

شناسایی کاربری اراضی شهری از طریق محتوای کاربر تولید و با بهره‌گیری از روش طبقه‌بندی یادگیری عمیق

علی گلی پور^۱، محمد طالعی^{۲*}، علی اصغر ال شیخ^۳، قاسم جوادی^۲

۱- دانشجوی کارشناسی ارشد سیستم های اطلاعات مکانی، دانشکده مهندسی نقشه برداری، دانشگاه صنعتی خواجه نصیرالدین طوسی

۲- استاد گروه سیستم های اطلاعات مکانی، دانشکده مهندسی نقشه برداری، دانشگاه صنعتی خواجه نصیرالدین طوسی

۳- استادیار گروه مهندسی نقشه برداری، دانشکده فنی و مهندسی، دانشگاه بجنورد، خراسان شمالی، ایران

تاریخ دریافت مقاله: ۱۳۹۹/۱۰/۲۷ تاریخ پذیرش مقاله: ۱۳۹۹/۱۲/۱۱

چکیده

نقشه بروز کاربری زمین، از جمله اطلاعات لازم جهت سیاست‌گذاری و مدیریت شهری است درحالی‌که روش سنتی تولید و به‌روزرسانی اطلاعات مکانی توسط سازمان‌های تولید نقشه، نیازمند صرف زمان و هزینه زیاد است. ایجاد فناوری‌هایی نظیر گوشی‌های هوشمند، تعیین موقعیت آنی و توسعه شبکه‌های اجتماعی، باعث تولید انبوه داده‌های کاربر تولید مکانی شده است. هدف این مطالعه شناسایی کاربری زمین با استفاده از اطلاعات کاربر تولید است. در این پژوهش کاربری‌های شهری در شش طبقه مسکونی، تجاری و خرید، اداری و خدماتی، مختلط، تجمع و تفریحی و دیگر کاربری‌ها در نظر گرفته شده و از اطلاعات شبکه اجتماعی تویتر به‌عنوان محتوای کاربر تولید استفاده شده است. روش مورد استفاده جهت طبقه‌بندی اطلاعات کاربر تولید، طبقه‌بندی با استفاده از یادگیری عمیق و شبکه مورد استفاده، از نوع شبکه بازگشتی است. با توجه به عدم توازن موجود در اطلاعات، جهت رفع آن از الگوریتم ماشین بردار پشتیبان استفاده شد. ارزیابی نتایج نشان‌دهنده این است که با استفاده از روش ارائه شده، کاربری‌های شهری با دقت کلی ۶۴ درصد طبقه‌بندی شده‌اند. در بین طبقات شهری، کاربری مسکونی با دقت ۷۷ درصد بهترین دقت را دارد. همچنین سطح زیر نمودار منحنی مشخصه عملکرد برابر با ۰.۸۸ است که نشان‌دهنده قابلیت اطمینان مناسب طبقه‌بندی است. در مقایسه نتایج حاصل از روش الگوریتم ماشین بردار پشتیبان برای رفع عدم توازن داده با روش بیش نمونه‌برداری تصادفی، مشاهده شد که استفاده از روش ماشین بردار پشتیبان، باعث ایجاد بهبود دقت می‌شود.

کلید واژه‌ها: یادگیری عمیق، کاربری زمین، اطلاعات کاربر تولید، شبکه عصبی بازگشتی، تویتر.

* نویسنده مکاتبه کننده: تهران - خ ولیعصر (عج) - بالاتر از تقاطع میرداماد - دانشکده مهندسی نقشه برداری دانشگاه صنعتی خواجه نصیرالدین طوسی.

تلفن: ۰۲۱۸۸۷۸۶۲۱۲

۱- مقدمه

در روش‌های سنتی، اطلاعات مکانی توسط سازمان‌ها و شرکت‌ها به‌وسیله افراد متخصص و با بهره‌گیری از ابزار و روش‌های دقیق تولید می‌شوند. زمان و هزینه تولید و به‌روزرسانی زیاد یکی از مسائل مهم تولید اطلاعات مکانی به روش سنتی است که باعث می‌شود اطلاعات به‌سرعت کارایی خود را از دست بدهند [۱ و ۲].

نقشه کاربری زمین، از جمله محصولات تولید نقشه به روش سنتی است که نقش مهمی را در مدیریت شهری، سیاست‌گذاری دولت و نظارت بر فعالیت‌های مردم، ایفا می‌کند [۳ و ۴]. امروزه ایجاد فناوری‌هایی نظیر گوشی‌های تلفن همراه، شبکه‌های اجتماعی، تعیین موقعیت آنی خودروها و غیره سبب تولید داده‌های مکانی انبوه و ارزشمندی شده است که می‌تواند منجر به شناخت محیطی مناسب‌تر و اتخاذ تصمیم‌های کارآمدتر در حوزه مدیریت شهری برای حل چالش‌های پیش روی مدیران شود [۵]. در دسترس بودن این نوع از داده‌ها یک فرصت عالی برای کشف روش‌های جدید در شناسایی کاربری زمین را فراهم می‌کند. از مزایای مهم این داده‌ها می‌توان حجم زیاد و پوشش زمانی مناسب اشاره کرد [۶].

هدف از این مطالعه شناسایی کاربری‌های زمین از طریق اطلاعات کاربر تولید^۱ است. کاربری زمین را می‌توان از دو دیدگاه فیزیکی و اجتماعی می‌تواند مورد بررسی قرار داد. در بسیاری از مطالعات سنجش‌ازدور به طبقه‌بندی کاربری زمین با توجه به ویژگی‌های فیزیکی زمین مانند جنس خاک و رنگ زمینه و غیره پرداخته می‌شود [۷]. طبقه‌بندی‌های کاربری از دیدگاه فیزیکی می‌تواند شامل طبقات شهری، جنگل، بایر و غیره باشد [۸]. طبقه‌بندی کاربری از دیدگاه اجتماعی بیشتر به نوع فعالیتی که در مکان مورد نظر صورت می‌گیرد، می‌پردازد. طبقه‌بندی کاربری

از دیدگاه اجتماعی می‌تواند شامل طبقات مسکونی، تجاری، غذا، تفریحی و غیره باشد [۷]. الگوی زمانی مربوط به نوع فعالیت ساکنین در هر کاربری متفاوت است که می‌تواند در شناسایی کاربری زمین مورد استفاده قرار بگیرد. به‌عنوان مثال، در مناطق با کاربری مسکونی، افراد در ساعات‌های ابتدایی روز کاربری را به‌منظور کار ترک می‌کنند و در عصر به کاربری مسکونی بازمی‌گردند. در صورتی که الگوی زمانی فعالیت در کاربری‌های کسب‌وکار برخلاف کاربری مسکونی است [۹].

داده‌های کاربر تولید به‌منظور کشف الگوهای فعالیت مختلف شهری در زمان‌های مختلف مورد استفاده قرار می‌گیرند. از جمله داده‌های کاربر تولید پرکاربرد در کشف الگوهای فعالیت شهری اطلاعات گوشی‌های هوشمند، شبکه‌های اجتماعی و موقعیت خودروها هستند [۱۰]. به‌عنوان مثال از داده‌های خط سیر تاکسی^۲ به‌منظور بررسی الگوی حرکت ساکنین در شهر و طبقه‌بندی کاربری زمین استفاده شده است [۱۱ و ۱۲]. همچنین در مطالعات مختلف از اطلاعات شبکه‌های اجتماعی (توییتر^۳، فیس‌بوک^۴، ویجت^۵ و ویبو^۶) جهت شناسایی ساختار شهری و کشف روابط پیچیده داینامیک^۷ شهر استفاده شده است [۷ و ۱۱ و ۱۳ و ۱۴]. در این مطالعه، با استفاده از داده‌های منتشرشده کاربران شبکه اجتماعی مکان‌مبنا، به شناسایی کاربری زمین در سطح پارسل در محدوده شهری پرداخته می‌شود. ارزیابی نتایج روش پیاده‌سازی شده به کمک نقشه‌های رسمی کاربری زمین انجام می‌گیرد.

در مطالعات مختلف با استفاده از دو بعد اطلاعات معنایی و زمانی داده‌های کاربر تولید به شناسایی کاربری زمین پرداخته شده است. از جمله مطالعاتی که

² Taxi Trajectory

³ Twitter

⁴ Facebook

⁵ Wechat

⁶ Weibo

⁷ Dynamic

¹ User-generated content

عملکرد مناطق با استفاده از تکنیک‌های مدل‌سازی موضوع در شبکه‌های اجتماعی و همبستگی الگوهای انواع نقاط موردعلاقه در مناطق توسعه داده شده است [۷]. رناتو و همکاران در سال ۲۰۲۰ در یک مطالعه به ارزیابی شناسایی کاربری زمین با استفاده از تحلیل نقاط موردعلاقه پرداخته‌اند. آن‌ها شبکه سلولی بر روی منطقه مورد مطالعه خود برآزش دادند. سپس بر مبنای فاصله نقاط موردعلاقه به هر سلول کاربری زمین به سلول اختصاص داده می‌شود. جهت تعیین کاربری بر مبنای فاصله از شبکه عصبی مصنوعی استفاده شده است. در این مطالعه نوع طبقه‌بندی زمین انتخاب شده نیز ارزیابی شده است. به این منظور روش ارائه شده در هفت نوع طبقه‌بندی زمین مختلف اجرا شده‌اند و در نهایت طبقه‌بندی زمین که شامل سه طبقه کشاورزی، شهری و صنعتی به ترتیب با دقت ۹۱،۹۲ و ۸۵ درصد، دارای بیشترین دقت طبقه‌بندی است. از مزایای این مطالعه ارزیابی نوع طبقه‌بندی بر نتایج است. از معایب این مطالعه طبقه‌بندی کلی زمین و استفاده از شبکه سلولی است که تفسیرپذیری کمتر نسبت به نقشه‌های برداری دارد [۱۸].

