

# مقایسه عملکرد روش‌های یادگیری عمیق و جنگل تصادفی در طبقه‌بندی پوشش اراضی شهری (مطالعه موردی: شهر تبریز)

میثم محرمی<sup>۱</sup>، نجمه نیسانی سامانی<sup>۲\*</sup>

<sup>۱</sup> دانشجوی دکتری سنجش‌ازدور و GIS - دانشکده جغرافیا - دانشگاه تهران  
moharramimeisam@ut.ac.ir

<sup>۲</sup> دانشیار دانشکده جغرافیا - دانشگاه تهران  
nneysani@ut.ac.ir

(تاریخ دریافت شهریور ۱۳۹۹، تاریخ تصویب بهمن ۱۴۰۰)

## چکیده

تهیه نقشه پوشش اراضی شهری یکی از پیش شرط‌های اساسی بسیاری از برنامه‌های شهری محسوب می‌شود. صرف کمترین زمان و هزینه برای تهیه این نقشه‌ها از جمله چالش‌های مدیران شهری محسوب می‌شود. امروزه تصاویر ماهواره‌ای و طبقه‌بندی آن‌ها کاربرد گسترده‌ای در تهیه نقشه‌های پوشش اراضی شهری پیدا کرده‌اند. بر این اساس هدف از این تحقیق، تهیه نقشه پوشش اراضی شهری در شهر تبریز با استفاده از تصویر ماهواره‌ای سنتینل-۲ می‌باشد. برای طبقه‌بندی تصاویر ماهواره‌ای، از دو الگوریتم جنگل تصادفی و یادگیری عمیق مبتنی بر شبکه عصبی (شبکه عصبی عمیق) استفاده شد. کلاس‌های کاربری مورد نظر شامل پنج پوشش سطحی: اراضی بایر، مناطق ساخته شده، راه، پوشش گیاهی و آب بودند. تمام مراحل پردازش تصاویر ماهواره‌ای به صورت خودکار و در سامانه‌های پردازش ابری Google Earth Engine و Google Colab انجام شد. با توجه به نتایج به دست آمده، الگوریتم شبکه عصبی عمیق با صحت کلی ۹۵/۲ درصد عملکرد بهتری را نسبت به الگوریتم جنگل تصادفی با صحت کلی ۹۳/۱ درصد ارائه کرد. بررسی عملکرد این دو الگوریتم در استخراج هر یک از کلاس‌ها نشان داد که روش شبکه عصبی عمیق در استخراج کلاس‌های اراضی بایر و مناطق ساخته شده عملکرد بهتری داشته است، به طوری که مقادیر صحت کاربر و تولید کننده آن در کلاس اراضی بایر به ترتیب ۹/۶ و ۱ درصد بیش تر از الگوریتم جنگل تصادفی بودند. این میزان در کلاس مناطق ساخته شده نیز به ترتیب ۰/۳ و ۴/۳ درصد بیش تر از الگوریتم جنگل تصادفی بودند. از طرفی الگوریتم جنگل تصادفی در استخراج کلاس راه عملکرد بهتری داشت و مقادیر صحت کاربر و تولید کننده آن به ترتیب ۳/۶۵ و ۴/۱ درصد بیش از روش شبکه عصبی عمیق بودند. بنابراین می‌توان گفت هر دو الگوریتم عملکرد مناسبی در تهیه نقشه پوشش شهری ارائه دادند، اما عملکرد کلی الگوریتم شبکه عصبی عمیق، مناسب تر بود.

**واژگان کلیدی:** پوشش اراضی شهری، شبکه عصبی عمیق، جنگل تصادفی، سنتینل-۲

## ۱- مقدمه

نواحی شهری ۳ درصد از مساحت خشکی‌های سطح زمین را تشکیل می‌دهند، اما با این حال ۵۴ درصد از جمعیت جهان در مناطق شهری ساکن می‌باشند که این رقم تا سال ۲۰۵۰ میلادی به ۶۵ درصد افزایش خواهد یافت [۱]. رشد جمعیت شهری باعث افزایش چشمگیر پوشش‌های شهری در سطح زمین شده است [۲]. توسعه نواحی شهری باعث افزایش تولید گازهای گلخانه‌ای، بی‌ثبات کردن اکوسیستم‌ها و ایجاد چالش‌های گسترده اجتماعی می‌شود [۳]. یکی از اساسی‌ترین داده‌ها برای مطالعات شهری، نقشه پوشش اراضی شهری<sup>۱</sup> و نحوه پراکنش آن‌ها می‌باشد [۴]. اطلاعات به‌هنگام و قابل اعتماد در مورد وسعت اراضی شهری و پوشش‌های آن، از عناصر اصلی مدیریت پایدار شهری محسوب می‌شود [۵]. همچنین یکی از داده‌های اساسی برای ارزیابی سیاست‌های مدیریت شهری، نقشه پوشش اراضی شهری می‌باشد [۶].

تاکنون مطالعات بسیاری در زمینه تهیه نقشه پوشش شهری با استفاده از روش‌ها و داده‌های مختلف از جمله داده‌های ماهواره‌ای و نقشه‌برداری زمینی انجام شده است، روش‌های نقشه‌برداری زمینی از صحت بیشتری برای تهیه نقشه‌های پوشش شهری برخوردار می‌باشند. اما با این حال، تهیه نقشه پوشش شهری با روش‌های نقشه‌برداری زمینی، هزینه‌بر و زمان‌بر می‌باشد و به افراد زیادی برای تهیه نقشه‌های پوشش شهری با این روش نیاز است [۷]. از طرفی، تصاویر ماهواره‌ای به دلیل پوشش وسیع و مقرون به‌صرفه بودن، به ابزاری مهم و منحربه‌فرد برای تهیه نقشه پوشش شهری تبدیل شده‌اند [۸].

تصاویر ماهواره‌ای با ارائه اطلاعات به‌روز و در مقیاسی وسیع از سطح زمین، به‌طور گسترده‌ای در تهیه نقشه پوشش شهری به‌کار می‌روند [۹]. از تصاویر ماهواره‌ای با قدرت‌های تفکیک مکانی مختلف به‌طور گسترده‌ای در تهیه نقشه‌های پوشش زمین‌های شهری استفاده می‌شود [۱۰]. از جمله داده‌های ماهواره‌ای که توسط محققان مختلف برای تهیه نقشه پوشش‌های شهری استفاده شده است می‌توان به تصاویر سنجنده مودیس<sup>۲</sup> [۹ و ۱۱-۱۲].

سنجنده DMSP-OLS [۱۳-۱۵]، سری ماهواره‌های لندست [۱۶-۱۹]، داده‌های راداری سنتینل-۱ [۲۱-۲۲]، داده‌های اپتیک سنتینل-۲ [۲۳-۲۵]، داده‌های لایدار [۲۶-۲۸] و تصاویر ماهواره‌ای با قدرت تفکیک مکانی بسیار بالا [۲۹-۳۱] اشاره کرد. ماهواره سنتینل-۲ از جمله مأموریت‌های سازمان فضایی اروپا می‌باشد که اقدام به برداشت تصاویر چند طیفی از سطح زمین می‌کند [۳۲]. تصاویر سنتینل-۲ برای بسیاری از کاربردها و زمینه‌ها از قبیل: زمین‌شناسی، کشاورزی، پایش‌های سیستم‌های آبی و تهیه نقشه‌های خاک مناسب می‌باشند. استفاده از تصاویر سنتینل-۲ برای تهیه نقشه‌های شهری هنوز در مراحل اولیه می‌باشد، اما با این حال نتایج تحقیقات مختلف برای تهیه نقشه‌های پوشش شهری با استفاده از تصاویر سنتینل-۲ نتایج مطلوبی در بر داشته است [۳۳].

