



## Estimating the travel modes using machine learning algorithms for sustainable urban transportation

Omid Shamohammadi<sup>1</sup> | Parham Pahlavani<sup>2\*</sup> | Mohammad Ali Sharifi<sup>3</sup>

1. Department of GIS, School of Surveying and Geospatial Engineering, College of Engineering, University of Tehran, Tehran, Iran. Email: [omid.shamohammadi@ut.ac.ir](mailto:omid.shamohammadi@ut.ac.ir)

2. Corresponding Author, Department of GIS, School of Surveying and Geospatial Engineering, College of Engineering, University of Tehran, Tehran, Iran. Email: [pahlavani@ut.ac.ir](mailto:pahlavani@ut.ac.ir)

3. Department of Geodesy, School of Surveying and Geospatial Engineering, College of Engineering, University of Tehran, Tehran, Iran. E-mail: [sharifi@ut.ac.ir](mailto:sharifi@ut.ac.ir)

### ARTICLE INFO

#### Article type:

Research Article

#### Article History:

Received December 29, 2023

Revised January 30, 2024

Accepted February 04, 2024

Published online 17 February 2025

#### Keywords:

Sustainable urban transportation,  
Travel modes,  
Streaming GNSS,  
Feature extraction,  
Supervised classification algorithms.

### ABSTRACT

A significant portion of daily urban intra-city trips is aimed at accessing services, amenities, and goods that are not readily available in a specific area. Therefore, analyzing the frequently used trajectory and identifying the reasons for high traffic volumes on these trajectories can lead to a more accurate distribution of facilities, services, and proper land use allocation with the goal of reducing the number, distance, and time of intra-city trips. With the advent of Global Navigation Satellite Systems (GNSS) positioning sensors on smartphones, the real-time collection of individuals' positions, speed, acceleration, and more has become possible. Consequently, this research has sought to examine the possibility of using GNSS data recorded by smartphones to identify the transportation mode used by the user through four supervised machine learning models named Random Forest (RF), Gradient Boosting (GB), eXtreme Gradient Boosting (XGB), and Light Gradient Boosting Model (LightGM). For this purpose, two datasets, Microsoft Geolife and MTL 2017, which possess the necessary features for this goal, have been used as the input data. After extracting the features of each trajectory from these two datasets, with the aim of improving the models' performance and reducing processing time, among the available features, the most important ones have been identified, and classification has been applied based on them. Among the models used, the LightGM and XGB models achieved the best performance for the first and second datasets with respective F1-Scores of 92.57% and 92.67% for test data. Out of a total of 1349 trips, this algorithm accurately estimated 1250 trips, contributing to sustainable urban transportation.

**Cite this article:** Shamohammadi, O.; Pahlavani, P. & Sharifi, M. A. (2024-25). Estimating the travel modes using machine learning algorithms for sustainable urban transportation. *Town and Country Planning*. 16 (2), 239-254.  
<http://doi.org/10.22059/jtcp.2024.370374.670427>



© The Author(s).

**Publisher:** University of Tehran Press.

DOI: <http://doi.org/10.22059/jtcp.2024.370374.670427>



انتشارات دانشگاه تهران

## آمایش سرزمین

شایا الکترونیکی: ۲۴۲۳-۶۲۶۸

سایت نشریه: <https://jtcp@ut.ac.ir/>

# تخمین حالت‌های سفر به کمک الگوریتم‌های یادگیری ماشین به منظور حمل و نقل پایدار شهری

امید شامحمدی<sup>۱</sup> پرهام پهلوانی<sup>۲\*</sup> | محمدعلی شریفی<sup>۳</sup>

۱. گروه GIS، دانشکده مهندسی نقشه‌برداری و اطلاعات مکانی، دانشکدگان فنی، دانشگاه تهران، تهران، ایران. رایانame: [omid.shamohammadi@ut.ac.ir](mailto:omid.shamohammadi@ut.ac.ir)  
۲. نویسنده مسئول، گروه GIS، دانشکده مهندسی نقشه‌برداری و اطلاعات مکانی، دانشکدگان فنی، دانشگاه تهران، تهران، ایران. رایانame: [pahlavani@ut.ac.ir](mailto:pahlavani@ut.ac.ir)  
۳. گروه رئودزی، دانشکده مهندسی نقشه‌برداری و اطلاعات مکانی، دانشکدگان فنی، دانشگاه تهران، تهران، ایران. رایانame: [sharifi@ut.ac.ir](mailto:sharifi@ut.ac.ir)

## چکیده

## اطلاعات مقاله

بخش زیادی از سفرهای روزانه درون شهری با هدف دسترسی به خدمات، سرویس‌ها، و کالاهایی است که امکان تهیه آن‌ها در یک منطقه مشخص وجود ندارد. از این رو، آنالیز مسیرهای پرتردد و علت حجم بالای ترافیک در آن‌ها می‌تواند به توزیع صحیح‌تر امکانات، خدمات، و اختصاص کاربری مناسب به زمین‌ها با هدف کاهش تعداد و مسافت و زمان سفرهای درون شهری منجر شود. با ظهور سنسورهای تعیین موقعیت مبتنی بر سامانه‌های جهانی ناوبری ماهواره‌ای بر تلفن‌های همراه، امکان ثبت آنی مواردی چون موقعیت و سرعت و شتاب افزاد به صورت آنی فراهم شده است. بنابراین، در این پژوهش تلاش شده امکان استفاده از اداده‌های GNSS ثبت‌شده توسط تلفن همراه با هدف شناسایی حالت حمل و نقلی که کاربر از آن استفاده کرده است توسط چهار مدل یادگیری ماشین نظارت شده با نام‌های *XGB*, *GB*, *RF*, *LightGM* و *MTL*. بدین منظور، دو مجموعه داده مایکروسافت *Geolife* و *2017 MTL*، که از ویژگی‌های لازم برای این هدف برخوردارند، به عنوان داده ورودی استفاده شد. پس از استخراج ویژگی‌های هر مسیر از این دو مجموعه داده، با هدف بهبود کارایی مدل‌ها و کاهش حجم پردازش، از میان ویژگی‌های موجود ویژگی‌های مهم‌تر شناسایی و کلاسه‌بندی بر اساس آن‌ها اعمال شد. بین مدل‌های استفاده شده، مدل *LightGM* برای مجموعه داده اول با کسب مقدار ۹۲/۵۷ درصد در *F1-Score* برای داده‌های تست و مدل *XGB* برای مجموعه داده دوم با کسب مقدار ۹۲/۶۷ در *F1-Score* برای داده‌های تست بین مدل‌های موجود بهترین عملکرد را داشته‌اند. از تعداد ۱۳۴۹ سفر موجود، ۱۲۵۰ سفر توسط این الگوریتم به درستی تخمین زده شد که منجر به حمل و نقل پایدار شهری می‌شود.

نوع مقاله:  
پژوهشی

تاریخ‌های مقاله:  
تاریخ دریافت: ۱۴۰۲/۱۰/۰۹  
تاریخ بازنگری: ۱۴۰۲/۱۱/۱۰  
تاریخ پذیرش: ۱۴۰۲/۱۱/۱۵  
تاریخ انتشار: ۱۴۰۳/۱۱/۲۹

کلیدواژه:  
استخراج ویژگی، الگوریتم‌های کلاسه‌بندی نظارت شده، جریان داده‌های GNSS، حالت‌های سفر، حمل و نقل پایدار شهری.

استناد: شامحمدی، امید؛ پهلوانی، پرهام و شریفی، محمدعلی (۱۴۰۳). تخمین حالت‌های سفر به کمک الگوریتم‌های یادگیری ماشین به منظور حمل و نقل پایدار شهری. آمایش سرزمین، ۱۶ (۲) ۲۳۹-۲۵۴. <http://doi.org/10.22059/jtcp.2024.370374.670427>

ناشر: مؤسسه انتشارات دانشگاه تهران.  
DOI: <http://doi.org/10.22059/jtcp.2024.370374.670427>



## مقدمه و بیان مسئله

انسان همواره برای رفع نیازهای خود، زنده ماندن، و تجسس و تفتيش در محل زندگی از ابتدای خلقت تا کنون در حال جابه‌جایی بوده است (Schlebusch & Jakobsson, 2018). گسترش محیط‌های شهری و افزایش بی‌رویه جمعیت در کلان‌شهرها سبب افزایش تقاضا برای جابه‌جایی‌های درون‌شهری شده است که از آثار آن می‌توان به ایجاد ترافیک، آلودگی هوای هدررفت زمان و انرژی اشاره کرد. از این‌رو، ارزیابی دقیق رفتار حرکتی افراد در جامعه به منظور درک حرکت و تأثیر آن بر فعالیت‌های شهروندان و حفاظت از محیط زیست امری ضروری برای برنامه‌ریزان شهری به منظور حمل و نقل پایدار شهری است (Martín-Baos et al., 2023).

