

مروری بر کاربرد روش‌های یادگیری ماشین و عامل-مبنا در برنامه‌ریزی کاربری زمین

حمید میرزاحسین*^۱، امیرحسین زمانی^۲، نسترن سادات حاجی سیدرضی^۳

^۱ استادیار گروه عمران، برنامه‌ریزی حمل‌ونقل - دانشکده فنی و مهندسی - دانشگاه بین‌المللی امام خمینی (ره)
mirzahosseini@eng.ikiu.ac.ir

^۲ کارشناس ارشد برنامه‌ریزی حمل‌ونقل - دانشکده عمران - دانشگاه بین‌المللی امام خمینی (ره)
amirhosinzamaniyi@gmail.com

^۳ دانشجوی کارشناسی ارشد برنامه‌ریزی حمل‌ونقل - دانشکده عمران - دانشگاه بین‌المللی امام خمینی (ره)
nastaranhajiseyedrazi97@gmail.com

(تاریخ دریافت فروردین ۱۴۰۰، تاریخ تصویب مرداد ۱۴۰۰)

چکیده

رشد جمعیت، تغییرات اقلیمی گسترده و پراکنده‌روی شهرها سبب تغییرات چشم‌گیری در کاربری‌های اراضی شده است. پیشرفت هوش مصنوعی در سالین اخیر در کنار دسترسی گسترده به داده‌های برخط و ظهور روش‌های نوین تحلیل کلان داده سبب گشته تا راه‌حل‌های جدیدی برای تحلیل مسائل و حل مشکلات ناشی از این تغییرات فراهم آید. از این‌رو، طبقه‌بندی، پیش‌بینی و شبیه‌سازی به کمک داده‌های حاصل از این تغییرات در ادوار مختلف می‌تواند زمینه ساز اخذ تصمیمات صحیح و کاربردی باشد. در این راستا، همواره استفاده از راه‌کارهای نوین مدلسازی و برنامه‌ریزی کاربری اراضی مورد توجه متخصصان این امر بوده است. اگرچه مطالعات گسترده‌ای در حوزه روش‌های یادگیری ماشین به عنوان رویکرد جدید طبقه‌بندی، پیش‌بینی و شبیه‌سازی در حوزه‌های مختلف علوم صورت پذیرفته است؛ اما این مطالعات کمتر به بررسی و مرور روش‌های مطرح و کاربردی عامل-مبنا و یادگیری ماشین در تحلیل و مدل‌سازی تغییرات کاربری زمین پرداخته‌اند. بدین منظور، این مقاله فرصت یک مرور نظام‌مند از کاربرد الگوریتم‌های یادگیری ماشین و مدل‌سازی عامل-مبنا در حوزه کاربری زمین را که در اهم پژوهش‌ها و شواهد تجربی ایالات متحده آمریکا، اروپا و بخش‌های مختلف آسیا و همچنین ایران تا به امروز ثبت شده فراهم آورده است. در این راستا، الگوریتم‌ها و روش‌های مختلف پیاده‌سازی شده در هر یک از مطالعات، بررسی شده و نتایج حاصل از تحلیل داده‌های متناسب با آن‌ها که می‌تواند مبنای ادامه کار پژوهش‌های آتی باشد معرفی شده است. نتایج نشان می‌دهد جنبه‌های مختلف مسائل کاربری اراضی از جمله طبقه‌بندی، مدل‌سازی، شبیه‌سازی و پیش‌بینی نیازمند الگوریتم‌هایی با ساختار متناسب خود هستند از این‌رو هیچکدام از روش‌ها را نمی‌توان به‌طور مطلق بر سایرین برتر دانست. اما در این مقاله، پرکاربردترین روش‌ها برای طبقه‌بندی، پیش‌بینی و شبیه‌سازی تغییرات کاربری زمین دسته‌بندی شده‌اند. همچنین مشخص شد روش‌های ماشین بردار پشتیبان (SVM) و شبکه‌های عصبی (CNN) با توجه به ارائه بهترین نتایج، بیشترین کاربرد را در قیاس با سایر روش‌های معرفی شده داشته‌اند.

واژگان کلیدی: برنامه‌ریزی کاربری زمین^۱، تغییر کاربری زمین^۲، یادگیری ماشین^۳، مدل‌سازی عامل-مبنا^۴

* نویسنده رابط

^۱ Land-use planning

^۲ Land-use change

^۳ Machine learning

^۴ Agent-based model

۱- مقدمه

رشد سریع جمعیت باعث تغییر در کاربری زمین می‌شود [۱]. مطالعه و شناخت مدل‌های تغییر کاربری زمین در رشته‌هایی مانند برنامه‌ریزی شهری، علوم جغرافیایی و علوم کاربری زمین کاربرد دارد [۳،۲]. الگوهای فضایی^۱ مدل‌های تغییر کاربری زمین ابزاری برای برنامه‌ریزان و سیاست‌گذاران است، تا تأثیرات تغییرات احتمالی را بر کاربری زمین مشاهده کنند و بر مبنای آن تصمیم‌گیری کنند. همچنین شناخت نحوه توزیع افراد در فضا و زمان در تصمیم‌گیری افراد در برنامه‌ریزی شهری بسیار مهم است [۴]. تغییر کاربری زمین از عواملی چون؛ شرایط اقتصادی-اجتماعی، جمعیت‌شناسی، توپوگرافی منطقه، زیرساخت‌های فیزیکی و محدودیت‌های برنامه‌ریزی و سیاست‌گذاری اثر می‌پذیرد [۵]. تغییرات کاربری زمین می‌تواند ناشی از سیاست، مدیریت، اقتصاد، فرهنگ، رفتار انسان و محیط‌زیست باشد [۶]. مدل‌هایی که الگوهای مکانی کاربری زمین را پیش‌بینی می‌کنند، اطلاعات بیشتری را برای ارزیابی تأثیرات تغییر فراهم می‌کنند [۷]. در حال حاضر، طبقه‌بندی تحت نظارت و طبقه‌بندی بدون نظارت دو روش طبقه‌بندی برای کاربری زمین است [۸].

هوش مصنوعی^۲ فناوری پیشرفته‌ای است که در سال‌های اخیر در بسیاری از علوم مورد استفاده قرار گرفته است. در اصل هوش مصنوعی فرایندی است که ساختاری را برای انجام عملیات هوشمند در رایانه فراهم می‌کند. انسان به کمک هوش مصنوعی موفق به ساخت ماشین‌های بهتر و هوشمند شد. در سال‌های اخیر، با افزایش تکنولوژی فناوری اطلاعات، مطالعات تحقیقاتی متعددی در مورد بررسی رویکردهای داده محور پدیدار شده است. محققان می‌توانند با استفاده از داده‌کاوی یا روش‌های مبتنی بر داده، مدل‌های کاربری زمین را بسازند [۹]. یادگیری ماشین (ML) یک رویکرد داده محور و نوعی زمینه مطالعاتی از فناوری هوش مصنوعی است. در یادگیری ماشین، ماشین‌ها از کارهای قبلی خود اطلاعات جدید یاد می‌گیرند؛ یعنی ماشین‌ها می‌توانند تصمیمات جدید بگیرند یا عملکرد خود را تغییر دهند که این کار با

استفاده از داده‌های در دسترس انجام می‌شود. هدف اصلی این است که رایانه‌ها بتوانند به‌طور خودکار بدون مداخله یا کمک انسان یاد بگیرند و بر این اساس اقدامات را تنظیم کنند [۱۰]. روش یادگیری ماشین می‌تواند در بسیاری از زمینه‌ها از جمله تغییرات کاربری زمین مفید باشد [۱۱]. برای مثال یادگیری ماشین (ML) در زمینه زمین‌شناسی [۱۲]، بوم‌شناسی [۱۳،۱۴]، هیدرولوژی [۱۵] و سنجش‌ازدور [۱۶،۱۷] بررسی طیفی و فرا طیفی تصاویر دورسنجی اجرا و بررسی شده است.

طبقه‌بندی، پیش‌بینی، شبیه‌سازی و مدل‌سازی فرآیند تغییر کاربری زمین کاری چالش‌برانگیز است که با استفاده از تکنیک‌های مختلف مانند، لجستیک و رگرسیون چندگانه^۳، مدل‌های مارکوف^۴، اتوماتای سلولی^۵ و اخیراً با استفاده از روش‌های یادگیری ماشین انجام شده است. یکی از چالش‌های طبقه‌بندی، پیش‌بینی، شبیه‌سازی و مدل‌سازی تغییر کاربری زمین، وجود چندین تغییر کاربری زمین در یک منطقه است. برای مثال، در یک منطقه زمین کشاورزی به شهری تبدیل می‌شود در حالی که در مجاورت آن جنگل به زمین کشاورزی تبدیل می‌شود [۱۸،۱۹]. تعداد کمی از محققان بر موضوع تغییر کاربری زمین و یا به‌عبارت‌دیگر چندین تغییر کاربری تمرکز کرده‌اند، که همین امر روند تغییر کاربری زمین را ساده کرده است. طبقه‌بندی، پیش‌بینی، شبیه‌سازی و مدل‌سازی بیش از یک تغییر کاربری زمین، به‌عنوان طبقه‌بندی‌های چندگانه (MC) مطرح می‌شود و نیاز به حجم زیادی از داده‌های تاریخی^۶، داده‌های جمعیتی^۷ و داده‌های مکانی^۸ دارند [۱۶]. برای مثال احمدلو و دلاوری [۱۷] برای شبیه‌سازی تغییرات کاربری زمین شهرهای ساری و قائم‌شهر از داده‌های تصویری یک بازه زمانی ۲۲ ساله از سال ۱۹۹۲ تا سال ۲۰۱۴ استفاده کردند. با توجه به گسترش دامنه استفاده از تکنیک‌های یادگیری ماشین در برنامه‌ریزی کاربری زمین [۱۸] فرایند پیچیده طبقه‌بندی، پیش‌بینی، شبیه‌سازی و مدل‌سازی تغییر کاربری زمین توسط الگوریتم‌های یادگیری ماشین مدل شده و راه‌حل مناسبی را برای این مسائل ارائه می‌دهند.

^۳ Multiple regression

^۴ Markov models

^۵ Cellular automata

^۶ Historical data

^۷ Demographic data

^۸ Geospatial data

^۱ Spatial

^۲ Artificial intelligence

- تفاوت‌های یادگیری ماشین با خودکار سازی و داده‌کاوی در چیست؟
- بخش‌های مختلف یادگیری ماشین و شاخه‌های متفاوت آن کدام است؟
- ابعاد مختلف کاربری زمین و مسائل موجود کدام است؟ با توجه به هدف تحقیق در این مقاله از ترکیب این کلیدواژه‌ها مانند یادگیری ماشین و برنامه‌ریزی کاربری زمین در همه مراحل جستجو استفاده شد. با استفاده از جستجوی محدود شونده در هر مرحله مقالات مرتبط‌تر شناسایی شدند. بیش از ۷۰ مقاله در این مرور بررسی شدند که از میان این تعداد ۳۴ مقاله مرتبط با بحث کاربرد یادگیری ماشین در کاربری زمین شناسایی شد. ۲۰ روش برای طبقه‌بندی، ۱۹ روش برای پیش‌بینی، ۶ روش برای شبیه‌سازی و ۶ روش برای مدل‌سازی تغییر کاربری زمین و همچنین مقالات دیگری در حوزه تعاریف یادگیری ماشین، کاربردها و شاخه‌های یادگیری ماشین بررسی شد. در شکل ۱ الگوریتم جمع‌آوری مقالات مربوطه آورده شده است.

پژوهش حاضر باهدف بررسی کارایی، عملکرد و تأثیرات روش‌های یادگیری ماشینی در تهیه نقشه‌ها و بررسی تغییرات کاربری اراضی در زمینه‌های شبیه‌سازی، مدل‌سازی، پیش‌بینی و طبقه‌بندی انجام شده است. با توجه به گستردگی تکنیک‌ها یادگیری ماشین پیش‌بینی می‌شود این تکنیک‌های راه‌حل‌های بهینه‌ای را برای چالش‌های مختلف تغییرات کاربری در نواحی مختلف جهان ارائه دهند. در این مقاله، ابتدا، تعاریف مربوط به هوش مصنوعی و یادگیری ماشین مرور شده است، سپس، تکنیک‌های یادگیری ماشین مورداستفاده در تغییر کاربری زمین شامل؛ روش‌های یادگیری نظارت‌شده^۱، روش‌های یادگیری نظارت‌نشده^۲، روش‌های یادگیری نیمه نظارت‌شده^۳، روش‌های یادگیری تقویتی^۴، شبکه‌های عصبی^۵، یادگیری مبتنی بر نمونه^۶، آموزش چندوظیفه‌ای^۷ و یادگیری گروهی^۸ گروهی^۸ و بخش‌های مختلف هرکدام که توسط محققین ارائه شده است، بررسی می‌شوند. سپس کاربرد این تکنیک‌ها در بحث تغییرات کاربری اراضی بررسی می‌شوند.

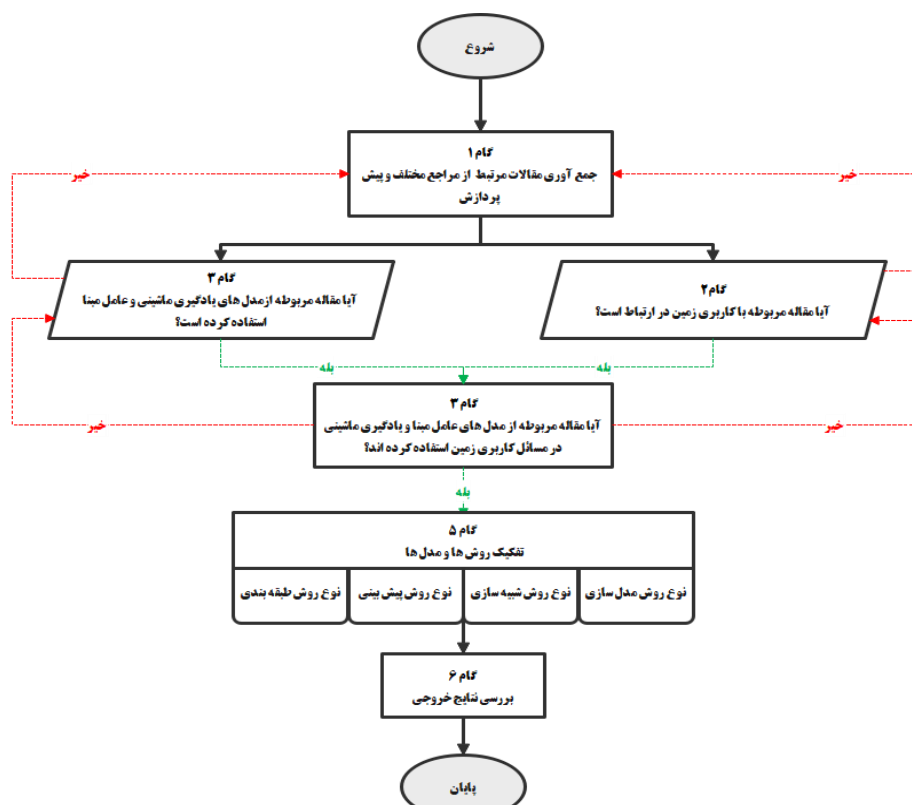
۲- روش تحقیق

در این تحقیق ابتدا از تعدادی کلیدواژه مناسب شامل، برنامه‌ریزی کاربری زمین، هوش مصنوعی، یادگیری ماشین، تغییر کاربری اراضی، توسعه شهری و شبکه‌های عصبی برای انجام یک جستجوی کامل و جامع درزمینه کاربردهای یادگیری ماشین در کاربری زمین انتخاب شد. سپس، تمامی کلیدواژه‌های بالا را در پایگاه‌های اطلاعاتی semanticscholar، ScienceDirect، Springer، IEEE، Sci-Hub و موارد دیگر جستجو شد و مقالات مرتبط استخراج گردید.