طبقه‌بندی تصاویر ماهواره‌ای از جمله روش‌های پر کاربرد در زمینه تهیه نقشه پوشش‌های شهری محسوب می‌شود [۳۴]. تنوع الگوریتم‌های طبقه‌بندی، به کاربر امکان تولید اطلاعات گوناگون را می‌دهد. انعطاف‌پذیری و قابلیت‌های بالای الگوریتم‌های طبقه‌بندی باعث شده است تا این روش‌ها به‌عنوان مهم‌ترین روش استخراج اطلاعات از تصاویر ماهواره‌ای مورد استفاده قرار گیرند [۳۵]. در طول سال‌های گذشته الگوریتم‌های طبقه‌بندی مختلفی برای طبقه‌بندی و تهیه نقشه کاربری اراضی ارائه شده‌اند که از آن جمله می‌توان به: حداکثر احتمال<sup>۳</sup>، درخت تصمیم‌گیری<sup>۴</sup>، ماشین بردار پشتیبان<sup>۵</sup>، جنگل تصادفی<sup>۶</sup> و شبکه عصبی<sup>۷</sup> اشاره کرد. الگوریتم جنگل تصادفی از جمله الگوریتم‌های قدرتمند غیر پارامتریک یادگیری ماشین می‌باشد که به‌طور گسترده‌ای در طبقه‌بندی کاربری اراضی مورد استفاده قرار گرفته‌است [۳۶]. این الگوریتم هم به‌منظور رگرسیون و هم به‌منظور طبقه‌بندی داده‌های پیوسته و گسسته مورد استفاده قرار می‌گیرد. عدم حساسیت به نویز و کارایی مناسب در مواجهه با داده‌های نامتوازن از ویژگی‌های مهم این الگوریتم محسوب می‌شود

<sup>۳</sup> Sentinel-1

<sup>۴</sup> Sentinel-2

<sup>۵</sup> Maximum Likelihood

<sup>۶</sup> Decision Trees

<sup>۷</sup> Support Vector Machines

<sup>۸</sup> Random Forest

<sup>۹</sup> Neural Networks

<sup>۱</sup> Urban Land Covers

<sup>۲</sup> MODIS

مورد استفاده قرار گرفته است [۴۷-۴۳]. یادگیری عمیق به عنوان موضوعی جدید، امروزه کاربرد گسترده‌ای در استخراج ویژگی‌های سطحی و طبقه‌بندی تصاویر ماهواره‌ای پیدا کرده است [۴۸]. روش‌های یادگیری عمیق نیز جزو روش‌های یادگیری ماشین محسوب می‌شوند و اساس یادگیری در آن‌ها بر اساس شبکه‌های عصبی می‌باشد. تا کنون مدل‌های مختلفی جهت یادگیری عمیق ارائه شده است که برخی از پرکاربردترین آن‌ها در مباحث سنجش از دور مدل‌های DNN<sup>۵</sup> و CNN<sup>۶</sup> می‌باشند [۴۹]. در میان روش‌های مختلف یادگیری عمیق، مدل DNN (شبکه عصبی عمیق) روشی مناسب برای آنالیز مکانی تصاویر ماهواره‌ای و طبقه‌بندی آن‌ها می‌باشد [۵۰]. استخراج اطلاعات کاربری اراضی از تصاویر سنجش از دور توسط الگوریتم‌های یادگیری عمیق در قالب طبقه‌بندی تصاویر ماهواره‌ای توسط محققان مختلفی انجام شده است. ژانگ و همکاران<sup>۷</sup> (۲۰۱۹) به طبقه‌بندی کاربری اراضی شهری در دو شهر منچستر و ساوتهمپتون انگلستان با استفاده از الگوریتم یادگیری عمیق پرداختند. نتایج نشان داد الگوریتم یادگیری عمیق در هر دو شهر نتایج بهتری را نسبت به الگوریتم‌های MLP، SVM و MRF ارائه داده است [۵۱]. شی و همکاران<sup>۸</sup> (۲۰۲۱) به طبقه‌بندی تصاویر فراطیفی با استفاده از الگوریتم‌های یادگیری عمیق پرداختند. محققان در این تحقیق از چهار تصویر فراطیفی مختلف به منظور طبقه‌بندی چهار هدف مختلف استفاده کرده‌اند. در تصویر اول، به طبقه‌بندی گونه‌های گیاهی؛ در تصویر دوم، به طبقه‌بندی کاربری اراضی؛ در تصویر سوم به طبقه‌بندی مناطق شهری و در تصویر چهارم به طبقه‌بندی بیماری‌های گیاهی پرداخته شده است. الگوریتم مورد استفاده در این تحقیق الگوریتم BIT-DNN می‌باشد که دارای یادگیری دو مرحله‌ای می‌باشد، بدین صورت که در مرحله اول به یادگیری ویژگی‌های طیفی و در مرحله دوم به یادگیری همزمان ویژگی‌های طیفی و مکانی می‌پردازد. نتایج به دست آمده نشان داد الگوریتم پیشنهادی دارای دقت بالاتری نسبت به سایر الگوریتم‌های یادگیری عمیق (DFCNN, VCNN, SSCNN, SSRN, CapsNet)

[۳۷]. تاکنون مطالعات مختلفی صورت گرفته است که در آن‌ها با استفاده از الگوریتم جنگل تصادفی به تهیه نقشه کاربری اراضی پرداخته شده است. قاسمی اسفهلان (۲۰۱۳) به تهیه نقشه پوشش اراضی شهری در شهر هیوستون با استفاده از الگوریتم جنگل تصادفی پرداخت. او در این تحقیق به مقایسه الگوریتم‌های جنگل تصادفی و ماشین بردار پشتیبان در تهیه نقشه پوشش اراضی شهری پرداخت. نتایج بدست آمده نشان داد که الگوریتم جنگل تصادفی با دقت کلی ۸۲ درصد از عملکرد بهتری برخوردار می‌باشد [۳۸]. صدیقی و شاهرخ امینی (۲۰۲۰) به طبقه‌بندی حوضه آبی پریشان با استفاده از تصاویر ماهواره‌ای لندست و الگوریتم‌های جنگل تصادفی و ماشین بردار پشتیبان پرداختند. نتایج نشان داد الگوریتم ماشین بردار پشتیبان در سال‌های ۲۰۰۸ و ۲۰۱۰ دقت کلی بالاتری را ارائه داده است و الگوریتم جنگل تصادفی در سال‌های ۲۰۱۲، ۲۰۱۴، ۲۰۱۶ و ۲۰۱۸ دقت کلی بالاتری را ارائه داده است، بنابراین الگوریتم جنگل تصادفی عملکرد کلی بهتری را داشته است [۳۹]. شیخ و همکاران<sup>۱</sup> (۲۰۲۱) به بررسی تغییرات کاربری اراضی شهری در شهرهای شمالی کشور تایوان پرداختند. بدین منظور از تصاویر ماهواره‌ای لندست در سال‌های ۱۹۹۰ و ۲۰۱۵ استفاده شده است؛ محققان در این تحقیق از الگوریتم جنگل تصادفی به منظور طبقه‌بندی تصاویر ماهواره‌ای استفاده کرده‌اند. نتایج به دست آمده نشان داد الگوریتم جنگل تصادفی از کارایی مناسبی در طبقه‌بندی کاربری اراضی شهری برخوردار می‌باشد و همچنین بیشترین تغییر کاربری اراضی رخ داده در این بازه زمانی مربوط به افزایش اراضی ساخته شده در منطقه مورد مطالعه می‌باشد [۴۰]. از دیگر پژوهش‌های انجام شده در زمینه کاربرد الگوریتم جنگل تصادفی برای تهیه نقشه کاربری اراضی می‌توان به پژوهش‌های ژانگ و همکاران<sup>۲</sup> (۲۰۲۱) و بوی و موسی<sup>۳</sup> (۲۰۲۱) اشاره کرد [۴۱-۴۲]. از سال ۲۰۱۴ میلادی روش‌های یادگیری عمیق<sup>۴</sup> وارد مطالعات سنجش از دور شد و در زمینه‌های مختلفی همچون طبقه‌بندی کاربری/پوشش زمین، طبقه‌بندی صحنه و تشخیص هدف

<sup>۵</sup> Deep Neural Networks

<sup>۶</sup> Convolutional Neural Networks

<sup>۷</sup> Zhang et al

<sup>۸</sup> Shi et al

<sup>۱</sup> Shih et al

<sup>۲</sup> Zhang et al

<sup>۳</sup> Bui and Mucsi

<sup>۴</sup> Deep Learning

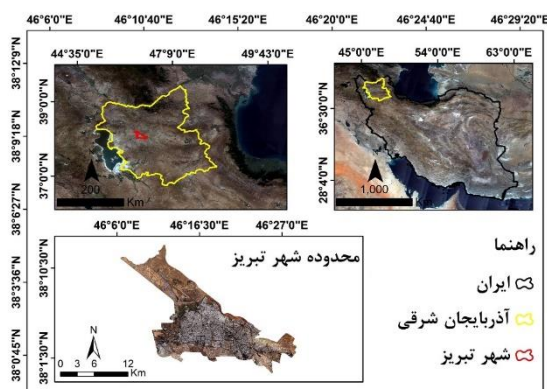
می‌باشد [۵۲]. از دیگر پژوهش‌های انجام شده در زمینه کاربرد الگوریتم یادگیری عمیق در تهیه نقشه کاربری اراضی می‌توان به پژوهش‌های فاندیسی و همکاران<sup>۱</sup> (۲۰۲۱) و گوپال سینگ و همکاران<sup>۲</sup> (۲۰۲۱) اشاره کرد [۵۴و۵۳].

