

## کشف الگوهای مکانی-زمانی سفر در حمل و نقل عمومی شهری: بینش‌هایی از

### تحلیل داده‌های کارت هوشمند

شریعت رادفر، گروه مهندسی صنایع، واحد نجف آباد، دانشگاه آزاد اسلامی، نجف آباد، ایران  
حمیدرضا کوشا، گروه مهندسی صنایع، دانشکده مهندسی، دانشگاه فردوسی مشهد، ایران  
علی غلامی (مسئول مکاتبات)، گروه مهندسی عمران، دانشکده مهندسی، دانشگاه گلستان، گرگان، ایران

**E-mail: a.gholami@gu.ac.ir**

عاطفه امین‌دوست، گروه مهندسی صنایع، واحد نجف آباد، دانشگاه آزاد اسلامی، نجف آباد، ایران

پذیرش: ۱۴۰۴/۰۲/۲۱

دریافت: ۱۴۰۳/۱۲/۰۴

#### چکیده

سیستم‌های حمل و نقل عمومی، رفتارهای سفر پیچیده‌ای را نشان می‌دهند که تحت تأثیر عوامل مکانی و زمانی مانند مبدأ مسافران، تقاضای مبتنی بر زمان و ویژگی‌های ساختاری شهری قرار دارند. درک این رفتارها برای بهبود برنامه‌ریزی حمل و نقل و توسعه شهری بسیار مهم است. این پژوهش، روندهای سفر مبتنی بر مناطق در شهر مشهد، ایران را با استفاده از داده‌های کارت‌های هوشمند سیستم‌های اتوبوس و مترو بررسی می‌کند. الگوهای زمانی سفر مسافران با استفاده از روش خوشه‌بندی *K-means* در ۲۵۳ منطقه ترافیکی، به سه دسته صبح، ظهر و عصر تقسیم‌بندی شدند. در همین حال، از روش خوشه‌بندی *Mean Shift* برای بررسی ویژگی‌های مکانی مانند توزیع جمعیت و توسعه شهری در هر منطقه استفاده شد. نتایج، خوشه‌های متمایزی را برای ابعاد زمانی و مکانی نشان می‌دهد که ارتباط پیچیده بین روندهای سفر، عوامل جمعیتی و کاربری اراضی را برجسته می‌کند. یافته‌های کلیدی شامل ارتباط قوی بین مناطق مسکونی و سفرهای صبحگاهی، مراکز تجاری و آموزشی با سفرهای ظهرگاهی، و اتصال مناطق حاشیه‌ای با محله‌های مسکونی مجاور است. این نتایج، بینش‌های عملی برای برنامه‌ریزان شهری و سیاست‌گذاران فراهم می‌کند تا سیستم‌های حمل و نقل و سیاست‌های کاربری اراضی را بهبود بخشند.

واژه‌های کلیدی: الگوهای سفر، حمل و نقل عمومی، داده‌های کارت هوشمند، تحلیل مکانی-زمانی، خوشه‌بندی

## ۱. مقدمه

کند تا مجموعه‌های داده‌های بزرگ را تجزیه و تحلیل کرده و اطلاعات معناداری را از آنها استخراج کنند. داده‌های کارت هوشمند سیستم حمل‌ونقل عمومی فرصتی را برای ردیابی فعالیت‌ها و الگوهای سفر، توزیع مکانی و زمانی و پیش‌بینی تقاضای حمل‌ونقل عمومی و در نهایت برنامه‌ریزی بهتر ارائه خدمات را فراهم کرده است (Ma et al., 2013; Kim et al., 2018; Lin et al., 2020; Cats, 2024). برخی از محققان داده‌های کارت هوشمند را با داده‌های سایر منابع مانند داده‌های بررسی سفر، مشخصات کاربری اراضی، مشخصات جمعیت شناختی، شاخص‌های اجتماعی-اقتصادی، روزهای هفته، تعطیلات و عوامل دیگری مانند آب و هوا، برای بررسی الگوهای سفر مسافران حمل‌ونقل عمومی ترکیب کرده‌اند. ترکیب مزایای داده‌های کارت هوشمند با سایر داده‌ها، دقت و تفسیرپذیری مدل‌ها را بهبود می‌بخشد (Han and Sohn, 2016; Nagy et al., 2017; Liu and Cheng, 2018; Lin et al., 2020; Marinas-Collado et al., 2022). موسسه دموگرافیا در آخرین گزارش جمعیت‌شناسی نواحی شهری جهان تراکم شهر مشهد را ۱۰۲۷۵ نفر به ازای هر کیلومتر مربع اعلام کرده است که خود بازگو کننده تراکم بالای جمعیتی در این شهر است. تراکم بالای جمعیت علی‌رغم مشکلات عدیده‌ای که بوجود می‌آورد، فرصت طلایی برای ارائه خدمات حمل‌ونقل عمومی با تواتر بالا ایجاد می‌کند، که این نیازمند درک بهتر از ساختار مکانی شهری است. هدف از این تحقیق تعیین خوشه‌بندی‌های مکانی و زمانی سفر حمل‌ونقل عمومی در شهر مشهد می‌باشد.

## ۲. ادبیات پژوهش

یک شهر هوشمند با فراهم کردن دسترسی به خدمات همه جانبه، کیفیت زندگی شهروندان خود را بهبود می‌بخشد. سیستم‌های حمل‌ونقل هوشمند نقش اساسی در تبدیل یک منطقه شهری به یک شهر هوشمند دارند (Gohar et al., 2018). شهرهای هوشمند همیشه در حال تولید حجم عظیمی از داده‌ها می‌باشند

درک رفتارهای سفر و الگوهای فعالیت افراد در برنامه‌ریزی و پیش‌بینی جریان ترافیک شهری و همچنین بهره‌برداری از سیستم‌های حمل‌ونقل عمومی مهم است. عواملی مانند جمعیت، مکان و زمان به‌طور قابل توجهی رفتارهای سفر متفاوتی را شکل می‌دهند به‌طوری که ایجاد پیوندهای معنی‌دار بین آنها و ویژگی‌های مسافران مسأله مهمی می‌باشد (Lin et al., 2020; Tang et al., 2021; Li et al., 2021). 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. 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).

به‌طور سنتی، حوزه تحقیقات حمل‌ونقل عمومی به نظرسنجی-هایی که در ایستگاه‌ها یا سطح خانوار انجام می‌شود، متکی می‌باشد. از سوی دیگر پیشرفت سریع فناوری اطلاعات و ارتباطات، انقلابی را در حوزه تحقیقات حمل‌ونقل در دهه گذشته به وجود آورده است. فراگیر بودن این منابع داده منجر به تولید حجم بی‌سابقه‌ای از داده‌ها شده که دارای مرجع جغرافیایی و ماهیت مکانی - زمانی بوده و برای توضیح الگوهای تحرک انسان با هزینه‌های بسیار کمتر مناسب هستند (Zannat and Choudhury, 2019). داده‌های کارت هوشمند بینش‌هایی را در مورد پویایی‌های شهری و الگوهای تحرک حمل‌ونقل عمومی شهر ارائه می‌دهد (Anda et al., 2017). داده‌های جمع‌آوری شده از کارت‌های هوشمند این امکان را برای محققان فراهم می‌

## کشف الگوهای مکانی-زمانی سفر در حمل و نقل عمومی شهری: بینش‌هایی از تحلیل داده‌های کارت هوشمند

خاصی در طراحی شهر هوشمند و پردازش کلان داده‌ها دارد (Han and Kamber, 2006; Rajaei et al.; 2017). جدول ۱ مطالعات انجام شده توسط سایر پژوهشگران را برای استخراج الگوهای سفر حمل و نقل عمومی و بر پایه داده‌های تراکنش‌های کارت‌های هوشمند نشان می‌دهد.

