

نشریه علمی نامه معماری و شهرسازی

DOI: 10.30480/AUP.2023.3964.1870

نوع مقاله: پژوهشی

ارائه مدل پیش‌بینی کننده ترجیحات نمای مسکونی

با بهره‌گیری از یادگیری ماشین

* بررسی موردی: شهر تهران

نجمه موسوی

کارشناس ارشد طراحی شهری، دانشکده معماری و شهرسازی، دانشگاه هنر، تهران، ایران

مریم محمدی

دانشیار گروه طراحی شهری، دانشکده معماری و شهرسازی، دانشگاه هنر، تهران، ایران (نویسنده مسئول مکاتبات)

E-mail : m.mohammadi@art.ac.ir

چکیده

میزان ترجیحات نمای شهری برای کاربران، یکی از موضوعات مهم در حیطه نما و سیمای شهری است. پاسخ به این موضوع در قالب روش‌های متعدد عینی و ذهنی توسط پژوهشگران مورد توجه بوده است. این پژوهش بر آن است تا از روش‌های یادگیری ماشین بهره گیرد. هدف پژوهش، طراحی مدلی پیش‌بینی کننده است که خروجی آن میزان ترجیحات کاربران از نمای شهری مسکونی شهر تهران خواهد بود. تصاویر نمای مسکونی استفاده شده، مربوط به تصاویر ارائه شده به کمیسیون نما و سیمای شهر تهران در سال‌های ۱۳۹۵ تا ۱۳۹۸ است که از میان ۸۰۰ تصویر اولیه، در فرایند انتخاب داده ۲۷۸ تصویر انتخاب شده‌اند. ویژگی‌های مورد توجه، با استفاده از رویکرد ترجیحات بصری و پردازش تصویر به دست آمده است. میزان ترجیحات از طریق پرسشنامه آنلاین توسط کاربران (۲۱۸ نفر) در چهار دسته ترجیحات کم (٪۲۵-۰)، متوسط (٪۵۰-۵۱)، خوب (٪۷۶-۱۰۰) و خیلی خوب (٪۷۷-۸۰) بدست آمده و به عنوان برچسب به مدل ارائه شده است. براساس نتایج، سه الگوریتم ماشین بردار پشتیبان، درخت تصمیم‌گیری و جنگل تصادفی با دقت صدرصد و روش ایکس‌جی‌بوست با دقت نود و هفت درصد بهترین عملکرد را داشته‌اند. همچنین اهمیت تأثیر عناصر در انتخاب آن‌ها توسط کاربران به ترتیب شامل: حداقل فاصله بین پنجره‌ها، نسبت سطح شفاف به کدر در نما، وجود گلشن/باغچه در بالکن، تنوع مصالح، حداقل فاصله بین پنجره‌ها، تعداد بازشوها، طول و تعداد بالکن‌ها، تعداد طبقات، تنوع رنگ، ترئینات در رخ بام، نوع خطوط بام، تعداد ورودی و نسبت ارتفاع به طول بنا بوده است.

کلیدواژه‌ها: ترجیحات بصری نما، نمای مسکونی، یادگیری ماشین نظارت شده، پردازش تصویر، تهران

* این مقاله برگرفته از پایان‌نامه کارشناسی ارشد نجمه موسوی با عنوان «شناسایی ترجیحات بصری مردم از نمای‌های خیابان‌های شهری با بهره‌گیری از یادگیری ماشین (نمونه موردی: شهر تهران)» است که با راهنمایی دکتر مریم محمدی در دانشکده معماری و شهرسازی دانشگاه هنر انجام شده است.

مقدمه

تصور هر شخص از منظر شهری تحت تأثیر حس بینایی، مکان و محتوای محیطی است که فرد در آن قرار می‌گیرد (Khastou & Najafi Charmini, 2015, 43). برای داشتن مناظر ترجیحی، معیارهای طراحی باید بر اساس اولویت افراد از مناظر بصری اتخاذ شوند. ترجیحات بصری، رویکردی است برای ارزیابی مناظر در مورد چگونگی درک افراد از محیط و آنچه مردم ترجیح می‌دهند (Abkar et al., 2011, 1991). آنچه اغلب نادیده گرفته می‌شود، چگونگی تأثیر حس بینایی بر درک خوشایندی یا ناخوشایندی محیط است. دریافت‌های بصری انسان تا حدودی به مکانیسم بینایی بستگی دارد که در تمام انسان‌ها به‌طور یکسان عمل می‌کند. چشمی که انسان با آن به دنیا نگاه می‌کند؛ ساختار همان چشمی را دارد که تمام مردم دنیا با آن به جهان می‌نگرند (پاکزاد و بزرگ، ۱۳۹۵، ۷۰). به‌نظر می‌رسد یکی از بهترین راه‌ها برای بررسی نماهای شهری مطلوب، سنجش مکانیسم بینایی باشد. تاکنون سیستم کامپیوترا که توانایی انسان را بسنجد، به‌اندازه دیدن مورد توجه قرار نگرفته است. همین امر لزوم استفاده از پردازش تصویر برای انجام مطالعات بینایی را نمایان می‌سازد (Pourjafar & Baba Abbasi, 2015, 119). استفاده از پردازش تصویر سبب تشخیص و اندازه‌گیری ویژگی‌های پنهان تصاویر می‌شود. در پژوهش‌های پیشین، برای شناسایی و پیش‌بینی ترجیحات بصری از ابزارهای مختلف دستگاه ریدیابی چشم، پاسخ سمپاتیک پوست و پرسشنامه استفاده شده است. این پژوهش به‌منظور شناسایی مطلوبیت نماهای شهری از روش یادگیری ماشین استفاده می‌کند. انتخاب این روش از آن جهت است که قابلیت ارائه مدلی پیش‌بینی کننده را دارد که به سرعت و با دقت مناسب می‌تواند میزان مطلوبیت و ترجیحات نماها را شناسایی نماید. بنابراین، منطقی به‌نظر می‌رسد به‌جای روش‌های متداول که نیازمند صرف هزینه و وقت هستند؛ از طریق آموزش ماشین، وضع موجود و نماهای پیشنهادی جدید را در قالب آلترناتیو ارزیابی نمود.

پیشینه پژوهش

پیشینه پژوهش در سه حوزه «ترجیحات بصری»، «یادگیری ماشین» و «پردازش تصویر» بررسی و سپس مبانی نظری ارائه می‌شود.

ترجیحات بصری: ترجیحات بصری اولین بار توسط آنتون نلسن^۱ در اواخر سال ۱۹۷۰ تعریف شد و تا سال ۱۹۹۰ به پدیده‌ای مردم‌پسند و روشی مقبول برای ارزیابی بازخورد طرح تبدیل شد. ترجیحات بصری از آن جهت ارزشمند است که انتقال دهنده احساسات و عواطف به‌شمار می‌آید. از دید نلسن این تکنیک به‌عنوان یک ابزار، ساکنین را قادر می‌سازد تا برش از وضعیت فعلی بیان کنند و به ایجاد شخصیت آینده جامعه خود کمک نمایند (Rahn, 2014, 8). خستو و نجفی چارمینی در «ساماندهی منظر شهری با تأکید بر خوانایی، با استفاده از تکنیک ترجیحات بصری (مطالعه موردي: خیابان خیام قزوین)» به این مهم دست یافتند که ترکیب نظرات متخصصین و مردم به‌منظور تحلیل منظر شهری مطلوب است (Khastou & Najafi Charmini, 2015, 48). کنگ و باکر^۲ در مقاله «ترجیحات منظر شب با استفاده از آنالیز حرکت چشم» نشان دادند که کاربران تصاویر مناظر روشی و باز را به تصاویر تاریک و محصور ترجیح می‌دهند (Kang & Bakar, 2013, 86). نولاند^۳ و همکاران در «تکنولوژی ریدیابی چشم، بررسی ترجیحات بصری و طراحی شهری: شواهد اولیه از یک روش کارآمد» تأکید کردند که عناصر مختلف تصاویر گرفته شده از مناظر شامل مردم، ویژگی‌های عابر پیاده و فضای سبز، واجد ترجیحات پیشتری هستند؛ در حالی که تصاویر با اتومبیل و پارکینگ از ترجیحات بصری کمتری برخوردار هستند (Noland et al., 2016, 11). میشرا و کولای^۴ در «ترجیح بصری از نما خیابان

یک شهر تاریخی: مطالعه موردي از شهر قدیمي جیپور^۵ هند» نشان دادند که ویژگی های معماري عناصر مانند: ستون ها، قرنیزها، پنجره های هلالی، لمبه های تزئینی و نقش و نگارها، به تصویر شهر هویت می دهند (Mishra & Kolay, 2019, 389). شاه حسینی و همكاران در «ترجيحات بصری پارک های شهری کوچک بر اساس پیکره بندی فضایي مكان» بيان کردند که در ميان پیکره بندی بصری فضایي، رمزآلودگی بالاترین رتبه ترجيح را در بين ویژگی های بصری دارد، در حالی که مناظر با چشم انداز فضایي گسترشده، کمترین ميزان اولويت را دارند (Shahhoseini et al., 2015, 91).

يادگيري ماشين: در «تشخيص نمای ساختمان با آثار هنري دیوارنگاری» انجام شده توسيط نواك^۶ و همكاران، رویکرد جديدی برای تعين محل تقريبي آثار هنري نقاشي دیواری (با عدم قطعیت هندسي ۶۰ متر) بر اساس داده های فلیکر^۷ (گوگل استريت مپ چيني) پيشنهاد شد. تصاوير از محيط اطراف عکس های فلیکر استخراج و توسيط يك شبکه عصبي کانولوشن سفارشي، تفسير شدند. موقعیت احتمالي آن ها برای امتيازدهي به نمای ساختمان با توجه به پتانسیل آن ها در داشتن آثار هنري قابل مشاهده در تصاوير در نظر گرفته شد. بيش از ۳۶۰۰۰ تصوير و ۵۰۰۰ نما از ساختمان های ارائه شده در اوپن استريت مپ پردازش و ارزیابی شدند. ميزان دقت برای آستانه های مختلف امتياز نما محاسبه شد. خطاهای مثبت کاذب بيشتر به دليل تبليغات و دیوار نوشته ها در نما ساختمان و همچنین اشیاء متتحرك حاوي آثار هنري دیوارنگاری ايجاد شده است. بالين حال، در نظر گرفتن امتيازات بالاتر به عنوان آستانه تشخيص نمای های حاوي دیوارنگاری منجر به دقت كامل می شود (Novack et al., 2020, 15). لوپهaimer^۸ و همكاران در «شبکه های عصبي برای طبقه بندی ساختمان با استفاده از تصاوير نمای خيابان»، مدل های شهری سه بعدی را برای طبقه بندی تصاوير سطح خيابان به صورت خودکار غني سازي معنائي کردند. نماهای ساختمان در پنج گروه مختلف (تجاري، مختلط، مسكنوني، کاربری خاص، تحت ساخت و ساز) دسته بندی شده است. داده های پژوهش شامل يك چند ضلعی دو بعدی برای هر ساختمان است که با اطلاعات معنائي مانند: آدرس، ناحيه، اشتراك، شماره بلوک و کاربری ساختمان بر چسب زده شده است. آن ها با استفاده از چندين معماري شبکه عصبي پيچشي از پيش آموزش دide، دقت طبقه بندی تصاوير نما ساختمان را افزايش داده اند (Laupheimer et al., 2018, 177). ليو^۹ و همكاران در «رويکرد يادگيري عميق به تحليل نما» از روش مبتنى بر يادگيري عميق برای تقسيم بندی نما به دسته های معنائي استفاده کرده اند. ۱۰۴ تصوير از بناهای سبک هوسمناني در شهر پاريس به عنوان نمونه در نظر گرفته شده است. هر تصوير به پيكسل های مختلف تقسيم می شود و موقعیت قرارگيري هر پيكسل در دسته های مختلف نمای ساختمان (پنجره، دیوار، بالکن و...) مشخص خواهد شد. برای بهبود نتایج، از قدرت شبکه های عصبي و ساختارهای معماري ساخته شده به طور همزمان استفاده شده است. ميزان دقت عملکرد اين مدل ۹۳٪/۴۰٪ است که مطلوبیت اين روش را نشان می دهد (Liu et al., 2012, 2301). در پژوهشی که توسيط تيم تحقیقاتی در آزمایشگاه نوكيا بل در كمبrij و دانشگاه تورین در سال ۲۰۱۷ منتشر شده است؛ پلتفرم زندگی شهری خوب برای تحليل احساسات شهری و مكان نگاشت منظر با هدف تهييه «نقشه نواحي شاد» ارائه شد. اين پروژه به بررسی داده هایي می پردازد که زندگی شهری را برای ساكنان لذت بخش تر می کند. به دليل موفقیت پروژه تيم تحقیقاتی، پروژه را به صورت يك پلتفرم بزرگ تر گسترش دادند. سپس، چندين پروژه نقشه برداری حسبي در دوازده شهر اروپا و آمريكا با هدف بهبود کيفيت زندگي در مناطق شهری انجام شد. بر اساس داده های جمع آوري شده، سه نقشه «عرصه های شاد»، «فضاهای بدبو» و «فضاهای پرسرو صدا^{۱۰}» به دست آمد (Quer-cia & Aiello, 2017). پژوهش دیگري توسيط ليو و همكاران برای ارزیابي مقیاس کلان و خودکار کيفيت محيط شهری با استفاده از تکنيک های پيش رفتنه يادگيري ماشين پيشنهاد شده است. در اينجا، تصاوير نما از نظر ویژگی های مختلف فيزيكي که برای تجربه بصری شهر مهم هستند؛ بررسی و تحليل شده اند. دو ویژگي کيفيت

ساخت و نگهداری نمای ساختمان و تداوم جداره خیابان در این پروژه انتخاب و اندازه‌گیری شده‌اند. به‌منظور آزمون اعتبار روش پیشنهادی، امتیاز به‌دست آمده از یادگیری ماشین را با امتیاز رتبه عمومی مکان‌ها که در ۵۶ مکان از ۷۵۲ فضای شهر به‌صورت سنتی جمع‌آوری شده، مقایسه گردیده است. نتایج نشان داد که مدل‌های یادگیری ماشین می‌توانند برآورده متوسط تا خوب را براساس نتایج محیط واقعی ایجاد کرده و داده‌های حاصل می‌تواند توسط پژوهشگران، برنامه‌ریزان و ساکنان محلی مورد استفاده قرار گیرد (Liu *et al.*, 2017, 123).

