

## یک مدل استنتاج عصبی - فازی تطبیقی برای پیش‌بینی تقاضای سفر در اتوبوس و قطارشهری با استفاده همزمان از داده‌های مکانی و زمانی

### مقاله علمی - پژوهشی

شریعت رادفر، گروه مهندسی صنایع، واحد نجف آباد، دانشگاه آزاد اسلامی، نجف آباد، ایران  
حمیدرضا کوشا، گروه مهندسی صنایع، دانشکده مهندسی، دانشگاه فردوسی مشهد، مشهد، ایران  
علی غلامی\*، گروه مهندسی عمران، دانشکده مهندسی گرگان، دانشگاه گلستان، گرگان، ایران  
عاطفه امین‌دوست، گروه مهندسی صنایع، واحد نجف آباد، دانشگاه آزاد اسلامی، نجف آباد، ایران  
\*پست الکترونیکی نویسنده مسئول: ali.gholami32@gmail.com

دریافت: ۱۴۰۳/۰۴/۰۱ - پذیرش: ۱۴۰۳/۱۱/۰۱

صفحه

### چکیده

دسترسی به خدمات حمل‌ونقل عمومی با کیفیت و عملکرد و کارایی بالا مستلزم انواع نوآوری‌ها در برنامه‌ریزی عملیاتی و عوامل مؤثر بر آن است. پیش‌بینی تقاضای مسافر بخشی جدایی‌ناپذیر از عملیات حمل‌ونقل عمومی است، زیرا تقاضا به طور همزمان تحت تأثیر تعاملات پیچیده و غیرخطی بین بسیاری از عوامل مکانی و زمانی قرار می‌گیرد. این مطالعه یک مدل استنتاج عصبی - فازی تطبیقی را با هدف پیش‌بینی تقاضای سفر حمل‌ونقل عمومی به تفکیک نواحی ترافیکی مشهد برای بهبود برنامه‌ریزی عملیاتی در این حوزه توسعه می‌دهد. به دلیل انعطاف‌پذیر و قابل توسعه بودن مدل، امکان ترکیب متغیرهای زمانی و مکانی مختلفی در پیش‌بینی تقاضای سفر فراهم می‌شود. این پژوهش چهار مدل انجیس که با چهار مجموعه داده توسعه داده می‌شوند را ارزیابی و مقایسه می‌کند. به طوری که دو مجموعه داده یک و دو شامل کلیه متغیرهای ممکن در تحقیق، بدون پیش‌دوری از تأثیرگذاری آنها بر تقاضا و به ترتیب در افق‌های روزانه و سالانه می‌باشند. مجموعه داده سه و چهار نیز شامل متغیرهای مؤثر دو مجموعه قبلی هستند که به منظور شناسایی و انتخاب ویژگی‌های مؤثر بر متغیر وابسته تقاضا از الگوریتم جنگل تصادفی استفاده می‌شود. این اقدام موجب افزایش سرعت در پردازش این مدل‌ها و کاهش خطای آنها می‌گردد. یافته‌ها نشان داد که مجموعه داده شماره چهار که شامل ویژگی‌های مکانی در مقیاس سالانه است، عملکرد بهتری در توسعه مدل پیش‌بینی تقاضای انجیس برای دو سیستم اتوبوس و قطارشهری مشهد دارد. خطای داده‌های آموزش برای این مدل ۰/۳۳۱ و خطای داده‌های آزمایش ۱۱/۰۹۵ است. خروجی مدل‌های پیش‌بینی در این تحقیق، در صورت ایجاد تغییرات در سطح بهره‌برداری از انواع کاربری‌های شهری مشهد، برآوردی از تقاضای حمل‌ونقل عمومی در دو افق روزانه و سالانه و به تفکیک نواحی ترافیکی در اختیار برنامه‌ریزان قرار می‌دهند.

واژه‌های کلیدی: برآورد مقصد، پیش‌بینی تقاضای سفر حمل‌ونقل عمومی، داده‌های تراکنش‌های کارت‌های هوشمند، سیستم استنتاج عصبی فازی تطبیقی، متغیرهای مکانی و زمانی

### ۱- مقدمه

(2021) و از دیدگاه ترافیک می‌تواند به‌طور مؤثر آلودگی هوا را کاهش دهد. از سویی دیگر ازدحام ترافیک می‌تواند با افزایش

حمل‌ونقل عمومی از یکسو نقش اساسی در ایجاد رفاه و کیفیت زندگی شهروندان دارد ( Zarei and Mamdoohi,

روش‌های ترکیبی است که قابلیت استدلال منطقی فازی و قابلیت یادگیری یک شبکه عصبی را با هم ترکیب می‌کند، به طوری که شبکه‌های عصبی مصنوعی به صورت خودکار قوانین فازی را از داده‌های اصلی استخراج کرده و توابع عضویت به صورت تطبیقی تنظیم می‌شوند. شبکه‌های عصبی مدل‌های جعبه سیاه هستند و قادر به تعیین میزان تأثیر یک ورودی بر خروجی مدل نمی‌باشند. از سویی دیگر منطق فازی چارچوبی از استدلال تقریبی ایجاد می‌کند و نقطه ضعف آن فقدان قابلیت خودآموزی است. بنابراین از این مدل ترکیبی می‌توان انتظار داشت که دقت پیش‌بینی را به دلیل داشتن مزایای هر یک از آنها بهبود بخشد. انفیس می‌تواند پارامترهای توابع عضویت را به سرعت تطبیق دهد و آنها را با داده‌های ورودی بهینه کند. انفیس ظرفیت یادگیری سریع و قابلیت تفسیر را برای مدل‌سازی الگوهای پیچیده و درک روابط غیرخطی فراهم می‌کند و راه حل‌هایی را برای مشکلات رایج تکرار شونده با بهبود پیچیدگی زمانی و مکانی ارائه می‌نماید (Xiao et al., 2014; Atsalakis, 2014; Liang et al., 2019; Chopra et al., 2021).

سال‌های اخیر شاهد انفجار مجموعه داده‌های جغرافیایی گسترده مرتبط با حرکت انسان بوده‌ایم که دانشمندان را قادر می‌سازد تا الگوهای تحرک فردی و جمعی را به صورت کمی مطالعه و مدل‌هایی تولید نمایند که می‌توانند ساختارها و نظم‌های مکانی - زمانی در مسیر حرکت انسان را ضبط و بازتولید کنند (Barbosa et al., 2018). در میان منابع مختلف داده جدید، داده‌های کارت هوشمند این قابلیت را دارند تا تصمیمات و برنامه‌ریزی‌ها در ارائه خدمات حمل و نقل عمومی را بهبود دهند کارت‌های هوشمند ضمن بهبود بخشیدن به کیفیت داده‌ها و ارائه نگاهی مدرن‌تر به حمل و نقل (Bouteiller and d'Arcier, 2015; Chen et al., 2019)، دارای مزایای ذاتی از جمله هزینه کم و جزئیات و دقت بیشتر و کارایی بالا برای جمع‌آوری کرایه و ذخیره داده‌های تراکنش (Ma et al., 2012)، صرفه‌جویی در زمان (Wang et al., 2017a)، فراگیر بودن داده‌ها (Bonnel et al., 2021)، حجم زیاد از داده‌های سفر شخصی، دسترسی به داده‌های سفر متوالی در دوره‌های زمانی طولانی‌تر، شناسایی بیشترین کاربران (Oort et al., 2015) می‌باشند. داده‌های کارت هوشمند حمل و نقل عمومی امکان بررسی پژوهشگران در خصوص الگوهای حرکت و استخراج خوشه‌های مکانی و

زمان رفت و آمد به طور قابل توجهی آلودگی هوا را تشدید کند (Henke et al., 2020; Lu et al., 2021; González et al., 2021). استفاده از حمل و نقل عمومی برای توسعه پایدار ضروری است (Guzman et al., 2023; Zarrinmehr and Moloukzade, 2023). حمل و نقل انبوه بر یکی از اجزای حیاتی تحرک پایدار است. افزایش استفاده از حمل و نقل انبوه به طور بالقوه می‌تواند وابستگی به وسایل نقلیه شخصی و در نتیجه اثرات زیست محیطی آنها را کاهش دهد. پذیرش حمل و نقل عمومی را می‌توان با برنامه‌ریزی مؤثر و در نتیجه کمتر کردن زمان سفر و انتظار تشویق کرد (Miller et al., 2016; Mohammad and Oke, 2023).

ارائه دسترسی به خدمات حمل و نقل عمومی با کیفیت و عملکرد و کارایی بالا مستلزم انواع نوآوری‌ها در برنامه‌ریزی و عملیاتی و عوامل مؤثر بر آنها است (Liyanage et al., 2019; Liyanage and Dia, 2020). پیش‌بینی تقاضای مسافر بخشی جدایی‌ناپذیر از عملیات حمل و نقل عمومی در دنیای واقعی و بسیار چالش برانگیز است، زیرا تقاضا به طور همزمان تحت تأثیر تعاملات پیچیده و غیرخطی بین بسیاری از عوامل مکانی و زمانی و سایر عوامل خارجی مانند شرایط آب و هوایی، تراکم ترافیک و رویدادهای خاص قرار می‌گیرد. در حال حاضر پیش‌بینی تقاضا با دو رویکرد اصلی پارامتریک و ناپارامتریک انجام می‌شود. رویکردهای پارامتریک که به عنوان مدل‌های آماری یا خطی شناخته می‌شوند از تجزیه و تحلیل سری‌های زمانی سرچشمه می‌گیرند و فقط از اطلاعات زمانی استفاده می‌کنند. روابط مکانی و زمانی غیرخطی پیچیده از یکسو و تولید حجم زیادی از داده‌های حمل و نقل عمومی از سویی دیگر، باعث ظهور رویکردهای ناپارامتریک که روابط غیرخطی بین متغیرهای ورودی و خروجی ایجاد می‌کنند، گردید. با توسعه سریع هوش محاسباتی و داده‌کاوی، روش‌های هوشمند مبتنی بر داده در پیش‌بینی تقاضا محبوب شده‌اند. از مهمترین روش‌های رویکرد ناپارامتریک می‌توان به شبکه‌های عصبی، منطق فازی اشاره کرد (Milenkovic et al., 2018; Ghalekhondabi et al., 2019; Liang et al., 2019; Wu et al., 2020; Wu et al., 2021; Liyanage et al., 2022; Liu et al., 2020; Chen et al., 2020; Mitra et al., 2022). ظهور روش‌های ترکیبی هوش مصنوعی در سال‌های اخیر باعث بهبود قابلیت پیش‌بینی شده است. سیستم استنتاج عصبی فازی تطبیقی یکی از این

محققان سه مدل استنباط مقصد سفر حمل و نقل عمومی با استفاده از داده‌های کارت‌های هوشمند معرفی شده است:

مدل زنجیره سفر ( Barry et al., 2002; Zhao et al., 2007; Nassir et al., 2011; Munizaga and Palma, 2012; Gordon et al., 2013; Alsgar et al., 2015; He and Trépanier, 2015; Alsgar et al., 2016; Kumar et al., 2018; Gordon et al., 2018; Mosallanejad et al., 2019; Assemi et al., 2020; Cheng et al., 2020; Hussain et al., 2021 احتمال ( Dou et al., 2007; Zhou et al., 2012; Zhang et al., 2014; Tamblay et al., 2016; Cheng Yu and Yang, 2019)؛ مدل یادگیری عمیق (et al., 2019)؛ مزیت اصلی مدل زنجیره سفر این است که فقط به داده‌های کارت هوشمند که شامل اطلاعات سفر از قبیل زمان و مکان سوار شدن و میزان پیاده‌روی است، نیاز دارد و می‌تواند ایستگاه پیاده شدن هر مسافر را پیش‌بینی کند. اما از معایب این مدل دشواری اعتبارسنجی آن است. در مدل احتمالی و یادگیری عمیق فاکتورهای جامع‌تری مثل اطلاعات شبکه حمل و نقل عمومی از قبیل مسافت شبکه، تراکم مسیر و ایستگاه و اطلاعات کاربری زمین مثل کاربری مسکونی و تجاری در نظر گرفته می‌شود. ضمن اینکه مدل یادگیری عمیق مانند مدل زنجیره سفر می‌تواند ایستگاه پیاده شدن هر مسافر را پیش‌بینی کند. این مدل از طریق داده‌های متعدد سفر قابل اعتبارسنجی است. توسط مدل احتمالی فقط تعداد کل مسافران برآورد می‌شود و ویژگی‌های سفر فردی در این مدل نادیده گرفته می‌شود. مدل یادگیری عمیق که نیاز به داده‌های فراوان دارد و از الگوریتم پیچیده‌ای برخوردار است، برای سیستم ورود و خروج مناسب می‌باشد (Li et al., 2018).

هدف این مطالعه پرداختن به یکی از مهمترین موضوعات حمل و نقل عمومی یعنی پیش‌بینی تقاضای سفر در افق‌های کوتاه مدت روزانه و بلند مدت سالانه به تفکیک مناطق مختلف شهر می‌باشد؛ که منجر به بهبود برنامه‌ریزی عملیاتی، کاهش هزینه‌ها و افزایش رضایت مشتری در این حوزه می‌گردد. برای این منظور ما یک مدل پیش‌بینی ترکیبی مبتنی بر هوش مصنوعی (مدل استنتاج عصبی فازی) برای تقاضا را در افق‌های روزانه و سالانه توسعه می‌دهیم. شکاف تحقیقاتی کلیدی که در این مقاله مورد توجه قرار گرفته است، بررسی همزمان تأثیر چندین متغیر با مجموعه داده کامل و مقادیر یک ساله، شامل متغیرهای

زمانی ( Ma et al., 2013; Briand et al., 2017; Wang et al., 2017a; Medina, 2018; Bonnel, 2021; Mohammad and Oke, 2023)، پیش‌بینی تغییرات رفتار کاربران ( Bouteiller and d'Arcier, 2015; Dou et al., 2015)، استنباط هدف سفر ( Lee and Hickman, 2014; Kusakabe and Asakura, 2014; Alsgar et al., 2018; Chen et al., 2019)، مدل‌سازی انتخاب مسیرهای سفر ( Kim et al., 2017; Zhao et al., 2017; Mohammad and Oke, 2023) و پیش‌بینی تقاضای سفر (Wang et al., 2017c; Zhao et al., 2018)، برآورد زمان انتظار مسافر (Ingvardson et al., 2018) و نیز تحلیل استفاده از شیوه‌های مختلف حمل و نقل ( El Mahrsi et al., 2014) را فراهم می‌نماید. همچنین محققین در مطالعات خود از این داده‌ها در تعیین ایستگاه مبدأ یا مقصد سفر و تولید ماتریس‌های مبدأ - مقصد ( Barry et al., 2002; Trépanier et al., 2007; Zhao et al., 2007; Chu and Chapleau, 2008; Barry et al., 2009; Chu and Chapleau, 2010; Wang et al., 2011; Nassir et al., 2011; Ma et al., 2012; Munizaga and Palma, 2012; Gordon et al., 2013; Bouteiller and d'Arcier, 2015; Alsgar et al., 2016; Wang et al., 2017a; Li et al., 2018; Bonnel, 2021) استفاده می‌کنند. ماتریس OD ترافیک، تقاضای تحرک را در یک شبکه فراهم می‌کند. مدل‌های برآورد OD مدرن می‌توانند منابع کلان داده را که در زمان واقعی یا نزدیک به زمان واقعی جمع‌آوری شده، برای کمک به برنامه‌ریزان در درک الگوهای تحرک و نیز شناسایی جریان‌های سفر از ایستگاه‌های مبدأ تا ایستگاه‌های مقصد، استفاده کنند ( Hussain et al., 2021; Mohammad and Oke, 2023).

