https://doi.org/10.22131/SEPEHR.2023.552921.2868

فصلنامه علمی - پژوهشی

اطلاعات جغرافیایی (سپهر) دوره ۳۲، شماره ۱۲۶، تابستان ۱۴۰۲

صفحات ۲۷ - ۷

قیمت‌گذاری املاک مسکونی به کمک الگوریتم ترکیبی یادگیری عمیق–فازی

زهرا مرادی [۱] محمد سعدی‌مسگری [۲]

تاریخ دریافت مقاله: ۱۴۰۱/۰۳/۱۵ تاریخ پذیرش مقاله: ۱۴۰۱/۱۲/۱۷

****

چکیده

اهمیت مسئله مسکن، لزوم برآورد قابل‌اعتماد از قیمت املاک را برای امر سیاست‌گذاری در این زمینه ایجاب می‌نماید. لذا ضروری است قیمت‌گذاری املاک با در نظر گرفتن صدها عامل تأثیرگذار بر آن، به صورتی کارآمد انجام شود. با توجه به ماهیت پیچیده‌ی بازار املاک در تحقیقات انجام‌شده از الگوریتم‌های متداول یادگیری عمیق مانند DNN، RNN، CNN و ... استفاده شده است، اما این الگوریتم‌ها در خصوص داده‌های جدولی چندان مناسب نمی‌باشند. از طرفی مدل‌های یادگیری عمیق موجود در قیمت‌گذاری ملک نیز کاملاً قطعی هستند و عدم قطعیت داده‌ها را لحاظ نمی‌کنند. در این مقاله سعی شده است که در به‌کارگیری روش‌های یادگیری عمیق به ساختار جدولی داده‌های املاک توجه شود. برای این منظور معماری عمیق جدید TabNet به‌کار گرفته شده است. این الگوریتم برخلاف سایر الگوریتم‌های متداول یادگیری عمیق داده‌های جدولی خام را بدون هیچ‌گونه پیش‌پردازشی دریافت می‌کند. در پژوهش حاضر، همچنین با استفاده از تکنیک‌های ترکیب موجود، منطق فازی با الگوریتم‌های یادگیری عمیق ترکیب شده است تا ضمن یادگیری سریع و دقیق‌تر مسائل پیچیده، بر کاستی‌های قطعی بودن مدل‌های یادگیری عمیق و در نظر نگرفتن عدم قطعیت ذاتی داده‌ها در این مدل‌ها غلبه شود. همچنین با به‌کارگیری سیستم اطلاعات مکانی (GIS) ارزیابی شفاف‌تری ارائه شد تا بصری‌سازی کامل الگوی مکانی ویژگی‌های ملک و همچنین ارتباط این ویژگی‌ها و قیمت‌گذاری تضمین و متغیرهای مکانی نیز در مدل ارزش‌گذاری لحاظ شوند. به‌منظور ارزیابی روش‌های پیشنهادی از داده‌های املاک منطقه‌ی پنج تهران استفاده شده است. ترتیب و اولویت‌بندی تأثیرگذاری ویژگی‌ها در قیمت‌گذاری املاک مسکونی تهران توسط الگوریتم TabNet نشان‌دهنده‌ی تأثیر قابل‌توجه عوامل مکانی است. به‌طوری‌که در این رتبه‌بندی پس از مساحت، دو ویژگی مکانی طول و عرض جغرافیایی به ترتیب رتبه‌ی دوم و سوم را به خود اختصاص می‌دهند. از این‌رو برای مجموعه داده‌ی تهران الگوریتم‌های TabNet، DNN، CNN، RNN، LSTM، خود رمزگذار و همچنین الگوریتم یادگیری ماشین XGBoost به‌کار گرفته‌شده و معیارهای ارزیابی RMSE، MAE و R^2 مقایسه شدند که بر اساس معیار R^2، با به‌کارگیری TabNet پنج درصد بهبود دقت حاصل شد. درنهایت الگوریتم ترکیبی FuzzyTabNet برای داده‌ی تهران نسبت به الگوریتم پایه‌ی TabNet ٤/٦٥ درصد کاهش یافت. همچنین شبکه‌ی خود رمزگذار فازی نیز نسبت به شبکه‌ی خود رمزگذار معمولی ٦/٥٢ درصد بهبود یافت.

واژه‌های کلیدی: قیمت‌گذاری املاک مسکونی، یادگیری عمیق، شبکه‌های عصبی عمیق، فازی، TabNet

****

۱- دانشجوی کارشناسی ارشد مهندسی عمران نقشه‌برداری، گرایش سیستم‌های اطلاعات جغرافیایی، دانشگاه خواجه‌نصیرالدین طوسی (نویسنده مسئول)
Zahra-moradi@email.kntu.ac.ir

۲- دانشیار دانشکده نقشه‌برداری، دانشگاه صنعتی خواجه‌نصیرالدین طوسی mesgari@kntu.ac.ir

۱- مقدمه

مسکن به‌عنوان سرمایه‌ای که سهم زیادی از بودجه خانوارها، هزینه‌ها و سرمایه‌گذاری ثابت ناخالص ملی را به خود اختصاص داده است، نقش زیادی در اشتغال و ارزش‌افزوده کشورها دارد *(عبده کلامچی و دیگران،۱۳۹۳)*. اهمیت روزافزون مسکن به لحاظ تأثیرات عمیق و قابل‌توجهی که بر ابعاد مختلف اجتماعی، سیاسی و اقتصادی کشورها می‌گذارد، بر کسی پوشیده نیست *(Afonso et al., 2019)*؛ بنابراین برآورد دقیق و قابل‌اعتماد قیمت به‌طورقطع امر سیاست‌گذاری در این زمینه را آسان می‌نماید. در شرایط مختلف ممکن است صدها عامل به‌صورت زیرمجموعه‌ای از عوامل ساختاری، مکانی و اجتماعی – اقتصادی بر قیمت املاک تأثیر بگذارد. بنابراین بایستی با در نظر گرفتن این عوامل، قیمت‌گذاری املاک به‌طور کارآمد انجام شود *(Yiorkas & Dimopoulos, 2017)*. ازجمله روش‌های معمول برای قیمت‌گذاری املاک، روش‌های مبتنی بر رگرسیون چندگانه (MRA)[1] است که در بسیاری از پژوهش‌ها به‌کار گرفته می‌شود. پارامترها و عوامل دخیل در قیمت املاک بسیار متعدد و زیاد هستند. به‌علاوه، نوع و ذات این پارامترها بسیار مختلف و متنوع، و مقادیر آن‌ها از نوع عدد صحیح، اعشاری، اسمی، باینری و غیره هستند. ضمناً ارتباط قیمت با این عوامل مؤثر غیرخطی می‌باشد، لذا استفاده از رویکردهای متداول رگرسیون دشوار و ناکارآمد خواهد بود. همچنین، به دلیل تأثیرپذیری قیمت ملک از ویژگی‌های مختلف پارامتری و غیر پارامتری با روابط آماری ناشناخته، استفاده از پیشرفته‌ترین الگوریتم‌ها برای تجزیه‌وتحلیل و مدل‌سازی ضروری است. ازاین‌رو به‌کارگیری روش‌های داده‌کاوی و یادگیری ماشین اهمیت بیشتری پیدا می‌کند. یادگیری عمیق[2] به‌عنوان شاخه جدیدی از یادگیری ماشین، به دلیل توانایی در یادگیری خودکار و عدم محدودیت در خصوص الگوهای ذاتی داده‌ها و قابلیت کار با مدل‌های پیچیده، موردتوجه جوامع هوش مصنوعی قرار گرفته است. یادگیری عمیق همچنین از توانایی نگاشت غیرخطی زیادی برخوردار است که انعطاف‌پذیری بیشتری را در درک ماهیت پیچیده‌ی بازار املاک فراهم می‌کند. به‌علاوه این الگوریتم‌ها باعث کاهش نیاز به مهندسی ویژگی[3] نیز خواهد شد که این مسئله در حال حاضر در یادگیری داده‌های جدولی[4] جنبه‌ای کلیدی دارد. داده‌های جدولی یک نوع از انواع داده‌های موجود در جهان واقعی هستند که اطلاعات در قالب ترتیب ساختاریافته‌ای از سطرها و ستون‌ها جمع‌آوری شده است. از طرفی اگرچه الگوریتم‌های متعارف یادگیری عمیق موفقیت قابل‌توجهی را با تصاویر، متن و صدا نشان داده‌اند اما داده‌های جدولی که رایج‌ترین نوع داده در جهان واقعی هستند، چندان مناسب نبوده و روش‌های دیگر عملکرد بهتری داشته‌اند. معماری جدید یادگیری جدولی تفسیرپذیر توجه (TabNet)[5] که خاص داده‌های جدولی است، برخلاف سایر الگوریتم‌های متداول یادگیری عمیق، داده‌های جدولی خام را بدون هیچ‌گونه پیش‌پردازشی دریافت می‌کند. به‌علاوه هم‌زمان با فرایند یادگیری انتخاب ویژگی را به‌صورت کاملاً تفسیرپذیر انجام می‌دهد و فرایند یادگیری بهتر انجام می‌شود، به این دلیل که کل ظرفیت یادگیری صرف ویژگی‌های بااهمیت‌تر می‌شود. با توجه به ارزیابی TabNet در سایر موضوعات انتظار می‌رود که این الگوریتم بر روی‌داده‌های رده‌بندی‌شده‌ی املاک نیز نتیجه‌ی قابل قبولی داشته باشد. از طرفی به‌علت عدم قطعیت ذاتی در فرایند قیمت‌گذاری املاک و مستغلات، به‌کارگیری منطق فازی در کنار یادگیری عمیق سودمند بوده و شفافیت ارزیابی را در قالب قوانین فازی معنادار، بیشتر می‌کند.

ترکیب این دو روش علاوه بر اینکه گزینه‌ی مناسبی برای تجزیه‌وتحلیل داده‌ی زیاد با سطح بالای پیچیدگی است، سیستم استنتاج فازی را نیز بهبود می‌بخشد. چراکه استخراج قوانین فازی مبتنی بر دانش در روش‌های فازی مسئله‌ای زمان‌بر است و یادگیری عمیق می‌تواند از جفت داده‌های ورودی/

1- Multiple Regression Analysis
2- Deep Learning
3- Feature Engineering
4- Tabular Data
5- Attentive Interpretable Tabular Learning

خروجی، این قوانین فازی را تولید نماید؛ بنابراین به‌نظر می‌رسد روش مناسب برای دستیابی به مزایای هر دو روش و حل مشکلات مربوط به هرکدام، ترکیب آن‌ها در یک سیستم یکپارچه است که ضمن یادگیری سریع و دقیق‌تر مسائل پیچیده، بر کاستی‌های قطعی بودن مدل‌های یادگیری عمیق و در نظر نگرفتن عدم قطعیت ذاتی داده‌ها در این مدل‌ها غلبه می‌کند. این روش ترکیبی در حوزه‌های دیگر مانند پیش‌بینی جریان ترافیک و طبقه‌بندی، به‌کار گرفته‌شده و عملکرد خوبی حاصل‌شده است *(Chen et al., 2015; Chen et al., 2018; Talpur et al., 2020)*. به‌علاوه رایج‌ترین استنباط از دنیای املاک و مستغلات این است که ارزش املاک اساساً بر اساس موقعیت مکانی آن‌ها مشخص می‌شود. به گفته رابرت والنر مکان، مهم‌ترین عامل تعیین‌کننده ارزش املاک مسکونی در بازار مسکن است. یک ملک معمولاً به‌عنوان یک دارایی غیرمنقول شناخته می‌شود که در فضای اجتماعی و فیزیکی وجود دارد، جایی که مکان، ویژگی برتری است که بر ارزش آن‌ها تأثیر می‌گذارد *(Yiorkas & Dimopoulos, 2017)*. بااین‌وجود اکثر مدل‌های قیمت‌گذاری سنتی وجود همبستگی مکانی در قیمت‌ها را که منعکس‌کننده‌ی نقش ویژگی‌های مکانی است، در نظر نمی‌گیرند *(Rambaldi & Rao, 2011)*. یورکاس و دیموپلوس[1] (۲۰۱۷) استدلال می‌کنند که املاک مجاور اغلب ویژگی‌های ساختاری مشابهی دارند و ویژگی‌های مکانی را به اشتراک می‌گذارند، درنتیجه وابستگی مکانی ایجاد می‌شود. ویژگی‌های مکانی مانند فاصله تا نزدیک‌ترین امکانات، می‌تواند محیط ناملموس اطراف را توصیف کند *(Kang et al., 2021)* و بالعکس غفلت از این ویژگی‌ها باعث کاهش دقت قیمت‌گذاری خواهد شد *(McCord et al., 2012)*.