حمل و نقل دومین هزینه کلان در زندگی افراد است. در مطالعات اتحادیه اروپا و امریکا، شهروندان به ترتیب به طور متوسط ۱۵ و ۲۵ درصد از کل هزینه‌های زندگی خود را صرف حمل و نقل می‌کنند (Wang et al., 2018). این مقدار می‌تواند معیاری از اهمیت حمل و نقل در فعالیت‌های انسانی در نظر گرفته شود.

بخش بسیاری از سفرهای صورت‌گرفته در طول روز با هدف دسترسی به کالاهای امکانات و خدماتی است که افراد در نزدیکی محل سکونت خود به آن‌ها دسترسی ندارند. مثلاً بخشی از سفرهای شهری با هدف دسترسی به امکانات یک ورزش خاص، نظیر زمین تنیس، صورت می‌گیرد؛ حال آنکه توزیع مناسب این امکانات در سطح یک شهر به طرز چشمگیری می‌تواند منجر به کاهش نیاز به حمل و نقل شود (Sun et al., 2023). آنالیز جابه‌جایی‌های صورت‌گرفته در سطح شهر و همچنین فرم حمل و نقل مورد استفاده در هر یک از آن‌ها، علاوه بر آنکه می‌تواند درک مناسبی از مسیرهای پرتردد فراهم آورد، در شناسایی هدف جابه‌جایی صورت‌گرفته نیز تأثیرگذار است (Kashifi et al., 2022). از این‌رو مدیران شهری می‌توانند متناسب با اهداف جابه‌جایی‌ها به بهبود توزیع امکانات در سطح شهر با ابزار تشخیص کاربری زمین پردازنند. چنین رخدادی باعث کاهش حجم سفرهای روزانه، مصرف انرژی، تولید گازهای گلخانه‌ای، و صرفه‌جویی در زمان می‌شود.

افراد برای سفرهای خود از روش‌های مختلف حمل و نقل - مانند پیاده‌روی، دوچرخه‌سواری، ماشین، اتوبوس، قطار - استفاده می‌کنند که به آن حالت‌های سفر می‌گویند. نحوه حرکت و طریقه استفاده شهریوندان از حالات حمل و نقلی از الگوی خاصی پیروی می‌کند. شناخت این الگوها موجب شناسایی حالت‌های حمل و نقلی شهریوندان خواهد شد. شناسایی دقیق حالت حمل و نقلی عاملی ضروری برای دولتها، شرکتها، و مؤسسات تحقیقاتی است تا رفتارهای انسانی را درک و سیستم‌های حمل و نقلی هوشمندی را راهاندازی کنند (Yazdizadeh et al., 2021). به منظور شناسایی و تخمین حالت‌های حمل و نقلی، اطلاعات دقیق سفرهای انجام‌شده افراد مورد نیاز است. گسترش استفاده از تلفن‌های هوشمند در دهه دوم قرن جاری، که جمع‌آوری موقعیت لحظه‌ای را به صورت برشط با استفاده از سنسورهای GNSS محقق کرده، منبع مناسبی برای استخراج این ویژگی‌ها و اطلاعات فراهم آورده است (Hasan et al., 2022). تحلیل و آنالیز داده‌های این سنسورها با هدف شناسایی حالت‌های سفر توسط محققان مختلف صورت پذیرفته است. با این حال، چنین تحلیلی به دلیل ناکافی بودن روش‌های تشخیص حالت حمل و نقل موجود همچنان نیاز به مطالعه بیشتر دارد (Al Momin et al., 2022).

با توجه به توانایی الگوریتم‌های یادگیری ماشین به عنوان ابزاری مناسب برای طبقه‌بندی اطلاعات گوناگون، در این پژوهش از چهار مدل یادگیری ماشین برای شناسایی حالت سفر استفاده شد. بدین منظور، مجموعه‌ای از ویژگی‌ها از داده‌های ثبت‌شده توسط سنسور GNSS تلفن‌های همراه کاربران استخراج شد. با هدف بهبود عملکرد و کاهش حجم پردازش‌های صورت‌گرفته شناسایی ویژگی‌های مؤثر و کاهش تعداد ویژگی‌ها با چهار روش انتخاب ویژگی با استفاده از K-best، استفاده از مدل RFEVCV، استفاده از Bult-in، و در نهایت انتخاب ویژگی با استفاده از الگوریتم ژنتیک مدنظر قرار داده شد.

## پیشینهٔ پژوهش

با پیشرفت و هوشمندی تلفن‌های همراه، تعداد حسگرهای مورد استفاده در ساخت آن‌ها رو به افزایش رفت. مطالعات زیادی از داده‌ها و حسگرهای متفاوت، برگرفته از داده‌های ثبت‌شده توسط تلفن‌های همراه هوشمند، برای شناسایی حالت‌های حمل و نقلی

استفاده کرده‌اند. برخی از مطالعات پیشین چالش استفاده تنها از داده‌های GPS<sup>1</sup> به صورت خام، بدون استفاده از داده‌های مکمل و حسگرهای دیگر، را مورد بررسی و پیش‌بینی قرار داده‌اند (Nawaz et al., 2020). مثلاً Li و همکارانش (۲۰۲۰) از مجموعه داده‌های GPS ثبت‌شده در شهر پکن کشور چین، Song و همکارانش (۲۰۱۶) از داده‌های GPS خام ثبت‌شده در کشور ژاپن، Yazdizadeh و همکارانش (۲۰۲۱) از داده‌های ثبت‌شده در شهر مونترال کشور کانادا، و Bolbol و همکارانش (۲۰۱۲) از داده‌های شهر لندن کشور انگلیس استفاده کردند.

در برخی مطالعات، از حسگرهای دیگر بدون استفاده وابستگی به حسگر GPS استفاده شده است. مثلاً Friedrich و همکارانش (۲۰۲۰) از مجموعه داده‌های مرکز تحقیقاتی<sup>2</sup> SHL شامل حسگرهای شتاب‌سنج، ژیروسکوپ، شتاب خطی، مغناطیس‌سنج، فشار‌سنج، جهت‌سنج، گرانش‌سنج، و موارد دیگر استفاده کردند.

مطالعات دیگری از حسگرهای هوشمند به عنوان حسگرهای مکمل در کنار داده‌های اخذشده از حسگر GPS استفاده کرده‌اند. Bantis & Haworth (۲۰۱۷) از حسگر شتاب‌سنج در کنار حسگر GPS، Byon & Liang (۲۰۱۴) از حسگرهای شتاب‌سنج و مغناطیس‌سنج و GPS، و در Jahangiri & Rakha (۲۰۱۵) از حسگرهای شتاب‌سنج و ژیروسکوپ و بردار چرخش در کنار حسگر GPS استفاده کردند.

برخی از مطالعات داده‌های محتوایی اجتماعی-جمعیتی نظیر سن، جنسیت، شغل، و اطلاعات اقتصادی-اجتماعی را در کنار داده‌های حاصل از حسگرهای تلفن‌های همراه استفاده کردند (Yazdizadeh et al., 2019).

الگوریتم‌های متفاوتی به جهت کلاسه‌بندی حالت‌های حمل و نقلی در مطالعات استفاده شده است که به طور کلی می‌توان آن‌ها را به چهار دسته اصلی روش‌های مبتنی بر قانون، روش‌های مبتنی بر منطق فازی، الگوریتم‌های یادگیری ماشین، و الگوریتم‌های یادگیری عمیق طبقه‌بندی کرد.

در روش مبتنی بر قانون، حالت سفر بر اساس معیارهای از پیش‌ تعیین شده و به صورت مرحله‌ای به کلاسه‌بندی می‌پردازد (Bohte & Maat, 2009). مثلاً Gong et al., 2012) اعلام کردن اگر میانگین سرعت کمتر از ۲۵ کیلومتر بر ساعت و پیشینه سرعت کمتر از ۴۵ کیلومتر بر ساعت باشد حالت حمل و نقلی دوچرخه‌سواری پیش‌بینی می‌شود. در برخی دیگر از مطالعات منطق فازی اجرا شده است. در این مطالعات، با تعریف توابع عضویت، تمایز بین حالت‌های حمل و نقلی مختلف صورت گرفته است؛ به گونه‌ای که احتمال رخداد یک حالت حمل و نقلی خاص بین ۰ و ۱ تنظیم شده است (Sauerländer-Biebl et al., 2017).