«مدل‌سازی مبتنی بر نمای ساختمان‌های هوسمانی» توسط لیو و گالاگوویچ انجام شده است. در این پژوهش، مدل‌سازی مبتنی بر تصویر از نمای هوسمانی سه بخش عمده را دربرمی‌گیرد: الف) مجموعه‌ای از تصاویر برای بازسازی بهتر، از جمله انواع پنجره‌ها. ب) طراحی یک روش مبتنی بر مشخصات رنگ و لبه برای گونه‌شناسی ساختمان. ج) طراحی یک روش ترکیبی برای تشخیص عناصر معماری. در حالت کلی نما ساختمان به صورت شبکه‌ای از موزائیک‌ها به صورت افقی و عمودی تقسیم‌بندی شده و با استفاده از توصیفگرهای مختلف تصویر، عناصر معماری شناسایی شده است. تشخیص پنجره، بالکن، بام، در و رو دی از جمله عناصر قابل تشخیص بوده‌اند (Liu & Gagalowicz, 2010, 122).

پردازش تصویر: پردازش تصویر^{۱۱} کلیه روش‌هایی است که یک تصویر دیجیتال را به عنوان ورودی دریافت و تصویر دیگر یا اطلاعاتی را به صورت مجموعه‌ای از پارامترها در اختیار می‌گذارد. توکر^{۱۲} و همکاران در «روشی برای تحلیل بصری مناظر خیابان»، به این نتیجه دست یافتند که می‌توان از ابزارهای مختلف پردازش تصویر برای توصیف ویژگی‌های مناظر خیابانی، بهره برد (Tucker *et al.*, 2004, 138). «پیکربندی مورفولوژی تصاویر نمای ساختمان» که توسط هرناندز و مارکوتگی^{۱۳} در سال ۲۰۱۳ منتشر شد، یک روش کاملاً خودکار برای پیکربندی تصاویر نمای ساختمان‌ها ارائه شد (Hernandez & Marcotegui, 2013, 4029).

پورجعفر و بابا‌عباسی در «طراحی و ساماندهی فضاهای شهری با رویکرد پردازش تصویر در راستا ارتقاء منظر شهری با تحلیل نمونه موردي خیابان ۱۷ شهریور تهران» به این مهم دست یافتند که روش پردازش تصویر می‌تواند ویژگی‌های پنهان بصری را استخراج نموده و به عنوان جزئی از مطالعات در تحلیل طرح‌های شهری مورد استفاده قرار گیرد (Pourjafar & Baba Abasi, 2015, 119).

رشید قلم در پایان نامه خود «سنجهش تأثیرگذاری مطلوبیت بصری بر حضور پذیری استفاده‌کنندگان از فضا مبتنی بر تکنیک پردازش تصویر، نمونه موردي خیابان سی تیر، منطقه ۱۲ شهرداری تهران»، ضمن معرفی جایگاه پردازش تصویر و نحوه کاربرد آن در مطلوبیت و میزان حضور، به این نتیجه رسید که مطلوبیت بصری بر تعداد استفاده‌کنندگان از فضا مؤثر است (رشید قلم، ۱۳۹۵، ۶۶).

با توجه به موارد بیان شده، نوآوری پژوهش در به کارگیری روش یادگیری ماشین برای پاسخ بهتر و سریع‌تر به مسئله تشخیص میزان ترجیحات بصری کاربران در تصاویر نماهای مسکونی است. همچنین تعیین میزان اهمیت هر یک از ویژگی‌های کالبدی و آماری مؤثر بر ترجیحات بصری نما براساس الگوریتم‌های یادگیری ماشین نظارت شده از دیگر نوآوری‌های پژوهش است.

مبانی نظری

ترجیحات بصری و تعیین عناصر کالبدی مؤثر بر طراحی نما: همان‌طورکه بیان شد مسئله این پژوهش، شناسایی میزان ترجیحات نماهای مسکونی از دید شهروندان تهرانی است. بنابراین، ابتدا لازم است تا در مورد ترجیح بصری نما و عوامل مؤثر بر آن بحث شود. همان‌طورکه پیش از این بیان شد، موضوع ترجیحات بصری توسط آنتوان نلسن بیان و آن را به عنوان یک روش بینایی توسعه داد (Rahn, 2014, 9).

این مفهوم

شامل موارد عینی (کیفیت‌های بصری) و موارد ذهنی (ادراک) است. بر اساس تعاریف، می‌توان ترجیحات بصری را به عنوان «درجه‌ای از خوشایندی یا ناخوشایندی بصری و ارزیابی ادراک کاربران برای ایجاد یک چشم‌انداز مشترک (Abkar et al., 2011; Rahn, 2014) تعریف نمود. ویژگی‌های ترجیحات بصری با مرور آراء نظریه‌پردازان این حوزه شناسایی شده‌اند. از آنجا که این ویژگی‌ها در فرایند ارتباطات با فرستنده و گیرنده و یا محیط و انسان مرتبط هستند؛ بر همین اساس در جدول زیر دسته‌بندی شده‌اند.

جدول ۱. ویژگی‌های ترجیحات بصری براساس مبانی نظری

ویژگی‌های ترجیحات بصری از آراء نظریه‌پردازان مختلف		
پیشینه فرهنگی جامعه (Pourdehghan et al., 2017; Dacci, 2017) میزان آشتیابی با بستر مطالعه (Santosa et al., 2012; Bin, 1984; Shahhoseini et al., 2015 تفاوت‌های فردی (سن، جنس، از نظر اجتماعی و اقتصادی) (شاھین راد و همکاران ۱۳۹۴: Cohen, 1996 : Pourdehghan et al., 2017 : Stamps, 1999)	مرتبط به ادراک انسان	ویژگی‌های مرتبط به انسان
نتیجه چشم (Noland et al., 2016 : Kang & Bakar, 2013) میزان حدت بینایی (اختلالات بینایی مرتبط به سن و یا موروثی) (Krosl et al., 2018 مدت زمان مشاهده (Kang & Bakar, 2013)	مرتبط به چشم انسان	
محضوریت و گشودگی فضایی (شاھین راد و همکاران ۱۳۹۴: Bin, 1984 : & Constantine, 1993 منحصر به فرد بودن (Kang & Bakar, 2013) ارزشمندی تاریخی (شاھین راد و همکاران ۱۳۹۴ : Nelessen & Constantine, 1993 : Santosa et al., 2012 : Nelessen & Constantine, 1993 معنادار بودن (Pourdehghan et al., 2017) اصالت و هویت عنصر (Mishra & Kolay, 2019: Nelessen & Constantine, 1993 در خشندگی (Kang & Bakar, 2013) پیچیدگی (Cohen, 1996 : Shahhoseini et al., 2015 : Shahhoseini et al., 2015 خوانایی (شاھین راد و همکاران ۱۳۹۴ نگهداری مناسب (Shahhoseini et al., 2015 نظم (Shahhoseini et al., 2015 پیکربندی و محتوا فضایی (Shahhoseini et al., 2015 سبک معماري ساختمن و نما (Santosa et al., 2012) افزونگی (садگی و قابل ادراک) و آنتروپی (پیچیدگی) (Pourdehghan et al., 2017 سر پناه ۱۴ (شاھین راد و همکاران ۱۳۹۴ انسجام (Shahhoseini et al., 2015) رازآوردگی (Shahhoseini et al., 2015) پوشش گیاهی (Santosa et al., 2012 : Bin, 1984 : Abkar et al., 2011 : Shahhoseini et al., 2015 تکرار پذیری و جدید بودن (Cohen, 1996 : Pourdehghan et al., 2017 جنبه‌های تغییرپذیری (Cohen, 1996)	جنبه ذهنی محرك	ویژگی‌های مرتبط به محرك (محیط)
بافت و مصالح، نسبت‌ها در ابعاد مختلف فضا (Santosa et al., 2012 : Bin, 1984 : Abkar et al., 2011 : Shahhoseini et al., 2015 اندازه، رنگ و موقعیت (Kang & Bakar, 2013 : Bin, 1984 : Pourdehghan et al., 2017 شكل و اجزای فضا (Cohen, 1996 : Pourdehghan et al., 2017 : Dacci, 2019 : Santosa et al., 2012)	جنبه عینی محرك	

ویژگی‌های کالبدی مؤثر بر خوشایندی نما از ارتباط بین ویژگی‌های ترجیحات بصری (که در جدول بالا آمده) با ارکان و اجزاء نما شناسایی شده‌اند. این ویژگی‌ها به طور کلی شامل: تعداد عناصر، رنگ، فاصله بین عناصر،

مصالح، خطوط، فرم، تناسبات، کنتراست، رخ بام و جزئیات هستند. در جدول (۲) به صورت جزئی بررسی شده‌اند.

جدول ۲. ویژگی‌های کالبدی مؤثر در طراحی نما

منبع	جزئیات	ویژگی
Natalya <i>et al.</i> , 2014; Zyagina <i>et al.</i> , 2019	کنتراست	کنتراست
Kozlova, 2016; Natalya <i>et al.</i> , 2014; Zyagina <i>et al.</i> , 2019; Tsvetkov <i>et al.</i> , 2019	تعداد و رنگ	رنگ
Natalya <i>et al.</i> , 2014; Zyagina <i>et al.</i> , 2019	فاصله بازشوها	فاصله بین عناصر
Kozlova, 2016; Natalya <i>et al.</i> , 2014	تعداد و نوع مصالح	مصالح
Luchinin <i>et al.</i> , 2018; Natalya <i>et al.</i> , 2014; Zyagina <i>et al.</i> , 2019; Tsvetkov <i>et al.</i> , 2019	سطح شفاف/کدر؛ ارتفاع/طول طبقات؛ طول بالکن	تناسبات
Kozlova, 2016; Natalya <i>et al.</i> , 2014; Zyagina <i>et al.</i> , 2019; Tsvetkov <i>et al.</i> , 2019	نوع و پیوستگی خطوط	خطوط
Kozlova, 2016; Zyagina <i>et al.</i> , 2019; Tsvetkov <i>et al.</i> , 2019	فرم بازشوها، بالکن‌ها و درب ورودی؛ جلوآمدگی/عقب‌رفتگی طبقات، بازشوها و طبقه همکف؛ فرم کلی بنا	فرم
Luchinin <i>et al.</i> , 2018; Natalya <i>et al.</i> , 2014; Glukhova <i>et al.</i> , 2018; Zyagina <i>et al.</i> , 2019; Kukhta & Pelvin, 2014; Tsvetkov <i>et al.</i> , 2019; Tsvetkov <i>et al.</i> , 2019	تعداد طبقات، بازشوها و بالکن‌ها	تعداد عناصر
Luchinin <i>et al.</i> , 2018	رنگ متفاوت، نوع خطوط، جلوآمدگی، تزئینات بام	رخ بام
Kozlova, 2018; Luchinin <i>et al.</i> , 2018; Kozlova, 2016; Glukhova <i>et al.</i> , 2018; Zyagina <i>et al.</i> , 2019	تزئینات سطح بنا، دیوار سبز و گلشن (فلوراکس)	جزئیات

روش پژوهش

پارادایم پژوهش حاضر اثبات‌گرایی است. پژوهش از حیث هدف کاربردی بوده و از حیث رویکرد توصیفی-تحلیلی است. همان‌طورکه پیش از این بیان شد، روش پژوهش یادگیری ماشین است. یادگیری ماشین، کلمه‌ای است که در سال ۱۹۵۹ توسط آرتور ساموئل^{۱۴} به ثبت رسید (Gupta & Gola, 2020, 2). این روش با توجه به شیوه آموزش به سه دسته: یادگیری نظارت شده، یادگیری بدون نظارت و یادگیری تقویتی تقسیم می‌شود (Abdi, 2016, 1). نوع داده‌های ورودی (داده‌های دارای برچسب و بدون برچسب)، خروجی (طبقه‌بندی، خوشه‌بندی) و یا روند یادگیری (مبتنی بر پاداش) مبنای این دسته‌بندی است. این نوشتار از روش یادگیری نظارت شده بهره برده است.