با توجه به مطالعات قبلی صورت گرفته در زمینه تهیه نقشه پوشش اراضی با استفاده از الگوریتم‌های جنگل تصادفی و یادگیری عمیق می‌توان گفت هر دو الگوریتم از دقت و کارایی مناسبی در طبقه‌بندی تصاویر ماهواره‌ای برخوردار می‌باشند. حال آنکه با توجه به نوع کاربری‌های مورد نظر و تصاویر ماهواره‌ای مورد استفاده، میزان دقت و عملکرد الگوریتم‌های جنگل تصادفی و یادگیری عمیق نیز تغییر می‌کند. بر این اساس هدف این تحقیق، طبقه‌بندی پوشش اراضی شهری در شهر تبریز با استفاده از تصویر ماهواره‌ای سنتینل-۲ و الگوریتم‌های شبکه عصبی عمیق و جنگل تصادفی می‌باشد. در انتها بر اساس نتایج به دست آمده از طبقه‌بندی تصویر، کارایی این دو الگوریتم برای تهیه نقشه پوشش شهری ارزیابی گردیده است. تاکنون تحقیقات اندکی در زمینه مقایسه دو الگوریتم شبکه عصبی عمیق و جنگل تصادفی به منظور طبقه‌بندی پوشش اراضی شهری با استفاده از تصاویر ماهواره‌ای سنتینل-۲ انجام گرفته است و در این تحقیق برای اولین بار به مقایسه این دو الگوریتم برای تهیه نقشه پوشش‌های شهری در شهر تبریز پرداخته شده است. همچنین در این تحقیق تمام مراحل پردازش تصویر ماهواره‌ای به صورت خودکار و در سامانه‌های پردازش ابری Google Colab و Google Earth Engine انجام گرفته است. سایر قسمت‌های مقاله عبارتند از: بخش دوم که به معرفی منطقه مورد مطالعه و داده‌های مورد استفاده در تحقیق می‌پردازد، در بخش سوم روش تحقیق و الگوریتم‌های مورد استفاده بیان خواهد شد، در بخش چهارم نتایج حاصل از تحقیق ارائه خواهد شد و در نهایت در بخش پنجم به نتیجه‌گیری و ارائه پیشنهادات پرداخته خواهد شد.

## ۲- منطقه مطالعاتی و داده‌های مورد استفاده

منطقه مورد مطالعه در این تحقیق شهر تبریز می‌باشد. شهر تبریز مرکز استان آذربایجان شرقی، و یکی از

کلانشهرهای ایران می‌باشد. بر اساس آخرین سرشماری انجام شده در سال ۱۳۹۵ جمعیت این شهر ۱۵۵۸۶۹۳ نفر می‌باشد. شهر تبریز از لحاظ جغرافیایی در مختصات  $17^{\circ} 6' 46''$  الی  $12^{\circ} 31' 38''$  عرض شمالی قرار گرفته است (شکل ۱). مساحت این شهر حدود ۲۵۲ کیلومتر مربع می‌باشد. در سال‌های اخیر، توسعه شهری تبریز و تغییرات کاربری زمین در آن، در مقایسه با افزایش جمعیتی این شهر سرعت و شدت بیشتری داشته است [۵۵]. در نتیجه تهیه نقشه پوشش اراضی شهری در این شهر، می‌تواند به‌عنوان یکی از اطلاعات کاربردی برای مدیریت شهری محسوب شود.

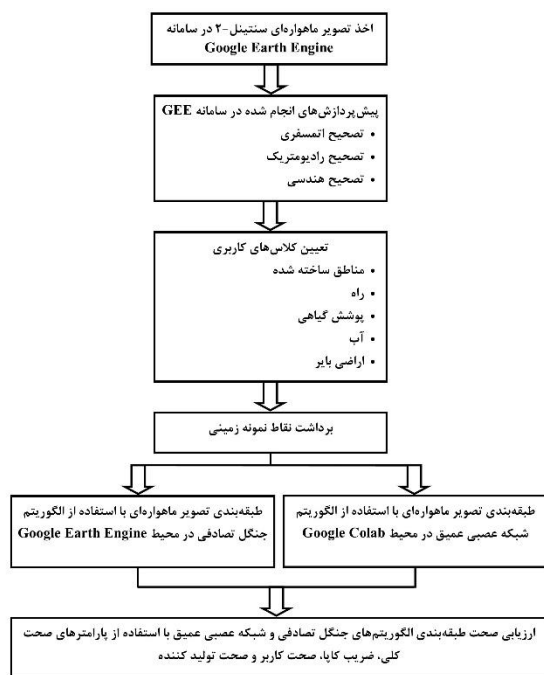


شکل ۱- موقعیت منطقه مورد مطالعه

در این تحقیق، به‌منظور تهیه نقشه پوشش اراضی شهری، از تصویر ماهواره‌ای سنتینل-۲ استفاده شد. برای این منظور، از تصویر ماهواره‌ای سنتینل-۲ در تاریخ ۲۷ آگوست ۲۰۱۹ استفاده شده است، تصویر مورد نظر فاقد پوشش ابر می‌باشد که این امر به‌نوبه خود در افزایش صحت طبقه‌بندی تأثیرگذار می‌باشد. ماهواره سنتینل-۲ در ۱۳ باند طیفی و در محدوده طول موج ۴۴۳ نانومتر تا ۲۱۹۰ نانومتر تصویر برداری می‌کند. از ۱۳ باند طیفی ماهواره سنتینل-۲، ۴ باند (در محدوده طیفی مرئی و مادون قرمز نزدیک) دارای قدرت تفکیک مکانی ۱۰ متر، ۶ باند (در محدوده طیفی لبه قرمز و مادون قرمز کوتاه) دارای قدرت تفکیک مکانی ۲۰ متر و ۳ باند (باندهای مربوط به تصحیحات اتمسفری) دارای قدرت تفکیک مکانی ۶۰ متر می‌باشند [۵۶]. در این تحقیق از باندهای ۱، ۹ و ۱۰ که دارای قدرت تفکیک مکانی ۶۰ متر می‌باشند و کاربرد آن‌ها بیشتر در مطالعات بخار آب و

<sup>۱</sup> Fundisi et al

<sup>۲</sup> Gopal Singh et al



شکل ۲- فلوجارت مراحل کار

### ۳-۱- تعیین کلاس‌های کاربری

با توجه به قدرت تفکیک مکانی ۱۰ متری تصاویر سنتینل-۲، کلاس‌های کاربری مورد نظر نیز در همین راستا و با توجه به قدرت تفکیک مکانی تصویر ماهواره‌ای در قالب ۵ نوع پوشش سطحی: اراضی بایر، مناطق ساخته شده، راه، پوشش گیاهی و آب تعریف شد. منظور از اراضی بایر مناطقی می‌باشد که در آن‌ها هیچ‌گونه ساخت‌وسازی صورت نگرفته است و فاقد پوشش گیاهی می‌باشند. مناطق ساخته شده شامل کلیه مناطقی می‌باشد که در آن‌ها به‌نوعی ساخت‌وساز صورت گرفته است که از آن‌جمله می‌توان به مناطق مسکونی، تجاری، صنعتی و غیره اشاره کرد. تمامی خطوط ارتباطی مانند راه‌های اصلی و فرعی در قالب کلاس راه در نظر گرفته شده است. تمامی پوشش‌های گیاهی از جمله فضای سبز شهری، باغات و اراضی کشاورزی به‌عنوان کلاس پوشش گیاهی، و در نهایت همه پوشش‌های سطحی آب نیز به‌عنوان کلاس آب در نظر گرفته شده‌اند.