فرناندو و همکاران در مطالعه خود به ترکیب محتوای کاربری تولید مبتنی و برمکان و مبتنی بر متن جهت شناسایی کاربری زمین پرداختند. در این مطالعه ابتدا با استفاده از خوشه‌بندی اطلاعات مبتنی بر مکان مناطق شهری تفکیک می‌شوند. سپس بر اساس اطلاعات مبتنی بر متن به هر منطقه سه طبقه کاربری زمین با اولویت اختصاص داده می‌شود. جهت طبقه‌بندی از سه روش جنگل تصادفی، ماشین بردار پشتیبان و رگرسیون لجستیک استفاده کردند. روش ارائه شده بر روی اطلاعات دو شهر نیویورک و سانفرانسیسکو ارزیابی شد که نتایج نشان‌دهنده مقدار شاخص F -measure بین ۰.۵۶ تا ۰.۹. برای طبقات مختلف کاربری است. مزایای این مطالعه ارائه چند برجسب مکانی به جای یک برجسب برای هر منطقه است و از معایب مهم روش ارائه شده روش خوشه‌بندی

به تحلیل بعد معنایی داده‌های کاربر تولید پرداخته است می‌توان به مطالعه کریمی پور و همکاران در سال ۲۰۱۸ اشاره نمود. آن‌ها در مطالعه خود به تعیین کاربری اجتماعی در محیط‌های شهری بر مبنای داده‌های شبکه‌های اجتماعی مکان‌مبنا فوراسکوئر پرداخته‌اند. در مرحله اول، با استفاده از خوشه‌بندی داده‌ها و دیگرام ورونوی^۱ منطقه مورد مطالعه را به چندین منطقه مختلف تقسیم شده است. با بررسی کمی اطلاعات معنایی داده‌ها به هر منطقه یک کاربری اجتماعی تخصیص داده شده است [۱۵]. از جمله معایب این مطالعه می‌توان به منطقه‌بندی بزرگ جهت شناسایی کاربری زمین اشاره کرد.

جیانگ و همکاران در سال ۲۰۱۵ از داده‌های نقاط موردعلاقه یاهو و داده‌های جمع‌آوری شده از سرشماری در سطح بلوک برای به دست آوردن کاربری زمین بلوک شهری استفاده نمودند. نتایج نشان‌دهنده این است که روش پیشنهادی آن‌ها مطابقت بهتری در سراسر بلوک شهری نسبت به روش‌های سنتی دارد [۱۶]. در مطالعه دیگر یک روش شناسایی نوع فعالیت مناطق از طریق تراکم نقاط موردعلاقه^۲ و اطلاعات موجود در OSM ^۳ ارائه شده است. مناطق شامل چهار طبقه بانک‌ها، دستگاه‌های خودپرداز، رستوران‌ها، اماکن توریستی و زیرشاخه‌های دیگر که به عنوان مناطق خرید شناسایی شده‌اند [۱۷]. از جمله محدودیت‌های این مطالعه محدود کردن طبقات کاربری به چند زیرشاخه از کاربری‌های خدماتی است.

گائو و همکاران، اطلاعات مربوط به کاربران در شبکه اجتماعی فور اسکوئر^۴ و چک این^۵ کاربران را در ۱۰ منطقه مشهور در ایالت متحده بررسی کرده‌اند. در این مطالعه یک چهارچوب آماری به منظور کشف نوع

^۱ Voronoi

^۲ Point of interest

^۳ Open Street Map

^۴ Foursquare

^۵ Check-in

است که باعث شده فقط مناطق محدودی از منطقه مورد مطالعه را پوشش دهد [۲]. از جمله مطالعاتی که به تحلیل بعد زمانی و استخراج الگو داده‌های کاربر تولید پرداخته است می‌توان به مطالعه انجام شده توسط حسن و همکاران در سال ۲۰۱۳ اشاره کرد. آن‌ها با استفاده از داده‌های شبکه اجتماعی توییتر و با بهره‌گیری از بعد زمانی داده‌ها، به تعیین کاربری شهری پرداخته‌اند. برای این منظور ابتدا یک شبکه سلولی با ابعاد ۲۰۰ متر روی شهر نیویورک تعریف شد و سپس برای شش کاربری مختلف در ساعت‌های مختلف شبانه‌روز با استفاده از تابع چگالی کرنل^۱ شاخص هر کاربری در سطح محیط شهری در زمان‌های مختلف برآورد گردید [۱۹].

فریاس و همکاران در سال ۲۰۱۴ از داده‌های شبکه توییتر برای شناخت محیط‌های شهری استفاده کردند. آن‌ها ابتدا با استفاده از روش‌های خوشه‌بندی، مناطق شهری را از هم تفکیک نموده و در مرحله بعد به هر منطقه یک بردار نسبت دادند که درایه‌های آن تعداد داده‌ها به ازای هر ۲۰ دقیقه در هر منطقه است. نوع روز هفته در دو طبقه روز کاری و روز تعطیل برای رسیدن به دقت بالاتر بررسی شد. به این ترتیب برای تعیین کاربری هر منطقه یک شاخص نموداری تعریف گردید. نتایج مطالعه در شهر لندن نشان دهند این است که روش ارائه شده توانسته است مناطق مسکونی را با دقت ۶۱ درصد و مناطق غیرمسکونی را با دقت ۵۶ درصد شناسایی کند. همچنین فضای سبز در شهر لندن در این روش با دقت ۷۲ درصد شناسایی شده است [۲۰]. در یک مطالعه مشابه به استخراج کاربری مناطق به‌وسیله الگوی تغییرات تعداد چک این شبکه‌های اجتماعی انجام شده است. به‌منظور تهیه نقشه مناطق از نقشه منطقه بندی تحلیل ترافیکی^۲ شهر استفاده شده است. در این مطالعه ابتدا بردار

تغییرات تعداد چک این در هر منطقه با حد تفکیک یک ساعت به‌دست آمده است. به‌منظور شناسایی کاربری‌های مناطق نیز از رابطه محاسبه تشابه کسینوسی^۳ استفاده شده است [۲۱].

اطلاعات تماس تلفن‌های همراه^۴ از جمله داده‌های پرکاربرد به‌منظور تحلیل زمانی در مطالعات مختلف به‌منظور شناسایی مناطق است. جیمسون و همکاران در سال ۲۰۱۲ به مطالعه استخراج کاربری مناطق با استفاده از اطلاعات فعالیت تلفن همراه کاربران پرداختند. آن‌ها از روش جنگل تصادفی^۵ برای شناسایی کاربری مناطق با استفاده از الگوی مکانی-زمانی فعالیت تلفن همراه کاربران استفاده کردند نقشه خروجی شامل ۵ نوع کاربری مسکونی، تجاری، صنعتی، پارک و دیگر کاربری‌ها است. ارزیابی انجام شده نشان‌دهنده این است که کاربری‌های مسکونی با دقت ۶۲ درصد و کاربری‌های پارک و دیگر کاربری‌ها به ترتیب با دقت ۲۰ و ۱۰ درصد شناسایی شده‌اند [۲۲].

برخی از مطالعات نیز به ترکیب نتایج حاصل از تحلیل بعد معنایی و زمانی داده‌های کاربر تولید پرداخته‌اند. جلیلی و همکاران در سال ۲۰۱۸ یک روش شناسایی کاربری مناطق شهری با استفاده از خط سیر و مشخصات عابران ارائه دادند. در این مطالعه ابتدا نقاط توقف خطوط سیر عابران پیاده توسط تحلیل زمانی استخراج شده و بر اساس اطلاعات معنایی مانند سن، شغل و جنسیت کاربر نوع عملکرد مناطق مختلف بررسی شده است. برای طبقه‌بندی انواع کاربری زمین شهری از طبقه‌بندی *OSM* استفاده کردند [۲۳]. در مطالعه انجام شده توسط ژیا یک روش شناسایی کاربری زمین با استفاده از ترکیب اطلاعات موقعیت تلفن همراه و تصاویر ماهواره‌ای ارائه شده است. در روش ارائه شده ابتدا اطلاعات تلفن همراه و تصاویر ماهواره‌ای با

⁴ Cosine Similarity

⁵ Call Detail Record

⁶ Random Forest

¹ Kernel Density

² Traffic Analysis Zone

روش طبقه‌بندی یادگیری عمیق^۲ استفاده می‌شود. جهت رفع عدم توازن داده‌ها^۳ در طبقه‌بندی از الگوریتم ماشین بردار پشتیبان کمک گرفته شده است. کاربری مختلط به‌عنوان یک کاربری مستقل در طبقه‌بندی کاربری شهری در نظر گرفته شده است.

