

تجزیه و تحلیل الگوهای زمانی - مکانی سفر حمل و نقل عمومی شهر مشهد

شریعت رادفر (دانشجوی دکتری، گروه مهندسی صنایع، واحد نجف آباد، دانشگاه آزاد اسلامی، نجف آباد، ایران)

shariatradfar@sin.iaun.ac.ir

<https://orcid.org/0009-0005-9599-8460>

حمیدرضا کوشا (دانشیار، گروه مهندسی صنایع، دانشکده مهندسی، دانشگاه فردوسی، مشهد، ایران)

Email: koosha@um.ac.ir

<https://orcid.org/0000-0002-5155-0040>

علی غلامی (استادیار، گروه مهندسی عمران، دانشکده مهندسی، دانشگاه گلستان، گرگان، ایران، نویسنده مسئول)

a.gholami@gu.ac.ir

<https://orcid.org/0000-0001-5888-6420>

عاطفه امین دوست (دانشیار، گروه مهندسی صنایع، واحد نجف آباد، دانشگاه آزاد اسلامی، نجف آباد، ایران)

a.amindoost@pin.iaun.ac.ir

<https://orcid.org/0000-0003-1791-4864>

چکیده

الگوهای سفر به طور قابل توجهی با ویژگی های خاصی مثل تنوع مکانی و زمانی مسافران، تراکم جمعیتی، کاربری زمین و دسترسی به وسایل نقلیه عمومی در ارتباط هستند و ایجاد پیوندهای معنی دار بین آنها مسأله مهمی می باشد. الگوی نحوه حرکت افراد و رفتارهای سفر آنها ارتباط تنگاتنگی با ساختارهای شهری دارد. در این مطالعه برای درک بهتر این الگوها در سفر حمل و نقل عمومی شهر مشهد، یک تحلیل خوشه بندی ناحیه محور بر پایه داده های کارت هوشمند انجام شده است. بر پایه تراکنش های سفر حمل و نقل عمومی از الگوریتم K-Means برای خوشه بندی نواحی در بازه های زمانی صبح، ظهر و عصر، و از الگوریتم Mean Shift برای خوشه بندی آنها بر پایه متغیرهای مکانی جمعیت و مساحت انواع کاربری ساخته شده در هر ناحیه، استفاده شده است. در خوشه بندی زمانی نواحی برای تراکنش های اتوبوس به ۲ و قطار شهری به ۷ خوشه؛ و در خوشه بندی مکانی نواحی به ۸ خوشه تقسیم شدند. تحلیل خوشه ها با اطلاعات جمعیتی و مساحت کاربری ساخته شده در هر ناحیه نشان داد که هر خوشه عملکرد خاص خود را دارد و یک دلیل واحد و مشخص برای میزان تراکنش همه نواحی نمی توان تعیین کرد. یافته های پژوهش توانستند ارتباط بین جمعیت و مساحت کاربری مسکونی ساخته شده را با تراکنش های صبح و یا کاربری های تجاری و آموزشی با تراکنش های ظهر و همچنین ارتباط بین تراکنش های نواحی حاشیه ای با مناطق مسکونی نزدیک خارج از شهر را در بازه های زمانی تصدیق نمایند. نتایج این مطالعه در طراحی و توسعه سیاست های زمین و حمل و نقل برای تصمیم گیرندگان و برنامه ریزان این حوزه ها با اهمیت می باشد. کلمات کلیدی: الگوهای زمانی و مکانی، خوشه بندی نواحی ترافیکی، داده های کارت های هوشمند، کاربری ساخته شده

درک الگوها و رفتارهای سفر افراد در پرداختن به عدالت اجتماعی و پشتیبانی مؤثر از برنامه‌ریزی و پیش‌بینی جریان ترافیک شهری و همچنین بهره‌برداری از سیستم‌های حمل‌ونقل عمومی مهم است (لین و همکاران^۱، ۲۰۲۰؛ تانگ و همکاران^۲، ۲۰۲۰؛ ژانگ و همکاران^۳، ۲۰۲۱). الگوهای سفر افراد یکنواخت نمی‌باشند. این الگوها معمولاً با ویژگی‌های خاصی مثل تنوع مکانی و زمانی سفر، تراکم جمعیتی، کاربری زمین و دسترسی به وسایل نقلیه عمومی مشخص می‌شوند. با استفاده از این ویژگی‌ها می‌توان تجزیه و تحلیل‌هایی همچون شناسایی و خوشه‌بندی مسافر و تکامل الگوهای حرکت را انجام داد (چنگ و همکاران^۴، ۲۰۲۰؛ لی و همکاران^۵، ۲۰۲۱). الگوی نحوه حرکت مردم و رفتارهای سفر آنها در یک شهر ارتباط تنگاتنگی با ساختارهای شهری دارد (لی و همکاران^۶، ۲۰۱۸؛ کیم و همکاران^۷، ۲۰۱۸). توزیع متناسب کاربری‌ها باعث استفاده کمتر از خودرو برای حمل‌ونقل شده و می‌تواند الگوهای تحرک مسافران شهری را تغییر دهد. بنابراین، یک روش مؤثر پیش‌بینی الگوی تحرک برای ارزیابی اثر طولانی مدت تغییر ساختار کاربری اراضی یک منطقه مورد نیاز است (خاکپور و شاداب‌مهر، ۱۳۹۲؛ کای و همکاران^۸، ۲۰۱۸).

داده‌های کارت هوشمند سیستم حمل‌ونقل عمومی بینش‌هایی را در مورد پویایی‌های شهری و درک الگوهای سفر ایجاد کرده که نقشی اساسی در برنامه‌ریزی در این حوزه را ایفا می‌کنند (ما و همکاران^۹، ۲۰۱۳؛ کیم و همکاران^{۱۰}، ۲۰۱۸؛ لین و همکاران^{۱۱}، ۲۰۲۰). از مزایای مهم این کارت‌ها بهبود کیفیت داده‌های سفر با حجم نمونه زیاد است که به معنای پوشش مکانی و زمانی بهتر می‌باشد (چن و همکاران^{۱۲}، ۲۰۱۹). با توجه به برخی از ویژگی‌ها و نواقص داده‌های کارت هوشمند مثل نبودن اطلاعات شخصی مسافران و هدف سفر آنها، تعدادی از محققین داده‌های کارت هوشمند را با داده‌های منابع دیگر مانند داده‌های نظرسنجی سفر، ویژگی‌های کاربری زمین، ویژگی‌های جمعیتی، شاخص‌های اجتماعی - اقتصادی و عواملی مانند آب و هوا ترکیب کرده‌اند تا الگوهای سفر مسافران حمل‌ونقل عمومی را بررسی کنند. تلفیق مزایای داده‌های کارت هوشمند با سایر داده‌ها، دقت و تفسیرپذیری مدل‌ها را بهبود می‌بخشد (ناگی و همکاران^{۱۱}، ۲۰۱۷؛ لیو و چنگ^{۱۲}، ۲۰۱۸؛ لین و همکاران^{۱۳}، ۲۰۲۰؛ ماریناس-کولادو و همکاران^{۱۳}، ۲۰۲۲).

-
- 1 Lin et al
 - 2 Tang et al
 - 3 Zhang et al
 - 4 Cheng et al.
 - 5 Li et al.
 - 6 Li et al.
 - 7 Kim et al.
 - 8 Qi et al.
 - 9 Ma et al.
 - 10 Chen et al.
 - 11 Nagy et al.
 - 12 Liu & Cheng
 - 13 Mariñas-Collado et al.

دو مفهوم پر کاربرد برای انجام تجزیه و تحلیل داده‌ها و حل مسائل یادگیری ماشینی و داده کاوی مفاهیم طبقه‌بندی و خوشه‌بندی هستند. خوشه‌بندی در خدمات شخصی مسافر، بهبود مدل‌های تقاضا، روش‌های استخراج اطلاعات در الگوهای سفر و سایر کاربردهای مختلف در حمل و نقل مهم است (بریاند و همکاران^۱، ۲۰۱۶؛ چنگ و همکاران، ۲۰۲۰). مطالعات متعددی در مورد استفاده از داده‌های کارت هوشمند در الگوهای سفر شهری انجام شده است. یک دیدگاه عملیاتی ایستگاه محور و یک دیدگاه متمرکز بر مسافر برای خوشه‌بندی روی الگوهای تحرک در سیستم‌های حمل و نقل عمومی بر اساس داده‌های کارت هوشمند مورد استفاده قرار می‌گیرند (المهرسی و همکاران^۲، ۲۰۱۷).