(Nagarkar, 2017). برای دستیابی به شهر هوشمند و به تبع آن حمل و نقل هوشمند به‌عنوان یکی از مؤلفه‌های آن نیاز به ابزاری است تا بتواند داده‌های ذخیره شده را پردازش کرده و اطلاعات حاصل از این پردازش را در اختیار دولت و کاربران قرار دهد. در این میان داده کاوی به‌عنوان ابزاری مؤثر، جایگاه

جدول ۱. مطالعات مرتبط با الگوهای سفر

تحقیق	موضوع یا هدف مطالعه	شیوه حمل و نقل	محیط مطالعه	روش خوشه‌بندی
Agard et al. (2006)	کشف رفتار و الگوهای روزانه کاربران	اتوبوس	گاتینو، کانادا	HAC و K-Means
Morency et al. (2006)	تحلیل تغییرپذیری رفتار کاربران حمل و نقل و خوشه‌بندی روزهای سفر	اتوبوس	گاتینو، کانادا	K-Means
Chen et al. (2009)	بررسی الگوهای مکانی و زمانی مسافر	مترو	نیویورک، آمریکا	K-Means
Lathia et al. (2013)	خوشه‌بندی و کشف الگوهای رفتاری مسافران	مترو	لندن، انگلیس	سلسله مراتبی تجمعی
Ma et al. (2013)	شناسایی الگوهای مکانی و زمانی مسافران شبکه حمل و نقل	اتوبوس و مترو	پکن، چین	K-Means++ و DBSCAN
Lee & Hickman (2014)	استنباط هدف سفر و شناسایی الگوهای سفر	مترو	سینت پل، مینیاپولیس	درخت تصمیم
Kusakabe & Asakura (2014)	تخمین ویژگی‌های رفتاری و هدف سفرها	مترو	اوزاکا، ژاپن	مدل احتمالی ساده بیز
Zhao et al. (2014)	استخراج الگوهای سفر مکانی-زمانی مسافران	مترو	شنژن، چین	K-Means
Poussevin et al. (2014)	کشف الگوهای رفتاری برای توصیف مسافران و خوشه‌بندی ایستگاه‌ها	مترو	پاریس، فرانسه	K-Means
El Mahrsi et al. (2014)	بررسی توزیع ویژگی‌های اقتصادی-اجتماعی بر روی خوشه‌های زمانی	اتوبوس و مترو	رنس، فرانسه	Unigram
Zhong et al. (2015)	اندازه‌گیری تنوع الگوهای تحرک روز به روز	اتوبوس و مترو	سنگاپور	K-Means
Kieu et al. (2015)	خوشه‌بندی و استخراج الگوی سفر کاربران	اتوبوس، مترو، کشتی	کوئینزلند، استرالیا	DBSCAN
Long & Thill (2015)	تجزیه و تحلیل الگوهای مکانی و زمانی و روابط شغل و مسکن	اتوبوس	پکن، چین	درخت تصمیم
Wang et al. (2015)	تجزیه و تحلیل الگوهای سفر	مترو	هنگ کنگ	HAC
Goulet-Langlois et al. (2016)	شناسایی خوشه‌های کاربران با ساختار توالی فعالیت مشابه	اتوبوس و مترو	لندن، انگلیس	K-Means و PCA

مدل عامل سازی احتمالی	سنگاپور	اتوبوس و مترو	درک الگوهای مکانی - زمانی تحرک شهری	Sun & Axhausen (2016)
مخلوط گاوسی	رنس، فرانسه	-	خوشه بندی مسافران بر اساس فعالیت های زمانی	Briand et al. (2016)
مخلوط گاوسی	گاتینو، کانادا	اتوبوس	خوشه بندی مسافران بر اساس رفتار زمانی در طول سالها	Briand et al. (2017)
مدل مولد	رنس، فرانسه	اتوبوس و مترو	خوشه بندی زمانی نحوه استفاده از ایستگاه ها و نحوه رفتار مسافران	El Mahrsi et al. (2017)
PCA و مخلوط گاوسی	گوانگژو، چین	اتوبوس	تجزیه و تحلیل ویژگی های مکانی-زمانی تقاضای سفر	Yu et al. (2017)
DBSCAN و ISODATA	پکن، چین	اتوبوس و مترو	شناسایی الگوهای مکانی و زمانی سفر	Ma et al. (2017)
K-DBSCAN و Means	ووهان، چین	مترو	استنباط عملکرد مناطق شهری در سطح ایستگاه با توجه به الگوهای فعالیت های ماندگار	Zhou et al. (2017)
HAC	شنژن، چین	مترو	بررسی ساختار مکانی-زمانی فضای شهری پویا با استفاده از رفتار سفر	Gong et al. (2017)
K-Means و رگرسیون	سئول، کره جنوبی	مترو	تحلیل الگوهای روزانه ایستگاه ها و تعیین رابطه بین این الگوها و سایر محیط های محلی	Kim et al. (2017)
C-means فازی با محدود کننده داخلی، فاکتورگیری تانسور غیرمنفی و شبکه عصبی	پکن، چین	اتوبوس	پیش بینی الگوهای سفر منطقه ای بر اساس مشخصات منطقه ای و استخراج الگوی های سوار و پیاده شدن	Qi et al. (2018)
درخت تصمیم احتمالی	بریزبن، استرالیا	اتوبوس و مترو	اندازه گیری شباهت های بین فعالیت های مسافران	Faroqi et al. (2018)
تخصیص پنهان دیریکله	لندن، انگلیس	مترو	استخراج الگوهای حمل و نقل	Liu & Cheng (2018)
K-Spectral Centroid	سئول، کره	اتوبوس و مترو	رابطه بین الگوهای سفر و ویژگی های شهری	Kim et al. (2018)
مدل n-gram بیزی	لندن، انگلیس	-	پیش بینی تحرک فردی شامل پیش بینی انجام سفر و ویژگی های آن در حمل و نقل عمومی	Zhao et al. (2018)
DBSCAN	سنگاپور	-	شناسایی الگوهای هفتگی فعالیت های اولیه کاربران حمل و نقل عمومی	Medina (2018)
درختان تصمیم تقویت کننده گرادیان	واشینگتن، آمریکا	مترو	بررسی چگونگی اثرات محیط ساخته شده در اطراف ایستگاه بر سفر با مترو	Ding et al. (2019)
K-Medoids	نانجینگ، چین	مترو	خوشه بندی ایستگاه ها و درک روابط بین الگوهای ایستگاه و کاربری های اطراف آن	Zhao et al. (2019)