جدول ۳. انواع مدل‌های یادگیری ماشین

خروجی	برداش داده‌ها	نوع آموزش	ورودی	یادگیری
خروجی مطلوب (نتیجه صحیح)	طبقه‌بندی	وظیفه محور	داده‌های دارای برچسب	یادگیری نظارت شده
خروجی مطلوب (توزیع داده‌ها)	خوشه‌بندی	داده محور	داده‌های بدون برچسب	یادگیری بدون نظارت
تعدادی نتیجه (نمراهای برای نتیجه)	بهترین تضمیم‌گیری	پاداش محور	داده‌های بدون برچسب	یادگیری تقویتی

منبع: کیم، ۱۳۹۹، ۲۹.

برای پیش‌بینی کلاس و نتیجه تابع، می‌توان از طبقه‌بندی یا رگرسیون استفاده کرد. تنها تفاوت بین آن‌ها در ماهیت ویژگی‌هایشان است. اگر داده‌ها مطلق باشند؛ الگوریتم‌های طبقه‌بندی و اگر پیوسته باشند مدل

رگرسیونی می‌تواند عملکرد مطلوبی را ایجاد نماید (Leopard *et al.*, 2016, 7). تعدادی از الگوریتم‌های رگرسیون شامل: رگرسیون خطی، رگرسیون لاسو^{۱۵} و تعدادی از الگوریتم‌های طبقه‌بندی متداول شامل: ماشین بردار پشتیبان^{۱۶}، شبکه‌های عصبی مصنوعی^{۱۷}، درخت تصمیم‌گیری^{۱۸}، رگرسیون لجستیک^{۱۹}، جنگل تصادفی^{۲۰}، آدابوست^{۲۱} و ایکس جی بوست^{۲۲} هستند. در این پژوهش از تمامی الگوریتم‌های طبقه‌بندی ذکر شده، استفاده شده است.

ویژگی‌های کالبدی نما مبتنی بر بخش مبانی نظری و ویژگی‌های آماری مبتنی بر تکنیک پردازش تصویر و توسط نگارندگان استخراج شده است. مرحله برچسبزنی داده‌ها (نماها ترجیحی و غیرترجیحی) از پرسش‌نامه و رویکرد مردم‌محور استفاده شده و داده‌ها برای آموزش وارد ماشین شده‌اند. برای سنجش میزان اعتبار مدل یادگیری ماشین نظارت شده از ماتریس درهم‌آمیختگی استفاده و جزئیات هر یک از مراحل در بخش‌های بعد ارائه شده است.

تحلیل داده‌ها و یافته‌ها

مرحله اول، جمع‌آوری و آماده‌سازی داده‌ها

تمیزکردن و پاکسازی: داده‌ها با فرمت ناسازگار، ناقص، ساختارهای غیر همتراز و متغایر بر نتیجه تحلیل تأثیر منفی می‌گذارند. همچنین، به دست آوردن همبستگی مناسب بین ویژگی‌ها مهم است. اطمینان از درستی و مرتبط بودن داده‌ها، فرایند را یک گام به جلو سوق می‌دهد (Ridzuan *et al.*, 2019, 732). از آنجا که عکس برداری نما از زاویه مشخص و بدون پرسپکتیو (لازم‌به پردازش تصویر و یادگیری ماشین) ممکن نیست؛ از تصاویر نماهای ارائه شده به کمیسیون نما و سیمای شهر تهران از سال ۱۳۹۵ تا ۱۳۹۸ استفاده شده است. داده‌های تکراری، دارای پرسپکتیو و عناصر زائد (افراد و وسائل نقلیه عمومی)، دارای نور زیاد یا کم و نماهای ناقص، توسط نگارندگان حذف و از ۸۰۰ تصویر اولیه ۵۰۰ تصویر باقی ماند.

انتخاب داده‌ها: یکی از مهم‌ترین مراحل، انتخاب داده‌هایی است که در اختیار ماشین قرار داده می‌شود. اگر تعداد داده‌ها برای آموزش کافی نباشد؛ ماشین توانایی پیش‌بینی صحیح نتایج را نخواهد داشت. در اینجا، از متخصصین حوزه معماری و شهرسازی (۵ متخصص) با سابقه کاری میانگین پنج سال نظرسنجی شده و در نهایت ۲۷۸ تصویر انتخاب تا ماشین با کشف الگو میان میانگین ترجیح مردم و تصاویر آموزش بینند. معیار انتخاب نما توسط متخصصان رایج بودن تصاویر نماها است. تصاویر منتخب بین ۲ تا ۸ طبقه، در طیف رنگی سفید تا مشکی و همچنین، با مصالح: شیشه، آجر، سنگ و بتون بوده‌اند که در جدول (۴) آورده شده‌اند.

جدول ۴. جزئیات تصاویر نماهای منتخب در پژوهش

تعداد طبقات	رنگ‌های به کار برده شده	مصالح بدکار برده	تعداد ورودی	جزئیات دیگر
۳ طبقه:	% ۱۹,۷	% ۴,۴۲	% ۴۱,۳۰	درصد سطح کدر به شفاف در نماها:
۴ طبقه:	% ۳,۸	% ۴,۴۲	% ۲۰,۴۹	یک ورودی: % ۱۴,۵۳ آجر:
۵ طبقه:	% ۱۷,۲۴	% ۱,۹۴	% ۶۲,۲۳	دو ورودی: % ۲۹,۷ سنگ:
۶ طبقه:	% ۴,۰۶	% ۱۴,۴۹	۱۴,۳۸	کامپوزیت: % ۷,۷۶۵ قهوه‌ای:
۷ طبقه:	% ۸,۸۴	% ۱,۶۷	۴ ورودی: % ۲,۱ بتن:	ذغالی: % ۱,۶۷ ذغالی:
۸ طبقه:	% ۱,۸۰	% ۰,۹	۵ ورودی: % ۰,۸ چوب:	خشکه‌ای: % ۰,۹ خردلی:
	% ۱۱,۶۴	% ۲,۸۹		مشکی: % ۲,۷۹۵ آجری:
				آجری: % ۲,۷۹۵



شکل ۱. نمونه تصاویر منتخب توسط متخصصین

استانداردسازی: استانداردسازی شامل یکی کردن فرمتهای و سایر مشخصات داده‌های ورودی است که سبب از بین رفتن خطاها احتمالی مدل در یادگیری ماشین می‌شود. استفاده از قالب ورودی یکسان در فرایند، کدنویسی برای آموزش و تست، موجب نوشتمن یک کد خواهد شد. استانداردسازی تصاویر توسط نگارنده‌گان بهوسیله یکی کردن فرمتهای مختلف (جی.پی.جی.، پی.ان.جی. و...) و مقیاس تصاویر به صورت دستی و بهبود، معادل کردن رنگشان با نرم‌افزار فتوشاپ انجام شده است. تقسیم‌بندی داده‌ها برای آموزش و تست: داده‌های منتخب پس از غربالگری و استانداردسازی به‌طور مستقیم توسط دیتاست ورودی به دو قسمت داده‌های آموزشی و تست تقسیم‌بندی شده‌اند. داده‌ها می‌توانند به نسبت‌های مختلف ۲۰ به ۸۰، ۳۰ به ۷۰، ۴۰ به ۵۰ و ۵۰ به ۵۰ تقسیم شوند (Prashantha et al., 2019, 2445). در این پژوهش از نسبت نرمال ۲۰ به ۸۰ استفاده شده است.

مرحله دوم، مهندسی و استخراج ویژگی

انتخاب ویژگی، به عنوان یک تکنیک کاهش ابعاد با هدف انتخاب مجموعه کوچکی از ویژگی‌های مربوط به ویژگی‌های مرتبط اصلی بهوسیله حذف ویژگی‌های نامرتب و اضافی است. انتخاب ویژگی منجر به تغییر در دقت آموزش نمی‌شود؛ بلکه با کاهش زمان و جلوگیری از قرار گرفتن الگوریتم‌ها در کمینه‌ها/بیشنه‌های محلی، سرعت کانونرژن به پاسخ نهایی را بیشتر می‌کند. ویژگی‌های نامریط ویژگی‌هایی هستند که نمی‌توانند به تمایز نمونه‌ها از کلاس‌های مختلف (با نظارت) یا خوشها (بدون نظارت) کمک کنند. حذف ویژگی‌های نامرتب ممکن است به یادگیری بهتر مدل کمک کند، زیرا ویژگی‌های نامریط ممکن است سیستم یادگیری را دچار سردرگمی کرده و باعث ناکارآمدی محاسبات شود (Wang et al., 2016, 1). برای تشخیص میزان اهمیت ویژگی‌های آماری و کالبدی در فرایند یادگیری ماشین می‌توان نقش هر یک را به صورت جداگانه سنجید. به این معنی که آیا صرفاً ویژگی‌های کالبدی به نتایج مطلوب می‌رسد و یا ویژگی‌های کالبدی در کنار ویژگی‌های آماری می‌تواند به نتایج بهتر رهنمون شود. برای این منظور دو الگوی کلی زیر برای یادگیری ماشین در نظر گرفته شد. در نهایت، الگوی اول نتایج بهتری را ارائه داد.

- استفاده از ویژگی‌های کالبدی:
- استفاده از ویژگی‌های کالبدی و آماری.

میزان ترجیحات بصری نما: ۲۷۸ تصویر از فیلتر تمیز کردن، انتخاب و استانداردسازی در مرحله قبل رد شدند که از آن‌ها در پرسشنامه تصویری استفاده شد. با توجه به بحران همه‌گیری ویروس کرونا، ۳ لینک پرسشنامه در فضای مجازی به اشتراک گذاشته شد که در هر لینک حدود ۹۰ تصویر قرار داشت. در نهایت، ۵۰ پرسشنامه با این شرایط تکمیل شد: الف) در نظر گرفتن افراد با پیشینه فرهنگی و آشنایی یکسان با بستر پژوهش که سبب حذف پاسخ ساکنین غیر تهران شد. ب) عدم وجود پیشینه علمی در حوزه پژوهش (نماهای ساختمن)، نیز

سبب حذف پاسخ افراد متخصص معماری و شهرسازی شد. ج) مشاهده دقیق هر نمای ساختمان و پاسخ دقیق به پرسش‌ها، سبب حذف پاسخ‌هایی با انتخاب کمتر از ۵ گزینه شد. در این پرسشنامه، انتخاب نمای ترجیحی تنها سؤال مورد نظر است. گزینه‌های منتخب می‌توانند شامل تعداد محدودی از تصاویر یا هر ۹۰ تصویر باشند. در مجموع ۲۱۸ پاسخ از بین ۲۳۰ پرسشنامه قابل انتکاباقی ماند. طبق فرمول‌های تعیین حجم نمونه، در صورتی که حجم جامعه آماری مشخص نباشد برای رسیدن به اطمینان ۹۵ درصدی، ۱۸۱ پرسشنامه کافیست می‌کند؛ بنابراین تعداد پرسشنامه‌ها مناسب تشخیص داده شد. بازه سنی تعداد ۲۱۸ پاسخ قابل قبول، بین ۲۴ تا ۴۹ سال بوده که در میان آن‌ها افراد ۹٪ دیپلم، ۵۳٪ کارشناسی، ۹٪ ارشد و ۲٪ دکترا بوده‌اند. با توجه به اینکه مدل پژوهش، یادگیری ماشین نظارت شده است؛ میزان ترجیحات به عنوان خروجی ماشین باید دسته‌بندی شود. برای دسته‌بندی بهتر میزان ترجیحات می‌توان با فرمول $(100 \times \frac{X_i - \min(x)}{\max(x) - \min(x)})$ دسته‌بندی شود. ($Z_i = \frac{X_i - \min(x)}{\max(x) - \min(x)}$) آن‌ها را بین صفر تا صد نرمالیزه کرد و سپس در بازه (ترجیح کم، متوسط، خوب و زیاد) تقسیم‌بندی نمود؛ به‌گونه‌ای که میزان ۲۵-۰ در دسته ترجیح کم، ۵۰-۲۶ در دسته ترجیح متوسط و ۵۱-۷۵ در دسته ترجیح خوب، ۱۰۰-۷۶ در دسته ترجیح زیاد قرار گیرند. برای مثال استاندارد سازی میزان ترجیح در پرسشنامه برای فردی با پاسخ ۲۲ درصد $(100 \times \frac{11-0}{44.5-0})$ ($= Z_i = \frac{11-0}{44.5-0}$) ۷۴٪ محاسبه می‌شود. به همین ترتیب برای هر فرد پاسخ‌دهنده این مقدار محاسبه شده است. تعداد تصاویر نما در هر چهار دسته، به شرح: ۲۱۹ تصویر در دسته اول، ۴۱ تصویر در دسته دوم، ۱۳ تصویر در دسته سوم و ۵ تصویر در دسته چهارم است. این دسته‌ها کاملاً گسترشده و جدا از هم هستند.