هدف این مقاله، مدل‌سازی مسئله‌ی قیمت‌گذاری املاک مسکونی در قالب تعدادی از الگوریتم‌های متداول یادگیری عمیق است. از دیگر اهداف تحقیق حاضر، توجه کامل بر ساختار داده‌های مسئله و به‌کارگیری الگوریتم جدید TabNet در کنار دیگر الگوریتم‌های یادگیری عمیق می‌باشد. مهم‌ترین هدف این تحقیق طراحی و مدل‌سازی ساختار فازی برای مسئله و درنهایت پیاده‌سازی و ارزیابی مدل یادگیری عمیق فازی به‌عنوان یک روش ترکیبی بهبودیافته در قیمت‌گذاری املاک مسکونی می‌باشد. به‌علاوه با در نظر گرفتن موقعیت نسبتاً دقیق املاک و فاصله‌ی مکانی از مراکز مهم تأثیرگذار بر قیمت، بر روی جنبه‌ی مکانی مسئله نیز تمرکز شده است. در ادامه این مقاله، بعد از بیان مرور کارهای گذشته، روش‌های پیشنهادی توضیح داده شده و سپس نحوه پیاده‌سازی و ارزیابی روش‌ها بیان شده است. در انتها هم نتایج و پیشنهادهایی برای کارهای آتی در بخش نتیجه‌گیری ارائه شده است.

۲- مروری بر روش‌های قیمت‌گذاری املاک مسکونی

مدل‌سازی و پیش‌بینی قیمت ملک سابقه‌ای طولانی دارد *(McCord et al., 2012)*. با توجه به اهمیت روزافزون مسکن و لزوم قیمت‌گذاری دقیق آن، در طول دهه‌های گذشته تحقیقات زیادی در این زمینه انجام شده است. از طرفی تعدد پارامترهای تأثیرگذار و پیچیدگی ارتباط قیمت با این پارامترها، انتخاب بهترین روش قیمت‌گذاری را با چالش روبه‌رو کرده است. مرور تحقیقات پیشین در این زمینه و روش‌های موردنظر این مقاله، در ادامه ارائه شده است.

۲-۱- الگوریتم‌های سنتی متداول

ازجمله روش‌های معمول برای قیمت‌گذاری املاک، روش‌های مبتنی بر رگرسیون چندگانه بود که در پژوهش‌های بسیاری استفاده شده است. در پژوهش بنجامین[2] و همکاران (۲۰۰٤) تمرکز مطالعه بر مبانی قیمت‌گذاری املاک و تحلیل رگرسیون چندگانه است. به‌این صورت که تحلیل رگرسیون چندگانه توسط ارزیابان و دانشجویان مبتدی انجام شد و به فهم چگونگی استفاده از رویکرد مقایسه بازار و تحلیل رگرسیون چندگانه برای قیمت گذاری املاک انجامید. در پژوهش سوری و منیری[3] (۲۰۱۱) ترکیب نسبی قیمت‌های

1- Yiorkas and Dimopoulos

2- Benjamin

3- Souri and Moniri

فروش مکرر املاک به‌عنوان شاخص قیمت در نظر گرفته شد. درنهایت تکنیک‌های استاندارد تحلیل رگرسیون برای تخمین این شاخص مورد استفاده قرار گرفت. تحلیل رگرسیون ضمن اینکه از اطلاعات مربوط به شاخص قیمت دوره‌های قبلی موجود در قیمت‌های فروش در دوره‌های بعدی استفاده کرده است، خطاهای استاندارد شاخص تخمینی را به‌آسانی محاسبه و حذف کرده و به‌این طریق کارآمدتر از روش‌های دیگر به‌نظر می‌رسید.

۲-۲- شبکه‌های عصبی مصنوعی

به‌تدریج روش‌های شبکه عصبی مصنوعی (ANN)[1] به‌عنوان جایگزینی مناسب‌تر پیشنهاد شدند چراکه عملکرد MRA با افزایش حجم داده و متغیرهای وابسته کاهش می‌یافت ***(Nghiep & Al, 2001)***. به‌کارگیری شبکه‌های عصبی در قیمت‌گذاری ملک قابل‌توجه بوده و موفقیت‌های بسیاری حاصل‌شده است ***(Guan et al., 2014)***. مطالعه‌ی بورس[2] (۱۹۹۱) یکی از اولین مواردی است که از روش شبکه عصبی برای پیش‌بینی قیمت ملک استفاده کرد. نگویت و کریپس[3] (۲۰۰۱) عملکرد پیش‌بینی شبکه‌های عصبی مصنوعی و تحلیل رگرسیون چندگانه را برای فروش مسکن تک خانواده مقایسه کردند. این مقایسه بین دو مجموعه داده با اندازه‌ی نمونه‌ی متفاوت انجام شد که ANN در مجموعه داده با حجم نمونه‌ی بزرگ‌تر، بهتر از MRA عمل کرد. به‌این ترتیب آن‌ها دریافتند که وقتی داده‌های کافی برای آموزش در دسترس باشد، شبکه‌های عصبی می‌توانند عملکرد بهتری نسبت به رگرسیون‌های خطی متعدد داشته باشند. خیاولونگ و مینگ[4] (۲۰۱۰) برای پیش‌بینی قیمت املاک و مستغلات از شبکه‌های عصبی پس انتشار خطا[5] و شبکه عصبی المان (ENN)[6] استفاده کرده و تأیید می‌کنند که این دو روش از دقت خوبی برخوردار هستند. به‌علاوه آن‌ها دریافتند که شبکه عصبی المان می‌تواند دقیق‌تر و سریع‌تر از روش‌های دیگر پیش‌بینی کند. پژوهش تابالز[7] و همکاران (۲۰۱۳) نیز نشان داد که در صورت وجود اطلاعات آماری کافی و مجموعه گسترده‌ای از داده‌ها، استفاده از شبکه ANN مناسب است.

۲-۳- شبکه‌های عصبی فازی

لی و ژانگ[8] (۲۰۰۷) قیمت‌های املاک و مستغلات را در راستای تأیید اهمیت استدلال و یادگیری فازی با استفاده از شبکه عصبی فازی پیش‌بینی کردند. درواقع آن‌ها برای پیش‌بینی دقیق‌تر، منطق فازی را با شبکه عصبی ترکیب کردند تا یک شبکه عصبی فازی که توانایی استدلال و یادگیری فازی دارد، ایجاد نمایند. تحقیقات آن‌ها نشان داد ازآنجایی‌که عوامل نامطمئن و غیرمعمول زیادی در برآورد قیمت مؤثر هستند، شبکه عصبی به‌تنهایی قادر به مدیریت این اطلاعات فازی نیست، لذا شبکه عصبی فازی می‌تواند بهتر از رویکردهای شبکه عصبی سنتی عمل کند. مطالعه‌ی گان[9] و همکاران (۲۰۰۸) نیز استفاده از شبکه عصبی فازی را درزمینه‌ی ارزیابی انبوه املاک و مستغلات بررسی کرده و نتایج قابل قبولی حاصل شد. بااین‌حال این مطالعه از حجم نمونه‌ی بسیار کمی استفاده کرده است. آن‌ها ضمن استفاده از این روش برای یک مجموعه داده‌ی بزرگ‌تر، تعریفی منحصربه‌فرد از همسایگی ارائه دادند که به بهبود نتایج قیمت‌گذاری منجر شد ***(Guan et al., 2008)***. بااین وجود مدل‌های شبکه عصبی برای همگرایی، بسته به پیچیدگی مسئله به هزاران یا میلیون‌ها تکرار نیاز داشتند و نمی‌توانستند مسائل تشخیص الگوهای پیچیده را به‌طور مؤثر و در یک مدت‌زمان محاسباتی معقول مدل‌سازی کنند ***(Rafiei & Adeli, 2016)***. بااین‌حال وجود مدل‌های شبکه عصبی برای همگرایی بسته به پیچیدگی مسئله به هزاران یا میلیون‌ها

1- Artificial Neural Network
2- Borst
3- Nghiep and Cripps
4- Xiaolong and Ming
5- Back Propagation
6- Elman Neural Network
7- Tabales
8- Li and Zhang
9- Guan

تکرار نیاز داشتند و نمی‌توانستند مسائل تشخیص الگوهای پیچیده را به‌طور مؤثر و در یک مدت‌زمان محاسباتی معقول مدل‌سازی کنند *(Rafiei & Adeli, 2016)*.

۲-٤- الگوریتم‌های یادگیری عمیق

امروزه الگوریتم‌های یادگیری عمیق تخمین پیشرفته و قوی‌تری را ارائه می‌دهند. پژوهش رافعی و عادلی[1] (۲۰۱٦) برای برآورد قیمت املاک در مرحله طراحی یا شروع ساخت‌وساز، یک مدل جدید و جامع ارائه داد. در این پژوهش با ادغام مبتکرانه‌ی ماشین بولتزمن محدود[2] باور عمیق[3] و الگوریتم ژنتیک یک ساختار داده‌ی مؤثر ارائه شد که ضمن در نظر گرفتن تعداد زیادی شاخص اقتصادی، تغییرات فصلی و وابسته به زمان متغیرها را نیز در برگرفت. از طرفی با در نظر گرفتن تعداد زیادی از متغیرها، آموزش مدل به مجموعه داده‌های آموزشی بزرگ و منابع محاسباتی قابل‌توجهی نیاز داشت و قسمت دوم این پژوهش با ارائه‌ی راهبردی هوشمندانه، بر کاهش ابعاد داده تمرکز داشت که درنتیجه‌ی آن برآوردی منطقی حاصل شد.

در مطالعه‌ای دیگر برای ارزیابی هوشمندانه‌ی ارزش املاک، یک شبکه عصبی عمیق (DNN)[4] ساختاریافته ارائه شد که در مقایسه با متدهای مبتنی بر رگرسیون و حتی DNN بااتصال کامل، کارآمدتر و دقیق‌تر بود *(Xu & Gade, 2017)*. به‌طور دقیق‌تر این پژوهش برای طراحی یک شبکه عصبی عمیق ساختاریافته یک روش سیستماتیک ارائه می‌نماید و اتصال ساختاریافته‌ی گره‌ها[5]، منجر به کاهش قابل‌توجه گره‌ها و اتصالات آن‌ها خواهد شد که به‌تبع نیاز به داده نیز کمتر خواهد شد. این پژوهش برای نشان دادن اثربخشی رویکرد پیشنهادی، به مطالعه‌ی موردی قیمت‌گذاری املاک واقعی در شهرهای کوچک پرداخت. مطالعه‌ی سیا و شیرویی[6] (۲۰۱۹) دقت شبکه عصبی عمیق را برای پیش‌بینی قیمت اجاره آپارتمان در ژاپن با روش کریجینگ[7] که یک روش رگرسیون فضایی است مقایسه کرد تا تفاوت دقت این دو روش را با یک مجموعه داده‌ی بزرگ نشان دهد. این مطالعه نشان داد که با افزایش حجم نمونه، دقت پیش‌بینی برون نمونه‌ای[8] DNN به Kriging نزدیک شده و در حجم نمونه‌ی ۱۰[6]، برابر می‌شود. علاوه بر این در مواردی که انحراف از میانه‌ی قیمت ملک زیاد است، دقت پیش‌بینی DNN بهتر خواهد بود. چراکه این روش غیرخطی بودن فرم تابع را نیز در نظر می‌گیرد.

در مطالعه‌ی چن[9] و همکاران (۲۰۱۷) برای پیش‌بینی قیمت ملک از شبکه عصبی حافظه طولانی کوتاه‌مدت (LSTM)[10] ساده که شاخه‌ای از شبکه عصبی بازگشتی (RNN)[11] محسوب می‌شود و توالی زمان را نیز در قیمت‌گذاری املاک لحاظ می‌کند، استفاده شد. نتیجه نشان داد که مدل LSTM با توجه به‌پیش‌بینی‌های سری زمانی خود درزمینه‌ی قیمت ملک عملکرد خوبی دارد. همچنین برای مطالعه‌ی بیشتر و بهبود دقت مدل، از دو نوع دیگر این روش استفاده شد. بائه و یو[12] (۲۰۱۷) ثابت کردند که در پیش‌بینی قیمت املاک مسکونی اگرچه مدت‌زمان آموزش DNN طولانی‌تر است اما در مقایسه با LSTM دقت بهتری دارد. مطالعه‌ی کیم[13] و همکاران (۲۰۲۰) با استفاده از داده‌های ۱٦۷ ماه و به‌کارگیری LSTM ساده، به پیش‌بینی دقیق و قابل‌اعتمادی دست‌یافت. در پژوهشی دیگر درزمینه‌ی بازار املاک یک رویکرد جدید مبتنی بر شبکه عصبی پیچشی (CNN)[14] به‌کار گرفته شد که در مقایسه با رویکردهای سنتی برآوردی منطقی و مناسب ارائه داد *(Piao et al., 2019)*. پژوهش آیان و اکن[15] (۲۰۲۱) حباب قیمت در مسکن

1- Rafiei & Adeli
2- Restricted Boltzmann Machines (RBM)
3- Deep Belief
4- Deep Neural Network
5- Node
6- Seya and Shiroi
7- Kriging
8- Out of sample
9- Chen
10- Long Short-Term Memory
11- Recurrent Neural Network
12- Bae and Yu
13- Kim
14- Convolutional Neural Networks
15- Ayan and Eken

استانبول را از سال ۲۰۰۷ تا ۲۰۱۹ با استفاده از یک مدل خود رمزگذار[1] بررسی کرد. نتایج تجربی آن پژوهش نشان داد که برای تشخیص مؤثر حباب‌های مسکن می‌توان از مدل خود رمزگذار LSTM که ترکیبی از دو مفهوم قوی LSTM و خود رمزگذار است، استفاده کرد.