در بخش دوم این مقاله به معرفی مواد و روش تحقیق پرداخته می‌شود. در بخش سوم نتایج روش پیاده‌سازی شده با استفاده از نقشه‌های رسمی کاربری زمین ارزیابی می‌شود. در نهایت، در بخش چهارم بحث و نتیجه‌گیری حاصل از تحقیق و همچنین پیشنهادهایی برای تحقیقات آینده ارائه خواهد شد.

۲- مواد و روش تحقیق

در این بخش ابتدا به مبانی نظری مورد نیاز جهت انجام مطالعه بررسی خواهد شد. در قسمت دوم منطقه مطالعه و اطلاعات مورد استفاده معرفی خواهند شد. و در انتها به روش تحقیق جهت پیاده‌سازی پرداخته می‌شود.

۲-۱- مبانی نظری

روش‌های طبقه‌بندی با استفاده از یادگیری ماشین^۴ را می‌توان به شش دسته کلی روش‌های مبتنی بر درخت تصمیم‌گیری^۵، روش‌های مبتنی بر نظریه بی‌زغ، شبکه‌های عصبی، ماشین بردار پشتیبان، روش‌های مبتنی بر قانون^۶ و روش‌های مبتنی بر حافظه تقسیم می‌شوند [۲۵].

۲-۱-۱- شبکه عصبی بازگشتی

یادگیری عمیق یکی از زیرشاخه‌های یادگیری ماشین مبتنی بر شبکه‌های عصبی است. در یادگیری عمیق به‌منظور کشف ساختارهای پیچیده از چندین لایه یادگیری استفاده می‌شود [۲۶]. یکی از نمونه‌های اصلی

استفاده از ماشین بردار پشتیبان^۱ طبقه‌بندی شده و سپس نتایج با یکدیگر تلفیق می‌شوند. نتایج نشان می‌دهد که روش پیشنهادی برای شناسایی کاربری زمین از دقت کلی ۷۸ درصد برخوردار است [۲۴]. روش پیشنهادی این مطالعه نیازمند به تصاویر ماهواره‌ای با دقت بالا است. همچنین در این مطالعه کاربری‌های مختلط نادیده گرفته شده است.

لیو و همکاران یک مدل احتمالی برای ترکیب چند منبع و داده‌های حجیم مکانی جهت شناسایی کاربری زمین در محدوده شهری ارائه کرده‌اند. آن‌ها از چهار منبع داده شبکه اجتماعی، خط سیر تاکسی‌ها، نقاط مورد علاقه و تصاویر سنجش از دور استفاده نمودند. در این روش کاربری یک ساختمان با توجه به احتمال نوع سفر مقصد تاکسی برآورد می‌شود. زمان اوج استفاده از هر کاربری در شبکه‌های اجتماعی شناسایی شده و به‌منظور شناسایی کاربری استفاده می‌شود [۱۱].

بررسی مطالعات انجام شده نشان‌دهنده این است که اکثر مطالعات به شناسایی کاربری در سطح مناطق شهری پرداخته‌اند. با توجه به اینکه پارسل‌ها درون مناطق دارای کاربری یکسان نیستند، بنابراین کاربری غالب به‌عنوان کاربری منطقه در نظر گرفته شده است. طبقه‌بندی کاربری شهری در مطالعات انجام شده محدود به چندین طبقه‌بندی کلی است. همچنین ساختمان‌هایی که دارای کاربری مختلط می‌باشند در طبقه‌بندی ارائه شده توسط اکثر مطالعات نادیده گرفته شده است.

در این مطالعه به شناسایی کاربری زمین در سطح پارسل در محدوده شهری پرداخته می‌شود. تجزیه و تحلیل در سطح پارسل کارآمدتر، نزدیک به واقعیت و ذخیره‌سازی در پایگاه داده نسبت به شبکه‌بندی راحت‌تر است. طبقه‌بندی کاربری زمین با سطح جزئیات بیشتر نسبت به مطالعات انجام شده انتخاب شده است. به‌منظور بهبود دقت طبقه‌بندی از

⁷ Support Vector machine

¹ Deep learning

² Imbalance Data

³ Machine Learning

⁴ Decision Tree

⁵ Bayes' theorem

⁶ Rule Decision

حرکت روبه جلو و رو به عقب در طول زمان را به شبکه عصبی می‌دهد [۳۱].

از حافظه طولانی کوتاه‌مدت در مواردی همچون طبقه‌بندی و پیش‌بینی‌های مربوط به دنباله‌های زمانی که نیاز به کشف ارتباط دارند، استفاده می‌شود. بزرگ‌ترین مزیت حافظه طولانی کوتاه‌مدت، قابلیت بازگشت رو به عقب در زمان بدون نیاز به تکرار پردازش‌های گذشته است. این معماری از شبکه‌های عصبی دارای سربار کمتری بوده و بهترین روش برای استفاده در شبکه‌های عصبی بازگشتی عمیق هستند. برای جلوگیری از سربار حافظه موردنیاز برای ذخیره‌سازی اطلاعات حالت‌های قبلی شبکه، این حافظه‌ها به صورت کوتاه‌مدت هستند. همچنین این شبکه اطلاعاتی را که در آینده کاربرد کمتری دارند به دلخواه حذف می‌کند. شکل (۲) ساختار هر گره در این معماری را نشان می‌دهد. در معماری حافظه طولانی کوتاه‌مدت هر گره از شبکه از سه دروازه ورودی^۶، خروجی^۷ و فراموشی^۸ با دو حالت صفر یا یک به صورت دودویی تشکیل شده است. این سه دروازه به ترتیب مقادیر داده‌های ورودی از حالت قبلی شبکه، داده‌های ارسالی و ذخیره‌شده برای حالت بعدی شبکه و اطلاعات قابل حذف را کنترل می‌کنند. با توجه به توانایی معماری حافظه طولانی کوتاه‌مدت در پردازش داده‌های زمانی، در این تحقیق از این نوع معماری شبکه جهت طبقه‌بندی اطلاعات زمانی داده‌های کاربر تولید استفاده می‌شود.

و پر کاربرد روش‌های یادگیری عمیق، شبکه‌های عصبی بازگشتی^۱ هستند. شبکه‌های عصبی بازگشتی توانایی بالایی در پردازش داده‌های دارای توالی^۲ دارند. داده‌ها به صورت توالی (گام به گام) توسط شبکه طی شده و در هر مرحله حالت شبکه در مراحل قبلی در حافظه نورون وجود دارد. به این ترتیب این نوع شبکه‌ها می‌توانند با بهره‌گیری از ساختار پویا، به طور کامل ساختار داده‌ها را طی کنند [۲۷].

این نوع شبکه عصبی در پردازش اطلاعات سری‌های زمانی^۳، زبان گفتار^۴، متن و غیره مورد استفاده قرار گرفته است [۲۹، ۳۰ و ۳۱]. شکل (۱) نمای شماتیک بسته و باز یک شبکه عصبی بازگشتی بدون لایه خروجی را نشان می‌دهد. با توجه به رابطه (۱) در هر مرحله، حالت فعلی برگرفته از مجموعه حالت‌های قبلی است. در این مطالعه از الگوی زمانی فعالیت کاربران در کاربری‌های شهری جهت شناسایی کاربری زمین استفاده می‌شود، با توجه به ماهیت زمانی بودن اطلاعات به نظر می‌رسد استفاده از شبکه عصبی بازگشتی جهت طبقه‌بندی اطلاعات مناسب است.

$$h^{(t)} = f(h^{(t-1)}, x^{(t)}; \theta) \quad \text{رابطه (۱)}$$

۲-۱-۲- حافظه طولانی کوتاه‌مدت

یکی از معماری‌های اصلی برای پیاده‌سازی شبکه‌های عصبی بازگشتی، استفاده از حافظه طولانی کوتاه‌مدت^۵ است. در این نوع معماری، اطلاعات به مدت زمان دلخواهی توسط حافظه هر گره از شبکه عصبی ذخیره شده و در نهایت از حافظه پاک می‌شوند. در هر مرحله، اطلاعات موجود در گره اصلی به روز شده ولی پس از ثبت اطلاعات، دیگر محاسبه یا تغییری در اطلاعات صورت نمی‌گیرد. این نوع معماری اجازه

¹ Recurrent Neural Network

² Sequence data

³ Time Series


⁴ Natural Language

⁵ Long short-term memory


⁶ Input Gate

⁷ Output Gate

⁸ Forget Gate



شکل ۱: نمای بسته و باز یک شبکه عصبی بازگشتی [۲۷]