اتمسفر می‌باشد در انجام طبقه‌بندی استفاده نشدند. برای طبقه‌بندی تصویر ماهواره‌ای سنتینل-۲ از دو الگوریتم جنگل تصادفی و شبکه عصبی عمیق، استفاده شد. داده‌های مورد استفاده برای آموزش و ارزیابی الگوریتم‌های طبقه‌بندی، شامل داده‌های برداشت شده زمینی و نقشه پوشش/کاربری اراضی شهری شهر تبریز می‌باشد، که توسط شهرداری تبریز تهیه شده است. برای انجام عملیات مورد نظر (پیش‌پردازش، طبقه‌بندی و ارزیابی صحت طبقه‌بندی) بر روی تصویر ماهواره‌ای از سامانه پردازش ابری Google Earth Engine و کتابخانه Keras در محیط پردازشی Google Colab استفاده شد. تصاویر ماهواره‌ای سنتینل-۲ که در سامانه Google Earth Engine ارائه می‌شوند، از لحاظ اتمسفری تصحیح گردیده‌اند، همچنین مقادیر عددی پیکسل‌ها نیز از لحاظ رادیومتریک تصحیح شده و به‌صورت بازتاب سطحی<sup>۱</sup> ارائه می‌شوند؛ برای این-این منظور (تصحیح اتمسفری و رادیومتریک) از الگوریتم sen2cor استفاده شده است. علاوه بر این، تصاویر ارائه شده در این سامانه از لحاظ هندسی نیز تصحیح شده‌اند. برای تصحیح هندسی تصاویر سنتینل-۲ از مجموعه تصاویر GRI<sup>۲</sup> استفاده شده است، این تصاویر شامل پوشش جهانی باند ۴ تصویر سنتینل-۲ می‌باشند که فاقد پوشش ابر و دارای موقعیت جغرافیایی کاملاً مشخص و دقیقی می‌باشند. بر این اساس تصاویر سنتینل-۲ به‌صورت تصویر به تصویر تصحیح هندسی شده و با حداکثر خطای RMSE ۰/۳ پیکسل در سامانه Google Earth Engine ارائه می‌شوند.

### ۳- روش تحقیق

مراحل کلی روش تحقیق (شکل ۲) شامل: اخذ تصویر ماهواره‌ای، پیش‌پردازش تصویر ماهواره‌ای، تعیین کلاس‌های کاربری، برداشت نقاط نمونه زمینی، طبقه‌بندی تصویر ماهواره‌ای با استفاده از الگوریتم‌های جنگل تصادفی و شبکه عصبی عمیق و در نهایت ارزیابی صحت طبقه‌بندی می‌باشد.

<sup>۱</sup> Reflectance

<sup>۲</sup> Geometric Reference Image



شکل ۳- تصویر ماهواره‌ای سنتینل-۲ مربوط به شهر تبریز

### ۳-۲- الگوریتم جنگل تصادفی

الگوریتم جنگل تصادفی دارای عملکرد مناسبی در طبقه‌بندی پوشش اراضی می‌باشد [۵۷]. این الگوریتم در ابتدا از نقاطی که به‌طور تصادفی و به‌منظور آموزش مدل انتخاب شده‌اند (متغیر پاسخ) و همچنین نمونه‌هایی از متغیرهای پیش‌بینی کننده استفاده می‌کند، در نتیجه تعدادی درخت مستقل از یکدیگر طبقه‌بندی می‌شوند. این روند چند صد بار تکرار می‌شود و در نتیجه جنگلی متشکل از صدها طبقه‌کننده تشکیل می‌شود؛ در این حالت هر درخت با یک رأی منصحبه‌فرد به انتخاب کلاس مورد نظر می‌پردازد، نتایج نهایی طبقه‌بندی بر اساس رأی اکثریت درختان تصمیم‌گیر تعیین می‌شود [۷]. دو معیار تعداد درختان<sup>۱</sup> و تعداد متغیرها<sup>۲</sup> به‌عنوان دو معیار اصلی در الگوریتم جنگل تصادفی مورد استفاده قرار می‌گیرند. بر این اساس در این تحقیق به‌منظور طبقه‌بندی تصویر ماهواره‌ای با استفاده از الگوریتم جنگل تصادفی در سامانه Google Earth Engine از ۳۰۰۰ نمونه آموزشی و ۱۰۰ درخت تصمیم‌گیری استفاده شد، همچنین از جذر تعداد ویژگی‌های (جذر تعداد باندهای تصویر سنتینل-۲) به‌عنوان تعداد متغیرها استفاده گردید.

### ۳-۳- الگوریتم شبکه عصبی عمیق

روش‌های یادگیری عمیق، بخشی از خانواده بزرگ روش‌های یادگیری ماشین<sup>۳</sup> محسوب می‌شوند که اصول

کلی یادگیری در آن‌ها، مشابه شبکه‌های عصبی مصنوعی<sup>۴</sup> می‌باشد [۵۸]. مفهوم یادگیری عمیق اشاره به تعداد زیادی از لایه‌های پنهان و ارتباط ناهمگن این لایه‌ها با یکدیگر دارد [۵۹]. برخی از مهم‌ترین معماری‌ها (مدل‌ها) در روش یادگیری عمیق عبارتند از: شبکه‌های عصبی عمیق<sup>۵</sup>، شبکه‌های عصبی پیچشی<sup>۶</sup> و شبکه‌های عصبی بازگشتی<sup>۷</sup> [۶۰]. در واقع شبکه عصبی عمیق (DNN) نوعی از شبکه عصبی مصنوعی (ANN) می‌باشد که دارای چندین لایه بین لایه ورودی و لایه خروجی می‌باشد [۵۸]. در این حالت برای تبدیل لایه ورودی به لایه خروجی از توابع غیر خطی استفاده می‌شود. روش‌های یادگیری عمیق دارای کاربرد گسترده‌ای در مسائل مختلف محیطی از جمله در پردازش تصاویر ماهواره‌ای می‌باشند [۶۱]. در سال‌های اخیر مدل DNN کارایی مناسبی را در مسائل مختلف سنجش از دور از جمله در طبقه‌بندی تصاویر ماهواره‌ای از خود نشان داده است. ویژگی مهم مدل‌های یادگیری عمیق، توانایی آن‌ها در کشف ویژگی‌ها از ساده‌ترین تا پیچیده‌ترین آن‌ها در حجم عظیمی از داده‌ها می‌باشد [۴۹]. در سال‌های اخیر پیشرفت‌های مهمی در شبکه‌های عصبی اتفاق افتاده است که عامل اصلی آن افزایش تعداد لایه‌های پنهان و استفاده از توابع محرک<sup>۸</sup> پیشرفته در این شبکه‌ها می‌باشد. استفاده از این مزایا که در شبکه‌های عصبی عمیق نیز شاهد آن هستیم، باعث ایجاد پیشرفت‌های چشمگیری در کاربردهای مختلف از جمله در طبقه‌بندی تصاویر ماهواره‌ای گردیده است [۶۲]. بر این اساس در این تحقیق از شبکه عصبی عمیق (شکل ۴) با یک لایه ورودی همراه با ۱۰ نرون (باندهای تصویر سنتینل-۲)، چهار لایه پنهان و ۲۰۰ نرون در هر لایه استفاده شد، همچنین لایه آخر (خروجی) این شبکه شامل ۵ نوع کلاس کاربری می‌باشد. مطالعه لو و همکاران<sup>۹</sup> (۲۰۱۷) نشان‌دهنده این موضوع می‌باشد که استفاده از تابع محرک ReLU در لایه‌های پنهان شبکه عصبی عمیق باعث افزایش عملکرد مدل می‌شود [۶۳]. بنابراین در این تحقیق نیز از تابع محرک ReLU در لایه‌های پنهان شبکه عصبی عمیق استفاده شد، همچنین از

<sup>۴</sup> Artificial Neural Networks

<sup>۵</sup> Deep Neural Networks

<sup>۶</sup> Convolutional Neural Networks

<sup>۷</sup> Recurrent Neural Networks

<sup>۸</sup> Activation Function

<sup>۹</sup> Lu et al

<sup>۱</sup> Number of Tree

<sup>۲</sup> Number of Feature

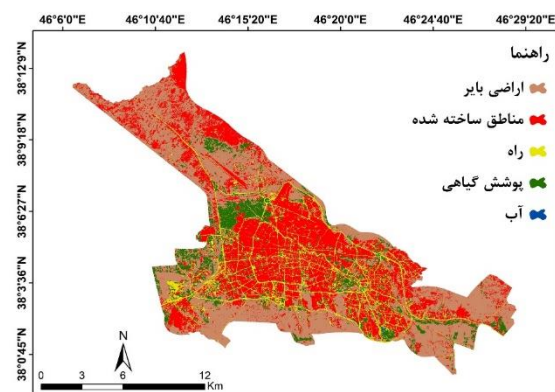
<sup>۳</sup> Machine Learning

نتایج حاصل از طبقه‌بندی مورد استفاده قرار گرفتند. با توجه به اینکه در روش شبکه عصبی عمیق نیاز است تا صحت مدل با افزایش تکرارها، بهینه و ارزیابی شود، از ۳۰ درصد نمونه‌ها، ۱۵ درصد برای بهینه کردن و اعتبارسنجی مدل و ۱۵ درصد به منظور ارزیابی صحت نتایج نهایی استفاده شد. روش متداول مورد استفاده برای ارزیابی صحت نقشه‌های طبقه‌بندی شده، استفاده از ماتریس خطا<sup>۴</sup> می‌باشد. صحت کلی، ضریب کاپا، صحت کاربر و صحت تولید کننده، از جمله پارامترهایی هستند که با توجه به ماتریس خطا قابل محاسبه می‌باشند [۳۵]. در این تحقیق نیز از این پارامترها برای ارزیابی نقشه‌های طبقه‌بندی شده استفاده گردید.