برای کشف رفتار مسافران و الگوهای زمانی و مکانی سفر، مرنسی و همکاران^۳ (۲۰۰۶)، چن و همکاران^۴ (۲۰۰۹)، ما و همکاران^۵ (۲۰۱۳) ژائو و همکاران^۶ (۲۰۱۴)، پوسوین و همکاران^۷ (۲۰۱۴)، ژونگ و همکاران^۸ (۲۰۱۵)، جولیت لنگلوئیس و همکاران^۹ (۲۰۱۶)، کیم و همکاران^{۱۰} (۲۰۱۷)، دشاینتر و همکاران^{۱۱} (۲۰۱۹) و ژانگ و همکاران^{۱۲} (۲۰۲۱) در مطالعات خود از روش خوشه‌بندی K-Means و کیو و همکاران^{۱۳} (۲۰۱۵)، ما و همکاران^{۱۴} (۲۰۱۷)، مدینا^{۱۵} (۲۰۱۸) از روش DBSCAN، استفاده کرده‌اند. همچنین برای این منظور لانگ و تیل^{۱۶} (۲۰۱۵) روش درخت تصمیم، بریاند و همکاران (۲۰۱۶ و ۲۰۱۷) و یو و همکاران^{۱۷} (۲۰۱۷) روش مخلوط گاوسی، لین و همکاران^{۱۸} (۲۰۲۰) و لیو و همکاران^{۱۹} (۲۰۲۰) روش تخصیص پنهان دیریکله را در خوشه‌بندی و استخراج الگوها در اتوبوس و یا مترو به کار گرفته‌اند. ولنگ و همکاران^{۲۰} (۲۰۱۵) در متروی هنگ‌کنگ، گونگ و همکاران^{۲۱} (۲۰۱۷) در متروی شنزن چین، هاریناس-کولادو و همکاران^{۲۲} (۲۰۲۲) در اتوبوس‌رانی سالامانکا، الگوریتم خوشه‌بندی سلسله مراتبی را برای تجزیه و تحلیل الگوهای سفر انتخاب کرده‌اند. K-

-
- 1 Briand et al.
 - 2 El Mahrssi et al.
 - 3 Morency et al.
 - 4 Chen et al.
 - 5 Ma et al.
 - 6 Zhao et al.
 - 7 Poussevin et al.
 - 8 Zhong et al.
 - 9 Goulet-Langlois et al.
 - 10 Kim et al.
 - 11 Deschaintres et al.
 - 12 Zhang et al.
 - 13 Kieu et al.
 - 14 Ma et al.
 - 15 Medina
 - 16 Long & Thill
 - 17 Yu et al.
 - 18 Lin et al.
 - 19 Liu et al.
 - 20 Wang et al.
 - 21 Gong et al.
 - 22 Mariñas-Collado et al.

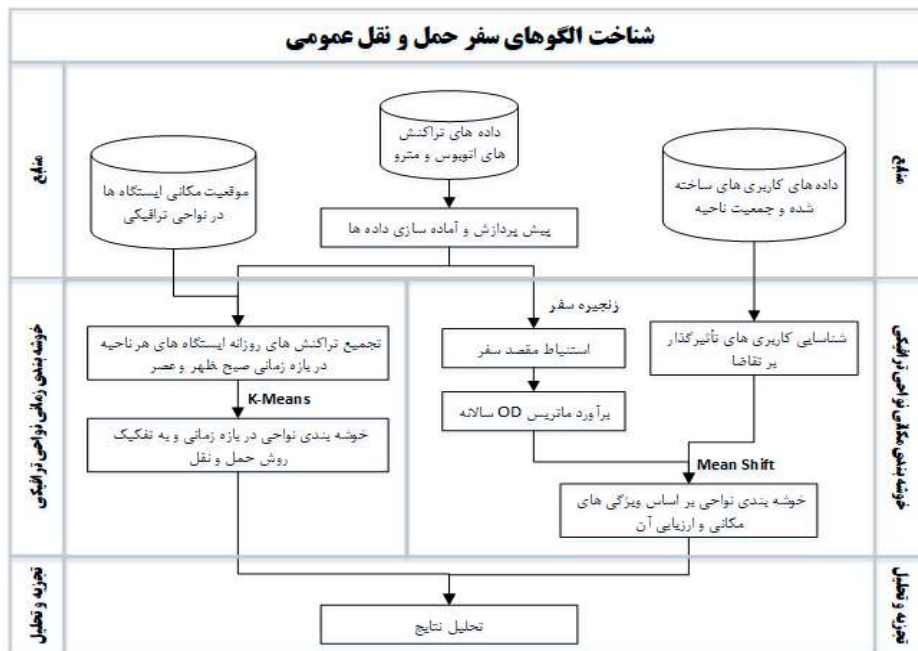
Spectral Centroid (کیم و همکاران، ۲۰۱۸)، K-Medoids (ژائو و همکاران^۱، ۲۰۱۹)، تجزیه NCP (تانگ و همکاران^۲، ۲۰۲۰) و تجزیه تاکر^۳ (فروتوس-برنال و همکاران^۳، ۲۰۲۲) از جمله روش‌های دیگر در تحقیقات این حوزه هستند. در مطالعات دیگری برای پیش‌بینی و شناسایی الگوهای سفر منطقه‌ای مسافران، کای و همکاران (۲۰۱۸) در پکن یک روش چند مرحله‌ای یکپارچه‌سازی خوشه‌بندی C-means فازی درونی-محدود، فاکتورهای تنسور غیرمنفی و شبکه عصبی مصنوعی را پیشنهاد و اجرا کردند. همچنین وانگ و همکاران^۴ (۲۰۲۰) و لی و همکاران^۵ (۲۰۲۱) در سیدنی از شبکه‌های عصبی و یادگیری عمیق برای این منظور استفاده کردند. در مطالعه دیگری ژو و همکاران^۶ (۲۰۱۷) روشی برای استنباط عملکرد مناطق شهری ووهان چین در سطح ایستگاه‌های مترو با توجه به الگوهای فعالیت‌های ماندگار به‌دست آمده از DBSCAN و K-Means ارائه می‌کنند. فاروقی و همکاران^۷ (۲۰۱۸)، شباهت‌های بین فعالیت‌های مسافران را از طریق درخت تصمیم احتمالی در سیستم اتوبوس و متروی بریزین کوئینزلند در استرالیا اندازه گرفتند. ال‌مهرسی و همکاران^۸ (۲۰۱۴) برای بررسی توزیع ویژگی‌های اقتصادی-اجتماعی بر روی خوشه‌های زمانی در حمل‌ونقل عمومی رنس فرانسه با مدل unigram پرداختند و توانستند گروه‌های مختلف شغلی را که در ساعات مختلف روز بین خانه و محل کار رفت و آمد می‌کنند شناسایی نمایند. ژائو و همکاران^۹ (۲۰۱۸) نیز پیش‌بینی انجام سفر و ویژگی‌های آن را در لندن با مدل n-gram انجام دادند. دینگ و همکاران^{۱۰} (۲۰۱۹) از طریق درختان تصمیم تقویت‌کننده گرادیان، اثرات غیرخطی ویژگی‌های محیط ساخته شده در اطراف ایستگاه‌های مترو بر پیش‌بینی تعداد مسافران را بررسی کردند. هوانگ و همکاران^{۱۱} (۲۰۲۰) از روش DBSCAN در به‌دست آوردن زمان رسیدن اتوبوس در سوژو در چین استفاده کردند. ژو و همکاران^{۱۲} (۲۰۲۱) در متروی ووهان با استفاده از الگوریتم جنگل تصادفی بررسی تغییرات در الگوهای فعالیت فردی در خلنه و محل کار را انجام دادند. در مطالعه دیگری ژائو و همکاران^{۱۳} (۲۰۲۱) با استفاده از K-Means++ ویژگی‌های سفر مسافران شامل زمان سفر، تقاضای سفر و اهداف سفر را در سفر با اتوبوس و مترو در پکن از طریق یک سیستم تحلیل بصری برای شناسایی همبستگی‌های تحرک مسافران بر پایه علاقه‌مندی آنها به صورت گروهی و فردی ارائه می‌دهند.

-
- 1 Zhao et al.
 - 2 Tang et al.
 - 3 Frutos-Bernal et al.
 - 4 Wang et al.
 - 5 Li et al.
 - 6 Zhou et al.
 - 7 Faruqi et al.
 - 8 El Mahrssi et al.
 - 9 Zhao et al.
 - 10 Ding et al.
 - 11 Huang et al.
 - 12 Zhou et al.
 - 13 Zhao et al.