شکل ۲: معماری یک بلوک از حافظه طولانی کوتاه مدت [۳۱]

۲-۱-۳- داده‌های نامتوازن

به مجموعه داده‌ای که تعداد نمونه‌های متعلق به کلاس‌ها در آن با یکدیگر برابر نیست مجموعه داده نامتوازن گفته می‌شود. روش‌های طبقه‌بندی در مواجهه با مجموعه داده‌های نامتوازن نتایج مناسبی را ارائه نمی‌دهند؛ چراکه روش‌های طبقه‌بندی به سمت طبقه با تعداد نمونه بیشتر تمایل پیدا می‌کنند و باعث کاهش دقت طبقه‌بندی می‌شوند. در مطالعات مختلف طبقه‌بندی داده‌های نامتوازن از یکی از روش‌های سطح داده، سطح الگوریتم یا ترکیبی از دو سطح داده و الگوریتم استفاده می‌کنند. در روش اصلاح داده‌ها با

استفاده از تولید داده‌های جدید در کلاس‌های اقلیت و حذف داده‌ها از کلاس‌های بزرگ توازن بین کلاس‌ها را برقرار می‌کنند. در روش‌های سطح الگوریتم با تغییر پارامترهای الگوریتم و ترکیب الگوریتم‌ها با یکدیگر باعث بالا بردن طبقه‌بندی کلاس‌های اقلیت می‌شود. همچنین می‌توان از هر دو روش سطح داده و سطح الگوریتم هم‌زمان جهت بهبود دقت استفاده کرد [۳۲].


۲-۲- منطقه مورد مطالعه و داده‌های مورد استفاده

منطقه مورد مطالعه شهر بوستون در ایالت ماساچوست واقع در شمال شرق کشور ایالت متحده آمریکا است.


اخذ شده است. این اطلاعات شامل ۳۰۰ هزار توییت دارای برچسب مختصات مکانی مربوط به ۳۲ هزار کاربر در سال ۲۰۱۹ هستند. نحوه پراکندگی اطلاعات توییت در منطقه مورد مطالعه در شکل (۳) نمایش داده شده است. چند نمونه از اطلاعات دریافتی توییت در جدول (۱) نمایش داده شده است.

به منظور برچسب گذاری اطلاعات توییت، جهت آموزش مدل و همچنین ارزیابی روش پیاده سازی شده نیاز به نقشه کاربری زمین هست. به این منظور از نقشه کاربری زمین سال ۲۰۱۸ شهر بوستون استفاده شده است. نقشه کاربری زمین شامل اطلاعات مربوط به ۱۶۶ هزار پارسل در ۲۴۵ طبقه مختلف کاربری زمین است. نقشه کاربری زمین یکی از مناطق شهر بوستون در شکل (۴) نمایش داده شده است.

جمعیت شهر بوستون در سال ۲۰۱۹ تقریباً ۷۰۰ هزار نفر است و مساحت آن در حدود ۱۲۷ کیلومترمربع است. داده های مورد نیاز تحقیق دو مجموعه داده اطلاعات کاربر تولید و نقشه کاربری زمین منطقه مورد مطالعه هستند. به منظور کشف الگوی فعالیت ساکنین در کاربری های مختلف از داده های شبکه اجتماعی توییت استفاده شده است. شبکه اجتماعی توییت که در سال ۲۰۰۶ فعالیت خود را آغاز کرده است، در سال ۲۰۱۹ نزدیک به ۳۳۰ میلیون کاربر فعال ماهانه را دارد. تقریباً نیمی از کاربران روزانه حداقل یک فعالیت ثبت شده در توییت دارند؛ که به طور میانگین در هر روز ۵۰۰ میلیون توییت از طریق این شبکه اجتماعی تولید می شود. اطلاعات توییت با استفاده از API (<https://developer.twitter.com>) توییت



شکل ۳: پراکندگی اطلاعات توییت در منطقه مورد مطالعه



شکل ۴: بخشی از نقشه کاربری زمین شهر بوستون

جدول ۱: چند نمونه از اطلاعات توییت استفاده شده

شناسه توییت	تاریخ	مختصات
۱۲۱۴۵۱۱۶۶۶۷۷۳۲۷۰۵۳۳	۲۰۱۹-۰۱-۰۷ ۱۱:۳۸:۴۰	۷۱.۰۴۴۶۶۷, ۴۲.۳۴۳۵۴۵
۱۲۱۴۵۰۹۷۲۹۸۸۵۶۷۱۴۲۹	۲۰۱۹-۰۱-۰۷ ۱۱:۳۰:۵۸	۷۱.۰۵۶۵, ۴۲.۳۵۷۷
۱۲۱۴۵۰۶۱۸۲۰۶۶۴۸۳۲۰۰	۲۰۱۹-۰۱-۰۷ ۱۱:۱۶:۵۲	۷۱.۰۸۹۴۳۰, ۴۲.۴۲۲۶۳۲
۱۲۱۴۵۰۵۹۸۳۹۶۵۳۵۶۰۳۲	۲۰۱۹-۰۱-۰۷ ۱۱:۱۶:۰۵	۷۱.۰۶۳۱۵۷, ۴۲.۳۸۱۶۵۶
۱۲۱۴۵۰۳۶۹۷۹۸۹۹۳۵۱۰۵	۲۰۱۹-۰۱-۰۷ ۱۱:۰۷:۰۰	۷۱.۰۶۵۴۲, ۴۲.۳۷۶۶
۱۲۱۴۵۰۰۵۳۳۹۲۴۴۴۶۲۰۹	۲۰۱۹-۰۱-۰۷ ۱۰:۵۴:۲۶	۷۱.۱۰۵۷۵۹, ۴۲.۳۳۷۴۳۱

داده‌ها و نتایج طبقه‌بندی داده‌های آزمایش مورد ارزیابی قرار می‌گیرند.

۲-۳-۱- طبقه‌بندی کاربری زمین

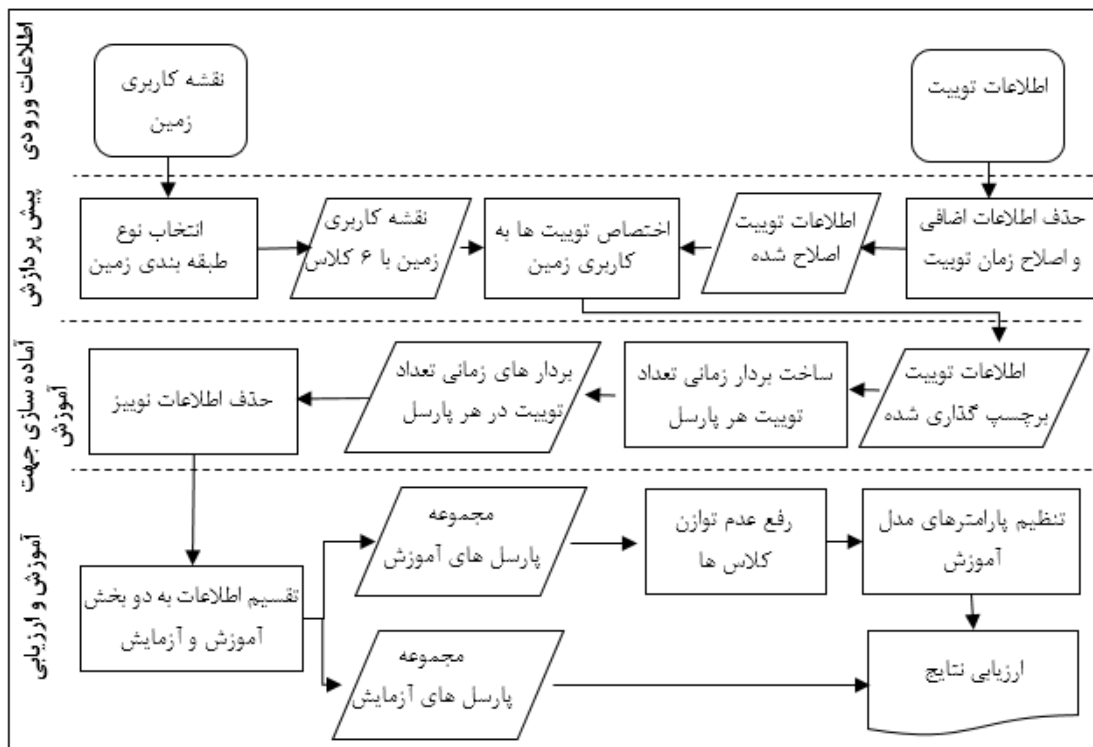
طبقه‌بندی کاربری زمین موردنظر بر مبنای استاندارد طبقه‌بندی زمین ایالت متحده انتخاب شده است. با توجه به این که هدف این تحقیق شناسایی کاربری اجتماعی زمین است، بنابراین طبقه‌بندی بر مبنای نوع فعالیت هر کاربری انتخاب شده است. طبق این استاندارد طبقه‌بندی کاربری زمین برحسب نوع فعالیت

۲-۳-۲- روش تحقیق

به‌منظور پیاده‌سازی روش پیشنهادی مطابق با روندنمای شکل (۵)، ابتدا نوع طبقه‌بندی کاربری زمین موردنظر انتخاب می‌شود و اطلاعات دریافتی از توییت‌ر آماده‌سازی می‌شوند. در مرحله بعد با تلفیق اطلاعات توییت و کاربری زمین بردار زمانی برچسب‌گذاری شده پارسل‌ها تولید می‌شوند. پس از رفع عدم توازن داده‌ها، پارامترهای مدل انتخاب شده و آموزش مدل انجام می‌شود. درنهایت روش استفاده‌شده در متوازن‌سازی

دارای چندین کاربری مختلف هستند یک طبقه به‌عنوان کاربری مختلط در نظر گرفته شده است. بنابراین طبقه‌بندی انتخاب شده برای شناسایی کاربری زمین در این تحقیق شامل ۶ طبقه مسکونی، تجاری و خرید، اداری و خدماتی، اوقات فراغت و ورزشی، مختلط و دیگر کاربری‌ها است. طبقات کاربری و زیر طبقات در جدول (۲) نمایش داده شده است.

