاعات بافتی پیکسل ها حساسیت دارد. با وجود اینکه کلاس زمین های بایر با استفاده از nDSM افزایش دقت بیشتری (از ۷۰٪ به ۷۸٪) را نسبت به کلاس راه (از ۷۴٪ به ۷۸٪) از خود نشان داده است، ولی کلاس راه امتیاز F1 بالاتری دارد و در رتبه بعد از پوشش گیاهی به لحاظ دقت جای می گیرد. مدل UNet با ورودی RGB+nDSM، کلاس زمین های بایر را با کمترین دقت استخراج نموده است در حالی که مدل UNet با ورودی RGB

جدول ۱- شاخص های ارزیابی مدل UNet با پیش شبکه VGG-16 برای دو مجموعه داده

Table 1. Evaluation criterias of UNet model with VGG-16 backbone for two datasets

Datasets	Evaluation criterias	Results
RGB	F1(%)	73.98
	OA (%)	76.34
	mIoU (%)	74.15
RGB+nDSM	F1(%)	82.52
	OA (%)	88.14
	mIoU (%)	86.21



شکل ۷- نمودار میانگین امتیاز F1 کلاس های مختلف در کلاسه بندی تصاویر تست

Fig. 7. Diagram of the average F1 score of different classes in the classification of test images

## ۵- نتیجه گیری

طبقه بندی پوشش اراضی شهری به علت اثرگذاری زیاد آن در برقراری ارتباط بین انسان و محیط فیزیکی، هموار از اهمیت زیادی برخوردار بوده است. از طرف دیگر، این نقشه های پوشش اراضی از مهم ترین داده ها در مطالعات شهری می باشند و نحوه پراکنش عوارض مختلف در شهر را نشان می دهند. بر همین اساس در این تحقیق از تصاویر هوایی با قدرت تفکیک مکانی بالا و مدل رقومی سطح زمین برای تهیه نقشه پوشش اراضی و استخراج خودکار عوارض در منطقه ۴ اهواز استفاده شد. یادگیری عمیق و مدل های مختلف آن، با دریافت مفاهیم انتزاعی سطح بالای اشیا و بکارگیری آنها در تولید نتیجه بهتر یکی از انتخاب های مناسب در حوزه استخراج ویژگی می باشد که در این پژوهش از آن بهره برده شد. این مدل ها دارای مزایایی چون آموزش کاملا خودکار ویژگی ها، دقت بالا و زمان آموزش پایین هستند. در این مطالعه کلاس های ساختمان، فضای سبز، زمین بایر و راه به عنوان کلاس های اصلی در نظر گرفته شدند. برای استخراج این عوارض بعد از آماده سازی داده های ورودی و برش آنها به ابعاد  $512 \times 512$ ، آموزش مدل UNet

با استفاده از پیش شبکه VGG-16 (یادگیری انتقالی) صورت گرفت. از بین کل داده ها، ۶۰ درصد آنها برای آموزش استفاده گردید و آموزش مدل با ۵۰ تکرار انجام شد. بعد از آموزش مدل، از آن برای پیش بینی عوارض در تصاویر تست استفاده شد. براساس نتایج بدست آمده مشخص گردید که مدل VGG-16+UNet، استخراج کلاس ها را در حضور مدل رقومی سطح با صحت کلی بالاتری (۸۸/۱۴٪) نسبت به اجرای مدل با باندهای تصویر هوایی (۷۶/۳۴٪) انجام داده است. با توجه به قابلیت های کاربردی این گونه نقشه ها در برنامه های مدیریت شهری، شایسته است مدیران شهری در جهت تسهیل فرایندهای تصمیم گیری از آنها بهره مند شوند. استفاده از مدل های دیگر یادگیری عمیق و مقایسه نتایج آنها می تواند یکی از موضوعات در تحقیقات آتی در این حوزه باشد.

### تقدیر و تشکر

بدین وسیله از حمایت مالی معاونت پژوهش و فناوری دانشگاه شهید چمران اهواز در قالب پژوهانه (SCU.EG1402.26151) در انجام این تحقیق تشکر و قدردانی میگردد.