#### ۴- نتایج و بحث

##### ۴-۱- نتایج الگوریتم جنگل تصادفی


به منظور طبقه‌بندی تصویر ماهواره‌ای سنتینل-۲ با استفاده از الگوریتم جنگل تصادفی (شکل ۵) از ۱۰۰ درخت تصمیم‌گیری استفاده شد، علت انتخاب ۱۰۰ درخت تصمیم‌گیری برای انجام طبقه‌بندی، پایدار (ثابت) ماندن نرخ خطا در این تعداد از درخت تصمیم‌گیری می‌باشد؛ در الگوریتم جنگل تصادفی تعداد درختان باید به اندازه کافی باشد تا نرخ خطا پایدار (ثابت) بماند [۳۸]. با توجه به مطالعات انجام شده در زمینه طبقه‌بندی تصاویر ماهواره‌ای با استفاده از الگوریتم جنگل تصادفی معمولاً جذر تعداد ویژگی‌ها به عنوان تعداد متغیرها در نظر گرفته می‌شود [۳۹ و ۶۵]. بر این اساس در این تحقیق نیز جذر تعداد ویژگی‌ها به عنوان تعداد متغیرها در نظر گرفته شد.



شکل ۵- نتایج طبقه‌بندی توسط الگوریتم جنگل تصادفی

۴ Error Matrix (Confusion Matrix)

تابع محرک softmax نیز به منظور دسته‌بندی (کلاس‌بندی) اطلاعات در لایه خروجی استفاده گردید. وجود لایه dropout باعث می‌شود تا از Overfit شدن نتایج کاسته شود و بتوان به نتایج قابل اعتمادتری دست پیدا کرد، مقدار عددی در نظر گرفته شده برای این لایه ۰/۲ می‌باشد. نکته مهمی که باید در شبکه عصبی عمیق در نظر گرفته شود، تعداد زیاد داده‌های آموزشی می‌باشد، با افزایش تعداد داده‌های آموزشی شبکه بهتر آموزش دیده و نتایج دقیق‌تری حاصل می‌شود. بر این اساس در این تحقیق از ۳۰۰۰ نمونه آموزشی برای آموزش الگوریتم و ارزیابی نتایج طبقه‌بندی استفاده شد. بر این اساس ۷۰ درصد نمونه‌ها برای آموزش<sup>۱</sup>، ۱۵ درصد برای بهینه کردن و اعتبارسنجی اولیه مدل<sup>۲</sup> و ۱۵ درصد برای ارزیابی صحت نتایج نهایی<sup>۳</sup> استفاده گردید. با توجه به نیاز به سیستم پردازشی قوی برای اجرای مدل DNN، از محیط پردازشی Google Colab و فضای ابری این محیط تحت عنوان Google cloud storage bucket برای اجرای این مدل استفاده شد. این محیط از قابلیت برقراری ارتباط و تبادل اطلاعات با سامانه Google Earth Engine و کتابخانه Keras برخوردار می‌باشد.




شکل ۴- ساختار مدل DNN استفاده شده در تحقیق

##### ۴-۳- ارزیابی صحت طبقه‌بندی

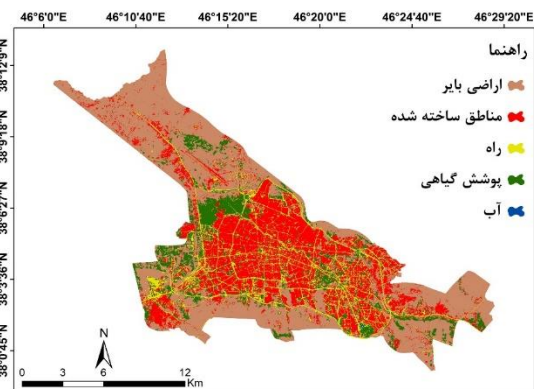
یکی از نکات مهم برای استفاده از هر نوع اطلاعات موضوعی، آگاهی از صحت آن اطلاعات می‌باشد [۶۴]. ارزیابی نتایج طبقه‌بندی، آخرین مرحله از تولید نقشه‌های طبقه‌بندی شده می‌باشد. در این تحقیق برای ارزیابی صحت نتایج از نمونه‌های آموزشی که در روند طبقه‌بندی دخالت داده نشده‌اند، استفاده گردید. بر این اساس ۷۰ درصد نمونه‌ها به منظور طبقه‌بندی تصویر و ۳۰ درصد نمونه‌ها برای ارزیابی صحت

۱ Train  
۲ Validate  
۳ Test





شکل ۷- روند کاهش خطا با افزایش تعداد تکرارهای مدل



شکل ۸- نتایج طبقه‌بندی توسط الگوریتم شبکه عصبی عمیق

بررسی نتایج الگوریتم شبکه عصبی عمیق نشان‌دهنده صحت کلی ۹۵/۲ درصد و ضریب کاپای ۰/۹۴۱ بود که با توجه به تصویر ماهواره‌ای و کلاس‌های کاربری، صحت مناسبی محسوب می‌شود. بررسی صحت هر یک از کلاس‌های کاربری به صورت جداگانه نشان داد (جدول ۲)، کلاس‌های پوشش گیاهی و آب با صحت کاربر و تولید کننده ۱۰۰ درصد به خوبی از سایر کلاس‌ها تشخیص داده شدند. از طرفی دیگر، کلاس راه با صحت کاربر ۹۴/۱۵ درصد و صحت تولید کننده ۹۳/۴ درصد کمترین صحت کاربر و تولید کننده را به خود اختصاص دادند.

جدول ۲- ارزیابی صحت نتایج الگوریتم شبکه عصبی عمیق

صحت تولید کننده	صحت کاربر	کلاس کاربری
۹۳/۵ %	۹۶/۱ %	اراضی بایر
۹۳/۷ %	۹۴/۲ %	مناطق ساخته شده
۹۳/۴ %	۹۴/۱۵ %	راه
۱۰۰ %	۱۰۰ %	پوشش گیاهی
۱۰۰ %	۱۰۰ %	آب
صحت کلی: ۹۵/۲ %		ضریب کاپای: ۰/۹۴۱


ارزیابی نتایج به دست آمده از الگوریتم جنگل تصادفی نشان‌دهنده صحت کلی ۹۳/۱ درصد و ضریب کاپای ۰/۹۰۲ بود که صحت مناسبی در طبقه‌بندی پوشش اراضی شهری با استفاده از تصاویر ماهواره‌ای با قدرت تفکیک مکانی ۱۰ متر محسوب می‌شود. صحت کلی و ضریب کاپا برای ارزیابی کلی نتایج مناسب می‌باشند و برای ارزیابی دقیق‌تر نتایج باید از صحت کاربر و صحت تولید کننده هر کلاس استفاده شود (جدول ۱). بر این اساس کلاس‌های پوشش گیاهی و آب با صحت کاربر و تولید کننده ۱۰۰ درصد، بهتر از سایر کلاس‌ها طبقه‌بندی شده‌اند. کلاس اراضی بایر با صحت کاربر ۸۶/۵ کمترین صحت کاربر و کلاس اراضی ساخته شده با صحت تولید کننده ۸۹/۴ کمترین صحت تولید کننده را به خود اختصاص دادند.

جدول ۱- ارزیابی صحت نتایج الگوریتم جنگل تصادفی

صحت تولید کننده	صحت کاربر	کلاس کاربری
۹۲/۵ %	۸۶/۵ %	اراضی بایر
۸۹/۴ %	۹۳/۹ %	مناطق ساخته شده
۹۷/۵ %	۹۷/۸ %	راه
۱۰۰ %	۱۰۰ %	پوشش گیاهی
۱۰۰ %	۱۰۰ %	آب
صحت کلی: ۹۳/۱ %		ضریب کاپا: ۰/۹۰۲

#### ۴-۲- نتایج الگوریتم شبکه عصبی عمیق

به منظور طبقه‌بندی تصویر ماهواره‌ای سنتینل-۲ با استفاده از روش شبکه عصبی عمیق (شکل ۸)، از یک لایه ورودی و چهار لایه پنهان استفاده شد، همچنین برای اجرای مدل از ۱۰۰ تکرار<sup>۱</sup> استفاده گردید. مطابق با نتایج با افزایش تکرارها، صحت مدل افزایش یافته (شکل ۶) و میزان خطا<sup>۲</sup> کاهش پیدا می‌کند (شکل ۷).