ویژگی‌های کالبدی: این ویژگی‌ها عبارتند از تعداد عناصر، رنگ، فاصله بین عناصر، مصالح، خطوط، فرم، تناسبات، کنتراست، رخ بام و جزئیات. نوشتمن این ویژگی‌ها برای هر یک از تصاویر بر عهده پژوهشگران بوده است. ویژگی‌هایی چون: تعداد عناصر، رنگ، خطوط، فرم، کنتراست، رخ بنا و جزئیات به‌طور دستی و ویژگی‌های دیگر مانند: فاصله بین عناصر و تناسبات از طریق محاسبات آماری در نرم‌افزار فتوشاپ محاسبه و سپس در نرم‌افزار اکسل نوشته شدند. نمونه وارد کردن ویژگی‌های یک نمونه از تصاویر در جدول زیر ارائه شده است.



شکل ۲. تصویر شماره ۲۶۸

جدول ۵. ویژگی‌های کالبدی برای تصویر شماره ۲۶۸

فرم						فاصله بین عناصر		تعداد عناصر		موقعیت ساختمان	
دارد	جلوآمدگی با عقب‌رفتگی بازشوها	ندارد	جلوآمدگی با عقب‌رفتگی سطح طبقات	دارد	فرم بازشوها	۰/۷	حداکثر فاصله بین بازشوها	۵	تعداد طبقات	تصویر نما ساختمان ۲۸۶	ردیف
			جلوآمدگی با عقب‌رفتگی طبقه همکف	دارد	فرم درب ورودی مستطیل		حداکثر فاصله بین بازشوها	۱۲	تعداد بازشوها	سال ۱۳۹۷	سال
۲	مصالح	ندارد	ترینیتات سطح بنا	دارد	جاداشدگی بام	۱/۷	حداکثر فاصله بین بازشوها	۰	تعداد بالکن‌ها	منطقه ۲ تهران	منطقه
			دیوار سبز	ندارد	جلوآمدگی بام		حداکثر فاصله بین بازشوها	۱	تعداد ورودی‌ها	منطقه ۲ تهران	منطقه
شیشه، سنگ	نوع مصالح	دارد	گلشن	ندارد	رنگ مقاومت بام	ندارد	خطوط	تناسبات	رنگ	تعداد	رنگ
		ندارد	کنتراست	ندارد	ترینیتات در بام		نوع خطوط (منحنی با صف)	۵/۵	نسبت سطح کدر به شفاف	۳	تعداد
		۰/۵	کنتراست	ندارد	خط بام		خط بام (پیوستگی با عدم پیوستگی)	۱/۵	نسبت ارتفاع به طول طبقات	خاکی، مشکی، نسکافه‌ای	نوع رنگ

با درنظر گرفتن این نکته که ماشین نمی‌تواند مقادیر توصیفی را دریافت کند؛ هر ویژگی کالبدی طراحی نما که با مقدار توصیفی تعیین شده، معادل یک عدد ثابت در نظر گرفته شده است. به طور مثال در ویژگی کالبدی مصالح که شامل: آجر، سنگ، شیشه، بتون است؛ اعداد ثابت یک تا چهار جایگزین شده‌اند. در حقیقت، ویژگی‌های چند بعدی در قالب چند ویژگی تک بعدی کدنویسی و به الگوریتم‌های یادگیری ماشین آموزش داده شده است.

ویژگی‌های آماری: به کمک پردازش تصویر ویژگی‌های سطح اول تصاویر که پیچیدگی‌های سطوح چند بعدی را ندارد، استخراج شده‌اند. توصیف‌گرهای آماری^{۳۳} مرتبه اول شامل میانگین: $\bar{x} = \frac{\sum_{i=1}^{N-1} x_i}{N-1}$ واریانس: $s^2 = \frac{\sum_{i=1}^{N-1} (x_i - \bar{x})^2}{N-1}$ ، کشیدگی: $k = \frac{\sum_{i=1}^{N-1} (x_i - \bar{x})^4}{(N-1) \times s^4}$ ، چولگی: $H(x) = -\sum_{i=1}^{N-1} p_i \log_2 p_i$ و آنتروپی: $E = \frac{\sum_{i=1}^{N-1} x_i^2}{N-1}$ ، $S_k = \frac{\sum_{i=1}^{N-1} (x_i - \bar{x})^3}{(N-1) \times s^3}$ $S_k = \frac{\sum_{i=1}^{N-1} (x_i - \bar{x})^3}{(N-1) \times s^3}$ $H(x) = -\sum_{i=1}^{N-1} p_i \log_2 p_i$ تک به‌تک، مقادیر شش پارامتر برای هر تصویر محاسبه و در نرم‌افزار اکسل وارد شدند. بنابراین ویژگی‌های آماری سطح اول که بهوسیله پردازش تصویر ویژگی‌های کالبدی که پژوهش‌گران به صورت دستی استخراج کرده‌اند، به عنوان ورودی فرایند یادگیری ماشین در نظر گرفته شده و یکبار هم صرفاً ویژگی‌های کالبدی به عنوان ورودی فرایند یادگیری ماشین لحاظ شده است. ویژگی‌های آماری سطح اول، پایین‌ترین سطح ویژگی هستند که خروجی‌شان به صورت تک عدد و در یک بعد خواهد بود. اما در استخراج ویژگی‌های دیگر، خروجی تصویر یک سیگنال دو بعدی با سطراها و ستون‌های پیکسلی است که خود سبب پیچیدگی محاسبات و کدنویسی در فرایند پژوهش می‌شود. از آنجاکه نتایج مورد انتظار در این پژوهش با به کارگیری ویژگی‌های سطح اول حاصل شده، نیازی به استفاده از ویژگی‌های آماری سطح دوم نبوده است.

مرحله سوم، انتخاب مدل

همان‌طورکه پیش از این بیان شد، در این پژوهش از مدل یادگیری تحت نظرارت استفاده شده است. این مدل یک مجموعه داده شامل خروجی‌های دلخواه (برچسب‌ها) است؛ به طوری که یکتابع می‌تواند خط را برای یک پیش‌بینی معین محاسبه کند. یکبار تصاویر (همان داده‌ها) به همراه ویژگی‌های آماری سطح اول و ویژگی‌های کالبدی به عنوان ورودی و میزان ترجیحات بصری نما برای کاربران (ترجیحات کم، متوسط، خوب

و زیاد) به عنوان برچسب در فرایند یادگیری ماشین تحت نظارت در نظر گرفته شدند. و یکبار صرفاً تصاویر به همراه ویژگی‌های کالبدی مورد توجه قرار گرفت. در مرحله آموزش ماشین، میزان ترجیحات به عنوان خروجی منتظر با هر تصویر وارد فرایند شد و در مرحله تست مدل، به عنوان خروجی ماشین، پیش‌بینی می‌شود. پس از آن، ماشین بر روی مقادیر پیش‌بینی شده از ترجیحات و مقدار واقعی آن نظارت می‌کند.

مرحله چهارم، آموزش مدل یادگیری ماشین بر اساس داده‌های آموزشی

در یادگیری ماشین تلاش می‌شود تا مدلی برای پیش‌بینی داده‌های آزمایشی ایجاد شود. بنابراین از داده‌های آموزشی برای برازش مدل و از داده‌های آزمایشی برای آزمایش آن استفاده می‌شود. مدل‌های تولید شده برای پیش‌بینی نتایج به عنوان مجموعه تست نامگذاری شده است. داده‌ها به مجموعه آموزش و تست تقسیم می‌شوند تا با آموزش و آزمایش میزان اطمینان مدل بررسی شود (Ray, 2018). در اینجا، تصاویر نمایه‌ای مسکونی شهر تهران به دو بخش «داده‌های آموزشی» و «داده‌های آزمایش» با نسبت ۸۰ به ۲۰ تقسیم شده‌اند. الگوریتم‌های یادگیری ماشین تحت نظارت از رابطه میان تصاویر و میزان ترجیحات کاربران در هر تصویر یاد می‌گیرد و سعی در کشف رابطه و الگوی میان آن‌ها دارند. با توجه به اینکه خروجی فرایند یادگیری ماشین، چهار کلاس از میزان ترجیحات کاربران است؛ الگوریتم‌های طبقه‌بندی چون: روش‌های ماشین بردار پشتیبان، پرسپترون چندلایه، ایکس جی بوست، درخت تصمیم‌گیری، جنگل تصادفی، رگرسیون لجستیک و آدابوست مناسب هستند.

مرحله پنجم، آزمودن یا تست مدل بر اساس داده‌های آزمون

طبقه‌بندی کننده‌های یادگیری ماشینی تحت نظارت شامل دو فاز هستند. فاز اول (آموزش) داده‌های آموزشی را تحلیل می‌کند. نتیجه این تحلیل مدلی است که تلاش می‌کند در مورد چگونگی ارتباط ویژگی‌ها با برچسب، تعیین یا پیش‌بینی کند. در فاز دوم (تست)، مدل به مجموعه داده جدید (داده‌های تست) اعمال می‌شود. در الگوریتم طبقه‌بندی، ماشین تلاش می‌کند تا برچسب هر نمونه را پیش‌بینی کند. یعنی ورودی داده‌های تست یک مورد آزمایشی بدون برچسب است و هدف، تعیین برچسب کلاس آن بر اساس رابطه داده و برچسب آموخته شده از مجموعه نمونه‌های آموزشی است (Xie et al., 2011, 454). در اینجا، پس از آموزش ماشین بهوسیله رابطه بین میزان ترجیحات بصری و ویژگی‌های تصاویر نما در دو الگو، نوبت به آزمایش مجموعه داده‌های تست می‌رسد. در فرایند تست، داده‌های ورودی شامل تصاویر و ویژگی‌هایشان است و میزان مطلوبیت بصری به عنوان خروجی توسط ماشین پیش‌بینی می‌شود.

مرحله ششم، ارزیابی اطمینان مدل یادگیری ماشین با استفاده از ماتریس درهم‌ریختگی

طبقه‌بندی چند کلاسه، نوعی از طبقه‌بندی است که در آن هر نمونه داده یا شیء به یک کلاس از مجموعه شناخته شده اولیه اختصاص داده می‌شود. صرف نظر از تعداد کلاس‌های ممکن، آن‌ها متقابلاً انحصاری هستند و هر شیء را می‌توان تنها به یک کلاس نسبت داد. این رویکرد در یادگیری ماشین، همچنین به عنوان طبقه‌بندی تک برچسب^{۲۴} شناخته می‌شود (Krstnic et al., 2020, 1). پیش‌بینی طبقه‌بندی کننده تنها در صورتی دقیق است که کلاس پیش‌بینی شده با کلاس داده مبنا^{۲۵} یکسان باشد (Krstinic et al., 2020, 3). با توجه به کلاس‌های خروجی (ترجیحات کم، متوسط، خوب و خیلی خوب)، ماتریس درهم‌ریختگی^{۲۶} این پژوهش یک ماتریس ۴ در ۴ است. اگر مدل همه مثبت واقعی و منفی واقعی‌ها را درست تشخیص دهد،

میزان خطا صفر است. در جدول زیر میزان دقت مدل در دو الگو کلی ارائه شده است. الگو دوم (استفاده از ویژگی‌های کالبدی و آماری) نسبت به الگوی اول (صرفاً استفاده از ویژگی‌های کالبدی)، قابلیت پیش‌بینی مدل بیشتر و از اطمینان بالاتری برخوردار است. این نتایج نشان دهنده اهمیت ویژگی‌های آماری سطح اول و مصدقی بر درستی انتخاب آن در فرایند پژوهش است.