امروزه روش‌های یادگیری ماشین و یادگیری عمیق بیش از باقی الگوریتم‌ها مورد استفاده قرار می‌گیرد. پیش‌بینی حالت‌های حمل و نقلی نیز از این مورد پشتیبانی می‌کند. چندین نوع الگوریتم در مطالعات بررسی شده و مورد استفاده و آزمایش قرار گرفته‌اند. در برخی مطالعات (Nawaz et al., 2020; Yazdizadeh et al., 2019) الگوریتم‌های یادگیری ماشین مدل‌های RF و در برخی دیگر (Li et al., 2018; Wang et al., 2018) مدل‌های GB استفاده شده است.

در کل، استفاده از روش‌های مبتنی بر قانون و تئوری فازی نیازمند تعیین قوانین و توابع عضویت به تفکیک هر یک از ویژگی‌های استخراجی است. این مورد در صورت افزایش تعداد ویژگی‌ها با مشکل روبرو می‌شود. همین طور در روش‌های یادگیری عمیق ویژگی‌ها در لایه موسوم به لایه پنهان استخراج خواهد شد و مهندسی ویژگی نقشی کمزنگ در پیش‌بینی خواهد داشت؛ به گونه‌ای که در بیشتر موارد موجب کاهش دقت در مقایسه با استخراج ویژگی دستی می‌شود. همچنین اگرچه در تحقیقات پیشین طبقه‌بندی حالت‌های حمل و نقل بررسی شده است، در این تحقیق تلاش شده مقایسه‌ای از عملکرد چندین روش طبقه‌بندی مطرح همراه با انتخاب ویژگی‌های مؤثر صورت پذیرد. به منظور بهبود جامعیت مقایسه‌ صورت گرفته، از تعداد ویژگی‌های بیشتری استفاده شده است تا ارزیابی دقیق‌تری بر عملکرد الگوریتم‌های انتخاب ویژگی در زمانی که کاهش ابعاد بیشتری مدنظر است صورت پذیرد.

## محدوده و قلمرو مورد مطالعه

در این تحقیق برای ارزیابی روش پیشنهادی از مجموعه داده‌های پروژه Geolife که توسط مرکز تحقیقاتی مایکروسافت تهیه و

1. global positioning system

2. sussex–huawei locomotion-transportation

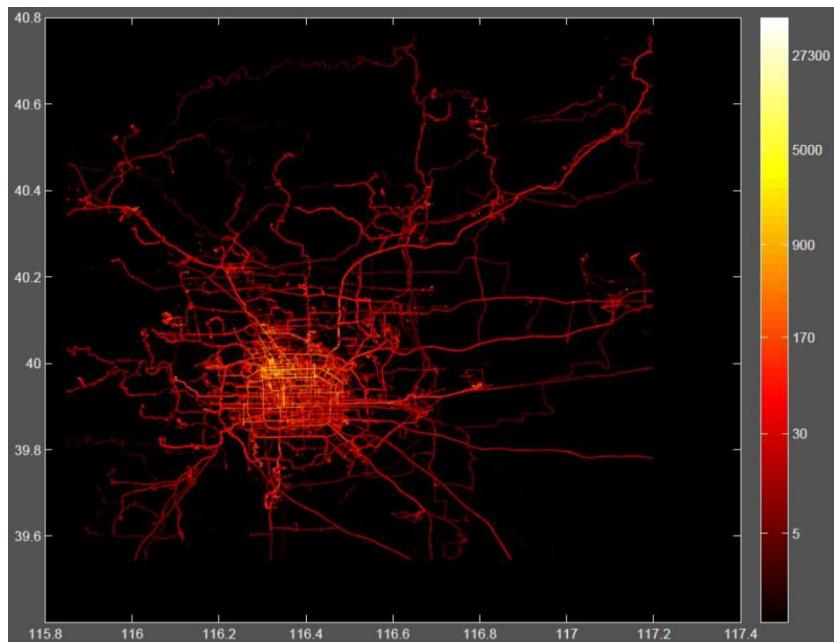
ذخیره شده است استفاده شد. این مجموعه داده طیف وسیعی از رفت و آمد های کاربران با مقاصد مختلف از جمله مکان‌های کاری، استادیوم‌ها، مراکز خرید و سرگرمی‌ را شامل می‌شود. ذخیره‌سازی این داده‌ها به صورت زمانی- مکانی در مدت پنج سال (آپریل ۲۰۰۷ تا آگوست ۲۰۱۲) و توسط ۱۸۲ نفر انجام پذیرفته است که ۶۹ کاربر در این مجموعه داده سفرهای خود را برچسب‌گذاری کرده‌اند. اطلاعات مربوط به این مجموعه داده در جدول ۱ نشان داده شده است.

این مجموعه داده به صورت منبع باز و رایگان در صفحه سازمان مایکروسافت قابل بارگیری و استفاده است (Geolife Dataset, Accessed June, 2022). خط سیر ثبت شده در این مجموعه داده توسط دستگاه‌های ثبت موقعیت مکانی<sup>۱</sup> و PDA تلفن همراه هوشمند با میزان نمونه‌برداری متفاوت ثبت و ذخیره شده است. این مجموعه داده در بیش از سی شهر در کشورهای مختلف، مانند چین و ایالات متحده امریکا و برخی از کشورهای اروپایی، جمع‌آوری شده است. شکل ۱ توزیع مجموعه داده‌ها در پکن را نشان می‌دهد؛ شهری که بیشتر داده‌ها در آن جمع‌آوری شده است.

در این مجموعه داده حالت‌های سفری که برچسب‌گذاری شده‌اند از: پیاده‌روی، دوچرخه، اتومبیل، اتوبوس، قطار، مترو، هواپیما، دویلن، موتورسیکلت، تاکسی، جابه‌جایی با استفاده از قایق.

جدول ۱. مشخصات سفرهای موجود در داده Geolife

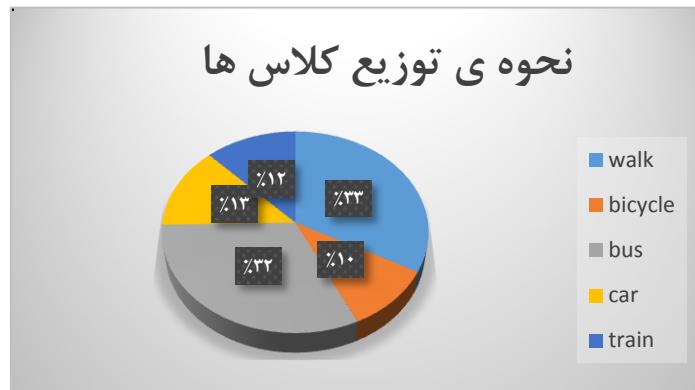
تعداد کل کاربران	تعداد کل سفرهای انجام گرفته	کل مسافت‌های پیموده شده (بر حسب کیلومتر)	کل زمان‌های پیموده شده (بر حسب ساعت)
۱۸۲	۱۷۶۲۱	۱۲۹۲۹۵۱	۵۰۱۷۶



شکل ۱. توزیع داده‌ها در شهر پکن

در این تحقیق، از حالت‌های حمل و نقل غیرزمینی اعم از هواپیما و قایق صرف نظر شد. در بین حالت‌های زمینی نیز با توجه به کافی نبودن داده‌ها در حالت‌های دویلن و موتورسیکلت این دو حالت نیز کنار گذاشته شدند. همچنین با توجه به فایل راهنمای موجود خود مایکروسافت برای داده‌های Geolife، دو حالت استفاده از اتومبیل و استفاده از تاکسی به عنوان یک حالت کلی استفاده از اتومبیل در نظر گرفته شد. در ادامه، با توجه به اینکه در شهر پکن مسیر قطارهای شهری و مترو به هم متصل و یکپارچه‌اند و از طرفی چون استاندارد خاصی برای تفکیک این دو وجود ندارد و شاید در برچسب‌گذاری اشتباه کنند، این دو حالت نیز به عنوان حالت حمل و نقل استفاده از قطار در نظر گرفته شد. در نهایت با حذف و ادغام حالت‌های گفته شده پنج حالت