## مراجع

- Abdollahi, A., Pradhan, B., Shukla, N., Chakraborty, S., Alamri, A., 2021. Multi-Object Segmentation in Complex Urban Scenes from High-Resolution Remote Sensing Data. *Journal of Remote Sensing* 13(18) 1-22. <https://doi.org/10.3390/rs13183710>
- Ahmadian, N., Sedaghat, A., Mohammadi, N., 2023. Performance evaluation of three deep learning models in building footprint extraction from aerial and satellite images. *Engineering Journal of Geospatial Information Technology* 11(1), 105-123. <http://jgit.kntu.ac.ir/article-1-912-en.html>
- Badrinarayanan, V., Kendall, A., Cipolla, R., 2017. Segnet: A deep convolutional encoder-decoder architecture for image segmentation. *IEEE transactions on pattern analysis and machine intelligence* 39(12), 2481-2495. <https://doi.org/10.1109/TPAMI.2016.2644615>
- Chen, L.C., Zhu, Y., Papandreou, G., Schroff, F., Adam, H., 2018. Encoder-decoder with atrous separable convolution for semantic image segmentation. In *Proceedings of the European conference on computer vision (ECCV)* 801-818. <https://link.springer.com/conference/eccv>
- Chen, Y., Jiang, H., Li, C., Jia, X., Ghamisi, P., 2016. Deep feature extraction and classification of hyperspectral images based on convolutional neural networks. *IEEE transactions on geoscience and remote sensing* 54 6232-6251. <https://doi.org/10.1109/TGRS.2016.2584107>
- Chen, Z., Zhang, T., Ouyang, C., 2018. End-to-end airplane detection using transfer learning in remote sensing images. *Remote Sensing*, 10(1) 139-151. <https://doi.org/10.3390/rs10010139>
- Dong, R., Bai, L., Li, F., 2020. SiameseDenseU-Net-based Semantic Segmentation of Urban Remote Sensing Images. *Mathematical Problems in Engineering*(1) 1515630. <https://doi.org/10.1155/2020/1515630>
- Du, S., Du, S., Liu, B., Zhang, X., 2021. Incorporating DeepLabv3+ and object-based image analysis for semantic segmentation of very high resolution remote sensing images. *International Journal of Digital Earth* 14(3), 357-378. <https://doi.org/10.1080/17538947.2020.1831087>

- Farhadi, N., Kiani, A., Ebadi, H., 2019. Target detection from high-resolution remote sensing images using deep learning methods. *Iranian Journal of Remote Sensing & GIS*, 11(1) pp.48-64. <https://doi.org/10.52547/gisj.11.1.48>
- He, K., Zhang, X., Ren, S., Sun, J., 2015. Deep Residual Learning for Image Recognition. *arXiv:1512.03385*. <https://doi.org/10.48550/arXiv.1512.03385>
- He, K., Zhang, X., Ren, S., Sun, J., 2015. Spatial pyramid pooling in deep convolutional networks for visual recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. vol. 37, no. 9, pp. 1904-1916. <https://doi.org/10.1109/TPAMI.2015.2389824>
- Iglovikov, V., Shvets, A., 2018. Terausnet: U-net with vgg11 encoder pre-trained on imagenet for image segmentation. *arXiv* vol. 18, no. 1, pp. 37-42. <https://doi.org/10.48550/arXiv.1801.05746>
- KaboliZadeh, M., Rangzan, K., Saberi, A., 2023. Automatic extraction of urban objects from high-resolution aerial images using convolutional neural networks (Study area: Ahvaz city). *Advanced Applied Geology* 13(2), 408-422. <https://doi.org/10.22055/aag.2023.42422.2330>
- Kingma, D.P., Ba, J., 2014. Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*. <https://doi.org/10.48550/arXiv.1412.6980>
- Liu, X., Chi, M., Zhang, Y., Qin, Y., 2018. Classifying high resolution remote sensing images by fine-tuned VGG deep networks. In *IGARSS 2018-2018 IEEE International Geoscience and Remote Sensing Symposium* (pp. 7137-7140). IEEE. <https://doi.org/10.1109/IGARSS.2018.8518078>
- Long, J., Shelhamer, E., Darrell, T., 2015. Fully convolutional networks for semantic segmentation. In *Proceedings of the IEEE conference on computer vision and pattern recognition (3431-3440 PP.)*. <https://doi.org/10.48550/arXiv.1411.4038>
- McGlinchy, J., Muller, B., Johnson, B., Joseph, M., Diaz, J., 2021. Fully convolutional neural network for impervious surface segmentation in mixed urban environment. *Photogrammetric Engineering & Remote Sensing* 87(2), 117-123. <https://doi.org/10.14358/PERS.87.2.117>
- Mulyanto, M., Faisal, M., Prakosa, S.W., Leu, J.S., 2020. Effectiveness of focal loss for minority classification in network intrusion detection systems. *Symmetry*, 13(1), 4-12 <https://doi.org/10.3390/sym13010004>
- Pan, Z., Xu, J., Guo, Y., Hu, Y., Wang, G., 2020. Deep learning segmentation and classification for urban village using a worldview satellite image based on U-Net. *Remote Sensing*, 12(10), 1574-1582. <https://doi.org/10.3390/rs12101574>
- Ronneberger, O., Fischer, P., Brox, T., 2015. U-net: Convolutional networks for biomedical image segmentation. In *Medical image computing and computer-assisted intervention—MICCAI 2015: 18th international conference, Munich, Germany, October 5-9, 2015, proceedings, part III 18* (234-241 PP.). Springer International Publishing. [http://dx.doi.org/10.1007/978-3-319-24574-4\\_28](http://dx.doi.org/10.1007/978-3-319-24574-4_28)
- Sang, D.V., Minh, N.D., 2018. Fully residual convolutional neural networks for aerial image segmentation. In *Proceedings of the 9th International Symposium on Information and Communication Technology*, 289-296. <https://doi.org/10.1145/3287921.3287970>
- Sariturk, B., Bayram, B., Duran, Z., Seker, D.Z., 2020. Feature extraction from satellite images using segnet and fully convolutional networks (FCN). *International Journal of Engineering and Geosciences* 5(3), 138-143. <https://doi.org/10.26833/ijeg.645426>
- Shinohara, T., Xiu, H., Matsuoka, M., 2020. FwNet: semantic segmentation for full-waveform LiDAR data using deep learning. *Sensors* 20 3568. <http://dx.doi.org/10.3390/s20123568>
- Simonyan, K., Zisserman, A., 2014. Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*. <https://doi.org/10.48550/arXiv.1409.1556>
- Singh Punn, N., Agarwal, S., 2021. Modality specific U-Net variants for biomedical image segmentation: A survey. *arXiv e-prints*, pp.arXiv.???. [https://ui.adsabs.harvard.edu/link\\_gateway/2021arXiv210704537S/doi:10.48550/arXiv.2107.04537](https://ui.adsabs.harvard.edu/link_gateway/2021arXiv210704537S/doi:10.48550/arXiv.2107.04537)
- Sudre, C.H., Li, W., Vercauteren, T., Ourselin, S., Jorge Cardoso, M., 2017. Generalised dice overlap as a deep learning loss function for highly unbalanced segmentations. In *Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support: Third International Workshop, DLMIA 2017, and 7th International Workshop, ML-CDS 2017, Held in Conjunction with MICCAI 2017, Québec City, QC, Canada, September 14, Proceedings 3*, pp. 240-248. <https://doi.org/10.48550/arXiv.1707.03237>