شامل ۸ طبقه مسکونی، تجاری و خرید، خدماتی و صنعتی، سفر، تجمع، اوقات فراغت، منابع طبیعی و زمین‌های بدون استفاده است [۳۳]. در این مطالعه کاربری‌های سفر، منابع طبیعی و زمین‌های بدون استفاده در یک طبقه به‌عنوان دیگر کاربری‌ها و همچنین کاربری‌های تجمع ورزشی و اوقات فراغت در یک طبقه کاربری قرار گرفته‌اند. برای زمین‌هایی که



شکل ۵: روند نمای مدل پیشنهادی

جدول ۲: مشخصات طبقات کاربری انتخاب شده

نوع کاربری	زیر طبقات	نوع کاربری	زیر طبقات	نوع کاربری	زیر طبقات
مسکونی	- آپارتمان - مجتمع مسکونی - هتل - خوابگاه	اداری و خدماتی	- بانک - اداری - تعمیرات - صنعتی - آموزشی - کتابخانه	مختلط	- مسکونی- تجاری - مسکونی- اداری - تجاری- اداری
	- فروشگاه - مرکز خرید - سوپرمارکت - رستوران - فست فود		تجاری و خرید		
تجاری و خرید	- فروشگاه - مرکز خرید - سوپرمارکت - رستوران - فست فود	مختلط	- مسکونی- تجاری - مسکونی- اداری - تجاری- اداری	مختلط	- مسکونی- تجاری - مسکونی- اداری - تجاری- اداری
	- مسکونی- تجاری - مسکونی- اداری - تجاری- اداری		تجاری و خرید		

۲-۳-۲- تلفیق اطلاعات و برچسب‌گذاری

به منظور ساخت بردارهای زمانی به عنوان ورودی روش طبقه‌بندی، ابتدا اطلاعات توییت پس از پیش‌پردازش اولیه با اطلاعات کاربری زمین تلفیق شده و بردارهای زمانی هر پارسل ایجاد می‌شود که پس از حذف اطلاعات نویز می‌تواند به عنوان داده ورودی روش طبقه‌بندی استفاده شود. یکی از فرض‌های تحقیق این است که اطلاعات توییت مربوط به یکی از پارسل‌ها است. وجود اطلاعات توییت در معابر ناشی از دقت پایین سیستم تعیین موقعیت تلفن همراه است؛ بنابراین به منظور برچسب‌گذاری اطلاعات توییت، نوع کاربری زمین نزدیک‌ترین پارسل به موقعیت ثبت توییت به عنوان برچسب کاربری توییت ثبت می‌شود.

۲-۳-۳- ساخت بردار زمانی فعالیت قطعه زمین (پارسل‌ها)

پس از برچسب‌گذاری نوع کاربری پارسل ارسال هر توییت، بردار زمانی فعالیت در هر پارسل ساخته می‌شود. با توجه به تاریخ ارسال هر توییت، نوع روز هفته (کاری، تعطیل) هر توییت مشخص می‌شود. بردار زمانی فعالیت هر پارسل شامل ۲۴ درایه است. هر درایه نشان‌دهنده تعداد توییت ایجاد شده در بازه‌های زمانی دو ساعت در هر پارسل است. به این صورت که ۱۲ درایه اول مربوط به توییت‌های ایجاد شده در روزهای کاری هفته و ۱۲ درایه دوم مربوط به روزهای تعطیل است؛ بنابراین هر بردار مطابق رابطه (۲) تشکیل می‌شود که در آن id : شناسه پارسل، t : نوع کاربری پارسل، x : تعداد توییت در هر بازه زمانی می‌باشند.

$$\langle id, t \rangle = \langle x_1, x_2, \dots, x_{23}, x_{24} \rangle$$

۲-۳-۴- حذف اطلاعات نویز

شهر بوستون دارای ۱۶۶ هزار پارسل است؛ که از این تعداد در ۸۶۰۰ پارسل حداقل یک توییت وجود دارد. با توجه به اینکه وجود یک توییت نمی‌تواند نشان‌دهنده الگوی زمانی تعداد توییت در هر کاربری باشد و

همچنین امکان دارد با توجه به دقت تقریبی تعیین موقعیت تلفن همراه این اطلاعات نویز^۱ باشد؛ بنابراین به منظور انتخاب اطلاعات قابل اعتماد، از پارسل‌هایی استفاده می‌شود که نمایانگر الگوی زمانی فعالیت در آن کاربری باشند. نحوه حذف اطلاعات نویز به دو صورت می‌تواند انجام بگیرد. در روش اول تعداد توییت در هر پارسل به عنوان معیار انتخاب می‌شود و از کاربری‌هایی که تعداد توییت در آن‌ها از یک آستانه بیشتر باشد استفاده می‌شود. مقدار بهینه آستانه می‌تواند توسط اجرای الگوریتم‌ها و بررسی دقت نهایی انتخاب شود. در روش دوم مقدار پراکندگی توییت‌ها در ساعات مختلف در هر پارسل می‌تواند به عنوان معیار قرار بگیرد. به این صورت که هر پارسل باید دارای توییت در ساعات مختلف باشد تا الگوی زمانی تعداد توییت قابل استخراج باشد.

نحوه شناسایی اطلاعات نویز در این تحقیق ترکیبی از دو روش حداقل تعداد و توزیع انتخاب شده است. حد آستانه شناسایی اطلاعات نویز باید به گونه‌ای انتخاب شود که هم اطلاعات باقیمانده نشان‌دهنده الگوی مناسب در هر کاربری باشد و هم اینکه تعداد پارسل مناسب جهت آموزش و ارزیابی مدل باقی‌مانده باشد. حد آستانه جهت حداقل تعداد توییت و حداقل بازه زمانی با استفاده از در نظر گرفتن مقادیر مختلف و ارزیابی پارسل‌های باقی‌مانده انتخاب شده است. انتخاب این مقادیر با توجه به تعداد اطلاعات منبع داده مورد استفاده و بازه زمانی محاسباتی می‌تواند متفاوت باشد. در این مطالعه پارسل‌هایی که کمتر از ۲۴ توییت و همچنین در کمتر از ۱۲ بازه زمانی دارای توییت باشند به عنوان نویز شناسایی شده و حذف می‌شوند. اطلاعات تعداد پارسل‌های باقیمانده هر طبقه کاربری زمین، پس از حذف پارسل‌های نویز و همچنین میانگین تعداد توییت در هر طبقه در جدول (۳) نشان داده شده است.

¹ Noise

جدول ۳: تعداد پارسل در هر طبقه و توزیع توییت در طبقات کاربری زمین

نوع کاربری	تعداد پارسل	تعداد توییت	میانگین توییت در پارسل
اداری و خدماتی	۲۵۶	۱۸۶۴۹۰	۷۲۸
مختلط	۶۹	۷۶۷۶	۱۱۱
دیگر کاربری‌ها	۱۳۹	۳۲۲۶۳	۲۳۲
مسکونی	۱۴۸	۱۹۲۴۰	۱۳۰
تفریحی و ورزشی	۴۸	۸۶۸۰	۱۸۱
خرید	۱۱۳	۱۲۱۲۴	۱۰۷

برچسب‌گذاری می‌شوند. در انتها از داده‌هایی که با دقت بهتری برچسب‌گذاری شده‌اند جهت متوازن کردن داده‌های آموزش استفاده می‌شود.

۲-۳-۶- تنظیم پارامترهای مدل

جهت طبقه بندی با توجه به ویژگی های شبکه عصبی بازگشتی و ماهیت زمانی اطلاعات استفاده شده از این نوع شبکه و گره حافظه طولانی کوتاه مدت استفاده شد. به منظور پیاده سازی از زبان برنامه نویسی پایتون^۴ و کتابخانه یادگیری عمیق تنسورفلو^۵ بر روی محیط برنامه نویسی گوگل کولب^۶ استفاده شده است. به منظور آموزش شبکه از پردازنده‌های گرافیکی گوگل استفاده شده است.