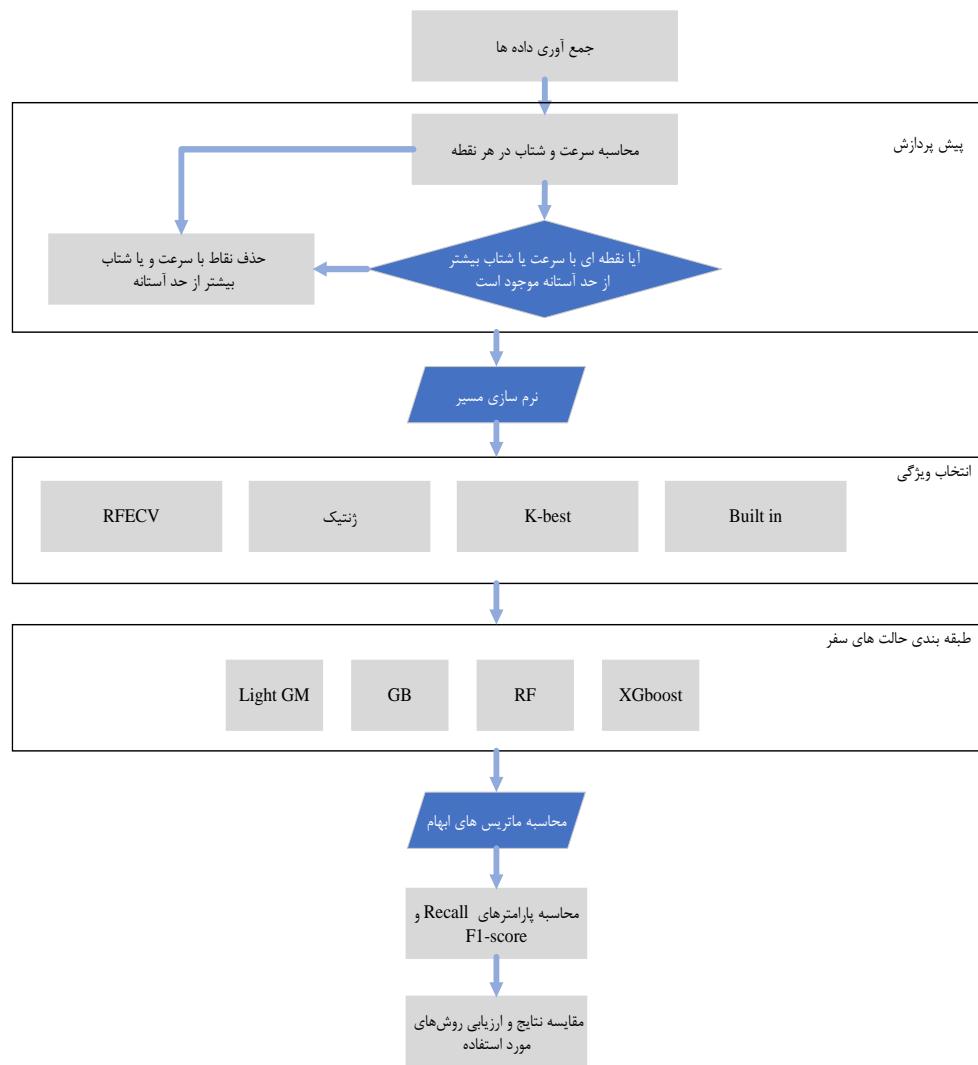
پیاده روی، دوچرخه، اتوبوس، ماشین، و قطار به عنوان کلاس های نهایی در این مطالعه مورد بررسی قرار گرفت. در شکل ۲ نحوه توزیع داده ها در هر یک از حالت ها به نمایش گذاشته شده است.



شکل ۲. نحوه توزیع کلاس‌ها

### روش پژوهش

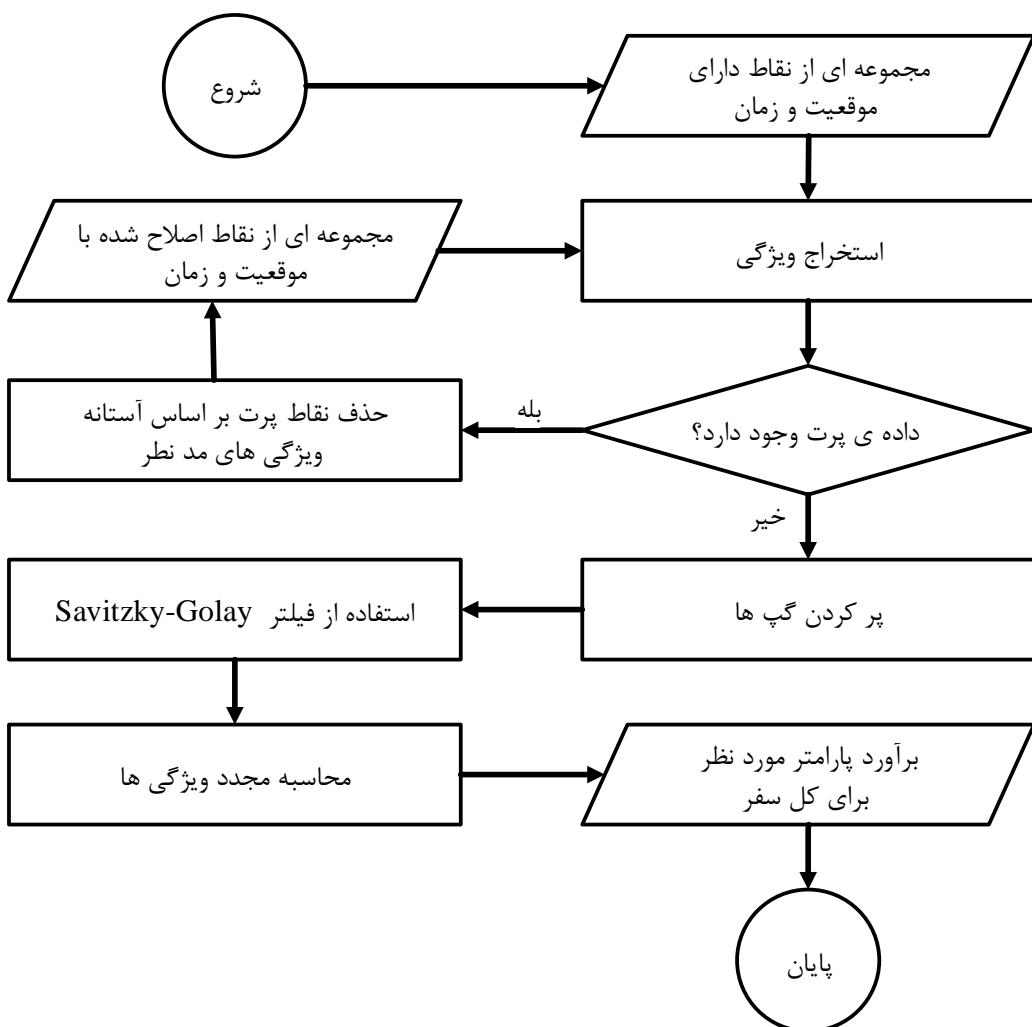
در شکل ۳ فلوچارت روش تحقیق برای پیش‌بینی و شناسایی حالت‌های حمل و نقل نشان داده شده است.



شکل ۳. فلوچارت مربوط به روش تحقیق

### تجزیه و تحلیل داده‌ها

برای پیش‌پردازش داده‌ها به ترتیب مراحل زیر صورت گرفت:



شکل ۴. فلوچارت پیش‌پردازش‌ها

در این مرحله ابتدا با استفاده از نقاط خام موجود در داده‌ها برای هر یک از نقاط موجود سرعت و شتاب محاسبه می‌شود. سپس با استفاده از حدآستانه تعریف شده در جدول ۲ نقاطی از این حدآستانه که دارای سرعت و شتاب بیشتری هستند از مجموعه داده‌ها حذف شدند.

جدول ۲. مقادیر حدآستانه برای شتاب و سرعت

حالات‌های حمل و نقلی	حدآستانه سرعت (m/s)	حدآستانه شتاب (m/s <sup>2</sup> )
پیاده روی	۷	۳
دوچرخه سواری	۱۲	۳
اتوبوس	۳۴	۲
اتومبیل	۵۰	۱۰
قطار	۳۴	۳

سپس نقاطی که سرعت و شتاب آن‌ها از حدآستانه بیشتر نیست بررسی می‌شوند که آیا از نظر زمانی گپ دارند یا خیر. در هر سفر این پارامتر بررسی می‌شود. اگر بین دو نقطه بیش از مدت زمان مشخص شده گذشته باشد با استفاده از تابع درون‌یابی گپ

تشخیص داده شده بین دو نقطه پر شده است. در مرحله بعد همه مسیرهای موجود با استفاده از فیلتر Savitzky-golay نرم شده اند. پس از این مرحله بار دیگر همه ویژگی های تعریف شده برای همه مسیرهای موجود محاسبه شده اند. در نهایت یک فایل اکسل با ۱۳۴۹ رکورد ذخیره شده است که هر رکورد نشان دهنده یک سفر مربوط به کاربر با شماره مورد نظر است.

### استخراج ویژگی ها

در ادامه پس از حذف نقاط اشتباه و پر کردن گپ های موجود بین نقاط حال ویژگی های گفته شده برای همه سفرهای موجود استخراج شده است. در نهایت برای هر یک از سفرها تعداد ۵۲ ویژگی متفاوت استخراج شده است. در جدول ۲ همه ویژگی های استخراج شده برای هر یک از سفرها نشان داده شده است.