## کشف الگوهای مکانی-زمانی سفر در حمل و نقل عمومی شهری: بینش‌هایی از تحلیل داده‌های کارت هوشمند

Deschaintres et al. (2019)	بررسی الگوهای رفتار سفر فردی به صورت هفتگی و در طول سال	اتوبوس و مترو	مونترال، کانادا	K-Means و Lloyd algorithm
Wang et al. (2020)	تشخیص رفتار نامنظم در سطح مسافر حمل و نقل عمومی	-	سیدنی، استرالیا	یادگیری عمیق
Cheng et al. (2020)	استخراج الگوهای زمانی و مکانی مسافران	مترو	گوانگژو، چین	تخصیص پنهان دیریکله
Lin et al. (2020)	شناسایی و طبقه‌بندی مسافران با استفاده از الگوهای مکانی - زمانی سفر	اتوبوس و مترو	پکن، چین	LightGBM و تخصیص پنهان دیریکله
Tang et al. (2020)	کشف الگوهای مکانی - زمانی سفر مسافران	مترو	شنژن، چین	تجزیه NCP
Liu et al. (2020)	بررسی الگوهای سفر و اهداف مسافر در طول تعطیلات جشنواره بهار	مترو	شنژن، چین	تخصیص پنهان دیریکله
Huang et al. (2020)	به دست آوردن زمان رسیدن اتوبوس	اتوبوس	سوژو، چین	DBSCAN
Mariñas-Collado et al. (2021)	الگوهای تحرک و طبقه‌بندی ایستگاه‌ها	مترو	بارسلونا، اسپانیا	PCA
Zhou et al. (2021)	بررسی تغییرات در الگوهای فعالیت فردی در خانه و محل کار	مترو	وو‌هان، چین	Random Forest
Zhang et al. (2021)	بررسی رفتارهای سفر و الگوهای فعالیت جمعیت آسیب‌پذیر در حمل و نقل عمومی	-	وو‌هو، چین	K-Means
Li et al. (2021)	استنباط ویژگی‌های مسافران با استفاده از الگوهای مکانی و زمانی آنها	اتوبوس، مترو، کشتی و قطار سبک	سیدنی، استرالیا	شبکه عصبی ترکیبی
Zhao et al. (2021)	ویژگی‌های سفر مسافران شامل زمان سفر، تقاضای سفر و اهداف سفر	اتوبوس و مترو	پکن، چین	K-Means++
Mariñas-Collado et al. (2022)	خوشه‌بندی ایستگاه‌ها	اتوبوس	سالامانکا، اسپانیا	HAC
Frutos-Bernal et al. (2022)	تجزیه و تحلیل الگوهای مکانی و زمانی سفر و خوشه‌بندی ایستگاه‌ها	مترو	بارسلونا، اسپانیا	تجزیه تاکر ۳

سفر مکانی - زمانی را فراتر از روش‌های ایستگاه محور گسترش می‌دهد. از الگوریتم‌های خوشه‌بندی K-means (K-میانگین) که یک روش مبتنی بر فاصله است (Eltibi and Ashour, 2011) و Mean Shift (انتقال میانگین) که یک روش مبتنی بر چگالی است (Jin and Han, 2017)، برای تجزیه و تحلیل الگوهای سفر مسافران استفاده می‌شود. در مطالعاتی که در جدول

این تحقیق الگوهای سفر حمل و نقل عمومی شهر مشهد را بررسی می‌کند. به‌طوریکه از یک رویکرد خوشه‌بندی برای شناسایی الگوها، با در نظر گرفتن ویژگی‌های زمانی (صبح، ظهر، عصر) و ویژگی‌های مکانی (تراکم جمعیت، مساحت انواع کاربری ساخته شده) در نواحی ترافیکی استفاده می‌شود. این رویکرد، که نواحی ترافیکی را بر اساس مساحت ساخته شده کاربری‌ها در سطح کل منطقه جمع‌بندی می‌کند، درک الگوهای فصلنامه مهندسی حمل و نقل / سال هفدهم / شماره دوم (۶۷) / زمستان ۱۴۰۴

حرکت در ساعات شلوغی) و بهینه‌سازی برنامه‌های خدمات (مانند افزایش فرکانس در ساعات اوج مصرف یا تنظیم برنامه‌ها بر اساس تغییرات مکانی در سفر مسافران) استفاده کرد.

روش‌های طبقه‌بندی و خوشه‌بندی داده‌ها برای شناسایی الگوهای متمایز در رفتار سفر بر اساس عواملی مانند ویژگی‌های زمانی (زمان روز، روزهای هفته) و ویژگی‌های مکانی (محل مسافر، تراکم جمعیت، کاربری زمین) استفاده می‌شود. با تجزیه و تحلیل این الگوها، هدف تحقیق آشکار کردن رابطه بین رفتار سفر، دوره‌های زمانی و زمینه‌های مکانی است.

### ۳-۱ روش شناسی مدل خوشه‌بندی نواحی ترافیکی

#### براساس داده‌های زمانی

نواحی ترافیکی بر اساس الگوهای زمانی در حمل‌ونقل عمومی دسته‌بندی شدند. این تجزیه و تحلیل از داده‌های تراکنش حمل‌ونقل عمومی (به‌عنوان مثال، ورود یا خروج مسافر) در دوره‌های زمانی مختلف برای هر ناحیه ترافیکی استفاده می‌کند. برای این منظور الگوریتم خوشه‌بندی K-means (MacQueen, 1967; Cao et al., 2009) به دلیل اثربخشی آن مورد استفاده قرار گرفت. تعیین تعداد بهینه خوشه‌ها (k) برای الگوریتم K-Means بسیار مهم است. برای شناسایی تعداد بهینه خوشه، از دو رویکرد روش آرنج و امتیاز نیم‌رخ استفاده می‌شود.

داده‌های مورد استفاده در این بخش زمان و ایستگاه تراکنش از سامانه جمع‌آوری کرایه اتوبوس و مترو و همچنین اطلاعات ناحیه ترافیکی ایستگاه‌های مختلف مترو و اتوبوس است. اطلاعات ناحیه ترافیکی ایستگاه‌ها برای پیوند دادن تراکنش‌ها به نواحی استفاده می‌شود. در پاکسازی داده‌ها، ویژگی‌های غیرمرتبط که در فرآیند خوشه‌بندی استفاده نمی‌شوند حذف می‌شوند. این امر تضمین می‌کند که تمرکز بر روی اطلاعات مهم برای خوشه‌بندی نواحی ترافیکی به‌طور مؤثر باقی بماند. جریان‌های اتوبوس و مترو به دلیل تفاوت در الگوهای سفر، برنامه‌های عملیاتی و سرفاصله زمانی، ظرفیت و تقاضا، دسترسی

۱ مورد بررسی قرار گرفتند استخراج الگوهای سفر مبتنی بر داده‌های تراکنش‌های کارت‌های هوشمند است. در این مطالعه داده‌های مکانی جمعیت و انواع مساحت کاربری ساخته شده (مانند مسکونی، تجاری، آموزشی) در کنار داده‌های سفر، در بازه‌های زمانی مختلف ترکیب خواهند شد. خوشه‌بندی مکانی نواحی ترافیکی برپایه داده‌های تقاضای سفر حمل‌ونقل عمومی در یک سیستمی که تراکنش‌ها فقط در زمان ورود مسافر ثبت می‌شوند و در زمان خروج تراکنشی انجام نمی‌شود؛ استفاده از ویژگی کاربری‌های ساخته شده در سطح ناحیه به جای خوشه‌بندی ایستگاه‌ها و نقاط جاذب اطراف آنها؛ و بررسی همزمان چندین متغیر مکانی، مهمترین شکاف‌های مطالعاتی هستند که در این تحقیق به آن پرداخته خواهد می‌شود.

هدف از این مطالعه توسعه حمل‌ونقل عمومی، توزیع بهتر کاربری زمین در سراسر مناطق، و کاهش سفرهای غیرضروری است که در نهایت منجر به کارآمدتر شدن سیستم می‌شود.

### ۳. روش پژوهش

چارچوب تحقیق، رفتار کاربر حمل‌ونقل عمومی را با استفاده از تکنیک‌های طبقه‌بندی داده و خوشه‌بندی بررسی می‌کند. تجزیه و تحلیل هر دو بعد زمانی و مکانی را برای ارائه بینش در موارد زیر در بر می‌گیرد:

- **برنامه‌ریزی شهری:** با درک الگوهای سفر، برنامه‌ریزان شهری می‌توانند تصمیمات آگاهانه‌ای در مورد تخصیص کاربری زمین بگیرند. این امر می‌تواند شامل قرار دادن مناطق مسکونی در نزدیکی مراکز حمل‌ونقل عمومی، مناطق تجاری در نزدیکی مناطق پرتردد، یا مؤسسات آموزشی در دسترس دانش‌آموزان باشد.