به منظور ارزیابی ۸۵ درصد پارسل‌ها به عنوان داده آموزش^۷ و ۱۵ درصد پارسل‌ها به عنوان داده آزمایش^۸ استفاده شده‌اند. از ده درصد مجموعه داده‌های آموزش جهت ارزیابی^۹ آموزش مدل در حین یادگیری استفاده شده است. اندازه لایه‌ها و پارامترهای شبکه از طریق تغییر پارامترها و بررسی نتایج با ۳ بار تکرار الگوریتم در هر بار اجرا تنظیم شده‌اند.

۲-۳-۵- رفع عدم توازن داده‌ها

همان‌طور که در جدول (۳) نمایش داده شده است، تعداد پارسل در طبقات مختلف کاربری با یکدیگر متفاوت هستند و باعث عدم توازن در داده‌ها شده است. برای حل مسأله داده‌های نامتوازن در این مطالعه از روش تغییر در سطح داده استفاده شده است. به این صورت که برای طبقه‌هایی که دارای تعداد نمونه کمتر هستند تعدادی نمونه از داده‌های موجود ایجاد شده تا مجموعه داده‌ها متوازن باشند.

در مطالعات مختلف جهت انتخاب داده‌ها از داده‌های موجود جهت نمونه‌برداری مجدد^۱ از روش‌های مختلفی مانند انتخاب تصادفی^۲، تولید داده مصنوعی^۳ و غیره استفاده می‌شود. در این مطالعه جهت بهبود دقت در طبقه بندی کلاس‌های اقلیت از داده‌هایی که با دقت بهتری نمایانگر کلاس هستند جهت بازنمونه‌برداری در مجموعه داده آموزش استفاده می‌شود. جهت انتخاب این داده‌ها از الگوریتم ماشین بردار پشتیبان استفاده می‌شود. ابتدا الگوریتم توسط داده‌های آموزش غیر متوازن آموزش داده می‌شود و پارامترهای الگوریتم تنظیم می‌شوند. در مرحله بعد داده‌های آموزش به عنوان داده‌های آزمایش توسط الگوریتم

⁴ Python

⁵ TensorFlow

⁶ Google Colab

⁷ Train data

⁸ Test Data

⁹ Validation Data

¹ Resampling

² Random Sampling

³ Synthetic Minority Oversampling TEchnique

همان‌طور که در شکل (۶) نمایش داده شده است هر سه شاخص ارزیابی دقت، حساسیت و F -measure در روش رفع عدم توازن داده‌ها با استفاده از نمونه‌برداری به کمک الگوریتم ماشین بردار پشتیبان بهتر از نمونه‌برداری تصادفی و هر دو روش متوازن‌سازی بهتر از طبقه‌بندی بدون متوازن‌سازی داده‌ها است. در روش طبقه‌بندی بدون متوازن‌سازی، مقدار حساسیت بیشتر از دو شاخص دقت و F -measure است که نشان‌دهنده این موضوع است که در یک طبقه که تعداد نمونه‌های بیشتری دارد مقادیر پیش‌بینی درست بیشتر از سایر طبقات هست.

جهت مقایسه بهتر بین روش‌های رفع عدم توازن انجام‌شده در این مطالعه از نمودار جعبه‌ای^۴ مقدار شاخص F -measure در شناسایی هرکدام از طبقات کاربری زمین استفاده شده است. همان‌طور که در شکل (۷) نمایش داده شده است، در صورت استفاده از داده‌ها جهت آموزش مدل بدون رفع عدم توازن در داده‌ها در بعضی از طبقات کاربری که دارای تعداد نمونه اقلیت هستند هیچ شناسایی درستی انجام نگرفته است و کمترین مقدار F -measure برابر با صفر است. با مقایسه دو روش نمونه‌برداری تصادفی و استفاده از الگوریتم ماشین بردار پشتیبان نیز مشاهده می‌شود کمترین دقت طبقه‌بندی کلاس‌ها در روش ماشین بردار پشتیبان بیشتر است به این معنا که کلاس‌های اقلیت با دقت بهتری شناسایی شده‌اند.

۳- نتایج پیاده‌سازی و ارزیابی

در این بخش به ارزیابی روش استفاده‌شده در بازنمونه‌برداری داده‌ها جهت رفع عدم توازن داده‌ها و همچنین به ارزیابی نتایج حاصل از طبقه‌بندی کاربری زمین با استفاده از شبکه عصبی بازگشتی پرداخته می‌شود.

۳-۱- روش رفع عدم توازن

به‌منظور ارزیابی طبقه‌بندی حاصل از سه روش بدون بازنمونه‌برداری، بیش نمونه‌برداری^۱ و روش نمونه‌برداری با استفاده از الگوریتم ماشین بردار پشتیبان از سه شاخص دقت^۲، حساسیت^۳ و F -measure نتایج استفاده می‌شود.

به‌منظور محاسبه شاخص‌های ارزیابی از رابطه (۳) تا (۵) استفاده شده است. در این روابط TP در هر کاربری تعداد پارسل‌هایی هستند که توسط مدل به‌درستی شناسایی شده‌اند. تعداد پارسل‌هایی که به‌عنوان کاربری مدنظر به اشتباه پیش‌بینی شده FP نام‌گذاری شده‌اند. تعداد پارسل‌هایی که به‌درستی عضو کاربری مدنظر تشخیص داده نشده‌اند TN و تعداد پارسل‌هایی که در واقعیت عضو کاربری مدنظر هستند ولی در مدل شناسایی نشده‌اند FN منظور شده است. به‌منظور محاسبه شاخص نهایی کل داده‌های آزمایش، از روش میانگین‌گیری وزن‌دار شاخص هرکدام از طبقات کاربری استفاده شده است.

$$\text{رابطه (۳)} \quad \text{Precision} = \frac{TP}{TP+FP}$$

$$\text{رابطه (۴)} \quad \text{Recall} = \frac{TP}{TP+FN}$$


$$\text{رابطه (۵)} \quad F\text{-measure} = \frac{2 \cdot \text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}}$$

¹ Oversampling


² Precision

³ Recall

⁴ Box plot



شکل ۶: ارزیابی سه روش نمونه برداری جهت رفع عدم توازن داده‌ها



شکل ۷: نمودار جعبه‌ای ارزیابی روش‌های عدم رفع توازن داده‌ها

نمایش داده شده است. بیشترین دقت طبقه‌بندی مربوط به کاربری مسکونی است که می‌تواند نشان‌دهنده همگون بودن الگوی زمانی کاربری‌های موجود در این طبقه باشد. همچنین کاربری‌هایی که در طبقه دیگر کاربری‌های شهری قرار گرفته‌اند با کمترین دقت نسبت به بقیه طبقات شناسایی شده‌اند. کاربری‌هایی مانند حمل‌ونقل، انبار، زمین بدون استفاده و غیره در این طبقه قرار گرفته‌اند. کاربری‌های مختلط نیز در این روش با دقت مناسب ۵۰ درصد شناسایی شده‌اند.

۲-۳- شناسایی کاربری زمین

به منظور ارزیابی روش ارائه شده جهت شناسایی کاربری زمین در این مطالعه از ماتریس ابهام نرمال شده حاصل از طبقه‌بندی داده‌های آزمایش و منحنی مشخصه عملکرد استفاده شده است. در شکل (۸) ماتریس ابهام نرمال^۱ شده و در جدول (۴) نتایج طبقه‌بندی داده‌های آزمایش با استفاده از شبکه عصبی بازگشتی

² Normalized Confusion Matrix

جدول ۴: ارزیابی شناسایی کاربری مجموعه پارس‌های آزمایش


	دقت	حساسیت	FI-score	Support
اداری	۰٫۷۷	۰٫۵۷	۰٫۶۶	۴۲
مختلط	۰٫۳۶	۰٫۵۰	۰٫۴۲	۸
سایر	۰٫۷۷	۰٫۴۵	۰٫۵۷	۲۲
مسکونی	۰٫۵۲	۰٫۸۰	۰٫۶۳	۱۸
اوقات فراغت	۰٫۶۳	۰٫۶۳	۰٫۶۳	۸
خرید	۰٫۳۸	۰٫۵۹	۰٫۴۷	۱۷
متوسط وزن دار	۰٫۶۴	۰٫۵۸	۰٫۵۹	۱۱۵

کاربری شناسایی شده						
اداری	مختلط	سایر	مسکونی	تفریحی و ورزشی	تجاری و خرید	
اداری	۰٫۵۷	۰	۰٫۱۷	۰٫۰۲	۰٫۱۹	اداری
مختلط	۰٫۱۵	۰	۰٫۱۲	۰	۰٫۲۵	مختلط
سایر	۰٫۱۸	۰٫۴۵	۰٫۰۹	۰٫۰۹	۰٫۱۴	سایر
مسکونی	۰٫۰۷	۰	۰٫۸	۰	۰٫۱۳	مسکونی
تفریحی و ورزشی	۰	۰	۰	۰٫۶۲	۰٫۱۲	تفریحی و ورزشی
تجاری و خرید	۰٫۰۶	۰٫۱۸	۰٫۰۶	۰	۰٫۵۹	تجاری و خرید

شکل ۸: ماتریس ابهام نرمال شده حاصل از طبقه‌بندی داده‌های آزمایش

نشان‌دهنده قابلیت اطمینان روش طبقه‌بندی مورد استفاده است. شکل (۹) نشان‌دهنده میانگین وزن دار منحنی مشخصه عملکرد طبقه‌بندی داده‌های آزمایش هست. همان‌طور که دیده می‌شود میزان انحراف نمودار نسبت به نمودار طبقه‌بندی تصادفی مناسب است که نشان‌دهنده طبقه‌بندی مناسب داده‌های آزمایش و دقت شناسایی کاربری زمین بر مبنای بردارهای زمانی توییت است. مقدار مساحت زیر نمودار برابر با ۰٫۸۸ است که بیانگر قابلیت اطمینان روش طبقه‌بندی مورد استفاده جهت شناسایی کاربری زمین است.

