

مدل تقویت شده برون یابی برای تصمیم گیری سفر:

یک رویکرد یادگیری ماشین مجموعه با در نظر گرفتن نظریه رفتاری

چکیده :

مدل سازی تصمیم گیری سفر افراد از نظر انتخاب حالت های حمل و نقل، مسیر و زمان حرکت برای فعالیت های روزانه یک جزء ضروری برای بهینه سازی و مدیریت سیستم حمل و نقل است.

رویکردهای مرسوم مدل سازی تصمیم گیری سفر از ساختارهای مدل فرضی و مشخصات پارامتری رنج می برند.

الگوریتم های یادگیری ماشینی در حال ظهور راه حل های مبتنی بر داده و غیرپارامتری را برای مدل سازی تصمیم گیری سفر ارائه می کنند، اما به دلیل نادیده گرفتن مکانیسم های رفتاری در چارچوب، با مسائل برون یابی (یعنی ناتوانی در پیش بینی سناریوهای فراتر از نمونه های آموزشی) مواجه می شوند. این مطالعه یک رویکرد مبتنی بر برون یابی را برای مدل سازی تصمیم گیری سفر پیشنهاد می کند، از مزایای مکمل الگوریتم های یادگیری ماشین گروهی (جنگل تصادفی در مطالعه ما) و نظریه تصمیم گیری مبتنی بر دانش برای افزایش دقت پیش بینی و برون یابی مدل استفاده می کند. رویکرد پیشنهادی با استفاده از سه مجموعه داده درباره تصمیم گیری سفر، از جمله یک مجموعه داده تخمینی (برای اعتبارسنجی متقابل) و دو مجموعه داده آزمایشی (برای آزمون های برون یابی مدل) مورد بررسی قرار می گیرد. به خصوص، ما از دو مجموعه داده آزمایشی حاوی سناریوهای انتخاب برون یابی با ویژگی هایی که فراتر از محدوده نمونه های آموزشی هستند، برای بررسی توانایی پیش بینی مدل های پیشنهادی در سناریوهای انتخاب برون یابی استفاده می کنیم، که به سختی توسط ادبیات مربوطه بررسی شده است.

نتایج نشان می دهد که هم مدل های پیشنهادی و هم کاربرد مستقیم جنگل تصادفی (RF) می تواند دقت پیش بینی بسیار خوبی (حدود ۸۰ درصد) در مجموعه داده های تخمین بدهد. با این حال، RF توانایی پیش بینی ناقصی در دو مجموعه داده آزمایشی با سناریوهای انتخاب برون یابی دارد. در مقابل، مدل های پیشنهادی عملکردهای پیش بینی کننده قابل توجهی را در دو مجموعه داده آزمایشی ارائه می کنند که نشان دهنده ظرفیت برون یابی بسیار قوی تر است. مدل مبتنی بر چارچوب پیشنهادی می تواند امتیاز دقت را 274.93 درصد نسبت به کاربرد مستقیم RF در مجموعه داده آزمایشی اول و 21.9 درصد در مجموعه داده آزمایشی دوم بهبود بخشد. نتایج حاکی از مزایای رویکرد پیشنهادی از نظر قدرت پیش بینی و توانایی برون یابی در مقایسه با روش های موجود است.

مدل‌سازی و پیش‌بینی تقاضاهای سفر مکانی-زمانی در یک سیستم حمل‌ونقل یکی از هسته‌های حیاتی و ورودی‌های ضروری برای بهینه‌سازی و مدیریت عملیات سیستم‌های حمل‌ونقل است. اینها مستلزم درک صریح و دقیق در مورد چگونگی تصمیم‌گیری مسافران از نظر حالت‌های حمل و نقل، مسیرها و زمان حرکت برای فعالیت‌های روزانه در سیستم‌های حمل و نقل با در نظر گرفتن هر دو هدف است (مثلاً متغیرهای سطح خدمات انتخاب‌های حمل و نقل مانند زمان سفر).، هزینه و راحتی) و عوامل ذهنی (به عنوان مثال، ویژگی‌های اجتماعی-اقتصادی و نگرش‌های ذهنی). به عنوان مثال، اگر روزانه 10000 نفر از منطقه A به منطقه B رفت و آمد کنند، مدیران سیستم حمل و نقل باید پیش‌بینی کنند که چند نفر حالت‌های مختلف حمل و نقل (به عنوان مثال، اتوبوس، مترو، ماشین و دوچرخه) را انتخاب می‌کنند و کدام مسیر را انتخاب می‌کنند. برای برنامه‌ریزی، مدیریت و بهینه‌سازی سیستم‌های حمل و نقل. بنابراین، مدل‌سازی دقیق در مورد تصمیم‌گیری سفر افراد مختلف برای مدیریت کارآمد حمل و نقل و بهینه‌سازی بسیار مهم است.

روش‌های مرسوم برای مدل‌سازی تصمیم‌گیری سفر مانند مدل لاجیت چندجمله‌ای [1] و مدل لاجیت مختلط [2] برای چندین دهه بر تحلیل تقاضای سفر غالب بوده‌اند.

روش‌های سنتی بر اساس تئوری‌های رفتاری شناخته شده‌ای مانند نظریه حداکثرسازی سودمندی و تئوری کمینه‌سازی پشیمانی هستند. چنین نظریه‌های رفتاری معیارهای سنجش اهداف افراد یا نتایج بهینه در تصمیم‌گیری را تعریف می‌کنند. به عنوان مثال، اساس نظریه حداکثرسازی سودمندی فرض می‌کند که تصمیم‌گیرندگان، حداکثر سودمندی هستند، در حالی که نظریه حداقل‌سازی پشیمانی، هدف تصمیم‌گیرندگان را به حداقل رساندن پشیمانی در تصمیم‌گیری به جای دستیابی به بالاترین مطلوبیت می‌داند. بر اساس تئوری‌های رفتاری، چارچوب‌های ریاضی خاص و ساختارهای مدل (به عنوان مثال، مدل‌های لاجیت) برای مدل‌سازی تصمیم‌گیری سفر در مورد زمان عزیمت، مسیر و انتخاب‌های حالت توسعه یافته‌اند [2]. با این حال، مدل‌های مرسوم دارای محدودیت‌های اساسی مانند ساختارهای مدل چوبی (به عنوان مثال، عموماً با استفاده از توابع خطی)، مشخصات مدل پارامتری، مفروضات مربوط به تصادفی‌های رفتاری و توزیع پارامترها، و مشکل در نظر گرفتن تعاملات پیچیده بین متغیرهای توضیحی و اثرات غیرخطی متغیرهای توضیحی هستند [3].

اخیراً، الگوریتم‌های یادگیری ماشین (ML) مانند ماشین‌های بردار پشتیبان و درخت‌های تصمیم، راه‌حل‌های بالقوه‌ای را برای محدودیت‌های روش‌های مرسوم ذکر شده در بالا ارائه می‌کنند [4,6,7]. الگوریتم‌های ML

مفروضات دقیقی را به فرمول‌بندی‌های مدل قبلی تحمیل نمی‌کنند و روابط پیچیده بین عوامل تأثیرگذار (به عنوان مثال، متغیرهای توضیحی) و انتخاب‌های مسافران (یعنی متغیر وابسته) را به روش داده‌محور یاد می‌گیرند [7،8]. ویژگی‌های اساسی و مکانیسم‌های مبتنی بر داده الگوریتم‌های ML آن‌ها را قادر می‌سازد تا نواقص روش‌های مرسوم را از جمله پرداختن به روابط غیرخطی بین متغیرهای وابسته و متغیرهای توضیحی، و یادگیری خودکار تعاملات پیچیده بین متغیرهای توضیحی، حل کنند. مزایای ML بسیاری از محققان را جذب کرده است تا از آنها در مطالعات تجربی مربوط به تصمیم‌گیری در سفر استفاده کنند (به عنوان مثال، [4،6،8،11]). با این حال، مزایای الگوریتم‌های ML با قیمت نیز همراه است. مکانیسم‌های مبتنی بر داده الگوریتم‌های ML همچنین به معنای نادیده گرفتن مکانیسم‌های رفتاری اساسی تصمیم‌گیری مسافران در چارچوب مدل‌سازی است. به طور خاص، روابط برآزش بین متغیرهای توضیحی و متغیرهای وابسته بر اساس الگوریتم‌های ML کاملاً مبتنی بر داده‌ها هستند و بر اساس نظریه‌های رفتاری صریح یا علیت ایجاد نمی‌شوند. اینها منجر به عمومیت کم و برون‌یابی مدل‌های آموزش دیده می‌شود. برون‌یابی در زمینه تصمیم‌گیری سفر به توانایی مدل‌های آموزش دیده برای پیش‌بینی تصمیم‌گیری در سناریوهای انتخابی که در نمونه‌های آموزشی وجود ندارد، اشاره دارد.

الگوریتم‌های ML مانند درخت‌های تصمیم‌گیری یک مسئله حیاتی دارند: مسئله برون‌یابی. آن‌ها نمی‌توانند داده‌هایی را با ویژگی‌های خارج از محدوده نمونه‌های آموزشی پیش‌بینی کنند، به دلیل مکانیسم‌های مبتنی بر داده و ناآگاهی از علیت در ساختارهای مدل [12]. با این وجود، یکی از اهداف اصلی مدل‌سازی تصمیم‌گیری سفر، خدمت به پیش‌بینی و ارزیابی تقاضای سفر در آینده با سناریوهای انتخابی فعلی است. به عنوان مثال، مدیران حمل‌ونقل یک مدل انتخاب سفر را بر اساس مجموعه داده‌های تجربی کالیبره می‌کنند، پارامترهای مدل را به دست می‌آورند و از آن برای پیش‌بینی انتخاب‌های مسافران در صورت یک سیاست جدید (مانند قیمت‌گذاری تراکم و استراتژی‌های مدیریت هوشمند) یا یک سرویس حمل‌ونقل جدید (مثلاً یک سرویس جدید) استفاده می‌کنند. خط اتوبوس سریع معرفی شده است. بنابراین، توانایی برون‌یابی برای پیش‌بینی انتخاب‌های تصمیم‌گیری سفر در موقعیت‌های موجود در حال حاضر ضروری و حیاتی است.