- **برنامه‌ریزی عملیاتی حمل‌ونقل:** این تجزیه و تحلیل می‌تواند استراتژی‌هایی را برای بهینه‌سازی عملیات حمل‌ونقل عمومی ارائه دهد. از آنها می‌توان برای تطبیق تعداد وسایل نقلیه در یک مسیر با تقاضای مسافر در دوره‌های زمانی مختلف (به‌عنوان مثال، داشتن اتوبوس‌های بیشتر در حال

## کشف الگوهای مکانی-زمانی سفر در حمل و نقل عمومی شهری: بینش‌هایی از تحلیل داده‌های کارت هوشمند

در مشهد» که توسط سازمان مدیریت و مهندسی شبکه حمل و نقل این شهر انجام شده، ارائه گردیده است. این تجمیع دوره، امکان ایجاد خوشه‌های ناحیه جداگانه را بر اساس الگوهای سفر صبح، ظهر و عصر آنها فراهم می‌کند. پس از این مراحل پیش پردازش، مجموعه داده نهایی آماده شده برای خوشه‌بندی نواحی ترافیکی به دست می‌آید. این مجموعه داده، تعداد تراکنش‌های ساعتی را برای هر ناحیه در هر یک از سه دوره زمانی (صبح، ظهر، عصر) در سفر با اتوبوس و مترو ترکیب می‌کند. این مجموعه داده جامع، ویژگی‌های مکانی استفاده از حمل و نقل عمومی در داخل شهر را به تصویر کشیده و پایه‌ای قوی برای خوشه‌بندی مؤثر ناحیه ترافیکی را فراهم می‌کند.

### ۲-۳ روش شناسی مدل خوشه‌بندی نواحی ترافیکی

#### بر اساس داده‌های مکانی

نواحی ترافیکی دارای مساحت ساخته شده (مسکونی، تجاری، آموزشی و غیره) و تراکم جمعیتی متفاوتی هستند. این ویژگی‌های مکانی بر تقاضای حمل و نقل عمومی و بر تصمیمات برنامه‌ریزی مانند تخصیص ناوگان و توزیع کاربری زمین تأثیر می‌گذارد. هدف این بخش شناسایی گروه‌های متمایز از نواحی ترافیکی بر اساس مساحت ساخته شده، جمعیت و تقاضای حمل و نقل عمومی است. برای تحلیل روابط این بخش، از خوشه‌بندی Mean Shift استفاده می‌شود. این روش به خوشه‌های از پیش تعریف شده یا دانش شکل توزیع آنها نیاز ندارد (Comaniciu and Meer, 2002; Georgescu et al., 2003; Zhu et al., 2022). تنها پارامتر مورد نیاز، پهنای باند است که به عنوان شعاع جستجو برای نقاط داده در اطراف یک مرکز خوشه عمل می‌کند (Demirović, 2019; Netzer et al., 2020). انتخاب پهنای باند بهینه، چالش مهمی در تحلیل خوشه‌بندی ایجاد می‌کند. در این مطالعه، از کتابخانه Scikit-learn پایتون برای خوشه‌بندی مناطق ترافیکی استفاده شده است. تابع داخلی کتابخانه، "sklearn.cluster.estimate"

مکانی و پوشش، و ساختار و برنامه‌ریزی سازمانی از هم جدا شدند. لذا جداول جداگانه برای تراکنش‌های اتوبوس و مترو ایجاد می‌شود. این جداسازی امکان تجزیه و تحلیل مناسب را با در نظر گرفتن تفاوت‌های بالقوه در الگوهای سفر بین دو نوع حمل و نقل عمومی فراهم می‌کند. در هر جدول، تراکنش‌ها بر اساس زمان تراکنش به ترتیب صعودی مرتب می‌شوند. این ترتیب زمانی مراحل تجمیع بعدی را تسهیل می‌کند. ناحیه ترافیکی برای هر تراکنش با استفاده از اطلاعات ایستگاه مربوطه مشخص می‌شود. این مرحله داده‌های تراکنش را با مناطق جغرافیایی خاص مرتبط می‌کند و فرآیند خوشه‌بندی را قادر می‌سازد تا توزیع مکانی استفاده از حمل و نقل عمومی را در نظر بگیرد. پس از مرتب‌سازی و شناسایی ناحیه، داده‌های تراکنش تجمیع زمانی شده تا الگوهای سفر را در بازه‌های زمانی ثبت کنند. این تجمیع در دو مرحله به دست می‌آید:

- **تجمیع ساعتی:** تعداد تراکنش‌های هر ایستگاه با فواصل یک ساعته برای هر روز تجمیع می‌شود. این یک تصویر دقیق از نحوه نوسانات حجم تراکنش در طول روز در هر ایستگاه ارائه می‌دهد.

- **تجمیع درون ناحیه‌ای:** بعد از تجمیع ساعتی برای هر ایستگاه،

تراکنش‌های بین ایستگاه‌های واقع در همان ناحیه ترافیکی تجمیع می‌شوند. در اینجا نیز فواصل یک ساعته در نظر گرفته شده است. این مرحله تعداد دفعات انجام تراکنش‌ها در یک ناحیه را مشخص می‌کند که منعکس کننده حرکت داخلی مسافران در آن منطقه خاص است.

برای در نظر گرفتن تغییرات بالقوه در رفتار سفر در زمان‌های مختلف روز، مرحله نهایی شامل جمع‌آوری داده‌ها در دوره‌های زمانی است. تراکنش‌های تجمعی برای هر ناحیه در سه دوره مجزا محاسبه می‌شود: صبح (۰۰:۰۰ - ۱۱:۰۰)، ظهر (۱۱:۰۰ - ۱۷:۰۰) و عصر (۱۷:۰۰ - ۲۴:۰۰). تعاریف این دوره‌ها بر اساس «مطالعه تعیین سیاست‌های جمع‌آوری کرایه حمل و نقل عمومی

• مساحت ساخته شده کاربری‌های مسکونی - تجاری با توجه به تغییرات بالقوه در مقیاس داده‌ها و پراکندگی در مجموعه داده‌ها، یک فرآیند استانداردسازی برای بهبود دقت پیش‌بینی مدل اجرا شد. این فرآیند داده‌ها را به گونه‌ای تبدیل می‌کند که میانگین صفر و انحراف استاندارد یک می‌شود و نقاط پرت تأثیر کمتری بر مدل دارند.

### ۳-۳ محدودده مورد مطالعه

مشهد شهری با بیش از ۳ میلیون نفر جمعیت دومین کلان‌شهر کشور است. براساس تقسیمات ترافیکی این شهر به ۲۵۳ ناحیه ترافیکی تقسیم شده است (Statistics of Mashhad, 2020; Demographia, 2023). جدول ۲ خلاصه اطلاعات حمل‌ونقل عمومی شهر مشهد در سال ۱۳۹۸ را نمایش می‌دهد. روش رایج در پرداخت کرایه حمل‌ونقل عمومی شهر مشهد استفاده از من کارت که یک کارت هوشمند است، در زمان سوار شدن به اتوبوس و یا در ایستگاه مبدأ قطارشهری می‌باشد؛ به‌طوری‌که مسافر با نزدیک کردن کارت خود به دستگاه‌های پرداخت، کرایه خود را پرداخت می‌کند. مبنای این مطالعه برای دستیابی به اهداف آن بر داده‌های تراکنش‌های من کارت که از طریق شهرداری مشهد در دسترس قرار گرفته، تکیه دارد. **Error!** **Reference source not found.** نقشه ایستگاه‌ها و خطوط اتوبوسرانی و مترو در مشهد را در نواحی ترافیکی نشان می‌دهد.