جدول ۶. مقایسه دقت در پیش‌بینی ترجیحات نما با استفاده از ویژگی‌های کالبدی و آماری

دقت		انواع روش‌های یادگیری ماشین
با استفاده از ویژگی‌های کالبدی و آماری	صرفاً با استفاده از ویژگی‌های کالبدی	
% ۱۰۰	% ۹۹	روش بردار پشتیبان
% ۱۰۰	% ۱۰۰	روش درخت تصمیم‌گیری
% ۱۰۰	% ۹۸	روش جنگل تصادفی
% ۹۷	% ۹۸	روش ایکس جی بوست
% ۴۱	% ۲۰	روش آدابوست
% ۸۲	% ۸۰	روش شبکه عصبی
% ۷۵	% ۵۵	روش رگرسیون لجستیک

با توجه به نتایج بالا، در جدول (۷) میزان اطمینان مدل یادگیری ماشین در الگوریتم‌های طبقه‌بندی استفاده شده در پژوهش، بر حسب پارامترهای ماتریس درهم‌آمیختگی (دقت، صحت، حساسیت و فرمول اف‌یک) در الگویی که هم ویژگی‌های کالبدی و هم ویژگی‌های آماری لحاظ شده، ارائه شده است. روش ماشین بردار پشتیبان، درخت تصمیم‌گیری و جنگل تصادفی با میزان اطمینان صدرصد و روش ایکس جی بوست با اطمینان نود و هفت درصد به عنوان بهترین روش‌ها برای پیش‌بینی میزان ترجیح نمای مسکونی از دید کاربران هستند.

روش یادگیری	ماتریس روش یادگیری ماشین در هر الگوریتم‌های مختلف	روش یادگیری	ماتریس روش یادگیری ماشین	روش یادگیری
الف) روش ماشین بردار پشتیبان		ب) روش ایکس جی بوست		روش ایکس جی بوست
میزان اطمینان	۰,۹۷	دقت	۱,۰۰	دقت
	۰,۹۷	صحت	۱,۰۰	صحت
	۰,۹۷	حساسیت	۱,۰۰	حساسیت
	۰,۹۷	فرمول اف یک	۱,۰۰	فرمول اف یک
ج) روش آدابوست		د) روش درخت تصمیم‌گیری		میزان اطمینان
میزان اطمینان	۱,۰۰	دقت	۰,۳۸	دقت
	۱,۰۰	صحت	۰,۵۱	صحت
	۱,۰۰	حساسیت	۰,۳۸	حساسیت
	۱,۰۰	فرمول اف یک	۰,۴۰	فرمول اف یک
و) روش شبکه عصبی		ه) روش جنگل تصادفی		میزان اطمینان
میزان اطمینان	۱,۰۰	دقت	۰,۸۳	دقت
	۱,۰۰	صحت	۰,۸۲	صحت
	۱,۰۰	حساسیت	۰,۸۳	حساسیت
	۱,۰۰	فرمول اف یک	۰,۸۱	فرمول اف یک
ی) روش رگرسیون لجستیک				میزان اطمینان
میزان اطمینان	۰,۷۳	دقت	۰,۷۳	دقت
	۰,۸۰	صحت	۰,۷۳	صحت
	۰,۷۴	حساسیت	۰,۷۴	حساسیت
	۰,۷۴	فرمول اف یک	۰,۷۴	فرمول اف یک

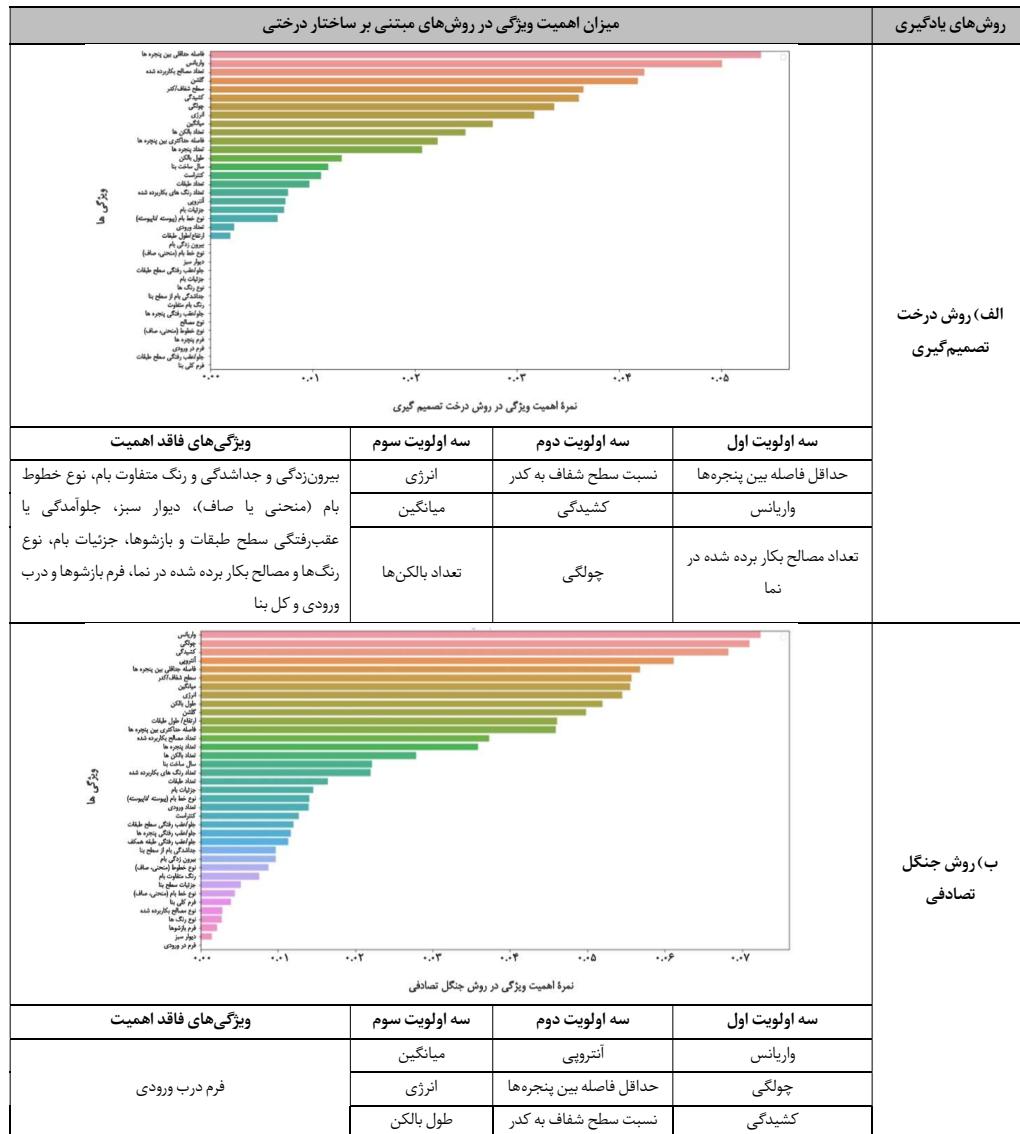
بحث

در این پژوهش، ماشین توسط روش‌های مختلف یادگیری تحت نظارت و الگوریتم دسته‌بند (روش ماشین بردار پشتیبان، جنگل تصادفی، درخت تصمیم‌گیری، ایکس جی بوست، آدابوست و شبکه‌های عصبی) آموزش

دید و طبق مدل ایجاد شده از هر یک از روش‌ها، میزان ترجیحات بصری نما برای کاربر در تصاویر نماهای شهر تهران پیش‌بینی شد.

شناسایی میزان اهمیت هر یک از ویژگی‌های کالبدی و آماری در تعیین ترجیحات بصری نما: به منظور تعیین میزان اهمیت هر یک از ویژگی‌ها از روش‌های ترکیبی^{۲۷} استفاده شد. اهمیت ویژگی تنها برای روش‌های ترکیبی: روش‌های مبنی بر ساختار درختی^{۲۸} (درخت تصمیم‌گیری، جنگل تصادفی) و روش‌های تقویتی^{۲۹} (آدابوست، ایکس جی بوست) قابل محاسبه است. بررسی اهمیت هر یک از ویژگی‌های آماری و کالبدی سبب نمایش نقش آن‌ها در میزان اطمینان ماتریس درهم ریختگی شده است. همچنین، میزان اهمیت بالای ویژگی‌های آماری سطح اول را نمایش می‌دهد. با توجه به در نظر گرفتن میزان تأثیر هر ویژگی در هر روش می‌توان به علت بالا یا پایین بودن میزان دقت آن روش پی برد.

جدول ۸. بررسی و مقایسه میزان تأثیرگذاری هر یک از وزیرگاه‌ها در پیش‌بینی مدل ایجاد شده توسط روش‌های مبتنی بر ساختار درختی



جدول ۹. بررسی و مقایسه میزان تأثیرگذاری هر یک از ویژگی‌ها در پیش‌بینی مدل ایجاد شده توسط روش‌های مبتنی بر ساختار تقویتی

میزان اهمیت ویژگی در روش‌های مبتنی بر ساختار تقویتی				روش‌های یادگیری
ویژگی‌های فاقد اهمیت	سه اولویت سوم	سه اولویت دوم	سه اولویت اول	
فرم درب ورودی	واریانس	فرم کلی بنا	تعداد مصالح به کار برده شده در نما	الف) روش ایکس جی بوسٹ
	میانگین	نوع خطوط صاف یا منحنی)	جدا شدگی بام از سطح بنا	
	جزئیات سطح بنا	کشیدگی	گلشن	
نمودارهای بالا، میزان اهمیت هر یک از ویژگی‌ها را در روش‌های ترکیبی (جنگل تصادفی، درخت تصمیم‌گیری، ایکس جی بوسٹ و آدابوست) مشخص کرده است. با در نظر گرفتن آنکه تنها دو روش درخت تصمیم‌گیری و جنگل تصادفی جزء روش‌های ترکیبی یادگیری ماشین هستند که به اطمینان بالایی رسیده‌اند. بنابراین میزان اهمیت ویژگی‌ها در این دو روش به عنوان میزان اهمیت ویژگی‌ها در شناسایی و پیش‌بینی مطلوبیت بصری نما برای کاربر محسوب می‌شود. بر این اساس با اهمیت‌ترین ویژگی‌های آماری به ترتیب شامل: واریانس، کشیدگی، چولگی، میانگین، انرژی و آنتروپی هستند. ویژگی‌های کالبدی طراحی نما که متغیرهای کاربردی				ب) روش آدابوست
ویژگی‌های فاقد اهمیت	سه اولویت سوم	سه اولویت دوم	سه اولویت اول	
تعداد طبقات و بالکن‌ها و درب ورودی، کشیدگی، بیرون‌زدگی و جداشدنی و رنگ متفاوت بام، نوع خطوط و خلطون بام (منحنی یا صاف)، دیوار سبز، جلوآمدگی یا غیررفتگی سطح طبقات و بازشوها، جزئیات بام و سطح بناء، نوع و تعداد رنگ‌ها و مصالح به کار برده شده در نما، فرم بازشوها و درب ورودی و کل بنا، حداقل و حداقل فاصله بین بازشوها، انرژی، نسب سطح شفاف به کدر و ارتفاع به طول طبقات، طول و تعداد بالکن، کنتراس	آنتروپی	گلشن	کشیدگی	
	میانگین	تعداد پنجره‌ها	فرم کلی بنا	
	-	جلوآمدگی یا غیررفتگی طبقه همکف در سطح نما	واریانس	

در طراحی شهری هستند: به ترتیب اهمیت شامل: حداقل فاصله بین پنجره‌ها، نسبت سطح شفاف به کدر در نما، گلشن/باغچه در بالکن، تعداد مصالح، حداقل فاصله بین پنجره‌ها، تعداد بازشوها، طول بالکن، تعداد بالکن‌ها، تعداد طبقات، تعداد رنگ، تزئینات استفاده شده در بام، نوع خطوط بام (پیوسته، ناپیوسته)، تعداد ورودی، نسبت ارتفاع به طول بنا هستند. این ویژگی‌های ذکر شده به ترتیب مهم‌ترین عوامل مؤثر بر مطلوبیت بصری نما برای کاربر در تصاویر نمای مسکونی شهر تهران هستند.