۳- روش پیشنهادی

روش پیشنهادشده در این مقاله بر پایه الگوریتم‌های یادگیری عمیق توسعه داده شده است. ساختار پیشنهادی این روش به‌صورت ترکیب بهبودیافته‌ی الگوریتم‌های متداول یادگیری عمیق و سیستم استنتاج فازی می‌باشد. قبل از مدل‌سازی مسئله با الگوریتم‌های پیشنهادی، بایستی آماده‌سازی و پیش‌پردازش‌های موردنیاز بر روی داده‌های ورودی انجام پذیرد. این پیش‌پردازش‌ها شامل شناسایی و حذف داده‌های پرت، شناسایی و محاسبه‌ی مقادیر نامعلوم و بررسی همبستگی میان ویژگی‌ها است. در صورت زیاد بودن پارامترهای مسئله، حذف ویژگی‌های اضافی و غیر مهم با روش‌های انتخاب ویژگی انجام می‌شود. سپس شبکه‌های عصبی عمیق متداول DNN، RNN، LSTM، CNN و AutoEncoder در کنار معماری جدید TabNet، به‌عنوان روش‌های حل مسئله‌ی قیمت‌گذاری و همچنین الگوریتم‌های پایه‌ی روش ترکیبی به‌کار گرفته می‌شوند.

TabNet یک مدل انتها به انتها[2] و خاص داده‌های جدولی است که در مقایسه با سایر مدل‌های پیشرفته عملکرد خوبی نشان داده است. این مدل، داده‌های خام را بدون هیچ پیش‌پردازشی می‌گیرد و به کمک الگوریتم‌های بهینه‌سازی مبتنی بر گرادیان کاهشی[3] آموزش می‌دهد. TabNet از توجه متوالی[4] برای انتخاب اینکه هر ویژگی در چه مرحله تصمیم‌گیری به‌کارگرفته شود، استفاده می‌کند که به تفسیرپذیری مدل منجر خواهد شد. سطح تفسیرپذیری TabNet به دو سطح محلی و سرتاسری تقسیم می‌شود. تفسیرپذیری محلی برای نشان دادن اهمیت ویژگی‌ها و اینکه چطور با یکدیگر ترکیب می‌شوند، استفاده می‌شود و تفسیرپذیری سرتاسری سهم هر ویژگی در مدل آموزش‌دیده را مشخص می‌کند. در این مدل یک معماری منفرد یادگیری عمیق نیز برای مهندسی ویژگی به‌کار گرفته می‌شود ***(Arık & Pfister, 2021)***. این الگوریتم جدید با ساختار داده‌های این مقاله متناسب است و با معماری متعارف خود به‌کار گرفته می‌شود. بنابراین نیازی به تغییر در ساختار الگوریتم برای داده‌های مسئله نیست. همچنین ازآنجایی‌که معماری جدید TabNet خاص داده‌های جدولی است، لزوم انجام پیش‌پردازش‌های لازم بر روی داده‌های مسئله را به حداقل می‌رساند. الگوریتم DNN نیز با معماری متعارف خود به‌کار گرفته می‌شود و نیازی به تغییر در ساختار الگوریتم برای داده‌های مسئله نیست. الگوریتم‌های RNN و LSTM برای داده‌هایی به‌صورت سری زمانی طراحی شده‌اند اما برای ارزیابی و مقایسه‌ی جامع‌تر الگوریتم‌های یادگیری عمیق، استفاده می‌شوند. بنابراین به‌کارگیری این شبکه برای داده‌های مسئله، نیاز به تغییرات جزئی در ساختار داده‌ها دارد. هم چنین اگرچه ساختار CNN در استخراج ویژگی به‌خوبی عمل می‌کند، اما به‌ندرت در داده‌های جدولی استفاده می‌شود، زیرا ترتیب ویژگی‌ها در این نوع داده مهم نیست. این در حالی است که ارتباط بین پیکسل‌های همسایه در تصاویر حائز اهمیت است. بااین‌وجود اخیراً CNN یک‌بعدی بهترین عملکرد را با داده‌های جدولی به دست آورده است ***(Shwartz-Ziv & Armon, 2022)***. بنابراین باوجوداینکه الگوریتم CNN برای داده‌هایی با ساختار تصویر، سیگنال و ... طراحی شده است، در مسئله‌ی حاضر CNN یک بعدی باکمی تغییر در ابعاد و شکل داده‌های جدولی مسئله، به‌کار گرفته می‌شود. به‌این ترتیب با توجه به نقطه‌ی قوت این الگوریتم در استخراج ویژگی‌ها، میزان اثرگذاری پارامترهای مؤثر بر قیمت نیز لحاظ می‌شود. رمزگذارهای خودکار نیز غالباً در کاربردهای بدون نظارت استفاده می‌شوند. در مسئله‌ی پیش رو برای کاربرد یادگیری تحت نظارت و

1- Autoencoder
2- End to End
3- Gradient Descent
4- Sequential Attention

برآورد قیمت، یک‌لایه‌ی برآوردگر به آخرین لایه پنهان[1] در خود رمزگذار متصل می‌شود. به‌این ترتیب با توجه به قابلیت حذف نویز این الگوریتم، هدف قیمت‌گذاری همراه با حذف نویز داده‌ها انجام می‌شود. در ادامه، ساختار پیشنهادی برای روش ترکیبی بهبودیافته یادگیری عمیق و سیستم استنتاج فازی شرح داده خواهد شد. در این روش ترکیبی، سیستم فازی تاکاگی–سوگنو–کانگ (TSK)[2] در نظر گرفته می‌شود *(Yazdanbakhsh & Dick, 2019)*. از طرفی برای ترکیب الگوریتم یادگیری عمیق و سیستم استنتاج فازی در قالب یک سیستم یکپارچه با ساختار هماهنگ از ترکیب هیبریدی[3] این دو روش استفاده می‌شود که پارامترهای فازی توسط الگوریتم یادگیری عمیق به دست می‌آید *(Yazdanbakhsh & Dick, 2019)*. ازآنجایی‌که در چنین سیستمی الگوریتم‌های یادگیری عمیق معمولی را مستقیماً نمی‌توان اعمال کرد، بنابراین در ساختار این الگوریتم ترکیبی به طراحی لایه‌های جدید فازی می‌پردازیم. در ادامه به شرح مدل‌سازی ساختار فازی پرداخته می‌شود. سپس نحوه ترکیب الگوریتم‌های پایه‌ی یادگیری عمیق با لایه‌های ساختار فازی، در قالب یک سیستم یکپارچه بیان می‌شود.

۳-۱- مدل‌سازی ساختار فازی

مدل‌سازی ساختار فازی چهار لایه‌ی فازی‌ساز[4]، قوانین فازی، نرمال‌سازی و فازی‌زدایی[5] را شامل می‌شود. مدل‌سازی فازی‌ساز، به‌عنوان اولین لایه‌ی قسمت فازی است. هرکدام از گره‌های این لایه، یک گره تطبیقی با یک تابع عضویت[6] مناسب است که با ورودی گره مطابقت دارد و درجه‌ی عضویت آن ورودی را مشخص می‌کند. بنابراین، این لایه شامل N گره است که به‌صورت m×n یا حاصل‌ضرب اندازه‌ی ورودی (n) و تعداد توابع عضویت برای هر متغیر ورودی (m) می‌باشد. خروجی هر گره به‌صورت رابطه(۱) است *(Guan et al., 2014)*:

$$O_{ij} = \mu_{ij}(x_i), for\ i = 1, \dots, n, \quad j = 1, \dots, m$$

رابطه (۱)

μ_{ij} تابع عضویت jم برای ورودی x_i می‌باشد. مقدار بهینه‌ی پارامترهای توابع عضویت به‌عنوان بخشی از پارامترهای شبکه طی فرایند آموزش و توسط الگوریتم پس انتشار[7] به‌دست می‌آید. به‌این ترتیب در مسئله‌ی پیش رو، به ازای هریک از پارامترهای مؤثر بر قیمت، توابع تعیین درجه‌ی عضویت اعمال شده و داده‌های ورودی به ورودی‌های فازی‌شده تبدیل می‌شوند. در قسمت طراحی قوانین فازی همه‌ی قوانین ممکن، توسط الگوریتم یادگیری عمیق به‌صورت خودکار ایجاد می‌شود. هر گره در این لایه یک گره ثابت است که تنها به یک قانون فازی TSK ارتباط دارد. درجه‌ی فعال هر قاعده‌ی k تحت‌عنوان خروجی این لایه از ضرب تمام ورودی‌های آن طبق رابطه(۲) به‌دست می‌آید *(Guan et al., 2014)*:

$$O_k = r_k = \mu_{1k}(x_1) \times \mu_{2k}(x_2) \dots \mu_{mk}(x_m)$$
$$for\ k = 1, \dots, R$$

رابطه (۲)

تعداد قواعد R به‌صورت m^n است که کلیه ترکیبات ممکن از حالت‌های مختلف ورودی را شامل می‌شود. قوانین ایجادشده توسط الگوریتم لایه‌ی عمیق در قسمت نرمال‌سازی، نرمال می‌شود. هر گره در این لایه یک گره دایره‌ای است و نرمال‌سازی هر قاعده‌ی ورودی را به‌صورت رابطه(۳) محاسبه می کند *(Jang, 1993)*:

$$O_k = \bar{r}_k = \frac{r_k}{r_1 + r_2 + \dots + r_R}, \qquad k = 1, \dots, R$$

رابطه (۳)

بنابراین در مقاله حاضر، با تقسیم هر قاعده بر مجموع قواعد ۱ تا R، قواعد قسمت فازی نرمال می‌شوند. در نهایت فازی‌زدایی به‌صورت یک لایه‌ی تک گره، خروجی‌های تمام قوانین لایه‌ی قبلی را به‌صورت رابطه(٤) ادغام می‌کند:

$$O = SUM(\bar{r}_k), \qquad k = 1, \dots, R$$

رابطه (٤)

1- Hidden Layer
2- Takagi–Sugeno–Kang
3- Hybrid
4- Fuzzification
5- Defuzzification
6- Membership Function
7- Back Propagation

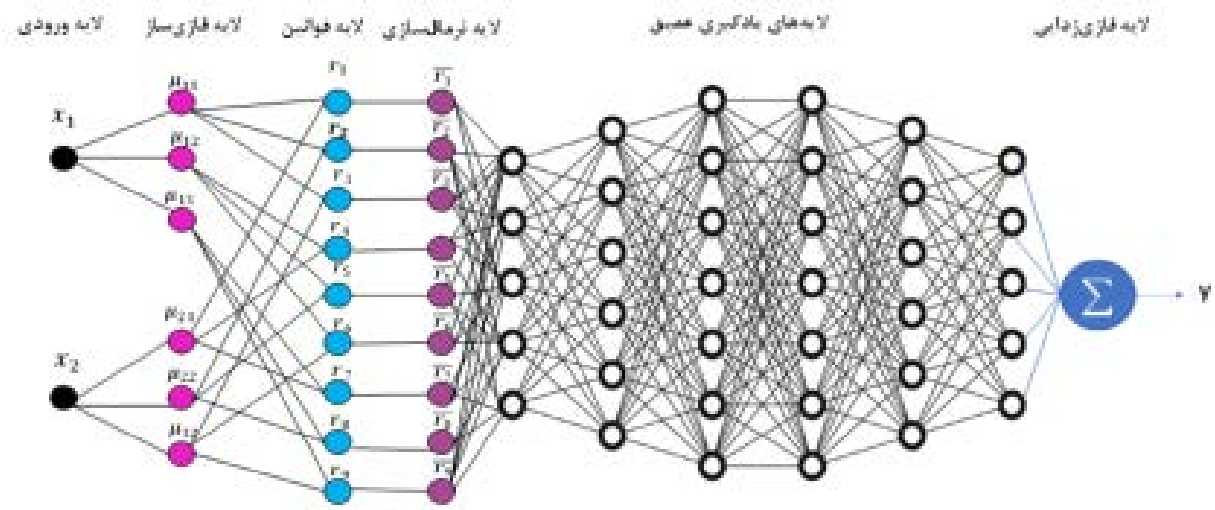

نگاره۱: ساختار ترکیب یادگیری عمیق متوالی و سیستم فازی

۳-۲- مدل‌سازی الگوریتم ترکیبی یادگیری عمیق-فازی

برای اجرای سیستم فازی در ساختار الگوریتم‌های یادگیری عمیق متوالی مانند LSTM، RNN، CNN، DNN و خود رمزگذار، تنها می‌بایست لایه‌های فازی‌ساز، قوانین و نرمال‌سازی طراحی‌شده در ابتدای این الگوریتم ترکیبی قرار گیرد و درنهایت بعد از لایه‌های شبکه عصبی عمیق، لایه‌ی فازی‌زدایی به‌کار گرفته شود (نگاره۱).

TabNet نیز با همین روش قابل‌ترکیب است؛ اما با توجه به اینکه قرارگیری لایه‌های فازی در ساختار الگوریتم‌های عمیق انتها به انتها کمی دشوار است، بایستی لایه‌های فازی در ساختار زیر کلاس‌بندی[1] لایه‌ها و کلاس‌های مدل TabNet، قبل از دیگر لایه‌ها قرار گیرد. به‌این‌ترتیب هر لایه، وزن زیر لایه‌های خود را ردیابی می‌کند. همچنین برای این الگوریتم انتها به انتها، از روش ترکیب تعمیم انباشته[2] یا انباشتن را نیز می‌توان به‌کار برد (*Ribeiro & dos Santos Coelho, 2020*). در این روش لایه‌های فازی و لایه‌های شبکه‌ی عمیق در قالب دو مدل مجزا و به‌صورت دوسطحی، در یک مدل واحد ترکیب می‌شوند (نگاره۲).