سیستم‌های جمع‌آوری کرایه مبتنی بر کارت‌های هوشمند را به‌صورت فقط ورودی و سیستم ورود و خروج دسته‌بندی می‌کنند. به‌طور کلی تعداد محدودی از سیستم‌های AFC مجهز به سیستم ورود و خروج هستند و نیاز است تا کاربران در آغاز و پایان سفر کارت هوشمند خود را بکشند. لذا بسیاری از محققان در تلاش برای استنباط و تعیین مقصد نامعلوم در سیستم‌های جمع‌آوری کرایه فقط ورودی هستند ( Alsgar et al., 2016; Li et al., 2018; Mohammad and Oke, 2023). بر اساس عوامل اصلی و تأثیرگذاری همچون «مکان و زمان سوار شدن مسافران»، «تعداد مسافر سوار شده»، «مدت/مسافت سفر در شبکه» و «استفاده از زمین»، توسط

مبدأ - مقصد تخمین می‌زند. استنباط مقصد سفر از طریق این الگوریتم بر پایه دو فرض اولیه می‌باشد. فرض اول این است که مسافران برای شروع سفر بعدی خود به ایستگاه مقصد سفر قبلی خود بر می‌گردند؛ و فرض دوم که فرض سفر تقارن نام دارد این است که مسافران آخرین سفر روز خود را در ایستگاهی که اولین سفر روزانه خود را در آنجا آغاز کرده بودند به پایان می‌رسانند ( Barry et al., 2002; Gordon et al., 2013; Alsker et al., 2015; Assemi et al., 2020).

این فرض تا زمانی معتبر است که: (۱) در دو سفر متوالی، هیچ نوع وسیله حمل‌ونقل شخصی (مانند خودرو، موتور سیکلت، دوچرخه و غیره) وجود ندارد که به‌عنوان فرض تداوم شناخته می‌شود؛ و (۲) مسافران برای سوار شدن در ایستگاهی متفاوت از ایستگاهی که در آنجا پیاده شده بودند، مسافت طولانی را طی نخواهند کرد ( Zhao et al., 2007; Nassir et al., 2011; Hussain et al., 2021).

در این مطالعه از روش زنجیره سفر بهبود یافته Alsker et al. (2016) به‌عنوان الگوریتم پایه استفاده می‌شود. همچنین برای تعیین وضعیت تعداد بیشتری از تراکنش‌های ورودی، بررسی سفرهای بدون پیوند در طول روز بر پایه تخمین تراکم هسته احتمالات مکانی و زمانی که توسط He and Trépanier (2015) ارائه گردیده، انجام می‌شود. مدل نهایی این تحقیق که در شکل (نمایش داده شده است، چند تفاوت مهم نسبت به مدل‌های پایه و سایر تحقیقات در این زمینه دارد. برخلاف Alsker et al. (2016) که از داده‌های یک روز هفته استفاده کرده بودند، ما کل داده‌های تراکنش‌های هر دو روش اتوبوس و مترو را در طول سال برای برآورد مقصد استفاده می‌کنیم.

به جای حذف کارت‌هایی که فقط یکبار در طول روز تراکنش داشته‌اند، در صورتیکه آن کارت دارای تراکنش‌های دیگری در طول ماه باشد، در بخش سفرهای بدون پیوند مجدد از طریق سوابق تاریخی آن را بررسی می‌کنیم.

در این مطالعه ما از زمان واقعی رسیدن به ایستگاه احتمالی پیاده شدن به جای زمان برنامه‌ریزی استفاده می‌کنیم. به‌طوری که با دریافت سرعت متوسط ناوگان در مسیر از سامانه AVL و نیز فاصله اقلیدسی بین ایستگاه سوار شدن تا ایستگاه احتمالی پیاده شدن، زمان رسیدن به آن محاسبه می‌شود.

جمعیت، انواع کاربری زمین، شرایط آب و هوا و شاخص کیفیت هوا و مناسبت‌های تقویم در پیش‌بینی تقاضا به تفکیک نواحی ترافیکی می‌باشد. استفاده از ماتریس OD در مدل انجیس پیش‌بینی تقاضای مسافران حمل‌ونقل عمومی در یک سیستم فقط ورودی مهم‌ترین چالش این تحقیق می‌باشد. از این رو پژوهشگران ابتدا با استفاده از کلان داده جمع‌آوری شده از تراکنش‌های کارت‌های هوشمند اتوبوس و مترو و با یک مدل زنجیره سفر بهبود یافته، برای اولین بار در شهر مشهد به استنباط مقصد سفر می‌پردازند. از جمله مسائلی که نسبت به مطالعات مشابه در این پژوهش مورد توجه می‌باشد، استفاده از کل مجموعه تراکنش‌های انجام شده در طول سال به‌جای استفاده از نمونه آماری در محاسبه ماتریس‌های OD و نیز تعیین وضعیت تمامی تراکنش‌ها در طی فرآیند استنباط مقصد است.

ادامه این مقاله عبارت از بخش‌های زیر است. بخش دوم شامل چارچوب روش شناختی مدل زنجیره سفر و مدل انجیس و بخش سه شامل توصیف محیط پژوهش و نیز آماده‌سازی داده‌ها و نتایج به تفکیک هر یک از مدل‌های ارائه شده در بخش دوم می‌باشد. بخش چهارم تحلیل نتایج و یافته‌های پژوهش بیان می‌شود. در نهایت، بخش پنجم نتیجه‌گیری و بینش‌هایی را برای کارهای تحقیقاتی بیشتر ارائه می‌کند.

## ۲- چارچوب کلی تحقیق

در این مطالعه پژوهشگران ابتدا با تغییراتی در یک مدل پایه زنجیره سفر بهبود یافته و بررسی همه تراکنش‌های یکساله، استنباط مقصد سفر حمل‌ونقل عمومی را انجام می‌دهند. سپس با تجمیع نتایج این بخش ماتریس‌های مبدأ - مقصد روزانه و سالانه به تفکیک نواحی ترافیکی را ایجاد می‌کنند. در گام بعدی با استفاده از نتایج ماتریس‌های OD و همچنین سایر متغیرهای تأثیرگذار احتمالی چهار مدل استنتاج عصبی فازی برای پیش‌بینی تقاضای حمل‌ونقل عمومی توسعه داده می‌شود و مورد ارزیابی قرار می‌گیرد.

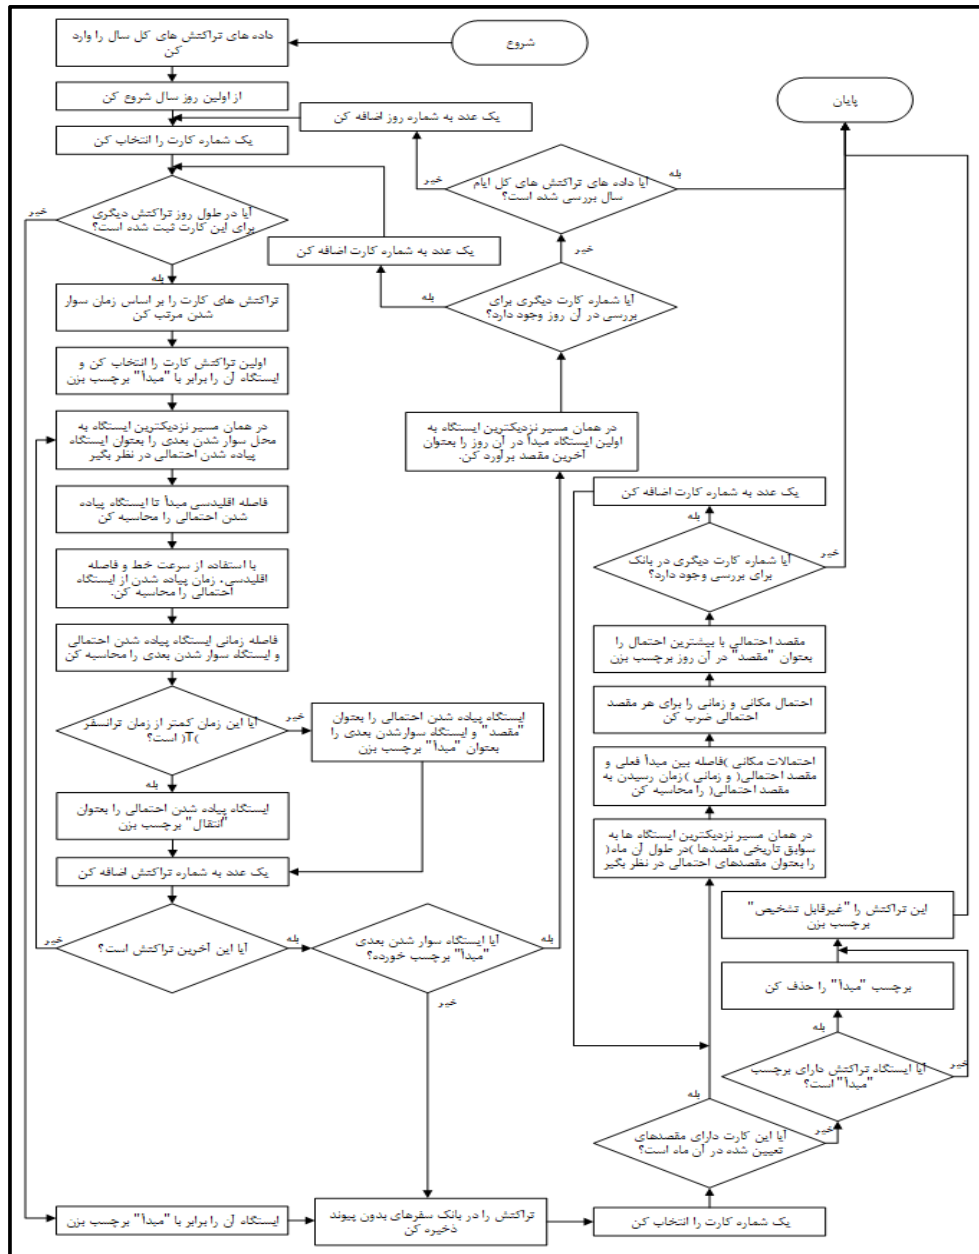
## ۲-۱- چارچوب روش شناختی مدل زنجیره سفر و تهیه

### ماتریس OD

الگوریتم روش زنجیره سفر ایستگاه‌های پیاده شدن و زنجیره‌ای از بخش‌های سفر را که بین آن انتقال نیز وجود دارد، برای استنتاج مقصد مسافران حمل‌ونقل عمومی در سفرهای

حمل و نقل عمومی می‌باشند، به همراه تراکنش‌هایی که در طی فرآیند استنتاج مقصد برچسب «غیر قابل تشخیص» خورده‌اند، به منظور برآورد ماتریس OD با بیشترین دقت، پس از محاسبه نسبت سهم هر مبدأ و مقصد از کل تراکنش‌هایی که در آن مسیر تعیین تکلیف شده‌اند تعیین وضعیت می‌شوند.

تراکنش‌هایی که در گام پیش‌پردازش داده‌ها، به‌عنوان داده‌های گمشده و داده‌های نویز و پرت شناسایی شده‌اند و یا کارت‌هایی که در طول ماه فقط یک تراکنش داشته‌اند، همگی به دلیل عدم امکان پیگیری و تعقیب زنجیره سفر مسافر برای ورود به مدل این مطالعه حذف می‌شوند، اما به صورت جداگانه ذخیره می‌گردند. همگی این تراکنش‌ها که در عمل به منزله یک سفر



شکل ۱. فلوچارت تعیین مقصد

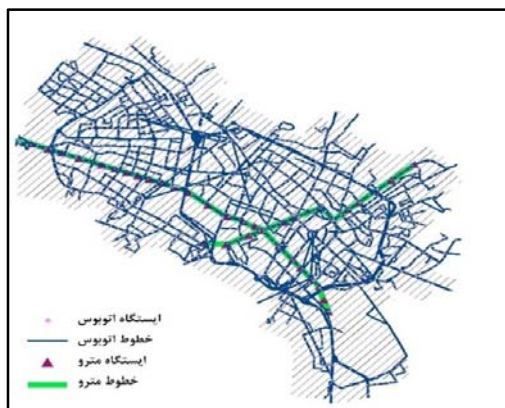
### ۲-۳- چارچوب روش شناختی مدل انفیس

۲۰۲۳، تراکم شهر مشهد را بیش از ۱۰۰۰۰ نفر به ازای هر کیلومتر مربع اعلام کرده که این یک فرصت طلایی برای ارائه خدمات حمل و نقل عمومی با تواتر بالا می‌باشد. با توجه به آمارنامه شهر مشهد این شهر به ۲۵۳ ناحیه ترافیکی تقسیم شده است. جدول ( خلاصه اطلاعات حمل و نقل عمومی شهر مشهد در سال ۱۳۹۸ را نمایش می‌دهد.

جدول ۱. خلاصه اطلاعات حمل و نقل عمومی شهر مشهد

عنوان	اتوبوس رانی	قطار شهری
تعداد مسیر فعال	۱۳۶	۲
تعداد ایستگاه‌های فعال	۳۵۱۱	۳۳
طول مسیر فعال (کیلومتر)	۲۱۶۲	۴۱/۵
تعداد ناوگان	۲۲۵۰	-
تعداد من کارت فعال	~ ۴,۵۰۰,۰۰۰	
تعداد تراکنش در سال ۹۸	~ ۳۶۱,۰۰۰,۰۰۰	

این مطالعه بر داده‌های تراکنش‌های من کارت که یک کارت هوشمند با قابلیت شارژ مجدد است تکیه دارد. در سیستم پرداخت الکترونیک کرایه‌های حمل و نقل عمومی شهر مشهد، مسافر در زمان سوار شدن به اتوبوس و یا در ایستگاه مبدأ قطار شهری با نزدیک کردن کارت خود به دستگاه‌های پرداخت، کرایه خود را پرداخت می‌کند و از این لحاظ سیستم AFC مشهد از نوع فقط ورودی محسوب می‌شود. برای این تحقیق، پژوهشگران به اطلاعات تراکنش‌ها از طریق شهرداری مشهد دسترسی پیدا کردند.