اهداف اصلی این تحقیق خوشه‌بندی نواحی ترافیکی برای یافتن الگوهای بین تولید سفر با ویژگی‌های زمانی و نیز تقاضای سفر با ویژگی‌های مکانی (مساحت کاربری‌های ساخته شده و جمعیت در ناحیه)؛ به‌منظور انجام برنامه‌ریزی‌های کلان شهری و برنامه‌ریزی‌های عملیاتی حمل‌ونقل عمومی در شهر مشهد که از تراکم جمعیتی بالایی برخوردار است، می‌باشد. برای انجام این کار از داده‌های ماتریس مبدأ - مقصد سالانه حمل‌ونقل عمومی مشهد استفاده خواهد شد. آنچه باعث تمایز این پژوهش نسبت به سایر تحقیقات در این حوزه می‌باشد و از جنبه نوآورانه برای آن حائز اهمیت، این است که ضمن استفاده از داده‌های تراکنش‌های یک‌ساله کرایه، از طریق آنها مقصد سفر برای اولین بار در شهر مشهد و با این حجم داده به روش زنجیره سفر استنباط و ماتریس OD حمل‌ونقل عمومی به‌عنوان یکی از ورودی‌های فرآیند خوشه‌بندی تولید می‌شود. همچنین در این تحقیق به‌جای خوشه‌بندی ایستگاه‌ها و در نظر گرفتن ویژگی‌های مکانی اطراف آنها، خوشه‌بندی در نواحی ترافیکی انجام می‌پذیرد. این کار شناخت از الگوهای زمانی و مکانی را از سطح ایستگاه به کل شبکه و سطح شهر توسعه می‌دهد. الگوریتم‌هایی که برای خوشه‌بندی نواحی ترافیکی و رسیدن به اهداف این مطالعه به‌کار گرفته شده‌اند، Mean Shift و K-Means می‌باشند. در این مطالعه از داده‌های مکانی جمعیت و مساحت انواع کاربری ساخته شده مثل مسکونی، تجاری و آموزشی در هر ناحیه ترافیکی و همچنین بازه‌های زمانی صبح، ظهر و عصر سفر حمل‌ونقل عمومی در خوشه‌بندی استفاده می‌گردد. نتایج این مطالعه در موضوعاتی مثل تخصیص تعداد ناوگان، توزیع بهتر انواع کاربری‌ها در نواحی مختلف و جلوگیری از سفرهای غیرضروری تأثیرگذار خواهد بود که در نهایت منجر به بهبود عملکرد حمل‌ونقل عمومی می‌شود.

۲. روش‌شناسی

هدف این بخش، شبیه‌سازی رفتار سفر کاربران حمل‌ونقل عمومی از طریق تکنیک‌های طبقه‌بندی و خوشه‌بندی داده‌ها در دو بعد زمانی و مکانی است که می‌تولند به‌طور همزمان در انجام برنامه‌ریزی‌های کلان شهری و تخصیص انواع کاربری‌ها به مناطق مختلف و همچنین در برنامه‌ریزی‌های عملیاتی حمل‌ونقلی از قبیل تخصیص ناوگان و یا تعیین سر فاصله زمانی آن استفاده شود. شکل ۱ نمودار چارچوب کلی این تحقیق را در ادامه کار نشان می‌دهد.



شکل ۱. نمودار چارچوب تحقیق

۱.۲. توصیف محیط پژوهش

مشهد شهری با بیش از ۳ میلیون نفر جمعیت ساکن و حدود ۲۵ میلیون مسافر در سال یکی از بزرگترین جمعیت‌های شهری در ایران می‌باشد. براساس تقسیمات ترافیکی این شهر به ۲۵۳ ناحیه ترافیکی تقسیم شده است (سقایی و جوانبخت قهفرخی، ۱۳۹۲؛ سرشماری عمومی نفوس و مسکن، ۱۳۹۵؛ آمارنامه شهر مشهد، ۱۳۹۸). جدول ۱ خلاصه اطلاعات حمل و نقل عمومی شهر مشهد در سال ۱۳۹۸ و شکل ۲ نقشه ایستگاه‌ها خطوط اتوبوسرانی و مترو در این شهر را نشان می‌دهد.

جدول ۱. خلاصه اطلاعات حمل و نقل عمومی شهر مشهد

عنوان	اتوبوس رانی	قطار شهری
تعداد خطوط فعال	۱۳۶	۲
تعداد ایستگاه‌های فعال	۳۵۱۱	۳۳
طول خطوط فعال (کیلومتر)	۲۱۶۲	۴۳/۵
تعداد ناوگان	۲۲۵۰	-
تعداد من کارت فعال در سال ۹۸	۲,۳۱۵,۰۱۷	
تعداد تراکنش در سال ۹۸	۲۶۱,۹۶۷,۰۷۵	



شکل ۲. نقشه ایستگاه‌ها و خطوط اتوبوسرانی و مترو

۲.۲. روش‌شناسی مدل خوشه‌بندی نواحی ترافیکی براساس داده‌های زمانی و تعداد تراکنش‌ها

بررسی وضعیت نواحی ترافیکی شهر بر مبنای تعداد تراکنش‌های صورت گرفته در بازه‌های مختلف زمانی می‌تواند در ارائه یک وضعیت کلی از شبکه به تصمیم‌گیران حمل‌ونقلی مؤثر باشد. به همین دلیل در این مطالعه با توجه به داده‌های تراکنش‌ها به ارائه وضعیت هر یک از نواحی پرداخته می‌شود.

به‌منظور خوشه‌بندی نواحی ترافیکی بر اساس داده‌های زمانی و تعداد تراکنش‌ها، در این بخش از الگوریتم K-Means (مک‌کوین^۱، ۱۹۶۷؛ کائو و همکاران^۲، ۲۰۰۹) که شناخته شده‌ترین الگوریتم مبتنی بر فاصله می‌باشد (التیبی و آشور^۳، ۲۰۱۱) استفاده شده است. در این مطالعه از دو روش ارزیابی آرنج^۴ (تورندایک^۵، ۱۹۵۳؛ شی و همکاران^۶، ۲۰۲۱) و امتیاز نیم‌رخ^۷ (روسیو^۸، ۱۹۸۷؛ شاهپور و نیکلاس^۹، ۲۰۲۰) برای بررسی بهترین تعداد خوشه‌بندی و در جهت بهبود و بهینه‌سازی مجموع مربعات فواصل درون خوشه‌ای و تفکیک‌پذیری خوشه‌ها استفاده می‌شود. داده‌های مورد استفاده در این بخش از سامانه جمع‌آوری کرایه اتوبوس‌رانی و قطارشهری و نیز اطلاعات ناحیه ترافیکی استقرار ایستگاه‌های مختلف ریلی و اتوبوس هستند. به‌منظور پیش‌پردازش داده‌های تراکنش‌ها بجز زمان و ایستگاه تراکنش سایر ویژگی‌ها که در فرآیند خوشه‌بندی کاربرد ندارند حذف شدند. سپس

-
- 1 MacQueen
 - 2 Cao et al.
 - 3 Eltibi & Ashour
 - 4 Elbow Method
 - 5 Thorndike
 - 6 Shi et al.
 - 7 Silhouette Score
 - 8 Rousseeuw
 - 9 Shahapure & Nicholas

تراکنش‌های پرداخت نقدی که توسط اتوبوس‌ران انجام شده است، حذف شدند. علت این امر جایگزینی این تراکنش‌ها با پرداخت نقدی مسافر و عدم اطلاع از زمان و مکان واقعی سوار شدن او می‌باشد. در مرحله بعد این داده‌ها به تفکیک اتوبوس‌رانی و قطارشهری و در دو جدول مجزا، بر مبنای زمان وقوع تراکنش از کم به زیاد مرتب شده و شماره ناحیه‌ای که ایستگاه محل انجام تراکنش در آن اتفاق افتاده است، تعیین گردید. سپس به تجمیع تعداد تراکنش‌های هر ایستگاه به تفکیک بازه‌های یک ساعته در روزهای مختلف اقدام شد. در ادامه تعداد تراکنش‌های هر ایستگاه با ایستگاه‌های دیگری که در یک ناحیه ترافیکی قرار دارند، با در نظر گرفتن بازه‌های زمانی یک ساعته تجمیع می‌شوند. در پایان مقادیر تجمعی هر ناحیه در بازه‌های زمانی صبح، ظهر و عصر^۱ جایگزین بازه‌های زمانی یک ساعته شده و خوشه‌بندی در این سه گروه زمانی و به تفکیک اتوبوس و مترو انجام شد.