این مطالعه در پی ادبیات مربوطه برای ارائه یک رویکرد مبتنی بر برون‌یابی برای مدل‌سازی تصمیم‌گیری سفر با ادغام یادگیری ماشین گروهی با نظریه تصمیم‌گیری مبتنی بر دانش است. رویکرد پیشنهادی از الگوریتم‌های ML مجموعه مبتنی بر درخت برای پرداختن به روابط پیچیده و غیرخطی بین متغیر وابسته و متغیرهای توضیحی و همچنین تعاملات پیچیده بین متغیرهای توضیحی بهره می‌برد. با تفاوت با ادبیاتی که مکانیسم‌های

رفتاری در مدل‌سازی را نادیده می‌گرفت، ما به طور همزمان، نظریه‌های تصمیم‌گیری مبتنی بر دانش شناخته‌شده از علوم رفتاری را در چارچوب مدل‌سازی تعبیه کردیم تا مکانیسم‌های رفتاری زیربنای تصمیم‌گیری سفر را در نظر بگیریم. ادغام نظریه‌های تصمیم‌گیری مبتنی بر دانش و الگوریتم‌های ML مجموعه داده‌محور در این مطالعه بهترین مزیت‌های متقابل آنها را برای افزایش قدرت مدل‌سازی و تولدایی برون‌یابی در پیش‌بینی ایجاد می‌کند. تا آنجا که به ما مربوط می‌شود، این مطالعه اولین کاری است که نظریه‌های رفتاری مبتنی بر دانش را در الگوریتم‌های ML مبتنی بر داده برای مدل‌سازی تصمیم‌گیری سفر ترکیب می‌کند.

علاوه بر این، رویکرد پیشنهادی با استفاده از سه مجموعه داده مختلف از تصمیم‌گیری سفر، از جمله یک مجموعه داده برآورد (برای اعتبارسنجی متقابل) و دو مجموعه داده آزمایشی (برای آزمون‌های برون‌یابی مدل) مورد بررسی قرار می‌گیرد. مهمتر از همه، ما از دو مجموعه داده آزمایشی حاوی سناریوهای انتخاب برون‌یابی با ویژگی‌هایی که فراتر از محدوده نمونه‌های آموزشی هستند، استفاده می‌کنیم تا به ویژه تولدایی پیش‌بینی مدل‌های پیشنهادی را در سناریوهای انتخاب برون‌یابی، که هرگز توسط ادبیات مرتبط بررسی نشده‌اند، بررسی کنیم. این مطالعه یک روش جدید برای مدل‌سازی و پیش‌بینی تصمیم‌گیری سفر ارائه می‌کند و بنابراین از مدیریت و بهینه‌سازی کارآمد و علمی سیستم‌های حمل‌ونقل پشتیبانی می‌کند.

بقیه مقاله به شرح زیر سازماندهی شده است. بخش بعدی مروری بر ادبیات مطالعات مربوطه ارائه می‌کند و شکاف‌های پژوهشی را با بحث‌ها مشخص می‌کند. بخش 3 جزئیاتی را در مورد رویکرد پیشنهادی و چارچوب مدل‌سازی ارائه می‌کند. بخش 4 مجموعه داده‌های مورد استفاده را تشریح می‌کند و فرآیندهای دقیق تخمین مدل و آزمایش را ارائه می‌دهد. نتایج و تجزیه و تحلیل در بخش 5 ارائه شده است و پس از آن در بخش آخر نکات پایانی ارائه شده است.

2. بررسی ادبیات

الگوریتم‌های ML برای مدل‌سازی تصمیم‌گیری سفر با در نظر گرفتن تصمیم‌گیری سفر به عنوان یک مشکل طبقه‌بندی استفاده شده‌اند. به طور خاص، وظیفه مدل‌سازی تصمیم‌گیری سفر، پیش‌بینی گزینه انتخابی مسافر زمانی است که جایگزین‌های موجود برای یک سفر و ویژگی‌های آنها ارائه شود.

به عنوان مثال، چهار حالت حمل و نقل ممکن (به عنوان مثال، اتوبوس، دوچرخه، ماشین شخصی، و مترو) از مکان A به مکان B وجود دارد و ویژگی‌های آنها (مانند زمان سفر، هزینه و راحتی) توسط مسافران شناخته شده است (مثلاً، از نقشه گوگل)؛ وظیفه مدل‌سازی این است که مسافر کدام حالت حمل و نقل را برای سفر

انتخاب می کند. این کار شبیه به طبقه بندی (به عنوان مثال، انتخاب ماشین برای سفر یا عدم انتخاب) بر اساس ویژگی های گزینه های ممکن است. بنابراین، الگوریتم های رایج طبقه بندی ML مانند شبکه های عصبی مصنوعی (ANN)، ماشین های بردار پشتیبان (SVM)، و درخت های تصمیم گیری (DTs)، در ادبیات مربوطه برای مدل سازی تصمیم گیری سفر به کار گرفته شده اند. شمولی و همکاران [13] یکی از اولین مطالعات را انجام داد که روش های ML را برای مدل سازی تصمیم گیری سفر به کار می برد. آنها از شبکه های عصبی شامل پرسپترون چند لایه ساده (MLP) و درختان طبقه بندی و رگرسیون (CART) برای مدل سازی انتخاب های حالت سفر استفاده کردند. آنها دریافتند که هر دو MLP و CART نسبت به مدل های مرسوم مانند مدل لاجیت چند جمله ای عملکردی مشابه و از لحاظ نظری سودمند دارند. چندین مطالعه تجربی دیگر (به عنوان مثال، [14-18]) گزارش کردند که ANN ها قابلیت پیش بینی بهتری را در مقایسه با مدل های لاجیت چند جمله ای سنتی و مدل های Nest Logit ارائه کردند. علاوه بر این، برخی از مطالعات از SVM ها برای مدل سازی تصمیم گیری سفر استفاده کردند.

Zhang و Xie [17] و Omrani [19] نشان دادند که SVM ها بالاترین دقت را برای پیش بینی انتخاب سفر در مقایسه با ANN و مدل Logit چند جمله ای دارند. در مورد DT ها، سخار و مادو [20] دقت پیش بینی جنگل تصادفی و مدل لاجیت چند جمله ای سنتی را مقایسه کردند و چنگ و همکاران. [4] یک جنگل تصادفی قوی برای مدل سازی انتخاب های حالت سفر با ترکیب عوامل محیطی ساخته شده ایجاد کرد.

Helbich و Hagenauer [9] یک مطالعه مقایسه ای بر روی دقت پیش بینی هفت طبقه بندی کننده مختلف یادگیری ماشین انجام دادند و گزارش کردند که Random Forest بالاترین دقت را انجام می دهد. اخیراً یک مطالعه تطبیقی توسط ژائو و همکاران انجام شده است. [6] برای بررسی دقت پیش بینی و تفسیرهای رفتاری مدل های سنتی و هفت الگوریتم ML برای مدل سازی تصمیم گیری سفر. آنها همچنین اشاره کردند که جنگل تصادفی بهترین عملکرد را نشان می دهد. به طور خلاصه، الگوریتم های ML مبتنی بر درخت مانند Random Forest اعلام شده اند که طبق ادبیات، عملکرد بسیار بهتری نسبت به سایر دسته بندی کننده های ML دارند (به عنوان مثال، [4،6،8،10]).

با این حال، هر سکه دو روی دارد. مکانیسم مبتنی بر داده به الگوریتم های ML این توانایی را می دهد تا روابط پیچیده بین عوامل تأثیرگذار و انتخاب های مسافران را بدون تحمیل ساختارها و مشخصات مدل از پیش تعریف شده به تصویر بکشند. با این حال، پارادایم مبتنی بر داده الگوریتم های ML به دلیل فقدان علیت، به ویژه در زمینه های مدل سازی تصمیم گیری سفر، کاستی های خود را دارد. همانطور که همه می دانیم، الگوریتم های

Table 1
An illustration example.

Factors	Choice scenario A: from home to shopping mall 1		Choice scenario B: from home to shopping mall 2	
	Bus	Metro	Bus	Metro
Cost	5 CNY	5 CNY	5 CNY	5 CNY
Travel time	45 min	65 min	45 min	35 min
Real choice	Chosen	Not chosen	Not chosen	Chosen

Note: 1 CNY = 0.14 dollar.

اطراف مبدا هر سفر و شخصی جمع آوری کرد. ویژگی های آنها یک جنگل تصادفی برای پیش‌بینی انتخاب‌های حالت سفر ایجاد کردند، که در آن متغیر وابسته حالت حمل‌ونقل انتخابی هر سفر بود و متغیرهای توضیحی ورودی قبلاً ویژگی‌های سفر ذکر شده بودند. به عبارت دیگر، ورودی‌های جنگل تصادفی در [4] برای پیش‌بینی تصمیم‌گیری مسافر در مورد نحوه حمل‌ونقل، صرفاً ویژگی‌های (به عنوان مثال، زمان سفر) استفاده از یک حالت حمل‌ونقل برای یک سفر هستند.

فرض اساسی مدل‌سازی تصمیم‌گیری سفر به این شکل این است که مسافران تصمیم سفر را صرفاً بر اساس ویژگی‌های استفاده از یک حالت حمل‌ونقل برای یک سفر می‌گیرند، که غیرقابل قبول است. اجازه دهید از یک مثال (نشان داده شده در جدول 1) برای توضیح استفاده کنیم. یک فرد می‌تواند از اتوبوس یا مترو از خانه تا مرکز خرید 1 و 2 برای خرید استفاده کند. ویژگی‌های استفاده از اتوبوس و مترو در مرکز خرید 1 و 2 در جدول 1 نشان داده شده است.

در سناریوی انتخابی A، استفاده از اتوبوس به دلیل زمان کمتر سفر و انتخاب توسط مسافر برتر است، در حالی که استفاده از مترو در سناریوی انتخاب B و انتخاب توسط همان مسافر بهتر است. اگر یک الگوریتم ML مانند چنگ و همکاران. [4] پیش‌بینی‌هایی را بر اساس ویژگی‌های یک جایگزین انجام می‌دهد، پیش‌بینی می‌کند که اتوبوس در هر دو سناریو A و B انتخاب شده یا انتخاب نشده است زیرا ویژگی‌های اتوبوس در دو سناریو یکسان هستند. بدیهی است که چنین پیش‌بینی‌هایی با واقعیت همخوانی ندارد. دلیل نظری این است که مکانیسم‌های رفتاری واقعی در پس تصمیم‌گیری سفر این است که تصمیم‌گیرندگان بین گزینه‌های موجود (مقایسه ویژگی‌های آنها) برای یک سفر خاص معاوضه می‌کنند و گزینه‌ای را با بالاترین مزایای ذهنی انتخاب می‌کنند (مانند حداکثر مطلوبیت یا حداقل پشیمانی) پس از مقایسه‌های دقیق [22،23]. پیوند مستقیم الگوریتم‌های

طبقه‌بندی ML در تصمیم‌گیری سفر نمی‌تواند چنین مکانیسم‌های رفتاری و علیت اساسی انتخاب‌های مسافران را منعکس کند.

Table 1
An illustration example.

Factors	Choice scenario A: from home to shopping mall 1		Choice scenario B: from home to shopping mall 2	
	Bus	Metro	Bus	Metro
Cost	5 CNY	5 CNY	5 CNY	5 CNY
Travel time	45 min	65 min	45 min	35 min
Real choice	Chosen	Not chosen	Not chosen	Chosen

Note: 1 CNY = 0.14 dollar.