به‌این ترتیب در مسئله‌ی پیش رو سیستم استنتاج فازی در ساختار شبکه‌های عمیق به‌کار گرفته می‌شود. بنابراین به‌جای ورودی‌های معمولی، ورودی‌های فازی شده منجر به قیمت‌گذاری خواهد شد. هم‌چنین با طراحی قوانین فازی شیوه‌ی جدیدی از محاسبات در ساختار یادگیری عمیق به‌کار گرفته می‌شود.

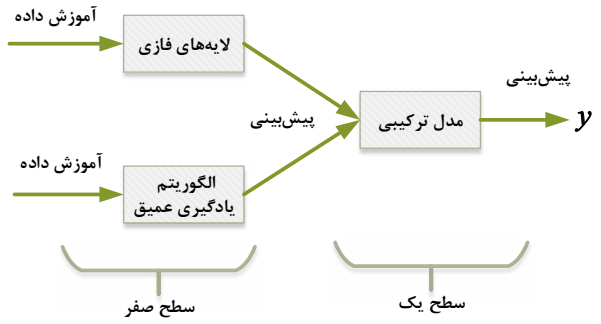

نگاره۲: ساختار ترکیب یادگیری عمیق و سیستم فازی به روش Stacking

٤- پیاده‌سازی و ارزیابی

به‌منظور پیاده‌سازی و ارزیابی روش‌های پیشنهادی در این مقاله، ۳۰ درصد داده‌ها به‌عنوان داده‌ی ارزیابی[3] و ۱۰ درصد مابقی داده‌ها به‌عنوان داده‌ی اعتبارسنجی[4] در نظر گرفته‌شده است. باقیمانده‌ی داده‌ها نیز به‌عنوان داده‌ی آموزشی[5] هستند. همچنین از روش اعتبارسنجی متقابل K-

1- Subclassing
2- Stacked Generalization
3- Test Data
4- Validation Data
5- Train data

لایه[1] با K=۱۰ برای ارزیابی دقیق‌تر مدل‌ها استفاده‌شده است *(Fan et al., 2015)*. برای ارزیابی هر روش از معیارهای آماری متداول به‌کار گرفته شده در بسیاری از پژوهش‌های قیمت‌گذاری املاک، استفاده شده است. این معیارها شامل معیارهای ارزیابی خطای جذر میانگین مربعات[2] (RMSE)، میانگین خطای‌مطلق[3] (MAE) و ضریب‌تعیین[4] (R^2) می‌شوند. برای آماده‌سازی داده‌ها و ایجاد متغیرهای مکانی از محیط نرم‌افزار ArcGIS استفاده شده است. پیاده‌سازی الگوریتم‌ها در محیط برنامه‌نویسی Python به‌کار گرفته شده است. ساختار یکپارچه‌ی لایه‌های در شبکه‌های عصبی عمیق کتابخانه‌ی آماده‌ای ندارد. لذا در این مقاله مدل‌سازی قسمت فازی به‌صورت لایه‌های سفارشی انجام شده است. هم چنین با توجه به چالش‌های مربوط به ترکیب این الگوریتم با فازی که در قسمت ۳-۲ شرح داده شد، از ساختار کلاسه‌بندی شده‌ی TabNet استفاده شده است.

٤-١- داده مورداستفاده

داده‌های ساختاری ۲۷۹٦ ملک مسکونی واقع در منطقه ۵ تهران به همراه موقعیتشان در فرودین ۱٤۰۰ از سایت "دو دوتا[5]" جمع‌آوری‌شده است (نگاره۳). اطلاعات املاک شامل قیمت، طول و عرض جغرافیایی، مساحت، تعداد پارکینگ، سال ساخت، تعداد اتاق و وجود یا عدم وجود حیاط، انباری، بالکن، آسانسور و امکانات ویژه می‌شود. برای سادگی به‌جای قیمت مترمربع، قیمت کل املاک در نظر گرفته شده است. داده‌های مکانی شامل نقشه‌ی پارک‌ها، مراکز خرید، بیمارستان، ایستگاه‌های مترو به کمک سرویس گوگل ارث انجین[6] و گوگل‌مپ[7] تهیه‌شده است. در این نقشه‌ها، امکانات اطراف و خارج از مرز منطقه‌ی ۵ نیز لحاظ شده است. داده‌ی ترافیک نیز از سازمان حمل‌ونقل و ترافیک تهیه‌شده است. ترافیک به‌عنوان یک عامل تأثیرگذار بر تمایل و تقاضای خریداران به خرید املاک و به‌تبع آن بر قیمت املاک، موردتوجه است.

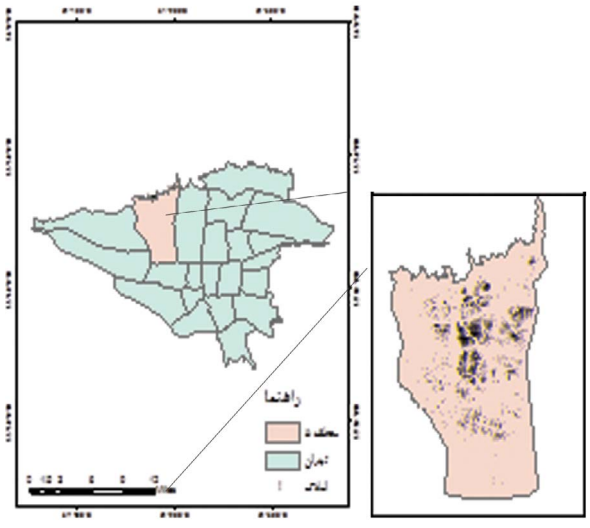

نگاره۳: منطقه‌ی مطالعه به همراه نمایش پراکندگی داده‌های املاک

٤-٢- پیش‌پردازش

در این پژوهش با استفاده از ArcGIS مکان و درواقع طول و عرض جغرافیایی با اطلاعات ساختاری ملک مرتبط شده است تا مدل قیمت‌گذاری به همراه جزئیات مکانی ایجاد شود. سپس برای در نظر گرفتن ویژگی‌های مکانی املاک دسترسی به پارک، بیمارستان، مراکز خرید و ایستگاه‌های مترو به‌صورت نقشه‌های فاصله به دست آمد. برای ساده‌تر شدن روند حل مسئله، فاصله‌ی اقلیدسی[8] در نظر گرفته شده است. همپوشانی داده موقعیت مکانی املاک با لایه دسترسی به پارک، فاصله هر ملک از پارک به‌عنوان یک ویژگی به جداول اطلاعات املاک اضافه شد. دقیقاً مشابه با این کار برای لایه‌های دسترسی به مرکز خرید، دسترسی به مترو و دسترسی به بیمارستان انجام‌شده است. این دسترسی‌ها به‌عنوان نزدیکی املاک به امکانات و خدمات مهم و با نظر کارشناسی مشاورین املاک شهر موردمطالعه انتخاب شده است. درنتیجه جدول اطلاعات توصیفی املاک شامل این پارامترها نیز می‌شود.

1- K-Fold Cross Validation
2- Root Mean Square Error
3- Mean Absolute Error
4- Coefficient of determination (R^2)
5- https://dodota.com
6- Google Earth Engine
7- Google Map
8- Euclidean Distance

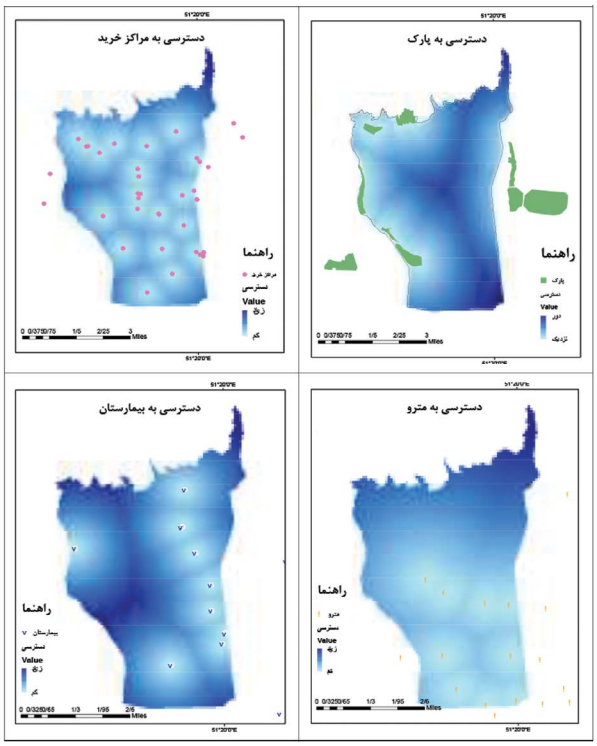

نگاره٤: نقشه‌های دسترسی برای املاک

اطلاعات ترافیک نیز شامل حوزه‌های ترافیک و راه‌ها است. ابتدا برای هر پلی‌گون مربوط به حوزه‌های ترافیک، راه‌های عبوری از آن شناسایی شده است. سپس ترافیک برای هر حوزه به‌صورت میانگین حجم ترافیک راه‌های عبوری به‌دست‌آمده است. حجم ترافیک هر راه درواقع میزان سفرهای تولیدشده است. درنهایت بازهم با همپوشانی داده موقعیت مکانی املاک با این لایه ترافیک، ترافیک هر حوزه به املاک واقع در آن منتسب شده و به‌عنوان یکی دیگر از ویژگی‌های مکانی املاک در نظر گرفته می‌شود (نگاره ۵).

در این پژوهش برای سادگی در مدل‌سازی، ترافیک که یک معیار متغیر است به‌صورت ویژگی ثابت املاک، فرض شده است. پس از آماده‌سازی ورودی، پیش‌پردازش‌های لازم در محیط Python انجام شد. اطلاعات ۱۵ ملک به دلیل پرت بودن با روش فاصله‌ی کوک[1] شناسایی و حذف شدند. وجود مقادیر نامعلوم در ویژگی‌های املاک بررسی شد. نگاره ٦ نمودار توزیع قیمت که درواقع توزیع کلی متغیر پیوسته‌ی قیمت املاک است را نشان می‌دهد. طبق این نمودار قیمت املاک در حدود ۱/۱۵ تا ٦/۷ میلیارد می‌باشد.

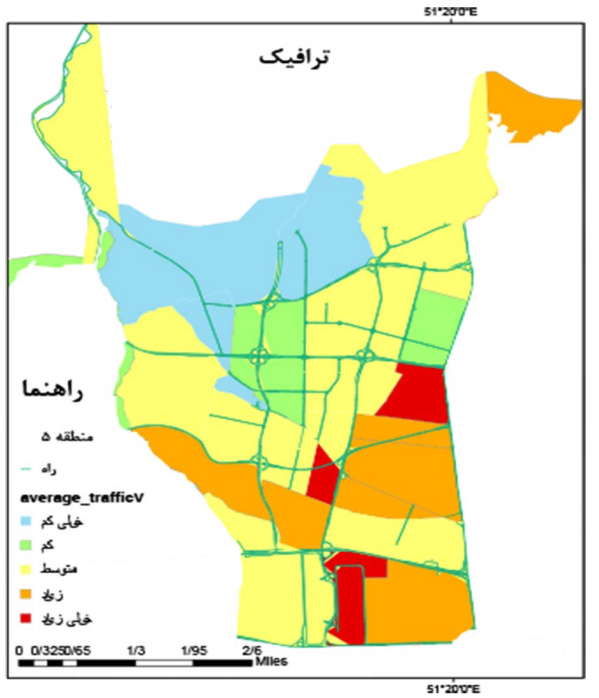

نگاره۵: نقشه‌ی ترافیک حوزه‌های ترافیک منطقه‌ی ۵ تهران

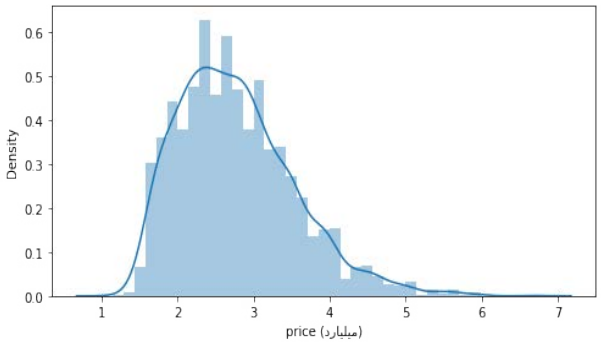

نگاره٦: نمودار توزیع متغیر پیوسته‌ی قیمت املاک

نگاره ۷ ماتریس همبستگی[2] بین ویژگی‌های ساختاری و مکانی املاک که در بخش ٤-۲ و ٤-۱ شرح داده شد و متغیر هدف (قیمت) را نشان می‌دهد. این ماتریس از نتایج ضریب همبستگی پیرسون[3] تشکیل شده است، به‌طوری‌که مقادیر در بازه منفی یک تا مثبت یک قرار دارند. مقادیر