مرور انجام شده در پژوهش حاضر به دنبال یافتن پاسخی برای پرسش‌های مطرح درزمینه یادگیری ماشین و برنامه‌ریزی کاربری اراضی، به شرح زیر است:

- یادگیری ماشین چیست؟
- کاربردهای یادگیری ماشین در علوم مختلف چیست؟

۱ Supervised Learning
 ۲ Unsupervised Learning
 ۳ Semi-supervised Learning
 ۴ Reinforcement Learning
 ۵ Neural Network Learning
 ۶ Instance-Based Learning
 ۷ Multitask Learning
 ۸ Ensemble Learning



شکل ۱- الگوریتم جمع‌آوری مقالات

آن را به شکل «علم و مهندسی ساخت دستگاه‌های هوشمند» تعریف کرده است. تحقیقات هوش مصنوعی همچنین برحسب برخی مسائل فنی نیز تقسیم‌بندی می‌شود. این زیرمجموعه بر حل مسائل خاص، بر یکی از چند روش ممکن، بر استفاده از ابزارهای کاملاً متفاوت و یا در رسیدن به کاربردهای خاص متمرکز بوده‌اند [۱۱، ۲۳-۲۵]. در هوش مصنوعی از ابزارهای متنوعی استفاده شده که شامل نسخه‌هایی از بهینه‌سازی تحقیق و ریاضیات، منطق، روش‌های مبتنی بر احتمالات و اقتصاد و بسیاری موارد دیگر می‌شود. هوش مصنوعی بیانگر این است که توانایی اصلی انسان، هوش را می‌توان به‌گونه‌ای دقیق توصیف کرد که دستگاه‌ها هم قادر به شبیه‌سازی آن باشند. امروزه هوش مصنوعی به بخشی ضروری از صنعت فناوری و بسیاری از دشوارترین مسائل علوم رایانه تبدیل شده است [۲۲].

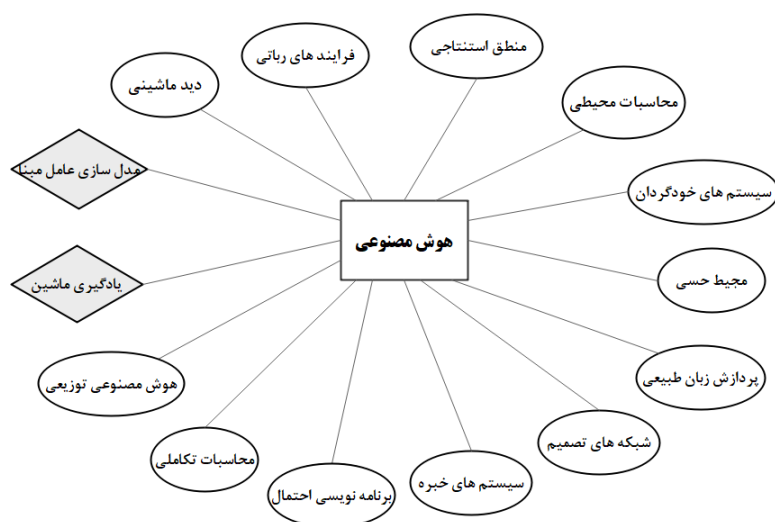
از الگوریتم‌های شناخته شده هوش مصنوعی می‌توان به شکل ۲ اشاره کرد [۱۱، ۲۴، ۲۵، ۲۷]. در این مقاله به بررسی مباحث مختلف یادگیری ماشین پرداخته خواهد شد.

۳- مبانی نظری

۳-۱- هوش مصنوعی

با ظهور و اختراع رایانه‌های دیجیتال قابل‌برنامه‌ریزی بر پایه مفاهیم ریاضی در دهه ۱۹۴۰ شبیه‌سازی فرایند اندیشیدن انسان‌ها به‌شدت موردعلاقه قرار گرفت و دانشمندان ساخت یک مغز الکترونیکی را موردبحث قرار دادند. با توجه به این‌که عصر امروز عصر تکنولوژی و ارتباطات است و نیز سیر تکامل زندگی و صنعت به سمت زندگی رباتیک، ربات‌ها و هوش مصنوعی می‌رود و تأثیر به‌سزایی که بر روند کار صنایع مختلف می‌گذارد، اهمیت پیدا می‌کند. هوش مصنوعی، فناوری و شاخه‌ای در علوم رایانه‌ای است که به مطالعه و توسعه نرم‌افزار و دستگاه‌های هوشمند می‌پردازد. کتب و محققان برجسته هوش مصنوعی، این رشته را با عبارت «مطالعه و طراحی عناصر هوشمند» توصیف می‌کنند که در آن یک عنصر یا عامل هوشمند سیستمی است که محیط را درک کرده و اقداماتی را برای حداکثر کردن احتمال موفقیت خود انجام می‌دهد. جان مک‌کارتی^۱، مبدع این عبارت در سال ۱۹۵۵

^۱ John McCarthy



شکل ۲- شاخه های مختلف هوش مصنوعی

۳-۱-۱- عامل مینا

عامل مینا در علوم مختلف می توان به، توسعه شهری [۳۰] و تغییرات کاربری اراضی [۳۱] اشاره کرد.

۳-۱-۲- یادگیری ماشین

یادگیری ماشین شاخه ای از هوش مصنوعی است که به مطالعه و ساخت دستگاه هایی با قابلیت یادگیری از داده ها می پردازد. به طور مثال، به کمک سیستم یادگیری ماشین می توان یک سیستم مدیریت ایمیل را آموزش داد تا پیام های هرزنامه^۴ را از دیگر پیام ها تشخیص دهد. این سیستم پس از یادگیری می تواند به دسته بندی ایمیل های جدید به هرزنامه و غیر آن بپردازد [۱۰]. یادگیری ماشین همچون داده کاوی، یک فرآیند تحلیل کننده است که برای هوش مصنوعی حیاتی خواهد بود [۳۲]. مسئله اصلی در یادگیری ماشین، عرضه و کپی سازی است. عرضه نمونه های داده ای و توابعی که بر اساس این نمونه ها ارزیابی می شوند، همگی بخشی از دستگاه های یادگیری ماشین هستند. کپی سازی به معنی این قابلیت است که سیستم روی نمونه های داده ای نادیده نیز به خوبی عمل خواهد کرد. شرایطی که تحت آن ها بتوان این مسئله را تضمین کرد، از موضوعات اصلی مطالعه در زیرمجموعه نظریه یادگیری محاسباتی است [۳۳، ۳۴]. از مزیت های این روش می توان به تشخیص الگوریتم های لازم، به عنوان مثال [۳۵] الگوهای راه رفتن افراد جوان و سالخورده را با استفاده از روش های یادگیری ماشین ماشین بردار پشتیبان^۵ (SVM) با دقت زیادی مشخص کرد و برای انواع الگوهای راه رفتن و ویژگی های مختلف

مدل سازی عامل مینا یکی از شاخه های هوش مصنوعی است که برای اولین بار توسط هاستون^۱ و همکاران [۲۸] در کنار نظریه مبتنی بر فرد^۲ ارائه شده است. رویکرد این مدل ها از پایین به بالا^۳ است. به عبارت دیگر، هر سیستم از تعدادی "عامل" تشکیل شده اند که هم با یکدیگر و با محیط خود ارتباط دارند. در این مدل سازی ابتدا اجزا (عامل ها) یک سیستم را شناسایی سپس رفتار آن ها و نحوه تعاملات آن ها تعریف می شود و در آخر و با راه اندازی مدل مشاهده می شود که رفتار و تعاملات چه اتفاقاتی را در سطح کلان سیستم به وجود می آورند. در واقع، مدل سازی عامل مینا (ABM) نشان می دهد که چگونه قواعد رفتاری و گاه ساده عامل ها و تعاملات محلی میان آن ها در سطح خرد می تواند الگوهای بسیار پیچیده ای را در سطح کلان ایجاد کند [۲۹]. با توجه به وابستگی رفتار کل سیستم به رفتار جمعی شرایطی فراهم می شود تا تأثیر رفتار انسان بر محیط به گونه ای هوشمند و صریح از نظر فضایی، با در نظر گرفتن ارتباطات اجتماعی، سازگاری و تصمیم گیری در سطوح مختلف، ادغام شود. عامل ها می توانند به طور غیرمستقیم از طریق یک محیط مشترک و یا مستقیماً با یکدیگر از طریق بازارها، شبکه های اجتماعی و یا مؤسسات تعامل داشته باشند. از کاربردهای گسترده مدل سازی

۴ Spam

۵ Support Vector Machine (SVM)

۱ huston

۲ Individual Based Modelling

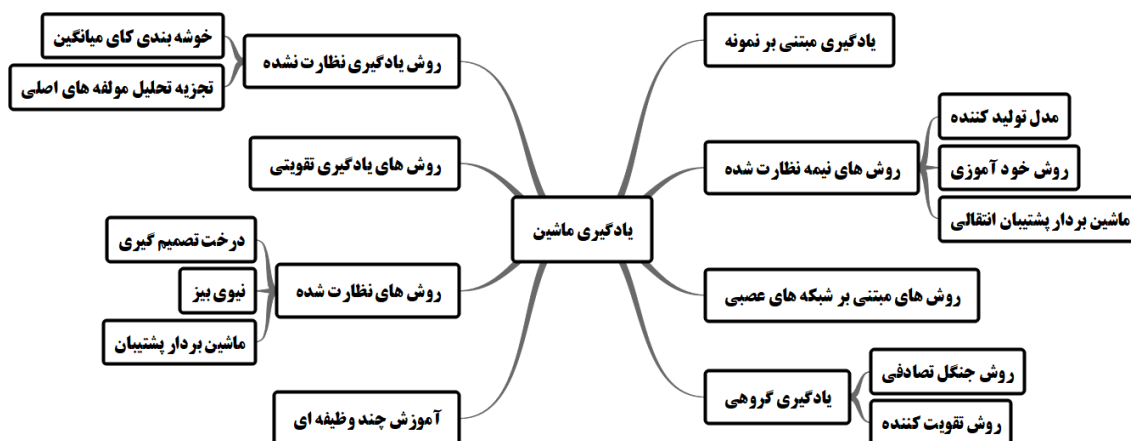
۳ Bottom-up

الگوریتم مناسبی را معرفی کرد که قابلیت بالایی در تشخیص داده‌ها داشت و همچنین شناسایی و معرفی بهترین داده‌ها به سیستم، به‌عنوان مثال [۳۶] یک چارچوب طبقه‌بندی و ارزیابی عملکرد برای شناسایی الگوهای شهری در تصاویر ماهواره‌ای چند طیفی و همچنین تأثیر تعداد و انتخاب داده‌های آموزش، تأثیر اندازه و ترکیب بردار ویژگی و تأثیر تقسیم تصویر بر دقت طبقه‌بندی انجام شد. همچنین محمدی و دلاوری [۳۷] نیز برای مدل توسعه شهری در سندج از الگوریتم‌های یادگیری ماشین برای مشخص کردن تغییرات ساختار شهری و تعیین سیاست‌های متقابل استفاده کردند. سامانه‌های یادگیری ماشین زیادی در اطراف ما مشغول فعالیت هستند. هنگامی که افراد از آمازون یا دیجی کالا خرید می‌کنند، این سامانه‌ها پیش‌بینی می‌کنند خرید بعدی آن‌ها چیست؟ یا به چه آیتم‌هایی ممکن است علاقه داشته باشند. هنگامی که یک ویدئو در یوتیوب یا آپارات تماشا می‌کنند، این سامانه‌ها

پیش‌بینی می‌کنند که از چه ویدئوهای دیگری ممکن است خوششان بیاید. در هر جستجوی گوگل از چندین سیستم یادگیری ماشین استفاده می‌شود. هدف از این کار فهمیدن منظور از جستجوی افراد است. همچنین دستیارهای مجازی، مانند سیری شرکت اپل، الکسای آمازون، دستیار گوگل و کورتانای مایکروسافت نمونه‌هایی از سامانه یادگیری ماشین است.

برخلاف تصور برخی افراد، یادگیری ماشین با خودکارسازی متفاوت است. خودکارسازی‌هایی که اتفاق می‌افتند مبتنی بر قانون هستند؛ یعنی یک سری کارها با الگو از قبل تعریف شده انجام شوند؛ اما یادگیری ماشین، از نتایج داده‌های قبلی خود برای تصمیم‌گیری‌های آینده استفاده می‌کند.

بخش‌های مختلف یادگیری ماشین را می‌توان در شکل ۳ یافت، که در ادامه به آن‌ها پرداخته خواهد شد.



شکل ۳- روش‌های مختلف یادگیری ماشین

۳-۱-۲-۱- روش‌های نظارت‌شده

در روش یادگیری نظارت‌شده، ورودی و خروجی الگوریتم از ابتدا مشخص است. در واقع، الگوریتم یادگیری ماشین نظارت‌شده، شروع به تجزیه و تحلیل روی مجموعه داده‌های ورودی می‌کند. در نهایت، الگوریتم یادگیری نظارت‌شده پس از آموزش دیدن^۱ روی مجموعه داده دارای خروجی‌های مشخص، یک الگو و یا به بیان بهتر، مدلی را استنباط می‌کند که داده‌های ورودی بر اساس آن به داده‌های خروجی مبدل می‌شوند [۳۲]. از روش‌های حل الگوریتم‌های نظارت‌شده می‌توان به موارد زیر اشاره کرد:

- درخت تصمیم‌گیری^۲ (DT): درخت تصمیم‌گیری عمدتاً برای طبقه‌بندی استفاده می‌شود. درخت تصمیم‌گیری به آن دسته از درختان گفته می‌شود که گروه‌ها را با مرتب‌سازی بر اساس مقادیر آن‌ها نسبت می‌دهد. هر درخت از گره‌ها و شاخه‌ها تشکیل شده است. هر گره نشان‌دهنده ویژگی‌های گروهی است که قرار است طبقه‌بندی شود و هر شاخه مقداری را نشان می‌دهد که گره می‌تواند بگیرد [۳۸]. مزیت یک مدل DT در قابلیت انتقال آن به مجموعه‌ای از قوانین (اگر-آن‌گاه^۳) است که ویژگی‌های ورودی و تصمیمات کلاس را به هم متصل می‌کند، که برای متخصصان دامنه به راحتی قابل درک است [۳۹].

^۲ Decision tree
^۳ If-then

^۱ Training

حداقل می‌رساند. خوشه‌بندی k میانگین تمایل به یافتن خوشه‌هایی با اندازه مکانی قابل‌مقایسه دارد [۳۳].

- تجزیه و تحلیل مؤلفه اصلی^۶ (PCA): یک روش چندبخشی است که جدولی از داده‌های موجود را بررسی و تجزیه و تحلیل می‌کند و مشاهدات در آن توسط چندین متغیر وابسته کمی همبسته تعریف می‌شوند. این روش یکی از محبوب‌ترین و قدیمی‌ترین روش‌های تجزیه تحلیل به حساب می‌آید [۴۲]. ایده اصلی این روش برداشت اطلاعات مهم از جدول، نشان دادن آن به‌عنوان مجموعه‌ای از متغیرهای متعامد است.

۳-۱-۲-۳- روش‌های نیمه نظارت‌شده

الگوریتم‌های یادگیری ماشین نیمه نظارت‌شده، از جمله روش‌های یادگیری ماشین هستند که می‌توان گفت بین یادگیری با ناظر و یادگیری بدون ناظر قرار می‌گیرند. در یادگیری نیمه نظارتی، از هر دو نوع داده، یعنی داده‌هایی با خروجی مشخص بر چسب‌دار و داده‌هایی فاقد خروجی مشخص فاقد برچسب برای مرحله آموزش مدل استفاده می‌شود. به‌طور معمول در زمان آموزش یک مدل یادگیری نیمه نظارت‌شده، از مقدار کمی از داده‌های دارای برچسب و مقدار زیادی از داده‌های بدون برچسب بهره برده می‌شود. دستگاه‌هایی که از این روش استفاده می‌کنند، به میزان قابل‌توجهی دقت یادگیری را بهبود می‌بخشند. البته، گروهی برای این باور هستند که روش‌های نیمه نظارت‌شده در واقع همان روش‌های بدون ناظر هستند [۴۳، ۴۴]. از الگوریتم‌های استفاده‌شده برای این روش می‌توان به موارد زیر اشاره کردند:

- مدل تولیدکننده^۷ (GA): مدل‌های تولیدی یکی از قدیمی‌ترین روش‌های یادگیری نیمه نظارت‌شده است. یک مدل مولد شامل توزیع خود داده است و به شما می‌گوید که یک مثال ارائه‌شده چقدر محتمل است. به‌عنوان مثال، معمولاً مدل‌های تولیدکننده، از جمله مدل‌هایی هستند که کلمه بعدی را در یک توالی پیش‌بینی می‌کنند [۴۵].