مهمتر از آن، ناآگاهی از مکانیسم‌های رفتاری منجر به سوگیری‌های قابل توجه در پیش‌بینی‌ها می‌شود، همانطور که در جدول 1 نشان داده شده است.

متأسفانه، بیشتر ادبیات مرتبط با استفاده از الگوریتم‌های ML برای مدل‌سازی تصمیم‌گیری سفر (به عنوان مثال، [16،18،21]) از روش‌های مدل‌سازی مشابه در [4] استفاده می‌کنند و سازگاری طبقه‌بندی‌کننده‌های ML را در زمینه مدل‌سازی تصمیم‌گیری سفر در نظر نمی‌گیرند. ساخت.

مکانیسم‌های رفتاری زیربنای تصمیم‌گیری مسافران این است که آنها تفاوت‌ها را در ویژگی‌های گزینه‌های مختلف موجود برای یک سفر مقایسه می‌کنند تا بهترین گزینه را انتخاب کنند، نه اینکه صرفاً بر اساس ویژگی‌های یک گزینه انتخاب کنند. تعیین اینکه آیا یک روش حمل و نقل برای یک سفر خاص صرفاً با توجه به ویژگی‌های حالت حمل و نقل انتخاب می‌شود، قابل قبول نیست. آنچه باعث تفاوت در فرآیند تصمیم‌گیری مسافران می‌شود، برتری نسبی یک روش حمل و نقل برای یک سفر خاص در مقایسه با سایر گزینه‌های رقیب است. از دیدگاه فنی، الگوریتم‌های طبقه‌بندی ML مانند ANN، SVM و DT در ابتدا برای اجرای طبقه‌بندی‌ها بر اساس ویژگی‌های یک نقطه داده سفارشی می‌شوند، نه اینکه برای طبقه‌بندی بر اساس اختلاف در ویژگی‌های نقاط داده مختلف طراحی شوند. این ممکن است دلیلی باشد که بسیاری از مطالعات با استفاده از الگوریتم‌های طبقه‌بندی ML تعیین می‌کنند که آیا یک حالت انتقال صرفاً با تکیه بر ویژگی‌های حالت حمل و نقل انتخاب می‌شود یا خیر. با این وجود، اینها با مکانیسم‌های رفتاری مسافران مطابقت ندارند.

Lhéritier و همکاران. [10] و ژائو و همکاران. [6] از سوگیری های در نظر نگرفتن جایگزین های رقابتی در الگوریتم های ML در مدل سازی تصمیم گیری های سفر آگاه بودند و جایگزین های انتخاب نشده را در داده های خود قرار دادند.

با این وجود، آنها فقط گزینه های انتخابی و قبلی را برای یک سفر در مجموعه داده های آموزشی گنجانده و از ساختار مدل سازی مشابهی مانند مطالعات قبلی استفاده کردند.

به ویژه، در مدل های آن ها، اینکه آیا یک حالت حمل و نقل انتخاب می شود یا خیر، همچنان صرفاً به ویژگی های یک حالت حمل و نقل بستگی دارد، نه اختلاف بین حالت های مختلف حمل و نقل موجود برای اتمام سفر. بنابراین، روش های آن ها هنوز ساختار الگوریتم های ML را به شیوه ای مناسب نمی سازند که بتواند مکانیسم های رفتاری پشت تصمیم گیری سفر را منعکس کند. برای پیش بینی تصمیم گیری در سناریوهای انتخابی که در نمونه های آموزشی وجود ندارد. ادبیات مربوطه به طور کلی گزارش می کند که الگوریتم های ML در مقایسه با مدل های سنتی مانند MNL بر اساس مجموعه داده هایشان، دقت پیش بینی بهتری دارند. با این حال، همیشه باید توجه داشت که به اصطلاح دقت پیش بینی در ادبیات مربوطه، نتایج پیش بینی کننده در اعتبارسنجی متقابل بود. مجموعه داده های مورد استفاده عموماً از نظرسنجی های SP مبتنی بر پرسشنامه بودند و شامل سناریوهای انتخابی محدود و حجم نمونه بودند، به این معنی که واریانس ها در ویژگی های نقاط داده قابل توجه نبودند. فرآیند اعتبارسنجی متقابل معمولی به طور تصادفی یک مجموعه داده را به چندین زیر مجموعه (مثلاً 5 یا 10) با اندازه یکسان تقسیم می کند و یک زیر مجموعه را برای اعتبارسنجی و بقیه را برای آموزش انتخاب می کند. ویژگی ها (به عنوان مثال، هزینه سفر و زمان) نقاط داده در نمونه های اعتبارسنجی عموماً در محدوده مشابه با نمونه های آموزشی هستند و حاوی ویژگی هایی نیستند که خارج از محدوده نمونه های آموزشی باشد. بنابراین تعجب آور نیست و حتی انتظار می رود که به اصطلاح دقت پیش بینی الگوریتم های ML بهتر از مدل های سنتی مانند مدل لوجیت چند جمله ای باشد. از آنجایی که الگوریتم های ML ساختارهای مدل را محدود نمی کنند، قدرت پیش بینی را در فرمول بندی مدل اولویت بندی کنید و مدل را به شیوه ای مبتنی بر داده آموزش دهید. همه اینها برای افزایش تناسب مدل در مجموعه داده های استفاده شده مفید هستند [6،8،24]. الگوریتم های ML مانند جنگل تصادفی با عمق درخت و مقدار درخت حتی می توانند تمام سناریوهای انتخابی ممکن را برشمارند و به دقت پیش بینی بسیار بالایی در اعتبارسنجی متقابل دست یابند، زیرا تنها چند سناریو انتخابی در مجموعه داده های مورد استفاده در ادبیات وجود دارد. تا آنجا که به ما مربوط می شود، هیچ مطالعه تجربی در مورد تصمیم گیری سفر، دقت پیش بینی الگوریتم های ML را در پیش بینی تصمیم گیری در

سناریوهای انتخابی که خارج از محدوده نمونه های آموزشی استفاده شده، یعنی برون یابی مدل هستند، بررسی نکرده است. الگوریتم های ML مبتنی بر داده اساساً دارای مسائل برون یابی حیاتی هستند، زیرا قادر به پیش بینی کلاس های نمونه با ویژگی های فراتر از محدوده نمونه های آموزشی نیستند [12]. از دیدگاه مدل سازی رفتاری، موضوع برون یابی در الگوریتم های ML برای مدل سازی تصمیم گیری سفر ناشی از عدم در نظر گرفتن مکانیسم های رفتاری در پس تصمیم گیری سفر در مدل ها و فقط مدل سازی تصمیم گیری سفر به روشی صرفاً مبتنی بر داده ها است. به طور خاص، الگوریتم های آموزش دیده ML در ادبیات مربوطه، مکانیسم های رفتاری را نشان نمی دهند که مسافران تصمیم نهایی را بسته به مقایسه بین گزینه های موجود برای یک سفر می گیرند. با این وجود، توانایی برون یابی برای پیش بینی انتخاب های سفر در موقعیت های انتخابی که در حال حاضر وجود ندارد، در زمینه های مدل سازی تصمیم گیری سفر بسیار مهم است. به طور همزمان، بسیار رایج است که مجموعه داده های موجود برای آموزش یک مدل انتخاب سفر، تنها سناریوهای انتخاب محدود از پاسخ دهندگان نمونه را پوشش می دهد، و به دست آوردن مجموعه داده هایی که همه موقعیت های انتخاب ممکن را در واقعیت پوشش می دهند، عملاً غیرممکن است، زیرا هر فرد دارای زمینه های سفر متفاوت و بنابراین متفاوت است. سناریوهای انتخاب مدل های سنتی مانند مدل لوجیت چندجمله ای، توانایی های برون یابی قابل قبولی دارند، زیرا مبتنی بر تئوری های رفتاری صریح هستند و مکانیسم های رفتاری پشت تصمیم گیری سفر را در مدل ها منعکس می کنند. اگرچه الگوریتم های ML در برخی جنبه ها برتری دارند (به عنوان مثال، ساختارهای مدل انعطاف پذیر)، اما به دلیل نادیده گرفتن مکانیسم های رفتاری در مدل، همچنان در برون یابی مدل کافی نیستند.

برای پر کردن شکاف های موجود در بالا، این مطالعه یک رویکرد مبتنی بر برون یابی ابتکاری را برای مدل سازی تصمیم گیری سفر با استفاده از مزایای متقابل مکمل یادگیری ماشین گروهی و نظریه تصمیم گیری مبتنی بر دانش پیشنهاد می کند. به طور دقیق تر، رویکرد پیشنهادی تئوری های تصمیم گیری مبتنی بر دانش شناخته شده از علوم رفتاری را در چارچوب مدل سازی مدل های گروهی ML ادغام می کند تا مکانیسم های رفتاری را در نظر بگیرد.

تا جایی که به ما مربوط می شود، این اولین مطالعه ای است که تئوری های رفتار را در الگوریتم های ML برای مدل سازی تصمیم گیری سفر به منظور افزایش توانایی پیش بینی و برون یابی گنجانده است. علاوه بر این، از سه مجموعه داده تجربی مختلف برای بررسی ظرفیت مدل سازی و قدرت پیش بینی رویکردهای پیشنهادی در مقایسه با روش های موجود در ادبیات استفاده می شود. به ویژه، ما به طور تجربی توانایی برون یابی رویکردها و مدل های پیشنهادی را در مطالعات موجود در پیش بینی تصمیم گیری مسافران در سناریوهای انتخاب برون

یابی که خارج از محدوده نمونه های آموزشی هستند، بررسی می کنیم، که تا آنجا که بهترین دانش ما، به طور جدی در موارد مربوطه نادیده گرفته شده است. ادبیات.

3. روش شناسی

3.1. روشی جدید برای فرمول بندی مجدد تصمیم گیری سفر به عنوان یک مساله طبقه بندی

این بخش فرعی را معرفی می کند که چگونه تصمیم گیری در سفر را به عنوان یک مساله طبقه بندی با استفاده از یک پارادایم (الگو) جدید دوباره فرموله می کنیم. مدل سازی تصمیم گیری سفر با هدف ترسیم و پیش بینی اینکه چگونه تصمیم گیرنده انتخاب های خود را در مواجهه با n گزینه برای پایان سفر (مانند رفت و آمد از خانه به محل کار) تحت یک سناریوی انتخابی خاص انجام می دهد. به عنوان مثال در این مطالعه تصمیم گیری در مورد انتخاب حالت حمل و نقل را در نظر می گیریم. اجازه دهید از یک سلول با تاپل ها در جدول 2 برای نشان دادن سناریوی انتخاب استفاده کنیم. X_{ijqm} مقدار ویژگی m th گزینه q th (یعنی حالت انتقال) را در سناریوی انتخاب j نشان می دهد. ما از $X_{i,j} = \{ X_{ijqm} \mid q = 1, 2, \dots, n ; m = 1, 2, \dots, k \}$ برای نشان دادن ماتریس حاوی ویژگی های همه گزینه های موجود در سناریوی انتخاب j برای تصمیم گیرنده i استفاده می کنیم.