1- Cook's Distance

2- Correlation Matrix

3- Pearson Correlation Coefficient

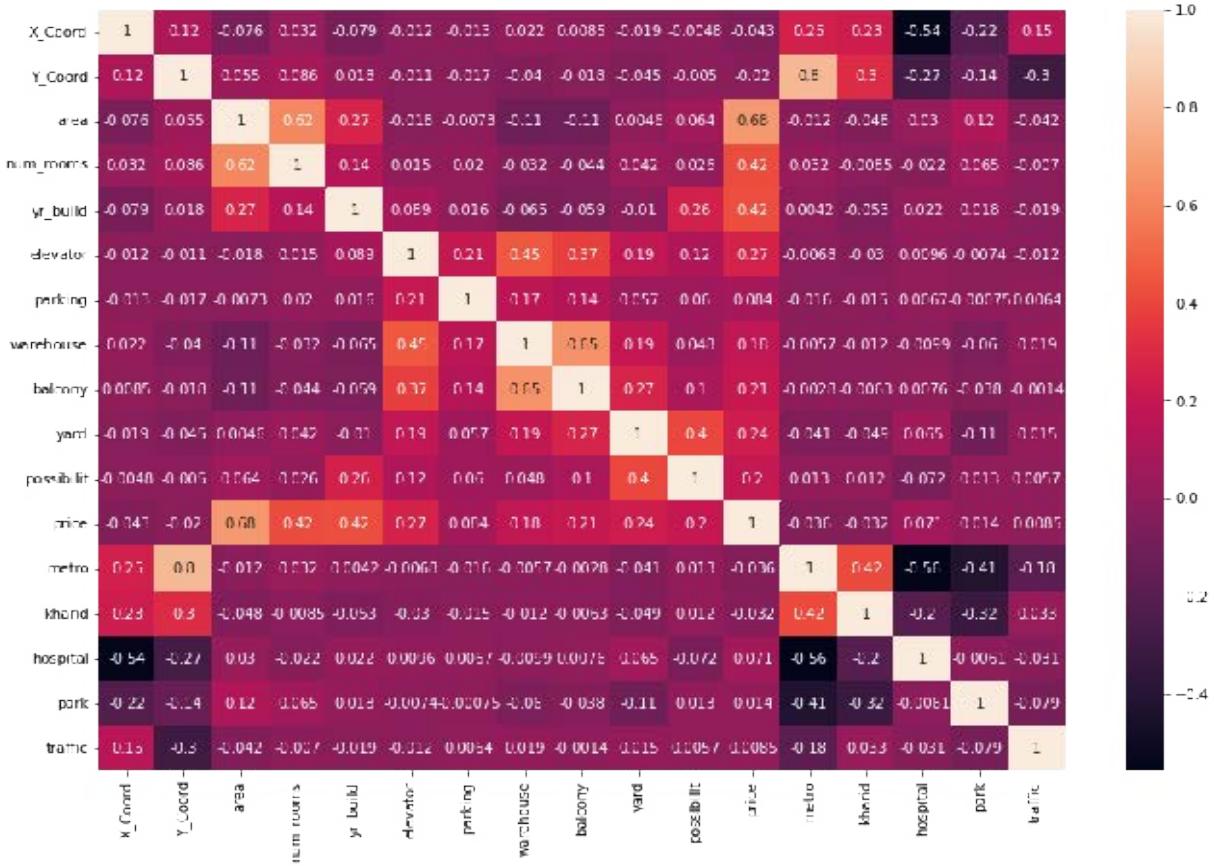

نگاره۷: ماتریس همبستگی ویژگی‌های ملک

مثبت نشان‌دهنده‌ی ارتباط مستقیم و مقادیر منفی رابطه‌ی معکوس دو ویژگی را نشان می‌دهد. هرچه مقادیر از صفر فاصله می‌گیرند، همبستگی بیشتر می‌شود. بنابراین در این ماتریس میزان همبستگی متوسط تا قوی بین ویژگی‌های ملک با متغیر هدف قابل مشاهده است. از طرفی همبستگی ویژگی‌های ملک با یکدیگر کم و نسبتاً مناسب است. این بدان معنی است که متغیرها یا ویژگی‌های انتخاب‌شده برای برآورد قیمت املاک مناسب و گویای تغییرات قیمت املاک می‌باشند.

٤-۳- پیاده‌سازی و مقایسه‌ی الگوریتم‌های یادگیری عمیق

ابتدا برای پیاده‌سازی الگوریتم‌ها، داده‌های تهران به سه قسمت آموزشی، اعتبارسنجی و ارزیابی تفکیک‌شده است. معماری شبکه‌های عمیق با آزمون و خطای معماری‌های شبکه در مسائل مشابه و اضافه و کم کردن لایه‌ها، به‌دست آمد. به‌منظور تنظیم[1] ابر پارامتر[2]های شبکه‌ها متناسب با داده‌های مسئله، از الگوریتم بهینه‌سازی بیزین[3] استفاده شده است ***(Victoria & Maragatham, 2021)***. همان‌طور که گفته شد برای DNN نیازی به تغییر در ساختار ورودی‌ها نبوده و ابعاد لایه‌ی ورودی نشان‌دهنده‌ی ١٦ پارامتر مؤثر بر قیمت ملک می‌باشد. معماری مناسب شبکه نیز شامل لایه ورودی، سه لایه‌ی پنهان تماماً متصل[4] و لایه‌ی خروجی می‌شود. برای به‌کارگیری شبکه RNN و LSTM برای داده‌های مسئله، نیاز به تغییرات جزئی در ساختار داده‌ها وجود دارد، به‌طوری‌که بایستی شکل داده‌های ورودی تغییر کرده

1- Tuning
2- Hyper Parameter
3- Bayesian Optimization
4- Fully Connected

و با ساختار ورودی در این شبکه‌ها منطبق شود. بنابراین به داده‌های جدولی املاک، بعد سوم زمان اضافه شد که تنها اطلاعات املاک در یک‌زمان ثابت را شامل می‌شود. به عبارتی بعد سوم تنها شامل یک لایه بوده و اطلاعات املاک در زمان ثابت فروردین ۱۴۰۰ را نشان می‌دهد. بنابراین برای به‌کارگیری RNN و LSTM در مسئله، ساختار ورودی تغییر کرده و ابعاد لایه‌ی ورودی نشان‌دهنده‌ی ۱۶ پارامتر مؤثر بر قیمت ملک و یک بعد زمان می‌باشد. الگوریتم RNN بعد از لایه‌ی ورودی، از دولایه RNN و یک‌لایه‌ی تماماً متصل تشکیل‌شده است و همانطور که گفته شد این معماری بهینه با آزمون و خطای معماری‌های شبکه در مسائل مشابه و اضافه و کم کردن لایه‌ها، به‌دست آمده است. به‌منظور حفظ مقادیر خروجی لایه‌های RNN در محدوده نرمال، بعدازاین لایه‌ها از لایه‌ی نرمال‌سازی دسته[1] نیز استفاده شده است.

معماری LSTM به عنوان خانواده‌ی شبکه‌ی RNN، مشابه با همان شبکه در نظر گرفته شده است ***(Zaremba et al., 2014)***؛ با این تفاوت که لایه‌های LSTM جایگزین لایه‌های RNN شده‌اند. در مسئله‌ی حاضر CNN یک‌بعدی باکمی تغییر در ابعاد و شکل داده‌های جدولی مسئله، به‌کار گرفته می‌شود. بنابراین شکل داده‌ها با اضافه شدن بعد سوم تغییریافته و داده‌های ورودی با ارتفاع ۱ و عرض ۱۶ که شامل پارامترهای تأثیرگذار بر قیمت هستند، وارد شبکه می‌شوند. معماری مناسب این الگوریتم شامل دولایه‌ی پیچشی[2] و یک لایه‌ی ادغام[3] با عملگر بیشینه است. همچنین از یک لایه‌ی انصراف[4] استفاده شده است که با حذف تصادفی تعدادی از گره‌ها در هر تکرار آموزش، آموزش مستقل گره‌ها را بهبود بخشیده و از برازش بیش‌ازحد[5] جلوگیری می‌نماید. در انتها پیش از لایه‌های تماماً متصل، ویژگی‌های استخراج‌شده‌ی لایه‌های پیچشی در لایه‌های مسطح[6] بار دیگر به‌صورت خطی تغییر شکل یافته و به بردار تبدیل شدند. همچنین در پژوهش پیش رو برای کاربرد یادگیری تحت نظارت و برآورد قیمت، یک‌لایه‌ی برآوردگر به آخرین لایه پنهان در خود رمزگذار متصل شده است. پس از حذف نویز ورودی‌ها در لایه‌های خود رمزگذار، برآورد قیمت در این لایه انجام می‌شود. هر دو بخش رمزگذار[7] و رمزگشای[8] این شبکه از لایه‌های تماماً متصل تشکیل شده‌اند. در این شبکه نیز از لایه نرمال‌سازی دسته استفاده شده است. الگوریتم جدید TabNet بدون نیاز به تغییر در ساختار داده‌ها یا شبکه، با ساختار متعارف خود به‌کار گرفته‌شده است. از طرفی ابر پارامترهای این الگوریتم یادگیری عمیق با دیگر الگوریتم‌ها متفاوت است که در جدول ۱ به تعدادی از آن‌ها پرداخته‌شده است. باقی پارامترها به‌صورت پیش‌فرض انتخاب شده‌اند.

به‌منظور مقایسه‌ی قدرت پیش‌بینی الگوریتم‌های یادگیری عمیق نتایج سه معیار ارزیابی بر روی مجموعه داده‌ی ارزیابی در جدول ۲ ارائه شده است. نتایج الگوریتم افزایش گرادیان اکسترمم[9] (XGBoost) نیز به‌عنوان یکی از متداول‌ترین الگوریتم‌های یادگیری ماشین برای داده‌های جدولی، لحاظ شده است. این الگوریتم در سال ۲۰۱۶ توسط چن و گواسترین معرفی شد ***(Chen & Guestrin, 2016)***. در کاربردهای قیمت‌گذاری املاک، XGBoost در مقایسه با الگوریتم‌های سنتی‌تر مانند رگرسیون خطی نتایج بهتری داشته است ***(Peng et al., 2019)***؛ بنابراین به‌عنوان نماینده‌ی قابل‌قبول سایر الگوریتم‌ها با الگوریتم‌های یادگیری عمیق مقایسه شده است. مقادیر کمتر RMSE و MAE ضمن در نظر گرفتن بازه‌ی مقادیر قیمت املاک، بهتر هستند. اگرچه برای معیار R^2 مقادیر بیشتر از ۵۰ درصد قابل‌قبول است، ولیکن افزایش این مقدار و نزدیکی آن به ۱۰۰ درصد، موجب افزایش تناسب مدل‌ها خواهد شد.

1- Batch Normalization
2- Convolutional Layer
3- Pooling Layer
4- Dropout Layer
5- Overfitting
6- Flatten Layer
7- Encoder
8- Decoder
9- Extreme Gradient Boosting (XGBoost)

جدول۱: ابر پارامترهای TabNet

ابر پارامتر	تعریف	مقدار بهینه
n_d	عمق لایه‌ی پیش‌بینی تصمیم/ مقادیر بزرگ‌تر ظرفیت بیشتری را به مدل می‌دهد.	۲٤
n_a	عمق به‌کارگیری مکانیسم توجه برای هر ماسک/ معمولاً n_d=n_a مقدار خوبی است.	۲٤
n_steps	تعداد مراحل معماری	٦
Gamma	این ضریب برای استفاده‌ی مجدد ویژگی در ماسک‌ها می‌باشد. مقدار نزدیک به ۱ باعث می‌شود که انتخاب ماسک کمترین همبستگی را بین لایه‌ها داشته باشد.	۲
n_independent	تعداد لایه‌های واحدهای خطی دروازه‌ای مستقل در هر مرحله	۲
ابر پارامتر	تعریف	مقدار بهینه
n_shared	تعداد واحدهای خطی دروازه‌ای مشترک در هر مرحله	۲
Momentum	تکانه برای نرمال‌سازی دسته‌ای	۰/٤
lambda_sparse	ضریب اتلاف پراکندگی اضافی است. هرچه این ضریب بزرگ‌تر باشد، مدل ازنظر انتخاب ویژگی محدودتر خواهد بود. بسته به پیچیدگی مسئله، کاهش این مقدار کمک‌کننده می‌باشد.	۱e-٤
mask_type	تابع ماسک کردن برای انتخاب ویژگی‌ها	"entmax“
Patience	تعداد دوره‌های متوالی بدون بهبود برای انجام توقف اولیه	۵۰
batch_size	تعداد نمونه در هر دسته	۵۱۲

جدول۲: مقایسه‌ی الگوریتم‌های یادگیری عمیق
(مجموعه داده تهران)

	RMSE	MAE	R^2
DNN	۰/٤٦	۰/۳۵	۰/۵٦
RNN	۰/٤۷	۰/۳۵	۰/٦۰
LSTM	۰/٤٦	۰/۳٦	۰/٦۳
CNN	۰/٤٤	۰/۳٤	۰/٦۰
خود رمزگذار	۰/٤٦	۰/۳۵	۰/٦۲
TabNet	۰/٤۳	۰/۳۳	۰/٦۸
Xgboost	۰/٤۱	۰/۳۲	۰/۷۰

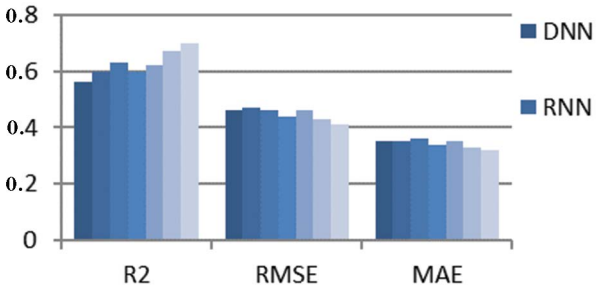

نگاره۸: نمودار مقایسه‌ی روش‌های یادگیری عمیق و XGBoost بر اساس معیارهای ارزیابی

با توجه به نتایج جدول کلیه معیارها نشان‌دهنده برتری مدل TabNet نسبت به دیگر مدل‌های یادگیری عمیق است. براساس نتایج به‌دست‌آمده TabNet در بین شبکه‌های عمیق خطای کمتر و درنتیجه کارایی بیشتری در پیش‌بینی قیمت املاک داشته است. مقدار R^2 و نزدیکی مقادیر پیش‌بینی‌شده‌ی TabNet و مقادیر واقعی قیمت در نگاره۹، تأییدی بر این ادعاست. البته با توجه به اینکه اختلاف بین R^2 این الگوریتم‌ها کم است، به‌طور دقیق قابل‌شناسایی و تحلیل نمی‌باشد، اما به‌طور کل ماحصل این بصری‌سازی برای کل داده، در مقدار این معیار نشان داده شده است.