جدول ۳. ویژگی های استخراج شده برای هر سفر

شماره	نام ویژگی	شماره	نام ویژگی
۱	TotalDistance(m)	۲۷	VelMax(m/s)
۲	StraightPAR	۲۸	VelSkew
۳	VelMean(m/s)	۲۹	VelKurtosis
۴	VelStd(m/s)	۳۰	VelIqr
۵	VelMed(m/s)	۳۱	VelChangePar
۶	jerk60	۳۲	acc40
۷	jerk80	۳۳	acc60
شماره	نام ویژگی	شماره	نام ویژگی
۸	bear20	۳۴	acc80
۹	bear40	۳۵	jerk20
۱۰	bear60	۳۶	jerk40
۱۱	accKurtosis	۳۷	jerkMed(m/s^3)
۱۲	accIqr	۳۸	jerkMax(m/s^3)
۱۳	accChangePar	۳۹	jerkSkew
۱۴	jerkMean(m/s^3)	۴۰	jerkKurtosis
۱۵	jerkStd(m/s^3)	۴۱	jerkIqr
۱۶	jerkChangePar	۴۲	HCR
۱۷	bearMean(deg)	۴۳	SR
۱۸	bearStd(deg)	۴۴	WeekDay
۱۹	bearMed(deg)	۴۵	meanTime
۲۰	bearMax(deg)	۴۶	Local Mean Time
۲۱	vel20	۴۷	AccMean(m/s^2)
۲۲	vel40	۴۸	AccStd(m/s^2)
۲۳	vel60	۴۹	AccMed(m/s^2)
۲۴	vel80	۵۰	AccMax(m/s^2)
۲۵	acc20	۵۱	AccSkew
۲۶	bear80	۵۲	Duration(s)

### مدل های کلاسه بندی

پس از پیش پردازش های مورد نظر و همچنین استخراج ویژگی های مورد نیاز، اجرای مدل های کلاسه بندی صورت پذیرفت. برای اجرای مدل های نامبرده، از کتابخانه های Scikit-learn و LightGM و XGBoost موجود در زبان برنامه نویسی پایتون استفاده شد و پیاده سازی صورت پذیرفت. به این منظور برای هر یک از مدل های مورد نظر حالت های زیر اجرا شد:

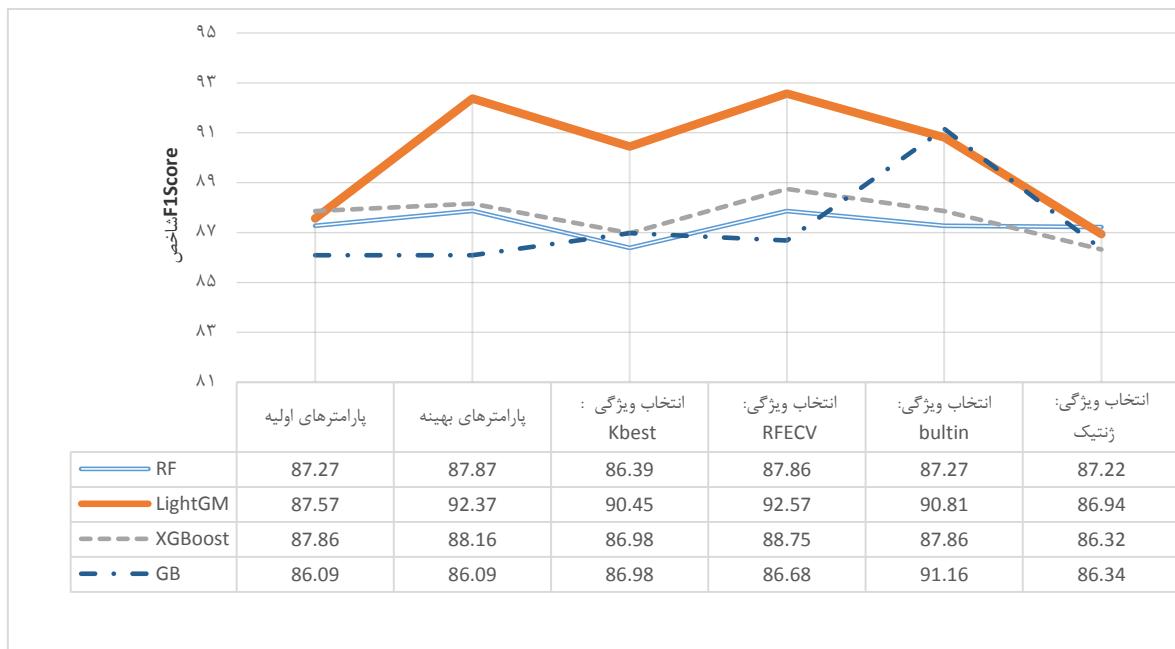
اجرای مدل با استفاده از پارامترهای پیش فرض؛

بهینه کردن ابر پارامترها برای هر مدل و اجرای مجدد؛

- استخراج ویژگی‌های مؤثر با استفاده از Kbest و اجرای مجدد مدل؛
- استخراج ویژگی‌های مؤثر با استفاده از RFECV و اجرای مجدد مدل؛
- استخراج ویژگی‌های مؤثر با استفاده از Built-in و اجرای مجدد مدل؛
- استخراج ویژگی‌های مؤثر با استفاده از الگوریتم ژنتیک و اجرای مجدد مدل.

### یافته‌های پژوهش

به منظور بررسی و ارزیابی نتایج به دست آمده برای مدل‌های کلاس‌بندی از پارامترهای F1-Score و بازخوانی<sup>۱</sup> و دقت<sup>۲</sup> استفاده شد. از آنجا که برچسب حالت‌های سفر برای کلاس‌های موجود به صورت نامتعادل است، ویژگی F1-Score ارزیابی دقیق‌تری را ممکن می‌سازد. در ادامه به تفکیک مدل‌های کلاس‌بندی مقدار هر یک از پارامترهای گفته شده در قالب شکل‌های ۵ تا ۷ به نمایش گذاشته شده است.



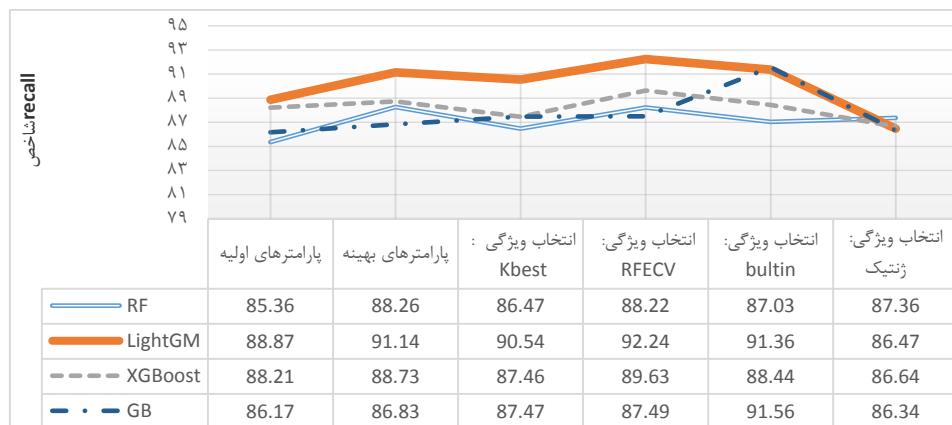
شکل ۵. میانگین وزنی F1-Score در مدل‌های کلاس‌بندی

همان‌طور که از شکل ۵ مشخص است دقت مدل‌های به کار رفته بسیار نزدیک به هم است. ولی مدل LightGM توانسته در استخراج ویژگی‌های مؤثر نسبت به سایر مدل‌ها کارایی بیشتری از خود نشان دهد و با کسب ۹۲/۵۷ درصد بین داده‌های تست در حالت انتخاب ویژگی با مدل RFECV بالاترین مقدار را در این پژوهش کسب کند.