Table 2
An example of choice scenarios and data formatting.

Scenarios	Alternatives (e.g., transport modes)	Features						Choices
j	1	X_{ij11}	X_{ij12}	...	X_{ij1m}	...	X_{ij1k}	C_{ij1}
	2	X_{ij21}	X_{ij22}	...	X_{ij2m}	...	X_{ij2k}	C_{ij2}

	q	X_{ijq1}	X_{ijq2}	...	X_{ijqm}	...	X_{ijqk}	C_{ijq}

	n_j	X_{ijn1}	X_{ijn2}	...	X_{ijnm}	...	X_{ijnk}	C_{ijn}
$j + 1$	1	$X_{i(j+1)11}$	$X_{i(j+1)12}$...	$X_{i(j+1)1m}$...	$X_{i(j+1)1k}$	$C_{i(j+1)1}$
	2	$X_{i(j+1)21}$	$X_{i(j+1)22}$...	$X_{i(j+1)2m}$...	$X_{i(j+1)2k}$	$C_{i(j+1)2}$

	q	$X_{i(j+1)q1}$	$X_{i(j+1)q2}$...	$X_{i(j+1)qm}$...	$X_{i(j+1)qk}$	$C_{i(j+1)q}$

	$n_{(j+1)}$	$X_{i(j+1)n1}$	$X_{i(j+1)n2}$...	$X_{i(j+1)nm}$...	$X_{i(j+1)nk}$	$C_{i(j+1)n}$

ویژگی های گزینه ها

در X_{ij} می‌تواند انواع مختلفی از عوامل تأثیرگذار مرتبط با تصمیم‌گیری سفر، از جمله ویژگی‌های سطح خدمات گزینه‌ها (به عنوان مثال، هزینه سفر و زمان) در سناریوی انتخاب، ویژگی‌های شخصی مسافران (مانند سن و جنسیت) باشد. و عوامل زمینه‌ای (به عنوان مثال، محیط‌های ساخته شده). ویژگی‌های سطح خدمات با گزینه‌های مختلف متفاوت است، اما ویژگی‌هایی مانند ویژگی‌های مسافران و عوامل زمینه‌ای برای همه گزینه‌ها در یک سناریوی انتخاب یکسان است (زیرا یک شخص همه گزینه‌ها را در سناریوی انتخابی برای همان سفر ارزیابی می‌کند). گزینه‌های موجود (به عنوان مثال، تعداد گزینه‌های موجود در یک سناریوی انتخاب) و ویژگی‌های گزینه ممکن است در سناریوهای مختلف انتخاب متفاوت باشد. $\epsilon_{C_{ijq}} \in \{0, 1\}$ یک متغیر باینری را نشان می‌دهد که نشان می‌دهد آیا گزینه q انتخاب شده است (یعنی 1) یا انتخاب نشده است (یعنی 0) توسط تصمیم‌گیرنده i در سناریوی انتخاب j . هدف نهایی مدل سازی روابط بین C_{ijq} و X_{ij} بر اساس داده‌های آموزشی و استفاده از مدل آموزش دیده برای پیش‌بینی تصمیم‌گیری سفر در سناریوهای انتخاب دیگر است.

با در نظر گرفتن تصمیم‌گیری سفر به عنوان یک مساله طبقه‌بندی، اکثر کارهای موجود ویژگی‌های گزینه‌های غیرانتخابی را در یک سناریوی انتخابی شامل نمی‌شوند و صرفاً ویژگی‌های گزینه‌های انتخابی را در مدل‌های آموزشی در نظر می‌گیرند (به عنوان مثال، [4,16,21]). ظاهراً اینها نمی‌توانند مکانیسم‌های رفتاری را منعکس کنند که مسافران تصمیمات سفر را بر اساس مقایسه بین گزینه‌های جایگزین در یک سناریوی انتخاب می‌گیرند. ما معتقدیم که گنجاندن اطلاعات در مورد گزینه‌های موجود اما غیرانتخاب شده در سناریوی انتخابی برای توسعه یک مدل کلی با برون‌یابی‌های پیشرفته ضروری است. برخی از مطالعات ویژگی‌های همه گزینه‌های X_{ij} را به عنوان متغیرهای توضیحی در مدل‌ها گنجانده و تصمیم‌گیری سفر را به عنوان یک رگرسیون طبقه‌بندی چند طبقه در نظر می‌گیرند. متغیر وابسته کلاسی است که یک نقطه داده به آن تعلق دارد، که قیاسی با حالت انتقال انتخابی است.

به عنوان مثال، ژائو و همکاران. [6] ویژگی‌های گزینه‌های انتخابی و غیرانتخابی را در یک سناریوی انتخابی به عنوان ویژگی‌های ورودی و حالت انتقال انتخابی را به عنوان خروجی برای آموزش الگوریتم‌های طبقه‌بندی ML در نظر گرفت. در [6]، هر ویژگی یک گزینه ممکن در یک سناریوی انتخاب، یک ویژگی در مدل است. با این حال، این روش صرفاً ویژگی‌های همه گزینه‌های ممکن را در یک سناریوی انتخاب در نظر می‌گیرد، اما هنوز قادر به انعکاس مکانیسم‌های رفتاری اساسی نیست. علاوه بر این، یکی دیگر از اشکال حیاتی این رویکرد این است که برای مدل‌سازی مجموعه داده‌ها با تعداد گزینه‌های مختلف در سناریوهای انتخاب مختلف، که یک پدیده رایج در تحلیل تصمیم‌گیری سفر است، ناسازگار است. به عنوان مثال، 3 و 4 گزینه رفت و آمد در

دسترس برای فردی A و Z به دلیل زمینه های رفت و آمد متفاوت، به ترتیب وجود دارد. اگر یک الگوریتم ML بر اساس مجموعه داده های 3 گزینه در یک سناریوی انتخابی و 4 ویژگی برای هر گزینه آموزش داده شود (بنابراین $3 \times 4 = 12$ ویژگی برای مدل)، نمی توان از الگوریتم برای پیش بینی انتخاب ها در سناریوهای با 4 گزینه استفاده کرد. و همان 4 ویژگی برای هر جایگزین (در مجموع $4 \times 4 = 16$ ویژگی). دلیل آن این است که الگوریتم های ML نمی توانند نقاط داده را با ویژگی های موجود در نمونه های آموزشی پیش بینی کنند.

برای رفع نواقص فوق، ما یک روش مدل سازی جایگزین پیشنهاد می کنیم. ما یک سناریوی انتخاب را با مجموعه ای از گزینه های ممکن (که یکی از آنها توسط تصمیم گیرنده انتخاب می شود) به عنوان نقطه داده در نظر می گیریم.

برای هر نقطه داده نشان داده شده در جدول 2، متغیرهای توضیحی ماتریس ویژگی های گزینه های موجود در سناریوی انتخاب هستند (یعنی X_{ij} و متغیر وابسته ماتریس $C_{ij} = C_{ij1}, C_{ij2}, \dots, C_{ijq}, \dots, C_{ijn}$ (نشان می دهد که آیا یک حالت حمل و نقل موجود در سناریوی انتخاب انتخاب شده است یا خیر.

احتمال 1 بودن C_{ijq} (یعنی انتخاب شده) یا 0 (یعنی انتخاب نشدن) در یک سناریوی انتخاب بر اساس X_{ij} با استفاده از یک الگوریتم طبقه بندی باینری نرم پیش بینی می شود.

طبقه بندی نرم به فرآیند تخمین احتمال شرطی $P(C_{ijq}|X_{ij})$ هر گزینه متعلق به یک کلاس (به عنوان مثال $C_{ijq} = 1$) در سناریوی انتخابی هنگام ارائه X_{ij} اشاره دارد، نه اینکه صرفاً یک برچسب کلاس پیش بینی شده ارائه کند. (یعنی به اصطلاح طبقه بندی سخت).

بنابراین، مدل احتمال انتخاب هر گزینه را در یک سناریوی انتخاب بر اساس X_{ij} پیش بینی می کند.

ما از احتمال انتخابی تخمینی هر گزینه در یک سناریوی انتخاب به عنوان امتیاز برای رتبه بندی گزینه ها استفاده می کنیم.

گزینه با بالاترین احتمال انتخاب شده به عنوان گزینه ترجیحی و انتخابی توسط تصمیم گیرنده تحت X_{ij} داده شده در سناریوی انتخاب در نظر گرفته می شود.

همه گزینه های دیگر در سناریوی انتخاب انتخاب نشده اند، زیرا تنها یک گزینه توسط تصمیم گیرنده در سناریوی انتخابی در زمینه رفتار سفر انتخاب می شود. از طریق فرآیند فوق، روش پیشنهادی می تواند همه گزینه های موجود را در یک سناریوی انتخابی در نظر بگیرد و سناریوهای انتخاب مدل سازی را با تعداد گزینه های مختلف،

که به ویژه برای برون‌یابی مدل برای پیش‌بینی سناریوهای انتخابی که در نمونه‌های آموزشی وجود ندارند، بسیار مهم هستند، در نظر بگیرد.

Table 2
An example of choice scenarios and data formatting.