شکل ۲. نقشه ایستگاه‌ها و خطوط اتوبوسرانی و مترو

انفیس با استفاده از دانش انسانی و مجموعه داده‌های ورودی/خروجی، یک سیستم استنتاج فازی می‌سازد که پارامترهای تابع عضویت با استفاده از الگوریتم‌های مختلف تنظیم می‌شود. این تنظیم به سیستم‌های فازی اجازه می‌دهد تا از داده‌ها یاد بگیرند. مدل انفیس با توجه به تعداد ورودی، خروجی و قوانین استفاده شده تغییر می‌کند. انفیس با استفاده از گرادیان کاهش و برآورد حداقل مربعات برای بهینه‌سازی پارامترهای آن طراحی شده است. گرادیان کاهش یک الگوریتم بهینه‌سازی بسیار محبوب است که معمولاً برای آموزش شبکه‌های عصبی استفاده می‌شود. و روش پس انتشار را برای محاسبه گرادیان به کار می‌گیرد، بنابراین ساده‌ترین سیستم محاسباتی را دارد. روش بهینه‌سازی برآورد حداقل مربعات که در مدل‌های مبتنی بر رگرسیون بسیار رایج است، کمترین مجموع مربعات خطاها را محاسبه می‌کند و ضرایب بهینه خطاها را پیدا می‌نماید ( Jang, 1993; Öztayşi and Bolturk, 2014; Razavi et al., 2018; Hassanniakalager, 2020; Chopra et al., 2021; Chanal et al., 2021).

روشی که در این مطالعه استفاده می‌شود، تعداد تقاضای (جذب) سفر حمل و نقل عمومی، به عنوان متغیر وابسته، در هر یک از نواحی ترافیکی را با انفیس پیش‌بینی می‌کند. با توجه به داده‌های برآورد مقصد از انفیس برای یادگیری الگوی تعداد تقاضا استفاده می‌شود. در اینجا متغیرهای مستقل به دو مجموعه داده‌های زمانی و مکانی تقسیم خواهند شد. مساحت اعیان هر یک از کاربری‌ها و جمعیت در نواحی ترافیکی به عنوان داده‌های مکانی و مناسبت‌ها، کیفیت و شاخص آلودگی هوا، میانگین دما، رطوبت نسبی، و بارش ۲۴ ساعته به عنوان داده‌های زمانی متغیرهای این تحقیق می‌باشند. در پایان نیز به منظور ارزیابی مدل‌ها، خطای آنها از روش میانگین مربعات اندازه‌گیری می‌شود.

### ۳- پیاده‌سازی مدل و نتایج

#### ۳-۱- توصیف محیط پژوهش و داده‌ها

طبق سرشماری عمومی نفوس و مسکن شهر مشهد در سال ۱۳۹۵ با بیش از ۳ میلیون نفر جمعیت ساکن یکی از بزرگترین جمعیت‌های شهری در ایران را شامل می‌شود. مساحت این شهر ۳۴۳/۵ کیلومتر مربع است. موسسه Demographia در آخرین گزارش جمعیت‌شناسی نواحی شهری جهان در سال

علاوه بر داده‌های مرتبط با تراکنش‌های کارت‌های هوشمند (من‌کارت) که برای استنباط مقصد سفر و تولید ماتریس‌های مبدأ - مقصد کاربرد دارند، در این تحقیق منابع و پایگاه‌های مختلف داده دیگری نیز مورد استفاده قرار گرفته‌اند.

جدول ۲. خلاصه اطلاعات گردآوری و استفاده شده در مطالعه (سال ۱۳۹۸)

عنوان	مهمترین ویژگی‌های موجود	کاربرد	مأخذ
داده‌های من‌کارت	شماره و یا سریال کارت، زمان تراکنش (ساعت و تاریخ)، مکان تراکنش، اطلاعات ناوگان	شناسایی زنجیره سفر مسافران	سازمان فن‌آوری اطلاعات و ارتباطات (فاوا) شهرداری مشهد
داده‌های معادل‌ساز	شماره کارت، سریال کارت	یکسان‌سازی داده‌های تراکنش‌ها در دو سیستم اتوبوس و قطار شهری	سازمان فن‌آوری اطلاعات و ارتباطات (فاوا) شهرداری مشهد
داده‌های AVL	شماره خط، سرعت ناوگان، موقعیت ناوگان	برآورد فاصله زمانی بین ایستگاه‌ها در هر خط	سازمان اتوبوس‌رانی و شرکت بهره‌برداری قطار شهری شهرداری مشهد
داده‌های ایستگاه‌ها	نام ایستگاه، کد ایستگاه، مختصات جغرافیایی، خطوط عبوری	شناسایی ایستگاه‌های بالقوه مقصد	سازمان اتوبوس‌رانی و شرکت بهره‌برداری قطار شهری شهرداری مشهد
داده‌های خطوط اتوبوس*	شماره خط، نوع خط، کد و ترتیب ایستگاه‌های عبوری، جهت خط	تشخیص مسیر حرکت مسافر در طول سفر	سازمان اتوبوس‌رانی شهرداری مشهد
داده‌های موقعیت ایستگاه در نواحی ترافیکی	کد ایستگاه، شماره ناحیه ترافیکی ایستگاه	تعیین ناحیه ترافیکی مبدأ تراکنش و مقصد برآورد شده به منظور تولید ماتریس OD نواحی ترافیکی	مطالعه جاری
داده‌های ناحیه ترافیکی	محدوده جغرافیایی، ایستگاه‌های موجود		سازمان حمل و نقل و ترافیک شهرداری مشهد
ماتریس‌های مبدأ - مقصد	تعداد تولید و جذب سفر حمل و نقل عمومی به تفکیک نواحی ترافیکی	پیش‌بینی تقاضا	مطالعه جاری
داده‌های کاربری‌ها	انواع کاربری‌های موجود، تعداد و مساحت کاربری‌ها، تراکم، مساحت اعیان	پیش‌بینی تقاضا	معاونت شهرسازی شهرداری مشهد
داده‌های ناحیه ترافیکی	محدوده جغرافیایی، ایستگاه‌های موجود	پیش‌بینی تقاضا	سازمان مدیریت و مهندسی شبکه حمل و نقل شهرداری مشهد
داده‌های جمعیت**	جمعیت مناطق مختلف شهر، تعداد خانوار	پیش‌بینی تقاضا	مرکز آمار ایران
داده‌های هواشناسی	میزان بارش، دما و رطوبت	پیش‌بینی تقاضا	سازمان هواشناسی خراسان رضوی
داده‌های کیفیت هوا	کیفیت آلاینده‌گی، شاخص آلودگی	پیش‌بینی تقاضا	سازمان حفاظت محیط زیست خراسان رضوی
داده‌های تقویم	مناسبت‌دار یا بدون مناسبت بودن روز، تعطیل یا غیرتعطیل بودن روز	پیش‌بینی تقاضا	مرکز تقویم مؤسسه ژئوفیزیک دانشگاه تهران

\* ایستگاه‌ها در مسیر رفت و برگشت خطوط قطار شهری کد یکسان دارند و مسافر در زمان ورود به ایستگاه ابتدا تراکنش را انجام می‌دهد و سپس جهت خود را مشخص می‌کند.

\*\* سرشماری نفوس و مسکن ۱۳۹۵

### ۲-۳- آماده‌سازی داده‌های مدل زنجیره سفر

دقت، همه داده‌های ذخیره شده در فایل «تراکنش‌های غیرقابل تشخیص»، پس از محاسبه نسبت سهم هر مبدأ و مقصد از کل تراکنش‌هایی که در آن مسیر تعیین تکلیف شده‌اند تعیین وضعیت می‌شوند. گام سوم تبدیل شماره سریال من‌کارت‌ها به شماره کارت به‌وسیله داده‌های معادل‌ساز می‌باشد. این امر برای یکسان‌سازی و سپس تجمیع تراکنش‌ها در دو سیستم قطار شهری با اتوبوس‌رانی براساس ویژگی شماره کارت انجام می‌شود. با توجه به این نکته که تعدادی از خطوط اتوبوس‌رانی مشهد به محدوده‌ها و شهرهای کوچک و نزدیک اطراف آن سرویس‌دهی می‌کنند و اطلاعات دقیقی از موقعیت ایستگاه محل تراکنش آنها در دسترس نمی‌باشد، مجموع این مناطق در این بخش از مطالعه با عنوان ناحیه ترافیکی "صفر" مورد بررسی قرار گرفتند.

جدول ۳ نمونه‌ای از داده‌های آماده‌سازی و تجمیع شده تراکنش‌های هر دو سیستم برای ورودی به الگوریتم تعیین مقصد را نمایش می‌دهد. محققین در برآورد ایستگاه مقصد، زمان انتقال برای تغییر خط یا شیوه حمل‌ونقل را ۳۰ دقیقه در نظر گرفتند. بنابراین در صورتی که زمان تراکنش بعدی مسافر بیشتر از زمان انتقال باشد آن ایستگاه به‌عنوان مقصد در نظر گرفته می‌شود و در صورتی که از این زمان کمتر باشد فرآیند تعیین مقصد در مدل ادامه پیدا می‌کند. در این مطالعه به منظور تهیه مبدأ - مقصد روزانه از طریق پیاده‌سازی الگوریتم تخمین مقصد سفر، به برنامه‌نویسی با نرم‌افزار پایتون در یک سیستم دارای پردازنده ۷ هسته‌ای و رم ۱۶ گیگابایتی اقدام گردید. پس از تکمیل فرآیند کدنویسی و ورود داده‌ها، اجرای برنامه و دریافت خروجی‌ها انجام شد. خروجی برنامه شامل ۳۶۴ فایل مبدأ - مقصد روزانه است. برای اجرا و دریافت خروجی هر کدام تقریباً ۳ ساعت زمان صرف می‌شود که البته امکان اجرای برنامه به‌صورت هم‌زمان برای ۵ روز وجود دارد.

داده‌های سامانه جمع‌آوری کرایه: این داده‌ها که از جمله مهمترین منابع داده در این تحقیق هستند اطلاعات ذخیره شده حاصل از تراکنش من‌کارت‌ها در روزهای مختلف توسط مسافرین و استفاده‌کنندگان از سیستم حمل‌ونقل عمومی مشهد می‌باشد. از آنجا که این سامانه تراکنش‌های اتوبوس و قطار شهری را به‌صورت مجزا و در جداول مرتبط با هر یک ذخیره می‌کند در گام اول ویژگی‌هایی که در برآورد مقصد تراکنش‌ها کاربردی ندارند، مانند نام راننده و مبلغ تخفیف حذف شدند. در گام دوم به‌منظور پیش‌پردازش داده‌ها، شناسایی داده‌های گمشده و داده‌های نوز و پرت انجام و به دلیل عدم امکان پیگیری و تعقیب زنجیره سفر مسافر برای ورود به مدل زنجیره سفر حذف یا اصلاح می‌شوند. از جمله اقدامات در این گام می‌توان به حذف داده‌های ۲۹ اسفند سال ۹۸ که به دلیل شرایط کرونایی و تعطیلی ناشی از آن در اکثر خطوط به‌عنوان داده پرت شناسایی شدند نام برد. همچنین تراکنش‌های پرداخت نقدی که توسط اتوبوسران انجام شده است، به دلیل عدم امکان پیگیری و تعقیب زنجیره سفر مسافر از فرآیند برآورد مقصد حذف و در فایل «تراکنش‌های غیرقابل تشخیص» ذخیره می‌شوند. از آنجا که در سفر با اتوبوس سیستم پرداخت نقدی به طور کامل منسوخ نشده و تعدادی از مسافران همچنان به صورت نقدی اعتبار لازم را پرداخت می‌کنند راننده از کاردتی که شماره ثابتی دارد و توسط اتوبوس‌رانی برای او تعریف شده است این اعتبار را به صورت جایگزین پرداخت‌های نقدی وارد سیستم جمع‌آوری خودکار کرایه می‌کند. دیگر تراکنش‌هایی که حذف و در این فایل ذخیره می‌شوند، مرتبط به قطار شهری هستند که از طریق QR کد و در مبدأ مشخص انجام شده‌اند و تعیین مقصد آنها امکان‌پذیر نمی‌باشد. برای برآورد ماتریس OD با بیشترین

جدول ۳. نمونه‌ای از داده‌های تجمیع شده تراکنش کارت‌ها در دو سیستم ریل و اتوبوس

پذیرنده کارت	شماره خط	شیوه	کد ایستگاه	ساعت	تاریخ	شماره کارت
۱	۸۰۰/۱	اتوبوس	۲۰۰۶	۰۰:۰۰:۰۶	۱۳۹۸-۰۹-۱۵	۱۰۰۲۴۹۷۳۹
۱	۸۰۰/۱	اتوبوس	۲۰۰۳	۰۰:۰۲:۰۷	۱۳۹۸-۰۹-۱۵	۱۳۶۳۶۶۰۴۱۴۷۴
۱	۸۰۰/۱	اتوبوس	۲۰۰۳	۰۰:۰۲:۳۴	۱۳۹۸-۰۹-۱۵	۱۰۰۵۶۴۰۴۸
۱۲۲۲۱	۱	مترو	۱۲۲	۰۶:۳۹:۰۱	۱۳۹۸-۰۹-۰۱	۱۸۳۲۰۳۶
۱۱۳۰۱	۱	مترو	۱۱۳	۰۶:۴۸:۱۱	۱۳۹۸-۰۹-۰۱	۱۱۸۴۵۷۱
۱۰۱۰۲	۱	مترو	۱۰۱	۰۶:۴۸:۱۵	۱۳۹۸-۰۹-۰۱	۱۲۶۱۴۲۱

### ۳-۳- نتایج مدل زنجیره سفر

با برآورد مقصد تراکنش‌ها و تعیین وضعیت شدن تراکنش‌های غیرقابل تشخیص، میزان سفر تولید و جذب شده در هر منطقه مشخص گردید. (جدول) قسمتی از نتایج حاصل از اجرای مدل برای روز پنجشنبه، اول فروردین ۱۳۹۸ را نمایش داده است.

در ادامه این بخش برای اینکه درک بهتری از میزان تولید و جذب سفر در هر یک از نواحی ترافیکی ایجاد شود، اقدام به تجمیع و خلاصه‌سازی داده‌ها می‌شود. (در جدول) تعداد تولید و جذب سفر نواحی ترافیکی در سال ۱۳۹۸ و در جدول) بخشی از ماتریس OD آن سال را می‌توان مشاهده کرد.