آزمایش و کاربرد مدل آموزش دیده در نمونه‌ای از تصاویر نمای: به منظور تعیین ارزش کاربردی مدل پژوهش، چند نمونه تصویر جدید نما به ماشین به عنوان ورودی داده شد تا خروجی بررسی شود. در عین حال با طراحی یک پرسشنامه آنلاین در فضای مجازی و تعیین میزان ترجیح آن توسط ۳۲ نفر، نتایج پیش‌بینی مدل با میزان ترجیح نماها مقایسه و موفقیت آن نمایش داده شده است. در جدول شماره ۱۰ ویژگی‌های کالبدی و آماری این تصاویر که به عنوان برچسب وارد فرایند یادگیری ماشین شده و در جدول (۱۱) میزان پیش‌بینی ماشین و بررسی شده است.

جدول ۱۰. ویژگی‌های کالبدی و آماری سه تصویر نمونه (برچسب تصاویر)

ویژگی‌های آماری	ویژگی‌های کالبدی نما	تصویر نما	
میانگین: ۸۳,۰۸۶۵۷۱۵ واریانس: ۴۲۰۵,۱۲۵۳۶۴ کشیدگی: ۲,۴۹E-۰۶ چولگی: ۱,۳۰ E-۰۷ انرژی: ۰,۰۰۶۱۲۲۲۷ آنتروپی: ۷,۵۸۶۸۲۳۸۱۶	جاداشدگی بام: ندارد جلوآمدگی بام: دارد رنگ متفاوت بام: ندارد نوخ خطوط بام: صاف ترنیتات سطح بنا: ندارد دیوار سیز: ندارد گلشن: دارد نوع مصالح: ۳ کنتراست: ۷۵	جادوآمدگی یا عقب رفتگی سطح: ندارد جلوآمدگی یا عقب رفتگی همکف: دارد جلوآمدگی یا عقب رفتگی بازشوها: دارد تعداد رنگ: ۳ نوع رنگ: کرمی، آجری، حاکستری نسبت سطح کدر به شفاف: ۶ نسبت تعداد طبقات به طول: ۱/۵ پیوستگی خط بام: پیوسته نوع مصالح: شیشه، آجر، سنگ	تعداد طبقات: ۵ تعداد بازشوها: ۱۲ تعداد بالکن‌ها: ۴ تعداد ورودی: ۳ حداقل فاصله بین بازشوها: ۶,۰ حداكتفه‌های بین بازشوها: ۱,۸ فرم بالکن: مریع، مستطیل فرم بالکن: مستطیل طول بالکن: ۲/۱
میانگین: ۱۶۳,۸۱۸۶۸۷۶ واریانس: ۵۰,۳۱۹۶۰۸۴ کشیدگی: -۸,۹E-۰۷ چولگی: ۵,۲۹E-۰۸ انرژی: ۰,۵۰۳۱۹۸۵۷ آنتروپی: ۶,۸۱۵۷۸۹۰۳۱	جاداشدگی بام: دارد جلوآمدگی بام: ندارد رنگ متفاوت بام: ندارد نوخ خطوط بام: صاف ترنیتات سطح بنا: ندارد دیوار سیز: ندارد گلشن: دارد نوع مصالح: ۳ کنتراست: ۰,۵	جادوآمدگی یا عقب رفتگی سطح: ندارد جلوآمدگی یا عقب رفتگی همکف: دارد جلوآمدگی یا عقب رفتگی بازشوها: دارد تعداد رنگ: ۲ نوع رنگ: نساکافه ای، قهوه‌ای نسبت سطح کدر به شفاف: ۳,۶ نسبت تعداد طبقات به طول: ۱,۶۳ پیوستگی خط بام: پیوسته نوع مصالح: شیشه، سنگ	تعداد طبقات: ۶ تعداد بازشوها: ۱۵ تعداد بالکن‌ها: ۸ تعداد ورودی: ۲ حداقل فاصله بین بازشوها: ۰,۹ حداكتفه‌های بین بازشوها: ۱,۵۳ فرم بالکن: مریع، مستطیل فرم بالکن: مستطیل طول بالکن: ۳/۱
میانگین: ۱۵۵,۱۹۴۲۰۰۲ واریانس: ۶۸۶۲,۴۰۶۸۴۷ کشیدگی: -۳,۸۱E-۰۷ چولگی: ۳,۴۰ E-۰۸ انرژی: ۰,۰۵۰۷۸۵۸۴۸ آنتروپی: ۶,۹۲۵۷۸۱۹۷۳	جاداشدگی بام: دارد جلوآمدگی بام: ندارد رنگ متفاوت بام: دارد نوخ خطوط بام: صاف ترنیتات سطح بنا: ندارد دیوار سیز: ندارد گلشن: دارد نوع مصالح: ۳ کنتراست: ۱	جادوآمدگی یا عقب رفتگی سطح: دارد جلوآمدگی یا عقب رفتگی همکف: دارد جلوآمدگی یا عقب رفتگی بازشوها: دارد تعداد رنگ: ۳ نوع رنگ: آجری، کرمی، دغالی نسبت سطح کدر به شفاف: ۵,۹ نسبت تعداد طبقات به طول: ۱,۷ پیوستگی خط بام: پیوسته نوع مصالح: شیشه، آجر، سنگ	تعداد طبقات: ۴ تعداد بازشوها: ۶ تعداد بالکن‌ها: ۱ تعداد ورودی: ۱ حداقل فاصله بین بازشوها: ۱,۶ حداكتفه‌های بین بازشوها: ۱,۶ فرم بالکن: مستطیل فرم بالکن: مستطیل طول بالکن: ۲/۱

میزان ترجیح هر سه تصویر نمونه توسط کاربران در فضای مجازی سنجیده شده است. به طور مثال تصویر شماره یک و سه به ترتیب با ترجیح ۱۳,۴ و ۲۳,۳۷ درصد در بازه ترجیحی کم (بین ۰ تا ۲۵) و تصویر شماره دو با ترجیح ۲,۳۳ درصد در بازه ترجیحی متوسط (بین ۲۶ تا ۵۰) قرار گرفته‌اند. پس از تعیین میزان واقعی ترجیح هر تصویر، میزان پیش‌بینی هر تصویر توسط ماشین محاسبه خواهد شد. پس از آن، سه تصویر با ویژگی‌های آماری و کالبدی (جدول بالا) برچسب گذاری خواهد شد. به طور مثال، در تصویر شماره یک ویژگی‌های کالبدی شامل: تعداد چهار طبقه، شش بازشو، یک بالکن و... و ویژگی‌های آماری شامل:

واریانس ۱۲، ۴۲۰۵، میانگین ۸۰/۰۸، آنتروپی ۷/۵۸ و... هستند. یادگیری ماشین برای سنجش نمونه‌ها بر مبنی روشهایی با قابلیت اطمینان صدرصد (درخت تصمیم‌گیری، جنگل تصادفی و ماشین بردار پشتیبان) مدل‌سازی می‌شود. در نهایت، میزان پیش‌بینی مدل با مقدار واقعی مقایسه و درستی یا نادرستی فرایند یادگیری ماشین مشخص خواهد شد.

جدول ۱۱. آزمایش و تست چند مورد از تصاویر برای شناسایی ترجیحات مردم مبتنی بر یادگیری ماشین

نما	دسته ترجیحات	درصد	میزان پیش‌بینی ماشین در سه روش با اطمینان صدرصد	درستی یا نادرستی
تصویر نما شماره یک	ترجیحات کم و بازه بین ۰ تا ۲۵	۱۳/۴	درخت تصمیم، جنگل تصادفی و ماشین بردار پشتیبان: دسته ترجیحی کم	درست
تصویر نما شماره دو	ترجیحات متوسط و بازه بین ۲۶ تا ۵۰	۳۳/۲	درخت تصمیم، جنگل تصادفی و ماشین بردار پشتیبان: دسته ترجیحی متوسط	درست
تصویر نما شماره سه	ترجیحات کم و بازه بین ۰ تا ۲۵	۲۳/۳۷	درخت تصمیم، جنگل تصادفی و ماشین بردار پشتیبان: دسته ترجیحی کم	درست

نتیجه‌گیری

این پژوهش به منظور ارائه مدلی پیش‌بینی کننده برای بررسی میزان ترجیحات نما مسکونی شهر تهران مبتنی بر روش یادگیری ماشین نظرارت شده انجام شد. بر اساس نتایج حاصل از ماتریس درهم ریختگی، سه الگوریتم طبقه‌بندی شده درخت تصمیم‌گیری، جنگل تصادفی، ماشین بردار پشتیبان صدرصد و الگوریتم ایکس جی بوست نود و هفت درصد قابلیت اطمینان دارد. به این معنا که پیش‌بینی ماشین در بازه ترجیحی تعريف شده (۰-۲۵ درصد: دسته ترجیحات کم، ۵۰-۲۶ درصد: متوسط، ۷۵-۵۱ درصد: خوب و ۷۶-۱۰ درصد: خیلی خوب)، درست خواهد بود. در ادامه، سه تصویر جدید به همراه برچسبشان وارد مدل ایجاد شده توسط الگوریتم‌های سه روش با اطمینان صد (درخت تصمیم‌گیری، جنگل تصادفی و ماشین بردار پشتیبان) و با پیش‌بینی درست دسته ترجیحی توسط ماشین، مدل اعتبار خود را به دست آورد. با توجه به آنکه مدل یادگیری همانند یک جعبه سیاه است و فرایند پیش‌بینی قابل مشاهده نیست؛ می‌توان با استفاده از روش‌های ترکیبی، اهمیت ویژگی‌ها مدنظر را بررسی نمود. به این ترتیب، نقش ویژگی‌های آماری در پیش‌بینی قابل توجه است. این پژوهش با محدودیت‌هایی نیز مواجه بوده است. برای نمونه عدم دسترسی به تصاویر نماهای شهری سال‌های اخیر و نبود تنوع در سبک‌های مختلف طراحی نما در تصاویر ارائه شده به کمیسیون سیما و منظر شهرداری تهران را می‌توان از محدودیتها تلقی نمود. همان‌طورکه بیان شد، تأثیر تعداد داده‌ها بر میزان اطمینان مدل آموزشی یادگیری ماشین تأثیر دارد و بنابراین هر چه تعداد تصاویر نما (داده‌ها) بیشتر باشد، نتیجه دقیق‌تری نیز حاصل می‌شود؛ لذا با حجم نمونه بیشتر می‌توان مدل دقیق‌تری را ارائه نمود. بر اساس نتایج به دست آمده و با آگاهی از محدودیت‌های پژوهش، برای مطالعات آتی می‌توان موضوع «مطلوبیت بصری نما برای کاربر را با استفاده از روش بینایی کامپیوتر مبتنی بر شبکه‌های عصبی پیچشی» پیشنهاد داد که به جای پردازش تصویر از بینایی کامپیوتر بهره برد. به‌واسطه این روش، امکان استخراج ویژگی‌های تصاویر به صورت خودکار و بدون دخالت پژوهشگر از طریق شبکه‌های عصبی پیچشی و سایر روش‌های مشابه وجود دارد.