- خودآموزی^۸ (S-T): گاهی طبقه‌بندی داده‌ها بسیار دشوار است با استفاده از یک سری داده‌ها که از قبل برچسب‌گذاری شده‌اند، داده‌های بدون برچسب را

- نیوی بیز^۱ (NB): این مدل عمدتاً برای طبقه‌بندی و خوشه‌بندی متن استفاده می‌شود. ساختار اصلی آن بر مبنای ساخت چارچوب‌های درخت مانند است که به احتمال شرطی بستگی دارند. درختانی که به این شکل ایجاد می‌شوند به شبکه بیزی^۲ نیز معروف هستند. این روش یک انتخاب مناسب برای دریافت سریع راه‌حل از مسائل احتمال عمومی است. نتایج این روش با نمونه‌گیری گیبس^۳ و انتقال باور قابل‌توجه است. این مدل‌ها جایگزین مناسبی برای شبکه‌های بیزی هستند. آزمایش روی تعداد زیادی از داده‌ها نشان می‌دهد که سریع‌تر، دقیق‌تر و گسترده‌تر هستند [۴۰].

۳-۱-۲-۳- روش‌های نظارت‌نشده

الگوریتم‌های یادگیری ماشین نظارت‌نشده هنگامی استفاده می‌شوند که در داده‌های مورد استفاده جهت آموزش ماشین، ورودی و خروجی سیستم از ابتدا مشخص نباشند. در واقع، در این نوع مسائل یادگیری ماشین، هدف ارتباط ورودی و خروجی نیست؛ بلکه الگوریتم یادگیری ماشین به دنبال تابعی برای توصیف ساختار پنهان و خاص موجود در داده‌ها است (منظور داده‌های ورودی است که خروجی آن‌ها مشخص نیست). در روش‌های یادگیری ماشین نظارت‌نشده، الگوریتم با بررسی شباهت‌ها و تفاوت‌های میان داده‌ها، به یک الگو برای خوشه‌بندی کردن داده‌ها دست پیدا می‌کند و بر اساس این الگو، می‌تواند خروجی را برای نمونه داده‌های جدید پیش‌بینی کند [۳۲، ۳۳]. از روش‌های استفاده‌شده در این الگوریتم می‌توان به موارد زیر اشاره کرد:

- خوشه‌بندی کای-میانگین^۴ (K-mean): خوشه‌بندی یا گروه‌بندی نوعی از روش یادگیری بدون نظارت است که با شروع آن، گروه‌ها به‌طور خودکار ایجاد می‌شود. مواردی که دارای مشخصات مشابه هستند در یک گروه قرار می‌گیرند. به این الگوریتم k -میانگین گفته می‌شود زیرا k خوشه‌های متمایز ایجاد می‌کند. خوشه‌بندی k میانگین واریانس‌های درون خوشه‌ای (فاصله‌های اقلیدسی^۵) را به

۱ Naive Bayes
 ۲ Bayesian Network
 ۳ Gibbs Sampling
 ۴ K-Means Clustering
 ۵ Euclidean distances

۶ Principal Component Analysis
 ۷ Generative models
 ۸ Self-Training

شناسایی و پیش‌بینی کرد. این روش برای تعداد زیاد و مختلف داده‌ها مناسب است [۴۶]. برای تعداد زیاد تصاویر ابر طیفی یک چارچوب مناسب (S-T) برای برچسب‌گذاری خودکار داده‌ها به وجود آورد و از محدودیت‌های موجود برای تنظیم فرایند خودآموزی استفاده کرد. نتایج بیانگر استحکام و دقت برچسب‌گذاری مدل ارائه شده بود [۴۷].

- ماشین بردار پشتیبان (SVM): ماشین بردار پشتیبان، تکنولوژی جدید یادگیری ماشینی است که روش آماری غیر پارامتری و نیمه نظارت‌شده است. ویژگی اصلی این روش، توانایی بالا در استفاده از نمونه‌های تعلیمی کمتر و رسیدن به دقت بالاتر در مقایسه با سایر روش‌ها است. اگر طبقات تفکیک خطی نداشته باشند، فضای SVM پدیده‌ها را در فضایی چندبعدی با استفاده از کرنل^۱ ترسیم می‌کند. سپس طبقات را در فضای جدید و تفکیک‌شده می‌سازد. این مورد در حل مشکلات طبقه‌بندی‌های پیچیده کاربرد دارند؛ درحالی‌که فرض اولیه‌ی روش‌هایی مانند ML، نرمال بودن داده است. ماشین بردار پشتیبان علاوه بر این، داده‌های سنجش‌ازدور^۲ را که دارای مشکل است معمولاً با توزیع مشخصی از مدلی که بر پایه‌ی کرنل است و با انتخاب کرنل مناسب می‌تواند مشکلات را حل کند [۴۸].

- ماشین بردار پشتیبان انتقالی^۳ (TSVM): این مدل گسترش یافته مدل SVM است. کارکرد این مدل به شکلی است که برچسب‌گذاری را برای مشکلات به بهترین و دقیق‌ترین حالت انجام دهد [۴۹].

۳-۲-۴- روش‌های یادگیری تقویتی

در یادگیری تقویتی، عامل هوشمند با انجام اقداماتی در محیط و دیدن نتایج آن‌ها، با محیط خود ارتباط برقرار می‌کند. نتیجه ارتباط عامل با محیط می‌تواند یک خطا یا یک امتیاز باشد. هدف در روش‌های یادگیری تقویتی، بیشینه کردن پاداش است. درواقع، عامل در مسیر بیشینه کردن امتیاز اقدام می‌کند و در غیر این صورت، خطا دریافت می‌کند. در یادگیری تقویتی، عامل هوشمند برای انجام تصمیم‌گیری‌های متوالی آموزش می‌بیند یا به بیان دیگر، عامل می‌آموزد که در یک محیط نامعلوم و

پیچیده به هدف یعنی همان بیشینه کردن امتیاز برسد [۵۱، ۵۰]. موارد بسیاری که می‌توان از کاربردهای گسترده این روش مثال زد:

- آموزش چندوظیفه‌ای: یک الگوی یادگیری در یادگیری ماشین است و هدف آن استفاده از اطلاعات مفید موجود در سابقه خود و ارسال آن به کارها مرتبط دیگر است. هنگامی که الگوریتم‌های یادگیری چندوظیفه‌ای برای یک کار اعمال می‌شوند، روش کار را به یاد می‌آورد که چگونه مسئله را حل کرده یا چگونه به نتیجه خاصی رسیده است. سپس الگوریتم از این مراحل برای یافتن راه‌حل مسئله یا کار مشابه دیگر استفاده می‌کند. این روش تفاوت‌ها و شباهت‌ها را در نظر می‌گیرد که باعث افزایش دقت پیش‌بینی و عملکرد می‌شود [۵۲].

۳-۱-۲-۵- یادگیری گروهی

این الگوی یادگیری ماشین از سال ۱۹۹۰ بر سر زبان‌ها افتاد. این یادگیری شامل تعداد زیادی از فراگیران است که به صورت منفرد آموزش دیده‌اند، این الگوریتم با ترکیب این فراگیران آن‌ها را برای حل یک مشکل آموزش می‌دهند. این رویکرد ترکیبی سعی در ساخت مجموعه‌ای از فرضیه‌ها است. این نوع یادگیری یک نوع یادگیری گروهی است [۵۳، ۵۴]. از روش‌های مرسوم حل مسائل این روش می‌توان به موارد زیر اشاره کرد:

- روش تقویت‌کننده^۴: اساس کار این روش مبتنی بر کاهش تعداد خطاها و واریانس است. هنگامی که تعداد الگوریتم‌ها افزایش پیدا می‌کند، این روش با وزن دهی به الگوریتم‌های ضعیف و قوی آن‌ها را برای طبقه‌بندی دقیق آماده می‌کند. منظور از ضعیف و قوی بودن این است که چه مقدار ارتباط درست با مجموعه ایجاد شده برقرار می‌کنند. یکی از مشهورترین نمونه‌های این روش ادابوست است [۵۵].

- ایجاد کیف یا یک کیسه^۵: برای افزایش دقت الگوریتم یادگیری ما مجموعه‌ای از زیرمجموعه‌های مختلف را در یک کیف یا کیسه قرار می‌دهیم که در طبقه‌بندی بسیار کاربرد دارد. این کار باعث کاهش واریانس و افزایش عملکرد آموزش به داده‌های جمع‌آوری شده می‌شود [۵۶]. از مهم‌ترین الگوریتم‌های این روش می‌توان به روش جنگل

۴ Boosting
۵ Bagging

۱ Kernel
۲ Remote Sensing
۳ Transductive support vector machine

تصادفی^۱ (RF) اشاره کرد که نمایانگر زیرمجموعه‌ای از مشاهدات تصادفی و شاخه‌های هر درخت نمایانگر زیرمجموعه‌ای از متغیرهای تصادفی موردنظر است. در این روش، در هر مشاهده، هر درخت یک کلاس را انتخاب می‌کند و برای پیش‌بینی کلی روش باید از پیش‌بینی‌های همه درخت‌ها میانگین‌گیری کرد [۵۷].

۳-۱-۲-۶- شبکه‌های عصبی

این روش برگرفته از عملکردهای سلول‌های عصبی موجودات زنده است. این الگوریتم یکی از بهترین الگوریتم‌های یادگیری ماشین است. وقتی دستورالعمل صحیحی از برنامه در اختیار نیست استفاده از این روش اهمیت پیدا می‌کند. عملکرد سلول را در بدن در نظر بگیرید، نورون‌ها مانند سلول‌ها است و شامل چهار قسمت: دندریت^۲، هسته^۳، سوما^۴ و آکسون^۵ هستند. یک سری اطلاعات یا سیگنال‌هایی از طریق دندریت دریافت می‌شود، سوما این اطلاعات دریافت شده را بررسی و تحلیل می‌کند و توسط آکسون‌ها به نورون بعدی منتقل می‌شوند. هرکدام از نورون‌ها و لینک‌های ارتباطی میان آن‌ها، وزنی دارند که در طی فرایند یادگیری تنظیم می‌شود. وزن، قدرت سیگنال‌های ارتباطی میان نورون‌ها را تقویت یا تضعیف می‌کند [۵۸، ۵۹].

۳-۱-۲-۷- یادگیری مبتنی بر نمونه

این روش با استفاده از یک سری نمونه‌های موجود به شکل ماشینی اقدام به تحلیل داده‌ها می‌کند. اساس این روش استفاده از یک الگوریتم نمونه برای طبقه‌بندی مابقی داده‌ها است. به این شکل که یک نمونه از الگوریتم نمونه به مدل معرفی می‌شود و مدل با استفاده از ویژگی مشابهت یاب خود الگوی مربوطی را پیدا کرده و بر اساس آن اقدام به پیش‌بینی می‌کند [۶۰]. از مشهورترین نمونه‌های این روش می‌توان به مورد زیر اشاره کرد [۳۲]:

k- نزدیک‌ترین همسایه^۶ (KNN): این روش با استفاده از الگویی که از قبل یاد گرفته داده‌های آزمون را

دریافت کرده و داده‌های موجود و اضافه‌شده را باهم مقایسه می‌کند. در این روش اطلاعات آموزش دارای برچسب‌گذاری صحیح به فراگیر منتقل می‌شود. که اینجا منظور از K بیشترین داده همبسته گرفته‌شده از مجموعه آموزش است. معمولاً از K به‌عنوان نماینده‌ای برای داده‌های آزمون استفاده می‌کنند [۶۱].

۴- کاربرد یادگیری ماشین در مدل‌سازی، طبقه‌بندی، شبیه‌سازی و پیش‌بینی برنامه‌ریزی کاربری زمین

تجزیه و تحلیل تناسب اراضی بر مبنای سیستم اطلاعات جغرافیایی^۷ (GIS) برای تعیین تناسب زمین، ارزیابی و برنامه‌ریزی لنداسکیپ^۸، کاربری زمین شهری، ارزیابی اثرات زیست‌محیطی و برنامه‌ریزی منطقه‌ای به‌کاربرده می‌شود. پیشرفت‌های اخیر در فن‌آوری اطلاعات به‌خصوص در زمینه‌ی هوش مصنوعی و یادگیری ماشین، توسعه رویکردهای جدید برای تحلیل برنامه‌ریزی کاربری زمین را سبب شده است. فرایندهای نظارت‌شده، نظارت‌نشده، شبکه‌های عصبی، نیمه نظارت‌شده، آموزش تقویتی و آموزش مبتنی بر نمونه روش‌های رایج هوش مصنوعی در برنامه‌ریزی کاربری زمین هستند. در این مقاله سعی شده الگوریتم‌های یادگیری ماشین و نحوه عملکرد آن‌ها بررسی و کارآمدترین تکنیک‌ها را در زمینه طبقه‌بندی، مدل‌سازی، شبیه‌سازی و پیش‌بینی تغییر کاربری زمین معرفی کند.

یک مطالعه موردی شبیه‌سازی توسعه شهری در شهر شنزن، چین انجام شده است [۶۲]. که ماشین‌های بردار پشتیبانی (SVM) را به‌عنوان روشی برای تعریف قوانین انتقال غیرخطی برای مدل‌سازی اتوماتای سلولی (CA) آزمایش می‌کند. متغیرهای مکانی مورد استفاده در این شبیه‌سازی از داده‌های سنجش از راه دور و (GIS) موجود حاصل‌شده است و متغیرهای فاصله با استفاده از تابع Euclidean در ArcGIS محاسبه‌شده‌اند. مدل‌سازی CA و ارتباط بین اجزای مختلف مدل با استفاده از ویژوال بیسیک^۹ برنامه‌ریزی‌شده است. همچنین از روش یادگیری

^۱ Random Forest

^۲ Dendrite

^۳ Core

^۴ Soma

^۵ Axon


^۶ K-Nearest Neighbor

^۷ Geographic information system

^۸ Landscape planning

^۹ Visual Basic

طبقه‌بندی و رگرسیون (CART) و رگرسیون تطبیقی چند متغیره اسپیلاین (MARS) توضیحات واضح‌تری از مهم‌ترین محرک‌ها و مقادیر مرتبط با هر نوع تغییر کاربری زمین ارائه داده‌اند.



شکل ۴- (a) تصویر طبقه‌بندی‌شده با استفاده از روش طبقه‌بندی کای میانگین (b) تصویر طبقه‌بندی‌شده با استفاده از روش طبقه‌بندی کای نزدیک‌ترین همسایه. (c) تصویر طبقه‌بندی‌شده با استفاده از روش طبقه‌بندی شبکه عصبی مصنوعی. (d) تصویر طبقه‌بندی‌شده با استفاده از روش طبقه‌بندی ماشین بردار پشتیبانی، (e) تصویر طبقه‌بندی‌شده با استفاده از طبقه‌بندی نیمه نظارت‌شده [۹]

پژوهشی در رابطه با بهبود ارزیابی کاربری زمین با اعمال روش طبقه‌بندی نیمه نظارت‌شده در منطقه خودمختار مغولستان داخلی، چین [۶۵] انجام شد؛ که در آن از روش اصلاح رادیومتریک^۸ در پیش‌پردازش داده‌ها و روش کاهش ابعاد برای تصویر فرایطیفی^۹ استفاده شد. این پژوهش طبقه‌بندی نیمه نظارت‌شده را با دیگر روش‌ها طبقه‌بندی (K-means)، روش طبقه‌بندی کای نزدیک‌ترین همسایه (KNN)، طبقه‌بندی شبکه عصبی مصنوعی و طبقه‌بندی ماشین بردار پشتیبانی مقایسه کرده است. در شکل ۴ می‌توان این مقایسه را مشاهده کرد. نتایج تجربی نشان می‌دهد که روش طبقه‌بندی نیمه نظارت‌شده دارای طبقه‌بندی کلی با دقت بالا است اما به دلیل نیاز به مدت‌زمان طولانی و نیاز به قدرت و سخت‌افزار محاسباتی بیشتر، بهترین روش نیست.