جدول ۴. بخشی از خروجی مدل برای روز پنجشنبه مورخ ۱۳۹۸/۰۱/۰۱

شماره ناحیه مبدأ	شماره ناحیه مقصد	تعداد سفر	شماره ناحیه مبدأ	شماره ناحیه مقصد	تعداد سفر	شماره ناحیه مبدأ	شماره ناحیه مقصد	تعداد سفر
۰	۰	۴۲/۱۵۶۲	۳۴	۱۴۲	۱/۴۸	۲۱۵	۰	۳۳/۴۷
۱	۱	۳۰/۹۹	۳۴	۱۴۳	۱/۴۸	۲۱۵	۲	۱/۴۸
۲	۲	۰	۳۴	۱۵۷	۲/۹۵	۲۱۵	۵	۴/۴۳
۳	۳	۰	۳۴	۱۶۰	۴/۴۳	۲۱۵	۸	۲/۹۵
۴	۴	۰	۳۴	۱۶۱	۴/۴۳	۲۱۵	۱۰	۱۳/۲۸
۵	۵	۵/۹۰	۳۴	۱۶۲	۱/۴۸	۲۱۵	۱۱	۱۳/۲۸
...	...	...	...	...	...	...	...	...

جدول ۵. تعداد تولید و جذب سفر برای هر یک از نواحی ترافیکی در سال ۱۳۹۸

شماره ناحیه	تولید سفر	جذب سفر	شماره ناحیه	تولید سفر	جذب سفر	شماره ناحیه	تولید سفر	جذب سفر
۰	۵۲۰۲۳۹۵	۵۴۴۷۰۷۰	۱	۸۲۶۶۹۷	۶۲۱۸۵۱	۲	۲۵۷۵۲۳۱	۱۹۵۱۴۳۰
۳	۱۵۲۵۴	۱۳۰۰۷	۴	۲۵۸۴۵۸	۲۲۹۱۰۶	۵	۱۷۰۹۵۱۵	۱۲۷۲۵۴۵
۶	۸۸۹۸۱	۷۸۶۸۸	۷	۴۸۳۹۸۸	۴۲۹۹۶۵	۸	۱۶۰۵۸۶۳	۱۲۵۰۴۱۳
۹	۳۶۶۴۰۱	۲۹۰۴۰۵	۱۰	۲۳۱۱۸۷۴	۱۹۹۴۳۹۰	۱۱	۱۲۴۵۲۹۳	۱۲۳۰۵۶۶
۱۳	۸۸۴۶	۷۷۴۰	۱۳	۰	۰	...	...	...

جدول ۶. ماتریس مبدأ - مقصد در سال ۱۳۹۸

شماره ناحیه	۰	۱	۲	۳	...	۲۵۲	۲۵۳
۰	۴۶۴۳۴۳/۸	۱۶۱۸۸/۷	۵۷۴۶۳/۶	۳۴۷/۷	...	۳۶۱۵۴/۳	۱۳۳۰۲/۹
۱	۲۷۲۹۰/۹	۳۶۳۷/۸	۱۱۷۱۰/۰	۶۷/۳	...	۵۴۲۴/۵	۲۵۳۰/۵
۲	۸۹۲۷۳/۹	۱۰۵۱۲/۸	۲۹۹۹۰/۰	۲۲۷/۳	...	۲۳۲۰۴/۹	۸۱۸۸/۲
۳	۴۵۳/۹	۷۲/۹	۲۳۷/۵	۰	...	۸۳/۲	۲۷/۷
...	...	...	...	...	...	...	...
۲۵۲	۳۸۸۵۸/۴	۳۸۳۶/۱	۱۴۷۵۱/۴	۸۲/۱	...	۲۱۹۱۱/۴	۳۷۳۶۸/۶
۲۵۳	۱۷۷۴۹/۲	۱۵۳۳/۵	۵۸۷۴/۷	۳۴/۴	...	۱۸۵۸۳/۵	۲۲۸۹۳/۰

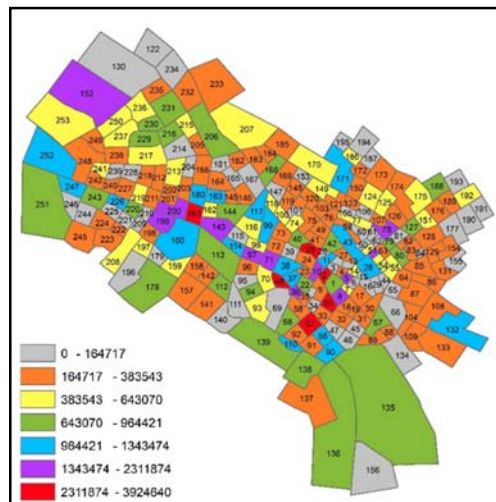
ترافیکی شهر مشهد قرار می‌گیرد. نقشه میزان تولید سفر و شکل ۴ نقشه میزان جذب سفر در سال ۱۳۹۸ را برای هر یک از نواحی ترافیکی نشان می‌دهند.

پس از آماده‌سازی جدول تولید و جذب سفر سالانه، به‌منظور ایجاد تصویری واقعی از این اتفاق در نقشه شهر با استفاده از نرم‌افزار ArcGIS این مقادیر روی لایه نواحی

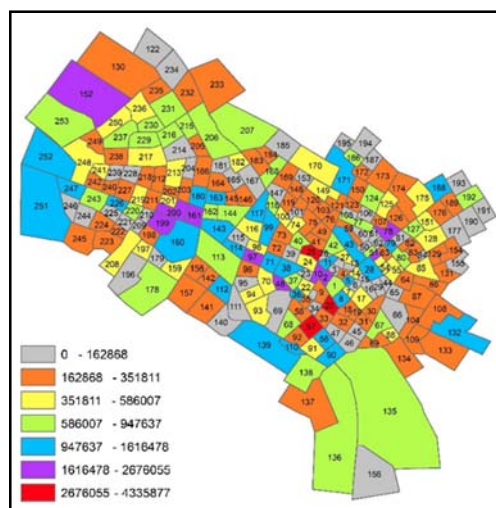
کاهش ترافیک و دستیابی به توسعه پایدار می‌شود. از سویی دیگر الگوی سفر ساکنان و تقاضا برای حمل‌ونقل نیز در چیدمان مکانی شهر، قیمت زمین و توزیع امکانات در یک منطقه تأثیرگذار خواهد بود (Sarkar and Mallikarjuna, 2013; Hu et al., 2016; Kim et al., 2018; Zhou et al., 2019; Cai et al., 2020; Afandizadeh et al., 2021). همچنین تغییرات جمعیتی نیز موجب ایجاد تغییر در تقاضای حمل‌ونقل عمومی می‌شود. رشد جمعیت بر افزایش تقاضا و تغییر الگوهای رفت‌وآمد حمل‌ونقل عمومی تأثیر می‌گذارد. به طوری که رشد جمعیت منجر به نسبت بیشتری از مسافرانی می‌شود که از حمل‌ونقل عمومی استفاده می‌کنند. همچنین نرخ سفر حمل‌ونقل عمومی را نیز افزایش می‌دهد (Zhang and Xu, 2022).

در این پژوهش اطلاعات کاربری‌های شهری با توجه به ضوابط طبقه‌بندی کاربری اراضی و با در نظر داشتن کاربری‌های موجود در سطح شهر در سبزه گروه دسته‌بندی می‌شوند. با استفاده از نرم‌افزار ArcGIS 9.3 ابتدا لایه‌های شیب فایل نقشه‌های نواحی ترافیکی، کاربری‌ها و جمعیت در محیط نرم‌افزار بازخوانی می‌گردند. پس از ترکیب اطلاعات این لایه‌ها با یکدیگر و تشکیل یک نقشه واحد، در گام بعدی هر یک از نواحی ترافیکی ادغام شده با نقشه کاربری و جمعیت برش خورده و با استفاده از جدول خصیصه اطلاعات مربوط به تعداد و مساحت عرصه و اعیان و نیز جمعیت در هر ناحیه ترافیکی استخراج می‌شوند. با حذف ویژگی‌های غیرضروری مثل تعداد و مساحت عرصه کاربری در نواحی ترافیکی که در این تحقیق کاربرد ندارند، جدول داده‌های مکانی ساخت مدل پیش‌بینی تهیه می‌شود. در این تحقیق از میزان مساحت کاربری که در عرصه زمین ساخته و مورد بهره‌برداری قرار گرفته است استفاده می‌گردد و ویژگی مساحت عرصه به دلیل وجود زمین‌های ساخته نشده و یا عدم در نظر گرفتن کاربری‌های ترکیبی در بهره‌برداری از آنها در مدل استفاده نشدند. جدول (بخشی از این اطلاعات را نمایش می‌دهد).

**شرایط آب و هوا:** حمل‌ونقل فعالیت‌هایی است که در معرض محیط بیرونی قرار دارد، لذا شرایط آب و هوا مثل میزان دما، بارش، رطوبت و باد و طوفان هم بر عملکرد سیستم‌های حمل‌ونقل و هم بر تقاضا و رفتار سفر مسافران تأثیر می‌گذارد. شرایط آب و هوایی مختلف به‌طور قابل توجهی پارامترهای جریان ترافیک را با تأثیر بر انتخاب مسافران برای زمان حرکت،



شکل ۳. نقشه میزان تولید سفر نواحی ترافیکی در سال ۱۳۹۸



شکل ۴. نقشه میزان جذب سفر نواحی ترافیکی در سال ۱۳۹۸

### ۳-۴- آماده‌سازی داده‌های مدل انفیس

داده‌های کاربری‌ها و جمعیت هر منطقه ترافیکی: خواسته‌های ترافیکی به دلیل عملکردهای مختلف مناطق در حال تکامل است، بنابراین اگر اطلاعات ویژگی‌های یک منطقه وجود داشته باشد می‌توان خواسته‌ها را نیز استنباط کرد (Nagy et al., 2017). یکی از ملاحظات مهم در حمل‌ونقل، ارتباط بین حمل‌ونقل و کاربری زمین است. الگوی سفر مردم در تعامل و ارتباط تنگاتنگ با الگوهای کاربری اراضی در یک شهر هستند. برنامه‌ریزی مناسب استفاده از زمین و محیط مکانی شهری باعث کاهش کلی سفر و تغییر روش سفر ساکنان آن از حالت‌های شخصی به حمل‌ونقل عمومی یا غیرموتوری، بهبود وضعیت آمد و شد در سطح شهر و سطح سرویس معابر،

جدول ۷. بخشی از اطلاعات کاربری‌ها و جمعیت هر ناحیه ترافیکی

ناحیه ترافیکی	۱	۲	۳	...	۱۴۳	۱۴۴	...	۲۵۲	۲۵۳
جمعیت (نفر)	۵۴	۴۵۵	۷۶۶	...	۱۱۴۷۳	۱۰۱۴۳	...	۱۰۹۰۳	۳۱۸۳۰
مساحت کل (مترمربع)	۶۵۶۴۲۲	۳۲۱۱۴۳	۲۰۵۴۵۶	...	۱۳۴۵۷۰۱	۱۲۳۹۹۴۱	...	۳۸۹۹۵۳۹	۴۹۶۷۶۵۱
مسکونی	۶۹۸۹	۵۹۲۶۴	۸۶۷۰۹	...	۱۵۱۹۳۹۴	۱۲۲۵۳۹۹	...	۴۸۷۵۷۴	۲۰۳۱۷۰۳
تجاری	۶۸۵۲۰	۳۸۹۳۲	۳۹۳۵	...	۱۲۶۶۲۲	۱۲۹۰۰۶	...	۱۳۸۳۹	۱۹۷۹۲
اداری	۳۸۴۵۱	۱۲۴۱۶	۲۴۵۶	...	۶۴۷۳	۱۵۴۲۱	...	۱۸۹۵۹	۹۳۱۴
اقامتی و هتل	۹۶۷۸	۵۴۷۰۵	۴۷۱۸۸	...	۰	۳۸۳۴۷	...	۲۷۸۶۹	۰
تفریحی، ورزشی، فرهنگی، گردشگری	۰	۰	۰	...	۷۹۸۵۰	۳۱۱۴۹	...	۳۷۳۸۸	۶۹۵۵
بهداشتی و درمانی	۷۲۴۵	۷۶۳	۲۹۲	...	۳۴۳۵	۱۴۷۱۷	...	۰	۰
آموزشی	۷۴۷۴	۱۵۳۲۸	۳۱۲۷	...	۱۶۲۱۴	۴۱۲۷	...	۵۲	۳۴۹۴۹
نظامی و انتظامی	۲۲۰۶	۰	۰	...	۱۰۷۹	۱۹۵۶	...	۰	۰
مذهبی	۱۵۲۸۵	۳۴۴۹۸	۴۹۲۳	...	۱۳۸۵	۸۶۹	...	۲۵۴۸	۲۸۸۰
مسکونی - تجاری	۵۴۲۹	۶۶۴۰	۵۰۸۲	...	۱۹۵۷۳۱	۹۶۱۷۱	...	۵۵۱۵۵	۴۰۶۹۹۳
تجاری - اقامتی	۳۴۱۹۱	۹۶۲۶۳	۲۴۱۷۵	...	۱۲۲۸	۴۴۷۲	...	۱۵۸۷۹	۰
تجاری - اداری	۱۷۳۷۹	۰	۰	...	۴۱۶۸	۰	...	۰	۰
سایر	۱۲۱۱	۵۸۱۰	۴۷۷۲	...	۶۱۹۴۰۰	۶۵۱۹۷۱	...	۴۳۷۹۸	۱۱۱۳۵

مساحت کاربری ساخته شده (مترمربع)

برآورد تقاضای سفر نواحی ترافیکی مورد استفاده قرار می‌گیرند. جدول ۸ بخشی از این داده‌ها را نمایش می‌دهد.

**میزان آلودگی هوا:** آلودگی هوا تقاضای سفر را کاهش می‌دهد و کاربران حمل‌ونقل عمومی در این شرایط مسافت و زمان سفر خود را تنظیم می‌کنند. همچنین آلودگی هوا رفتار سفر را در سفرهای تفریحی و تمایل به استفاده از مکان‌های بسته و در دسترس را می‌تواند تغییر دهد. کاهش کیفیت هوا و محدودیت تردد خودروهای شخصی و نیز خطرات سفرهای پیاده و دوچرخه باعث افزایش تقاضای حمل‌ونقل عمومی می‌شود (Wang and Zheng, 2020).

شیوه حمل‌ونقل، رفتار رانندگی، ایمنی یا حتی انجام یا عدم انجام سفر تغییر می‌دهد. در حوزه حمل‌ونقل عمومی شرایط آب و هوایی بر تقاضای کلی و مسافت طی شده در اتوبوس‌ها، خطوط تراموا یا سیستم‌های مترو تأثیر می‌گذارد. مطالعات مختلف نشان داده‌اند که دماهای بالاتر و یا برف سنگین منجر به افزایش مسافران مترو می‌شوند و یا در روزهای بارانی تقاضای حمل‌ونقل عمومی کاهش می‌یابد.