۳.۲. روش‌شناسی مدل خوشه‌بندی نواحی ترافیکی براساس داده‌های مکانی و تعداد تقاضا

نواحی ترافیکی دارای مساحت‌های ساخته شده مختلفی از انواع کاربری شهری و تعداد جمعیت ساکن در این نواحی می‌باشند. به‌طوری‌که این ویژگی‌های مکانی در میزان تقاضای سفر حمل‌ونقل عمومی و در نتیجه برنامه‌ریزی‌های آن از جمله تخصیص تعداد ناوگان تأثیرگذار هستند. همچنین این اطلاعات به توزیع بهتر انواع کاربری‌ها در نواحی مختلف و جلوگیری از سفرهای غیرضروری کمک می‌کند.

الگوریتم بکار گرفته شده در خوشه‌بندی نواحی ترافیکی Mean Shift می‌باشد، که یک الگوریتم خوشه‌بندی بر پایه تخمین چگالی هسته است (جین و هان^۲، ۲۰۱۷). این روش به اطلاعاتی در مورد تعداد خوشه‌ها، تعداد نقاط در هر گروه و شکل توزیع نیاز ندارد (ژو و همکاران^۳، ۲۰۲۲) و پهنای باند^۴ تنها پارامتری است که باید تنظیم شود (دمیروویچ^۵، ۲۰۱۹). پارامتر پهنای باند نشان‌دهنده شعاع جستجو و در نتیجه حداکثر فاصله بین مراکز خوشه و نقاط داده اطراف است (نتزر و همکاران^۶، ۲۰۲۰). به‌منظور ارزیابی و تأیید نتایج خوشه‌بندی از امتیاز نیم‌رخ و شاخص دیویس-بولدین (دیویس و بولدین^۷، ۱۹۷۹؛ راس و همکاران^۸، ۲۰۲۳) برای اندازه‌گیری کیفیت و تفکیک‌پذیری خوشه‌ها استفاده می‌شود.

۱ مبنای تقسیم‌بندی انجام شده سه گروه صبح، ظهر و عصر، مطالعه "تعیین سیاست‌های اخذ کرایه حمل و نقل عمومی شهر مشهد" که توسط سازمان حمل‌ونقل و ترافیک شهرداری مشهد صورت پذیرفته می‌باشد. براساس این مطالعه بازه‌های زمانی سفر حمل‌ونقل عمومی در سه گروه فوق محاسبه شده است؛ به‌طوری‌که بازه زمانی صبح از ساعت ۰ تا ساعت ۱۱، بازه زمانی ظهر از ساعت ۱۱ تا ۱۷ و بازه زمانی عصر از ساعت ۱۷ تا ۲۴ در نظر گرفته شده است.

2 Jin & Han

3 Zhu et al.

4 Band Width

5 Demirović

6 Netzer et al.

7 Davies & Bouldin

8 Ros et al.

سیستم جمع‌آوری کرایه مشهد از نوع فقط ورودی است و مسافران در زمان سوار شدن کرایه خود را پرداخت می‌کنند، لذا داده‌های تقاضای مقصد در آن ثبت نمی‌شود. برای رفع کمبود اطلاعات در این زمینه با کمک داده‌های یک‌ساله AFC موجود در سال ۱۳۹۸، استنباط مقصد به روش زنجیره سفر (نصیر و همکاران^۱، ۲۰۱۱؛ هی و ترپانیر^۲، ۲۰۱۵؛ عاصمی و همکاران^۳، ۲۰۲۰) انجام شد. برآورد مقصد امکان تولید ماتریس‌های مبدأ - مقصد روزانه و سپس سالانه حمل‌ونقل عمومی را بر پایه نواحی ترافیکی ایجاد می‌کند. از این نتایج به‌عنوان داده‌های تقاضا استفاده شد. 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، کاهش ترافیک و دستیابی به توسعه پایدار می‌شود. لذا حمل‌ونقل یکی از عوامل مهم در پایداری شهری است و هماهنگی بین برنامه‌ریزی کاربری زمین و سیستم حمل‌ونقل می‌تواند به پایداری در شهرها کمک کند. همچنین الگوی سفر ساکنان و تقاضا برای حمل‌ونقل نیز در چیدمان مکانی شهر، قیمت زمین و توزیع امکانات در یک منطقه تأثیرگذار خواهد بود (فاطمی‌پور و همکاران^۴، ۱۴۰۲؛ سارکار و ملیکارجونان^۵، ۲۰۱۳؛ هو و همکاران^۶، ۲۰۱۶؛ کیم و همکاران^۷، ۲۰۱۸؛ ژو و همکاران^۸، ۲۰۱۹؛ سای و همکاران^۹، ۲۰۲۰). از سویی دیگر تغییرات جمعیتی نیز موجب ایجاد تغییر در تقاضای حمل‌ونقل عمومی می‌شود. رشد جمعیت بر افزایش تقاضا و تغییر الگوهای رفت‌وآمد حمل‌ونقل عمومی تأثیر می‌گذارد. به‌طوری‌که رشد جمعیت منجر به نسبت بیشتری از مسافرانی می‌شود که از حمل‌ونقل عمومی استفاده می‌کنند و باعث افزایش نرخ سفر در آن می‌شود (ژانگ و زو^{۱۰}، ۲۰۲۲).

در این پژوهش اطلاعات کاربری‌های شهری با توجه به ضوابط طبقه‌بندی کاربری اراضی و با در نظر داشتن کاربری‌های موجود در سطح شهر در سیزده گروه دسته‌بندی شدند. در گام بعدی اطلاعات مربوط به تعداد و مساحت عرصه و اعیان و نیز جمعیت در هر ناحیه ترافیکی استخراج و جدول داده‌های مکانی تهیه شد. در این تحقیق از مساحت کاربری که در عرصه زمین ساخته شده استفاده می‌گردد و ویژگی مساحت عرصه به دلیل وجود زمین‌های ساخته نشده و یا عدم در نظر گرفتن کاربری‌های ترکیبی، در مدل استفاده نشدند. سپس برای

1 Nassir et al.

2 He & Trépanier

3 Assemi et al.

4 Sarkar & Mallikarjuna

5 Hu et al.

6 Zhou et al.

7 Cai et al

8 Zhang & Xu

شناسایی و انتخاب بهترین ویژگی‌های مؤثر بر متغیر وابسته‌ی تقاضا از الگوریتم جنگل تصادفی^۱ (تین کام هو^۲، ۱۹۹۵ و ۱۹۹۸؛ ژو و همکاران^۳، ۲۰۲۱) استفاده شد.

۳. یافته‌های تحقیق

۱.۳. یافته‌های خوشه‌بندی براساس داده‌های زمانی

تعیین تعداد خوشه‌ها برای الگوریتم K-Means بسیار مهم است. به همین دلیل محققان در این مطالعه از دو روش آرنج و امتیاز نیم‌رخ برای تعیین تعداد خوشه‌ها استفاده کردند. نمودار آرنج مجموع مربع فواصل درون خوشه‌ای داده‌ها را به‌عنوان تابعی از مقادیر تعداد خوشه (k) مشخص می‌کند. نتایج این روش برای داده‌های اتوبوس‌رانی و قطارشهری در محل مفصل فرضی تعداد ۴ تا ۶ خوشه است. روش آرنج تعداد خوشه‌ها را به‌صورت دقیق مشخص نمی‌کند و فقط یک دید کلی نسبت به تعداد خوشه‌ها ایجاد می‌کند. با توجه به کاهشی بودن مجموع مربع فواصل درون خوشه‌ای داده‌ها در این نمودارها در فاصله بین ۲ تا ۱۹ خوشه برای هر دو گروه داده‌های اتوبوس‌رانی و قطارشهری، پژوهشگران در این تحقیق اقدام به محاسبه امتیاز نیم‌رخ هر یک از این تعداد خوشه و در نهایت تعیین تعداد خوشه نهایی کردند. معیار نیم‌رخ که میزان تفکیک‌پذیری خوشه‌ها یا به عبارتی کیفیت خوشه‌بندی را بررسی می‌کند در بین منفی یک تا یک قرار می‌گیرد. بهترین مقدار آن برابر یک است و مقادیر منفی نادرستی خوشه‌بندی را نشان می‌دهند. مقدار صفر نیز هم‌پوشانی بیش از حد خوشه‌ها تعریف می‌شود. نتایج حاصل و گزینه تعداد نهایی خوشه‌ها بیشترین امتیاز برای داده‌های اتوبوس‌رانی را برابر ۰/۷۱ و با تعداد دو خوشه و برای داده‌های ریلی برابر ۰/۶۵۹ و تعداد هفت خوشه نشان می‌دهد. با توجه به مقادیر به‌دست آمده الگوریتم K-Means نواحی ترافیکی را به تفکیک در سه بازه زمانی صبح، ظهر و عصر، برای اتوبوس‌رانی به دو خوشه کم و پر تراکنش (خوشه‌های صفر و یک) و برای قطارشهری به هفت خوشه از بسیار بسیار کم تراکنش تا بسیار بسیار پر تراکنش (خوشه‌های صفر تا شش) تقسیم‌بندی می‌کند. موقعیت مکانی خوشه‌ها در شکل ۳ برای اتوبوس‌رانی و در شکل ۴ برای قطارشهری نمایش داده شده است.