نقشه‌برداری محوطه‌های شهری برای ابعاد محیطی و اقتصادی اهمیت دارند. یکی از اصلی‌ترین موضوعات هنگام تهیه نقشه‌های پوششی زمین سردرگمی در پاسخ‌های طیفی ویژگی‌های مختلف است. دقت نقشه طبقه‌بندی‌شده به‌وضوح مکانی و طیفی، تنوع فصلی در انواع پوشش گیاهی و شرایط رطوبت خاک بستگی دارد. مجموعه ماهواره‌های Landsat متداول‌ترین منابع داده مشاهده

مبتنی بر نمونه [۶۳] برای اطمینان از اندازه مناسب داده‌های آموزش استفاده شد. در این پژوهش توسعه شهری این شهر را از سال ۱۹۸۸ تا ۲۰۰۴ شبیه‌سازی کرده‌اند و همچنین توسعه شهری برای سال‌های ۲۰۰۴-۲۰۱۰ پیش‌بینی شد. نتایج اعتبارسنجی انطباق خوبی بین الگوی توسعه شهری واقعی و شبیه‌سازی‌شده را نشان داد و روش پیشنهادی در مقایسه با مدل رگرسیون لجستیکی خطی به‌طور کلی دقت بالاتری داشت. در نهایت به این نتیجه رسیده‌اند که مدل CA مبتنی بر SVM ابزاری مفید برای شبیه‌سازی رشد شهری است.

با استفاده از مدل‌های یادگیری تقویتی (RL) که یکی از الگوریتم‌های یادگیری ماشین است [۶۴]، مدل مکانی-زمانی^۱ برای مدل‌سازی کاربری زمین-پوشش زمین^۲ (LULC) با تلفیقی از GIS را بررسی کرده‌اند. هدف این مطالعه بررسی تغییرات کاربری زمین و تغییرات پوششی زمین در پی استخراج منابع طبیعی است. نتایج این بررسی بینش‌هایی مفید را برای برنامه‌ریزان و مراجع ذی صلاح ایجاد کرد.

سه مدل تغییر کاربری زمین، مبتنی بر سه ابزار یادگیری ماشین؛ شبکه عصبی مصنوعی^۳ (ANN)، درخت طبقه‌بندی و رگرسیون^۴ (CART) و رگرسیون چند متغیره تطبیقی اسپیلاین^۵ (MARS) برای شبیه‌سازی هم‌زمان چندین کلاس کاربری زمین (شامل کشاورزی، جنگل و شهری) در دو منطقه؛ جنوب شرقی ویسکانسین و حوزه آبریز رودخانه موسکگون در میشیگان، واقع در ایالات متحده آمریکا بررسی شد [۹]. نتایج مربوط به این سه ابزار داده‌کاوی را با استفاده از یک روش طبقه‌بندی نرم، مانند مشخصه عملیاتی نسبی^۶ (ROC) و یک طبقه‌بندی سخت، مانند درصد مطابقت صحیح^۷ (PCM) مقایسه کرده‌اند و مشخص شد که به‌طور منطقی این سه ابزار عملکرد خوبی دارند. همچنین دریافته‌اند که شبکه ANN بهترین دقت را در هر دو منطقه برای سه کلاس کاربری زمین (شهری، کشاورزی و جنگل) فراهم کرده است اما قدرت توضیحی کمی دارند. درحالی‌که درخت

^۱ Spatio-temporal

^۲ Land use-Land cover

^۳ Artificial Neural Networks

^۴ Classification and regression tree

^۵ Multivariate Adaptive Regression Spline

^۶ Relative operating characteristic

^۷ Percent correct match

^۸ Radiometric

^۹ Hyperspectral

ماشین شامل؛ ماشین بردار پشتیبانی (SVM)، حداکثر تابع وقوع (MLE) و شبکه عصبی مصنوعی (ANN) بررسی کرده‌اند و از هفت کلاس جاده، مناطق آباد شده، مزارع تنباکو، زمین‌هایی با گیاهان پراکنده، زمین‌های نیشکر، زمین بایر و منابع آبی استفاده کرده‌اند. برای به دست آوردن اطلاعات از سطح زمین از سیستم تصویربرداری ماهواره‌ای استفاده شد و برای طبقه‌بندی تصاویر ماهواره‌ای از یک طبقه‌بندی نظارت‌شده بهره گرفته‌اند. برای ارزیابی عملکرد، از دقت کلی^۷ (OA)، دقت کاربر^۸ (UA)، دقت تولیدکننده^۹ (PA) و آمار کاپا^{۱۰} (KS) استفاده شده است. این معیارها بر اساس کاربرد گسترده در دامنه سنجش‌ازدور انتخاب شده‌اند. از آزمایش این پژوهش، نتیجه گرفته شد که SVM برای تجزیه و تحلیل کاربری زمین بهترین است. همچنین MLE برای تشخیص رضایت بخشی بهترین عملکرد را دارد.

از مطالعات کاربری زمین/پوشش زمین می‌توان به مطالعه‌ای در این زمینه اشاره کرد که انجام شده است [۶۹]. این مطالعه برای شهر ساپورو ژاپن انجام شده است. تعداد ۱۰۰۰۰۰۰ عکس Flickr از این ناحیه برای طبقه‌بندی جمع‌آوری شد. هدف این مطالعه استخراج خودکار توصیفات LULC بصری از عکس‌های آنلاین و تخمین توزیع احتمالات^{۱۱} بر روی انواع LULC برای شهر ساپورو است. روش پیشنهادی از یک طبقه‌بندی نیوی بیز (NB) با توصیف رنگ، شکل و شاخص رنگ استفاده می‌کند. عملکرد طبقه‌بندی کننده در مجموع بالای ۸۵ درصد بود. نتایج نشان می‌دهد که تصاویر Flickr با برچسب‌گذاری جغرافیایی شده می‌توانند انواع LULC را با دقت مناسب طبقه‌بندی کنند و در صورت وجود یک توزیع فضایی^{۱۲} کافی از داده‌های با منابع گسترده، روش پیشنهادی کاربری طبقه‌بندی LULC را بهبود می‌بخشد.

در پژوهشی از اتوماتا سلولی برای مدل‌سازی سیستم شهری همدان استفاده شده است [۷۰] و از منطق فازی به‌عنوان روشی برای تغییر قوانین مدل CA استفاده کرده‌اند که در دو مرحله طبقه‌بندی و شبیه‌سازی

زمین^۱ (EO) برای نقشه‌برداری پوشش اراضی برای مناطق شهری، نیمه‌شهری و روستایی هستند. روش‌های تجزیه و تحلیل تصویر مبتنی بر پیکسل و مبتنی بر شیء^۲ به‌طور گسترده‌ای شناخته شده‌اند مانند حداکثر تابع وقوع^۳ (MLE)، ماشین بردار پشتیبانی (SVM)، کی نزدیک‌ترین همسایه (KNN) ارائه شده است [۶۶]. با استفاده از ابزار یادگیری ماشین اقدام به طبقه‌بندی دقیق داده‌های جمع‌آوری شده‌ی حومه شهر Landsat TM و OLI کرد. تجزیه و تحلیل تصاویر با وضوح متوسط مانند Landsat TM و OLI با استفاده از روش‌های پیشرفته مانند (SVM) و خوشه‌بندی کای نزدیک‌ترین همسایه (KNN) نقشه‌های طبقه‌بندی بسیار دقیق را به دست آورد. (SVM) می‌تواند خصوصیات فضایی^۴ این مناظر را مانند تکه‌تکه شدن و جداسازی عناصر در فضا حفظ کند و مناسب‌ترین الگوریتم در این مطالعه برای تجزیه و تحلیل محوطه‌سازی یک محیط شهری است.

در [۶۷] به دلیل ضرورت مشاهده تهدیدات ناشی از تغییر کاربری منابع طبیعی و کشاورزی در مازندران انجام شد. این مطالعه تغییر کاربری زمین را با استفاده از دو مدل؛ درخت تصمیم‌گیری و رگرسیون CART و شبکه عصبی مصنوعی ANN در منطقه شمال ایران شامل شهرهای ساری و قائم‌شهر مدل‌سازی کرد که در آن داده‌های شبکه حمل‌ونقل از پایگاه داده OpenStreetMap گرفته شد و مدل ارتفاع دیجیتال^۵ (DEM) از وبسایت مرکز نقشه‌برداری ملی ایران بارگیری شد. از نرم‌افزار Salford Predictive Modeler و LTM برای مدل‌سازی LUC و انجام تجزیه و تحلیل حساسیت متغیرها استفاده شد. با ارزیابی عملکرد هر دو مدل با استفاده از دو معیار کالیبراسیون شامل گیرنده مشخصه عملیاتی (ROC) و ویژگی کلی عملکرد^۶ (TOC) این نتایج به دست آمد که شبکه ANN در شبیه‌سازی تغییرات شهری و کشاورزی نسبت به CART موفق‌تر عمل می‌کند.

[۶۸] در مقاله‌ای، کاربری زمین را در پیشاور واقع در کشور پاکستان، بر اساس برخی از رویکردهای یادگیری

^۷ Overall Accuracy

^۸ User Accuracy

^۹ Producer Accuracy

^{۱۰} Kappa Statistics

^{۱۱} Estimating the distribution of probabilities

^{۱۲} Spatial Distribution

^۱ Earth Observation

^۲ Object-based

^۳ Maximum Likelihood Estimator

^۴ Spatial properties

^۵ Digital Elevation Model

^۶ Total Operating Characteristic

کارکرده‌اند. در مرحله اول از طبقه‌بندی خطی برای تصمیم‌گیری با استفاده از رگرسیون برداری استفاده کرده‌اند و در مرحله شبیه‌سازی، با توجه به متغیرهای مختلف، احتمال تغییرات کاربری زمین در شهر همدان پیش‌بینی کرده‌اند. این پژوهش، توسعه شهر همدان را تا سال ۲۰۴۰ پیش‌بینی کرد و نتایج این شبیه‌سازی در قالب نقشه‌های شطرنجی و همچنین محاسبه توسعه فیزیکی شهر در سال ۲۰۴۰، نشان داد که اگر تغییرات کاربری زمین با این روند شبیه‌سازی شده ادامه یابد، سطح زمین‌ساخته شده تا سال ۲۰۴۰ افزایش می‌یابد. در نهایت، به این نتیجه رسیده‌اند که مدل اتوماتای سلولی، بر اساس قوانین بردار انتقال رگرسیون پشتیبان، ابزاری مفید برای شبیه‌سازی دستگاه‌های شهری است.

مطالعه تحقیقاتی در رابطه با تغییرات کاربری زمین در شهر بلگراد، جمهوری صربستان با استفاده از تکنیک‌های یادگیری ماشین (ML) انجام شد که سه روش ML که در این مطالعه مورد بررسی قرار گرفته شامل درخت تصمیم‌گیری (DT)، شبکه‌های عصبی (NN) و ماشین‌های بردار پشتیبانی (SVM) بوده‌اند. عملکرد این سه الگوریتم طبقه‌بندی، با استفاده از حساسیت (نرخ مثبت واقعی)^۱، سقوط (نرخ مثبت کاذب)^۲، منحنی مشخصه عملکرد تحت گیرنده^۳ (AUC) ارزیابی شد [۷۱]. آماده‌سازی داده‌ها با استفاده از چندین ابزار نرم‌افزاری انجام شد. از محیط SAGA GIS [۷۲] و ArcGIS برای ایجاد پایگاه داده و ویژگی‌های فضایی، تجزیه و تحلیل داده‌ها و ارائه نتایج نهایی استفاده شد. تجزیه و تحلیل دقیق با استفاده از روش رتبه‌بندی IG برای یافتن آموزنده‌ترین ویژگی‌های مربوط به LUC در منطقه مورد مطالعه انجام شد. روش SVM بهترین روش برای پیش‌بینی تغییرات کاربری زمین بود، در حالی که روش DT قادر به یادگیری مفهوم عدم تغییر بهتر از دو روش دیگر بود. سرانجام، تفسیر روش DT را می‌توان ساده‌ترین روش نسبت به NN و SVM دانست.

گسترش علم مطالعه تغییرات زمین‌ها و وجود داده‌های بسیار بزرگ از این تغییرات در سال‌های اخیر مورد توجه محققان قرار گرفته است. شبیه‌سازی این تغییرات نیاز به یک مدل‌سازی دقیق دارد. داده‌های

گسترده برای مدل‌سازی باید به شکل صحیح و بهینه‌ای خوشه‌بندی شوند [۷۳]. با استفاده از خوشه‌بندی (k-mean) داده‌ها را دسته‌بندی کرده‌اند. این مقاله یک چارچوب مدل‌سازی بر اساس مدل‌های شبکه عصبی ارائه داد تا تغییرات را پیش‌بینی کند. این مطالعه برای ایالات متحده انجام گرفت. نتایج بهینه‌ای در مقایسه با مدل قدیمی (LTM) مشاهده شد.

در کشور اتیوپی نیز مطالعه‌ای مبنی بر تغییرات (LULC) انجام گرفت [۷۴]. یک آزمایش دقیق در مورد چگونگی بهبود دقت طبقه‌بندی تصویر با تلفیق تجزیه و تحلیل مؤلفه‌های اصلی (PCA) و کامپوزیت‌های شاخص‌های طیفی^۴ (CSI) بررسی شد. این مطالعه نشان داده است که سنجش‌ازدور و GIS ابزار کلیدی برای نظارت بر تغییرات LULC هستند. ثابت شده است که هر قطعه داده سنجش‌ازدور بسیار ارزشمند است تا زمانی که رویکردهای مختلف مطالعه برای استخراج اطلاعات مفید از داده‌های خام آزمایش شود. با بهبود دقت طبقه‌بندی، که با تقویت (PCA) با کامپوزیت‌های شاخص‌های طیفی به دست آمد، شاهد آن بودیم. در زمان مناسب این مطالعه می‌تواند وضعیت LULC و پویایی منطقه مورد مطالعه را برجسته کند، که می‌تواند به عنوان یک نقطه شروع برای تجزیه و تحلیل روند بیشتر، تدوین سیاست‌ها و برنامه‌ریزی آینده استفاده از زمین باشد.

یکی از مسائل مهمی که امروزه مسئولان کشور چین با آن مواجه هستند رها شدن زمین‌های روستایی است. عدم استفاده از این زمین‌ها در پی افزایش تمایل به شهرنشینی صورت می‌گیرد. برخی از این زمین‌های روستایی اولویت بیشتری برای رها شدن و بایر ماندن دارند. تحقیقات زیادی روی عوامل تأثیرگذار در رها کردن زمین‌های روستایی انجام شده است که می‌توان به سه دسته تقسیم شوند: الف) عوامل اقتصادی، اجتماعی و زیست‌محیطی؛ ب) مطالعاتی که بر مبنای تصویربرداری و استفاده از داده‌های تاریخی صورت می‌گیرند؛ ج) استفاده از مدل‌های آماری کاربری زمین [۷۵]. با استفاده از ابزار و مدل‌های یادگیری ماشین اقدام به دسته‌بندی زمین‌های کشاورزی برحسب اولویت رها شدن و همچنین پیش‌بینی وضعیت این زمین‌ها در آینده را دستور کار قرار داده‌اند.

^۱ TPrate

^۲ FPrate

^۳ Area Under the Curve

^۴ Composites of spectral indices

از مدل‌های معرفی شده بررسی می‌شود. نتایج این گونه است که مدل‌های CNN و CapsNet از نظر صحت پیش‌بینی، مدل‌های مناسبی برای نقشه‌برداری کاربری زمین هستند. به‌ویژه، CapsNet از منبع و زمان محاسباتی بسیار بیشتری نسبت به الگوریتم‌های مقایسه شده استفاده می‌کند. CNN با دقت ۹۸٪ قادر به طبقه‌بندی نقشه‌برداری از زمین در هر کیلومترمربع در کمتر از یک ثانیه است. در مطالعه موردی، CNN بیشتر ظرفیت خود را در نقشه‌برداری تصاویر ماهواره‌ای در کاربری‌های مختلف نشان می‌دهد.