از طرفی ممکن است تقاضای سفر از سایر روش‌های حمل‌ونقل مانند دوچرخه، اسکوتر و پیاده‌روی به سمت حمل‌ونقل عمومی سوق پیدا کند ( Hofmann and O'Mahony, 2005; Zhou et al., 2017; Essien et al., 2018; Joshi, 2020; Gössling et al., 2023). داده‌های آب و هوای روزانه شامل میانگین دما، بارش و رطوبت نسبی روزانه متغیرهای زمانی هستند که در این مطالعه در

جدول ۸. بخشی از داده‌های وضعیت آب و هوا

روز	میانگین رطوبت نسبی (درصد)	بارش ۲۴ ساعته (میلی متر)	میانگین دما (سانتی گراد)
۱۳۹۸-۰۱-۰۱	۸۸/۳۷۵	۲/۴۲	۷/۱
۱۳۹۸-۰۱-۰۲	۸۷/۶۲۵	۳۰	۵/۱
۱۳۹۸-۰۱-۰۳	۶۹/۶۲۵	۰	۷/۵
۱۳۹۸-۰۱-۰۴	۷۲/۵	۰/۰۱	۱۱/۶
۱۳۹۸-۰۶-۲۷	۲۲/۳۷۵	۰	۲۷/۴
۱۳۹۸-۰۶-۲۸	۳۰/۷۵	۰	۲۶/۱
۱۳۹۸-۱۱-۲۹	۷۳/۷۵	۰	۲/۴

مناسبت و غیر تعطیل (کد دو)" و "مناسبت دار و تعطیل (کد سه)" دسته‌بندی و کدگذاری می‌شوند. توجه به مناسبت‌های مذهبی و اثر آن در تقویم رسمی در ایران یکی از ویژگی‌های این مطالعه نسبت به تحقیقات مشابه می‌باشد که با در نظر گرفتن خصوصیات فرهنگی مشهد در این مطالعه مورد استفاده قرار می‌گیرد.

**داده‌های تقاضا:** در جداول تولید و جذب سفر روزانه، از داده‌های تقاضا (جذب) به‌عنوان متغیر وابسته در مدل‌سازی پیش‌بینی تقاضا استفاده می‌شود. با توجه به اینکه ناحیه ترافیکی "صفر" به مفهوم تمام مناطق اطراف مشهد می‌باشد که در دامنه این پژوهش قرار ندارند، در این مرحله داده‌های تقاضای این ناحیه حذف می‌گردند. در ادامه فرآیند آماده‌سازی داده‌ها آنها را به‌صورت جداگانه از نظر داده‌های تکراری، داده‌های گم شده و داده‌های پرت که به دلایل متفاوت ممکن است در مجموعه داده‌ها وجود داشته باشد مورد بررسی قرار داده و تمیزسازی آنها صورت می‌گیرد. همچنین با استفاده از پایتون به‌منظور بهره‌گیری از داده‌ها در مدل نوع تمامی آنها بررسی و به اعداد اعشاری و یا صحیح تبدیل می‌شوند.

### ۳-۴-۱- مجموعه داده‌های انفیس

برای مدل‌سازی انفیس از چهار مجموعه داده استفاده می‌شود: **مجموعه داده اول:** این مجموعه داده بدون هیچ‌گونه پیش‌دوری و بررسی در مورد مؤثر بودن متغیرها بوده و شامل

عدد شاخص کیفیت هوا در محدوده بین صفر تا پانصد متغیر می‌باشد. داده‌های وضعیت آلاینده‌گی روزانه (جدول) نمونه‌ای از این داده‌ها را که در ساخت مدل استفاده شده نشان می‌دهد.

جدول ۹. بخشی از داده‌های وضعیت آلودگی هوا

روز	شاخص آلودگی هوا (AQI)
۱۳۹۸-۰۱-۰۱	۳۸
۱۳۹۸-۰۱-۰۲	۴۶
۱۳۹۸-۰۶-۲۷	۱۰۸
۱۳۹۸-۰۶-۲۸	۱۵۵
۱۳۹۸-۱۱-۲۹	۷۸

**مناسبت‌های تقویم:** ویژگی‌های سفر مسافر در روزهای عادی به لحاظ توزیع مکانی و زمانی متمایز از تقاضای سفر در تعطیلات است. لذا تأثیر ویژگی‌های اجتماعی و تعطیلات رسمی بر رفتار روزانه سفر را نمی‌توان نادیده گرفت. تعطیلات عمومی می‌توانند هم بر تقاضا برای فعالیت‌ها و هم بر عرضه فرصت‌های فعالیت در مکان و زمان تأثیر بگذارند. بدین جهت برای اطمینان از مدیریت کارآمد عملیات، پیش‌بینی دقیق توزیع جریان مسافران در تعطیلات و سایر مناسبت‌ها ضروری است (Cools et al., 2010; Wang et al., 2017b; Yao et al., 2021).

با توجه به مناسبت‌دار و یا بدون مناسبت بودن ایام سال و همچنین تعطیل بودن یا تعطیل نبودن آنها و نیز میزان اثرگذاری بر تقاضا، کل روزهای سال ۱۳۹۸ در چهار گروه "مناسبت‌دار و غیر تعطیل (کد صفر)"، "روزهای جمعه (کد یک)"، "بدون

کلیه متغیرهای مستقل مکانی و زمانی و تقاضای روزانه برای هر ناحیه ترافیکی می‌باشد، بدین صورت این مجموعه داده ۹۲۰۹۲ ستون (۳۶۴×۲۵۳) و تعداد ۲۱ سطر دارد. لازم به ذکر است داده‌های ۲۹ اسفند سال ۹۸ به دلیل شرایط کرونایی و تعطیلی ناشی از آن در اکثر خطوط، به‌عنوان داده پرت از مجموعه داده پاکسازی و حذف می‌شوند.

جدول ۱۰. بخشی از داده‌های تقسیم‌بندی شده ایام سال بر اساس مناسبت و تعطیلی

کد مناسبت	توضیحات	تاریخ
۳	عید نوروز	۱۳۹۸-۰۱-۰۱
۱	عید نوروز، وفات حضرت زینب (س)	۱۳۹۸-۰۱-۰۲
۱	عید نوروز	۱۳۹۸-۰۱-۰۹
۰	عید نوروز، جشن آبانگاه	۱۳۹۸-۰۱-۱۰
۲	بدون مناسبت	۱۳۹۸-۰۱-۱۵
۱	جمعه - بدون مناسبت	۱۳۹۸-۰۱-۱۶

جدول ۱۱. بخشی از مجموعه داده شماره یک در ساخت مدل یک انفیس (همه متغیرهای مکانی و زمانی)

...	۱۳۶	۲۷۵	۷۶۶	۴۵۵	۵۴	جمعیت ناحیه (نفر)
...	۲۳۸۸۵۲	۲۱۱۴۷۷	۲۰۵۴۵۶	۳۲۱۱۴۳	۶۵۶۴۲۲	مساحت ناحیه (m <sup>2</sup> )
...	۲۱۸۷۷	۵۷۵۰۳	۸۶۷۰۹	۵۹۲۶۴	۶۹۸۹	مسکونی (m <sup>2</sup> )
...	۲۸۴۳	۴۵۰۲	۳۹۳۵	۳۸۹۳۲	۶۸۵۲۰	تجاری (m <sup>2</sup> )
...	۲۳۳۳۸	۷۴۱۰۳	۴۷۱۸۸	۵۴۷۰۵	۹۶۷۸	اقامتی (m <sup>2</sup> )
...	۰	۲۷۴	۲۴۵۶	۱۲۴۱۶	۳۸۴۵۱	اداری (m <sup>2</sup> )
...	۰	۰	۳۱۲۷	۱۵۳۲۸	۷۴۷۴	آموزشی (m <sup>2</sup> )
...	۸۰۴	۳۵۵	۲۹۲	۷۶۳	۷۲۴۵	بهداشتی (m <sup>2</sup> )
...	۰	۰	۰	۰	۰	تفریحی (m <sup>2</sup> )
...	۲۵۲۷	۸۳۵۹	۴۹۲۳	۳۴۴۹۸	۱۵۲۸۵	مذهبی (m <sup>2</sup> )
...	۰	۰	۰	۰	۲۲۰۶	نظامی (m <sup>2</sup> )
...	۰	۰	۰	۰	۱۷۳۷۹	تجاری - اداری (m <sup>2</sup> )
...	۳۹۹۳۰	۴۶۱۵۷	۲۴۱۷۵	۹۶۲۶۳	۳۴۱۹۱	تجاری - اقامتی (m <sup>2</sup> )
...	۳۷۲۴	۷۴۰۶	۵۰۸۲	۶۶۴۰	۵۴۲۹	مسکونی - تجاری (m <sup>2</sup> )
...	۵۷۳۰	۱۰۲۵۳	۴۷۷۲	۵۸۱۰	۱۲۱۱	سایر کاربری ها (m <sup>2</sup> )
...	۳۸	۳۸	۳۸	۳۸	۳۸	شاخص آلودگی هوا (AQI)
...	۳	۳	۳	۳	۳	کد مناسبت
...	۷	۷	۷	۷	۷	دما (c)
...	۲	۲	۲	۲	۲	بارش (mm)
...	۸۸	۸۸	۸۸	۸۸	۸۸	رطوبت نسبی (درصد)
...	۱۶۹۱	۱۰۰	۷	۶۸۷	۱۰۹۰	تقاضا (نفر)

و تقاضا به‌عنوان متغیر وابسته برای هر ناحیه ترافیکی به صورت سالیانه محاسبه می‌گردد. علت ساخت این مجموعه داده و استفاده از تقاضای سالانه نواحی ترافیکی این فرض است که

مجموعه داده شماره دو: این مجموعه داده بر متغیرهای مستقل مکانی جمعیت ناحیه ترافیکی، مساحت ناحیه ترافیکی، مساحت اعیان کاربری‌هایی مثل مسکونی، تجاری، اقامتی و غیره می‌باشد

بهبود نتایج آن از بیش برآزش مدل به دلیل تعداد متغیر وابسته جلوگیری می‌کند. این الگوریتم که پایه‌ای از الگوریتم درخت تصمیم‌گیری دارد از هزاران درخت تشکیل شده که با ایجاد قوانین مختلف تأثیر هر متغیر مستقل بر متغیر وابسته و همچنین تأثیر مجموعه‌ای از متغیرهای مستقل بر متغیر وابسته را بررسی کرده و مؤثرترین متغیرهای مستقل را شناسایی می‌کند.

**مجموعه داده شماره سه:** با اجرای الگوریتم جنگل تصادفی از مجموعه داده اول متغیرهای مؤثر شناسایی و برای مجموعه داده سه انتخاب می‌شوند. جدول (۱۳) این متغیرها به همراه بخشی از داده‌ها را نمایش می‌دهد.

**مجموعه داده شماره چهار:** متغیرهای مؤثر انتخاب شده از مجموعه داده دوم توسط الگوریتم جنگل تصادفی، مجموعه داده شماره چهار را می‌سازند. این متغیرها به همراه بخشی از داده‌های آن که برای ساخت مدل چهار انفیس استفاده می‌شوند در جدول (۱۴) نمایش داده شده‌اند.

تغییرات کاربری در سطح شهر در بازه‌های زمانی بلند مدت انجام می‌شود. بنابراین با حذف متغیرهای زمانی و محاسبه تقاضای سالیانه نواحی ترافیکی این مجموعه داده با ۲۵۳ ستون که بیانگر تعداد نواحی ترافیکی و ۱۶ سطر که بیانگر هر یک از متغیرهای مستقل و وابسته می‌باشد، آماده می‌گردد. جدول ۱۲ بخشی از این مجموعه داده را نمایش می‌دهد.

با توجه به اینکه مجموعه داده شماره یک و دو دارای تمامی متغیرهای مستقل ممکن موجود می‌باشند، در این بخش قبل از ساخت مجموعه داده شماره سه و چهار و شناسایی مؤثرترین متغیرهای مستقل، همبستگی هر یک و نیز مجموعه‌ای از متغیرهای مستقل بر متغیر وابسته تقاضا در مجموعه داده شماره یک و دو مورد بررسی قرار می‌گیرد. به‌منظور انتخاب ویژگی مؤثر بر متغیر وابسته تقاضا در این مطالعه از الگوریتم جنگل تصادفی (Tin Kam Ho, 1995 and 1998; Zhou et al., 2021) برای شناسایی بهترین ویژگی‌ها استفاده می‌شود. این اقدام علاوه بر افزایش سرعت در پردازش مدل و

جدول ۱۲. بخشی از مجموعه داده شماره دو ساخت مدل دو انفیس (استفاده از متغیرهای مکانی و تقاضای سالانه)

...	۱۳۶	۲۷۵	۷۶۶	۴۵۵	۵۴	جمعیت ناحیه (نفر)
...	۲۳۸۸۵۲	۲۱۱۴۷۷	۲۰۵۴۵۶	۳۲۱۱۴۳	۶۵۶۴۲۲	مساحت ناحیه (مترمربع)
...	۲۱۸۷۷	۵۷۵۰۳	۸۶۷۰۹	۵۹۲۶۴	۶۹۸۹	مسکونی (مترمربع)
...	۲۸۴۳	۴۵۰۲	۳۹۳۵	۳۸۹۳۲	۶۸۵۲۰	تجاری (مترمربع)
...	۲۳۳۳۸	۷۴۱۰۳	۴۷۱۸۸	۵۴۷۰۵	۹۶۷۸	اقامتی (مترمربع)
...	۰	۲۷۴	۲۴۵۶	۱۲۴۱۶	۳۸۴۵۱	اداری (مترمربع)
...	۰	۰	۳۱۲۷	۱۵۳۲۸	۷۴۷۴	آموزشی (مترمربع)
...	۸۰۴	۳۵۵	۲۹۲	۷۶۳	۷۲۴۵	بهداشتی (مترمربع)
...	۰	۰	۰	۰	۰	تفریحی (مترمربع)
...	۲۵۲۷	۸۳۵۹	۴۹۲۳	۳۴۴۹۸	۱۵۲۸۵	مذهبی (مترمربع)
...	۰	۰	۰	۰	۲۲۰۶	نظامی (مترمربع)
...	۰	۰	۰	۰	۱۷۳۷۹	تجاری - اداری (مترمربع)
...	۳۹۹۳۰	۴۶۱۵۷	۲۴۱۷۵	۹۶۲۶۳	۳۴۱۹۱	تجاری - اقامتی (مترمربع)
...	۳۷۲۴	۷۴۰۶	۵۰۸۲	۶۶۴۰	۵۴۲۹	مسکونی - تجاری (مترمربع)
...	۵۷۳۰	۱۰۲۵۳	۴۷۷۲	۵۸۱۰	۱۲۱۱	سایر کاربری‌ها (مترمربع)
...	۱۲۷۲۵۴۵	۲۲۹۱۰۶	۱۳۰۰۷	۱۹۵۱۴۳۰	۶۲۱۸۵۱	تقاضا (نفر)

جدول ۱۳. بخشی از مجموعه داده شماره سه ساخت مدل سه انفیس (متغیرهای زمانی و مکانی مؤثر)

...	۱۳۶	۲۷۵	۷۶۶	۴۵۵	۵۴	جمعیت ناحیه (نفر)
...	۲۳۸۸۵۲	۲۱۱۴۷۷	۲۰۵۴۵۶	۳۲۱۱۴۳	۶۵۶۴۲۲	مساحت ناحیه (مترمربع)
...	۲۱۸۷۷	۵۷۵۰۳	۸۶۷۰۹	۵۹۲۶۴	۶۹۸۹	مسکونی (مترمربع)
...	۲۸۴۳	۴۵۰۲	۳۹۳۵	۳۸۹۳۲	۶۸۵۲۰	تجاری (مترمربع)
...	۰	۰	۳۱۲۷	۱۵۳۲۸	۷۴۷۴	آموزشی (مترمربع)
...	۳۷۲۴	۷۴۰۶	۵۰۸۲	۶۶۴۰	۵۴۲۹	مسکونی - تجاری (مترمربع)
...	۳۸	۳۸	۳۸	۳۸	۳۸	شاخص آلودگی هوا (AQI)
...	۳	۳	۳	۳	۳	کد مناسبت
...	۱۶۹۱	۱۰۰	۷	۶۸۷	۱۰۹۰	تقاضا (نفر)

### ۳-۵- نتایج مدل انفیس

در این تحقیق پیش‌بینی تقاضای سفر حمل‌ونقل عمومی هر یک از نواحی ترافیکی از طریق برنامه‌نویسی و ساخت مدل‌های انفیس در نرم‌افزار پایتون انجام شده است. پس از تکمیل فرآیند کدنویسی به تهیه چهار مدل برای هر یک از مجموعه داده‌ها با استفاده از یک پردازشگر ۷ هسته‌ای با رم ۱۶ گیگابایتی اقدام شد. در هر مدل از بیست درصد داده‌ها به‌عنوان داده‌های تست و از هشتاد درصد از آنها برای آموزش استفاده شد.