بر اساس نتایج نشان داده‌شده در جدول ۲ در این ارزیابی LSTM بر اساس معیار R^2 به‌عنوان دومین الگوریتم یادگیری عمیق مناسب شناخته‌شده است. باوجود به‌کارگیری داده‌های جدولی مقطعی همچنان پیچیدگی بلوک‌های LSTM موجب بهبود دقت بلوک‌های RNN معمولی شده است. همچنین دو بخش رمزگذار و رمزگشای شبکه‌ی خود رمزگذار در مقایسه با یک شبکه‌ی عمیق معمولی دقت را افزایش داده است. از طرفی تعداد کم داده‌های املاک تهران موجب شده

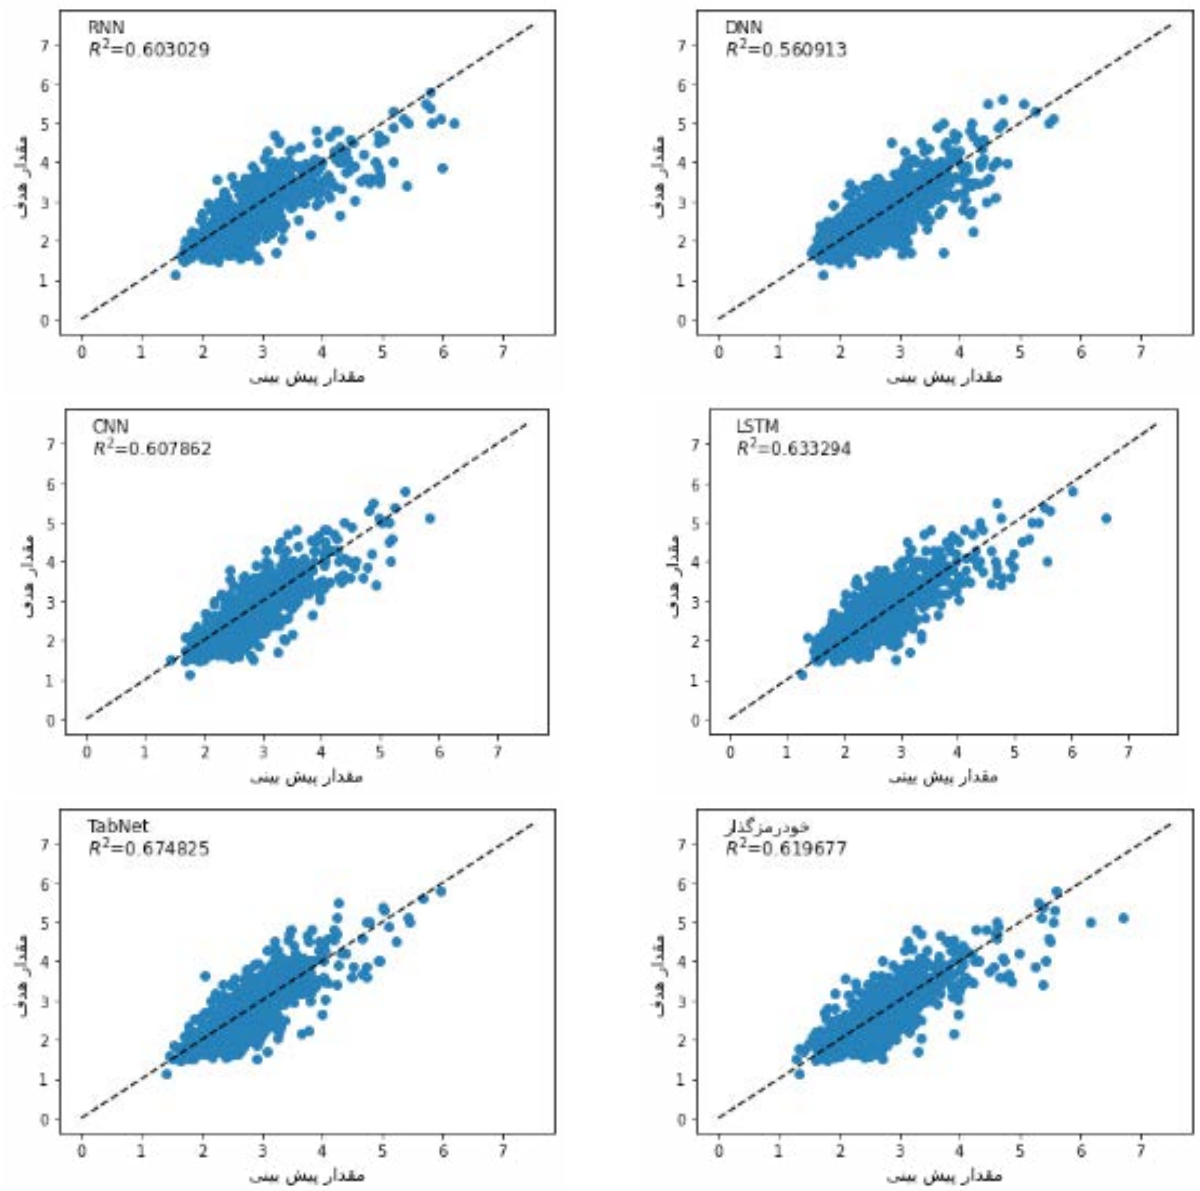

نگاره۹: نمودار مقدار واقعی و پیش‌بینی‌شده‌ی الگوریتم‌ها

است که برخلاف انتظار،از لحاظ معیار R^2 شبکه‌ی CNN در مواجهه با داده‌های جدولی ملک برتری قابل‌توجهی را کسب نکند. بااین‌حال این روش ازلحاظ دو معیار دیگر در جایگاه دومین الگوریتم یادگیری عمیق مناسب قرارگرفته است. همان‌طور که قبلاً اشاره شده است، در ارزیابی نهایی به دلیل اهمیت کاهش متوسط خطای پیش‌بینی در مسئله، معیار خطای RMSE ملاک قرارگرفته است و معیار R^2 به‌دلیل تأثیرپذیری از انحراف معیار و توجه به نتیجه‌ی موردی کمتر مورد توجه است. همچنین داده‌های پرت املاک غالباً بیانگر مقدارهای غیرمعمول بوده و کمتر حاصل مشاهدات مخدوش است. از طرفی معیار MAE اثر این داده‌های پرت را در برآورد مدل از بین می‌برد. لذا به‌نظر می‌رسد که همچنان استفاده از معیار RMSE به نسبت MAE مفیدتر باشد. کمتر بون معیار MAE به نسبت RMSE نیز به همین دلیل قابل توجیه است. در ادامه برتری الگوریتم XGBoost نسبت به TabNet و همچنین سایر شبکه‌های

عمیق به‌کاررفته، بر این احتمال تأکید می‌کند که کم بودن تعداد داده‌ها مانع از دستیابی به نتیجه‌ی مطلوب و ایده‌آل روش‌های یادگیری عمیق شده است. درنهایت با در نظر گرفتن نتایج کلیه روش‌ها به‌نظر می‌رسد که قیمت املاک در تهران به بسیاری از پارامترهای دیگر همچون نمای ساختمان، تعداد واحدهای آپارتمانی موجود در هر طبقه و در کل ساختمان، سیستم‌های گرمایشی و سرمایشی و موضوع پرستیژ، زیبایی و کلاس اجتماعی کوچه‌ها و خیابان‌ها ربط دارد. اضافه بر این، نیازهای شدید شخص فروشنده به فروش ملک و یا نیاز خاص خریدار به خرید عجولانه، گاهی باعث تغییرات شدید در قیمت هر ملک خاص می‌شود. این عوامل باعث کاهش دقت در نتایج همه‌ی الگوریتم‌ها می‌شود.

٤-٤- پیاده‌سازی الگوریتم ترکیبی یادگیری عمیق فازی و مقایسه با الگوریتم‌های پایه

برای پیاده‌سازی الگوریتم ترکیبی ابتدا با توجه به نتایج قسمت قبل، TabNet به‌عنوان بهترین الگوریتم یادگیری عمیق، انتخاب‌شده است. سپس لایه‌های فازی به‌صورت لایه‌های سفارشی[1] ایجاد شد. در ساختار قسمت فازی بعد از لایه‌ی ورودی لایه‌ی فازی‌ساز قرارگرفته است. تعداد گره‌های تطبیقی این لایه به تعداد ویژگی‌ها و همین‌طور تعداد توابع عضویت بستگی دارد. با توجه به افزایش قواعد و به‌تبع آن مشکل افزایش محاسبات، دو تابع عضویت به ازای هر ویژگی در نظر گرفته شده است. به‌این ترتیب برای داده‌های تهران با توجه به ١٦ ویژگی مسئله، تعداد گره‌ها ٣٢ بوده است. بر اساس آزمون‌وخطا، تابع عضویت گوسی با دو پارامتر μ ، σ به‌عنوان تابع عضویت مناسب انتخاب شد که خروجی هر گره با توجه به این توابع عضویت، درجه‌ی عضویت هریک از ویژگی‌ها را به مجموعه‌ی فازی مربوطه نشان می‌دهد. درنهایت خروجی این لایه شامل ورودی‌های فازی شده می‌شود. خروجی‌های این لایه وارد لایه‌ی قوانین شده است که تعداد گره‌های ثابت آن به تعداد قواعد یا به عبارتی تعداد ویژگی‌ها به توان تعداد توابع عضویت، می‌باشد. در این لایه بخش مقدم قوانین به‌صورت همه‌ی ترکیبات ممکن از ورودی‌های فازی شده‌ی لایه‌ی قبل، ایجاد می‌شود. بخش نتیجه‌ی قوانین نیز مقادیر غیرفازی قیمت املاک است. لایه بعد و یا لایه نرمال‌سازی نیز شامل گره‌های دایره‌ای است که خروجی‌های لایه‌ی قبل را نرمال کرده است. در انتها لایه‌ی فازی‌زدایی با تک گره، قوانین نرمال‌شده‌ای را که چه به‌صورت مستقیم یا غیرمستقیم به‌دست آمده است، به‌صورت مجموع وزنی ادغام می‌کند. منظور از محاسبه‌ی مستقیم قوانین لایه‌ی نرمال‌سازی این است که خروجی لایه‌ی نرمال‌سازی بدون وجود لایه‌ای دیگر، مستقیماً وارد لایه‌ی فازی‌زدایی شود. در حالت غیرمستقیم نیز بعد از لایه‌ی نرمال‌سازی قوانین، تعدادی از لایه‌های شبکه مانند لایه تماماً متصل، پیچشی و ... قرار داشته است و سپس لایه‌ی فازی‌زدایی به‌کار گرفته می‌شود. درنهایت وزن هر قاعده به‌عنوان پارامترهای این لایه در نظر گرفته شده است. باید توجه داشت که برای عمیق‌تر شدن قسمت فازی از لایه‌های تماماً متصل پس از لایه فازی‌زدایی استفاده شده است. ابتدا به روش ترکیب انباشتن، لایه‌های فازی و TabNet بهینه‌ی قسمت قبل، در قالب دو مدل مجزا و به‌صورت دوسطحی، در یک مدل واحد ترکیب شده‌اند. سپس برای ارزیابی دقیق‌تر، الگوریتم ترکیبی به روش زیر کلاس‌بندی نیز ایجاد شد. برای این ترکیب لایه‌های فازی‌ساز، قوانین و نرمال‌سازی در ساختار زیر کلاس‌بندی لایه‌ها و کلاس‌های مدل TabNet، قبل از دیگر لایه‌ها قرار گرفت. لایه‌ی فازی‌زدایی نیز پس از همه‌ی لایه و قبل از لایه‌ی خروجی TabNet به‌کار گرفته شد. پارامترهای n_d، n_a،n_steps و gamma به‌ترتیب ٢، ٣٦، ٣٦ و ١/٢ انتخاب شده است. در ادامه به ترکیب شبکه‌ی خود رمزگذار با لایه‌های فازی پرداخته شد. برای اجرای این سیستم فازی در بخش رمزگذار این شبکه، لایه‌های فازی به روش متوالی به‌کار گرفته شد. در ابتدا برای کاهش

1- Custom Layer

قوانین و حجم محاسبات فازی از روش کاهش بعد تحلیل مؤلفه‌های اصلی (PCA) [1] استفاده شد (*Khalid et al., 2014*) و با آزمون‌وخطا ویژگی‌ها ادغام و تعداد هشت ویژگی استخراج شد. به‌عنوان روش جایگزین، قرار دادن یک‌لایه تماماً متصل با تعداد گره کمتر، پیش از لایه‌ی فازی‌ساز به افزایش دقت منجر شد.