با به وجود آمدن تصاویر ماهواره‌ای با کیفیت بالا^۲ (HSRI) از جمله کارکردهای روش‌های سنجش‌ازدور نقشه‌برداری از تغییرات پوششی و کاربری اراضی نواحی شهری است [۷۸]. طبقه‌بندی با استفاده از مدل‌های یادگیری ماشین برای ویژگی‌های کاربری زمین‌های شهری انجام داده شد، پیشرفت‌هایی را در برخی مدل‌ها نشان داد. از جمله مدل‌هایی که برای طبقه‌بندی تصاویر ماهواره‌ای استفاده شد می‌توان به جنگل تصادفی (RF)، رمزگذاری خودکار^۳ (RAE)، درخت دارای کیسه (BT)، یادگیری‌های مبتنی بر نمونه (EL)، ماشین بردار پشتیبان (SVM) و درختان تقویت‌کننده گرادیان^۴ (XGB) اشاره کرد. نتایج نشان داد که (GB) و (SVM) نتایج طبقه‌بندی بسیار دقیقی را به وجود آوردند. همچنین نشان داد که رمزگذاری خودکار (RAE) برای آموزش بدون نظارت، نه تنها باعث بهبود دقت طبقه‌بندی نمی‌شود، بلکه باعث کاهش دقت نیز می‌شود. این نکته قابل توجه بود که هنوز قابلیت‌های مدل‌های مختلف و تلفیق آن‌ها می‌تواند موضوع بحث‌های آینده باشد.

امروزه یکی از اکوسیستم‌هایی که به دلیل رشد کاربری زمین شهری به خطر افتاده است، اکوسیستم‌های آبی هستند. یکی از ابزارهای مدیریت و پیش‌بینی تغییرات کاربری‌های شهری و تأثیر آن بر روی حوزه‌های آبخیز استفاده از ابزار یادگیری ماشین است. تغییرپذیری یکپارچگی جریان‌ها نقش مهمی در حوزه‌های آبخیز دارند. [۷۹] در همین راستا با استفاده از مدل‌های جنگل تصادفی (RF) و درخت رگرسیون تقویت‌شده^۵ (BRT) به شناسایی عوامل مختل‌کننده از طرف زمین‌های شهری

این مطالعه یک رویکرد تلفیقی از مدل‌های ماشین بردار پشتیبان (SVM)، جنگل تصادفی (RF) و نیوی بیز (NB) ارائه داد. نتایج این مدل‌سازی بینش‌های بسیاری برای توسعه پروتکل‌های برنامه‌ریزی به‌منظور بهبود کیفیت زندگی و محیط زندگی در مناطق روستایی و همچنین برنامه‌ریزی صحیح برای مدیریت بهتر زمین‌های رهاشده برای مراجع و مراکز مربوطه ارائه داد.

[۷۶] در پژوهشی در شیرگاه واقع در شمال ایران، مدل تغییر کاربری زمین (LUC) را در سه مرحله؛ آموزش، آزمایش و اعتبار سنجی بررسی شد. همچنین در این بررسی تغییر کاربری زمین را با استفاده از تکنیک یادگیری ماشین؛ درخت طبقه‌بندی و رگرسیون (CART)، رگرسیون چند متغیره تطبیقی اسپلاین (MARS) و جنگل تصادفی (RF) مورد آزمایش قرار داده‌اند. بیشتر اطلاعات موردنیاز در این مطالعه نیز از تصاویر ماهواره‌ای موجود در پایگاه داده اپن استریت مپ به دست آمد و کل فرآیند مدل‌سازی و اعتبارسنجی در نرم‌افزار MATLAB برنامه‌ریزی شده است. نتایج نشان داد که MARS می‌تواند بهترین دقت را در مرحله اعتبار سنجی ارائه دهد در حالی که کمترین سطح دقت را در مرحله آزمایش دارد. RF بالاترین دقت را در اجرای آزمایش و کمترین سطح دقت را در مرحله اعتبار سنجی فراهم می‌کند.

تغییرات الگوهای زمین برای بخش‌های مختلف مانند جوامع کشاورز، صنعت، دولت، بخش خصوصی و مراکز تحقیقاتی از اهمیت بالایی برخوردار است. نقشه‌برداری ماهواره‌ای از این تغییرات و طبقه‌بندی این تصاویر در سال‌های متوالی برای پیش‌بینی تغییرات و یافتن یک روش نقشه‌برداری مؤثر برای نظارت و سرمایه‌گذاری وضعیت منابع طبیعی، کارایی کشاورزی، پایداری و برنامه‌ریزی، حفاظت از تنوع زیستی، مدیریت بلایای طبیعی و امنیت زیستی دستور کار بسیاری از مراکز بوده است. برای طبقه‌بندی تصاویر نقشه‌برداری ماهواره‌ای روش‌های زیادی وجود دارد که با استفاده از روش‌های کای نزدیک‌ترین همسایه (K-nearest)، ماشین بردار پشتیبان (SVM)، شبکه‌های عصبی کانولوشن^۱ (CNN) و (CapsNet) که به تازه گسترش یافته است، اقدام به دسته‌بندی تصاویر نموده است [۷۷]. به‌عنوان نمونه، یک منطقه کاشت موز با استفاده

^۲ High Quality satellite images

^۳ Recursive Auto-Encoder

^۴ XGBoost

^۵ Reinforced Regression Tree

^۱ Convolutional Neural Network

روی یکپارچگی حوزه آبخیز پرداخته‌اند. هر دو الگوریتم قادر به توضیح حداقل ۵۰٪ از تغییرپذیری داده‌های یکپارچگی جریان با استفاده از متغیرهای LULC بودند. یکی دیگر از کاربردهای سنجش‌ازدور کاربری زمین و تغییرات پوششی در شهر سرادو برزیل انجام شد [۸۰]. تکنیک‌های یادگیری ماشین استفاده‌شده شامل، درخت تصمیم‌گیری (DT)، طبقه‌بندی نیوی بیز (NB)، پرسپترون چندلایه^۱ (MLP) و ماشین بردار پشتیبان (SVM) است. این مطالعه برای ناحیه‌ای به مساحت ۳۶۶۰ کیلومترمربع انجام شد. نتایج طبقه‌بندی شامل (NB, DT) و (MLP, RF) در نظر گرفته شد، گروه دوم نتایج دقیق‌تری را ارائه دادند.

سرعت افزایش شهرنشینی در سال‌های اخیر تغییرات زیادی در جنبه‌های مختلف مانند اقتصاد، اجتماع، محیط‌زیست، جمعیت و منابع به وجود آورده است. کاربری زمین‌های شهری یکی از مواردی است که دستخوش این تغییرات قرار می‌گیرد. از جنبه‌های مهم این تغییر می‌توان به تغییر ارزش و قیمت زمین‌های شهری اشاره کرد. ارزش زمین عامل مهمی در تغییر کاربری زمین شهری است. اخیراً تعدادی از محققین بر روی ارزش‌گذاری زمین‌های شهری تمرکز کرده‌اند. داده‌های موجود برای ارزیابی ارزش زمین دامنه وسیعی دارد. مزایای تجزیه و تحلیل داده‌های بزرگ در مورد ارزش شامل دو بخش است؛ اول در نظرگیری تعداد زیادی از ویژگی‌ها و متغیرها و دوم نتایج دقیق‌تر [۸۱]. برای این منظور با استفاده از روش‌های غیرخطی یادگیری ماشین (ML) عوامل تأثیرگذار بر ارزش زمین در هر فوت مربع بر اساس "داده‌های بزرگ" در شهر نیویورک را بررسی کرده‌اند. شش الگوریتم یادگیری ماشین، از جمله جنگل تصادفی (RF)، درخت تصمیم‌گیری (DT)، رگرسیون چندخطی (MLR)، رگرسیون بردار پشتیبان خطی (SVR)، رگرسیون پرسپترون چندلایه (MLP) و رگرسیون K نزدیک‌ترین همسایه (KNN) ارزیابی و مقایسه شدند. در این تجزیه و تحلیل مدل‌های، جنگل تصادفی (RF) و درخت تصمیم‌گیری نتایج بهتری را ارائه داده‌اند. این نتایج، راهبردها و سیاست‌گذاری‌های مناسبی را در اختیار برنامه‌ریزان شهری برای تخصیص مجدد منابع و همچنین پیش‌های مناسبی برای اصلاح سیاست‌ها ارائه داد.

با توجه به کاربردهای سنجش از راه دور مانند مدیریت منابع زمین، توسعه شهری و حفاظت از طبیعت با استفاده از تصاویر از راه دور با کیفیت بالا (HRRS) استخراج ویژگی‌های مؤثر طبقه‌بندی و بهبود دقت طبقه‌بندی موضوع تحقیق [۸۲] بوده است. بر اساس فن یادگیری ماشین، یک روش یادگیری گروهی dropout-based در این مقاله بررسی شد که ترکیبی از شبکه عصبی کانولوشن (CNN) و دستگاه یادگیری شدید^۲ (ELM) است. این مدل گروهی یک راه‌حل دقیق و مؤثر در راستای طبقه‌بندی دقیق تصاویر ارائه داد.

ترکیب مطالعاتی بین کاربری زمین‌های شهری و تغییرات پوششی شهر یکی از ابعاد مهم پیش‌بینی کاربری زمین‌ها است. گستردگی نواحی شهری و نیاز به یک نظارت همه‌جانبه، امروزه استفاده از روش‌های سنجش از راه دور را بیشتر مطرح می‌کند [۸۳]. با استفاده از یک مدل کانولوشن (CNN) چندوظیفه‌ای اقدام به بررسی و طبقه‌بندی تصاویر کاربری‌های زمین‌های شهری کرد. همچنین این طبقه‌بندی را با مدل طبقه‌بندی جنگل تصادفی (RF) مقایسه شد. این شبکه چندوظیفه‌ای در لایه خروجی شبکه عصبی، ویژگی‌های کاربری و پوششی را باهم ادغام کرد و نتایج نشان داد که طبقه‌بندی کاربری زمین‌ها با تغییرات پوششی نقشه‌های طبقه‌بندی‌شده را بهبود بخشیده است. این مطالعه پیش‌بینی تغییرات پوششی شهری را نیز بهبود بخشید.

میرزاده و علی بخش [۸۴] طبقه‌بندی تصاویر و تهیه نقشه کاربری اراضی دشت مهریز استان ایلام را به روش شبکه عصبی مصنوعی کوهون انجام و تغییرات توسط مدل تحلیل زنجیره‌های مارکوف پیش‌بینی شد. نتایج طبقه‌بندی نشان دهنده تخریب و کاهش میزان وسعت اراضی جنگل کم تراکم و مرتع متوسط و افزایش مساحت سایر کاربری است. علاوه بر این، نتایج حاصل از ماتریس پیش‌بینی تغییرات بر مبنای نقشه‌های سالهای ۲۰۰۱ و ۲۰۱۳ نشان داد که احتمال می‌رود در فاصله زمانی ۲۰۳۰ الی ۲۰۱۳، ۴۵٪ جنگل کم تراکم، ۷۱٪ مرتع متوسط، ۹۶٪ مرتع فقیر، ۸۱٪ کشاورزی ۹۳٪ رسوبات آبرفتی و ۱۰۰٪ اراضی بدون پوشش بدون تغییر باقی بمانند.

^۲ Extreme Learning Machine

^۱ Multilayer perceptron

تعداد سلول‌های شهری موجود در همسایگی، فاصله از ۳×۳ گسل و فاصله از مراکز نواحی شهر بیشترین تأثیر را داشتند. نتایج حاصل از ارزیابی عملکرد توسط درصد تناظر صحیح، ضریب کاپا و درجه تناسب بیانگر دقت خیلی خوب طبقه‌بندی است [۸۹].

کامیاب و همکاران [۹۰] از یک مدل شبکه عصبی با الگوریتم پس انتشاری برای مدل‌سازی، شناسایی و بهبود درک ما از نیروهای اجتماعی - اقتصادی، فیزیکی و کاربری زمین که بر توسعه شهری تأثیر می‌گذارند، و نیز برای یافتن محتمل‌ترین مکان‌ها برای توسعه شهری آینده گرگان، مورداستفاده قرار گرفت. در این مدل از سه گروه پارامتر استفاده شد، و نتایج اعتبارسنجی مدل با ROC بیانگر معناداری متغیرهای کاربری زمین بر رشد شهری دوره زمانی ۲۰۰۱-۱۹۸۷ در گرگان بود.

در استان همدان نیز از شبکه‌های عصبی به‌منظور پیش‌بینی سری‌های زمانی داده‌های ماهواره‌ای سنجش‌ازدور استفاده شد. این تحقیق به‌منظور تهیه نقشه تغییر کاربری اراضی کشاورزی و سطح زیر کشت صورت گرفت. نتایج پیش‌بینی توسط ارزیابی صورت گرفته دارای صحت ۹۵٪ و خطای کمتر از ۰.۰۰۰۱ بود [۹۱].

در شرق استان مازندران [۹۲] مطالعه‌ای در رابطه با پیش‌بینی کاربری زمین با استفاده از شبکه عصبی مصنوعی در محیط GIS انجام شد. بررسی‌ها بر روی داده‌های حاصل از تصاویر ماهواره‌ای لندست سال‌های ۱۳۶۶ تا ۱۳۸۰ بود و با استفاده از پرسپترون چندلایه (MLP) و تغییرات کاربری زمین را تا ۱۳۹۴ پیش‌بینی کرد. ارزیابی مدل از انطباق زیاد تصویر پیش‌بینی شده مدل با تصویر واقعی خبر داد و به معنای خطای کم این مدل و کارایی خوب آن است. همچنین در مطالعاتی مشابه، در شهر ایلخچی استان آذربایجان شرقی با استفاده از تحلیل تصاویر لندست ۵ در بازه زمانی ۳۰ ساله تغییرات کاربری اراضی و توسعه شهری را بررسی کرد [۹۳].

پژوهشی باهدف پیش‌بینی تغییرات کاربری زمین با استفاده از اتوماتای سلولی (CA) و شبکه عصبی مصنوعی در شهر مشهد [۹۴] انجام شد. داده‌ها مربوط به سال‌های ۱۳۷۲ و ۱۳۹۰ جمع‌آوری و برای پیش‌بینی برای سال‌های ۱۴۰۸، ۱۴۲۶، ۱۴۴۴ و ۱۴۶۲ در محیط QGIS2.4 شبیه‌سازی شد. زیاد بودن شاخص اعتبارسنجی کاپا (۰.۸۲)، خطای کلی اعتبارسنجی حداقل معادل

با توجه به اهمیت طبقه‌بندی استفاده از کاربری زمین و تغییرات پوشش نیز با استفاده از الگوریتم‌های یادگیری ماشین اقدام به طبقه‌بندی بهینه عکس‌ها و نقشه‌های ماهواره‌ای شده است [۸۵]. در این مقاله از مدل‌های ماشین بردار پشتیبان (SVM) و کای میانگین فازی (FKM) بهره گرفته شده است. این الگوریتم‌ها دقت بالایی در طبقه‌بندی را نشان دادند.

در راستای توسعه شهری در استان تهران، صوفی و همکاران [۸۶] مدل‌سازی عامل‌مبنا (ABM) را به جهت داشتن دیدگاه فردگرا، انعطاف‌پذیری و قابلیت انطباق با محیط و الگو گرفتن از آن و پویا بودن انتخاب کرده‌اند. عامل‌های این مدل قطعات زمین، محدودیت‌های فیزیکی، تناسب و محدوده حفاظتی بود. این عامل‌ها قادر بودند در هر گام زمانی وضعیت خود را از توسعه‌نیافته به توسعه یافته تغییر دهند. ارزیابی انجام شده نتایج مثبتی را برای مطلوبیت عوامل مختلف توسعه شهری نشان داد. ترکیب مدل‌سازی عامل‌مبنا و مدل‌های دیگر می‌تواند دقت و بهره‌وری مدل را افزایش دهد.