جدول ۱۴. بخشی از مجموعه داده شماره چهار ساخت مدل چهار انفیس (متغیرهای مکانی مؤثر)

...	۱۳۶	۲۷۵	۷۶۶	۴۵۵	۵۴	جمعیت ناحیه (نفر)
...	۲۳۸۸۵۲	۲۱۱۴۷۷	۲۰۵۴۵۶	۳۲۱۱۴۳	۶۵۶۴۲۲	مساحت ناحیه (مترمربع)
...	۲۱۸۷۷	۵۷۵۰۳	۸۶۷۰۹	۵۹۲۶۴	۶۹۸۹	مسکونی (مترمربع)
...	۲۸۴۳	۴۵۰۲	۳۹۳۵	۳۸۹۳۲	۶۸۵۲۰	تجاری (مترمربع)
...	۰	۰	۳۱۲۷	۱۵۳۲۸	۷۴۷۴	آموزشی (مترمربع)
...	۳۷۲۴	۷۴۰۶	۵۰۸۲	۶۶۴۰	۵۴۲۹	مسکونی - تجاری (مترمربع)
...	۱۲۷۲۵۴۵	۲۲۹۱۰۶	۱۳۰۰۷	۱۹۵۱۴۳۰	۶۲۱۸۵۱	تقاضا (نفر)

جدول ۱۵. بخشی از نتایج مدل شماره ۳ با استفاده از داده‌های تست

۱۸۵۶۴	۱۸۱۱۷	۹۹۵۸	۱۰۱۴۳	جمعیت ناحیه (نفر)
۶۷۶۲۰۲	۵۷۶۳۱۰	۵۵۹۸۱۵	۱۲۳۹۹۴۱	مساحت ناحیه (مترمربع)
۳۶۹۱۱۷	۲۵۲۲۵۹	۳۷۹۷۰۹	۱۲۲۵۳۹۹	مسکونی (مترمربع)
۶۳۲۲	۲۳۵۹	۶۴۸۸۲	۱۲۹۰۰۶	تجاری (مترمربع)
۱۱۱۲	۲۶۳۶۳	۷۷۳۹	۴۱۲۷	آموزشی (مترمربع)
۱۱۵۰۰۸	۸۲۹۰۸	۱۵۲۸۱۸	۹۶۱۷۱	مسکونی - تجاری (مترمربع)
۱۰۹	۷۶	۶۳	۵۳	شاخص آلودگی هوا (AQI)
۱	۱	۱	۱	کد مناسبت
۴۲۶۷	۱۵۴۲	۱۱۱۰	۱۱۰۸	تقاضا (نفر)
۲۹۱۶	۲۹۳۷	۱۳۰۳	۹۵۵	پیش‌بینی (نفر)

جدول ۱۶. بخشی از نتایج مدل شماره ۴ با استفاده از داده‌های تست

جمعیت ناحیه (نفر)	۴۱۹۸۴	۱۶۷۴۷	۵۴	۱۹۷۵۹
مساحت ناحیه (مترمربع)	۶۹۷۲۸۱۱	۷۰۴۴۱۱	۶۵۶۴۲۲	۱۸۳۶۴۷۸
مسکونی (مترمربع)	۱۷۸۵۳۴۶	۴۰۴۶۴۲	۶۹۸۹	۱۳۲۱۹۴۲
تجاری (مترمربع)	۶۲۷۳۵	۲۶۶۹۳	۶۸۵۲۰	۱۵۰۶۹
آموزشی (مترمربع)	۶۸۷۵۶	۵۵۰۰	۷۴۷۴	۱۳۳۴
مسکونی - تجاری (مترمربع)	۸۳۸۸۱۵	۱۳۹۱۸۵	۵۴۲۹	۲۲۳۶۱۰
تقاضا (نفر)	۱۷۸۱۴۴۰	۶۵۲۴۰۷	۶۲۱۸۵۱	۴۸۰۲۷۰
پیش‌بینی (نفر)	۲۱۷۳۷۵۷	۷۳۲۹۲۵	۱۱۵۹۷۶	۵۶۲۰۷۴

#### ۴- تحلیل نتایج و یافته‌ها

نشان‌دهنده بررسی جامع و پوشش حمل‌ونقل عمومی در کلیه مناطق شهری می‌باشد. در نهایت به منظور تولید ماتریس OD، مقادیر تولید و جذب هر ناحیه ترافیکی به صورت مجزا جمع می‌شوند که می‌تواند تأثیر خطاهای احتمالی برآورد مقصد هر ترانکس را کاهش دهد. ماتریس‌های حاصل از داده‌های ترانکس‌های من کارت بیانگر و معرف نتایج واقعی وضع موجود شبکه هستند و به‌طور مستقیم برآوردی از جمع سفر تک‌تک کاربران در بازه زمانی مدنظر را محاسبه می‌کنند. مقادیر تقاضا در این ماتریس‌ها و سایر متغیرهای مورد بررسی در این تحقیق زمینه ساخت چهار مدل انجیس برای پیش‌بینی تقاضای آتی را فراهم کردند. به منظور ارزیابی مدل‌ها، خطای آنها از روش میانگین مربعات اندازه‌گیری شد. جدول ۱۷ نتایج خطای محاسبه شده آنها را نمایش می‌دهد.

جدول ۱۷. میانگین مربع خطا برای هر یک از مدل‌های انجیس

مدل	خطای داده‌های آموزش	خطای داده‌های آزمایش
شماره ۱	۹/۶۰۳	۱۵۵/۰۰۹
شماره ۲	۴/۸۳۱	۴۸/۰۰۵
شماره ۳	۱/۶۵۲	۱/۹۰۹
شماره ۴	۰/۳۳۱	۱/۰۹۵

با توجه به خطاهای محاسبه شده مدل‌های ۳ و ۴ که در ساخت آنها از متغیرهای تأثیرگذار مدل‌های ۱ و ۲ استفاده شده است، مدل‌های بهتری می‌باشند. زمان تقریبی پردازش مدل ۱ برابر با ۱۱ ساعت، مدل ۲ برابر با ۲۰ دقیقه و این زمان برای مدل‌های ۳ و ۴ به ترتیب، ۶ ساعت و ۴ دقیقه است. همگی این موارد نشان می‌دهد که داده‌های تقاضا برای هر ناحیه ترافیکی

از ۲۶۱،۹۶۷،۰۷۵ ترانکس انجام شده در حمل‌ونقل عمومی شهر مشهد در سال ۱۳۹۸ تعداد ۲۹،۸۶۴،۲۴۶ ترانکس از فرآیند بررسی تخمین ایستگاه مقصد سفر حذف شدند. بیشتر آنها ترانکس‌های کارت‌های نقدی اتوبوس‌ران و ترانکس‌های QR در قطار شهری بودند. از تعداد ۲۳۲،۱۰۲،۸۲۹ ترانکس که توسط الگوریتم تخمین ایستگاه مقصد سفر بررسی شدند برای بیش از ۹۸ درصد آنها ایستگاه مقصد برآورد شد.

الگوریتم‌های فعلی زنجیره سفر می‌توانند حدود ۶۰ تا ۸۵ درصد مقصد سفرها را بدست آورند (Cheng et al., 2020). با این حال اعتبارسنجی نتایج در مقیاس وسیع دشوار و چالش برانگیز است. از این رو فقط تعدادی از محققان به این موضوع اقدام کرده‌اند. مطالعات مختلف از اعتبارسنجی در مراحل مختلف فرآیند تخمین ماتریس OD همچون تخمین ایستگاه مقصد و یا انتقال روز و زمان پیاده‌روی برای انتقال استفاده کرده‌اند. برآورد این ماتریس و دقت اعتبارسنجی به نوع داده‌های ورودی و فیلدهای موجود در داده‌های کارت هوشمند بستگی دارد. مدل زنجیره سفر بهبود یافته‌ای که توسط (Alsgers et al., 2016) ارائه شد، ۷۲،۴٪ دقت، و تخمین ایستگاه مقصد سفرهای بدون پیوند توسط (He and Trépanier, 2015)، ۱۱٪ بهبود بیشتر را نشان می‌دهند.

در این مطالعه ضمن استفاده از مدل زنجیره سفر بهبود یافته به‌عنوان الگوریتم پایه، ایستگاه مقصد سفرهای بدون پیوند نیز برآورد گردید و ترانکس‌های غیرقابل تشخیص نیز پس از محاسبه نسبت سهم هر مبدأ و مقصد از کل ترانکس‌های تعیین تکلیف شده در آن مسیر، تعیین وضعیت شدند. حجم داده استفاده شده، کل ترانکس‌های کارت‌های هوشمند در هر دو سیستم اتوبوس و قطار شهری در طول سال ۹۸ است که خود

نواحی ترافیکی بود که با تجمیع آنها ماتریس OD سالانه استنتاج شد. در مرحله بعد چهار مجموعه داده مختلف در مقیاس روزانه و سالانه، یکبار با تمامی متغیرها و بدون پیش داوری در خصوص میزان تأثیرگذاری آنها بر تقاضا و یکبار از طریق الگوریتم جنگل تصادفی و با انتخاب متغیرهای مؤثر ایجاد گردید. سپس با استفاده از یک سیستم استنتاج عصبی فازی تطبیقی (انفیس) مدل‌های پیش‌بینی مربوط به هر کدام توسعه داده شد. ارزیابی خطای مدل‌ها نشان می‌دهد در افق‌های بلند مدت سالانه، متغیرهای مؤثر شامل جمعیت ناحیه و مساحت بهره‌برداری کاربری‌های مسکونی، تجاری، آموزشی، و مسکونی - تجاری، مدل پیش‌بینی بهتری از تقاضای حمل‌ونقل عمومی را ارائه می‌کنند. همچنین در افق کوتاه مدت روزانه متغیرهای مؤثر شامل مناسبت‌های روزهای سال و شاخص کیفیت هوا به همراه متغیرهای مکانی مؤثر در افق یک ساله این تأثیرگذاری را در توسعه مدل پیش‌بینی دارند. در زمان صدور مجوز احداث انواع کاربری در سطح شهر مشهد توسط برنامه‌ریزان شهرسازی برآوردی از تقاضای سفر در دوره بهره‌برداری آنها وجود ندارد. مدل‌های پیش‌بینی ارائه شده در این تحقیق، پاسخ بخشی از این شکاف موجود بین دو حوزه شهرسازی و حمل‌ونقل می‌باشند؛ به طوری که برای یک ناحیه ترافیکی در افق بلند مدت با تغییر دادن مقادیر داده‌های ورودی متغیرهای مکانی مثل مساحت کاربری مسکونی، تجاری و غیره و یا در افق کوتاه مدت بیشتر با تغییر متغیرهای زمانی در کنار متغیرهای مکانی، می‌توان به استنباط تعداد تقاضای حمل‌ونقل عمومی در آن ناحیه دست پیدا کرد.

اعتبارسنجی نتایج برآورد ایستگاه مقصد از طریق نظرسنجی‌های سفرهای خانگی، استفاده از داده‌های مکانی و داده‌های کارت هوشمند در سایر سال‌ها برای بهبود دقت و قابلیت اطمینان مدل‌ها، به روزرسانی و بررسی تغییرات تقاضا با توجه به بهره‌برداری از خطوط جدید قطار شهری و نیز اصلاحات انجام شده در مسیرها و ایستگاه‌های اتوبوسرانی از جمله پیشنهادات مطالعات آتی در زمینه این پژوهش می‌باشند. این تحقیق یک گام اولیه در پیش‌بینی تقاضای سفر حمل‌ونقل عمومی با انفیس است. در پژوهش‌های آینده باید سایر الگوریتم‌های یادگیری ماشین، بررسی میزان تأثیر سایر متغیرها مثل کیفیت خدمات حمل‌ونقل عمومی و مبلغ کرایه، و همچنین علل اثربخشی بیشتر بعضی از ویژگی‌ها در نظر گرفته شوند.

بیشتر متأثر از تغییر سالیانه است تا روزانه؛ لذا مدل شماره ۴ چه به لحاظ میزان خطا و چه به لحاظ زمان محاسبات بهترین مدل از بین مدل‌های ساخته شده در این مطالعه می‌باشد.

اجرای الگوریتم جنگل تصادفی برای شناسایی مؤثرترین متغیرهای مستقل بر تقاضای حمل‌ونقل عمومی، نتایج Zhang and Xu (2022) and برای جمعیت و Wang and Zheng (2020) در مورد تأثیر کیفیت هوا به دلیل ممنوعیت‌های احتمالی تردد خودروهای شخصی، پرهیز از استفاده از دوچرخه و کاهش پیاده‌روی و یا تعطیلی مراکز آموزشی و ورزشی در شرایط بحرانی را تأیید می‌کند. درخصوص مناسبت‌ها و ایام خاص تقویم یافته‌های Cools et al. (2010), Wang et al. (2017b) و Yao et al. (2021) به دلیل بافت اجتماعی و زیارتی بودن شهر مشهد در این مطالعه تأیید می‌شوند. همچنین این الگوریتم با شناسایی اثرگذارترین انواع کاربری زمین نتایج Sarkar and Mallikarjuna (2013), Hu et al. (2016), Kim et al. (2018), Zhou et al. (2019), Cai et al. (2020) و Liu et al. (2021) را تأیید کرد. اما نتایج ما برخلاف یافته‌های Hofmann and O'Mahony (2017), Zhou et al. (2017), Gössling et al. (2005) و (2023) نشان می‌دهد که تقاضای روزانه حساسیت معناداری نسبت به نوسانات متغیرهای آب و هوایی ندارد. به نظر می‌رسد مهمترین علت این امر تعدد مسافران دائمی حمل‌ونقل عمومی مشهد که جایگزینی برای این روش سفر ندارند و ترجیح مسافری سایر روش‌ها مثل شخصی و تاکسی بر ادامه استفاده از آنها دانست.