شکل ۶- روند افزایش صحت مدل با افزایش تعداد تکرارهای مدل

<sup>۱</sup> Epoch  
<sup>۲</sup> Loss



#### ۳-۴ - مقایسه نتایج الگوریتم جنگل تصادفی و شبکه عصبی عمیق

تصادفی در زمینه طبقه‌بندی راه از الگوریتم شبکه عصبی عمیق بهتر است، علاوه بر اینکه نوع تصویر ماهواره‌ای و تعداد نقاط آموزشی نیز در این زمینه تأثیرگذار می‌باشند. در مورد کلاس پوشش گیاهی و آب هر دو الگوریتم عملکرد مشابه و مناسبی ارائه داده‌اند و بیشترین صحت در طبقه‌بندی این دو کلاس حاصل شده است. بر این اساس می‌توان گفت الگوریتم شبکه عصبی عمیق در طبقه‌بندی اراضی بایر و مناطق ساخته شده عملکرد بهتری را نسبت به الگوریتم جنگل تصادفی ارائه داده است، این موضوع در شکل‌های شماره ۷ و ۸ نیز مشخص می‌باشد. بر این اساس در مناطق شمال‌غربی شهر تبریز که عمدتاً شامل مناطقی با تراکم ساختمانی پایین می‌باشد، الگوریتم شبکه عصبی عمیق به‌خوبی توانسته این پراکندگی را تشخیص داده و در تفکیک مناطق ساخته شده و اراضی بایر کمتر دچار خطا شده است، ولی نتایج الگوریتم جنگل تصادفی در طبقه‌بندی این مناطق با خطاهایی همراه بوده است. از طرفی نتایج صحت کاربر و تولید کننده کلاس راه نشان می‌دهد الگوریتم جنگل تصادفی در تشخیص و طبقه‌بندی این کلاس‌های کاربری استفاده شده در این تحقیق محدود و شامل پوشش‌های کلی اراضی شهری می‌باشد، ولی در عین حال، هر دو الگوریتم (جنگل تصادفی و شبکه عصبی عمیق) به‌خوبی توانسته‌اند کلاس‌های کاربری مورد نظر را با توجه به قدرت تفکیک مکانی تصاویر ماهواره‌ای سنتینل-۲ طبقه‌بندی کنند.

بررسی نتایج حاصل از ارزیابی صحت دو الگوریتم جنگل تصادفی و شبکه عصبی عمیق (شکل ۹) نشان داد که در حالت کلی الگوریتم شبکه عصبی عمیق عملکرد بهتری را ارائه کرده است، به‌طوری‌که صحت کلی الگوریتم شبکه عصبی عمیق نسبت به الگوریتم جنگل تصادفی ۲/۱ درصد و ضریب کاپای آن ۰/۳۹ بیشتر می‌باشد. بررسی عملکرد این دو الگوریتم در طبقه‌بندی هر یک از کلاس‌ها نیز نشان از عملکرد بهتر الگوریتم شبکه عصبی عمیق دارد. به‌طوری‌که در کلاس اراضی بایر، صحت کاربر الگوریتم شبکه عصبی عمیق ۹/۶ درصد و صحت تولید کننده آن ۱ درصد بیشتر از الگوریتم جنگل تصادفی بود. در کلاس مناطق ساخته شده نیز صحت کاربر الگوریتم شبکه عصبی عمیق ۰/۳ درصد و صحت تولید کننده آن ۴/۳ درصد بیشتر از الگوریتم جنگل تصادفی بود. نتایج به‌دست آمده نشان داد الگوریتم شبکه عصبی عمیق در طبقه‌بندی مناطق ناهمگن با تغییرات مقادیر طیفی زیاد (راضی بایر و مناطق ساخته شده) عملکرد بهتری نسبت به الگوریتم جنگل تصادفی دارد. این نتایج با نتایج تحقیق ژانگ و همکاران<sup>۱</sup> (۲۰۱۸) همخوانی دارد؛ محققان در این تحقیق از تصاویر ماهواره‌ای لندست-۸ و الگوریتم‌های شبکه عصبی عمیق، جنگل تصادفی و ماشین بردار پشتیبان برای طبقه‌بندی آب‌های سطحی، مناطق ساخته شده، اراضی بایر و مزارع برنج استفاده کردند. نتایج نشان داد که الگوریتم شبکه عصبی عمیق در مناطق ناهمگن دقت بالاتری را نسبت به الگوریتم‌های جنگل تصادفی و ماشین بردار پشتیبان ارائه می‌دهد [۶۶]. در طبقه‌بندی کلاس راه، الگوریتم جنگل تصادفی عملکرد بهتری را ارائه داده است، به‌طوری‌که صحت کاربر آن ۳/۶۵ درصد و صحت تولید کننده آن ۴/۱ درصد بیشتر از الگوریتم شبکه عصبی عمیق می‌باشد. بر این اساس می‌توان گفت الگوریتم جنگل تصادفی در طبقه‌بندی عوارض خطی عملکرد بهتری را داشته است. به‌طوری‌که در تحقیق هایس و همکاران<sup>۲</sup> (۲۰۱۴) نیز نشان داده شده است که الگوریتم جنگل تصادفی در طبقه‌بندی راه عملکرد مناسبی را داشته است [۶۷]. در این مورد به تحقیقات بیشتری نیاز است تا بتوان با قطعیت گفت عملکرد الگوریتم جنگل



شکل ۹- صحت طبقه‌بندی الگوریتم جنگل تصادفی و یادگیری عمیق

#### ۵- نتیجه‌گیری و پیشنهادات

طبقه‌بندی پوشش اراضی شهری به‌علت قابلیت برقراری ارتباط بین عناصر انسانی و محیط فیزیکی همواره از اهمیت زیادی برخوردار بوده است. از طرفی، یکی از

<sup>۱</sup> Zhang et al

<sup>۲</sup> Hayes et al

با در نظر گرفتن این نقشه‌ها، برنامه‌ریزی‌های مناسبی را در جهت توسعه پایدار شهری اتخاذ کنند. بر این اساس توجه به مسائلی همچون، عدم توسعه شهری در نواحی با پوشش گیاهی متراکم و توجه به تعادل و پراکنش مناسب کاربری‌ها در نواحی مختلف شهر، از جمله مسائلی می‌باشد که در این زمینه حائز اهمیت می‌باشد. همچنین به‌منظور مدیریت بهتر شهری، نیاز است تا نقشه‌های پوشش شهری با جزئیات و در تعداد کلاس‌های بیشتری تهیه شوند، بر این اساس پیشنهاد می‌شود تا در تحقیقات آتی از تصاویر ماهواره‌ای با قدرت تفکیک مکانی بسیار بالا و یا عکس‌های هوایی استفاده شود تا با استفاده از آن‌ها بتوان کاربری‌ها و پوشش‌های شهری را با جزئیات و در تعداد کلاس‌های بیشتری طبقه‌بندی کرد. استفاده از سایر الگوریتم‌های طبقه‌بندی و مقایسه نتایج آن‌ها با یکدیگر نیز می‌تواند از موضوعات جالب در تحقیقات آتی محسوب شود.

اساسی‌ترین داده‌ها برای مطالعات شهری، نقشه پوشش اراضی شهری و نحوه پراکنش آن‌ها می‌باشد. بر این اساس در این تحقیق با استفاده از تصاویر ماهواره‌ای سنتینل-۲ و الگوریتم‌های طبقه‌بندی جنگل تصادفی و شبکه عصبی عمیق، به تهیه نقشه پوشش شهری تبریز پرداخته شد. کلاس‌های کاربری مورد نظر در این تحقیق شامل پنج کلاس: اراضی بایر، مناطق ساخته شده، راه، پوشش گیاهی و آب بودند. بر اساس نتایج به‌دست آمده مشخص گردید، الگوریتم شبکه عصبی عمیق با صحت کلی ۹۵/۲ درصد، صحت بهتری را نسبت به الگوریتم جنگل تصادفی با صحت کلی ۹۳/۱ درصد ارائه داده است. در حالت کلی می‌توان گفت هر دو الگوریتم عملکرد مطلوبی در تهیه نقشه پوشش اراضی شهری ارائه داده‌اند، اما عملکرد کلی الگوریتم شبکه عصبی عمیق مناسب‌تر بوده است. با توجه به اهمیت نقشه پوشش اراضی شهری در برنامه‌ریزی‌های شهری، پیشنهاد می‌شود تا مدیران شهری