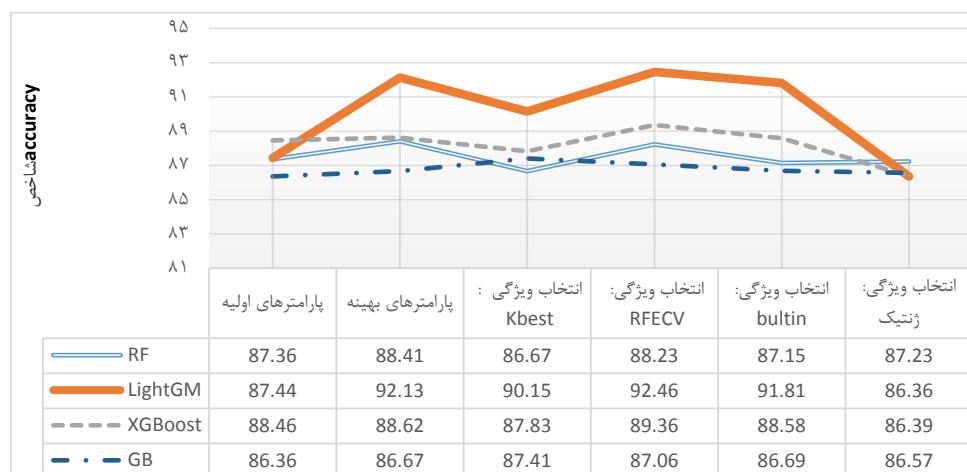
این دو شاخص نیز نتایج مشابهی همچون شاخص F1-Score ارائه می‌دهند. مدل LightGM مدل برتر است و پس از آن مدل XGBoost قرار دارد که نتایج بالاتری از دو مدل دیگر کسب کرده‌اند. بدین ترتیب مدل‌های مورد بررسی در این پژوهش توانسته‌اند در پیش‌بینی حالت‌های سفر موفق عمل کنند.

برای مقایسه بهتر مدل‌ها و نحوه کارایی هر مدل برای هر یک از کلاس‌ها شاخص F1-Score به تفکیک مدل و حالت انتخابی برای هر یک از کلاس‌ها همراه تعداد ویژگی انتخابی در قسمت انتخاب ویژگی در جدول ۴ نشان داده شده است.

1. recall  
2. accuracy



شکل ۶. شاخص Recall در مدل‌های کلاسیفیکر



شکل ۷. شاخص accuracy در مدل‌های کلاسیفیکر

جدول ۴. محاسبه میزان F1-Score و ارزیابی هر یک از کلاس‌ها در مدل

مدل کلاسیفیکر	حالت انتخابی	پیاده	دوچرخه	اتوبوس	اقطار	Weighted	تعداد ویژگی
Random Forest	پارامترهای اولیه	94	80	85	75	93	52
	پارامترهای بهینه	94	79	86	77	94	52
	Kbest	94	77	85	73	91	20
	RFECV	94	79	86	76	95	22
	Built-in	94	78	86	76	92	32
	GA	94	79	86	74	91	20
LightGBoost	پارامترهای اولیه	95	83	86	73	91	52
	پارامترهای بهینه	95	88	94	86	94	52
	Kbest	93	87	92	83	87	19
	RFECV	95	90	93	76	96	31
	Built-in	93	86	93	83	94	14
	GA	94	77	85	72	90	27
XGBoost	پارامترهای اولیه	94	81	87	76	91	52
	پارامترهای بهینه	95	84	86	74	93	52
	Kbest	95	80	85	72	92	25
	RFECV	95	82	87	78	94	14
	Built-in	95	84	87	73	91	24
	GA	95	79	85	69	87	22
GB	پارامترهای اولیه	94	81	83	69	94	52
	پارامترهای بهینه	94	81	83	69	94	52
	Kbest	95	78	84	71	95	26
	RFECV	95	80	85	70	92	14
	Built-in	94	83	84	72	93	25
	GA	95	78	84	67	89	27

در تعیین نوع حالت سفر حالت‌های استفاده از قطار و پیاده با دقت بالاتری شناسایی شدند که می‌تواند ناشی از تمایز سرعت پایین فرد در حالت پیاده با سایر حالت‌ها و در حالت قطار به سبب مستقیم بودن مسیر طی شده باشد. در ادامه برای مقایسه بهتر کارایی هر یک از مدل‌های به کار گرفته شده، در جدول ۵ تعداد کلاس‌های تخمین شده برای هر یک از کلاس‌های موجود آورده شده است.

جدول ۵. بررسی تعداد سفرهای تخمین شده توسط هر یک از مدل‌ها

مجموع (۱۳۴۹)	قطار (۱۶۴)	اتومبیل (۱۷۸)	اتوبوس (۴۲۷)	دوچرخه (۱۳۷)	پیاده (۴۴۳)	حالت انتخابی	مدل کلاس‌بندی
1177	153	134	363	110	417	پارامترهای اولیه	Random Forest
1183	154	137	367	108	417	پارامترهای بهینه	
1163	149	130	363	105	416	Kbest	
1181	156	135	367	108	415	RFECV	
1176	151	135	367	107	416	Built-in	
1173	149	132	367	108	417	GA	
1181	149	130	367	114	421	پارامترهای اولیه	
1250	154	153	401	121	421	پارامترهای بهینه	
1215	143	148	393	119	412	Kbest	LightGBoost
1233	157	135	397	123	421	RFECV	
1233	154	148	397	118	416	Built-in	
1160	148	128	363	105	416	GA	
1182	149	135	371	111	416	پارامترهای اولیه	
1188	153	132	367	115	421	پارامترهای بهینه	
1173	151	128	363	110	421	Kbest	XGBoost
1196	154	139	371	112	420	RFECV	
1186	149	130	371	115	421	Built-in	
1157	143	123	363	108	420	GA	
1159	154	123	354	111	417	پارامترهای اولیه	
1159	154	123	354	111	417	پارامترهای بهینه	
1168	156	126	359	107	420	Kbest	GB
1169	151	125	363	110	420	RFECV	
1170	153	128	359	114	416	Built-in	
1152	146	119	359	107	421	GA	

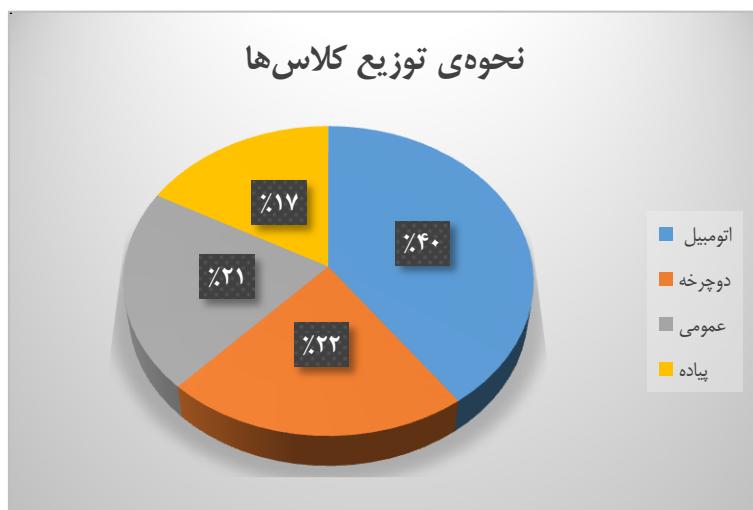
در پایان ارزیابی، دقت حاصل از روش تحقیق این مطالعه با سایر تحقیقات انجام‌شده مورد مقایسه قرار گرفت. در این قسمت هشت مطالعه اخیر که بر داده Geolife صورت گرفته‌اند همراه حالت‌های حمل و نقلی که مورد استفاده قرار گرفته است با روش پیشنهادی این مطالعه مقایسه شدند که نتایج حاصل از این مقایسه در جدول ۶ به نمایش گذاشته شده است. همچنین برای اینکه قیاس بهتری بین تحقیقات صورت گرفته شود شاخص وزنی F1-Score در جدول آورده شده است.

جدول ۶. مقایسه F1-Score بدست آمده با تحقیقات اخیر

F1-Score	حالت‌های حمل و نقلی	منبع
۸۴/۶۳	دوچرخه، اتوبوس، اتومبیل، قطار، پیاده	Dabiri et al. 2018
۹۰/۹۲	دوچرخه، اتوبوس، اتومبیل، قطار، مترو، پیاده	Xiao et al. 2017
۹۰/۵۱	دوچرخه، اتوبوس، اتومبیل، تاکسی، قطار، مترو، پیاده	Wang et al. 2018
۸۱/۴۳	دوچرخه، اتوبوس، اتومبیل، مترو، پیاده	Huang et al. 2020
۸۳/۷۹	دوچرخه، اتوبوس، اتومبیل، پیاده	Nawaz et al. 2020
۹۱/۰۵	دوچرخه، اتوبوس، اتومبیل، مترو، پیاده	Li et al. 2021
۸۶/۸۴	دوچرخه، اتوبوس، اتومبیل، قطار، پیاده	Li et al. 2020
۸۶/۱۹	دوچرخه، اتوبوس، اتومبیل، قطار، پیاده، هوایپما	Liang et al. 2017
۹۲/۳۷	دوچرخه، اتوبوس، اتومبیل، قطار، پیاده	LightGM با تمام ویژگی‌ها
۹۲/۵۷	دوچرخه، اتوبوس، اتومبیل، قطار، پیاده	LightGM با الگوریتم RFEVC
۹۰/۴۵	دوچرخه، اتوبوس، اتومبیل، قطار، پیاده	LightGM با الگوریتم K best
۹۰/۸۱	دوچرخه، اتوبوس، اتومبیل، قطار، پیاده	LightGM با الگوریتم Built-in

در ادامه برای ارزیابی روش پیشنهادی و کارآیی آن لازم است این روش بر یک مجموعه‌داده دیگر نیز اجرا شود. از این رو ابتدا مجموعه‌داده دوم به صورت مختصر معرفی و سپس نتایج به نمایش گذاشته می‌شود.