جدول ۲. خلاصه اطلاعات حمل‌ونقل عمومی شهر مشهد

عنوان	اتوبوس‌رانی	قطارشهری
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	

"bandwidth"، به طور خودکار پهنای باند بهینه را با تجزیه و تحلیل توزیع داده‌ها و فواصل جفتی بین نقاط محاسبه می‌کند. داده‌هایی که در این بخش مورد استفاده و نسبت به آماده‌سازی آنها اقدام می‌شود عبارتند از:

• **اطلاعات تقاضا:** سیستم جمع‌آوری کرایه مشهد فقط داده‌های ورودی را ثبت می‌کند و اطلاعاتی در مورد مقصد مسافر ندارد. برای رفع این محدودیت، محققان از مدل زنجیره سفر بهبود یافته (Radfar et al., 2025) با استفاده از مجموعه داده‌های یکساله کرایه موجود در سال ۱۳۹۸ استفاده کردند. این روش، تخمین مقصد و تولید ماتریس‌های مبدأ - مقصد روزانه و سالانه حمل‌ونقل عمومی را بر اساس نواحی ترافیکی امکان‌پذیر می‌کند، که سپس از آنها به‌عنوان داده‌های تقاضا استفاده می‌شود.

• **داده‌های مکانی:** تقاضای ترافیک تحت تأثیر ویژگی‌های یک منطقه مانند کاربری زمین و جمعیت شناخته شده است. محققان رابطه بین حمل‌ونقل و کاربری زمین را مورد بررسی قرار دادند و اذعان داشتند که چگونه الگوهای سفر با الگوهای کاربری زمین شهری ارتباط نزدیک دارد. برای این مطالعه، اطلاعات کاربری زمین‌های شهری بر اساس معیارهای طبقه‌بندی کاربری اراضی موجود مختص شهر مشهد در سیزده گروه مجزا طبقه‌بندی و برای مدیریت فرآیند آماده‌سازی آنها از نرم‌افزار ArcGIS 9.3 استفاده شد.

برای شناسایی مؤثرترین ویژگی‌های تأثیرگذار بر متغیر وابسته (تقاضا)، از الگوریتم جنگل تصادفی (Tin Kam Ho, 1995; Tin Kam Ho, 1998; Zhou et al., 2021) استفاده شد. با اجرای الگوریتم، ویژگی‌های زیر به‌عنوان مؤثر شناسایی شدند:

- جمعیت ناحیه
- مساحت ناحیه
- مساحت ساخته شده کاربری‌های مسکونی
- مساحت ساخته شده کاربری‌های تجاری
- مساحت ساخته شده کاربری‌های آموزشی

## کشف الگوهای مکانی-زمانی سفر در حمل و نقل عمومی شهری: بینش‌هایی از تحلیل داده‌های کارت هوشمند

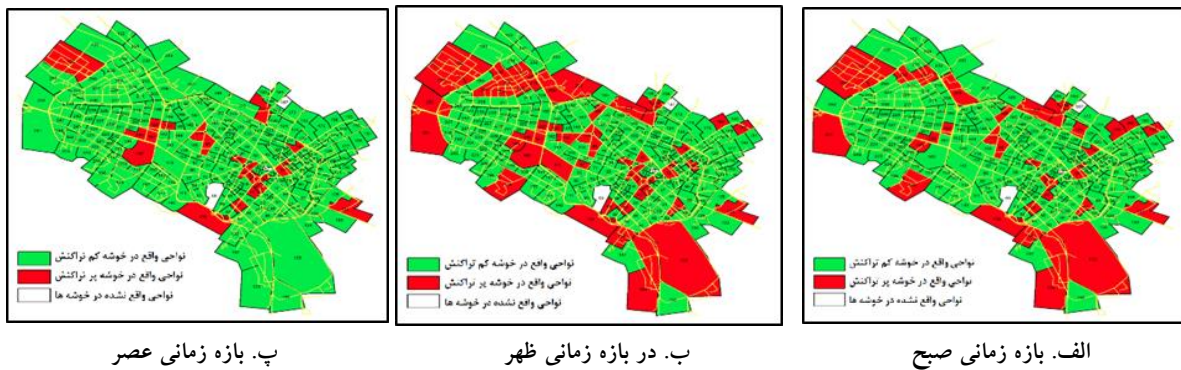
### ۴. تحلیل داده‌ها

در این بخش به بیان نتایج حاصل از الگوریتم‌های خوشه‌بندی استفاده شده و بحث در مورد آنها پرداخته خواهد شد.

#### ۱-۴ الگوهای زمانی

الگوریتم K-Means نواحی ترافیکی برای حمل و نقل اتوبوس را به دو خوشه «کم تراکنش» (خوشه صفر) و «پر تراکنش»

(خوشه یک)، برای هر بازه زمانی صبح، ظهر و عصر تقسیم می‌کند (شکل ۱). همچنین برای قطارشهری، هفت خوشه از «بسیار بسیار کم تراکنش» تا «بسیار بسیار پر تراکنش» (خوشه‌های صفر تا شش) این تقسیم‌بندی در بازه‌های زمانی صورت می‌پذیرد (شکل ۲ **Error! Reference source not found.**).



شکل ۱. موقعیت مکانی خوشه‌های نواحی ترافیکی اتوبوس‌رانی



شکل ۲. موقعیت مکانی خوشه‌های نواحی ترافیکی قطارشهری

در این بخش الگوهای مکانی و زمانی که در خوشه‌های نواحی ترافیکی شناسایی شده‌اند، با استفاده از داده‌های جمعیتی، کاربری زمین و ماتریس سالانه مبدأ-مقصد مورد بررسی قرار می‌گیرند.

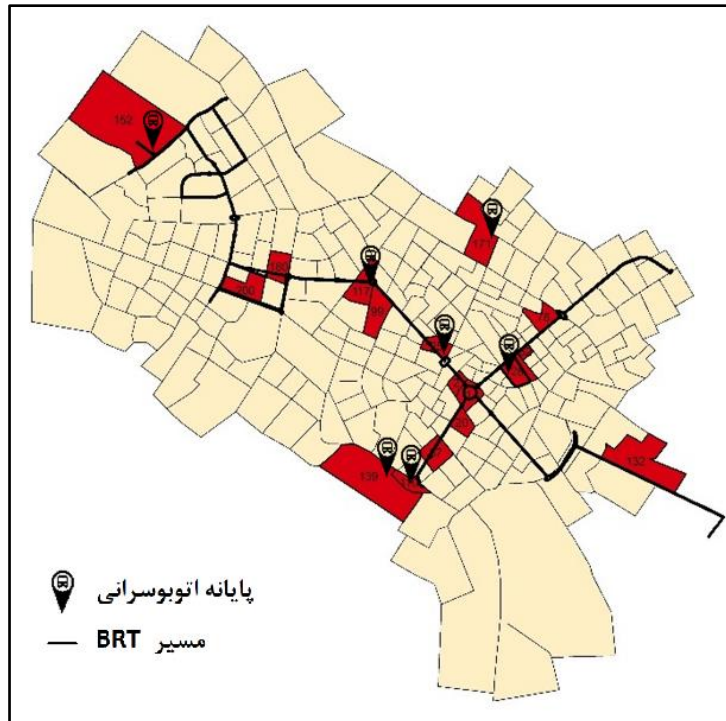
#### ۱-۴ سفرهای اتوبوس

تجزیه و تحلیل تراکنش‌های اتوبوس در سه بازه زمانی الگوهای متمایزی را نشان داد:

- کم تراکنش: ۱۹۷ (۷۸ درصد) از ۲۵۳ ناحیه ترافیکی تراکنش‌های پایینی را در تمام دوره‌ها به نمایش گذاشتند.