در همین راستا، در سال ۱۳۹۴ کاویاری و همکاران [۸۷] یک مدل تلفیقی از الگوریتم ذرات^۱ (PSO) و مدل‌های عامل‌مبنا (ABM) را برای توسعه زمین‌های شهری ارائه داده‌اند. در این مطالعه توسعه شهر زنجان در یک بازه زمانی ۱۰ ساله بررسی شد. نتایج مدل با در نظرگیری عامل روابط اجتماعی فرد، با شاخص کاپا دقت پیش‌بینی ۷۴٪ را نشان داد.

استفاده از مدل‌های عامل‌مبنا در سالیان اخیر توجه زیادی پیدا کرده است که می‌توان به یک برنامه آینده‌نگر برای استفاده از زمین‌های مسکونی شهر شنزن چین با استفاده از مدل‌سازی عامل‌مبنا اشاره کرد. در این پژوهش اعتبارسنجی مدل پیش‌بینی برای بازه زمانی ۲۰۱۵ الی ۲۰۳۵ کاربرد مدل برای تدوین برنامه‌ریزی دقیق زمین‌های مسکونی و خدمات عمومی و ارزیابی اثربخشی برنامه‌ریزی کاربری زمین را نشان داد [۸۸].

در شهر سمنجان ایران، از یک مدل‌سازی رگرسیون لجستیک و شبکه عصبی برای طبقه‌بندی تصاویر ماهواره‌ای و اطلاعات مکانی استفاده شد. در این مدل پارامترهای فاصله از راه‌های اصلی، فاصله از فضای سبز، ارتفاع، شیب،

^۱ Particle Swarm Optimization

۰۰۴۶ و شاخص دقت کلی منفی در این شبیه‌سازی نتیجه می‌شود که اعتبار و دقت این روش بالاست. همچنین نتایج خبر از افزایش کنترل نشده اراضی کشاورزی و مراتع و تبع آن خشک شدن سکونتگاه‌های روستایی خبر داد که یک معضل بزرگ برای محیط‌زیست در آینده این شهر است و به مدیریت و برنامه‌ریزی نیاز دارد.

در استان گیلان نیز از تصاویر لندست برای بررسی میزان تغییرات پوشش سرزمین و پیش‌بینی کاربری اراضی شهر رشت استفاده شد. مدل‌های شبکه عصبی و سلول‌های خودکار زنجیره مارکوف با در نظرگیری پارامترهای نزدیکی به راه‌های اصلی، فاصله از رودخانه، طبقات ارتفاعی، شیب و فاصله از روستاهای اطراف به دقت ضریب کاپای ۸۲٪ الی ۸۷٪ دست یافتند [۹۵]. در مطالعه‌ای مشابه، ارزیابی میزان

و جهت و پیش‌بینی تغییرات اراضی و پوشش گیاهی در دو شهر تفت و مهریز استان یزد توسط داده‌های تصاویر سنجنش‌ازدور و پیش‌بینی توسط شبکه‌های عصبی بررسی شد. تغییرات اراضی و پوشش گیاهی در شهر تفت بیشتر از شهر مهریز بود به طوری که بیشترین تغییرات مربوط به باغ‌ها بوده است اما به لحاظ گسترش شهری از لحاظ مساحت و تبدیل کاربری‌ها، شهر مهریز دارای بیشترین مقدار بود [۹۶].

مجموعه نتایج تفکیکی مقاله‌های مروری به زبان انگلیسی در جدول ۱ آورده شده است. همچنین نتایج کلی در رابطه با مقالات فارسی داخل کشور در جدول ۲ ارائه گردیده است.

جدول ۱- نتایج حاصل از مقالات مرور شده به زبان انگلیسی

نام نویسندگان	سال انتشار	زمینه تحقیق در رابطه با کاربری زمین	روش‌های یادگیری ماشین	نتیجه ارزیابی
یانگ ^۱ و همکاران [۶۲]	۲۰۰۸	شبیه‌سازی	SVM بر پایه CA	SVM ابزاری مفید
بن و دراگچویچ ^۲ [۶۴]	۲۰۰۹	مدل‌سازی	RL	RL ابزاری مفید
طیبی و پیجانوسکی [۹]	۲۰۱۳	شبیه‌سازی	ANN, CART, MARS	ANN بهترین دقت و MARS و CRT توضیح واضح‌تر
پورسندیس ^۳ و همکاران [۶۶]	۲۰۱۴	طبقه‌بندی	MLE, SVM, k-Nearest Neighbor	SVM بهترین ابزار
سون ^۴ و همکاران [۸۵]	۲۰۱۴	طبقه‌بندی	FKM, SVM	FKM, SVM دقیق.
وانگ ^۵ و همکاران [۶۵]	۲۰۱۵	طبقه‌بندی	k-mean, k-Nearest Neighbor, ANN, SVM	نیمه نظارت‌شده و SVM نتایج بهتر
احمدلو و همکاران [۶۷]	۲۰۱۶	شبیه‌سازی	ANN, CART	ANN موفق‌تر
علی و همکاران [۶۸]	۲۰۱۶	طبقه‌بندی	ANN, MLE, SVM	SVM بهترین ابزار
سیتھی ^۶ و همکاران [۶۹]	۲۰۱۶	طبقه‌بندی	NB	NB دقت مناسب.
حاجی بابایی و ذاکر حقیقی [۷۰]	۲۰۱۷	شبیه‌سازی	SVM بر پایه CA	SVM ابزاری مفید
ایچ پتروویچ ^۷ و همکاران [۵]	۲۰۱۷	پیش‌بینی	DT, NN, SVM	SVM بهترین ابزار و DT ساده‌ترین روش
تفرا ^۸ و همکاران [۷۴]	۲۰۱۷	طبقه‌بندی	PCA	PCA ابزار مفید
عمرانی ^۹ [۷۳]	۲۰۱۸	پیش‌بینی	k-mean	K-mean ابزاری مفید
لی ^{۱۰} و همکاران [۸۸]	۲۰۱۹	پیش‌بینی	ABM	نتایج دقیق
زو و همکاران [۷۵]	۲۰۱۹	طبقه‌بندی و پیش‌بینی	NB, RF, SVM	NB, RF, SVM ابزار مفید
احمدلو و همکاران [۷۶]	۲۰۱۹	مدل‌سازی	CART, MARS, RF	RF بهترین روش

^۱ Q. Yang

^۲ C. Bone and S. Dragičević

^۳ D. Poursanidis

^۴ Y. Sun

^۵ C. Wang

^۶ A. Sittthi

^۷ M. S. ić-Petrović

^۸ Z. L. Teffera

^۹ H. Omrani

^{۱۰} F. Li

جدول ۱- نتایج حاصل از مقالات مرور شده به زبان انگلیسی

نام نویسندگان	سال انتشار	زمینه تحقیق در رابطه با کاربری زمین	روش های یادگیری ماشین	نتیجه ارزیابی
لیاو و همکاران [۷۷]	۲۰۱۹	طبقه بندی	k-Nearest Neighbor, SVM, CNN, CapsNet	CNN و CapsNet بهترین ابزار
جدزانی و همکاران [۷۸]	۲۰۱۹	طبقه بندی	RF, RAE, BT, EL, SVM, GB	GB و SVM دقیق ترین نتایج
گیری و همکاران [۷۹]	۲۰۱۹	پیش بینی	RF, BRT	RF, BRT با نتایج تقریباً مفید
کامرگو و همکاران [۸۰]	۲۰۱۹	پیش بینی	DT, NB, MLP, SVM	SVM و MLP نتایج بهتر
ما و همکاران [۸۱]	۲۰۲۰	پیش بینی	RF, DT, MLR, SVR, MLP, k-Nearest Neighbor	RF و DT نتایج بهتر
ژانگ و همکاران [۸۲]	۲۰۲۰	طبقه بندی	CNN, IELM	CNN, IELM دقیق
برگاردو و همکاران [۸۳]	۲۰۲۰	طبقه بندی و پیش بینی	CNN, RF	CNN بهترین روش

از جمع آوری مقاله های زبان انگلیسی در جدول ۱ می-توان نتیجه گرفت که در میان استفاده از روش های مختلف یادگیری ماشین برای طبقه بندی، شبیه سازی، مدل سازی و پیش بینی تغییرات کاربری زمین باگذشت زمان روش های مبتنی بر شبکه های عصبی کاربرد بیشتر و دقت بهتری داشته است. همچنین، باتوجه به بررسی مطالعات در طول

سال های ۲۰۰۸ تا ۲۰۲۰ میلادی، مشخص شد که روش-های ANN، CART، SVM، روش های قدیمی تری هستند و روش CNN روشی جدید است که بیشتر مورد استفاده قرار گرفته است. می توان گفت که روش ها و الگوریتم های جدید مبتنی بر شبکه های عصبی محبوبیت ویژه ای در حل مسائل برنامه ریزی کاربری زمین پیدا کرده اند.

جدول ۲- نتایج حاصل از مقالات مرور شده به زبان فارسی

مقاله مربوطه	شهر/استان مربوطه	سال انتشار	زمینه تحقیق در رابطه با کاربری زمین	روش های یادگیری ماشین	نتیجه ارزیابی
کامیاب و همکاران [۹۰]	گلستان	۱۳۹۰	مدل سازی	ANN	ANN نتایج معنادار
سفینیان و همکاران [۹۱]	همدان	۱۳۹۰	پیش بینی و طبقه بندی	MLP	دقت طبقه بندی و پیش بینی بالای ۸۰٪
محمدی و دلاور [۸۹]	سنندج	۱۳۹۳	طبقه بندی	LR, NN	LR, NN دقت خیلی خوب
داداش پور و جهان زاده [۹۴]	خراسان	۱۳۹۵	شبیه سازی	CA, NN	دقت بالا
میرزاده و علی بخش [۸۴]	دهلران	۱۳۹۵	پیش بینی و طبقه بندی	ANN و زنجیره مارکوف	نتایج پیش بینی با دقت مناسب و طبقه بندی کاربردی
کاواری و همکاران [۸۷]	زنجان	۱۳۹۶	پیش بینی	PSO, ABM	تلفیق PSO, ABM دقت قابل قبول
جورابیان شوشتری و همکاران [۹۲]	مازندران	۱۳۹۷	پیش بینی	NN, MLP	نتایج با خطای کم و کارایی مناسب
محمود زاده و رنجبر نوازی [۹۳]	ایلیخچی	۱۳۹۷	پیش بینی	ANN	نتایج کاربردی و دقیق
صوفی و همکاران [۸۶]	تهران	۱۳۹۸	مدل سازی	ABM	دقت بالا در ترکیب ABM و مدل های دیگر
سپهری و همکاران [۹۶]	تفت و مهریز	۱۳۹۸	پیش بینی	ANN	نتایج دقیق پیش بینی برای هر دو شهر
اکبری و همکاران [۹۵]	رشت	۱۳۹۸	پیش بینی	MLP و زنجیره مارکوف	پیش بینی با دقت بالا

با جمع بندی مقالات به زبان فارسی داخل کشور در جدول ۲ نیز مشاهده شد که از روش های مربوط به یادگیری ماشین بیشتر برای پیش بینی تغییرات کاربری زمین استفاده شده است. همچنین روش هایی مانند

ANN، NN، MLP و زنجیره مارکوف بیشترین مطلوبیت را در مطالعات مربوط به ایران را داشته اند. همچنین، روش های عامل مبنا در میان مطالعات کشور ایران کاربرد کمتری داشته است. در نهایت، با بررسی مقالات مربوطه،

نقاط قوت و ضعف مدل‌های یادگیری ماشین و مدل‌های عامل مبنا در کاربردهای برنامه‌ریزی کاربری اراضی مطابق جدول ۳ بیان شده است. می‌توان نتیجه گرفت که مدل‌های عامل مبنا و مدل‌های شبکه‌های عصبی با توجه به ساختار منعطف خود کاربردهای وسیع‌تری در حوزه برنامه‌ریزی کاربری زمین دارند.

جدول ۳- نقاط قوت و ضعف مدل‌های یادگیری ماشین و مدل‌های عامل مبنا

نقاط ضعف	نقاط قوت	مدل
<ul style="list-style-type: none"> • مراحل پیاده‌سازی مشکل • پیچیدگی فوق‌العاده رفتارهای انسانی در برنامه‌ریزی کاربری زمین • عدم مدل‌سازی کامل رفتار انسان • دشواری مدل‌سازی تمامی عامل‌های تأثیرگذار بر مسائل کاربری زمین 	<ul style="list-style-type: none"> • عملکرد جزء به کل • قابلیت شبیه‌سازی تصمیم‌گیری • تنوع • انعطاف‌پذیری بالا • در نظرگیری رفتار عامل‌های مرتبط با انسان • بررسی طیف گسترده‌ای از مسائل 	مدل‌های عامل مبنا
<ul style="list-style-type: none"> • وقت‌گیر بودن برچسب‌گذاری • عملکرد ضعیف‌تر نسبت به مدل‌های شبکه عصبی در مسائل پیش‌بینی تغییرات کاربری زمین 	<ul style="list-style-type: none"> • برچسب‌گذاری داده‌ها برای افزایش دقت مدل‌ها • مناسب موضوعات طبقه‌بندی در برنامه‌ریزی کاربری زمین • عملکرد مناسب در ترکیب با مدل‌ها دیگر یادگیری ماشین 	روش‌های نظارت‌شده
<ul style="list-style-type: none"> • نیازمند حجم داده زیاد • زمان‌بر بودن مرحله آموزش مدل 	<ul style="list-style-type: none"> • بدون نیاز به برچسب‌گذاری برای تشخیص الگو • تشخیص بهتر ناهنجاری‌ها و پیچیدگی‌های داده‌ها • قابلیت کاهش ابعاد 	روش‌های نظارت‌نشده
<ul style="list-style-type: none"> • مراحل آموزش وقت‌گیر • حساس به پارامترها • بروز خطا در هنگام وجود داده با نویز بالا 	<ul style="list-style-type: none"> • آزادی عمل بهتر نسبت به مدل‌های نظارت‌شده و نظارت‌نشده • داده‌های کمتر • پیچیدگی محاسباتی کمتر نسبت به رویکردهای شبکه عصبی • عملکرد مناسب در طبقه‌بندی 	روش‌های نیمه نظارت‌شده
<ul style="list-style-type: none"> • نیاز به داده زیاد • عدم دسترسی به بهترین راندمان ممکن 	<ul style="list-style-type: none"> • در نظرگیری پارامترهای زیاد برای افزایش دقت مدل • امکان آموزش برخط • درجه کاوش بالا 	مدل‌های مبتنی بر یادگیری ماشین
<ul style="list-style-type: none"> • مناسب موضوعات خاص کاربری زمین • کاربرد ضعیف‌تر نسبت به مدل‌های انفرادی • انعطاف‌پذیری کمتر • فرایند محاسباتی پیچیده 	<ul style="list-style-type: none"> • مناسب برای ترکیب با مدل‌های دیگر و افزایش دقت • غیر حساس به تنوع داده‌های آموزش • پتانسیل کاهش خطای داده‌های طبقه‌بندی 	یادگیری گروهی
<ul style="list-style-type: none"> • نیاز به حجم داده زیاد • فرایند پیچیده • حساس به تنظیم پارامترها 	<ul style="list-style-type: none"> • قابلیت عملکرد غیرخطی • قابلیت استفاده برای مسائل پویا • دقت بالا در درک و پردازش تصویر • عملکرد دقیق در رویکردهای پیش‌بینی تغییرات کاربری اراضی 	شبکه‌های عصبی
<ul style="list-style-type: none"> • کاهش دقت مدل با افزایش داده‌ها • آموزش ضعیف داده‌های ورودی • روند کند 	<ul style="list-style-type: none"> • عملکرد مناسب برای مسائل طبقه‌بندی • دقت زیاد در ترکیب با الگوریتم‌های دیگر • ساده، کارآمد و پیاده‌سازی آسان 	یادگیری مبتنی بر نمونه


مسائل طبقه‌بندی، پیش‌بینی، مدل‌سازی و شبیه‌سازی بوده‌اند. البته مشخص شد که با توجه به پارامترهای مختلف مسائل کاربری اراضی با قطعیت نمی‌توان یک روش واحد را به عنوان کارآمدترین روش در نظر گرفت. به‌عنوان مثال نمی‌توان انتظار داشت که روشی که در طبقه‌بندی تصاویر تغییرات کاربری اراضی در یک منطقه دارای جواب مناسبی است در مسائل پیش‌بینی روند تغییرات هم دقیق عمل کند.