این مجموعه‌داده در تاریخ ۱۸/۰۹/۲۰۱۷ تا ۱۸/۰۹/۲۰۱۷ در کشور کانادا، شهر مونترال، بزرگ‌ترین شهر استان کبک، توسط آزمایشگاه تحقیقات برنامه حمل و نقل<sup>۱</sup> با همکاری دانشگاه کنکوردیا ثبت و ذخیره شده است. جمع‌آوری داده‌ها از طریق یک برنامه قابل نصب بر تلفن همراه هوشمند (در هر دو سیستم عامل iOS و Android) انجام شد که به طور خودکار خط سیر کاربر را ثبت می‌کند و هنگامی که کاربر در یک مکان معین به مدت بیش از ۱۲۰ ثانیه متوقف شود از کاربر می‌خواهد اطلاعات سفر خود را تکمیل کند. این اطلاعات شامل برچسب‌دهی حالت سفر و هدف از سفر است. حالت‌های حمل و نقلی پس از ترجمه شامل پیاده‌روی، استفاده از اتومبیل / موتورسیکلت، استفاده از تاکسی، استفاده از حمل و نقل عمومی، استفاده از دوچرخه، و استفاده از اتومبیل‌های اجاره‌ای است. در این مطالعه حالت‌های حمل و نقلی استفاده از تاکسی، استفاده از اتومبیل / موتورسیکلت، و استفاده از اتومبیل‌های اجاره‌ای به عنوان حالت استفاده از اتومبیل در نظر گرفته شدن. شکل ۸ نحوه توزیع حالت‌های حمل و نقلی مورد استفاده در این مجموعه‌داده را نمایش می‌دهد.



شکل ۸. نحوه توزیع کلاس‌ها در مجموعه‌داده دوم

در این مجموعه‌داده نیز مانند مجموعه‌داده اول برچسب حالت‌های حمل و نقلی نامتعادل توزیع شده است. بدین منظور میزان F1-Score با استفاده از این مجموعه‌داده به تفکیک مدل‌های کلاسه‌بندی RF، LightGBoost، XGBoost، و GB در چهار حالت پارامترهای اولیه و پارامتر بهینه و چهار حالت انتخاب ویژگی در جدول ۷ محاسبه شده است.

## نتیجه و پیشنهاد

با شناسایی دقیق حالت حمل و نقل هر کاربر، می‌توان درک واقعی‌تری از تعداد وسایل نقلیه مورد نیاز برای جابه‌جایی افراد از یک مکان خاص به مکان دیگر در هر روز ارائه داد که کمک بزرگی به کاهش ترافیک و حمل و نقل پایدار می‌کند. یکی از راهکارهای کاهش ترافیک ایجاد انگیزه در مسافران برای استفاده از حمل و نقل عمومی است. همچنین می‌توان با ایجاد خطوط پرسرنژین<sup>۲</sup> (HOV) در اتوبان‌های شهری تمایل به استفاده از اتومبیل‌های تک‌سرنشین را کاهش داد.

1. transportation research for integrated planning (TRIP)  
2. high-occupancy vehicle

جدول ۷. محاسبه میزان F1-Score و ارزیابی هر یک از کلاس‌ها برای مجموعه‌داده دوم

مدل کلاسه‌بندی	حالات انتخابی	پیاده	دوچرخه	اتومبیل	عمومی	Weighted	تعداد ویژگی
Random Forest	پارامترهای اولیه	87.92	95.66	91.58	61.7	87.86	52
	پارامترهای بهینه	86.82	96.79	94.02	62.36	88.87	52
	Kbest	84.62	95.66	89.14	60.37	86.85	27
	RFECV	86.82	96.79	90.46	63.03	88.87	26
	Built-in	85.72	94.37	91.03	61.04	87.86	29
	GA	86.82	94.28	90.36	60.37	86.67	23
LightGBoost	پارامترهای اولیه	87.71	96.15	92.72	68.59	91.36	52
	پارامترهای بهینه	88.64	96.24	93.07	69.42	91.51	52
	Kbest	87.17	94.82	91.06	65.58	90.64	24
	RFECV	86.84	95.04	91.74	67.63	90.75	29
	Built-in	86.94	94.57	90.67	66.47	90.34	20
	GA	86.57	95.03	91.45	67.84	90.31	31
XGBoost	پارامترهای اولیه	88.19	95.53	92.74	68.58	91.45	52
	پارامترهای بهینه	90.37	95.68	92.81	70.09	92.67	52
	Kbest	87.1	93.33	87.86	68.33	90.41	23
	RFECV	87.28	93.07	91.18	67.94	90.49	18
	Built-in	87.82	94.48	87.58	68.06	90.57	27
	GA	86.01	90.25	84.2	65.57	86.37	23
GB	پارامترهای اولیه	81.57	83.59	69.49	94.67	86.61	52
	پارامترهای بهینه	82.05	83.94	70.24	94.84	86.91	52
	Kbest	78.55	82.57	68.92	93.68	86.04	28
	RFECV	80.56	82.47	69.81	92.66	85.94	19
	Built-in	80.58	83.04	69.24	93.66	86.31	31
	GA	78.55	82.61	67.48	89.63	84.82	24

چالش‌های متنوعی تا رسیدن به هدف پژوهش وجود دارد. امروزه، به لطف حسگرهای موجود در تلفن‌های هوشمند، داده‌های متنوعی توانایی اخذ و ذخیره شدن دارند. چالش اول انتخاب داده‌های مورد استفاده در پیش‌بینی است؛ به گونه‌ای که علاوه بر در دسترس بودن بالاترین سرعت و کمترین هزینه را داشته باشد. چالش دوم وجود داده‌های پرت و خطأ به دلیل وجود خطاهای سیستمی و تصادفی در زمان اخذ داده‌هاست که می‌تواند دقت را به صورت مستقیم تحت شعاع خود قرار دهد. چالش بعدی استخراج ویژگی از مجموعه داده‌ها است. استخراج ویژگی یکی از مراحل مهم در پیش‌بینی است که استخراج ویژگی‌های مهم در آن موجب بهبود عملکرد پیش‌بینی خواهد شد. مهم‌ترین قسمت تحقیق صورت گرفته انتخاب ویژگی‌های مهم و به کارگیری آن‌ها در پیش‌بینی است؛ به گونه‌ای که موجب کاهش هزینه پردازشی در نتیجه افزایش سرعت و بهبود دقت در پیش‌بینی شود. چالش نهایی اجرا و انتخاب یک الگوریتم کلاسه‌بندی نظارت شده است که علاوه بر قدرتمند بودن بتوان با سرعت بالاتری نتیجه را پیش‌بینی کرد.

اگرچه در تحقیقات پیشین تمرکز بیشتر مطالعات تنها بر استخراج ویژگی‌ها، انتخاب ویژگی‌ها، و کلاسه‌بندی بوده است، در این تحقیق تلاش شده مقایسه‌ای بر عملکرد روش‌های مختلف در انجام دادن این مهم صورت گیرد. در این تحقیق، از چهار مدل طبقه‌بندی استفاده شده است که مدل GM و برخی از روش‌های انتخاب ویژگی برای اولین بار با هدف طبقه‌بندی حالات حمل و نقل استفاده شده‌اند. به منظور بهبود جامعیت مقایسه صورت گرفته، تعداد ویژگی‌های بیشتری نیز استفاده شد تا ارزیابی دقیق‌تری بر عملکرد الگوریتم‌های انتخاب ویژگی در زمانی که کاهش ابعاد بیشتری مد نظر بود صورت پذیرد.

نتایج بدست‌آمده در این پژوهش از دقت مطلوبی در برآورده ساختن اهداف و طبقه‌بندی حالت‌های سفر به منظور حمل و نقل پایدار شهری برخوردار است. با وجود این، به دلیل استفاده از تنها یک مجموعه داده که بخش اعظمی از آن در کشور چین تهیه شده است این احتمال که مدل‌های برازش داده شده متناسب با شرایط حمل و نقل این کشور آموزش دیده باشند و از قابلیت تعمیم کمی به شرایط موجود در سایر کشورها برخوردار باشند وجود دارد.