- پر تراکنش: ۵۶ ناحیه (۲۲ درصد) تراکنش‌های بالا را در حداقل یک بازه زمانی نمایش می‌دهند.
- تعداد ۲۳ ناحیه سطوح تراکنش متفاوتی را بین صبح و ظهر نشان دادند. در مجموع ۳۵، ۵۲ و ۲۴ ناحیه به ترتیب در خوشه «پر تراکنش» در بازه‌های صبح، ظهر و عصر قرار داشتند. قابل ذکر است که ۱۷ ناحیه به‌طور مداوم در هر سه بازه زمانی در این خوشه قرار می‌گیرند. این نواحی که در شکل ۳ نمایش داده شده‌اند حداقل یکی از ویژگی‌های زیر را دارند:

- وجود خط اتوبوس BRT که سفر با سرعت بالا را از طریق مسیرهای اختصاصی ارائه می دهد.
- محل ایستگاه ترانسفر اتوبوس که تبادل مسافر از مسیرهای متعدد را تسهیل می کند.




شکل ۳. موقعیت مکانی نواحی ترافیکی پرتراکنش در همه خوشه های زمانی اتوبوسرانی

گرفتند) نمایش می دهد. این موضوع نقش آنها به عنوان نقاط مبدأ برای مسافرانی که صبح ها به مناطق دیگر سفر می کنند و در هنگام عصر از طریق آن به مبدأ بازگشت می کنند را نشان می دهد.

تجزیه و تحلیل بیشتر بر روی نواحی خوشه بندی شده در هر دو گروه صبح و عصر اتوبوس متمرکز شد. شکل ۴ تعداد ۱۶ ناحیه که عمدتاً در مناطق پیرامونی شهر قرار دارند و از جمعیت بالایی از ساکنین برخوردار هستند (۱۳ منطقه در سه دهک برتر قرار

## کشف الگوهای مکانی-زمانی سفر در حمل و نقل عمومی شهری: بینش‌هایی از تحلیل داده‌های کارت هوشمند



شکل ۴. موقعیت مکانی نواحی ترافیکی پرتراکنش در خوشه‌های صبح و ظهر اتوبوس‌رانی

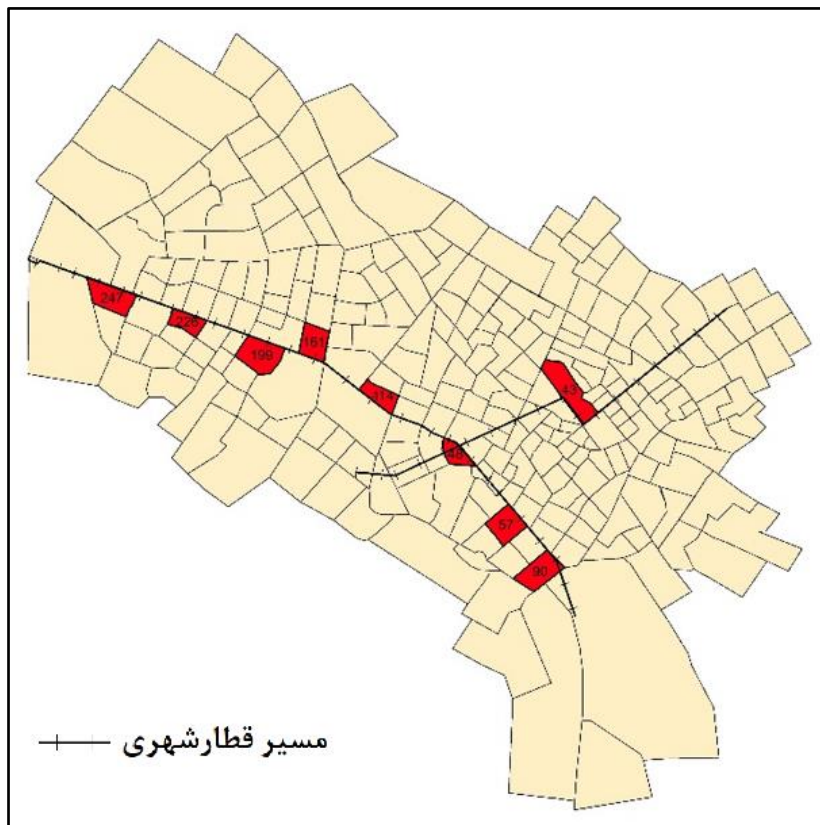
این مناطق ممکن است به‌عنوان «کم تراکنش» در خوشه‌های خدمات اتوبوس طبقه‌بندی شوند، که معمولاً پوشش منطقه‌ای گسترده‌تری را ارائه می‌دهند.

تعداد ۹ ناحیه به‌طور پیوسته سطوح تراکنش بالاتر از میانگین را در هر سه دوره زمانی به نمایش گذاشتند (شکل ۵). هیچ مشخصه تعیین‌کننده واحدی برای همه این نواحی ظاهر نشد. با این حال، تجزیه و تحلیل جداگانه آنها برای مشخص کردن دلایل خاص الگوهای تراکنش بالا نشان داد که نواحی ترافیکی ۴۳ و ۱۶۱ دهک اول جمعیت و مساحت ساخته شده کاربری‌های مسکونی، تجاری و آموزشی را دارند. علاوه بر این، ناحیه ۴۳ از وجود «ایستگاه راه‌آهن حومه‌ای» در مجاورت ایستگاه مترو بهره‌مند است؛ در حالی که منطقه ۱۶۱ دارای «پارک ملت» و یک پایانه اتوبوس در نزدیکی ایستگاه مترو بود که به‌طور بالقوه به تراکنش‌های مداوم آنها کمک می‌کند. تقاطع خطوط ۱ و ۲ مترو در ناحیه ترافیکی ۴۸ نیز ممکن است گنجاندن آن در این مجموعه از نواحی پرتراکنش را توضیح دهد.

نواحی ترافیکی ۹۹، ۱۳۲، ۱۵۲، ۱۷۱، ۱۸۰ و ۲۰۰ نمونه‌ای از الگوهایی با همبستگی قوی بین تراکم جمعیت و کاربری‌های زمین در تولید/تقاضای سفر بالا هستند، که عضویت در خوشه صبحگاهی آنها، منعکس‌کننده این موضوع است. علاوه بر این، رتبه سه دهک برتر آنها در کاربری مسکونی نیز این ارتباط را بیشتر تقویت می‌کند. برعکس، کاربری‌های آموزشی یا تجاری در این مناطق، که در سه دهک برتر نیز قرار گرفته‌اند، احتمالاً به تراکنش‌های بالا در خوشه‌های ظهر و عصر کمک می‌کنند که نشان‌دهنده پایان سفرهای مرتبط با این اهداف است. بررسی ماتریس سالانه OD این تحلیل را تأیید کرد، به‌طوری‌که فرکانس سفرهای درون ناحیه‌ای در این نواحی، در مقایسه با فرکانس سفرهای از مبدأ یا مقصد هر یک از مناطق دیگر به مقصد یا مبدأ این نواحی بالاتر است.

### ۴-۱-۲ سفرهای مترو

تمامی نواحی ترافیکی واقع در مسیر مترو از نظر تولید سفر سالانه در سه دهک برتر قرار دارند. جالب توجه است، برخی از



شکل ۵. موقعیت مکانی نواحی ترافیکی دارای تراکنش بیشتر از متوسط در همه خوشه‌های قطار شهری


ترافیکی ۵۷ عبور می‌کند که دسترسی مستقیم به مهم‌ترین مقصد گردشگری شهر یعنی «حرم مطهر امام رضا (ع)» را فراهم می‌کند. همچنین تقاطع ناحیه با خط ۱ مترو، باعث تقویت بیشتر موضوع و تقاضای سفر بیشتر شده است. این یافته تأثیر قابل توجه زیرساخت‌های حمل‌ونقل عمومی و جاذبه‌های کلیدی را بر الگوهای ترافیکی در مناطق خاص برجسته می‌کند.