پی‌نوشت

1. Anthon Nelson
2. Kang, Bakar
3. Noland
4. Mishra and Kolay

۵. Jaipur
 6. Novack
 7. Flicker
 8. Laupheimer
 9. Liu
 10. Chatty Map
۱۱. پردازش تصویر، شاخه‌ای از هوش مصنوعی است که هدف آن نقلید از هوش انسان است (گونزالو وودز، ۱۳۳۳، ۲۰).
 12. Tucker
 13. Hernandez and Marcotegui
 14. Refuge
 15. Arthur Samuel
 16. Lasso Regression
۱۷. ماشین بردار پشتیبان: فرایند آموزش تابع تصمیم‌گیری ماشین بردار پشتیبان (Support Vector Machine) به معنای شناسایی یک ابر صفحه (Hyperplane) قابل تکرار است که فاصله (Margin) بین بردارهای پشتیبانی هر دو برجسته کلاس را حداکثر می‌کند؛ بنابراین ابر صفحه مطلوب آن است که «حداکثر فاصله» بین کلاس‌ها را ایجاد کند. ماشین بردار پشتیبان می‌تواند خطی یا غیر خطی باشد (Mechelli & Vieira, 2020, 102).
۱۸. شبکه‌های عصبی مصنوعی (Artificial Neural Networks): سعی می‌کنند عملکرد نورون‌های مغز را تا حد اندکی شبیه‌سازی کنند. شبکه‌های عصبی مصنوعی از اتصال نورون‌های مصنوعی که به صورت ریاضی شبیه‌سازی شده‌اند؛ پدید می‌آیند. تعداد این نورون‌ها و نحوه اتصال آن‌ها به یکدیگر می‌تواند بسیار متغیر باشد. بدین ترتیب شبکه‌های مصنوعی مشابه یک جعبه سیاه عمل می‌کنند که به ورودی‌های خود پاسخ مناسبی را می‌دهد (مقسمی و علیزاده سواره، ۱۳۹۷، ۱۰).
۱۹. درخت تصمیم‌گیری (Decision Tree): ایده اصلی درگیر در هر رویکرد چند مرحله‌ای این است که یک تصمیم پیچیده را به چندین تصمیم ساده‌تر پیوسته تقسیم کند، به این امید که راه حل نهایی به دست آمده از این راه شبیه راه حل مورد نظر باشد (Safavian & Landgrebe, 1991, 670).
۲۰. رگرسیون لجستیک (Logistic Regression): رگرسیون لجستیک برای توصیف داده‌ها و توضیح رابطه بین یک متغیر دوتایی وابسته و یک یا چند متغیر مستقل از فاصله یا نسبت استفاده می‌شود. رگرسیون لجستیک زمانی مورد استفاده قرار می‌گیرد که متغیر وابسته (هدف) طبقه‌بندی شده باشد. مقادیر ورودی به صورت خطی با استفاده از وزن یا مقادیر ضریب برای پیش‌بینی مقدار خروجی ترکیب می‌شوند (Malhotra & Semwal, 2019, 5).
۲۱. جنگل تصادفی (Random Forest): جنگل‌های تصادفی ترکیبی از درخت‌های تصمیم‌گیری هستند؛ به طوری که هر درخت به مقادیر بردار تصادفی که به طور مستقل نمونه‌برداری شده‌اند، بستگی دارد و با همان توزیع برای همه درختان جنگل است (Anurag & Xiaodai, 2016, 1).
۲۲. آدابوست (Ada Boost): اولین بار توسط یاورون و رابت شاپیر (1997) الگوریتم آدابوست معرفی شد. برخلاف این الگوریتم، اکثر الگوریتم‌های تقویت کننده برای کاهش مشکل طبقه‌بندی چند کلاس به دو کلاس با مشکلات متعدد محدود شده‌اند. فریدمن در سال ۲۰۰۱، نشان داد که آدابوست معادل یک الگوریتم مدل‌سازی افزایشی مرحله به مرحله است که ضرر نمایی را به حداقل می‌رساند (Zou et al., 2009, 349).
۲۳. ایکس جی بوست: این الگوریتم یادگیری برای مدیریت داده‌های پراکنده مناسب است و به عنوان یک روش طرح‌بندی کمی وزن دار از لحاظ نظری، امکان کنترل وزن نمونه را در یادگیری درخت تقویتی فراهم می‌کند. محاسبه موازی و توزیع شده یادگیری را سریع‌تر می‌کند که امکان کاوش سریع تر مدل را فراهم می‌کند (Chen & Guestrin, 2016, 785).
۲۴. ویژگی‌های آماری، هر یک از ویژگی‌های ثبت شده از جسم یا هر داده‌ای که به ارائه مؤلفه‌های توصیف کننده ویژگی‌های آن پپردازد، می‌باشد. توصیف‌گرهای آماری مرتبه اول، میزان شباهت یک درجه خاکستری که به صورت تصادفی انتخاب شده را به پیکسل‌های همسایه در یک ناحیه از تصویر محاسبه می‌کند و می‌توان آن‌ها را با استفاده از هیستوگرام شدت روشنایی تصویر استخراج کرد. دو توصیف‌گر میانگین و واریانس درجات خاکستری به عنوان توصیف‌گرهای آماری به صورت $\frac{\sum_{i=1}^{N-1} x_i}{n-1}$ و $\sigma^2 = \frac{\sum_{i=0}^{N-1} (I(ij) - \mu)^2}{n-1}$ می‌باشد که در این روابط ($I(j)$) بزرگی درجات خاکستری پیکسل‌ها در پنجره همسایگی پیکسل است (رنجبر و همکاران، ۱۳۹۱، ۲۳۱).
25. Singlelabel classification
 26. Ground Truth
۲۷. ماتریس درهم‌ریختگی (Confusion Matrix): یک معیار بسیار محبوب است که هنگام حل مسائل طبقه‌بندی استفاده می‌شود. می‌توان آن را برای طبقه‌بندی باینری و همچنین برای مسائل طبقه‌بندی چند کلاسه اعمال کرد. نمونه‌ای از یک

ماتریس درهم‌ریختگی برای طبقه‌بندی باینری در جدول زیر نشان داده شده است. این ماتریس شمارش مقادیر پیش‌بینی شده و واقعی را نشان می‌دهند. خروجی TN است که تعداد نمونه‌های منفی طبقه‌بندی شده را به دقت نشان می‌دهد. به طور مشابه، TP مخفف True Positive است که تعداد نمونه‌های مشتب طبقه‌بندی شده را به طور دقیق نشان می‌دهد؛ و FP مقدار مشتب کاذب را نشان می‌دهد، به عنوان مثال، تعداد نمونه‌های منفی واقعی طبقه‌بندی شده به عنوان مشتب و FN به معنای یک مقدار منفی کاذب است که تعداد نمونه‌های مشتب واقعی طبقه‌بندی شده به عنوان منفی است (90, 2020, Batarseh & Yang).

۲۸. یادگیری ترکیبی، یک الگوی یادگیری ماشین است که در آن چندین یادگیرنده برای حل یک مشکل آموزش می‌بینند. برخلاف روش‌های یادگیری ماشین معمولی که سعی در یادگیری یک فرضیه از داده‌های آموزشی دارند، روش‌های ترکیبی سعی می‌کنند مجموعه‌ای از فرضیه‌ها را باساند و آن‌ها را برای استفاده ترکیب کنند. پیش‌بینی‌های انجام شده توسط ترکیب مجموعه‌ای از طبقه‌بندی‌کننده‌ها اغلب دقیق‌تر از پیش‌بینی‌های انجام شده توسط بهترین طبقه‌بندی‌کننده منفرد هستند (Zhou & Liu, 2022, 270).

۲۹. تقریباً تمام معیارهای اهمیت ویژگی که در مدل‌های مبتنی بر درخت استفاده می‌شوند به دو دسته تعلق دارند: بهبود تقسیم یا اهمیت جایگشت. به طور شهودی، اگر پیوند بین متغیر Z_j و Z_i قطع کنیم، خطای پیش‌بینی افزایش می‌یابد، سپس متغیر Z_i را می‌توان مهم در نظر گرفت. اگر مجموعه آموزشی را به عنوان یک ماتریس X به اندازه $n \times p$ مشاهده کرد که در آن هر ردیف x_i مشاهده می‌شود، فرض کنید $Z_{\pi(i)}$ ماتریسی باشد که با جایه‌جایی ستون Z_i بر اساس مکانیزم π به دست می‌آید. اهمیت ویژگی ز به صورت زیر تعریف می‌شود:

در حالی که معیارهای اهمیت جایگشت به طور کلی می‌تواند برای هرتابع پیش‌بینی اعمال شود، بهبود تقسیم برای روش‌های مبتنی بر درخت منحصر به فرد است و می‌تواند مستقیماً از فرایند آموزش محاسبه شود. هر بار که یک گره بر روی متغیر Z تقسیم می‌شود، ناخالصی ترکیبی برای دو گره پایین‌تر کمتر از گره اصلی است. جمع کردن وزن ناخالصی برای هر شکاف در یک درخت کاهش می‌یابد و به طور میانگین برای همه درختان در جنگل امتیاز مهمی برای هر ویژگی به دست می‌آید (Zhou, 2020, 4).& Hooker, 2020, 4

۳۰. تقویت گرادیان از یک معیار قوی به اسم ویژگی/اهمیت استفاده می‌کند تا نمرات هر ویژگی را بر اساس اهمیتشان پس از ساخته شدن درخت تقویت بازیابی کند. این مدل نمره‌دهی، اهمیت هر ویژگی را از نظر تصمیم‌گیری کلیدی در هنگام ساخت درخت‌های تصمیم‌گیری ارائه می‌دهد. به طور کلی، اهمیت ویژگی امتیازی را ارائه می‌دهد که نقش مهم هر ویژگی را مشخص می‌کند. این اهمیت به صراحت با مقایسه و رتبه‌بندی همه ویژگی‌ها در میان یکدیگر در مجموعه داده محاسبه می‌شود. اهمیت یک درخت تصمیم منفرد با مقدار هر نقطه تقسیم ویژگی محاسبه می‌شود که با تعداد مشاهدات آن گره وزن می‌شود. این نقطه تقسیم برای بهبود عملکرد و کارایی الگوریتم استفاده می‌شود. به طور خاص، شاخص جینی برای انتخاب نقاط تقسیم یا شناسایی یک تابع خطأ خاص‌تر استفاده می‌شود. اهمیت ویژگی هر درخت در تمام درخت‌های تصمیم‌گیری در مدل به طور میانگین محاسبه می‌شود. کلاس انتخاب ویژگی مبتنی بر مدل برای تبدیل یک مجموعه داده به زیرمجموعه‌ها با استفاده از امیدوارکننده‌ترین ویژگی‌ها استفاده می‌شود. نقطه کانونی این رویکرد تعبیه پیش‌پردازش با این مدل برای کاهش زمان آموزش با حذف ویژگی‌های نامرتب از مجموعه داده‌های ارائه شده است. هنگامی که مرتبطترین آن‌ها استخراج شوند، می‌توان به طور مؤثر از آن‌ها برای آموزش و آزمایش مدل استفاده کرد (Upadhyay et al., 2017, 5).

منابع

- پاکزاد، جهانشاه، و بزرگ، حمیده (۱۳۹۵). الفبای روان‌شناسی محیط برای طراحان، چاپ چهارم. تهران: انتشارات آرمان شهر.
- رنجبر، هادی، حق‌دوست، علی‌اکبر، صلصالی، مهوش، خوشدل، علیرضا، سليمانی، محمدعلی، و بهرامی، نسیم (۱۳۹۱). نمونه‌گیری در پژوهش‌های کیفی: راهنمایی برای شروع. مجله علمی پژوهشی دانشگاه علوم پزشکی ارشت جمهوری اسلامی ایران، ۱۰(۳)، ۲۲۸-۲۵۰.
- رشید قلم، پریچهر (۱۳۹۵). سنجش تأثیرگذاری مطلوبیت بصری بر حضور پذیری استفاده‌کنندگان از فضا مبتنی بر تکنیک پردازش تصویر، نمونه‌موردی خیابان سی تیر، منطقه ۱۲ شهرداری تهران. پایان‌نامه برای دریافت درجه کارشناسی شهرسازی، دانشگاه هنر.
- شاهین راد، بهنوش، رفیعیان، مجتبی، و پور جعفر، محمدرضا (۱۳۹۴). ارزیابی ترجیحات بصری زنان از فضاهای شهری تهران. فصلنامه تازه‌های علوم‌شناسخنی، ۱۷(۱)، ۲۴-۱۰.
- گونزالز، رافائل، و وودز، ریچارد یوجین (۱۳۹۳). پردازش دیجیتالی تصاویر، (مترجمان: مجتبی لطفی‌زاده، امیرمسعود عمومی، حمیدرضا محمدشیرازی، سعید میرفاسمی). چاپ پنجم، تهران: انتشارات نیاز دانش.