با بررسی نتایج حاصل از این مطالعه و مقایسه آن با مطالعات پیشین، دقت محاسبه شده در روش پیشنهادی بهتر از باقی

مطالعات برآورده شده است. با توجه به دقت‌های برآورده شده در مجموعه‌داده می‌توان پیش‌بینی حالت‌های حمل و نقلی با استفاده از تلفن‌های هوشمند را جایگزینی بهتر از پرسشنامه‌ها در نظر گرفت که با هزینهٔ پایین و سرعت بالا حجم عظیمی از داده‌ها را ثبت و ذخیره می‌کنند.

با توجه به اثبات کارآمدی روش ارائه شده پیشنهاد می‌شود در ادامه تحقیق و جهت جمع‌آوری داده‌های بومی هر شهر در کشور، با مراجعه و هماهنگی با سازمان‌های ذی‌ربط، برنامه‌ای در سیستم‌عامل اندروید تهیه شود و در اختیار کاربران مختلف قرار گیرد. به این صورت که کاربر، در ابتدای مسیر، با روشن کردن موقعیت مکانی تلفن همراه و معرفی شروع سفر برنامه، شروع به ذخیره کردن نقاط مکانی بر حسب بازه زمانی مورد نظر کند و در انتهای سفر هم با پایان یافتن سفر، برنامه برچسب حالت جابه‌جایی را از کاربر بگیرد و ذخیره کند.

همچنین چون مجموعه‌داده مورد استفاده دارای تعداد زیادی کاربر است که سفرهای خود را برچسب‌گذاری نکرده‌اند، در ادامه تحقیق، توانایی روش‌های نیمه‌نظرارت شده مورد ارزیابی قرار گیرد و دقت‌های بدست‌آمده از این روش را می‌توان با استفاده از داده‌هایی که دارای برچسب حالت سفر هستند، مورد ارزیابی قرار داد.

## منابع

- Al Momin, K., Barua, S., Hamim, O. F., & Roy, S. (2022). Modeling The Behavior In Choosing The Travel Mode For Long-Distance Travel Using Supervised Machine Learning Algorithms. *Komunikácie*, 24(4):A187-A197.
- Bantis T. & Haworth, J. (2017). Who you are is how you travel: A framework for transportation mode detection using individual and environmental characteristics. *Transportation Research Part C: Emerging Technologies*, Vol. 80, 286-309.
- Bohte, W. & Maat, K. (2009). Deriving and validating trip purposes and travel modes for multi-day GPS-based travel surveys: A large-scale application in the Netherlands. *Transportation Research Part C: Emerging Technologies*, Vol. 17, No. 3, 285-297.
- Bolbol, A., Cheng, T., Tsapakis, I., & Haworth, J. (2012). Inferring hybrid transportation modes from sparse GPS data using a moving window SVM classification. *Computers, Environment and Urban Systems*, Vol. 36, No. 6, 526-537.
- Byon, Y.-J. & Liang, S. (2014). Real-time transportation mode detection using smartphones and artificial neural networks: Performance comparisons between smartphones and conventional global positioning system sensors. *Journal of Intelligent Transportation Systems*, Vol. 18, No. 3, 264-272.
- Chen, T. & Guestrin, C. (2016). "Xgboost: A scalable tree boosting system" in Proceedings of the 22nd ACM SIGKDD international conference on knowledge discovery and data mining, 785-794.
- Dabiri, S. & Heaslip, K. (2018). Inferring transportation modes from GPS trajectories using a convolutional neural network. *Transportation research part C: emerging technologies*, Vol. 86, 360-371.
- Dabiri, S., Lu, C.-T., Heaslip, K., & Reddy, C. K. (2019). Semi-supervised deep learning approach for transportation mode identification using GPS trajectory data. *IEEE Transactions on Knowledge and Data Engineering*, Vol. 32, No. 5, 1010-1023.
- Friedman, J. H. (2001). Greedy function approximation: a gradient boosting machine. *Annals of statistics*, 1189-1232.
- Friedrich, B., Lübbe, C., & Hein, A. (2020). Analyzing the importance of sensors for mode of transportation classification. *Sensors*, Vol. 21, No. 1, 176.
- Geolife Dataset. <https://www.microsoft.com/en-us/research/publication/geolife-gps-trajectory-dataset-user-guide/> (accessed).
- Gong, H., Chen, C., Bialostozky, E., & Lawson, C. T. (2012). A GPS/GIS method for travel mode detection in New York City. *Computers, Environment and Urban Systems*, Vol. 36, No. 2, 131-139.
- Han, J., Kamber, M., & Pei, J. (2012). Data Mining: Concepts and Techniques Third Edition [M]. *The Morgan Kaufmann Series in Data Management Systems*, Vol. 5, No. 4, 364-371.
- Hasan, R. A., Irshaid, H., Alhomaidat, F., Lee, S., & Oh, J.-S. (2022). Transportation mode detection by using smartphones and smartwatches with machine learning. *KSCE Journal of Civil Engineering*, 26(8), 3578-3589.
- Huang, Z., Wang, P., & Liu, Y. (2020). Statistical characteristics and transportation mode identification of individual trajectories. *International Journal of Modern Physics B*, Vol. 34, No. 10, 2050092.
- Jahangiri, A. & Rakha, H. A. (2015). Applying machine learning techniques to transportation mode recognition using mobile phone sensor data. *IEEE transactions on intelligent transportation systems*, Vol. 16, No. 5, 2406-2417.
- Kashifi, M. T., Jamal, A., Kashefi, M. S., Almoshaogeh, M., & Rahman, S. M. (2022). Predicting the travel mode choice with interpretable machine learning techniques: A comparative study. *Travel Behaviour and Society*, 29, 279-296.
- Li, J., Pei, X., Wang, X., Yao, D., Zhang, Y., & Yue, Y. (2021). Transportation mode identification with GPS trajectory data and GIS information. *Tsinghua Science and Technology*, Vol. 26, No. 4, 403-416.
- Li, L., Zhu, J., Zhang, H., Tan, H., Du, B., & Ran, B. (2020). Coupled application of generative adversarial networks and conventional neural networks for travel mode detection using GPS data. *Transportation Research Part A: Policy and Practice*, Vol. 136, 282-292.
- Martín-Baos, J. Á., López-Gómez, J. A., Rodriguez-Benitez, L., Hillel, T., & García-Ródenas, R. (2023). A prediction and behavioural analysis of machine learning methods for modelling travel mode choice. arXiv preprint arXiv: 2301.04404.
- Nawaz, A. et al. (2020). Mode Inference using enhanced Segmentation and Pre-processing on raw Global Positioning System data. *Measurement and Control*, Vol. 53, No. 7-8, 1144-1158.
- Nawaz, A., Zhiqiu, H., Senzhang, W., Hussain, Y., Khan, I., & Khan, Z. (2020). Convolutional LSTM based transportation mode learning from raw GPS trajectories. *IET Intelligent Transport Systems*, Vol. 14, No. 6, 570-577.
- Noble, W. S. (2006). What is a support vector machine?. *Nature biotechnology*, Vol. 24, No. 12, 1565-1567.

- Sasaki, Y. (2007). The truth of the F-measure. *Teach tutor mater*, Vol. 1, No. 5, 1-5.
- Sauerländer-Biebl, A., Brockfeld, E., Suske, D., & Melde, E. (2017). Evaluation of a transport mode detection using fuzzy rules. *Transportation research procedia*, Vol. 25, 591-602.
- Schlebusch, C. M. & Jakobsson, M. (2018). Tales of human migration, admixture, and selection in Africa. *Annual Review of Genomics and Human Genetics*, Vol. 19, 405-428.
- Song, X., Kanasugi, H., & Shibasaki, R. (2016). "Deeptransport: Prediction and simulation of human mobility and transportation mode at a citywide level" in Proceedings of the Twenty-Fifth International Joint Conference on Artificial Intelligence, 2618-2624.
- Sun, Y., Dong, Y. D., Waygood, E. O., Naseri, H., Jiang, Y., & Chen, Y. (2023). Machine-learning approaches to identify travel modes using smartphone-assisted survey and map application programming interface. *Transportation Research Record*, 2677(2), 385-400.
- Vapnik, V. N. (1995). The nature of statistical learning. Theory.
- Wang, B., Wang, Y., Qin, K., & Xia, Q. (2018). "Detecting transportation modes based on LightGBM classifier from GPS trajectory data" in 2018 26<sup>th</sup> International Conference on Geoinformatics, IEEE, 1-7.
- Xiao, Z., Wang, Y., Fu, K., & Wu, F. (2017). Identifying different transportation modes from trajectory data using tree-based ensemble classifiers. *ISPRS International Journal of Geo-Information*, Vol. 6, No. 2, 57.
- Yazdizadeh, A., Patterson, Z., & Farooq, B. (2019). An automated approach from GPS traces to complete trip information. *International Journal of Transportation Science and Technology*, Vol. 8, No. 1, 82-100.