#### ۲-۴ الگوهای مکانی

پس از اجرای الگوریتم Mean Shift، نواحی ترافیکی در ۸ خوشه طبقه‌بندی شدند. با توجه به ماهیت ویژگی‌های مورد استفاده قرار گرفته در خوشه‌بندی و ابعاد مختلف هر مشاهده در مجموعه داده، نقشه‌های گرافیکی بر اساس موقعیت مکانی درک بهتری را ایجاد خواهند کرد. شکل ۶ خوشه هر ناحیه ترافیکی را روی نقشه شهر مشهد نشان می‌دهد.

چهار ناحیه ۳۶، ۷۱، ۹۷ و ۱۴۳ الگوهای تراکنش متضادی را نشان دادند - کمتر از میانگین در خوشه صبح و بالاتر از میانگین در خوشه‌های ظهر و عصر - بررسی کاربری‌ها نشان داد که مساحت تجاری ساخته شده در هر یک از این پهنه‌ها متعلق به سه دهک بالا است. شروع و پایان ساعات کاری در این نواحی تجاری دلیل تغییرات مشاهده شده در سطوح تراکنش در خوشه‌های زمانی مختلف است.

نکته قابل توجه، ناحیه ترافیکی ۵۷ به‌عنوان یک مورد منحصر به فرد ظاهر شد که سطوح تراکنش بالا را در تمام دوره‌های زمانی اتوبوس و مترو نشان می‌داد. این ناحیه از نظر تولید سفر در رتبه دوم و در جذب سفر سالانه رتبه اول را به خود اختصاص داده است؛ در حالی که جمعیت (دهک ششم) و کاربری‌های مسکونی و تجاری ساخته شده (دهک نهم)، عوامل برجسته‌ای در این ناحیه نبودند. عاملی که نقش مهمی در این ناحیه ایفا می‌کند، موقعیت استراتژیک آن است. بخشی از خط ۱ بی‌آرتی، از ناحیه




شکل ۶. موقعیت مکانی خوشه‌بندی نواحی ترافیکی

سفر متمرکز شد. بر این اساس خوشه‌ها دارای ویژگی‌های زیر هستند:

- خوشه ۰ (۲۳۶ عضو): نواحی موجود در آن دهک‌های مختلفی از کاربری‌ها، جمعیت و تقاضا هستند.
- خوشه ۱ (۷ عضو): نواحی این خوشه در دهک ۱۰ کاربری آموزشی ساخته شده قرار دارند.
- خوشه‌های ۲ و ۴ (۱ عضو): شامل تعدادی از نواحی حاشیه ای و دارای دهک ۱۰ برای همه کاربری‌های ساخته شده و جمعیت هستند و تقاضای سفر بالایی دارند.
- خوشه ۳ (۳ عضو): نواحی آن در دهک ۱۰ برای جمعیت و کاربری مسکونی و تجاری ساخته شده و دهک ۶ و ۸ تقاضا هستند.

به‌منظور درک بهتری از پراکندگی خوشه‌ها و مراکز آنها شکل ۷ خوشه‌ها و مراکز خوشه‌ها را نمایش می‌دهد. در این تصاویر علامت (x) مراکز خوشه‌ها و هر محور بیانگر یک ویژگی می‌باشد که مقدار آن در فضا مشخص شده است.



شکل ۷. نمایش پراکندگی خوشه‌ها و مراکز آنها

تجزیه و تحلیل مکانی بر شناسایی ویژگی‌های خوشه بر اساس مساحت کاربری‌های ساخته شده تأثیرگذار، جمعیت و تقاضای فصلنامه مهندسی حمل و نقل / سال هفدهم / شماره دوم (۶۷) / زمستان ۱۴۰۴

ترانزیتی نسبت می دهند ( MA et al., 2017; Gao et al., 2018). باوتیستا هرناوندز (۲۰۲۰) نشان می دهد که برای کاربران حمل و نقل عمومی، دسترسی به شغل، تراکم جمعیت و کاربری مختلط زمین در مبدأ تأثیر بیشتری بر تعداد سفرها دارد (Bautista-Hernández, 2020). بریاند و همکاران (۲۰۱۶) مناطقی را که مردم عمدتاً صبح‌ها از آنجا خارج می شوند به عنوان محل سکونت و آنهایی که در عصر از آنجا حرکت می کنند به عنوان محل کار نسبت می دهند (Briand et al., 2016). کای و همکاران (۲۰۱۸) معتقدند که ویژگی های یک ناحیه و جاذبه های سفر آن یک عامل مهم و تأثیرگذار در الگوهای سفر آن منطقه است (Qi et al., 2018).

## ۵. نتیجه گیری و ارائه پیشنهادها

این مطالعه از تحلیل خوشه بندی مبتنی بر ناحیه برای بررسی الگوهای زمانی و مکانی سفرهای حمل و نقل عمومی استفاده کرد. داده های کارت هوشمند و ماتریس سالانه مبدأ - مقصد برای حمل و نقل عمومی، پایه و اساس این تحلیل را فراهم کرد. داده های تراکنش کارت هوشمند، بینش های ارزشمندی را در مورد استفاده از شبکه در دنیای واقعی ارائه می دهد و سفرهای فردی کاربر را در زمان ها و مکان های خاص ثبت می کند. این داده ها خوشه بندی زمانی نواحی ترافیکی را در دوره های حمل و نقل عمومی صبح، ظهر و عصر تسهیل کرد. خوشه بندی بر اساس تراکنش های ورودی در هر ناحیه بود. برای انجام خوشه بندی زمانی نواحی از الگوریتم K-Means استفاده شده است. همچنین در خوشه بندی مکانی از الگوریتم Mean Shift و تقاضای (جذب) سفر در کنار متغیرهای مکانی استفاده گردید. این متغیرهای مکانی شامل داده های جمعیت و مساحت ساخته شده برای کاربری های مختلف زمین (به عنوان مثال مسکونی، تجاری و آموزشی) در هر ناحیه بود. این تحقیق با تغییر تمرکز خوشه بندی از ایستگاه ها به نواحی ترافیکی خود را متمایز کرد. علاوه بر این، به جای تجزیه و تحلیل ویژگی های مکانی در اطراف ایستگاه ها، کل جمعیت و کاربری های ساخته شده را در

• خوشه ۵ (۳ عضو): نواحی آن در دهک ۱۰ برای جمعیت و کاربری مسکونی و آموزشی ساخته شده و دهک ۶ و ۸ تقاضا قرار دارند.

• خوشه ۶ (۱ عضو): تنها ناحیه این خوشه دارای جمعیت بالا (دهک ۹)، کاربری تجاری ساخته شده بالا (دهک ۱۰) و دهک ۷ تقاضا است.

• خوشه ۷ (۱ عضو): جمعیت و کاربری مسکونی ساخته شده بالا (دهک ۱۰ بالا) اما تقاضای کم (دهک اول) ویژگی ناحیه این خوشه است.