Scenarios	Alternatives (e.g., transport modes)	Features						Choices
j	1	X_{ij11}	X_{ij12}	...	X_{ij1m}	...	X_{ij1k}	C_{ij1}
	2	X_{ij21}	X_{ij22}	...	X_{ij2m}	...	X_{ij2k}	C_{ij2}

	q	X_{ijq1}	X_{ijq2}	...	X_{ijqm}	...	X_{ijqk}	C_{ijq}

	n_j	X_{ijn1}	X_{ijn2}	...	X_{ijnm}	...	X_{ijnk}	C_{ijn}
$j + 1$	1	$X_{i(j+1)11}$	$X_{i(j+1)12}$...	$X_{i(j+1)1m}$...	$X_{i(j+1)1k}$	$C_{i(j+1)1}$
	2	$X_{i(j+1)21}$	$X_{i(j+1)22}$...	$X_{i(j+1)2m}$...	$X_{i(j+1)2k}$	$C_{i(j+1)2}$

	q	$X_{i(j+1)q1}$	$X_{i(j+1)q2}$...	$X_{i(j+1)qm}$...	$X_{i(j+1)qk}$	$C_{i(j+1)q}$

	$n_{(j+1)}$	$X_{i(j+1)n1}$	$X_{i(j+1)n2}$...	$X_{i(j+1)nm}$...	$X_{i(j+1)nk}$	$C_{i(j+1)n}$

3.2. چارچوب و فرآیند مدل‌سازی

همانطور که گفته شد، ناکافی بودن استفاده مستقیم از الگوریتم‌های طبقه‌بندی ML در ادبیات کنونی برای مدل‌سازی تصمیم‌گیری سفر این است که ساختار مدل احتمال انتخاب یک جایگزین تحت یک سناریوی انتخاب خاص را با ویژگی‌های جایگزین تعیین می‌کند و هیچ رابطه‌ای با سایر گزینه‌های ممکن در سناریوی انتخاب ندارد. به این ترتیب، مدل قادر به انعکاس مکانیسم‌های رفتاری زیربنای انتخاب‌های مشاهده‌شده مسافران نیست و صرفاً بر اساس روشی صرفاً مبتنی بر داده‌ها ساخته می‌شود. این منجر به کمبود برون‌یابی مدل می‌شود. ما یک راه حل جدید برای این موضوع با ادغام نظریه‌های تصمیم‌گیری مبتنی بر دانش در الگوریتم‌های ML پیشنهاد می‌کنیم، همانطور که در شکل 1 نشان داده شده است. تفکر اساسی راه حل پیشنهادی بازسازی ویژگی‌های هر گزینه در یک سناریوی انتخاب شرح داده شده در بخش است. 3.1، بر اساس نظریه‌های تصمیم‌گیری مبتنی بر دانش. هدف از این کار منعکس کردن حقایقی است که تصمیم‌گیرندگان تصمیم‌گیری می‌کنند که به تفاوت‌های بین گزینه‌ها بستگی دارد نه ارزش‌های مطلق ویژگی‌های یک گزینه. ما در اینجا از یک مثال مفصل برای نشان دادن فرآیند استفاده می‌کنیم. جدول 3 یک مثال گویا از یک سناریوی انتخاب را ارائه می‌دهد. ویژگی‌های اصلی حالت‌های حمل و نقل احتمالی در سناریوی انتخاب، ویژگی‌های سطح خدمات گزینه‌های موجود مانند زمان سفر، هزینه و سطح ازدحام در کالسکه است. روش‌های تبدیل ویژگی‌های سفارشی مبتنی بر تئوری‌های رفتاری برای فرمول‌بندی مجدد هر ویژگی (مثلاً X_{ijqm}) یک گزینه به عنوان یک ویژگی تبدیل‌شده

جدید (به عنوان مثال، $T(X_{ijqm})$) که برتری یا فرودستی ویژگی جایگزین را در مقایسه منعکس می‌کند، پیشنهاد می‌شود. به همان ویژگی گزینه‌های دیگر در سناریوهای انتخاب، یعنی $X_{ijqm} \rightarrow T(X_{ijqm})$. این مکانیسم رفتاری را تعبیه می‌کند که آنچه در تصمیم‌گیری سفر اهمیت دارد، مقایسه با گزینه‌های رقیب است.

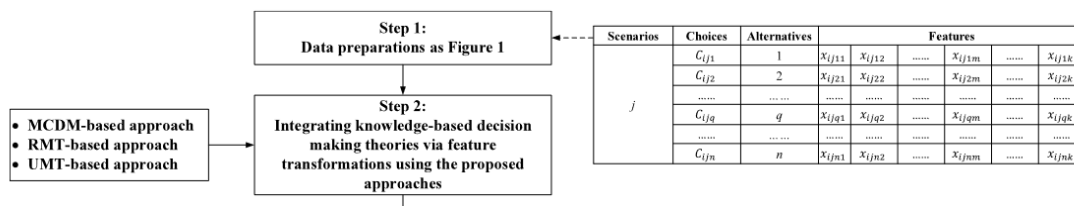
به عنوان مثال، هزینه خودرو در مثال جدول 30 است و به $T_{cost}(30)$ تبدیل می‌شود که در آن تابع $T(X_{ijqm})$ بعداً با جزئیات معرفی خواهد شد. زمان سفر مترو مثال در جدول 50 است و با $T_{time}(50)$ تبدیل می‌شود. تمام ویژگی‌های اصلی مربوط به متغیرهای سطح خدمات جایگزین‌ها در سناریوی انتخاب توسط رویکردهای تبدیل ویژگی پیشنهادی بر اساس نظریه‌های رفتاری پردازش می‌شوند. ویژگی‌های تبدیل‌شده هر گزینه، مقادیر مطلق ویژگی‌های هر گزینه نیستند و به دلیل تعبیه تئوری‌های تصمیم‌گیری مبتنی بر دانش توسط تبدیل‌های ویژگی، دارای برتری یا فرودستی جایگزین در مقایسه با سایر گزینه‌ها در سناریوی انتخاب هستند. اینها مکانیسم‌های رفتاری زیربنای انتخاب‌های افراد را منعکس می‌کنند که تصمیم‌گیرندگان بسته به مقایسه گزینه‌های موجود در یک سناریوی انتخاب، انتخاب می‌کنند.

پس از آن، یک الگوریتم ML برای مدل‌سازی روابط بین گزینه انتخابی (یعنی متغیر وابسته) و ویژگی‌های تبدیل‌شده (یعنی متغیرهای توضیحی) با استفاده از مزایای آن از نظر مدل‌سازی روابط غیرخطی بین متغیرهای توضیحی و متغیر وابسته، مدل انعطاف‌پذیر استفاده می‌شود. مشخصات، و یادگیری تعاملات پیچیده بین متغیرهای توضیحی به روش داده محور. با در نظر گرفتن مثال در جدول 3 برای نشان دادن، ویژگی‌های ورودی در الگوریتم ML، ویژگی‌های تبدیل‌شده یک گزینه در سناریوی انتخاب است، و خروجی احتمال انتخاب گزینه توسط تصمیم‌گیرنده در سناریوی انتخاب از طریق طبقه‌بندی نرم که در بخش 3.1 نشان داده شده است. پس از آن، فرآیند توضیح داده شده در آخرین پاراگراف بخش 3.1 برای تعیین اینکه کدام گزینه انتخاب پیش‌بینی شده در سناریوی انتخاب است، استفاده می‌شود. تازگی چارچوب پیشنهادی، ادغام نظریه‌های رفتاری در الگوریتم‌های ML با بازسازی ویژگی است. رویکرد پیشنهادی مزایای تئوری‌های رفتاری در تفاسیر رفتاری و برون‌یابی، و برتری الگوریتم‌های ML در مدل‌سازی روابط پیچیده را با هم ترکیب می‌کند. انتظار می‌رود رویکرد پیشنهادی هم قدرت مدل‌سازی و هم دقت پیش‌بینی را برای به تصویر کشیدن تصمیم‌گیری سفر بهبود بخشد. به خصوص، رویکرد پیشنهادی تئوری‌های رفتاری را در ساختار مدل تعبیه می‌کند تا برون‌یابی مدل را افزایش دهد، که یک نیاز بسیار مهم در مدل‌سازی تصمیم‌گیری سفر است.

ما به‌ویژه توانایی برون‌یابی مدل‌های پیشنهادی را در پیش‌بینی تصمیم‌گیری مسافران در سناریوهای انتخابی که خارج از محدوده نمونه‌های آموزشی مبتنی بر مجموعه داده‌های تجربی هستند، آزمایش خواهیم کرد.

3.3. ادغام تئوری‌های تصمیم‌گیری مبتنی بر دانش در الگوریتم‌های ML مجموعه‌ای درختی

برای ادغام نظریه‌های تصمیم‌گیری مبتنی بر دانش در الگوریتم‌های ML در مرحله 2 از شکل 1، از سه نوع مختلف تئوری رفتار معروف، از جمله تصمیم‌گیری چند معیاره، نظریه حداقل‌سازی پشیمانی، و نظریه حداکثرسازی سودمندی استفاده و بررسی می‌کنیم. این سه نظریه معیارهای تصمیم‌گیری را از دیدگاه‌های مختلف از پیش تعریف می‌کنند. با این حال، شایستگی‌های مشترک این سه نظریه می‌توانند برتری یا حقارت نسبی را در ویژگی‌های یک جایگزین در مقایسه با سایرین در سناریوی انتخاب منعکس کنند و مکانیسم‌های رفتاری قابل قبولی را که در انتخاب‌های مسافران نهفته است، منعکس کنند. این نظریه‌های رفتاری به طور گسترده در مدل‌های مختلف تصمیم‌گیری مورد استفاده قرار گرفته‌اند. بنابراین، در اینجا برای بازسازی ویژگی‌های جایگزین‌ها در هر سناریوی انتخابی برای جاسازی مکانیسم‌های رفتاری در چارچوب مدل‌سازی، همانطور که در بخش 3.2 نشان داده شده است، استفاده می‌شوند. ما عملکرد استفاده از سه نظریه را بر اساس تحلیل تجربی مقایسه می‌کنیم.



MCDM – topsis رویکرد	ادغام نظریه‌های تصمیم‌گیری مبتنی بر دانش از طریق تبدیل ویژگی‌ها با استفاده از رویکرد پیشنهادی
RMT رویکرد	
UMT رویکرد	

تصمیم‌گیری چند معیاره (MCDM) فرآیندی را نشان می‌دهد که چگونه تصمیم‌گیرندگان به طور صریح معیارهای متضاد متعدد را در تصمیم‌گیری ارزیابی می‌کنند و به طور گسترده برای تصمیم‌گیری در حوزه‌های مختلف به کار رفته است [25]. اساس MCDM این است که تصمیم‌گیرندگان تصمیمات خود را بر اساس اختلاف بین ویژگی‌های گزینه‌ها اجرا می‌کنند [26]. فرمول‌های مدل‌های مختلفی از MCDM وجود دارد

[25،26]. تکنیک برای ترتیب اولویت بر اساس شباهت به راه حل ایده آل (TOPSIS) یکی از رایج ترین روش های MCDM در هر دو کاربرد تحقیقاتی و عملی است [27،28]. TOPSIS بر اساس این مفهوم ساخته شده است که گزینه ترجیحی تصمیم گیرنده باید کمترین فاصله هندسی را از بهترین گزینه و دورترین فاصله هندسی را از بدترین گزینه داشته باشد [27،28]. در اینجا، ما TOPSIS را برای نشان دادن کاربرد MCDM در رویکرد پیشنهادی خود به دلیل سازگاری و شیوع عالی آن اتخاذ می کنیم. با این حال، هنگام استفاده از TOPSIS در تصمیم گیری چند ویژگی، به وزن های قبلی ویژگی های مختلف (یعنی درجه اهمیت یک ویژگی در تصمیم گیری) نیاز است. به طور کلی، وزن ویژگی های مختلف در TOPSIS شناخته شده است. با این وجود، وزن ویژگی ها از قبل در موارد ما شناخته نشده است (به عنوان مثال، وزن زمان سفر در تصمیم گیری انتخاب حالت) و در واقع پارامترهای مدل هستند که باید تخمین زده شوند. بنابراین، ما نمی توانیم TOPSIS را برای MCDM با وزن مشخصی از ویژگی ها، همانطور که بیشتر ادبیات انجام می دهند، اعمال کنیم. ما، در اینجا، از مفهوم TOPSIS برای مقایسه برتری یک ویژگی واحد از یک گزینه در مقایسه با ویژگی مشابه سایر گزینه ها در یک سناریوی انتخاب استفاده می کنیم. بر اساس TOPSIS، یک ویژگی از یک جایگزین در هر سناریوی انتخاب نشان داده شده در جدول 2 می تواند با استفاده از

$$T_{TOPSIS}(x_{ijqm}) = \frac{|x_{ijqm} - x^*_{ijm}|}{|x^{\#}_{ijm} - x^*_{ijm}|} \quad (1)$$

$$x^*_{ijm} = \max\{x_{ijqm} | q = 1, 2, \dots, n\}$$

$$x^{\#}_{ijm} = \min\{x_{ijqm} | q = 1, 2, \dots, n\}$$

جایی که $T_{TOPSIS}(x_{ijqm})$ مقدار تبدیل شده برای ویژگی m th گزینه q th در سناریوی انتخاب j برای فرد i را نشان می دهد بازسازی x_{ijm}^* و $x_{ijm}^{\#}$ به ترتیب بدترین و بهترین موقعیت های ویژگی m th از همه گزینه ها در سناریوی انتخاب j هستند.