## ۵- نتیجه‌گیری

این مقاله یک معماری انفیس در حوزه پیش‌بینی تقاضای حمل‌ونقل عمومی را ارائه می‌کند که با استفاده از داده‌های واقعی توسعه داده شده است. داده‌ها از سیستم پرداخت کرایه کارت هوشمند من‌کارت در شهر مشهد و همچنین اطلاعات کاربری‌ها و جمعیت در نواحی ترافیکی، مناسبت‌های روزهای سال، شرایط آب و هوایی و شاخص آلودگی هوای روزانه به دست آمده است. ابتدا به منظور برآورد ماتریس مبدأ - مقصد سفر در سیستم فقط ورودی حمل‌ونقل عمومی شهر مشهد از دو روش زنجیره سفر و تخمین تراکم هسته احتمالات مکانی و زمانی برای استنباط مقصد تراکنش‌ها استفاده شد. مهمترین نتیجه حاصل از این روش، ماتریس‌های OD روزانه برحسب

and applications. *Physics Reports*. doi:10.1016/j.physrep.2018.01.001

-Barry, J., Freimer, R., & Slavin, H. (2009). Use of Entry-Only Automatic Fare Collection Data to Estimate Linked Transit Trips in New York City. *Transportation Research Record Journal of the Transportation Research Board*, 2112(2112), 53-61. doi:10.3141/2112-07

-Barry, J., Newhouser, R., Rahbee, A., & Sayeda, S. (2002). Origin and Destination Estimation in New York City with Automated Fare System Data. *Transportation Research Record: Journal of the Transportation Research Board*, 1817(1), 183-187. doi:10.3141/1817-24

-Bonnell, P. (2021). Benefits of cellular telecommunication and smart card data for travel behavior analysis. *International Transport Forum Discussion Paper*, No. 2021/06. doi:10.1787/3884255b-en

-Bouteiller, C., & d'Arcier, B. F. (2015). How fare simulation tools in urban public transport can benefit from smart card data analysis? Retrieved from [http://web.mit.edu/cron/project/CUPUM2015/proceedings/Content/pss/199\\_bouteiller\\_h.pdf](http://web.mit.edu/cron/project/CUPUM2015/proceedings/Content/pss/199_bouteiller_h.pdf).

Briand, A. S., Côme, E., Trépanier, M., & Oukhellou, L. (2017). Analyzing year-to-year changes in public transport passenger behavior using smart card data. *Transportation Research Part C*, 79, 274-289. doi:10.1016/j.trc.2017.03.021

-Cai, Z., Li, T., Su, X., Guo, L., & Ding, Z. (2020). Research on Analysis Method of Characteristics Generation of Urban Rail Transit. *IEEE Transactions on Intelligent Transportation Systems*, 21(9), 3608-3620. doi:10.1109/TITS.2019.2929619

-Chanal, D., Steiner, N., Raffaele, P., Chamagne, D., & Marion-Péra, M.-C. (2021). Online Diagnosis of PEM Fuel Cell by Fuzzy C-Means Clustering. In S. Elias, *Reference Module in Earth Systems and Environmental Sciences*. doi:10.1016/B978-0-12-819723-3.00099-8

-Chen, E., Ye, Z., Wang, C., & Zhang, W. (2019). Discovering the spatio-temporal impacts of built environment on metro ridership using smart card data. *Cities*, 95, 102359. doi:10.1016/j.cities.2019.05.028

-Chen, R., Zhao, B., Wang, Y., Duan, Z., & Zhao, X. (2020). Multitask Learning and GCN-Based Taxi Demand Prediction for a Traffic Road Network. *Sensors (Basel)*, 20(13), 3776. doi:10.3390/s20133776

-Cheng, Z., Trepanier, M., & Sun, L. (2019). Inferring trip destinations in transit smart card data using a probabilistic topic model. Montreal, Quebec, Interuniversity Research Centre on Enterprise Networks, *Logistics and Transportation (CIRRELT)*.

-Cheng, Z., Trépanier, M., & Sun, L. (2020). Probabilistic model for destination inference

## ۶- مراجع

-افندی زاده، شهریار، احمدی نژاد، محمود، کلاتری، نوید و نجفی نژاد، علی رضا (۱۴۰۰). مدل‌سازی یکپارچه حمل‌ونقل و کاربری زمین با استفاده از روش‌های شبیه‌سازی (مطالعه موردی: شهر قم). *فصلنامه علمی پژوهشنامه حمل و نقل*، ۱۸(۱)، ۹۵-۱۱۲. doi:10.22034/TRI.2021.118089

-آمارنامه شهر مشهد. (۱۳۹۸). معاونت برنامه ریزی و توسعه سرمایه انسانی شهرداری مشهد.

-زارعی، حمید و ممدوحی، امیر رضا (۱۴۰۰). ارزیابی کمی عدالت در حمل و نقل همگانی چندوسیله‌ای شهری شامل مترو، اتوبوس و BRT (مطالعه موردی: کلان شهر تهران). *فصلنامه علمی پژوهشنامه حمل و نقل*، ۱۸(۲)، ۵۸-۴۵. doi:10.22034/TRI.2021.84259

-زرین مهر، امیرعلی و ملوک زاده، هانیه (۱۴۰۲). طراحی شبکه خطوط همگانی با استفاده از اولویت‌بندی حریصانه خطوط در شبکه‌های شطرنجی. *فصلنامه علمی پژوهشنامه حمل و نقل*، ۲۰(۲).

doi:10.22034/TRI.2022.318126.2988. ۱۶۷-۱۶۰

-سرشماری عمومی نفوس و مسکن. (۱۳۹۵).

-Alsger, A., Assemi, B., Mesbah, M., & Ferreira, L. (2016). Validating and improving public transport origin-destination estimation algorithm using smart card fare data. *Transportation Research Part C*, 68, 490-506. doi:10.1016/j.trc.2016.05.004

-Alsger, A., Mesbah, M., Ferreira, L., & Safi, H. (2015). Use of Smart Card Fare Data to Estimate Public Transport Origin-Destination Matrix. *Transportation Research Record Journal of the Transportation Research Board*, 2535(2535), 88-96. doi:10.3141/2535-10

-Alsger, A., Tavassoli, A., Mesbah, M., Ferreira, L., & Hickman, M. (2018). Public transport trip purpose inference using smart card fare data. *Transportation Research Part C*, 87, 123-137. doi:10.1016/j.trc.2017.12.016

-Assemi, B., Alsger, A., Moghaddam, M., Hickman, M., & Mesbah, M. (2020). Improving alighting stop inference accuracy in the trip chaining method using neural networks. *Public Transport*, 12, 89-121. doi:10.1007/s12469-019-00218-9

-Atsalakis, G. (2014). New technology product demand forecasting using a fuzzy inference system. *Operational Research an International Journal*, 14, 225-236. doi:10.1007/s12351-014-0160-y

-Baek, J., & Sohn, K. (2016). Deep-Learning Architectures to Forecast Bus Ridership at the Stop and Stop-To-Stop Levels for Dense and Crowded Bus Networks. *Applied Artificial Intelligence*, 30(9), 861-885. doi:10.1080/08839514.2016.1277291

-Barbosa, H., Barthelemy, M., Ghoshal, G., James, C., Lenormand, M., Louail, T., Tomasini, M. (2018). Human mobility: Models

- Transportation Research Part D: Transport and Environment*, 98, 102952. doi:10.1016/j.trd.2021.102952
- Gordon, J., Koutsopoulos, H., & Wilson, N. (2018). Estimation of population origin–interchange–destination flows on multimodal transit networks. *Transportation Research Part C*, 90, 350-365. doi:10.1016/j.trc.2018.03.007
- Gordon, J., Koutsopoulos, H., Wilson, N., & Attanucci, J. (2013). Automated Inference of Linked Transit Journeys in London Using Fare-Transaction and Vehicle Location Data. *Transportation Research Record Journal of the Transportation Research Board*, 2343(1), 17-24. doi:10.3141/2343-03
- Gössling, S., Neger, C., Steiger, R., & Bell, R. (2023). Weather, climate change, and transport: a review. *Natural Hazards*. doi:10.1007/s11069-023-06054-2
- Guzman, L., Beltran, C., Morales, R., & Sarmiento, O. (2023). Inequality in personal exposure to air pollution in transport microenvironments for commuters in Bogotá. *Case Studies on Transport Policy*, 11, 100963. doi:10.1016/j.cstp.2023.100963
- Hassanniakalager, A., Sermpinis, G., Stasinakis, C., & Verousis, T. (2020). A conditional fuzzy inference approach in forecasting. *European Journal of Operational Research*, 283(1), 196-216. doi:10.1016/j.ejor.2019.11.006
- He, L., & Trépanier, M. (2015). Estimating the Destination of Unlinked Trips in Transit Smart Card Fare Data. *Transportation Research Record Journal of the Transportation Research Board*, 2535, 97-104. doi:10.3141/2535-11
- Henke, I., Carteni, A., Moliterno, C., & Errico, A. (2020). Decision-Making in the Transport Sector: A Sustainable Evaluation Method for Road Infrastructure. *Sustainability*, 12(3), 764. doi:0.3390/su12030764
- Hofmann, M., & O'Mahony, M. (2005). The Impact of Adverse Weather Conditions on Urban Bus Performance Measures. *Intelligent Transportation Systems, 2005 IEEE*. doi:10.1109/ITSC.2005.1520087
- Hu, N., Legara, E. F., Lee, K. K., Hung, G. G., & Monterola, C. (2016). Impacts of land use and amenities on public transport use, urban planning and design. *Land Use Policy*, 57, 356-367. doi:10.1016/j.landusepol.2016.06.004
- Hussain, E., Bhaskar, A., & Chung, E. (2021). Transit OD matrix estimation using smartcard data: Recent developments and future research challenges. *Transportation Research Part C*, 125, 103044. doi:10.1016/j.trc.2021.103044
- Ingvardson, J., Nielsen, O., Raveau, S., & Nielsen, B. (2018). Passenger arrival and waiting time distributions dependent on train service frequency and station characteristics: A smart card data analysis. *Transportation Research Part C: Emerging Technologies*, 90, 292-306. doi:10.1016/j.trc.2018.03.006
- and travel pattern mining from smart card data. *Transportation*. doi:10.1007/s11116-020-10120-0
- Chopra, S., Dhiman, G., Sharma, A., Shabaz, D. M., Shukla, P., & Arora, M. (2021). Taxonomy of Adaptive Neuro-Fuzzy Inference System in Modern Engineering Sciences. *Computational Intelligence and Neuroscience*, 2021, 14. doi:10.1155/2021/6455592
- Chu, K. K., & Chapleau, R. (2010). Augmenting Transit Trip Characterization and Travel Behavior Comprehension. *Transportation Research Board*, 2183, 29-40. doi:10.3141/2183-04
- Chu, K., & Chapleau, R. (2008). Enriching Archived Smart Card Transaction Data for Transit Demand Modeling. *Transportation Research Record Journal of the Transportation Research Board*, 2063(1), 63-72. doi:10.3141/2063-08
- Cools, M., Moons, E., & Wets, G. (2010). Assessing the Impact of Public Holidays on Travel Time Expenditure. *Transportation Research Record Journal of the Transportation Research Board*, 2157(2157), 29-37. doi:10.3141/2157-04
- Dou, H., Liu, H., & Yang, X. (2007). OD Matrix Estimation Method of Public Transportation Flow Based on Passenger Boarding and Alighting. *Journal of Transport Information and Safety*, 25(2), 79-82. doi:10.3963/j.issn.1674-4861.2007.02.020
- Dou, M., He, T., Yin, H., Zhou, X., Chen, Z., & Luo, B. (2015). Predicting Passengers in Public Transportation Using Smart Card Data. *Databases Theory and Applications. ADC. 9093*, 28-40. Springer. doi:10.1007/978-3-319-19548-3\_3
- Edition, W. U. (2023, 08). <http://www.demographia.com/db-worldua.pdf>, 16. (DEMOGRAPHIA)
- El Mahrsi, M., Côme, E., Baro, J., & Oukhellou, L. (2014). Understanding Passenger Patterns in Public Transit through Smart Card and Socioeconomic Data: A Case Study in Rennes, France. *The 3rd International Workshop on Urban Computing (UrbComp 2014)*, New York, 9-10.
- Essien, A., Petrounias, I., Sampaio, P., & Sampaio, S. (2018). The Impact of Rainfall and Temperature on Peak and Off-Peak Urban Traffic. *29th International Conference, DEXA 2018*, Regensburg, Germany. doi:10.1007/978-3-319-98812-2\_36
- Ghalekhondabi, I., Ardjmand, E., Young, W., & Weckman, G. (2019). A review of demand forecasting models and methodological developments within tourism and passenger transportation industry. *Journal of Tourism Futures*, 5, 75-93. doi:10.1108/JTF-10-2018-0061
- González, L., Perdiguero, J., & Sanz, À. (2021). Impact of public transport strikes on traffic and pollution in the city of Barcelona.