- کیم، فیل (۱۳۹۹). یادگیری عمیق با متلب، (متراجمان: جواد وحیدی و محمد رحیمی). بابل: انتشارات فناوری نوین.
- مقسمی، حمیدرضا، و علیزاده سواره، بهروز (۱۳۹۷). شبکه‌های عصبی با متلب و سی پلاس. تهران: نیاز دانش.
- Abdi, A. (2016). *Three types of Machine Learning Algorithms*, Netherlands, Enschede: University of Twente, 1-50.
- Anurag, V. Xiaodai, D. (2016). Detection of Ventricular Fibrillation Using Random Forest Classifier. *Journal of Biomedical Science and Engineering*, 9(5), 1-33.
- Batarseh, F. & Yang, R. (2020). *Data Democracy: At the Nexus of Artificial Intelligence, Software Development, and Knowledge Engineering*. Durham City: Academic Pess.
- Bin, I. (1984). Visual Preferences in Enclosed Urban An Exploration of a Scientific Approach to Environmental Design. *Environment and Behavior Journal*, 16 (2), 235-262.
- Chen, T. & Guestrin, C. (2016). Xgboost: A Scalable Tree Boosting System. *nd acm sigkdd international conference on knowledge discovery and data mining*, New York.
- Cohen, L. (1996). Observing Responses, Visual Preferences and Habituation to Visual Stimuli in Infants. *Journal of Experimental Child Psychology*, 7, 419-433.
- Dacci, L. (2019). Aesthetical cognitive perceptions of urban street form, Pedestrian preferences towards straight or curvy route shapes. *Journal of Urban Design*, 24(6), 896-912.
- Gupta, R. & Gola, K. (2020). Analysis of Machine Learning for Processing Big Data in High Performance Computing. *EAI Endorsed Transactions on Cloud Systems*, 6(19), 1-12.
- Glukhova, D. Katilova, J. Krupina, A. (2018). Graphic-Analytical Method in Architectural Assessment Urban Visual Environment, *MATEC Web of Conferences* 245.
- Hernandez, J. & Marcotegui, B. (2013). Morphological Segmentation of Building Facade Images 16 .*th IEEEI international Conference on Image Processing*, Le Caire.
- Khastou, M. & Najafi charmini, H. (2015). Organizing The Urban landscape with Emphasis on legibility, Using Visual Preference Technique (V.P.T) (case study : Khayyam Street of Qazvin). *International journal of architecture and urban development*, 5(2), 43-56.
- Kang, K. Bakar, A. (2013).A Nightscape Preference Study Using Eye Movement Analysis. *Journal Universiti Putra Malaysia*, 6(2), 85-99.
- Kozlova, N. (2018).Architectural Organization Of Facades According to The Principle of Variability: Videoelectrical Aspect. *Journal of Architecture and Urbanism*, 42(1), 52-62.
- Kozlova, N. (2016). Contemporary Facades Of Multistorey Residential Building In Kiev: Videoelectrical Aspect. *Journal of Spaium*, 1(36) , 24-33.
- Krstinic, D., Braovic, M., Seric, L., & Bozic-Stulic, D. (2020). Multi-Label Classifier Performance Evaluation with Confusion Matrix. *AIRCC Publishing Corporation*, 10(18), 1-14.
- Krosl, K., Bauer, D., Schwarzer, M., Fuchs, H., Suter, G., & Wimmer, M. (2018). A VR-Based User Study On The Effects Of Vision Impairments On Recognition Distances Of Escape-route Signs In Buildings. *The Visual Computer Journal*, 34(6), 911-923.
- Kukhta, M., & Pelvin, Y. (2014).The Specifics Of Creating Emotional Comfort By Means Of Modern Design. *Social and Behavioral Sciences Journal*, 166, 199 - 203.
- Leopold, H., Kipruto Cheruiyot, W., & Kimani, S. (2016).A Survey and Analysis on Classification and Regression Data Mining Techniques for Diseases Outbreak Prediction in Datasets. *The International Journal Of Engineering And Science*, 5(9), 1-11.
- Liu, C., & Gagalowicz, A. (2010). Image-based Modeling of Haussmannian Facades. *The International Journal of Virtual Reality*, 9(1), 13-18.

- Liu, I. Silva, E. Wu, Ch. Wamg, H. (2017). A machine learning-based method for the large-scale evaluation of the qualities of the urban environment, Computers. *Environment and Urban Systems Journal*, 65, 113-125.
- Liu, H. Zhang, J. Zhu, J. C.H. Hoi, S. (2012). DeepFacade : A Deep Learning Approach to Facade Parsing. *Proceedings of the Twenty-Sixth International Joint Conference on Artificial Intelligence*, Melbourne.
- Laupheimer, D., Tutzauer, P., Haala, N. & Spicker, M. (2018). Neral Networks For the Classification of Building Use From Srteet : View Imagery, ISPRS Annals of the Photogrammetry. *Remote Sensing and Spatial Information Sciences*, 2, 177-184.
- Luchinin, N., Asylgaraeva, M., Startsev, S., & Samosudova, N. (2018). Characterization Of The New Dormitory Towns Visual Environments And Its Perceptual Influence On Their Residents. *MATEC Web of Conferences*,
- Malhotra, V., & Semwal, M. (2019). *Comparison of 3 Supervised Machine Learning Models*. Phd Thesis, University of Windsor.
- Mishra, S., & Kolay, S. (2019). Visual Perception of the Street Facade of a Historic Town, Case Study of the Walled City of Jaipur, India. *Springer Nature Singapore*, 2, 377-389.
- Mechelli, A., & Vieira, S. (2020). *Machine Learning Methods and Applications to Brain Disorders*. Durham City: Academic Press.
- Natalya, Z., Lyudmila, S., Lyudmila, M., Svetlana, L., & Anna, Ch. (2014). Eye Tracking and Autonomic Nervous System Reactivity During Perception of Visual Environments of Different Comfort. *European Scientific Journal*, 3, 1857-7881.
- Nelessen, A., & Constantine, J. (1993). Understanding & Making Use of People's Visual Preferences. *Planning cimmissioners journal*, 9, 12-14.
- Noland, R., Weiner, M., Gao, D., Cook, M., & Nelessen, A. (2016). Eye-Tracking Technology, Visual Preference Surveys, and Urban Design :Preliminary Evidence of an Effective Methodology. *Journal of Urbanism: International Research on Placemaking and Urban Sustainability*, 10(1), 1-11.
- Novack, T., Vorbeck, L., Lorei, H., & Zipf, A. (2020). Towards Detecting Building Facades with GraffitiArtwork Based on Street View Images. *International Journal of Geo-Information*, 9(2), 1-17.
- Pourjafar, M. & Baba Abbasi, M. (2015). Improving the Quality of Urban Spaces Through Image Processing, Case Study: 17th-Shahrivar Street of Tehran. *Journal of Armanshahr Architecture & Urban Development*, 8(14), 119-130.
- Pourdehghan, H., Shahcheraghi, A., Mokhtabad, M., & Majedi, H. (2017). Evaluating Visual Preferences of Architects and People Toward Housing Facades, Using Multidimensional Scaling Analysis. *Space Ontology International Journal*, 6(4), 7585.
- Quercia, D, Aiello, L.(2017). *Good City Life: Crowdsourcing Satellite Data and Emotions to Map Our Urban Landscape*, Retrieved, 2017 from https://www.eurisy.eu/stories/good-city-life-crowdsourcing-satellite-data-and-emotions-to-map-our-urban-landscape_241.pdf.
- Prashantha, D., Mehta, V., & Sharma, N. (2019). Classification of Handwritten Devanagari Number -An analysis of Pattern Recognition Tool using Neural Network and CNN. *International Conference on Computational Intelligence and Data Science*, India, 1672445-2457.
- Rahn, S. (2014). *Visualizing Living Streets in North St. Paul, A Visual Preference Survey in the Casey Lake Neighborhood*, Minneapolis City, Hubert H. Humphrey School of Public Affairs.
- Ray, S. (2018). A Comparative Analysis and Testing of Supervised Machine Learning Algorithms. *International Journal of Advanced Computer Science and Applications*, 10(12), 1-8.

- Ridzuan, F., Nazmee, W., & Zainon, W. (2019). *A Review on Data Cleansing Methods for Big Data. The Fifth Information Systems International Conference 2019, Penang*, 731-738.
- Safavian, R., & Landgrebe, D. (1991). A Survey Of Decision Tree Classifier Methodolog. *Reprinted From IEEE Transactions On Systems, Man, and Cybernetics*, 21(3), 660-674.
- Santosa, H., Kobayashi, Sh., & Kobayashi, T. (2012). Study of visual preferences on the growth of urban commercial streetscape through building owners assessment. *11 International Conference on Design & Decision Support Systems 2012 in Architecture and Urban Planning*, Eindhoven.
- Shahhoseini, H., Bin, M.K., & Bin Maulan, S. (2015). Visual Preferences of Small Urban Parks Based on Spatial Configuration of Place. *International Journal of Architectural Engineering & Urban Planning*, 25(2), 84-91.
- Stamps, A. (1999). Sex, Complexity, And Preferences For Residential Facades. *Institute of Environmental Quality, SAGE Journal*, 88(3), 1301-1312.
- Tucker, C., Ostwald, M., & Marshall, J. (2004). A Method For The Visual analysis of The Streetscape. *38th Annual Conference of the Architectural Science Association ANZASCA and the International Building Performance Simulation Association*, Australia.
- Tsvetkov, O., Simankina, T., & Karmokova, K. (2019). Video-Ecological Coefficient Of Real Estate Objects. *E3S Web of Conferences*, Moscow.
- Upadhyay, D., Manero, J., Zaman, M., & Sampalli, S. (2017). Gradient Boosting Feature Selection with Machine Learning Classifiers for Intrusion Detection on Power Grids. *IEEE transactions on network and service management*, 18(1), 1-14.
- Wang, S., Liu, H., & Tang, J. (2016). *Encyclopedia of Machine Learning and Data Mining*. New York City : Springer New York, NY publisher.
- Xie, X., Murphy, C., Kaiserc, G., Xue, B., & Yueh Chena, T. (2011). Testing and Validating Machine learning Classifiers by Metamorphic Testing. *The Journal of Systems and Software*, 84(4), 544-558.
- Zou, H., Zhu, J., Hastie, T., & Rosset, S. (2009). Multi-Class Adaboost. *Statistics and its Interface Journal*, (2)1, 349-360.
- Zhou, Z. Liu, J. (2022). A Review of Ensemble Learning Algorithms Used in Remote Sensing Applications. *MDPI Journals*, (12)7, 270-281.
- Zhou, Z., & Hooker, G. (2020). Unbiased Measurement of Feature Importance in Tree-Based Methods. *Journal of ACM Transactions on Knowledge Discovery from Data*, (15)2, 1-21.
- Zyagina, N., Taleeva, A., & Kuznetsova, D. (2019). Physiological Markers Of Visual Environment Comfort In The North. *Earth and Environmental Science*, 263, 1-7.

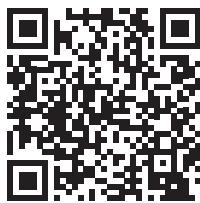
COPYRIGHTS

Copyright for this article is retained by the author(s), with publication rights granted to Journal of Architecture and Urban Planning. This is an open-access article distributed under the terms and conditions of the Creative Commons Attribution License (<https://creativecommons.org/licenses/by/4.0/>).



نحوه ارجاع به این مقاله

موسوی، نجمه و محمدی، مریم (۱۴۰۲). ارائه مدل پیش‌بینی‌کننده ترجیحات نما مسکونی با بهره‌گیری از یادگیری ماشین؛ بررسی موردی: شهر تهران. *نشریه علمی نامه معماری و شهرسازی*، ۱۶(۴۱)، ۲۳-۴۴.



DOI: 10.30480/AUP.2023.3964.1870

URL: http://aup.journal.art.ac.ir/article_1142.html

Presenting a Predictive Model of Residential Facade Preferences Using Machine Learning Case Study: Tehran

Najmeh Moosavi

MA in Urban Design, Faculty of Architecture and Urban Planning, University of Art, Tehran, Iran

Maryam Mohammadi

Associate Professor, Department of Urban Design, Faculty of Architecture and Urban Planning, University of Art, Tehran,
Iran (Corresponding Author)

Abstract

The issue of urban facade preferences for users is one of the most important issues in the field of urban design. The answer to this question has been considered by researchers in the form of various objective and subjective methods. This study intends to use machine learning method as a predictable approach to evaluate the preferences and also desirability of urban facades for users. Therefore, the aim of the research is to design a predictive model that its output is the level of user preferences of residential facades in Tehran. According to the expected output, the data provided to the model consists of residential facade image. Due to the necessity of standard data in the machine learning process, residential facade images submitted to the Tehran City Facade and Landscape Commission in the years 2016 to 2019 have been used. Out of the original 800 images, 278 images were chosen in selection process. The input of this predictive model is images along with features. The features considered in this research have been obtained using the approach of visual preferences and image processing. The issue of whether the physical characteristics related to the visual preferences approach and the statistical characteristics obtained with the image processing technique both have an effect on the level of visual preference was tested with machine learning and the results showed that the use of both the feature provide better results. Since the supervised machine learning method has been used, it was necessary to present the labels to the machine. Therefore the number of preferences were carried out through an online questionnaire by users (218) in four categories of low preferences (0–25%), medium (50–26%), good (51–75%) and very good (100–76%). By selecting the models and determining the amount of 80 to 20 as the training to test data volume, the learning process was carried out and then using the confusion matrix, the validity of the models used in machine learning was tested. Also, to ensure the predictability of the machine, at the end, some new facades which were neither training nor test data were presented to the machine and the degree of predictability of their visual preference was checked by the machine and with the result of the survey. Based on the results, three algorithms of support vector machine, decision tree and random forest with 100% accuracy and X-G-Boost method with 97% accuracy have performed best. Based on the results, the importance of the influence of elements on users' preferences, includes the minimum distance between windows, the ratio of transparent to opaque surface in the facade, the presence of gardens in the balcony, the variety of materials, the maximum distance between windows, the number of openings, the length of the balcony, the number of balconies, the number of floors, the variety of colors, the decorations used on the roof, the type of roof lines (continuous, discontinuous), the number of entrances, and the ratio of the height to the length of the building.

Keywords: Visual facade preferences, residential facade, supervised machine learning, image processing, Tehran