یکی از روش‌های ارزیابی نتایج طبقه‌بندی به‌وسیله یادگیری ماشین، استفاده از منحنی مشخصه عملکرد (Receiver Operating Characteristic) و مقدار سطح زیر نمودار (Area Under the ROC Curve) است. منحنی مشخصه عملکرد نشان‌دهنده نسبت نرخ طبقه‌بندی درست به نرخ طبقه‌بندی اشتباه در هر طبقه است. منحنی مشخصه هر طبقه هرچقدر نسبت به خط طبقه‌بندی تصادفی انحراف داشته باشد نشان‌دهنده دقت خوب طبقه‌بندی است. مقدار مساحت زیر نمودار بیانگر احتمال این است که یک نمونه تصادفی از داده‌ها به‌درستی طبقه‌بندی شود. زیاد بودن سطح زیر نمودار



شکل ۹: نمودار میانگین وزن دار منحنی مشخصه عملکرد حاصل از طبقه‌بندی داده‌های آزمایش

۴- بحث و نتیجه‌گیری

در این مطالعه به ارزیابی روش طبقه‌بندی با استفاده از یادگیری عمیق جهت شناسایی کاربری زمین با استفاده از اطلاعات مکانی کاربر تولید پرداخته شد. به منظور طبقه‌بندی از شبکه عصبی بازگشتی که یک نوع از شبکه‌های یادگیری عمیق هست استفاده شد. جهت پیاده‌سازی از اطلاعات زمانی و مکانی سال ۲۰۱۹ شهر بوستون استفاده شد. گام بعدی در شناسایی کاربری زمین، آماده‌سازی داده‌های کاربر تولید و همچنین داده‌های رسمی جهت برچسب‌گذاری داده‌ها است. در مرحله آماده‌سازی با توجه به تعداد کم اطلاعات در دسترس بازه‌های زمانی مناسب جهت ساخت بردارهای زمانی هر پارسل ایجاد شد. همچنین با توجه به اینکه در روش‌های طبقه‌بندی، داده‌های نویز تأثیر زیادی بر روی نتیجه طبقه‌بندی دارند سعی شد با انتخاب بهینه حد آستانه اطلاعات نویز حذف شوند. با توجه به عدم توازن موجود در تعداد داده‌های هر طبقه، داده‌های آموزش با استفاده از روش بیش نمونه‌برداری مجدد متوازن شدند. جهت انتخاب داده‌ها برای متوازن‌سازی داده‌ها از الگوریتم ماشین بردار پشتیبان استفاده شد که مشاهده شد استفاده از این روش باعث بهبود دقت در طبقه‌بندی نسبت به روش انتخاب تصادفی داده‌ها می‌شود. پارامترهای مدل با استفاده از تغییر و ارزیابی خروجی بهینه شدند.

ارزیابی روش پس از سه بار اجرا با استفاده از ماتریس ابهام و منحنی مشخصه عملکرد بررسی شد. نتایج نشان‌دهنده این هستند که کاربری‌های داده‌های آزمایش با دقت کلی ۶۴ درصد شناسایی شدند. کاربری مسکونی با ۷۷ درصد دقت دارای بیشترین دقت و پس از آن کاربری‌های تجمع و سرگرمی، خرید، اداری و کاربری مختلط به ترتیب با ۶۳، ۵۹، ۵۷ و ۵۰ درصد شناسایی شدند. دیگر کاربری‌های شهری که در طبقه شناسایی شده‌اند. مقدار سطح زیر منحنی مشخصه عملکرد ۰,۸۸ است که بیانگر قابلیت اطمینان روش طبقه‌بندی استفاده شده است.

از مهم‌ترین ویژگی‌های این مطالعه نسبت به مطالعات پیشین در این زمینه در نظر گرفتن واحد پارسل برای شناسایی کاربری زمین است. در نظر گرفتن واحد پارسل باعث می‌شود استفاده از نتایج این روش در به‌روزرسانی نقشه‌های کاربری زمین ساده‌تر انجام گیرد. در اکثر مطالعات کاربری مختلط نادیده گرفته شده است. این مطالعه کاربری‌های مختلط به‌عنوان یک طبقه مجزا کاربری زمین در نظر گرفته شد. در بعضی از روش‌های شناسایی کاربری زمین نیازمند تصاویر ماهواره‌ای با دقت بالا است که در روش ارائه شده در این مطالعه نیازی به این منبع از اطلاعات پرهزینه نیست. با توجه به ماهیت اطلاعات استفاده شده در این مطالعه

اطلاعات جهت کشف رخدادهای معمولاً نیازمند در اختیار داشتن داده‌ها در بازه زمانی بیشتر است. با توجه به شروع همه‌گیری بیماری کرونا در پایان سال ۲۰۱۹ و تغییر الگوی زمانی تحرکات افراد در کاربری‌های مختلف شهری امکان استفاده از داده‌های زمان همه‌گیری کرونا وجود نداشت. تعداد کم داده‌ها باعث کاهش تلفیق چند نوع کاربری و کاهش دقت در طبقه‌بندی بعضی کاربری‌ها شد. روش‌های طبقه‌بندی به‌وسیله یادگیری عمیق اغلب باعث افزایش زمان آموزش شبکه می‌شود که به این منظور از محیط پردازش گوگل کولب استفاده شد.

پیشنهاد می‌شود جهت تحقیقات آتی دیگر منابع موجود داده‌های کاربر تولید جهت شناسایی کاربری زمین استفاده شود. همچنین می‌توان با در دسترس بودن مجموعه داده‌های بزرگ‌تری از اطلاعات توپیت از اطلاعات معنادار توپیت‌ها مانند جنسیت و سن نیز استفاده کرد. می‌توان از دیگر روش‌های رفع عدم توازن در داده‌ها و ارزیابی آن‌ها استفاده کرد.

که نشان‌دهنده فعالیت در کاربری‌های مختلف است، بنابراین با جایگزینی منبع داده‌های مشابه مانند اطلاعات تلفن همراه، چک این و غیره روش ارائه‌شده تغییری نمی‌کند. در بعضی از مطالعات طبقه‌بندی کاربری زمین شناسایی شده فقط محدود به چند کلاس کلی است یا دقت شناسایی کاربری زمین فقط در یک کلاس عمده مانند کاربری‌های مسکونی مناسب است و در کاربری‌های اقلیت مناسب نیست. در این مطالعه دقت شناسایی کاربری زمین در اکثر کلاس‌ها نسبت به مطالعات انجام‌شده نسبتاً مناسب است.

یکی از چالش‌های موجود در تحلیل زمانی اطلاعات کاربر تولید رخدادهایی هستند که باعث تغییر الگوی زمانی می‌شود. از جمله این رخدادهای کمپین‌های اعتراضی، تجمع‌های مناسبتی و غیره است. این رخدادهای باعث تغییر الگوی زمانی حرکت افراد در کاربری‌های مختلف می‌شود. با بررسی ذاتی اطلاعات و مطالعه حوادث منطقه مورد مطالعه می‌توان تأثیر رخدادهای را بر روی نتایج کاهش داد. بررسی ذاتی

مراجع

- [1] M. F. Goodchild, "Commentary: whither VGI?," *GeoJournal*, vol. 72, no. 3-4, pp. 239-244, 2008.
- [2] F. Terroso-Saenz and A. Munoz, "Land use discovery based on Volunteer Geographic Information classification," *Expert Systems with Applications*, vol. 140, p. 112892, 2020.
- [3] J. Jokar Arsanjani, M. Helbich, M. Bakillah, J. Hagenauer, and A. Zipf, "Toward Mapping Land-Use Patterns From Volunteered Geographic Information," *International Journal of Geographical Information Science*, vol. 27, no. 12, pp. 2264-2278, 2013.
- [4] X. Liu et al., "Classifying Urban Land Use By Integrating Remote Sensing And Social Media Data," *International Journal of Geographical Information Science*, vol. 31, no. 8, pp. 1675-1696, 2017.
- [5] Y. Zheng, L. Capra, O. Wolfson, and H. Yang, "Urban Computing: Concepts, Methodologies, and Applications," *ACM Trans. Intell. Syst. Technol.*, vol. 5, no. 3, pp. 1-55, 2014.
- [6] D. Leung and S. Newsam, "Proximate sensing: Inferring what-is-where from georeferenced photo collections," 2010.
- [7] S. Gao, K. Janowicz, and H. Couclelis, "Extracting Urban Functional Regions from Points of Interest and Human Activities on Location - Based Social Networks," *Transactions in GIS*, vol. 21, no. 3, pp. 446-467, 2017.
- [8] B. Zhao, Y. Zhong, and L. Zhang, "Hybrid generative/discriminative scene classification strategy based on latent Dirichlet allocation for high spatial resolution remote sensing imagery," in *Geoscience and Remote Sensing Symposium (IGARSS), 2013 IEEE International*, 2013, pp. 196-199: IEEE.