- Liyanage, S., Abduljabbar, R., Dia, H., & Tsai, P.-W. (2022). AI-based neural network models for bus passenger demand forecasting using smart card data. *Journal of Urban Management*, *11*, 365-380. doi:10.1016/j.jum.2022.05.002
- Liyanage, S., Dia, H., Abduljabbar, R., & Asadi Bagloee, S. (2019). Flexible Mobility On-Demand: An Environmental Scan. *Sustainability*, *11*(5), 1262. doi:10.3390/su11051262
- Lu, J., Li, B., Li, H., & Al-Barakani, A. (2021). Expansion of city scale, traffic modes, traffic congestion, and air pollution. *Cities*, *108*, 102974. doi:10.1016/j.cities.2020.102974
- Ma, X.-l., Wang, Y.-h., Chen, F., & Liu, J.-f. (2012). Transit smart card data mining for passenger origin information extraction. *Journal of Zhejiang University Science C*, *13*(10), 750-760. doi:10.1631/jzus.C12a0049
- Ma, X.-l., Wu, Y.-J., Wang, Y., Chen, F., & Liu, J. (2013). Mining smart card data for transit riders' travel patterns. *Transportation Research Part C*, *36*, 1-12. doi:10.1016/j.trc.2013.07.010
- Medina, S. (2018). Inferring weekly primary activity patterns using public transport smart card data and a household travel survey. *Travel Behaviour and Society*, *12*, 93-101. doi:10.1016/j.tbs.2016.11.005
- Milenkovic, M., Svadlenka, L., Melichar, V., Bojovic, N., & Avramovic, Z. (2018). SARIMA modelling approach for railway passenger flow forecasting. *Transport*, *33*(5), 1113-1120. doi:10.3846/16484142.2016.1139623
- Miller, P., De Barros, A., Kattan, L., & Wirasinghe, S. (2016a). Analyzing the sustainability performance of public transit. *Transportation Research Part D: Transport and Environment*, *44*, 177-198. doi:10.1016/j.trd.2016.02.012
- Mitra, A., Jain, A., Kishore, A., & Kumar, P. (2022). A Comparative Study of Demand Forecasting Models for a Multi-Channel Retail Company: A Novel Hybrid Machine Learning Approach. *Operations Research Forum*, *3*(4), 2-22. doi:10.1007/s43069-022-00166-4
- Mohammed, M., & Oke, J. (2023). Origin-destination inference in public transportation systems: A comprehensive review. *International Journal of Transportation Science and Technology*, *12*(1), 315-328. doi:10.1016/j.ijst.2022.03.002
- Mosallanejad, M., Somenahalli, S., Vij, A., & Molls, D. (2019). An Approach to Distinguish Destination from the Alighting Stop based on Fare Data. *Journal of the Eastern Asia Society for Transportation Studies*, *13*, 1348-1360.
- Munizaga, M., & Palma, C. (2012). Estimation of disaggregate multimodal public transport Origin-Destination matrix from passive smartcard data from Santiago, Chile. *Transportation Research Part C: Emerging Technologies*, *24*, 9-18. doi:10.1016/j.trc.2012.01.007
- Jang, S. (1993). ANFIS: adaptive-network-based fuzzy inference system. *IEEE Transactions on Systems, Man, and Cybernetics*, *23*(3), 665-685. doi:10.1109/21.256541
- Joshi, S. (2020). Quantifying Impact of Weather Condition on Travel Time. School of City and Regional Planning. *Georgia Institute of Technology*.
- Jung, J., & Sohn, K. (2017). Deep-learning Architecture to Forecast Destinations of Bus Passengers from Entry-only Smart-card Data. *IET Intelligent Transport Systems*, *11*(6), 334-339. doi:10.1049/iet-its.2016.0276
- Kim, J., Corcoran, J., & Papamanolis, M. (2017). Route choice stickiness of public transport passengers: measuring habitual bus ridership behavior using smart card data. *Transportation Research Part C: Emerging Technologies*, *83*, 146-164. doi:10.1016/j.trc.2017.08.005
- Kim, M.-K., Kim, S., & Sohn, H.-G. (2018). Relationship between Spatio-Temporal Travel Patterns Derived from Smart-Card Data and Local Environmental Characteristics of Seoul, Korea. *Sustainability*, *10*(3), 787. doi:10.3390/su10030787
- Kumar, P., Khani, A., & He, Q. (2018). A robust method for estimating transit passenger trajectories using automated data. *Transportation Research Part C: Emerging Technologies*, *95*(2063), 731-747. doi:10.1016/j.trc.2018.08.006
- Kusakabe, T., & Asakura, Y. (2014). Behavioral data mining of transit smart card data: a data fusion approach. *Transportation Research Part C: Emerging Technologies*, *46*, 179-191. doi:10.1016/j.trc.2014.05.012
- Lee, S., & Hickman, M. (2014). Trip purpose inference using automated fare collection data. *Public Transport*, *6*, 1-20. doi:10.1007/s12469-013-0077-5
- Li, T., Sun, D., Jing, P., & Yang, K. (2018). Smart Card Data Mining of Public Transport Destination: A Literature Review. *Information*, *9*, 18. doi:10.3390/info9010018
- Liang, X., Wang, G., Min, M., Qi, Y., & Han, Z. (2019). A Deep Spatio-Temporal Fuzzy Neural Network for Passenger Demand Prediction. *Faculty Publications*, *135*. Retrieved from <https://digitalscholarship.tsu.edu/facpubs/135>
- Liu, W., Tan, Q., & Wu, W. (2020). Forecast and Early Warning of Regional Bus Passenger Flow Based on Machine Learning. *Mathematical Problems in Engineering*, *2020*. doi:10.1155/2020/6625435
- Liyanage, S., & Dia, H. (2020). An Agent-Based Simulation Approach for Evaluating the Performance of On-Demand Bus Services. *Sustainability*, *12*(10), 4117. doi:10.3390/su12104117

- Trépanier, M., Chapleau, R., & Tranchant, N. (2007). Individual Trip Destination Estimation in a Transit Smart Card Automated Fare Collection System. *Journal of Intelligent Transportation Systems: Technology, Planning and Operations*, 11(1), 1-14. **doi:10.1080/15472450601122256**
- Wang, B., & Zheng, S. (2020). Air pollution lowers travel demand in a consumer city. *Transportation Research Part D: Transport and Environment*, 89, 102616. **doi:10.1016/j.trd.2020.102616**
- Wang, B., Shao, C., & Ji, X. (2017b). Influencing Mechanism Analysis of Holiday Activity-Travel Patterns on Transportation Energy Consumption and Emissions in China. *Energies*, 10(7). **doi:10.3390/en10070897**
- Wang, J., Lingzhi Yang, Y., & Zhou, B. (2017a). The OD matrix estimation model of passenger flow based on the POI around the bus station. *Applied Decision Sciences*, 10, 118-130. **doi:10.1504/IJADS.2017.084308**
- Wang, W., Attanucci, J., & Wilson, N. (2011). Bus passenger origin-destination estimation and related analyses using automated data collection systems. *Journal of Public Transportation*, 14(4), 131-150. **Doi:10.5038/2375-0901.14.4.7**
- Wang, Y., Almeida, G. H., de Romph, E., & Timmermans, H. (2017c). Using metro smart card data to model location choice of after-work activities: An application to Shanghai. *Journal of Transport Geography*, 63, 40-47. **doi:10.1016/j.jtrangeo.2017.06.010**
- Wu, W., Jiang, S., Liu, R., Jin, W., & Ma, C. (2020). Economic development, demographic characteristics, road network and traffic accidents in Zhongshan, China: gradient boosting decision tree model. *Transportmetrica A Transport Science*, 16(3), 359-387. **doi:10.1080/23249935.2020.1711543**
- Wu, W., Xia, Y., & Jin, W. (2021). Predicting Bus Passenger Flow and Prioritizing Influential Factors Using Multi-Source Data: Scaled Stacking Gradient Boosting Decision Trees. *IEEE Transactions on Intelligent Transportation Systems*, 22(4), 2510-2523. **doi:10.1109/TITS.2020.3035647**
- Xiao, Y., Liu, J., Hu, Y., Wang, Y., Lai, K., & Wang, S. (2014). A neuro-fuzzy combination model based on singular spectrum analysis for air transport demand forecasting. *Journal of Air Transport Management*, 39, 1-11. **doi:10.1016/j.jairtraman.2014.03.004**
- Yao, E., Hong, J., Pan, L., Li, B., Yang, Y., & Guo, D. (2021). Forecasting Passenger Flow Distribution on Holidays for Urban Rail Transit Based on Destination Choice Behavior Analysis. *Journal of Advanced Transportation*, 2021. **doi:10.1155/2021/9922660**
- Yu, J., & Yang, X.-G. (2006). Estimating a Transit Route OD Matrix from On-Off Data through an Artificial Neural Network Method. Nagy, V., Horváth, B., & Horváth, R. (2017). Land-use zone estimation in public transport planning with data mining. *Transportation Research Procedia*, 27, 1050-1057. **doi:10.1016/j.trpro.2017.12.145**
- Nam, D., Kim, H., Cho, J., & Jayakrishnan, R. (2017). A Model Based on Deep Learning for Predicting Travel Mode Choice. *Transportation Research Board 96th Annual Meeting Transportation Research Board*, 17-06512. Washington, DC.
- Nassir, N., Khani, A., Lee, S., Noh, H., & Hickman, M. (2011). Transit Stop-Level Origin-Destination Estimation Through Use of Transit Schedule and Automated Data Collection System. *Transportation Research Record Journal of the Transportation Research Board*, 2263(1), 140-150. **doi:10.3141/2263-16**
- Oort, N., Brands, T., & de Romph, E. (2015). Short-Term Prediction of Ridership on Public Transport with Smart Card Data. *Transportation Research Record Journal of the Transportation Research Board*, 2535(1), 105-111. **doi:10.3141/2535-12**
- Öztayşi, B., & Bolturk, E. (2014). Fuzzy Methods for Demand Forecasting in Supply Chain Management. *Supply Chain Management under Fuzziness*, 313, 243-268. **doi:10.1007/978-3-642-53939-8\_11**
- Polson, N., & Sokolov, V. (2017). Deep learning for short-term traffic flow prediction. *Transportation Research Part C: Emerging Technologies*, 79, 1-17. **doi:10.1016/j.trc.2017.02.024**
- Razavi, S., Abbasian Najafabadi, T., & Mahmoodian, A. (2018). Remaining Useful Life Estimation Using ANFIS Algorithm: A Data-Driven Approach for Prognostics. *2018 Prognostics and System Health Management Conference (PHM-Chongqing)*, IEEE. 522-526. **doi:10.1109/PHM-Chongqing.2018.00095**
- Sarkar, P., & Mallikarjuna, C. (2013). Effect of Land Use on Travel Behaviour: A Case Study of Agartala City. *Procedia - Social and Behavioral Sciences*, 104, 533-542. **doi:10.1016/j.sbspro.2013.11.147**
- Tamblay, S., Galilea, P., Iglesias, P., Raveau, S., & Muñoz, J. C. (2016). A zonal inference model based on observed smart-card transactions for Santiago de Chile. *Transportation Research Part A: Policy and Practice*, 84, 44-54. **doi:10.1016/j.tra.2015.10.007**
- Tin Kam Ho. (1995). Random decision forests. *Proceedings of 3rd International Conference on Document Analysis and Recognition*, 1, pp. 278-282. Montreal, QC, Canada. **doi:10.1109/ICDAR.1995.598994**
- Tin Kam Ho. (1998). The random subspace method for constructing decision forests. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 20(8), 832-844. **doi:10.1109/34.709601**

- Zhao, Z., Koutsopoulos, H., & Zhao, J. (2018). Individual mobility prediction using transit smart card data. *Transportation Research Part C*, 89, 19-34. **doi:10.1016/j.trc.2018.01.022**
- Zhou, M., Wang, D., Li, Q., Yue, Y., Tu, W., & Cao, R. (2017). Impacts of weather on public transport ridership: Results from mining data from different sources. *Transportation Research Part C: Emerging Technologies*, 75, 17-29. **doi:10.1016/j.trc.2016.12.001**
- Zhou, X., Yang, X., & Wu, X. (2012). Origin-destination matrix estimation method of public transportation flow based on data from bus integrated-circuit cards. *J. Tongji Univ*, 40, 1027-1030. **Doi:10.3969/j.issn.0253-374x.2012.07.011**
- Zhou, Y., Qian, C., Xiao, H., Xin, J., Wei, Z., & Feng, Q. (2019). Coupling Research on Land Use and Travel Behaviors Along the Tram Based on Accessibility Measurement -Taking Nanjing Chilin Tram Line1 as an Example. *Sustainability*, 11(7), 2034. **Doi:10.3390/su11072034**
- Zhou, Y., Thill, J.-C., Xu, Y., & Fang, Z. (2021). Variability in individual home-work activity patterns. *Journal of Transport Geography*, 90, 102901. **doi:10.1016/j.jtrangeo.2020.102901**
- Applications of Advanced Technology in Transportation. The Ninth International Conference.* Chicago Illinois, United States. **doi:10.1061/40799(213)74**
- Zhang, M., Guo, Y., & Ma, Y. (2014). A Probability Model of Transit OD Distribution Based on the Allure of Bus Station. *Journal of Transport Information and Safety*(3), 57-61. **doi:10.3963/j.issn.1674-4861.2014.03.012**
- Zhang, Y., & Xu, D. (2022). The bus is arriving: Population growth and public transportation ridership in rural America. *Journal of Rural Studies*, 95, 467-474. **doi:10.1016/j.jrurstud.2022.09.018**
- Zhao, J., Rahbee, A., & Wilson, N. (2007). Estimating a Rail Passenger Trip Origin-Destination Matrix Using Automatic Data Collection Systems. *Computer-Aided Civil and Infrastructure Engineering*, 22(5), 376-387. **doi:10.1111/j.1467-8667.2007.00494.x**
- Zhao, J., Zhang, F., Tu, L., Xu, C., Shen, D., Tian, C., Li, Z. (2017). Estimation of Passenger Route Choice Pattern Using Smart Card Data for Complex Metro Systems. *IEEE Transactions on Intelligent Transportation Systems*, 18, 790-801. **doi:10.1109/TITS.2016.2587864**

# An ANFIS Model for Integrated Bus and Metro Travel Demand Prediction Using Automatic Data

*Shariat Radfar, Department of Industrial Engineering, Najafabad Branch,  
Islamic Azad University, Najafabad, Iran.*

*Hamidreza Koosha, Department of Industrial Engineering, Faculty of Engineering,  
Ferdowsi University of Mashhad, Iran.*

*Ali Gholami, Department of Civil Engineering, Faculty of Engineering, Golestan University,  
Gorgan, Iran.*

*Atefeh Amindoust, Department of Industrial Engineering, Najafabad Branch,  
Islamic Azad University, Najafabad, Iran.*

*E-mail: ali.gholami32@gmail.com*

Received: November 2024- Accepted: February 2025

## **ABSTRACT**

This research explores the use of machine learning to predict public transportation demand in Mashhad, Iran. Predicting demand is crucial for optimizing operational plans and ensuring efficient service delivery. The complex nature of travel patterns necessitates a model that can account for both spatial (geographic) and temporal (time-based) factors. The developed model utilizes various spatial and temporal data points, offering flexibility and adaptability. The study compares four models built with different datasets. The research employs Adaptive Neuro-Fuzzy Inference Systems (ANFIS) to identify distinct travel patterns within each time period across the city's 253 traffic zones. Additionally, the random forest algorithm is used to identify and select the features that affect the demand variable. The most effective model leverages spatial data on an annual scale, resulting in highly accurate predictions (training error: 0.331, testing error: 1.095). This model allows planners to estimate public transportation demand across different traffic zones, both daily and annually, in response to potential changes in urban land use.

**Keywords:** Destination Estimation, Public Transportation Travel Demand Prediction, Smart Card Transaction Data, Adaptive Neuro-Fuzzy Inference System, Spatiotemporal Variables