1 Random Forest
2 Tin Kam Ho
3 Zhou et al.

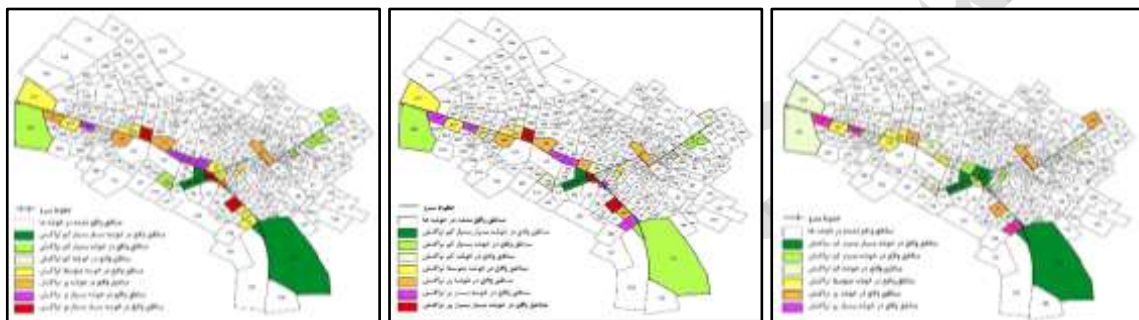


پ. بازه زمانی عصر

ب. بازه زمانی ظهر

الف. بازه زمانی صبح

شکل ۳. موقعیت مکانی خوشه‌های نواحی ترافیکی اتوبوس‌رانی




پ. بازه زمانی عصر

ب. بازه زمانی ظهر

الف. بازه زمانی صبح


شکل ۴. موقعیت مکانی خوشه‌های نواحی ترافیکی قطارشهری

الگوهای زمانی نواحی ترافیکی با توجه به تراکنش‌های اتوبوس نشان می‌دهند که از ۲۵۳ ناحیه ترافیکی ۱۹۷ ناحیه ترافیکی در هر سه بازه زمانی «کم تراکنش» و ۵۶ ناحیه حداقل در یکی از خوشه‌ها «پرتراکنش» هستند. تعداد ۲۳ ناحیه رفتار متفاوتی در صبح نسبت به ظهر داشته‌اند. همچنین ۳۵ ناحیه در خوشه بازه صبح، ۵۲ ناحیه در خوشه بازه ظهر و ۲۴ ناحیه در خوشه بازه عصر «پرتراکنش» می‌باشند. در این بین ۱۷ ناحیه در خوشه «پرتراکنش» هر سه بازه زمانی قرار گرفته‌اند. بررسی‌های بیشتر مشخص ساخت که این ۱۷ ناحیه حداقل یکی از این دو ویژگی را دارند: عبور خط BRT و یا استقرار پایانه اتوبوس. خطوط BRT به دلیل سرعت زیاد از طریق مسیرهای ویژه اتوبوس و یا اولویت به آن در عبور از تقاطع‌ها، و پایانه‌های اتوبوس به علت قرار گرفتن ایستگاه مبدأ چند مسیر مختلف در آن پذیرای مسافران بیشتر و در نتیجه افزایش تراکنش‌ها در آن نواحی هستند. شکل ۵ موقعیت این نواحی را نمایش می‌دهد.



شکل ۵. موقعیت مکانی نواحی ترافیکی پرتراکنش در همه خوشه‌های زمانی اتوبوسرانی


پژوهشگران در این مطالعه با ادامه بررسی بازه‌های صبح و عصر اتوبوسرانی برای نواحی ترافیکی دریافتند که ۱۶ ناحیه به صورت همزمان در این دو بازه زمانی «پرتراکنش» هستند (شکل ۶) که از این بین ۱۳ ناحیه در سه دهک بالای جمعیت ساکن و قالب این نواحی در مناطق حاشیه‌ای شهر قرار دارند. با توجه به سرویس‌دهی ناوگان اتوبوسرانی به مناطق حومه‌ای و شهرهای کوچک و نزدیک اطراف مشهد، نواحی حاشیه‌ای به‌عنوان نقطه انتقال مسافری به داخل و یا خارج از شهر محسوب می‌شوند. بنابراین به نظر می‌رسد تولید سفر بالا در این نواحی در بازه زمانی صبح به علت جمعیت آنها و نیز مسافری مناطق حومه‌ای که همگی که از آن به‌عنوان مبدأ سفر و رفتن به سایر نواحی استفاده می‌کنند باشد. در بازه عصر نیز این نواحی احتمالاً مبدأ سفرهای بازگشت به خارج از شهر هستند که تراکنش بالایی دارند.



شکل ۶. موقعیت مکانی نواحی ترافیکی پرتراکنش در خوشه‌های صبح و ظهر اتوبوسرانی

نواحی ترافیکی ۹۹، ۱۳۲، ۱۵۲، ۱۷۱، ۱۸۰ و ۲۰۰ از نواحی با تولید و تقاضای سفر بالا هستند که ارتباط بین کاربری‌ها و جمعیت را با الگوهای زمانی تراکنش‌های اتوبوس‌رانی تصدیق می‌کنند. جمعیت و کاربری مسکونی ساخته شده در این نواحی جزء سه دهک بالا است که می‌تواند دلیلی بر شروع تعداد زیادی سفر با اهداف مختلف در بازه صبح این نواحی باشد. از سویی دیگر کاربری‌های آموزشی و یا تجاری ساخته شده آنها نیز در سه دهک بالا قرار دارد که می‌تواند علتی بر پایان سفرهایی با این اهداف و پرتراکنش بودن بازه‌های ظهر و عصر آنها باشد. آنچه که باعث تقویت این تحلیل می‌شود، بررسی ماتریس OD سالانه است، به طوری که سفرهای با مبدأ و مقصد داخل ناحیه نسبت به سفرهایی که به/از هر یک از نواحی دیگر از/به این نواحی انجام می‌شود بیشتر است.

بررسی‌ها در ارتباط با بازه‌های زمانی قطارشهری نشان می‌دهند که همه نواحی ترافیکی در مسیر مترو در تولید سفر سالانه جزء سه دهک بالا هستند. این درحالی است که تعدادی از این نواحی در خوشه‌های اتوبوس‌رانی؛ که دارای گستردگی بیشتر سرویس‌دهی در سطح ناحیه است؛ «کم‌تراکنش» برچسب خورده‌اند. به طور کلی در الگوهای زمانی مترو، ۹ ناحیه در هر سه بازه زمانی بیشتر از تعداد متوسط دارای تراکنش هستند. شکل ۷ این نواحی را نمایش می‌دهد. ویژگی مشترکی در بین این نواحی یافت نشد اما بررسی جداگانه هر یک از آنها علت این موضوع را مشخص می‌کند. به‌طور مثال دو ناحیه ترافیکی ۴۳ و ۱۶۱ در جمعیت و کاربری‌های مسکونی، تجاری و آموزشی ساخته شده هر یک از آنها در دهک اول قرار دارند. اما وجود «ایستگاه راه‌آهن برون شهری» در مجاورت ایستگاه مترو در ناحیه ۴۳ و همچنین وجود «پارک ملت» و پایانه اتوبوس‌رانی در مجاورت ایستگاه متروی ناحیه ۱۶۱ آنها را در هر سه بازه زمانی با تراکنش بالاتر از متوسط قرار داده‌اند. درخصوص ناحیه ترافیکی ۴۸ به نظر می‌رسد وجود ایستگاه تقاطع دو خط ۱ و ۲ مترو در این ناحیه باعث قرار گرفتن آن در این مجموعه نواحی با تراکنش بالا شده است.