درنهایت به‌جز قسمت‌های فازی، ساختار بهینه‌ی الگوریتم ترکیبی خود رمزگذار فازی مشابه الگوریتم پایه‌ی خود رمزگذار است. برای ارزیابی روش ترکیبی یادگیری عمیق-فازی برای داده‌های تهران، در جدول ۳ به مقایسه‌ی نتایج الگوریتم‌های ترکیبی با شبکه‌های پایه پرداخته شده است.

جدول ۳: مقایسه‌ی الگوریتم ترکیبی یادگیری عمیق-فازی با الگوریتم‌های پایه

	RMSE	MAE	R^2
TabNet	۰/٤۳	۰/۳۳	۰/٦۸
TabNet (ترکیب به روش انباشتن)	۰/٤۱	۰/۳۲	۰/۵۵
TabNet (ترکیب به روش زیر کلاس‌بندی)	۰/٤۷	۰/۳۵	۰/٦۲
خود رمزگذار	۰/٤٦	۰/۳۵	۰/٦۲
خود رمزگذار فازی	۰/٤۳	۰/۳۳	۰/۵۹

با توجه به جدول ۳ و بر اساس دو معیار RMSE و MAE، ترکیب الگوریتم TabNet به روش انباشتن موجب بهبود دقت شده است. همچنین مقایسه‌ی این دو معیار بهبودیافته و نتایج جدول ۳ نشان‌دهنده‌ی برتری این روش ترکیبی نسبت به همه‌ی روش‌های یادگیری عمیق و برابری با XGBoost می‌باشد. بااین‌حال این روش در معیار سوم نتیجه‌ی قابل قبولی نداشته است. همان‌طور که پیش‌ازاین گفته شد در این ترکیب سیستم استنتاج فازی و TabNet به‌صورت دو مدل مجزا در نظر گرفته شده‌اند؛ بنابراین دقت هر دو مدل پایه بر روی فرا مدل نهایی تأثیرگذار است. ازآنجایی‌که ساختار فازی به‌تنهایی نتیجه‌ی بسیار دقیقی نداشته است عدم بهبود معیار سوم ارزیابی، قابل توجیه به‌نظر می‌رسد. با توجه به نتایج، استفاده از زیر کلاس‌بندی برای ایجاد این ساختار ترکیبی، به افزایش این معیار منجر می‌شود. اگرچه بازهم معیار موردنظر در مقایسه با الگوریتم پایه بهبودی نداشته است، اما بااین‌حال در رقابت با سایر الگوریتم‌های یادگیری عمیق مقدار قابل قبولی دارد. البته این ترکیب ازلحاظ دو معیار RMSE و MAE بهبودی نداشته است. بازهم بر اساس دو معیار RMSE و MAE، ترکیب الگوریتم خود رمزگذار و فازی موجب بهبود دقت و برتری این الگوریتم نسبت به همه‌ی الگوریتم‌های یادگیری عمیق شده است. البته باید توجه داشت که به‌طور کل ترکیب TabNet و فازی از این ترکیب بهتر عمل کرده است. همچنان این ترکیب ازلحاظ معیار سوم بهبودی نداشته است. بااین‌حال این معیار مقدار قابل قبولی داشته است. بنابراین باوجود اینکه ترکیب سیستم استنتاج فازی و الگوریتم‌های یادگیری عمیق همواره و بر اساس تمام معیارهای ارزیابی بهبود قابل‌توجهی نداشته است، بااین‌حال منجر به بهبود قابل‌قبول دو معیار RMSE و MAE شده است. همان‌طور که اشاره شد در ارزیابی نهایی مسئله به دلیل اهمیت کاهش متوسط خطای پیش‌بینی، معیار خطای RMSE ملاک قرار گرفته است و معیار R^2 به‌دلیل تأثیرپذیری از انحراف معیار و توجه به نتیجه‌ی موردی کمتر مورد توجه است. درنتیجه با توجه به این ارزیابی در مسائلی که با عدم قطعیت و لزوم استفاده از منطق فازی همراه است، بهتر است از الگوریتم ترکیبی یادگیری عمیق-فازی استفاده شود.

٤-۵- تحلیل اهمیت پارامترهای مکانی

ترتیب و اولویت‌بندی تأثیرگذاری ویژگی‌ها در قیمت‌گذاری املاک مسکونی تهران توسط الگوریتم TabNet که دقت بهتری داشته، مشخص‌شده است (نگاره ۱۰). این ویژگی‌ها در بخش ٤-۲ و٤-۱ شرح داده شد.

1- Principal Component Analysis

الگوریتم TabNet با توجه به سطح تفسیرپذیری سرتاسری خود، سهم هر ویژگی در مدل آموزش‌دیده را مشخص کرده است. نتایج نشان‌دهنده‌ی آن است که اکثر متغیرها معنادار هستند. باوجود اینکه بعضی از عوامل ساختاری بیشتر از عوامل مکانی قیمت واحد مسکونی را تحت‌تأثیر قرار می‌دهند، اما به‌طور کل عوامل مکانی تأثیر قابل‌توجهی داشته‌اند. مساحت به‌عنوان یک ویژگی ساختاری، مهم‌ترین ویژگی تأثیرگذار بر قیمت است. در رتبه‌ی دوم و سوم ویژگی‌های تأثیرگذار، طول و عرض جغرافیایی قرارگرفته است که به‌عنوان مهم‌ترین ویژگی مکانی اثرگذار بر قیمت ملک قابل مشاهده‌اند.

اساساً طول و عرض جغرافیایی بیانگر معیار محلات و تیپ و پرستیژ مکان‌های مختلف شهر و کلاس اجتماعی خیابان‌ها و محله‌های مختلف شهری است که مشخصاً عامل تأثیرگذاری در قیمت محسوب می‌شود. همچنین در میان ویژگی‌های مکانی دسترسی به مترو رتبه‌ی سوم را دارا است. با توجه به نگاره ٤، دسترسی مترو در نواحی مرکزی و جنوبی منطقه بیشتر است، بنابراین انتظار می‌رود که ارزش املاک نیز در این نواحی نسبتاً بیشتر باشد.

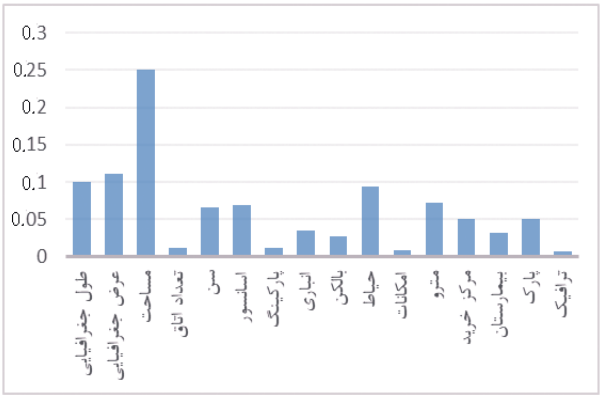

نگاره۱۰: نمودار رتبه‌بندی اهمیت ویژگی‌ها به روش TabNet

در نگاره ۱۱ نقشه‌ی منطقه‌ای املاک منطقه‌ی ۵ تهران تهیه شده است. قیمت‌ها در این نقشه نیز نتیجه قیمت‌گذاری املاک مسکونی توسط الگوریتم TabNet می‌باشد.

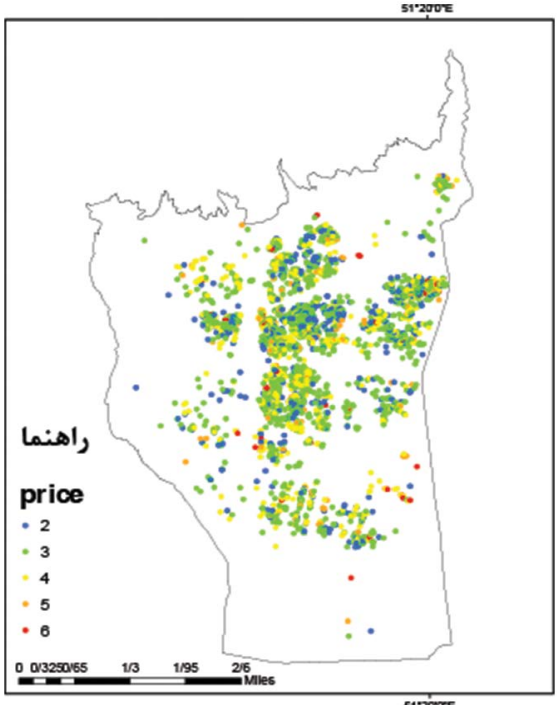

نگاره۱۱: نقشه منطقه‌ای املاک قیمت‌گذاری شده به روش TabNet

۵- نتیجه‌گیری و پیشنهادات

با توجه به اهمیت روزافزون مسکن و لزوم قیمت‌گذاری دقیق آن، در این مقاله به ساختار داده‌ها توجه شده است و ضمن به‌کارگیری الگوریتم‌های متداول یادگیری عمیق از معماری جدید TabNet که خاص داده‌های جدولی است، استفاده شده است که ازجمله تفاوت‌های این مقاله با سایر مطالعات صورت گرفته، محسوب می‌شود. در این مقاله سعی شده است با در نظر گرفتن موقعیت نسبتاً دقیق املاک و فاصله‌ی اقلیدسی از مراکز مهم تأثیرگذار بر قیمت مانند بیمارستان، مراکز خرید، مترو و پارک، بر روی جنبه‌ی مکانی مسئله نیز تمرکز شود. درنهایت برای مدل‌سازی عدم قطعیت ذاتی پارامترهای تأثیرگذار بر قیمت املاک به‌عنوان یکی از اهداف اصلی، منطق فازی با الگوریتم‌های یادگیری عمیق TabNet و خود رمزگذار ترکیب شده است. برای یک ترکیب یکپارچه، در ساختار این الگوریتم ترکیبی به طراحی لایه‌های جدید فازی پرداخته شده است.