در این مقاله، پس از مرور روش‌های مختلف تغییر کاربری اراضی، این نتایج به دست آمد که بهترین روش برای طبقه‌بندی تغییر کاربری زمین به ترتیب: SVM، NB، RF، PCA، CNN، GB، IELM و FKM است. بهترین روش‌ها برای پیش‌بینی تغییر کاربری زمین به ترتیب: SVM، k-mean، NB، RF، MLP، DT و CNN است. بهترین روش برای شبیه‌سازی تغییر کاربری زمین؛ SVM بر پایه CA و ANN است و در نهایت بهترین روش برای مدل‌سازی تغییر کاربری زمین؛ RL و RF و ABM است. همچنین مشخص شد که در مجموع روش ماشین بردار پشتیبان (SVM) و شبکه‌های عصبی (CNN) به‌عنوان روش‌های پرکاربرد و با ارائه بهترین نتایج، راه‌حل‌های مفیدی برای طبقه‌بندی، پیش‌بینی و شبیه‌سازی کاربری زمین ارائه کردند و مورد اقبال پژوهشگران بوده‌اند.

در نهایت می‌توان گفت که، درک محدودیت‌های حاکم بر مدل‌ها، مسائل مختلف تغییر کاربری اراضی و نوع ناحیه مورد مطالعه می‌توانند کمک قابل توجهی به برنامه‌ریزی‌های آینده نواحی کند. همچنین، سناریوسازی با این مدل‌ها در ارزیابی اثرات انواع توسعه و انتخاب بهترین آن‌ها از جنبه‌های مختلف لازم و ضروری خواهد بود.

۶- پیشنهادها کاربردی

رشد روزافزون جمعیت، رشد هوشمند شهرها، تغییرات گسترده در کاربری زمین، پوشش مناطق، مهاجرت مردم به سمت شهرها با در نظر گیری مفاهیم توسعه پایدار نیازمند توجه جدی متخصصان شهری است. با توجه به نتایج این مقاله، پیشنهاد می‌شود روش‌های جدید یادگیری ماشین که به‌طور هدفمند، دقیق و بهینه برنامه‌ریزی شده‌اند، به عنوان رویکردی نوین و قابل اتکا در



شکل ۵- میزان استفاده از روش‌های یادگیری ماشین در مطالعات کاربری زمین

مطابق شکل ۵ روش‌های ANN و SVM و ترکیبی از این مدل‌ها سهم به‌سزایی در بین تحلیل و مدل‌سازی مقالات بررسی شده داشتند. و مطلوبیت استفاده از روش ANN با دیگر روش‌ها فاصله زیادی داشت.

۵- نتیجه‌گیری

پیشرفت علوم داده کمک شایانی به آسان شدن برنامه‌ریزی در زمینه‌های مختلف توسط محققین کرده است. هوش مصنوعی شاخه‌ای از علم رایانه و فناوری است که به ابزاری گفته می‌شود که می‌تواند واکنش‌هایی مشابه رفتارهای انسانی از جمله؛ درک شرایط، تحلیل موقعیت‌ها و شبیه‌سازی فرایندها را داشته باشند. یادگیری ماشین نیز شاخه‌ای از هوش مصنوعی است که با ذخیره داده‌ها، تشخیص الگوریتم‌ها و نتایج حاصل از آن، به یک فرایند معین می‌رسد و با استفاده از آن الگو داده‌های ورودی را تحلیل می‌کند. یادگیری ماشین روش‌های مختلفی مانند، روش‌های نظارت‌شده، روش‌های نظارت‌نشده، روش‌های نیمه نظارت‌شده، روش‌های یادگیری تقویتی، یادگیری مبتنی بر نمونه، آموزش چندوظیفه‌ای و یادگیری گروهی دارد.

یادگیری ماشین در فرایند تغییر کاربری زمین، الگوریتم‌هایی را پیشنهاد می‌دهد، به همین منظور در مقاله مروری حاضر، ۳۴ مقاله مرتبط با بحث کاربرد یادگیری ماشین در کاربری زمین مورد بررسی قرار گرفت. هدف از پژوهش حاضر، مقایسه الگوریتم‌های یادگیری ماشین و مدل‌سازی عامل مبنا برای بررسی نحوه عملکرد آن‌ها در فرایند برنامه‌ریزی و شناخت الگوی تغییرات کاربری اراضی بود. نتایج نشان داد که روش‌های بررسی شده، قادر به حل سریع‌تر و کاراتر مسائل کاربری زمین در

تعریف مسائل و حل مشکلات مختلف موجود به تحقیقات آینده جهت دهند. به عنوان نمونه؛

- می‌توان از روش‌های یادگیری ماشین برای طبقه‌بندی و درک بهتر فرایندهای پراکندگی زمین در مناطق شهری و روستایی استفاده کرد. با استفاده از تکنیک‌های جدید یادگیری ماشین طبقه‌بندی پیشرفته‌تر تصاویر ماهواره‌ای در کاربری‌های مختلف با وضوح بالاتر، در اختیار محققان قرار می‌گیرد و خطاها را به حداقل می‌رساند.

- همچنین با استفاده از این روش‌ها در شبیه‌سازی سیستم‌های رشد شهری، پیشنهاد می‌شود که مناطق مختلف شهر در نظر گرفته شده و با یکدیگر مقایسه شوند. این مدل‌سازی می‌تواند وضعیت شهرها و تغییرات کاربری زمین را در آینده به شکل کارایی شبیه‌سازی کند.

- این نکته حائز اهمیت است که استفاده از تنها یک مدل ممکن است ایده آل نباشد و مدل‌ها بتوانند مکمل یکدیگر باشند. استفاده از دو یا چند ابزار قدرتمند یادگیری ماشینی به تقویت توضیح روند پیچیده در تغییرات کاربری زمین کمک می‌کند و خطاها را کاهش دهد.

- مدل‌سازی تغییرات کاربری زمین توسط ابزار یادگیری ماشین، در راستای حفاظت از سیاست‌های یکپارچگی زمین‌های روستایی از طرح‌های هدفمند برای کاهش ضرر روی زمین‌های کشاورزی و توسعه روستایی می‌تواند تعریف شود. بنابراین، هدایت تغییرات کاربری اراضی برای اهداف

مختلف مانند شهرنشینی متراکم و مناطق بوم گردی پایدار، می‌توانند هدف پژوهش محققان قرار گیرند.

- تأثیر تغییر کاربری زمین و تغییرات پوششی بر روی حیات وحش نواحی مختلف با استفاده از تکنیک‌های یادگیری ماشین و هوش مصنوعی کمک شایانی به زیستگاه‌ها خواهد کرد.

- فرسایش بادی از مهم‌ترین عوامل تخریب خاک در نواحی خشک و نیمه‌خشک و یکی از جدی‌ترین مشکلات زیست‌محیطی جهان به شمار می‌رود. توانایی پیش‌بینی دقیق فرسایش بادی خاک برای بسیاری منظرها از جمله برنامه‌های حفاظتی، منابع طبیعی و کاهش آلودگی هوا ضروری است. استفاده از تکنیک‌های یادگیری ماشین برای داده‌های سنجش‌ازدور و مدل‌سازی صحیح می‌تواند راه‌حل‌های بسیاری را ارائه دهد. با توجه به‌مرور انجام‌شده در مقاله حاضر، مطالعات انجام‌شده در زمینه‌ی فرسایش بادی در ایران بسیار اندک و پراکنده است؛ از این‌رو، هرگونه پژوهش در این زمینه برای ایران که بخش زیادی از آن را مناطق خشک و نیمه‌خشک فراگرفته ضرورتی انکارناپذیر است.

- نتایج تحقیق حاضر بیانگر این است که ابزار یادگیری ماشین می‌توانند در موضوعاتی مانند، تشویق به توسعه‌ی متراکم شهری، تشویق توسعه‌ی درون بافتی، تلاش برای انطباق تغییرات کاربری با برنامه‌ریزی حمل‌ونقل و تجدید حیات حومه‌ها، مراکز شهری و مناطق تجاری قدیمی موردبحث در تحقیقات آتی پژوهش‌گران قرار گیرند.

مراجع

- [1] J. D. Marshall, T. E. McKone, E. Deakin, and W. W. Nazaroff, "Inhalation of motor vehicle emissions: Effects of urban population and land area," *Atmos. Environ.*, vol. 39, no. 2, pp. 283–295, Jan. 2005, doi: 10.1016/j.atmosenv.2004.09.059
- [2] C. Agarwal, G. M. Green, J. M. Grove, T. P. Evans, and C. M. Schweik, "A Review and Assessment of Land-Use Change Models: Dynamics of Space, Time, and Human Choice," *Apollo Int. Mag. Art Antiq.*, p. 62, 2002, [Online]. Available: <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.86.2775&rep=rep1&type=pdf>.
- [3] P. H. Verburg, P. P. Schot, M. J. Dijst, and A. Veldkamp, "Land use change modelling: Current practice and research priorities," *GeoJournal*, vol. 61, no. 4, pp. 309–324, 2004, doi: 10.1007/s10708-004-4946-y.
- [4] J. L. Toole, M. Ulm, M. C. González, and D. Bauer, "Inferring land use from mobile phone activity," *Proc. ACM SIGKDD Int. Conf. Knowl. Discov. Data Min.*, pp. 1–8, 2012, doi: 10.1145/2346496.2346498.
- [5] M. S. ić-Petrović, M. Kovačević, B. Bajat, and S. Dragičević, "Machine learning techniques for modelling short term land-use change," *ISPRS Int. J. Geo-Information*, vol. 6, no. 12, 2017, doi: 10.3390/ijgi6120387.
- [6] K. E. Medley, B. W. Okey, G. W. Barrett, M. F. Lucas, and W. H. Renwick, "Landscape change with agricultural intensification in a rural watershed, southwestern Ohio, U.S.A.," *Landscape Ecol.*, vol. 10, no. 3, pp. 161–176, 1995, doi: 10.1007/BF00133029.
- [7] G. H. J. De Koning, P. H. Verburg, A. Veldkamp, and L. O. Fresco, "Multi-scale modelling of land use change dynamics in Ecuador," *Agric. Syst.*, vol. 61, no. 2, pp. 77–93, Aug. 1999, doi: 10.1016/S0308-521X(99)00039-6.

- [8] M. Pal, "Extreme-learning-machine-based land cover classification," *Int. J. Remote Sens.*, vol. 30, pp. 3835–3841, 2009.
- [9] A. Tayyebi and B. C. Pijanowski, "Modeling multiple land use changes using ANN, CART and MARS: Comparing tradeoffs in goodness of fit and explanatory power of data mining tools," *Int. J. Appl. Earth Obs. Geoinf.*, vol. 28, no. 1, pp. 102–116, 2014, doi: 10.1016/j.jag.2013.11.008.
- [10] M. I. Jordan and T. M. Mitchell, "Machine learning: Trends, perspectives, and prospects," *Science (80-.)*, vol. 349, no. 6245, pp. 255–260, 2015.
- [11] N. Wu and E. A. Silva, "Artificial intelligence solutions for urban land dynamics: A review," *J. Plan. Lit.*, vol. 24, no. 3, pp. 246–265, 2010, doi: 10.1177/0885412210361571.
- [12] B. Pradhan, "A comparative study on the predictive ability of the decision tree, support vector machine and neuro-fuzzy models in landslide susceptibility mapping using GIS," *Comput. Geosci.*, vol. 51, pp. 350–365, Feb. 2013, doi: 10.1016/j.cageo.2012.08.023.
- [13] Z. S. Pourtaghi, H. R. Pourghasemi, R. Aretano, and T. Semeraro, "Investigation of general indicators influencing on forest fire and its susceptibility modeling using different data mining techniques," *Ecol. Indic.*, vol. 64, pp. 72–84, 2016, doi: 10.1016/j.ecolind.2015.12.030.
- [14] M. Leuenberger and M. Kanevski, "Extreme Learning Machines for spatial environmental data," *Comput. Geosci.*, vol. 85, pp. 64–73, 2015, doi: 10.1016/j.cageo.2015.06.020.
- [15] G. Corani, "Air quality prediction in Milan: Feed-forward neural networks, pruned neural networks and lazy learning," *Ecol. Modell.*, vol. 185, no. 2–4, pp. 513–529, 2005, doi: 10.1016/j.ecolmodel.2005.01.008.
- [16] A. P. Bradley, "The use of the area under the ROC curve in the evaluation of machine learning algorithms," *Pattern Recognit.*, vol. 30, no. 7, pp. 1145–1159, Jul. 1997, doi: 10.1016/S0031-3203(96)00142-2.
- [17] H. Jamshid Moghadam and M. Mohammady Oskuei, "An Overview of Nonlinear Spectral Unmixing Methods in the Processing of Hyperspectral Data," *J. Geomatics Sci. Technol.*, vol. 10, no. 1, pp. 1–26, 2020, [Online]. Available: <http://jgst.issge.ir/article-1-846-en.html>.
- [18] K. Alexandridis and B. C. Pijanowski, "Assessing Multiagent Parcelization Performance in the MABEL Simulation Model Using Monte Carlo Replication Experiments," *Environ. Plan. B Plan. Des.*, vol. 34, no. 2, pp. 223–244, Apr. 2007, doi: 10.1068/b31181.
- [19] C. Washington-Ottombre et al., "Using a role-playing game to inform the development of land-use models for the study of a complex socio-ecological system," *Agric. Syst.*, vol. 103, no. 3, pp. 117–126, Mar. 2010, doi: 10.1016/j.agsy.2009.10.002.
- [20] T. K. Ho, "Complexity of classification problems and comparative advantages of combined classifiers," in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 2000, vol. 1857 LNCS, pp. 97–106, doi: 10.1007/3-540-45014-9_9.
- [21] M. Ahmadiou and M. R. Delavar, "Multiple Land Use Change Modeling Using Multivariate Adaptive Regression Spline and Geospatial Information System," *J. Geomatics Sci. Technol.*, vol. 5, no. 2, pp. 131–146, 2015, [Online]. Available: <http://jgst.issge.ir/article-1-294-en.html>.
- [22] Z. Gong, J. C. Thill, and W. Liu, "ART-P-MAP Neural Networks Modeling of Land-Use Change: Accounting for Spatial Heterogeneity and Uncertainty," *Geogr. Anal.*, vol. 47, no. 4, pp. 376–409, 2015, doi: 10.1111/gean.12077.
- [23] S. A. Oke, "A literature review on artificial intelligence," *Int. J. Inf. Manag. Sci.*, vol. 19, no. 4, pp. 535–570, 2008.
- [24] S. A. Kalogirou, *Artificial intelligence for the modeling and control of combustion processes: a review*, vol. 29. 2003.
- [25] A. Bilski, "A review of artificial intelligence algorithms in document classification," *Int. J. Electron. Telecommun.*, vol. 57, no. 3, pp. 263–270, 2011, doi: 10.2478/v10177-011-0035-6.
- [26] *iss, Multiagent systems: a modern approach to distributed artificial intelligence*. MIT press, 1999.
- [27] R. Nishant, M. Kennedy, and J. Corbett, "Artificial intelligence for sustainability: Challenges, opportunities, and a research agenda," *Int. J. Inf. Manage.*, vol. 53, no. March, p. 102104, 2020, doi: 10.1016/j.ijinfomgt.2020.102104.
- [28] M. Huston, D. DeAngelis, and W. Post, "New computer models unify ecological theory: computer simulations show that many ecological patterns can be explained by interactions among individual organisms," *Bioscience*, vol. 38, no. 10, pp. 682–691, 1988.
- [29] J. Ferber and G. Weiss, *Multi-agent systems: an introduction to distributed artificial intelligence*, vol. 1. Addison-Wesley Reading, 1999.