شکل ۷. موقعیت مکانی نواحی ترافیکی دارای تراکنش بیشتر از متوسط در همه خوشه‌های قطارشهری

در خوشه‌های قطارشهری چهار ناحیه ترافیکی ۳۶، ۷۱، ۹۷ و ۱۴۳ دارای الگوی زمانی متفاوتی در صبح (خوشه‌های با تراکنش کمتر از متوسط) نسبت به ظهر و عصر (خوشه‌های با تراکنش بیشتر از متوسط) هستند. بررسی کاربری‌های این نواحی علت این رخداد را توجیه می‌کند، به طوری که میزان کاربری تجاری ساخته شده در هر یک از این نواحی جزء سه دهک بالای نواحی ترافیکی می‌باشد و شروع و پایان ساعت کاری واحدهای تجاری در این نواحی را می‌توان علت تفاوت بین میزان تراکنش خوشه‌ها دانست.

از بین تمام نواحی ترافیکی فقط ناحیه ترافیکی ۵۷ در همه خوشه‌های زمانی اتوبوس و مترو دارای تراکنش بالا است. این ناحیه به لحاظ جمعیت در دهک ۶ و در کاربری‌های مسکونی و تجاری ساخته شده در دهک ۹ می‌باشد. اما به نظر می‌رسد ویژگی مهمتری که این اتفاق را رقم زده و باعث شده این ناحیه رتبه ۲ در تولید و رتبه ۱ در جذب سفر سالانه باشد، عبور بخشی از خط ۱ BRT که در مسیر خود مهمترین نقطه جذب سفر شهر مشهد یعنی حرم رضوی را دارد و همچنین تقاطع آن با خط ۱ قطارشهری در این ناحیه، می‌باشد.

۲.۳. یافته‌های خوشه‌بندی بر اساس داده‌های مکانی

در این مطالعه برای خوشه‌بندی نواحی ترافیکی از نرم‌افزار پایتون استفاده شده است. بدین منظور ابتدا مقدار بهینه پهنای باند، به عنوان یک متغیر ورودی روش Mean Shift، از طریق الگوریتم تخمین مقدار بهینه پهنای باند محاسبه شد. این پارامتر براساس داده استفاده شده برابر ۲/۱۸ به دست آمده است. پس از اجرای الگوریتم، نواحی ترافیکی در ۸ خوشه طبقه‌بندی شدند. شکل ۸ خوشه هر ناحیه ترافیکی را روی نقشه نشان می‌دهد.



شکل ۸. موقعیت مکانی خوشه‌بندی نواحی ترافیکی

در ادامه این بخش برای ارزیابی خوشه‌بندی انجام شده از معیار نیم‌رخ و شاخص دیویس - بولدین استفاده شد که جدول ۲ نتایج را نشان می‌دهد. با توجه به مقدار مثبت معیار نیم‌رخ و همچنین مقدار نزدیک به صفر شاخص دیویس - بولدین می‌توان نتیجه گرفت که خوشه‌بندی مناسبی انجام شده است.

جدول ۲. نتایج ارزیابی خوشه‌بندی نواحی ترافیکی

مقدار	شاخص ارزیابی
۰/۴۲	نیم‌رخ
۰/۷۳	دیویس - بولدین

با توجه به اینکه خوشه‌بندی مکانی نواحی ترافیکی بر پایه کاربری‌های ساخته شده تأثیرگذار و جمعیت و نیز میزان جذب سفر در هر ناحیه انجام شده است، یافته‌های ما معطوف به تعیین ویژگی‌های خوشه‌ها می‌باشد. خوشه صفر که دارای ۲۳۶ عضو است و نواحی موجود در آن در دهک‌های مختلفی از کاربری‌ها، جمعیت و تقاضا می‌باشند.

- خوشه یک تعداد ۷ عضو دارد. ویژگی مشترک نواحی این خوشه دهک ۱۰ در کاربری آموزشی ساخته شده است.
- خوشه‌های دو و چهار در تمامی کاربری‌های مورد بررسی و جمعیت در دهک ۱۰ قرار دارند. تنها عضو
- این خوشه‌ها جزء نواحی حاشیه‌ای و دارای تقاضای سفر زیاد است.
- خوشه سه که ۳ عضو دارد، جمعیت و کاربری مسکونی و تجاری ساخته شده هر یک از نواحی آن در دهک ۱۰ و تقاضا در دهک ۶ و ۸ است.
- خوشه پنج ویژگی‌هایی شبیه به خوشه سه دارد با این تفاوت که به‌جای کاربری تجاری ساخته شده کاربری آموزشی ساخته شده در نواحی این خوشه جزء دهک ۱۰ است.
- خوشه شش با یک عضو، که در جمعیت در دهک ۹ نواحی و در تجاری ساخته شده در دهک ۱۰ قرار دارد. تقاضای آن نیز در دهک ۷ است.
- خوشه هفت نیز یک عضوی است. در جمعیت و کاربری مسکونی ساخته شده در دهک ۱۰ قرار دارد اما در تقاضا در دهک ۱ می‌باشد.

۴. بحث

در این پژوهش سعی شد با استفاده از اطلاعات جمعیتی و کاربری زمین ساخته شده در هر ناحیه ترافیکی و همچنین نتایج حاصل از ماتریس OD سالانه، برای درک بهتر خوشه‌های مکانی و زمانی به تحلیل آنها پرداخته

شود. نتایج این تحقیق اهمیت توجه به مناطق جمعیتی حاشیه شهر و انجام سفرهای ترانزیت از طریق پایانه‌های واقع در نواحی حاشیه‌ای، توسعه خطوط انبوه‌بر، برنامه‌ریزی خطوط و تخصیص ناوگان از طریق محاسبه مقدار کارایی آنها و توزیع انواع کاربری‌ها در نواحی شهر را نشان می‌دهند.

یافته‌های گزارش شده در تعدادی از مطالعات هم‌سو با تحلیل نتایج این تحقیق و تأیید کننده یافته‌های آن می‌باشند، به طوری که دینگ و لو^۱ (۲۰۱۶) و کیم و همکاران (۲۰۱۸) الگوهای استفاده از زمین را به طور قابل توجهی بر رفتار سفر افراد تأثیرگذار می‌دانند. آنها همچنین معتقدند جمعیت و تنوع کاربری‌ها نیز تأثیرات مثبتی در تعداد سفرها خواهند داشت. ما و همکاران (۲۰۱۷) و گائو و همکاران^۲ (۲۰۱۸) عدم تعادل بین فرصت‌های شغلی در مناطق مرکزی شهر با محل سکونت در مناطق حومه‌ای و نیز پایین بودن قیمت مسکن در این بخش‌ها را دلیلی بر تولید سفر توسط مسافران ترانزیتی می‌دانند. باوتیستا هرناندز^۳ (۲۰۲۰) نشان می‌دهد که برای استفاده کنندگان از حمل‌ونقل عمومی، دسترسی شغلی، تراکم جمعیت و کاربری مختلط زمین در مبدأ دارای تأثیر بیشتری بر تعداد سفرها می‌باشند. بریاند و همکاران (۲۰۱۶) مناطقی را که مردم عمدتاً صبح از آنجا حرکت می‌کنند به عنوان محل سکونت و آنها که در عصر از آنجا سفر می‌کنند، به محل کار تفسیر کردند. کای و همکاران (۲۰۱۸) خصوصیات یک منطقه و نقاط جاذب سفر در آن را یک عامل مهم و تأثیرگذار در الگوهای سفر آن منطقه بیان کرده‌اند.

۵. نتیجه‌گیری

در این مطالعه برای درک بهتر الگوهای زمانی و مکانی سفر حمل‌ونقل عمومی، یک تحلیل خوشه‌بندی ناحیه محور در سیستم‌های اتوبوس و مترو بر پایه داده‌های کارت هوشمند و ماتریس مبدأ - مقصد سالانه حمل‌ونقل عمومی شهر مشهد انجام شده است. داده‌های تراکنش‌های من کارت بیانگر و معرف نتایج واقعی وضع موجود شبکه هستند و به طور مستقیم اطلاعاتی از سفر تک‌تک کاربران را در زمان و مکان مورد نظر ارائه می‌کنند. برای انجام خوشه‌بندی زمانی نواحی در بازه‌های صبح، ظهر و عصر سفر حمل‌ونقل عمومی از الگوریتم K-Means و بر پایه داده‌های تراکنش‌ها در زمان ورود به سیستم و در هر کدام از نواحی، استفاده شده است. در خوشه‌بندی مکانی نواحی نیز از الگوریتم Mean Shift و بر پایه جذب سفر و متغیرهای مکانی جمعیت و مساحت انواع کاربری ساخته شده مثل مسکونی، تجاری و آموزشی در هر ناحیه ترافیکی، استفاده شده است. در نهایت پیشنهاد می‌شود تصمیم‌گیرندگان در حوزه‌های شهرسازی و حمل‌ونقل از نتایج این مطالعه در طراحی و توسعه سیاست‌های زمین و حمل‌ونقل از طریق توزیع بهتر انواع کاربری‌ها در نواحی مختلف و جلوگیری از سفرهای غیرضروری، طراحی خطوط میان‌راهی و افزایش تعداد ناوگان اتوبوس و نیز کاهش سرفاصله زمانی

1 Ding & Lu

2 Gao et al.

3 Bautista-Hernández

در نواحی پرتراکشن در بازه‌های زمانی، توسعه خطوط BRT، توسعه پایانه‌ها در نواحی حاشیه‌ای و تکمیل خطوط مترو برای بهبود و افزایش سطح رضایت شهروندان در ارائه خدمات بهره گیرند.