لایه‌های فازی شامل چهار لایه‌ی فازی‌ساز، قوانین فازی، نرمال‌سازی و فازی‌زدایی می‌باشد. درنهایت بخش فازی در ابتدای الگوریتم خود رمزگذار به‌صورت دنباله‌ای قرار گرفته است. برای ترکیب TabNet و بخش فازی نیز از دو روش متفاوت انباشتن و زیر کلاس‌بندی استفاده شده است. به‌منظور ارزیابی نتایج الگوریتم‌های یادگیری عمیق، داده‌های ۲۷۹۷ ملک مسکونی تهران با یکدیگر مقایسه شد. برای مقایسه‌ی قابل‌اطمینان‌تر، نتایج الگوریتم XGBoost نیز به‌عنوان یکی از رایج‌ترین الگوریتم‌های یادگیری ماشین در مسائل رگرسیون، لحاظ شده است. در آخر برای ارزیابی روش ترکیبی یادگیری عمیق-فازی بر روی داده‌های تهران، به مقایسه‌ی نتایج این الگوریتم با شبکه‌های پایه پرداخته شده است. رتبه‌بندی تأثیرگذاری ویژگی‌ها در قیمت‌گذاری املاک مسکونی تهران نیز توسط الگوریتم TabNet که دقت بهتری داشته، مشخص‌شده است. نتایج رتبه‌بندی ویژگی‌ها حاکی از آن است که اکثر متغیرها معنادار بوده و به‌درستی انتخاب شده‌اند. البته باوجود اینکه بعضی از عوامل ساختاری بیشتر از عوامل مکانی، قیمت واحد مسکونی را تحت‌تأثیر قرار می‌دهند، اما به‌طورکلی عوامل مکانی تأثیر قابل‌توجهی داشته‌اند. رتبه‌ی دوم و سوم تأثیرگذاری ویژگی‌های طول و عرض جغرافیایی تأییدی بر این ادعاست. همچنین در میان ویژگی‌های مکانی دسترسی به مترو نیز تأثیر قابل‌توجهی داشته است. با توجه به جدول ۱ در مجموعه داده تهران کلیه معیارها نشان‌دهنده برتری مدل TabNet نسبت به دیگر مدل‌های یادگیری عمیق بوده است. این نتایج بیانگر کارایی بیشتر این الگوریتم در پیش بینی قیمت املاک و بهبود پنج درصدی R^2 است. بااین‌حال الگوریتم یادگیری ماشین XGBoost بهتر از TabNet و دیگر الگوریتم‌های یادگیری عمیق عمل کرده است. این برتری بر این احتمال تأکید می‌کند که کم بودن تعداد داده‌ها مانع از دستیابی به نتیجه‌ی مطلوب و ایده آل روش‌های یادگیری عمیق شده است. همچنین با در نظر گرفتن نتایج کلیه روش‌ها به‌نظر می‌رسد که ارتباط بین قیمت املاک تهران و تعدادی پارامتر ازجمله نمای ساختمان، تعداد واحدهای آپارتمانی موجود در هر طبقه و در کل ساختمان، سیستم‌های گرمایشی و سرمایشی و موضوع پرستیژ، زیبایی و کلاس اجتماعی کوچه‌ها و خیابان‌ها، قابل توجه است. شایان‌ذکر است که عواملی از قبیل نیاز فوری فروشنده به فروش ملک و یا نیاز خاص خریدار به خرید عجولانه نیز می‌توانند سبب تغییرات شدید در قیمت هر ملک خاص شوند. درمجموع، عوامل ذکرشده در بالا منجر به کاهش دقت در نتایج همه‌ی الگوریتم‌ها می‌شود. به‌طور کلی عملکرد مناسب یادگیری عمیق TabNet در مقایسه با دیگر الگوریتم‌های یادگیری عمیق بیان‌کننده‌ی اهمیت توجه به ساختار داده‌ها و تعدادشان در انتخاب الگوریتم یادگیری عمیق مناسب است. درنهایت ارزیابی دو معیار RMSE و MAE ترکیب الگوریتم TabNet به روش انباشتن بیانگر بهبود و برتری این روش ترکیبی نسبت به الگوریتم پایه TabNet و دیگر روش‌ها بوده است. طبق نتایج RMSE این الگوریتم ترکیبی نسبت به الگوریتم پایه‌ی TabNet ٤/٦٥ درصد کاهش‌یافته است که بیان‌کننده‌ی بهبود خطای متوسط پیش‌بینی بوده است. بااین‌حال ارزیابی معیار سوم نتیجه‌ی قابل قبولی نداشته است که نشان‌دهنده‌ی وجود اختلاف پیش‌بینی و انحراف از معیار تعدادی از نمونه‌هاست. با توجه به اینکه در این ترکیب سیستم استنتاج فازی و TabNet به‌صورت دو مدل مجزا در نظر گرفته‌شده است، دقت هر دو مدل پایه بر روی فرا مدل نهایی تأثیرگذار است. ازآنجایی‌که ساختار فازی به‌تنهایی نتیجه‌ی بسیار دقیقی نداشته است، عدم بهبود معیار سوم ارزیابی قابل توجیه به‌نظر می‌رسد. با استفاده از روش ترکیب زیر کلاس‌بندی تا حدودی این معیار افزایش‌یافته است که موجب افزایش درجه‌ی تناسب مدل با تمامی داده‌ها شده است. بااین‌حال به دلیل عدم بهبود دو معیار RMSE و MAE، متوسط خطای پیش‌بینی کاهشی نداشته است. اما بااین‌حال معیار موردنظر در مقایسه با الگوریتم پایه بهبودی نداشته است. ازلحاظ دو معیار RMSE، MAE نیز بهبودی مشاهده نمی‌شود و متوسط خطای پیش‌بینی کاهشی

نداشته است. اما بااین‌وجود ازلحاظ هر سه معیار ارزیابی، این ترکیب در رقابت با سایر الگوریتم‌های یادگیری عمیق مقدار قابل قبولی داشته است. در آخر تفاوت در بهبود نتایج ترکیب TabNet و فازی به دو روش انباشتن و زیر کلاس‌بندی بیانگر تأثیر انتخاب روش ترکیب، در بهبود این الگوریتم‌های ترکیبی است. همچنین برای ترکیب دنباله‌ای خود رمزگذار و فازی نیز ازلحاظ دو معیار RMSE و MAE بهبود قابل قبولی مشاهده شده است که بازهم تأییدی بر نتیجه‌ی قابل‌قبول این روش ترکیبی بوده است. به‌علاوه نتایج بیانگر برتری الگوریتم خود رمزگذار فازی نسبت به همه‌ی الگوریتم‌های یادگیری عمیق است. البته باید توجه داشت که به‌طور کل ترکیب TabNet و فازی از این ترکیب بهتر عمل کرده است. بنابراین باوجود اینکه ترکیب سیستم استنتاج فازی و الگوریتم‌های یادگیری عمیق براساس تمام معیارهای ارزیابی بهبود قابل‌توجهی نداشته است، بااین‌حال منجر به بهبود قابل‌قبول دو معیار RMSE و MAE شده است. همان‌طور که اشاره شد در ارزیابی نهایی مسئله به دلیل اهمیت کاهش متوسط خطای پیش‌بینی، معیار خطای RMSE ملاک قرارگرفته است و معیار R^2 به دلیل تأثیرپذیری از انحراف معیار و توجه به نتیجه‌ی موردی کمتر موردتوجه است. درنتیجه با توجه به این ارزیابی در مسائلی که با عدم قطعیت و لزوم استفاده از منطق فازی همراه است، به‌نظر می‌رسد که بهتر است از الگوریتم ترکیبی یادگیری عمیق-فازی استفاده شود. از طرفی با توجه به اینکه روش مناسب برای دستیابی به مزایای هردو روش و حل مشکلات مربوط به هرکدام، ترکیب آن‌ها در یک سیستم یکپارچه است، در پژوهش ترکیب یکپارچه‌ی مفاهیم فازی به یادگیری عمیق معرفی‌شده است تا ضمن یادگیری سریع و دقیق‌تر مسائل پیچیده، بر کاستی‌های قطعی بودن مدل‌های یادگیری عمیق و در نظر نگرفتن عدم قطعیت در این مدل‌ها غلبه شود.

با توجه به اینکه اضافه کردن لایه‌های فازی به افزایش پارامترهای قابل‌آموزش منجر می‌شود، انتظار می‌رود که با افزایش داده‌ها بهبود قابل‌توجه‌تری برای این الگوریتم ترکیبی مشاهده شود؛ بنابراین به‌منظور انجام مطالعه و تحقیقات آتی در راستای این مقاله می‌توان از ترکیب الگوریتم‌های یادگیری عمیق و فازی برای مجموعه داده‌ی بزرگ‌تر استفاده کرد. هم چنین در تحقیقات آتی می توان برای نقشه‌های دسترسی به امکانات در مقیاس منطقه‌ای ، از فاصله‌ی تحت شبکه استفاده کرد. در نهایت پیشنهاد می‌شود که با افزایش بعد زمان به داده‌ها، پیش‌بینی مکانی-زمانی صورت گیرد تا ظرفیت الگوریتم یادگیری عمیق-فازی در داده‌های وابسته به زمان نیز بررسی شود. درنهایت این پیش‌بینی زمانی، تأثیر ویژگی ترافیک را به‌عنوان یک معیار متغیر ، به شکل مناسب‌تری مدل‌سازی می‌کند.

منابع و مآخذ

۱ - عبده کلاهچی, م., رفیعیان نجف آبادی, م., دهقانی, م., & میرزاده, س. (۱۳۹۳). تحلیل عوامل مؤثر بر قیمت مسکن با استفاده از مدل تحلیل رگرسیون گام به گام (مطالعه موردی: محله فاطمی تهران). اقتصاد و مدیریت شهری, 2(7), -. https://www.sid.ir/fa/journal/ViewPaper.aspx?id=233672

2 - Afonso, B., Melo, L., Oliveira, W., Sousa, S., & Berton, L. (2019). Housing prices prediction with a deep learning and random forest ensemble. Anais do XVI Encontro Nacional de Inteligência Artificial e Computacional,

3 - Arık, S. O., & Pfister, T. (2021). Tabnet: Attentive interpretable tabular learning. AAAI,

4 - Ayan, E., & Eken, S. (2021). Detection of price bubbles in Istanbul housing market using LSTM autoencoders: A district-based approach. Soft Computing, 25(12), 7957-7973.

5 - Bae, S., & Yu, J. (2017). Predicting the real estate price index using deep learning. Korea Real Estate Review, 27(3), 71-86.

6 - Benjamin, J., Guttery, R., & Sirmans, C. (2004). Mass appraisal: An introduction to multiple regression analysis for real estate valuation. Journal of Real Estate Practice and Education, 7(1), 65-77.

7 - Borst, R. A. (1991). Artificial neural networks: the

of house price: Incorporating a geographically weighted regression approach within the Belfast housing market. Journal of Financial Management of Property and Construction.

19 - Nghiep, N., & Al, C. (2001). Predicting housing value: A comparison of multiple regression analysis and artificial neural networks. Journal of real estate research, 22(3), 313-336.

20 - Rafiei, M. H., & Adeli, H. (2016). A novel machine learning model for estimation of sale prices of real estate units. Journal of Construction Engineering and Management, 142(2), 04015066.

21- Ribeiro, M. H. D. M., & dos Santos Coelho, L. (2020). Ensemble approach based on bagging, boosting and stacking for short-term prediction in agribusiness time series. Applied Soft Computing, 86, 105837.

22 - Seya, H., & Shiroi, D. (2019). A comparison of apartment rent price prediction using a large dataset: Kriging versus DNN. arXiv preprint arXiv:1906.11099.

23 - Shwartz-Ziv, R., & Armon, A. (2022). Tabular data: Deep learning is not all you need. Information Fusion, 81, 84-90.

24 - Souri, D., & MONIRI, J. S. (2011). Estate pricing model, an application of geographic balanced regression.

25 - Tabales, J. M. N., Caridad, J. M., & Carmona, F. J. R. (2013). Artificial neural networks for predicting real estate price. Revista de Métodos Cuantitativos para la Economía y la Empresa, 15, 29-44.

26 - Talpur, N., Abdulkadir, S. J., & Hasan, M. H. (2020). A deep learning based neuro-fuzzy approach for solving classification problems. 2020 International Conference on Computational Intelligence (ICCI),

27 - Victoria, A. H., & Maragatham, G. (2021). Automatic tuning of hyperparameters using Bayesian optimization. Evolving Systems, 12(1), 217-223.

28 - Xiaolong, H., & Ming, Z. (2010). Applied research on real estate price prediction by the neural network. 2010 The 2nd Conference on Environmental Science and Information Application Technology,

29 - Xu, H., & Gade, A. (2017). Smart real estate assessments using structured deep neural networks. 2017 IEEE SmartWorld, Ubiquitous Intelligence & Computing,

next modelling/calibration technology for the assessment community. Property Tax Journal, 10(1), 69-94.

8 - Chen, C. P., Zhang, C.-Y., Chen, L., & Gan, M. (2015). Fuzzy restricted Boltzmann machine for the enhancement of deep learning. IEEE Transactions on Fuzzy Systems, 23(6), 2163-2173.

9 - Chen, W., An, J., Li, R., Fu, L., Xie, G., Bhuiyan, M. Z. A., & Li, K. (2018). A novel fuzzy deep-learning approach to traffic flow prediction with uncertain spatial–temporal data features. Future generation computer systems, 89, 78-88.

10 - Chen, X., Wei, L., & Xu, J. (2017). House price prediction using lstm. arXiv preprint arXiv:1709.08432.

11 - Guan, J., Shi, D., Zurada, J. M., & Levitan, A. S. (2014). Analyzing massive data sets: an adaptive fuzzy neural approach for prediction, with a real estate illustration. Journal of organizational computing and electronic commerce, 24(1), 94-112.

12 - Guan, J., Zurada, J., & Levitan, A. (2008). An adaptive neuro-fuzzy inference system based approach to real estate property assessment. Journal of real estate research, 30(4), 395-422.

13 - Jang, J.-S. (1993). ANFIS: adaptive-network-based fuzzy inference system. IEEE transactions on systems, man, and cybernetics, 23(3), 665-685.

14 - Kang, Y., Zhang, F., Peng, W., Gao, S., Rao, J., Duarte, F., & Ratti, C. (2021). Understanding house price appreciation using multi-source big geo-data and machine learning. Land Use Policy, 111, 104919.

15 - Khalid, S., Khalil, T., & Nasreen, S. (2014). A survey of feature selection and feature extraction techniques in machine learning. 2014 science and information conference,

16 - Kim, H., Kwon, Y., & Choi, Y. (2020). Assessing the impact of public rental housing on the housing prices in proximity: based on the regional and local level of price prediction models using long short-term memory (LSTM). Sustainability, 12(18), 7520.

17 - Li, Z. X. (2007). Using fuzzy neural network in real estate prices prediction. 2007 Chinese control conference,

18 - McCord, M., Davis, P., Haran, M., McGreal, S., & McIlhatton, D. (2012). Spatial variation as a determinant

Advanced & Trusted Computed, Scalable Computing & Communications, Cloud & Big Data Computing, Internet of People and Smart City Innovation (SmartWorld/ SCALCOM/UIC/ATC/CBDCom/IOP/SCI),
30 - Yazdanbakhsh, O., & Dick, S. (2019). A deep neuro-fuzzy network for image classification. arXiv preprint arXiv:2001.01686.
31 - Yiorkas, C., & Dimopoulos, T. (2017). Implementing GIS in real estate price prediction and mass valuation: the case study of Nicosia District. Fifth International Conference on Remote Sensing and Geoinformation of the Environment (RSCy2017),
32 - Zaremba, W., Sutskever, I., & Vinyals, O. (2014). Recurrent neural network regularization. arXiv preprint arXiv:1409.2329.

COPYRIGHTS

©2023 by the authors. Published by National Geographical Organization. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution-NoDerivs 3.0 Unported (CC BY-ND 3.0)