در زمینه انتخاب حالت سفر، بدترین و بهترین مقادیر به ترتیب حداکثر و حداقل مقادیر در بین همه گزینه ها هستند. زیرا ویژگی های در نظر گرفته شده مانند هزینه سفر و زمان تأثیرات منفی بر سودمندی یک جایگزین نشان می دهد.

به عنوان مثال، بدترین و بهترین مقادیر هزینه سفر در مثال جدول 3 به ترتیب 30 یوان و 3 یوان است. لازم به ذکر است که فرآیند تبدیل ویژگی نشان داده شده در معادله (1) به صورت ویژگی به ویژگی اجرا می شود زیرا

ما وزن ویژگی‌ها را از قبل نمی‌دانیم. مقدار تبدیل شده هزینه پارک و سوار شدن در مثال جدول 3 برابر با

$$\frac{|16 - 30|}{|2 - 30|} = 0.5$$

مقدار تبدیل شده زمان سفر Park and Ride در مثال جدول 3 برابر با

$$\frac{|35 - 50|}{|25 - 50|} = 0.6$$

اوزان تبدیل شده است

ویژگی‌ها خروجی‌های الگوریتم ML مورد استفاده هستند و بر اساس داده‌های تجربی تخمین زده می‌شوند. همین فرآیند برای رویکردهای تبدیل ویژگی زیر انجام می‌شود.

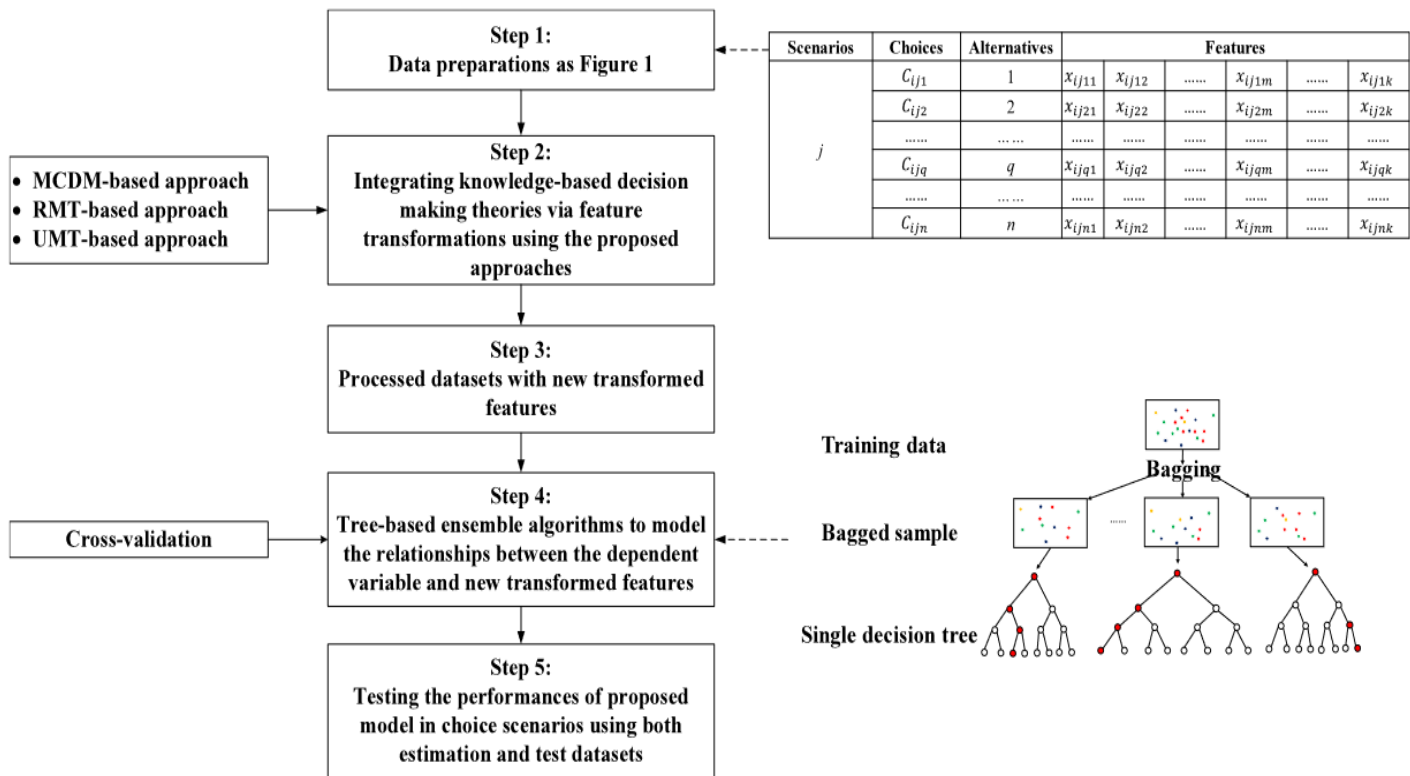


Fig. 1. The proposed framework.

Table 3
An illustrative example of a choice scenario about mode choice.

Scenarios	Alternatives (e.g., transport modes)	Features				Choices
		Cost	Travel time	Travel time reliability	Passenger density in the carriage	
j	1 (car)	30 CNY	25 min	8	0	C_{ij1}
	2 (metro)	4 CNY	50 min	2	0	C_{ij2}
	3 (Park and Ride)	16 CNY	35 min	10	0	...
	4 (bus)	3 CNY	35 min	14	6	C_{ij4}

دومین نظریه مورد استفاده نظریه کمینه سازی پشیمانی (RMT) است. RMT پیشنهاد شده توسط لومز و ساگدن [29] بر اساس این تصور است که تصمیم گیرندگان برای اجتناب از موقعیت‌هایی که در آن گزینه‌های

از دست رفته بهتر از گزینه انتخاب شده هستند، انتخاب می کنند، که منجر به پشیمانی پس از انتخاب می شود. به عبارت دیگر، RMT معتقد است که افراد پشیمانی پیش بینی شده در انتخاب را با اجرای مقایسه بین گزینه ها به حداقل می رساند. RMT در چارچوب مدل های انتخاب گسسته برای مدل سازی تصمیم گیری سفر مانند مدل کمینه سازی پشیمانی [23،30،31] استفاده شده است. بر اساس RMT، ما دو رویکرد متفاوت مبتنی بر RMT را برای بازسازی ویژگی های گزینه ها در یک سناریوی انتخاب پیشنهاد می کنیم تا مکانیسم های رفتاری را منعکس کنند.

اولین رویکرد مبتنی بر RMT فرض می کند که افراد پشیمانی مرتبط با یک گزینه را با جمع آوری پشیمانی از هر یک از ویژگی های گزینه، با مراجعه به Chorus و همکاران، ارزیابی می کنند. [23] و کویگین [32]. پشیمانی یک ویژگی یک گزینه در سناریوی انتخاب با مقایسه آن با بهترین ارزش ویژگی در بین همه گزینه ها به دست می آید. بر اساس RMT، فرمول بازسازی ویژگی های گزینه ها است

$$T_{RMT 1}(x_{ijqm}) = \max\{\max\{0, x_{ijqm} - x_{ijq'm}\} | q' = 1, 2, \dots, n\} \quad (2)$$

که در آن $T_{RMT 1}(x_{ijqm})$ مقدار تبدیل شده برای ویژگی m th گزینه q th را در سناریوی انتخاب j نشان می دهد. با توجه به اینکه ویژگی های در نظر گرفته شده در زمینه تصمیم گیری سفر با سودمندی یک گزینه ارتباط منفی دارد، هر چه ویژگی یک گزینه بزرگتر باشد، تصمیم گیرنده در صورت انتخاب گزینه، پشیمان بیشتری خواهد داشت. رویکرد دوم مبتنی بر RMT همچنین پشیمانی یک گزینه را بر اساس ویژگی به ویژگی محاسبه می کند. با این حال، دومین رویکرد مبتنی بر RMT فرض می کند که r' -gret یک گزینه به جای بهترین گزینه، به همه جایگزین های قبلی مرتبط است [30]. بر اساس این فرض، پشیمانی یک ویژگی یک گزینه با مقایسه ویژگی گزینه با همان ویژگی های همه گزینه های دیگر در یک سناریوی انتخاب، به عنوان مجموع پشیمانی های دوتایی در نظر گرفته می شود، همانطور که در معادله نشان داده شده است. (3).

$$T_{RMT 2}(x_{ijqm}) = \sum_{q'=1}^n (\max\{0, x_{ijqm} - x_{ijq'm}\}) \quad (3)$$

TRM که در آن $T_{RMT 2}(x_{ijqm})$ مقدار تبدیل شده برای ویژگی m th از جایگزین q th با استفاده از روش دوم مبتنی بر RMT است. سومین نظریه مورد استفاده، نظریه حداکثرسازی سودمندی (UMT) است که رایج ترین نظریه رفتاری است که برای مدل سازی تصمیم گیری سفر استفاده می شود. مدل های سودمند تصادفی معروف و مدل های مشتق شده آن ها همگی بر اساس UMT [33] پایه گذاری شده اند. به طور خلاصه، UMT معتقد است که افراد در طول فرآیند تصمیم گیری به دنبال کسب بالاترین رضایت یا مطلوبیت های مثبت هستند. فرض بر این است که تصمیم گیرندگان پس از ایجاد معاوضه در میان ویژگی های همه گزینه های موجود در

یک سناریوی انتخاب، گزینه را با بالاترین سودمندی ذهنی انتخاب می کنند. رویکرد مبتنی بر UMT پیشنهادی برای بازسازی ویژگی‌ها، مکانیسم رفتاری را منعکس می کند که مسافران تصمیم می گیرند تا پس از مقایسه، گزینه‌ای را با بالاترین سودمندی ذهنی انتخاب کنند. اگر یکی از ویژگی‌های گزینه انتخابی برتر (یعنی کوچکتر) نسبت به ویژگی‌های مشابه سایر گزینه‌های فراموش شده باشد، به یک مطلوبیت مثبت منجر می شود. میانگین مطلوبیت مثبت یک ویژگی یک گزینه در سناریوی انتخاب با فرمول زیر محاسبه می شود

$$T_{UMT}(X_{ijqm}) = \sum_{q=1}^n (\min \{ 0, X_{ijqm} - X_{ijqm} \}) / (n - 1) \quad (4)$$

که در آن $T_{UMT}(X_{ijqm})$ ویژگی تبدیل شده برای ویژگی m th از جایگزین q th با استفاده از رویکرد مبتنی بر UMT است.