## مراجع

- [1] Yoo, C., Han, D., Im, J. and Bechtel, B. (2019). "Comparison between convolutional neural networks and random forest for local climate zone classification in mega urban areas using Landsat images." *ISPRS Journal of Photogrammetry and Remote Sensing*. Vol. 157, PP. 155-170.
- [2] Seto, K. C., Fragkias, M., Güneralp, B. and Reilly, M. K. (2011). "A meta-analysis of global urban land expansion." *PloS one*. Vol. 6, No. 8, PP. 23777.
- [3] Ban, Y., Jacob, A. and Gamba, P. (2015). "Spaceborne SAR data for global urban mapping at 30 m resolution using a robust urban extractor." *ISPRS Journal of Photogrammetry and Remote Sensing*. Vol. 103, PP. 28-37.
- [4] Stefanov, W. L., Ramsey, M. S. and Christensen, P. R. (2001). "Monitoring urban land cover change: An expert system approach to land cover classification of semiarid to arid urban centers." *Remote sensing of Environment*. Vol. 77, No. 2, PP. 173-185.
- [5] Jacob, A. and Ban, Y. (2015). "Sentinel-1A SAR data for global urban mapping: preliminary results." *Proc. 35<sup>th</sup> IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, July, Milan, Italy, PP. 1179-1182.
- [6] Zhang, H., Li, J., Wang, T., Lin, H., Zheng, Z., Li, Y. and Lu, Y. (2018). "A manifold learning approach to urban land cover classification with optical and radar data." *Landscape and Urban Planning*. Vol. 172, PP. 11-24.
- [7] Gounaridis, D. and Koukoulas, S. (2016). "Urban land cover thematic disaggregation, employing datasets from multiple sources and RandomForests modeling." *International journal of applied earth observation and geoinformation*. Vol. 51, PP. 1-10.
- [8] Lu, D. and Weng, Q. (2006). "Use of impervious surface in urban land-use classification." *Remote Sensing of Environment*. Vol. 102, No. 2, PP. 146-160.
- [9] Wan, B., Guo, Q., Fang, F., Su, Y. and Wang, R. (2015). "Mapping US urban extents from MODIS data using one-class classification method." *Remote Sensing*. Vol. 7, No. 8, PP. 10143-10163.
- [10] Huang, X., Wen, D., Li, J. and Qin, R. (2017). "Multi-level monitoring of subtle urban changes for the megacities of China using high-resolution multi-view satellite imagery." *Remote sensing of environment*. Vol. 196, PP. 56-75.
- [11] Schneider, A., Friedl, M. A. and Potere, D. (2009). "A new map of global urban extent from MODIS satellite data." *Environmental research letters*. Vol. 4, No. 4, PP. 044003.

- [12] Schneider, A., Friedl, M. A. and Potere, D. (2010). "Mapping global urban areas using MODIS 500-m data: New methods and datasets based on 'urban ecoregions.'" *Remote Sensing of Environment*. Vol. 114, No. 8, PP. 1733-1746.
- [13] Elvidge, C. D., Hsu, F. C., Baugh, K. E. and Ghosh, T. (2014). "National trends in satellite-observed lighting." *Global urban monitoring and assessment through earth observation*. Vol. 23, PP. 97-118.
- [14] Xiao, P., Wang, X., Feng, X., Zhang, X. and Yang, Y. (2014). "Detecting China's urban expansion over the past three decades using nighttime light data." *IEEE Journal of selected topics in applied earth observations and remote sensing*. Vol. 7, No. 10, PP. 4095-4106.
- [15] Zhang, Q. and Seto, K. C. (2013). "Can night-time light data identify typologies of urbanization? A global assessment of successes and failures." *Remote Sensing*. Vol. 5, No. 7, PP. 3476-3494.
- [16] Lo, C. P. and Choi, J. (2004). "A hybrid approach to urban land use/cover mapping using Landsat 7 Enhanced Thematic Mapper Plus (ETM+) images." *International Journal of Remote Sensing*. Vol. 25, No. 14, PP. 2687-2700.
- [17] Zhu, Z., Woodcock, C. E., Rogan, J. and Kellndorfer, J. (2012). "Assessment of spectral, polarimetric, temporal, and spatial dimensions for urban and peri-urban land cover classification using Landsat and SAR data." *Remote Sensing of Environment*. Vol. 117, PP. 72-82.
- [18] Hu, T., Yang, J., Li, X. and Gong, P. (2016). "Mapping urban land use by using landsat images and open social data." *Remote Sensing*. Vol. 8, No. 2, PP. 151.
- [19] Liu, X., Hu, G., Chen, Y., Li, X., Xu, X., Li, S., Pei, F. and Wang, S. (2018). "High-resolution multi-temporal mapping of global urban land using Landsat images based on the Google Earth Engine Platform." *Remote sensing of environment*. Vol. 209, PP. 227-239.
- [20] Abdikan, S., Sanli, F. B., Ustuner, M. and Calò, F. (2016). "Land cover mapping using sentinel-1 SAR data." *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*. Vol. 41, PP. 757.
- [21] Corbane, C., Pesaresi, M., Politis, P., Syrris, V., Florczyk, A. J., Soille, P., Maffenini, L., Burger, A., Vasilev, V. and Rodriguez, F. (2017). "Big earth data analytics on Sentinel-1 and Landsat imagery in support to global human settlements mapping." *Big Earth Data*. Vol. 1, No. 2, PP. 118-144.
- [22] Corbane, C., Lemoine, G., Pesaresi, M., Kemper, T., Sabo, F., Ferri, S. and Syrris, V. (2018). "Enhanced automatic detection of human settlements using Sentinel-1 interferometric coherence." *International Journal of Remote Sensing*. Vol. 39, No. 3, PP. 842-853.
- [23] Priem, F., Canters, F., Okujeni, A. and van der Linden, S. (2017). "Optimizing mixed spectra generation for regression-based unmixing of land cover in urban areas." *Proc. 6<sup>th</sup> Joint Urban Remote Sensing Event (JURSE)*. March, Dubai, United Arab Emirates, PP. 1-4.
- [24] Haas, J. and Ban, Y. (2018). "Urban land cover and ecosystem service changes based on Sentinel-2A MSI and Landsat TM Data." *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*. Vol. 11, No. 2, PP. 485-497.
- [25] Qiu, C., Mou, L., Schmitt, M. and Zhu, X. X. (2019). "Local climate zone-based urban land cover classification from multi-seasonal Sentinel-2 images with a recurrent residual network." *ISPRS Journal of Photogrammetry and Remote Sensing*. Vol. 154, PP. 151-162.
- [26] Singh, K. K., Vogler, J. B., Shoemaker, D. A. and Meentemeyer, R. K. (2012). "LiDAR-Landsat data fusion for large-area assessment of urban land cover: Balancing spatial resolution, data volume and mapping accuracy." *ISPRS Journal of Photogrammetry and Remote Sensing*. Vol. 74, PP. 110-121.
- [27] Zhou, W. (2013). "An object-based approach for urban land cover classification: Integrating LiDAR height and intensity data." *IEEE Geoscience and Remote Sensing Letters*. Vol. 10, No. 4, PP. 928-931.
- [28] Degerickx, J., Roberts, D. A. and Somers, B. (2019). "Enhancing the performance of Multiple Endmember Spectral Mixture Analysis (MESMA) for urban land cover mapping using airborne lidar data and band selection." *Remote sensing of environment*. Vol. 221, PP. 260-273.
- [29] Zhang, C., Wei, S., Ji, S. and Lu, M. (2019). "Detecting large-scale urban land cover changes from very high-resolution remote sensing images using CNN-based classification." *ISPRS International Journal of Geo-Information*. Vol. 8, No. 4, PP. 189.
- [30] Willkomm, M., Follmann, A. and Dannenberg, P. (2019). "Rule-based, hierarchical land use and land cover classification of urban and peri-urban agriculture in data-poor regions with RapidEye satellite imagery: a case study of Nakuru, Kenya." *Journal of Applied Remote Sensing*. Vol. 13, No. 1, PP. 016517.
- [31] Huang, X., Wang, Y., Li, J., Chang, X., Cao, Y., Xie, J. and Gong, J. (2020). "High-resolution urban land-cover mapping and landscape analysis of the 42 major cities in China using ZY-3 satellite images." *Science Bulletin*. Vol. 65, No. 12, PP. 1039-1048.