- Sun, K., Zhao, Y., Jiang, B., Cheng, T., Xiao, B., Liu, D., Mu, Y., Wang, X., Liu, W., Wang, J., 2019. High-resolution representations for labeling pixels and regions. arXiv preprint arXiv:1904.04514. <https://doi.org/10.48550/arXiv.1904.04514>
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., Rabinovich, A., 2015. Going deeper with convolutions. In Proceedings of the IEEE conference on computer vision and pattern recognition pp. 1-9. <https://doi.org/10.48550/arXiv.1409.4842>
- United Nations Department of Economic and Social Affairs., 2014. World Urbanization Prospects The 2014 Revision. Demographic Research. 517. <https://doi.org/10.18090/ST/ESA/SER.A/366>.
- Vetrivel, A., Gerke, M., Kerle, N., Nex, F., Vosselman, G., 2018. Disaster damage detection through synergistic use of deep learning and 3D point cloud features derived from very high-resolution oblique aerial images, and multiple-kernel-learning. ISPRS journal of photogrammetry and remote sensing 140, 45-59. <https://doi.org/10.1016/j.isprsjprs.2017.03.001>
- Volpi, M., Tuia, D., 2016. Dense semantic labeling of subdecimeter resolution images with convolutional neural networks. IEEE Transactions on Geoscience and Remote Sensing 55(2), 881-893. <https://doi.org/10.1109/TGRS.2016.2616585>
- Wen, D., Huang, X., Zhang, L., Benediktsson, J.A., 2015. A novel automatic change detection method for urban high-resolution remotely sensed imagery based on multiindex scene representation. IEEE Transactions on Geoscience and Remote Sensing 54(1), 609-625. <https://doi.org/10.1109/TGRS.2015.2463075>
- Yang, H., Yu, B., Luo, J., Chen, F., 2019. Semantic segmentation of high spatial resolution images with deep neural networks. GIScience & remote sensing 56(5), 749-768. <https://doi.org/10.1080/15481603.2018.1564499>
- Yang, R., Dai, Q., Cheng, H., Zhang, Y., Chen, N., Wang, L., 2022. Improving Semantic Segmentation Performance by Jointly Using High Resolution Remote Sensing Image and Ndsm. ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences 3 77-83. <https://doi.org/10.5194/isprs-annals-V-3-2022-77-2022>
- Yu, B., Yang, L., Chen, F., 2018. Semantic segmentation for high spatial resolution remote sensing images based on convolution neural network and pyramid pooling module. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing 11(9) 3252-3261. <https://doi.org/10.1109/JSTARS.2018.2860989>
- Zhang, J., Lin, S., Ding, L., Bruzzone, L., 2020. Multi-scale context aggregation for semantic segmentation of remote sensing images. Remote Sensing, 12(4) 701. <https://doi.org/10.3390/rs12040701>
- Zhang, L., Shao, Z., Liu, J., Cheng, Q., 2019. Deep learning based retrieval of forest aboveground biomass from combined LiDAR and landsat 8 data. Remote Sensing 11 14591471 <https://doi.org/10.3390/rs11121459>