برای الگوریتم ML در مرحله 4 از شکل 1، این مطالعه از جنگل تصادفی (RF) [34] استفاده می کند که یک روش رایج یادگیری گروهی مبتنی بر درخت برای طبقه بندی است. اگرچه چندین الگوریتم طبقه بندی ML دیگر مانند SVM، ANN و DTs می توانند مورد استفاده قرار گیرند، RF به دلیل مزایای آن در ساختار مدل، ویژگی‌های مجموعه و تفسیرهای رفتاری در مدل سازی تصمیم گیری سفر برتر شناخته شده است [6،35]. برخلاف یک درخت تصمیم واحد، RF به طور متناوب مجموعه ای از درختان تصمیم گیری تصادفی ساده را ترکیب می کند تا به خوبی کلیت مدل را افزایش دهد و واریانس پیش بینی ها را کاهش دهد [6،35]. به روش بوت استرپینگ، RF تخصیص کلاس ها را در پیش بینی ها بر اساس رای اکثریت همه درخت های تصمیم در جنگل تعیین می کند و می تواند احتمال یک نقطه داده متعلق به یک کلاس (یعنی طبقه بندی نرم) را خروجی دهد. علاوه بر این، متفاوت از الگوریتم‌هایی مانند ANN و SVM، یکی از ویژگی‌های جذاب RF برای مدل سازی تصمیم گیری سفر، توانایی آن در استخراج اهمیت ویژگی، یعنی وزن‌های فوق الذکر ویژگی‌ها در مدل است.

شایستگی RF می تواند وزن ویژگی عوامل مختلف را بدست آورد و بنابراین برای تفسیرهای رفتاری (به عنوان مثال، استخراج ارزش زمان بر اساس نتایج) استفاده می شود.

برای هر درخت تصمیم در RF، یک زیرمجموعه با گزینه نمونه‌های آموزشی به طور تصادفی انتخاب می شود تا درخت تصمیم (یعنی بسته بندی) را آموزش دهد، و مجموعه‌ای جزئی از ویژگی‌های به طور تصادفی انتخاب شده در هر گره تقسیم در درخت تصمیم استفاده می شود.

از طریق دو تصادفی (یعنی کیسه‌بندی و انتخاب تصادفی ویژگی‌ها برای یک گره تقسیم‌کننده)، RF به تنوع درخت‌های تصمیم‌گیری مختلف، استحکام در برابر داده‌های پر سر و صدا، و ظرفیت مدیریت پیش‌بینی اضافی دست می‌یابد [34]. RF همچنین می‌تواند متغیرهای عددی و طبقه‌ای را در مدل جای دهد [35، 6]. در هر درخت تصمیم، هر گره داخلی یک فرآیند تقسیم را برای دسته‌بندی داده‌ها به گره‌های فرزند اجرا می‌کند. با تکرار بازگشتی فرآیند تقسیم، درخت تصمیم مجموعه داده‌های آموزشی را به زیر منطقه‌هایی با مشاهدات کمتر تقسیم می‌کند و تا زمانی که قوانین توقف از پیش تعریف‌شده برآورده شوند، متوقف می‌شود. بوت استرپ کردن، RF بسیاری از درختان تصمیم را آموزش می‌دهد و پیامدهای نهایی را با میانگین‌گیری بیش از همه پیش‌بینی‌ها از رای اکثریت به دست می‌آورد [34]. در نهایت، RF احتمال انتخابی هر گزینه را در یک سناریوی انتخابی خروجی خواهد داد. آموزش RF عبارت است از انتخاب متمایزترین ویژگی‌ها و آستانه‌ها برای هر گره در درخت‌های تصمیم برای به حداقل رساندن ناخالصی در مناطق فرعی تقسیم‌بندی شده. معمولاً از دو معیار ناخالصی استفاده می‌شود که شامل GINI و ناخالصی آنتروپی می‌شود [36]. ناخالصی GINI در مورد ما برای محاسبه سریع آن انتخاب شده است و تفاوت قابل توجهی در نتایج استفاده از این دو معیار وجود ندارد. ناخالصی (GIM) GINI یک گره توسط

$$GIM = \sum_{i=1}^N f_i(1 - f_i) \quad (5)$$

که در آن f_i بسامد برچسب i (یعنی حالت حمل و نقل در زمینه مدل‌سازی انتخاب‌های حالت سفر) در یک گره است و N تعداد برچسب‌های منحصربه‌فرد است.

4. مجموعه داده‌ها، آموزش مدل و تست

4.1. آزمایش‌ها و مجموعه داده‌های جمع‌آوری شده

سه مجموعه داده شامل یک مجموعه داده برای تخمین مدل و دو مجموعه داده دیگر برای آزمایش‌های مدل، برای بررسی کامل عملکردهای پیش‌بینی مدل‌های پیشنهادی در سناریوهای مختلف انتخاب استفاده می‌شوند. مجموعه داده برآورد برای آموزش مدل‌های پیشنهادی با اعتبارسنجی متقابل استفاده می‌شود. در مجموعه داده تخمینی، داده‌ها به نمونه‌های آموزشی و نمونه‌های اعتبارسنجی از طریق فرآیند اعتبارسنجی متقابل 10 پوشه‌ای تقسیم می‌شوند. اگرچه اعتبارسنجی متقابل به طور تصادفی نمونه‌های آموزشی و اعتبارسنجی را انتخاب می‌کند، متغیرهای توضیحی (یعنی ویژگی‌ها) در نمونه‌های اعتبارسنجی عموماً در مقیاس‌ها یا محدوده‌هایی مشابه با نمونه‌های آموزشی هستند. بنابراین، عملکردهای پیش‌بینی‌کننده در اعتبارسنجی متقابل

بر اساس مجموعه داده‌های تخمینی، صرفاً توانایی مدل‌های آموزش‌دیده برای پیش‌بینی تصمیم‌گیری سفر در سناریوهای انتخابی را نشان می‌دهند که در آن ویژگی‌ها محدوده‌های مشابهی با نمونه‌های آموزشی دارند. به عبارت دیگر، تنها با استفاده از اعتبارسنجی متقاطع در مجموعه داده برآورد، قادر به آزمایش عملکرد پیش‌بینی مدل‌های آموزش‌دیده در پیش‌بینی تصمیم‌گیری در سناریوهای انتخاب با ویژگی‌های خارج از محدوده، یعنی برون‌یابی مدل‌های آموزش‌دیده نیست. با این وجود، همانطور که در بالا ذکر شد، یکی از ظرفیت‌های اساسی مورد نیاز برای مدل‌سازی تصمیم‌گیری سفر در سناریوهای انتخابی است که در مجموعه داده‌های برآورد وجود ندارد. این محدودیت ما را تشویق می‌کند تا از دو مجموعه داده آزمایشی دیگر برای بررسی بیشتر برون‌یابی روش‌های پیشنهادی استفاده کنیم. دو مجموعه داده آزمایشی شامل سناریوهای انتخابی است که در مجموعه داده تخمینی وجود ندارد و ویژگی‌هایی که خارج از محدوده مجموعه داده‌های برآورد هستند. تا آنجا که به ما مربوط می‌شود، هیچ ادبیاتی در زمینه مدل‌سازی تصمیم‌گیری سفر وجود ندارد که توانایی برون‌یابی مدل الگوریتم‌های ML را بررسی کند. الگوریتم‌های آموزش‌دیده ML بر اساس مجموعه داده‌های تخمینی برای آزمایش قدرت پیش‌بینی آنها در دو مجموعه داده آزمایشی استفاده می‌شود.

مجموعه داده تخمینی از یک نظرسنجی اولویت‌اعلام شده (SP) در مورد انتخاب حالت رفت و آمد در سال 2017، شانگهای چین بدست آمد. در سناریوهای انتخابی این نظرسنجی، چهار حالت رفت و آمد رایج (ماشین، مترو، پارک و سوار، مترو و اتوبوس) گنجانده شد و چهار متغیر کلیدی سطح خدمات شامل هزینه، زمان سفر، قابلیت اطمینان زمان سفر و درون شلوغی وسایل نقلیه در نظر گرفته شد. از پاسخ‌دهنده خواسته می‌شود که حالت حمل و نقل ترجیحی خود را در سناریوهای SP داده شده انتخاب کند (برای جزئیات بیشتر به پیوست مراجعه کنید). علاوه بر ویژگی‌های سطح خدمات شیوه‌های حمل‌ونقل، ویژگی‌های شخصی پاسخ‌دهندگان از جمله ویژگی‌های جمعیت‌شناختی (به عنوان مثال، جنسیت، سن، تحصیلات، شغل، درآمد، مالکیت خودرو) و زمینه‌های رفت‌وآمد (مانند حالت رایج و مسافت) جمع‌آوری شد. و همچنین به دلیل تأثیر آنها بر تصمیم‌گیری سفر

هجده سناریوی انتخاب مختلف با استفاده از روش‌های طراحی کارآمد طراحی شده است [37]. از یک پاسخگو خواسته شد تا شش سناریوی انتخاب SP را که به طور تصادفی از میان هجده سناریو انتخاب شده بودند، به پایان برساند. ویژگی‌ها و توضیحات در مورد سناریوها و بررسی‌های SP در پیوست خلاصه شده است. مجموعه داده دارای 2316 مشاهدات موثر از 386 پاسخ‌دهنده با پوشش گسترده‌ای از ویژگی‌های اجتماعی-اقتصادی است. شرح مفصل‌تر از نظرسنجی و پاسخ‌دهندگان جمع‌آوری شده در [37] موجود است. ویژگی‌های در نظر