- [32] Interdonato, R., Ienco, D., Gaetano, R. and Ose, K. (2019). "DuPLO: A DUal view Point deep Learning architecture for time series classification." ISPRS journal of photogrammetry and remote sensing. Vol. 149, PP. 91-104.
- [33] Priem, F., Okujeni, A., van der Linden, S. and Canters, F. (2019). "Comparing map-based and library-based training approaches for urban land-cover fraction mapping from Sentinel-2 imagery." International Journal of Applied Earth Observation and Geoinformation. Vol. 78, PP. 295-305.
- [34] Poursanidis, D., Chrysoulakis, N. and Mitraka, Z. (2015). "Landsat 8 vs. Landsat 5: A comparison based on urban and peri-urban land cover mapping." International Journal of Applied Earth Observation and Geoinformation. Vol. 35, PP. 259-269.
- [35] Fatemi, S.B. and Rezaei, Y. (2018). "Principles of Remote Sensing." Azadeh press. Tehran (in Persian).
- [36] Breiman, L. (2001). "Random forests." Machine learning. Vol. 45, No. 1, PP. 5-32.
- [37] Adam, E., Mutanga, O., Odindi, J. and Abdel-Rahman, E. M. (2014). "Land-use/cover classification in a heterogeneous coastal landscape using RapidEye imagery: evaluating the performance of random forest and support vector machines classifiers." International Journal of Remote Sensing. Vol. 35, No. 10, PP. 3440-3458.
- [38] Ghasemi esfahlan, A. (2013). "Investigation on random forest method for improving urban land cover classification using satellite imagery." Master of Science, Faculty of Geodesy and Geomatics, K.N. Toosi University of technology (in Persian).
- [39] Sedighi, M. and Amini, A.Sh. (2020). "Classification lake parishan water basin by random forest classification using landsat satellite images." Journal of watershed engineering and management. Vol. 12, No. 3, PP. 621-634 (in Persian).
- [40] Shih, H., Stow, D. A., Chang, K. C. and Roberts, D. A. (2021). "From land cover to land use: Applying random forest classifier to Landsat imagery for urban land-use change mapping." Geocarto International. Vol. 36, No. 1, PP. 1-25.
- [41] Zhang, T., Su, J., Xu, Z., Luo, Y. and Li, J. (2021). "Sentinel-2 satellite imagery for urban land cover classification by optimized random forest classifier." Applied sciences. Vol. 11, No. 2, PP. 543-560.
- [42] Bui, D. H. and Mucsi, L. (2021). "From land cover map to land use map: A combined pixel-based and object-based approach using multi-temporal landsat data a random forest classifier and decision rules." Remote Sensing. Vol. 13, No. 9, PP. 1700-1724.
- [43] Chen, Y., Lin, Z., Zhao, X., Wang, G. and Gu, Y. (2014). "Deep learning-based classification of hyperspectral data." IEEE Journal of Selected topics in applied earth observations and remote sensing. Vol. 7, No. 6, PP. 2094-2107.
- [44] Zou, Q., Ni, L., Zhang, T. and Wang, Q. (2015). "Deep learning-based feature selection for remote sensing scene classification." IEEE Geoscience and Remote Sensing Letters. Vol. 12, No. 11, PP. 2321-2325.
- [45] Marmanis, D., Datcu, M., Esch, T. and Stilla, U. (2015). "Deep learning earth observation classification using ImageNet pretrained networks." IEEE Geoscience and Remote Sensing Letters. Vol. 13, No. 1, PP. 105-109.
- [46] Zhang, C., Sargent, I., Pan, X., Li, H., Gardiner, A., Hare, J. and Atkinson, P. M. (2018). "An object-based convolutional neural network (OCNN) for urban land use classification." Remote sensing of environment. Vol. 216, PP. 57-70.
- [47] Vetrivel, A., Gerke, M., Kerle, N., Nex, F. and 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. Vol. 140, PP. 45-59.
- [48] Chen, Y., Jiang, H., Li, C., Jia, X. and Ghamisi, P. (2016). "Deep feature extraction and classification of hyperspectral images based on convolutional neural networks." IEEE Transactions on Geoscience and Remote Sensing. Vol. 54, No. 10, PP. 6232-6251.
- [49] Cai, Y., Guan, K., Peng, J., Wang, S., Seifert, C., Wardlow, B. and Li, Z. (2018). "A high-performance and in-season classification system of field-level crop types using time-series Landsat data and a machine learning approach." Remote sensing of environment. Vol. 210, PP. 35-47.
- [50] Li, K., Wu, Y., Nan, Y., Li, P. and Li, Y. (2017). "Hierarchical multi-class classification in multimodal spacecraft data using DNN and weighted support vector machine." Neurocomputing. Vol. 259, PP. 55-65.
- [51] Zhang, C., Sargent, I., Pan, X., Li, H., Gardiner, A., Hare, J. and Atkinson, P. M. (2019). "Joint Deep Learning for land cover and land use classification." Remote sensing of environment. Vol. 221, PP. 173-187.

- [52] Shi, Y., Han, L., Huang, W., Chang, Sh., Dong, Y., Dancey, D. and Han, L. (2021). "A biologically interpretable two-stage deep neural network (BIT-DNN) for vegetation recognition from hyperspectral imagery." *IEEE transactions on geoscience and remote sensing*. Vol. 59, No. 7, PP. 1-20.
- [53] Fundisi, E., Tesfamichael, S. G. and Ahmed, F. (2021). "A bi-seasonal classification of woody plant species using Sentinel-2A and SPOT-6 in a localized species-rich savanna environment." *Geocarto International*. Vol. 36, NO. 4, PP. 1-22.
- [54] Gopal Singh, P., Bordu, N., Singh, D. and Yahia, H. (2021). "Permuted spectral and permuted spectral-spatial CNN models for PolSAR-Multispectral data-based land cover classification." *International Journal of Remote Sensing*. Vol. 42, No. 3, PP. 1096-1120.
- [55] Jafari, F., Moazzeni, M. and Badali, A. (2020). "Futures study of urban land use change in Tabriz metropolis." *Journal of spatial planning*. Vol. 10, No. 2, PP. 1-22 (in Persian).
- [56] Whyte, A., Ferentinis, K. P. and Petropoulos, G. P. (2018). "A new synergistic approach for monitoring wetlands using Sentinels-1 and 2 data with object-based machine learning algorithms." *Environmental modelling & software*. Vol. 104, PP. 40-54.
- [57] Rodriguez-Galiano, V. F., Ghimire, B., Rogan, J., Chica-Olmo, M. and Rigol-Sanchez, J. P. (2012). "An assessment of the effectiveness of a random forest classifier for land-cover classification." *ISPRS Journal of Photogrammetry and Remote Sensing*. Vol. 67, PP. 93-104.
- [58] Schmidhuber, J. (2015). "Deep learning in neural networks: An overview." *Neural networks*. Vol. 61, PP. 85-117.
- [59] Bengio, Y., Courville, A. and Vincent, P. (2013). "Representation learning: A review and new perspectives." *IEEE transactions on pattern analysis and machine intelligence*. Vol. 35, No. 8, PP. 1798-1828.
- [60] Ciregan, D., Meier, U. and Schmidhuber, J. (2012). "Multi-column deep neural networks for image classification." *Proc. 25<sup>th</sup> IEEE conference on computer vision and pattern recognition*. June, Rhode Island, PP. 3642-3649.
- [61] Krizhevsky, A., Sutskever, I. and Hinton, G. E. (2012). "Imagenet classification with deep convolutional neural networks." *Proc. 25<sup>th</sup> Advances in neural information processing systems*. December, Nevada, United States, PP. 1097-1105.
- [62] LeCun, Y., Bengio, Y. and Hinton, G. (2015). "Deep learning." *Nature*. Vol. 521, No. 7553, PP. 436-444.
- [63] Lu, Z., Pu, H., Wang, F., Hu, Z. and Wang, L. (2017). "The expressive power of neural networks: A view from the width." *Proc. 31<sup>st</sup> Advances in neural information processing systems*. December, California, United States, PP. 6231-6239.
- [64] Nikkhoo, N., Ildoromi, A. and Noori, H. (2015). "Development of land use development of the city of Malayer using remote sensing." *Quarterly journal of environmental based territorial planning*. Vol. 8, No. 30, PP. 63-86 (in Persian).
- [65] Gislason, P. O., Benediktsson, J. A., & Sveinsson, J. R. (2006). Random forests for land cover classification. *Pattern recognition letters*, 27(4), 294-300.
- [66] Zhang, M., Lin, H., Wang, G., Sun, H., & Fu, J. (2018). Mapping paddy rice using a convolutional neural network (CNN) with Landsat 8 datasets in the Dongting Lake Area, China. *Remote Sensing*, 10(11), 1840.
- [67] Hayes, M. M., Miller, S. N., & Murphy, M. A. (2014). High-resolution landcover classification using Random Forest. *Remote sensing letters*, 5(2), 112-121.