کتابنامه

۱. آمارنامه شهر مشهد (۱۳۹۸). <https://planning.mashhad.ir>.
۲. خاکپور، ب.، شاداب‌مهر، ه. (۱۳۹۲). اثرسنجی ترافیکی تغییر کاربری‌های مسکونی و فضای سبز به تجاری (مطالعه موردی: شهر مشهد). جغرافیا و توسعه فضای شهری، ۱، ۴۷-۶۴. doi:10.22067/gusd.v0i1.18969۶۴-۴۷.
۳. سرشماری عمومی نفوس و مسکن (۱۳۹۵). <https://www.amar.org.ir>.
۴. سقایی، م.، & جوانبخت قهفرخی، ز. (۱۳۹۲). تجلیلی بر آمار گردشگران و زائران داخلی ورودی به کلانشهر مشهد با استفاده از مدل‌های سری زمانی. تحقیقات کاربردی علوم جغرافیایی (علوم جغرافیایی)، ۱۳(۲۸)، ۷۱-۹۴.
۵. فائزه، ف.، رخشاد، ح.، سیدعلی، ج.، & مرتضی، ا. (۱۴۰۲). رتبه‌بندی مناطق توسعه حمل‌ونقل محور با استفاده از روش AHP و مقایسه آن با وضعیت کاربری اراضی (مطالعه موردی: خط یک متروی مشهد). جغرافیا و توسعه فضای شهری، doi:10.22067/jgusd.2023.80696.1289.
6. 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
7. Bautista-Hernández, D. (2020). Urban Structure and Its Influence on Trip Chaining Complexity in the Mexico City Metropolitan Area. *Urban, Planning and Transport Research*, 8(1), 71-96. doi:10.1080/21650020.2019.1708784
8. Briand, A. S., Côme, E., El Mahrsi, M. K., & Oukhellou, L. (2016). A mixture model clustering approach for temporal passenger pattern characterization in public transport. *International Journal of Data Science and Analytics*, 1(1), 37-50. doi:10.1007/s41060-015-0002-x
9. Briand, A. S., Côme, E., Trépanier, M., & Oukhellou, L. (2017). Analyzing year-to-year changes in public transport passenger behaviour using smart card data. *Transportation Research Part C*, 79, 274-289. doi:10.1016/j.trc.2017.03.021
10. 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
11. Cao, F., Liang, J., & Jiang, G. (2009). An initialization method for the K-Means algorithm using neighborhood model. *Computers & Mathematics with Applications*, 58(3), 474-483. doi:10.1016/j.camwa.2009.04.017
12. Chen, C., Chen, J., & Barry, J. (2009). Diurnal pattern of transit ridership: a case study of the New York City subway system. *Journal of Transport Geography*, 17(3), 176-186. doi:10.1016/j.jtrangeo.2008.09.002
13. 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
14. Cheng, Z., Trépanier, M., & Sun, L. (2020). Probabilistic model for destination inference and travel pattern mining from smart card data. *Transportation*. doi:10.1007/s11116-020-10120-0
15. Davies, D., & Bouldin, D. (1979). A Cluster Separation Measure. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, PAMI-1(2), 224-227. doi:10.1109/TPAMI.1979.4766909

16. Demirović, D. (2019). An Implementation of the Mean Shift Algorithm. *Image Processing On Line*, 9, 251-268. doi:0.5201/ipol.2019.255
17. Deschaintres, E., Morency, C., & Trépanier, M. (2019). Analyzing Transit User Behavior with 51 Weeks of Smart Card Data. *Transportation Research Record: Journal of the Transportation Research Board*, 2673(6), 1-13. doi:10.1177/0361198119834917
18. Ding, C., Cao, J., & Liu, C. (2019). How does the station-area built environment influence Metrorail ridership? Using gradient boosting decision trees to identify non-linear thresholds. *Journal of Transport Geography*, 77, 70-78. doi:10.1016/j.jtrangeo.2019.04.011
19. Ding, Y., & Lu, H. (2016). Activity participation as a mediating variable to analyze the effect of land use on travel behavior: A structural equation modeling approach. *Journal of Transport Geography*, 52, 23-28. doi:10.1016/j.jtrangeo.2016.02.009
20. 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)*, (p. 9). New York.
21. El Mahrsi, M., Côme, E., Oukhellou, L., & verleysen, M. (2017). Clustering Smart Card Data for Urban Mobility Analysis. *IEEE Transactions on Intelligent Transportation Systems*, 18(3), 712-728. doi:10.1109/TITS.2016.2600515
22. Eltibi, M., & Ashour, W. (2011). Initializing K-Means Clustering Algorithm using Statistical Information. *International Journal of Computer Applications (IJCA)*, 29(7), 51-55. doi:10.5120/3573-4930
23. Faroqi, H., Mesbah, M., Kim, J., & Tavassoli, A. (2018). A model for measuring activity similarity between public transit passengers using smart card data. *Travel Behaviour and Society*, 13, 11-25. doi:10.1016/j.tbs.2018.05.004
24. Frutos-Bernal, E., del Rey, Á., Mariñas-Collado, I., & Santos-Martín, M. (2022). An Analysis of Travel Patterns in Barcelona Metro Using Tucker3 Decomposition. *Mathematics*, 10(7), 1122. doi:10.3390/math10071122
25. Gao, Q.-L., Li, Q.-Q., Yue, Y., Zhuang, Y., Chen, Z.-P., & Kong, H. (2018). Exploring changes in the spatial distribution of the low-to-moderate income group using transit smart card data. *Computers, Environment and Urban Systems*, 72, 68-77. doi:10.1016/j.compenvurbsys.2018.02.006
26. Gong, Y., Lin, Y., & Duan, Z. (2017). Exploring the spatiotemporal structure of dynamic urban space using metro smart card records. *Computers, Environment and Urban Systems*, 64, 169-183. doi:10.1016/j.compenvurbsys.2017.02.003
27. Goulet-Langlois, G., Koutsopoulos, H., & Zhao, J. (2016). Inferring patterns in the multi-week activity sequences of public transport users. *Transportation Research Part C: Emerging Technologies*, 64, 1-16. doi:10.1016/j.trc.2015.12.012
28. 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
29. Hu, N., Legara, E. F., Lee, K. K., Hung, G. G., & Monterola, C. (2016). Impacts of land use and amenities on public transport use, urbanplanning and design. *Land Use Policy*, 57, 356-367. doi:10.1016/j.landusepol.2016.06.004
30. Huang, D., Yu, J., Shen, S., Li, Z., Zhao, L., & Gong, C. (2020). A Method for Bus OD Matrix Estimation Using Multisource Data. *Journal of Advanced Transportation*, 2020(1), 1-13. doi:10.1155/2020/5740521
31. Jin, X., & Han, J. (2017). Mean Shift. In C. Sammut, & G. Webb, *Encyclopedia of Machine Learning and Data Mining* (pp. 806-808). Boston, MA: Springer. doi:10.1007/978-1-4899-7687-1_532
32. Kieu, M., Bhaskar, A., & Chung, E. (2015). Passenger Segmentation Using Smart Card Data. *IEEE Transactions on Intelligent Transportation Systems*, 16(3), 1537 - 1548. doi:10.1109/TITS.2014.2368998