نتایج تحلیلی این مطالعه تأثیر عواملی مانند کاربری زمین، جمعیت، خطوط BRT و جاذبه های اصلی را بر روی الگوهای مکانی و زمانی تقاضای ناحیه ترافیکی برجسته می کند. به کارگیری الگوریتم جنگل تصادفی برای شناسایی مؤثرترین متغیرهای مستقل بر تقاضای حمل و نقل عمومی، یافته های ژانگ و جو (۲۰۲۲) را برای جمعیت و یافته های سارکار و مالیکارجونا (۲۰۱۳)، هو و همکاران (۲۰۱۶)، کیم و همکاران (۲۰۱۸)، ژو و همکاران (۲۰۱۹)، کای و همکاران (۲۰۲۰)، لیو و همکاران (۲۰۲۱) و چنگ و همکاران (۲۰۲۴) را برای مؤثرترین انواع کاربری زمین تأیید می کند ( Zhang and Xu, 2022; Sarkar and Mallikarjuna, 2013; Hu et al., 2016; Kim et al., 2018; Zhou et al., 2019; Cai et al., 2020; Liu et al., 2021; Cheng et al., 2024). یافته های گزارش شده در تعدادی از مطالعات با نتایج این تحقیق مطابقت دارد و یافته های آن را تأیید می کند، مانند دینگ و لو (۲۰۱۶) و کیم و همکاران (۲۰۱۸) که الگوهای کاربری زمین را دارای تأثیر قابل توجهی بر رفتار سفر مردم در نظر می گیرند (Ding and Lu, 2016; Kim et al., 2018). آنها همچنین بر این باورند که جمعیت و تنوع کاربری زمین تأثیرات مثبتی بر تعداد سفرها خواهد داشت. ما و همکاران (۲۰۱۷) و گائو و همکاران (۲۰۱۸) عدم تعادل بین فرصت های شغلی در مناطق مرکزی شهر با سکونتگاه ها در مناطق حومه شهر و همچنین قیمت پایین مسکن در این مناطق را، به ایجاد سفر توسط مسافران

Complexity in the Mexico City Metropolitan Area. *Urban, Planning and Transport Research*, 8(1), 71-96.

doi:10.1080/21650020.2019.1708784

– 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

– 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

– 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

– 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

– Cats, O. (2024). Identifying human mobility patterns using smart card data. *Transport Reviews*, 44(1), 213-243.

doi:10.1080/01441647.2023.2251688

– 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

خود نواحی ترافیکی مورد بررسی قرار داد. این رویکرد دامنه تشخیص الگو را از سطح ایستگاه به کل شبکه و سطح شهر گسترش می‌دهد. همچنین با استفاده از داده‌های تراکنش یک ساله کرایه، مقصد سفر، استنباط و ماتریس مبدأ - مقصد حمل و نقل عمومی به‌عنوان یکی از ورودی‌های فرآیند خوشه بندی تولید شد.

استفاده از نظرسنجی‌های سفرهای خانگی، داده‌های مکانی و داده‌های کارت هوشمند در سایر سال‌ها برای بهبود دقت و قابلیت اطمینان برآورد ایستگاه مقصد و همچنین به روزرسانی تغییرات احتمالی الگوهای سفر و استفاده از سایر الگوریتم‌های خوشه‌بندی و مقایسه نتایج آنها با توجه به بهره‌برداری از خطوط جدید قطار شهری و نیز اصلاحات انجام شده در مسیرها و ایستگاه‌های اتوبوسرانی، به عنوان پیشنهادات مطالعات آتی در زمینه موضوع این پژوهش می‌باشند.

یافته‌های این مطالعه برای تصمیم‌گیرندگان و برنامه‌ریزان در حوزه‌های حمل و نقل و شهرسازی ارزش قابل توجهی دارد. با آشکارسازی الگوهای تقاضای زمانی و مکانی، این تحقیق می‌تواند سیاست‌های بهینه‌سازی توزیع انواع کاربری زمین در مناطق مختلف، کاهش سفرهای غیرضروری، اختصاص تعداد ناوگان مناسب برای حمل و نقل عمومی و در نهایت بهبود ارائه خدمات و افزایش رضایت کاربران را فراهم نماید.

## ۶. مراجع

– Agard, B., Morency, C., & Trépanier, M. (2006). Mining public transport user behaviour from smart card data. *IFAC Proceedings Volumes*, 39(3), 399-404.

doi:10.3182/20060517-3-FR-2903.00211

– Anda, C., Fourie, P., & Erath, A. (2017). Transport Modelling in the Age of Big Data. *International Journal of Urban Sciences*, 21, 1-24. doi:10.1080/12265934.2017.1281150

– Bautista-Hernández, D. (2020). Urban Structure and Its Influence on Trip Chaining

- 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
- 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.
- 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
- 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
- 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
- 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
- Georgescu, B., Shimshoni, I., & Meer, P. (2003). Mean Shift Based Clustering in High
- Cheng, J., Liu, G., Gao, S., Raza, A., Li, J., & Juan, W. (2024). Short-Term Passenger Flow Prediction in Urban Rail Transit Based on Points of Interest. *IEEE Access*, 12, 95196 - 95208. doi:10.1109/ACCESS.2024.3425634
- 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
- Comaniciu, D., & Meer, P. (2002). Mean shift: a robust approach toward feature space analysis. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 24(5), 603-619. doi:10.1109/34.1000236
- Demirović, D. (2019). An Implementation of the Mean Shift Algorithm. *Image Processing On Line*, 9, 251-268. doi:0.5201/ipol.2019.255
- Demographia. (2023). Demographia world urban areas: 19th annual edition . Demographia. Retrieved from <http://www.demographia.com/db-worldua.pdf>
- 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
- 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

- 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
- 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
- Kieu, M., Bhaskar, A., & Chung, E. (2015b). Passenger Segmentation Using Smart Card Data. *IEEE Transactions on Intelligent Transportation Systems*, 16(3), 1537 - 1548.  
doi:10.1109/TITS.2014.2368998
- 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
- 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
- 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, 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
- Dimensions: A Texture Classification Example. *Proceedings Ninth IEEE International Conference on Computer Vision*. 1, pp. 456-463. Nice, France: IEEE Xplore.  
doi:10.1109/ICCV.2003.1238382
- Gohar, M., Muzammal, M., & Ur Rahman, A. (2018). SMART TSS: Defining transportation system behavior using big data analytics in smart cities. *Sustainable Cities and Society*, 41, 114-119.  
doi:10.1016/j.scs.2018.05.008
- 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
- 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
- Han, G., & Sohn, K. (2016). Clustering the seoul metropolitan area by travel patterns based on a deep belief network. *2016 3rd MEC International Conference on Big Data and Smart City (ICBDSC)*, (pp. 1-6).  
doi:10.1109/ICBDSC.2016.7460351
- Han, J., Kamber, M., & Pei, J. (2012). *Data Mining: Concepts and Techniques* (Third ed.). Morgan Kaufmann.
- 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

doi:10.1016/j.trc.2013.07.010

– 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).

– 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

– Mashhad Statistics. (2020). Retrieved from <https://planning.mashhad.ir>.

– 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

– 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

– Nagarkar, S. (2017). Data mining Applications for Smart city: A Review. *I J C T A*, 10(8), 705-710.

– 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

– 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

– 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

– 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

– Liu, X., Wu, J., Huang, J., Zhang, J., Chen, B., & Chen, A. (2021). Spatial-interaction network analysis of built environmental influence on daily public transport demand. *Journal of Transport Geography*, 92.

doi:10.1016/j.jtrangeo.2021.102991

– 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

– 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

– 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

– 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.

Card Data in Shenzhen, China. *Sustainability*, 12(4), 1475.

doi:10.3390/su12041475

– 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

– 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

– 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

– 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

– Zannat, K. E., & Choudhury, C. (2019). Emerging Big Data Sources for Public Transport Planning: A Systematic Review on Current State of Art and Future Research Directions. *Journal of the Indian Institute of Science*, 99, 601-619.

– 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

– 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

– Radfar, S., Koosha, H., Gholami, A., & Amindoust, A. (2025). A neuro-fuzzy and deep learning framework for accurate public transport demand forecasting: Leveraging spatial and temporal factors. *Journal of Transport Geography*, 126, 104207.

doi:10.1016/j.jtrangeo.2025.104217

– Rajaei, A., Moghadam, Z., Poodinehmoghadam, A., & sargolzaei, E. (2017). The Role of Data Mining in a Smart City: A literature Review. *International Journal of Computer Science and Software Engineering (IJCSSE)*, 6(4), 83-88.

– 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

– Tang, J., Wang, X., Zong, F., & Hu, Z. (2020). Uncovering Spatio-temporal Travel Patterns Using a Tensor-based Model from Metro Smart

- 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
- 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
- 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
- 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
- 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
- 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., 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
- 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
- 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
- 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