- [9] T. Pei, S. Sobolevsky, C. Ratti, S.-L. Shaw, T. Li, and C. Zhou, "A new insight into land use classification based on aggregated mobile phone data," *International Journal of Geographical Information Science*, vol. 28, no. 9, pp. 1988-2007, 2014.
- [10] Y. Liu et al., "Social sensing: A new approach to understanding our socioeconomic environments," *Annals of the Association of American Geographers*, vol. 105, no. 3, pp. 512-530, 2015.
- [11] X. Liu et al., "Characterizing Mixed-use Buildings Based on Multi-Source Big data," *International Journal of Geographical Information Science*, vol. 32, no. 4, pp. 738-756, 2018.
- [12] Y. Liu, F. Wang, Y. Xiao, and S. Gao, "Urban land uses and traffic 'source-sink areas': Evidence from GPS-enabled taxi data in Shanghai," *Landscape and Urban Planning*, vol. 106, no. 1, pp. 73-87, 2012.
- [13] X. Zhou and L. Zhang, "Crowdsourcing functions of the living city from Twitter and Foursquare data," *Cartography and Geographic Information Science*, vol. 43, no. 5, pp. 393-404, 2016.
- [14] A. Sabzali Yameqani and A. Alesheikh, "Developing a Location Distortion Model to Improve Reverse Geocoding with Weather Data," *Journal of Geomatics Science and Technology*, vol. 9, no. 2, pp. 1-13, 2019.
- [15] F. Karimipour, M. Tayebi, and K. Amozande, "Characterization of Social Land use in Urban Environments Based on the Semantic Dimension of Location Based Social Networks' Data," (in eng), *Journal of Geomatics Science and Technology, Applicable* vol. 7, no. 4, pp. 133-145, 2018.
- [16] S. Jiang, A. Alves, F. Rodrigues, J. Ferreira Jr, and F. C. Pereira, "Mining Point-of-Interest Data from Social Networks for Urban Land use Classification and Disaggregation," *Computers, Environment and Urban Systems*, vol. 53, pp. 36-46, 2015.
- [17] H. Hobel, A. Abdalla, P. Fogliaroni, and A. U. Frank, "A Semantic Region Growing Algorithm: Extraction of Urban Settings," in *AGILE 2015: Springer*, 2015, pp. 19-33.
- [18] R. Andrade, A. Alves, and C. Bento, "POI Mining for Land Use Classification: A Case Study," *ISPRS International Journal of Geo-Information*, vol. 9, no. 9, p. 493, 2020.
- [19] S. Hasan, X. Zhan, and S. V. Ukkusuri, "Understanding Urban Human Activity and Mobility Patterns Using Large-scale Location-Based Data From Online Social Media," in *Proceedings of the 2nd ACM SIGKDD international workshop on urban computing*, New York, 2013, p. 6: ACM, 2013.
- [20] V. Frias-Martinez, "Spectral Clustering for Sensing Urban Land use Using Twitter Activity," *Engineering Applications of Artificial Intelligence*, vol. 35, pp. 237-245, 2014.
- [21] L. Wu, X. Cheng, C. Kang, D. Zhu, Z. Huang, and Y. Liu, "A Framework for Mixed-use Decomposition Based on Temporal Activity Signatures Extracted from Big Geo-data," *International Journal of Digital Earth*, pp. 1-19, 2018.
- [22] J. L. Toole, M. Ulm, M. C. González, and D. Bauer, "Inferring Land use from Mobile Phone Activity," in *Proceedings of the ACM SIGKDD international workshop on urban computing*, New York, 2012, pp. 1-8: ACM.
- [23] M. Jalili, F. Hakimpour, and S. C. Van der Spek, "Extraction of Usage Patterns for Land-Use Types by Pedestrian Trajectory Analysis," in *International Symposium on Web and Wireless Geographical Information Systems*, Coruña, Spain, 2018, pp. 61-76: Springer.
- [24] Y. Jia et al., "Urban Land Use Mapping by Combining Remote Sensing Imagery and Mobile Phone Positioning Data," *Remote Sensing*, vol. 10, no. 3, p. 446, 2018.
- [25] S. B. Kotsiantis, I. Zaharakis, and P.

- Pintelas, "Supervised Machine Learning: A Review of Classification Techniques," *Emerging artificial intelligence applications in computer engineering*, vol. 160, pp. 3-24, 2007.
- [26] L. Deng and D. Yu, "Deep Learning: Methods and Applications," *Foundations and Trends® in Signal Processing*, vol. 7, no. 3-4, pp. 197-387, 2014.
- [27] I. Goodfellow, Y. Bengio, and A. Courville, *Deep Learning*. MIT press, 2016.
- [28] M. Hüskén and P. Stagge, "Recurrent Neural Networks for Time Series Classification," *Neurocomputing*, vol. 50, pp. 223-235, 2003.
- [29] A. Graves, A.-r. Mohamed, and G. Hinton, "Speech Recognition with Deep Recurrent Neural Networks," in *2013 IEEE international conference on acoustics, speech and signal processing, Vancouver, 2013*, pp. 6645-6649, Vancouver: IEEE.
- [30] P. Liu, X. Qiu, and X. Huang, "Recurrent Neural Network for Text Classification with Multi-task Learning," *arXiv preprint arXiv:1605.05101*, 2016.
- [31] A. Graves, "Supervised sequence labelling," in *Supervised Sequence Labelling with Recurrent Neural Networks*: Springer, 2012, pp. 5-13.
- [32] J. Tanha, Y. Abdi, N. Samadi, N. Razzaghi, and M. Asadpour, "Boosting Methods for Multi-class Imbalanced Data Classification: an Experimental Review," *Journal of Big Data*, vol. 7, no. 1, p. 70, 2020/09/01 2020.
- [33] A. P. Association, "Land Based Classification Standards (LBCS)," ed: Retrieved from American Planning Association: <http://www.planning.org/lbcs>, 2011.



Urban Land Use Identification Based on User-Generated Content and Utilizing Deep Learning Classification

Ali Golipoor¹, Mohammad Taleai^{2*}, Ali Asghar Alesheikh², Ghasem Javadi³

1- Ms.c student of GIS, Faculty of Geodesy and Geomatics, K.N. Toosi University of Technology

2- Professor of GIS, Faculty of Geodesy and Geomatics, K.N. Toosi University of Technology

3- Assistant Professor of Geomatics Engineering, University of Bojnord, North Khorasan, Iran

Abstract

One of the necessary pieces of information for policy-making and urban management is an up-to-date land use map, while the time and cost of producing and updating spatial information using traditional mapping methods and by national or private mapping organizations are too high. The advancement of technology such as smart phones, real-time positioning, and social network development has resulted in the mass production of User Generated Geographic Content (UGGC). The purpose of this study is to identify the land use type of the parcels using UGGCs. In this research six categories of urban land use types have been taken into consideration: residential, commercial/shopping, office/service, mixed, entertainment/recreational, and the other ones; and the social network data of Twitter is used as User-generated content. Deep learning classification and Recurrent Neural Network (RNN) are utilized to analyze the user-generated data. To eliminate the imbalance of the input data, the Support Vector Machine (SVM) algorithm is utilized. Evaluation of the results of the proposed method demonstrates classification of urban land uses with an overall accuracy of 64%. Among urban use classes, the residential one is the best with 77 percent accuracy. The area under the ROC curve is also 0.88, which indicates the appropriate reliability of the proposed method. To eliminate data imbalance, comparing the results of the SVM algorithm with the random method of sampling, reveals that SVM presents higher accuracy.

Key words: Deep Learning, Land use, User-generated Content, Recurrent Neural Network, Twitter.

Correspondence Address: Department of GIS, Faculty of Geomatics, K. N. Toosi University of Technology, Tehran, Iran.

Tel : +98 21 88786212

Email: Taleai@kntu.ac.ir