33. 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
34. Kim, M.-K., Kim, S.-P., Heo, J., & Sohn, H.-G. (2017). Ridership patterns at subway stations of Seoul capital area and characteristics of station influence area. *KSCE Journal of Civil Engineering*, 21(3), 964–975. doi:10.1007/s12205-016-1099-8
35. Lathia, N., Smith, C., Froehlich, J., & Capra, L. (2013). Individuals among commuters: Building personalised transport information services from fare collection systems. *Pervasive and Mobile Computing*, 9(5), 643-664. doi:10.1016/j.pmcj.2012.10.007
36. Li, C., Bai, L., Liu, W., Yao, L., & Waller, S. (2021). Urban Mobility Analytics: A Deep Spatial-Temporal Product Neural Network for Traveler Attributes Inference. *Transportation Research Part C: Emerging Technologies*, 124. doi:10.1016/j.trc.2020.102921
37. Li, J., Kim, C., & Sang, S. (2018). Exploring impacts of land use characteristics in residential neighborhood and activity space on non-work travel behaviors. *Journal of Transport Geography*, 70, 141-147. doi:10.1016/j.jtrangeo.2018.06.001
38. Lin, P., Weng, J., Alivanistos, D., Ma, S., & Yin, B. (2020). Identifying and Segmenting Commuting Behavior Patterns Based on Smart Card Data and Travel Survey Data. *sustainability*, 12, 5010. doi:10.3390/su12125010
39. Liu, J., Shi, W., & Chen, P. (2020). Exploring Travel Patterns during the Holiday Season—A Case Study of Shenzhen Metro System During the Chinese Spring Festival. *International Journal of Geo-Information*, 9(11), 651. doi:10.3390/ijgi9110651
40. Liu, Y., & Cheng, T. (2018). Understanding public transit patterns with open geodemographics to facilitate public transport planning. *Transportmetrica A: Transport Science*, 76-103. doi:10.1080/23249935.2018.1493549
41. Long, Y., & Thill, J.-C. (2015). Combining smart card data and household travel survey to analyze jobs–housing relationships in Beijing. *Computers, Environment and Urban Systems*, 53, 19-35. doi:10.1016/j.compenvurbsys.2015.02.005
42. Ma, X.-l., Liu, C., Wen, H., Wang, Y., & Yao-Jan, W. (2017). Understanding commuting patterns using transit smart card data. *Transport Geography*, 135-145. doi:10.1016/j.jtrangeo.2016.12.001
43. 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
44. MacQueen, J. (1967). Some methods for classification and analysis of multivariate observations. In *Proceedings of the fifth Berkeley symposium on mathematical statistics and probability* (Vol. 1, pp. 281-297).
45. Mariñas-Collado, I., Sipols, A., Santos-Martín, M., & Frutos-Bernal, E. (2022). Clustering and Forecasting Urban Bus Passenger Demand with a Combination of Time Series Models. *Mathematics*, 10(15), 2670. doi:10.3390/math10152670
46. 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
47. Morency, C., Trépanier, M., & Agard, B. (2006). Analysing the Variability of Transit Users Behaviour with Smart Card Data. *2006 IEEE Intelligent Transportation Systems Conference*. Toronto, Canada: IEEE. doi:10.1109/ITSC.2006.1706716
48. 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
49. 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

50. Netzer, M., Michelberger, J., & Fleischer, J. (2020). Intelligent Anomaly Detection of Machine Tools based on Mean Shift Clustering. *Procedia CIRP*, 93, 1448-1453. doi:10.1016/j.procir.2020.03.043
51. Poussevin, M., Baskiotis, N., Guigue, V., & Gallinari, P. (2014). Mining Ticketing Logs for Usage Characterization with Nonnegative Matrix Factorization. *International Workshop on Modeling Social Media International Workshop on Mining Ubiquitous and Social Environments International Workshop on Machine Learning for Urban Sensor Data*, (pp. 147-164). doi:10.1007/978-3-319-29009-6_8
52. Qi, G., Huang, A., Guan, W., & Fan, L. (2018). Analysis and Prediction of Regional Mobility Patterns of Bus Travellers Using Smart Card Data and Points of Interest Data. *IEEE TRANSACTIONS ON INTELLIGENT TRANSPORTATION SYSTEMS*, 20, 1197-1214. doi:10.1109/TITS.2018.2840122
53. Ros, F., RIAD, R., & Guillaume, S. (2023). PDBI: A partitioning Davies-Bouldin index for clustering evaluation. *Neurocomputing*, 528, 178-199. doi:10.1016/j.neucom.2023.01.043
54. Rousseeuw, P. (1987). Silhouettes: A graphical aid to the interpretation and validation of cluster analysis. *Journal of Computational and Applied Mathematics*, 20, 53-65. doi:10.1016/0377-0427(87)90125-7
55. 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
56. Shahapure, K., & Nicholas, C. (2020). Cluster Quality Analysis Using Silhouette Score. *2020 IEEE 7th International Conference on Data Science and Advanced Analytics (DSAA)* (pp. 747-748). Sydney, NSW, Australia: IEEE. doi:10.1109/DSAA49011.2020.00096
57. Shi, C., Wei, B., Wei, S., Wang, W., Liu, H., & Liu, J. (2021). A Quantitative Discriminant Method of Elbow Point for the Optimal Number of Clusters in Clustering Algorithm. *Journal on Wireless Communications and Networking*, 31(2021), 1-16. doi:10.1186/s13638-021-01910-w
58. Tang, J., Wang, X., Zong, F., & Hu, Z. (2020). Uncovering Spatio-temporal Travel Patterns Using a Tensor-based Model from Metro Smart Card Data in Shenzhen, China. *Sustainability*, 12(4), 1475. doi:10.3390/su12041475
59. Thorndike, R. (1953). Who belongs in the family? *Psychometrika*, 18(4), 267-276. doi:10.1007/BF02289263
60. 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
61. 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
62. Wang, W., Lo, S., & Liu, S. (2015). Aggregated Metro Trip Patterns in Urban Areas of Hong Kong: Evidence from Automatic Fare Collection Records. *Journal of Urban Planning and Development*, 141(3). doi:10.1061/(ASCE)UP.1943-5444.0000225
63. Wang, X., Yao, L., Liu, W., Li, C., Bai, L., & Waller, S. (2020). Mobility Irregularity Detection with Smart Transit Card Data. *Pacific-Asia Conference on Knowledge Discovery and Data Mining. PAKDD 2020. Lecture Notes in Computer Science. 12084*, pp. 541-552. Springer, Cham. doi:10.1007/978-3-030-47426-3_42
64. Yu, C., & He, Ph.D, Z.-C. (2017). Analysing the spatial-temporal characteristics of bus travel demand using the heat map. *Journal of Transport Geography*, 58, 247-255. doi:10.1016/j.jtrangeo.2016.11.009
65. Zhang, S., Yang, Y., Zhen, F., Lobsang, T., & Li, Z. (2021). Understanding the travel behaviors and activity patterns of the vulnerable population using smart card data: An activity space-based approach. *Journal of Transport Geography*. doi:10.1016/j.jtrangeo.2020.102938
66. 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

67. Zhao, J., Ruyue, L., Zhang, F., Xu, C.-Z., & Feng, S. (2014). Understanding temporal and spatial travel patterns of individual passengers by mining smart card data. *2014 IEEE 17th International Conference on Intelligent Transportation Systems (ITSC)* (pp. 2991-2997). Qingdao: IEEE. doi:10.1109/ITSC.2014.6958170
68. Zhao, X., Wu, Y.-p., Ren, G., Ji, K., & Qian, W.-w. (2019). Clustering Analysis of Ridership Patterns at Subway Stations: A Case in Nanjing, China. *Journal of Urban Planning and Development* , 145(2). doi:10.1061/(ASCE)UP.1943-5444.0000501
69. Zhao, X., Zhang, Y., Hu, Y., Qian, S., & yin, b. (2021). Interactive Visual Exploration of Human Mobility Correlation Based on Smart Card Data. *IEEE Transactions on Intelligent Transportation Systems*, 22(8), 4825 - 4837. doi:10.1109/TITS.2020.2983853
70. 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
71. Zhong, C., Manley, E., Arisona, S., Batty, M., & Schmitt, G. (2015). Measuring variability of mobility patterns from multiday smart-card data. *Journal of Computational Science*, 9, 125-130. doi:10.1016/j.jocs.2015.04.021
72. Zhou, Y., Fang, Z., Zhan, Q., Huang, Y., & Fu, X. (2017). Inferring Social Functions Available in the Metro Station Area from Passengers' Staying Activities in Smart Card Data. *ISPRS International Journal of Geo-Information*, 6(12), 394. doi:10.3390/ijgi6120394
73. 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
74. 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
75. Zhu, T.-L., Wang, X., Zhang, J., Yu, S., & Molotov, I. (2022). Mean-shift clustering approach to the tracklets association with angular measurements of resident space objects. *Astronomy and Computing*, 40, 100588. doi:10.1016/j.ascom.2022.100588