- [30] A. Ligmann-Zielinska and P. Jankowski, "Agent-based models as laboratories for spatially explicit planning policies," *Environ. Plan. B Plan. Des.*, vol. 34, no. 2, pp. 316–335, 2007.
- [31] D. C. Parker, S. M. Manson, M. A. Janssen, M. J. Hoffmann, and P. Deadman, "Multi-agent systems for the simulation of land-use and land-cover change: a review," *Ann. Assoc. Am. Geogr.*, vol. 93, no. 2, pp. 314–337, 2003.
- [32] A. Dey, "Machine Learning Algorithms: A Review," *Int. J. Comput. Sci. Inf. Technol.*, vol. 7, no. 3, pp. 1174–1179, 2016.
- [33] J. G. Carbonell, R. S. Michalski, and T. M. Mitchell, *An Overview of Machine Learning*. Morgan Kaufmann., 1983.
- [34] M. Metcalf, "A first encounter with f90," *ACM SIGPLAN Fortran Forum*, vol. 11, no. 1, pp. 24–32, 1992, doi: 10.1145/134304.134306.
- [35] R. Begg and J. Kamruzzaman, "A machine learning approach for automated recognition of movement patterns using basic, kinetic and kinematic gait data," *J. Biomech.*, vol. 38, no. 3, pp. 401–408, 2005.
- [36] M. Wieland and M. Pittore, "Performance evaluation of machine learning algorithms for urban pattern recognition from multi-spectral satellite images," *Remote Sens.*, vol. 6, no. 4, pp. 2912–2939, 2014.
- [37] S. Mohammady and M. R. Delavar, "Urban Expansion Modeling with Logistic Regression," *J. Geomatics Sci. Technol.*, vol. 4, no. 2, pp. 77–86, 2014, [Online]. Available: <https://jgst.issge.ir/article-1-244-en.html>.
- [38] S. B. Kotsiantis, I. Zaharakis, and P. Pintelas, "Supervised machine learning: A review of classification techniques," *Emerg. Artif. Intell. Appl. Comput. Eng.*, vol. 160, no. 1, pp. 3–24, 2007.
- [39] Y.-Y. Song and L. U. Ying, "Decision tree methods: applications for classification and prediction," *Shanghai Arch. psychiatry*, vol. 27, no. 2, p. 130, 2015.
- [40] D. Lowd and P. Domingos, "Naive Bayes models for probability estimation," *ICML 2005 - Proc. 22nd Int. Conf. Mach. Learn.*, pp. 529–536, 2005, doi: 10.1145/1102351.1102418.
- [41] A. Likas, N. Vlassis, and J. J. Verbeek, "The global k-means clustering algorithm," *Pattern Recognit.*, vol. 36, no. 2, pp. 451–461, 2003.
- [42] M. Andreucut, "Parallel GPU implementation of iterative PCA algorithms," *J. Comput. Biol.*, vol. 16, no. 11, pp. 1593–1599, 2009.
- [43] X. Zhu and A. B. Goldberg, "Introduction to semi-supervised learning," *Synth. Lect. Artif. Intell. Mach. Learn.*, vol. 3, no. 1, pp. 1–130, 2009.
- [44] hu, "Semi-supervised learning literature survey," 2005.
- [45] D. P. Kingma, D. J. Rezende, S. Mohamed, and M. Welling, "Semi-supervised learning with deep generative models," *Adv. Neural Inf. Process. Syst.*, vol. 4, no. January, pp. 3581–3589, 2014.
- [46] C. Rosenberg, M. Hebert, and H. Schneiderman, "Semi-supervised self-training of object detection models," 2005.
- [47] Y. Wu, G. Mu, C. Qin, Q. Miao, W. Ma, and X. Zhang, "Semi-supervised hyperspectral image classification via spatial-regulated self-training," *Remote Sens.*, vol. 12, no. 1, pp. 1–20, 2020, doi: 10.3390/RS12010159.
- [48] S. Shalev-Shwartz, Y. Singer, N. Srebro, and A. Cotter, "Pegasos: Primal estimated sub-gradient solver for svm," *Math. Program.*, vol. 127, no. 1, pp. 3–30, 2011.
- [49] X. Wang, J. Wen, S. Alam, Z. Jiang, and Y. Wu, "Semi-supervised learning combining transductive support vector machine with active learning," *Neurocomputing*, vol. 173, pp. 1288–1298, 2016.
- [50] Sutton and A. G. Barto, "Book Reviews Reinforcement Learning," pp. 126–134, 1999.
- [51] L. P. Kaelbling, M. L. Littman, and A. W. Moore, "Reinforcement learning: A survey," *J. Artif. Intell. Res.*, vol. 4, pp. 237–285, 1996.
- [52] R. Caruana, "Multitask learning," *Mach. Learn.*, vol. 28, no. 1, pp. 41–75, 1997.
- [53] R. Polikar, *Ensemble Machine Learning*. 2012.
- [54] T. G. Dietterich, "Ensemble learning," *Handb. brain theory neural networks*, vol. 2, pp. 110–125, 2002.
- [55] Z.-H. Zhou, "Ensemble learning," *Encycl. biometrics*, vol. 1, pp. 270–273, 2009.
- [56] G. Tuysuzoglu and D. Birant, "Enhanced bagging (eBagging): A novel approach for ensemble learning," *Int. Arab. J. Inf. Technol.*, vol. 17, no. 4, pp. 515–528, 2020.
- [57] L. Breiman, "Random forests," *Mach. Learn.*, vol. 45, no. 1, pp. 5–32, Oct. 2001, doi: 10.1023/A:1010933404324.

- [58] M. H. Hassoun, *Fundamentals of artificial neural networks*. MIT press, 1995.
- [59] S.-C. Wang, "Artificial neural network," in *Interdisciplinary computing in java programming*, Springer, 2003, pp. 81–100.
- [60] D. W. Aha, D. Kibler, and M. K. Albert, "Instance-based learning algorithms," *Mach. Learn.*, vol. 6, no. 1, pp. 37–66, 1991.
- [61] O. Kramer, "K-nearest neighbors," in *Dimensionality reduction with unsupervised nearest neighbors*, Springer, 2013, pp. 13–23.
- [62] Q. Yang, X. Li, and X. Shi, "Cellular automata for simulating land use changes based on support vector machines," *Comput. Geosci.*, vol. 34, no. 6, pp. 592–602, 2008, doi: 10.1016/j.cageo.2007.08.003.
- [63] R. G. Congalton, "A review of assessing the accuracy of classifications of remotely sensed data," *Remote Sens. Environ.*, vol. 37, no. 1, pp. 35–46, Jul. 1991, doi: 10.1016/0034-4257(91)90048-B.
- [64] C. Bone and S. Dragičević, "Defining transition rules with reinforcement learning for modeling land cover change," *Simulation*, vol. 85, no. 5, pp. 291–305, 2009.
- [65] C. Wang, Z. Guo, S. Wang, L. Wang, and C. Ma, "Improving hyperspectral image classification method for fine land use assessment application using semisupervised machine learning," *J. Spectrosc.*, vol. 2015, 2015, doi: 10.1155/2015/969185.
- [66] D. Poursanidis, N. Chrysoulakis, and Z. Mitraka, "Landsat 8 vs. Landsat 5: A comparison based on urban and peri-urbanland cover mapping," *Int. J. Appl. Earth Obs. Geoinf.*, vol. 35, no. PB, pp. 259–269, Mar. 2015, doi: 10.1016/j.jag.2014.09.010.
- [67] M. Ahmadi, M. R. Delavar, and A. Tayyebi, "Comparing ANN and CART to Model Multiple Land Use Changes: A Case Study of Sari and Ghaem-Shahr Cities in Iran," *J. Geomatics Sci. Technol.*, p. 303, 2016.
- [68] K. Ali et al., "Land Usage Analysis: A Machine Learning Approach," *Int. J. Comput. Appl.*, vol. 141, no. 12, pp. 23–28, 2016, doi: 10.5120/ijca2016909936.
- [69] A. Sitthi, M. Nagai, M. Dailey, and S. Ninsawat, "Exploring land use and land cover of geotagged social-sensing images using naive bayes classifier," *Sustain.*, vol. 8, no. 9, 2016, doi: 10.3390/su8090921.
- [70] S. Hajibabaei, K. Zakerhaghghi, Q. Journal, N. A. Studies, E. Issn, and سالم, "A Simulation of Land Use Change in Hamadan in 2040 Using Cellular Automation and Data Mining Method" Support Vector Vectorization and Fuzzy Automated Cells," *Hum. Geogr.*, vol. 76, no. 68, pp. 99–113, 2017.
- [71] C. E. Brodley and M. A. Friedl, "Decision tree classification of land cover from remotely sensed data," *Remote Sens. Environ.*, vol. 61, no. 3, pp. 399–409, 1997, doi: 10.1016/S0034-4257(97)00049-7.
- [72] O. Conrad et al., "System for Automated Geoscientific Analyses (SAGA) v. 2.1.4," *Geosci. Model Dev.*, vol. 8, no. 7, pp. 1991–2007, Jul. 2015, doi: 10.5194/gmd-8-1991-2015.
- [73] H. Omrani, "Applying big data computational tools to simulate land transformations: The LTM-cluster framework," *Environ. Model. Softw.*, 2018, doi: 10.1016/j.envsoft.2018.10.004.
- [74] Z. L. Teffera, J. Li, T. M. Debsu, and B. Y. Menegesa, "Assessing land use and land cover dynamics using composites of spectral indices and principal component analysis: A case study in middle Awash subbasin, Ethiopia," *Appl. Geogr.*, vol. 96, no. December 2017, pp. 109–129, 2018, doi: 10.1016/j.apgeog.2018.05.015.
- [75] F. Xu, H. C. Ho, G. Chi, and Z. Wang, "Abandoned rural residential land: Using machine learning techniques to identify rural residential land vulnerable to be abandoned in mountainous areas," *Habitat Int.*, vol. 84, pp. 43–56, Feb. 2019, doi: 10.1016/j.habitatint.2018.12.006.
- [76] M. Ahmadi, M. R. Delavar, A. Basiri, and M. Karimi, "Center of Excellence in Geomatics Engineering in Disaster Management , School of Surveying and Geospatial Engineering , College of Engineering , University of Tehran , Centre for Advanced Spatial Analysis , University College London , London , UK , E-mail," 2019.
- [77] X. Liao, X. Huang, and W. Huang, "ML-LUM: A system for land use mapping by machine learning algorithms," *J. Comput. Lang.*, vol. 54, no. February, 2019, doi: 10.1016/j.cola.2019.100908.
- [78] S. E. Jodzani, B. A. Johnson, and D. Chen, "Comparing Deep Neural Networks , Ensemble Classifiers , and Support Vector Machine Algorithms," *Remote Sens.*, vol. 11, no. 1, pp. 1–24, 2019.
- [79] S. Giri, Z. Zhang, D. Krasnuk, and R. G. Lathrop, "Evaluating the impact of land uses on stream integrity using machine learning algorithms," *Sci. Total Environ.*, vol. 696, p. 133858, 2019, doi: 10.1016/j.scitotenv.2019.133858.
- [80] F. F. Camargo, E. E. Sano, C. M. Almeida, J. C. Mura, and T. Almeida, "A comparative assessment of machine-learning techniques for land use and land cover classification of the Brazilian tropical savanna using ALOS-2/PALSAR-2 polarimetric images," *Remote Sens.*, vol. 11, no. 13, 2019, doi: 10.3390/rs11131600.

- [81] J. Ma, J. C. P. Cheng, F. Jiang, W. Chen, and J. Zhang, "Analyzing driving factors of land values in urban scale based on big data and non-linear machine learning techniques," *Land use policy*, vol. 94, no. February, p. 104537, 2020, doi: 10.1016/j.landusepol.2020.104537.
- [82] T. Zhang, M. Hou, T. Zhou, Z. Liu, and W. Cheng, "Land-use classification via ensemble dropout information discriminative extreme learning machine based on deep convolution feature," vol. 17, no. 2, pp. 427-443, 2020.
- [83] J. R. Bergado, C. Persello, and A. Stein, "Land use classification using deep multitask networks," *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci. - ISPRS Arch.*, vol. 43, no. B3, pp. 17-21, 2020, doi: 10.5194/isprs-archives-XLIII-B3-2020-17-2020.
- [84] S. R. Mir Alizadehfard 1 , S. M. Alibakhshi," Monitoring and forecasting of land use change by applying Markov chain model and land change modeler (Case study: Dehloran Bartash plains, Ilam)" *RS & GIS for Natural, Resources* vol.7(2), pp. 33-45, 2016.
- [85] Y. Sun, J. Xu, X. Wang, and C. Hu, "Enhanced land use / cover classification using support vector machines and fuzzy k-means clustering algorithms," 2014, doi: 10.1117/1.JRS.8.083636.
- [86] Soufi M, Behzadi S, Aghamohammadi H. Developing a Baseline Approach for Modeling Land use Change. *JGST*. 2018; 7 (4) :103-118. URL: <http://jgst.issge.ir/article-1-654-fa.html>
- [87] Kaviari.F, Mohamad S.M, Hosseinali. F, Samane. V, " Agent-Based Modeling of Urban Growth With Communications Inspired by Particle Swarm Optimization Algoritm", *Journal of Geospatial Information Technology* Vol.5, No.1, Spring 2017.
- [88] F. Li, Z. Li, H. Chen, Z. Chen, and M. Li, "Land Use Policy An agent-based learning-embedded model (ABM-learning) for urban land use planning : A case study of residential land growth simulation in," *Land use policy*, vol. 95, no. February 2019, p. 104620, 2020, doi: 10.1016/j.landusepol.2020.104620.
- [89] S. Mohammady, M. R. Delavar. Urban Expansion Modeling with Logistic Regression. *JGST*. 2014; 4 (2) : 77-86URL: <http://jgst.issge.ir/article-1-244-fa.htm>.
- [90] Kamyab. H, A Salman Mahiny, S. M. Hoseini, M. Gholamalifard, " Using Neural Network for Urban Growth Modeling(Case Study: Gorgan City)", *Human Geography Research*Vol.43, No.76, Summer 2011.
- [91] A. R. Soffianian, E. Mohamadi Towfigh , L. Khodakarami, F. Amiri, " Land use mapping using artificial neural network (Case study: Kaboudarahang, Razan and Khonjin- Talkhab catchment in Hamedan province)", *Journal of Applied RS & GIS Techniques in Natural Resource Science (Vol.2/ Issue1)* spring 2011.
- [92] Joorabian Shooshtari. S, Esmaili-Sari. A, Hosseini. S. M, Gholamalifard. M, " Application of Multilayer Perceptron Neural Network Method in Land Use Change Modeling in the East of Mzandaran Province", *Geography and Environmental Planning*, Vol.29, No.4, Summer 2017.
- [93] Mahmoudzadeh Hassan, Ranjbar Navazi Amir Masoud, " Application Of Ltm Model In Predicting And Modeling Of Physical Development Of The Ilkhichi City", *Human Geography Reserch Quarterly*, Spring 2018 , Volume 50 , Number 1 ; Page(s) 35 -53.
- [94] Dadashpoor. H, Jahanzad. N, " Forecasting Land-use Changes in Mashhad, Using Cellular Automata(CA) and Artificial Neural Network Algorithm (ANN) (Case Study: Mashhad metropolitan Region)", *Journal of Spatial Planning* Vol. 6, No. 1, Ser (20) Spring 2016.
- [95] Akbari. D, Moradzadeh. M, Akbari. M, " Land Use Changes And Urban Development Simulation Using Neural Network And Markov Chain Cellular Automata", *Reserch And Urban Planning* Winter 2020, Volume 10 , Number 39 ; Page(s) 167 To 170.
- [96] A. R. Sepehri, A. A. Jamali, M. Hasanzadeh, " Analysis and comparison of land use/land cover changes using artificial neural network (Case study: lands of Taft and Mehriz)", *RS & GIS for Natural Resources (Vol. 10/ Issue 4)* Winter 2019.