گرفته شده هر گزینه شامل متغیرهای عددی و دسته بندی می شود. تعاریف و کدگذاری آنها برای تجزیه و تحلیل در جدول 4 نشان داده شده است. برای متغیرهای سطح خدمات جایگزین ها در یک سناریوی انتخاب (به عنوان مثال، زمان سفر، هزینه، ازدحام خودرو، و قابلیت اطمینان زمان سفر)، رویکردهای پیشنهادی شرح داده شده در بخش 3.3 برای انجام تبدیل ویژگی ها، که با هدف ادغام مکانیسم های رفتاری مبتنی بر دانش انجام می شود، استفاده می شود. علاوه بر ویژگی های متغیرهای سطح خدمات، ما عوامل ذهنی مانند ویژگی های جمعیت شناختی (به عنوان مثال، سن و درآمد) و زمینه های سفر را نیز در نظر می گیریم زیرا آنها نیز از عوامل تأثیرگذار مهم در تصمیم گیری مسافران هستند. به عنوان مثال، افراد مختلف تمایلات متفاوتی به حالت های حمل و نقل مختلف دارند (مثلاً افراد با درآمد بالا معمولاً خودروهای شخصی را بیشتر ترجیح می دهند) و وزن های متفاوتی نسبت به متغیرهای سطح خدمات دارند (مثلاً افراد با درآمد بالا وزن کمتری نسبت به هزینه نشان می دهند). متفاوت از متغیرهای سطح خدمات گزینه ها، عوامل ذهنی تصمیم گیرنده برای همه گزینه ها در سناریوهای انتخاب یکسان است، زیرا همان تصمیم گیرنده همه گزینه ها را ارزیابی می کند. عوامل ذهنی به عنوان متغیرهای طبقه بندی شده با اشاره به گائو و همکاران در نظر گرفته می شوند. [37]. قوانین طبقه بندی دقیق برای عوامل ذهنی در جدول 4 توضیح داده شده است. برای متغیرهای طبقه بندی شده در جدول 4، رمزگذاری یک داغ برای تبدیل یک متغیر طبقه ای به ماتریسی از متغیرهای ساختگی برای مدیریت متغیرهای طبقه بندی در مدل جنگل تصادفی استفاده می شود.

اولین مجموعه داده آزمایشی یک مجموعه داده ترکیبی است که بر اساس مجموعه داده برآورد بالا ساخته شده است. مجموعه داده ترکیبی برای آزمایش توانایی برون یابی مدل های آموزش دیده سفارشی شده است. برای دستیابی به هدف آزمایش برون یابی، ما به طور مصنوعی یک گزینه ترکیب شده برای هر سناریوی انتخابی در مجموعه داده تخمین ایجاد می کنیم. جدول 5 نمونه ای از نحوه ایجاد مجموعه داده ترکیبی بر اساس مجموعه داده های برآورد بالا را نشان می دهد. محتویات با سایه ها یک سناریوی انتخاب واقعی در مجموعه داده تخمینی هستند. مشاهده کردیم که پاسخ دهنده خودرو را در سناریوی انتخاب بر اساس ترجیحات ذهنی خود انتخاب کرد.

این نشان می دهد که خودرو در سناریوی انتخاب جدول 5 بیشترین سود ذهنی را برای پاسخ دهنده در مقایسه با سایر گزینه ها داشته است. محتویات بدون سایه سناریوی انتخاب ترکیبی مرتبط هستند. سناریوی ترکیبی مربوطه یک گزینه ترکیبی جدید اضافه می کند که متغیرهای سطح سرویس 75 درصد مقادیر گزینه انتخاب شده در سناریوی انتخاب واقعی هستند. همانطور که در جدول 5 نشان داده شده است، متغیرهای سایر گزینه

ها بدون تغییر باقی می ماند. بنابراین، گزینه ترکیبی اضافه شده بسیار بهتر از جایگزین انتخاب شده در موقعیت انتخاب قبلی است. با توجه به اینکه مخاطب در سناریوی انتخاب واقعی خودرو را انتخاب کرده است، می توان نتیجه گرفت که همان پاسخ دهنده در صورت مواجهه با سناریوی انتخاب ترکیبی، گزینه ترکیبی را انتخاب می کند. با همان فرآیند، یک سناریوی انتخاب ترکیبی می تواند برای هر سناریوی انتخاب واقعی در مجموعه داده تخمینی ایجاد شود، که مجموعه داده سنتز را تشکیل می دهد. سناریوهای سنتز شامل ویژگی هایی هستند که خارج از محدوده سناریوهای انتخابی در مجموعه داده های برآورد (یعنی گزینه سنتز) هستند و برای بررسی برون یابی مدل های پیشنهادی استفاده می شوند. مدل های آموزش دیده بر اساس مجموعه داده های برآورد بیشتر برای پیش بینی تصمیم گیری سفر در سناریوهای انتخاب ترکیبی آزمایش می شوند.

مجموعه داده آزمایشی دوم از نظرسنجی SP دیگری در مورد رفتار انتخاب حالت برای رفت و آمد است که در سال 2019 و همچنین در شانگهای چین جمع آوری شد. سناریوهای انتخاب در نظرسنجی فرض می کردند که شرکت پاسخ دهنده محل کار را به مکان جدیدی تغییر داده است و چندین حالت حمل و نقل در دسترس برای رفت و آمد به محل کار جدید وجود دارد. پاسخ دهندگان انتخاب کردند که از کدام حالت حمل و نقل در سناریوهای SP داده شده استفاده کنند (برای جزئیات به پیوست مراجعه کنید). گزینه های ممکن شامل ماشین، مترو، اتوبوس و تاکسی است. متغیرهای سطح خدمات در نظر گرفته شده شامل هزینه سفر، زمان سفر و ازدحام داخل وسیله نقلیه است.

همان ویژگی های شخصی موجود در مجموعه داده های برآورد نیز در نظرسنجی جمع آوری شد. لازم به ذکر است که برخلاف سناریوهای موجود در مجموعه داده تخمینی، مجموعه داده آزمایشی دوم ویژگی «قابلیت اطمینان زمان سفر» را در سناریوها شامل نمی شود، بنابراین ویژگی قابلیت اطمینان زمان سفر به صورت مقادیر پیش فرض تنظیم می شود (یعنی، 0) در مجموعه داده آزمایشی دوم. سی و شش سناریو مختلف انتخاب SP برای این نظرسنجی طراحی شد [38]. یک پاسخ دهنده پنج سناریو را به طور تصادفی از این سناریوها انتخاب کرد. ویژگی ها و محدوده آنها در سناریوهای SP در جدول 2A. پیوست توضیح داده شده است. جزئیات بیشتر در مورد طراحی نظرسنجی و جمع آوری داده ها در [38] موجود است. مجموعه داده شامل 2405 سناریو انتخاب از 481 پاسخ دهنده معتبر با پوشش جمعیتی گسترده است [38]. سناریوهای انتخاب در مجموعه داده آزمون دوم با مجموعه داده تخمینی از نظر مقادیر ویژگی متفاوت است و بنابراین می تواند برای آزمایش برون یابی مدل های پیشنهادی استفاده شود. با این حال، دامنه ویژگی های گزینه های جایگزین در مجموعه داده

آزمایشی دوم در مقایسه با ویژگی‌های موجود در مجموعه داده‌های تخمین بسیار متمایز نیست (توضیحات بیشتر را در ضمیمه ببینید).

4.2. تنظیم، آموزش و تست مدل

سه فرآیند اصلی در RF بر عملکرد آن تأثیر می‌گذارند: تعداد درخت‌های تصمیم، حداکثر عمق هر درخت، و حداکثر تعداد ویژگی‌ها برای هر گره تقسیم‌کننده.

تعداد درختان باید به طور مناسب انتخاب شود تا پیچیدگی مدل و هزینه محاسبات را متعادل کند. ساختار درختی عمیق‌تر و ویژگی‌های بیشتر در هر گره تقسیم‌کننده پیش‌بینی می‌شود که ناخالصی زیرمنطقه‌های تقسیم‌بندی شده را بهبود بخشد، اما منجر به مشکلات بیش از حد برازش می‌شود [4،34]. بنابراین، سه فرآیند باید تنظیم شوند. ما از چندین معیار عملکرد برای اندازه‌گیری کمی عملکردهای پیش‌بینی مدل‌ها از جمله دقت، یادآوری و امتیاز F1 استفاده می‌کنیم که معادلات آنها در معادله نشان داده شده‌اند. (6).

یک ماتریس سردرگمی نشان داده شده در شکل 2، تعاریف نمادهای استفاده شده در معادله را نشان می‌دهد. (6). منظور از مثبت‌های واقعی (TP)، منفی‌های واقعی (TN)، مثبت‌های کاذب (FP) و منفی‌های کاذب (FN) به Stehman [40] اشاره دارد.

امتیاز منحنی ناحیه زیر گیرنده عامل مشخصه (AUROC) نیز برای اندازه‌گیری عملکرد یک مدل طبقه‌بندی در آستانه‌های طبقه‌بندی مختلف استفاده می‌شود.

برای تنظیم مدل‌ها، ابتدا شماره درخت را از طریق اعتبارسنجی متقابل 10 پوشه بر اساس مجموعه داده تخمینی آزمایش می‌کنیم. نتیجه نشان می‌دهد که تعداد درختان بیش از 200 به بهبودهای اضافی در عملکرد منجر نمی‌شود، اما به طور قابل توجهی زمان محاسبه را افزایش می‌دهد. بنابراین، اندازه جنگل را 200 تنظیم می‌کنیم.

پس از تأیید اندازه جنگل، عمق درخت و حداکثر تعداد ویژگی‌ها را در یک گره تقسیم می‌کنیم. مقدار پیشنهادی برای تعداد ویژگی‌ها در هر حالت تقسیم $\log_2(p)$ است که p تعداد ویژگی‌های استفاده شده است. ما حداکثر تعداد ویژگی‌ها را در یک گره تقسیم‌کننده از 1 تا 33 با افزایش 1 و حداکثر عمق یک درخت از 1 تا 100 با افزایش 2 با اعتبارسنجی متقاطع بر اساس مجموعه داده‌های تخمینی آزمایش کردیم.

عملکرد با امتیاز AUROC اندازه‌گیری می‌شود و نتایج تجربی در شکل 3 نشان داده شده‌اند. مشخص می‌شود که ترکیب 10 ویژگی حداکثر در یک گره شکاف با حداکثر عمق 10 برای هر درخت، بهترین عملکرد را نشان می‌دهد.

ما همچنین ابرپارامترها را با استفاده از سایر معیارهای عملکرد تنظیم کردیم و نتایج مشابهی را نشان دادیم. بنابراین، ما فرآپارامترهای فوق را در پیاده سازی های خود حل و فصل کردیم.

علاوه بر این، شایان ذکر است که کلاس متغیرهای وابسته (یعنی C_{ij}) نامتعادل است زیرا یک سناریوی انتخاب در مجموعه داده تخمین دارای چهار گزینه است و تنها یکی از آنها توسط تصمیم گیرنده در سناریوی انتخاب انتخاب می‌شود. بنابراین ما از یک RF متعادل برای کنترل عدم تعادل با ترکیب وزن‌های کلاس استفاده می‌کنیم. وزن یک کلاس با فرکانس‌های کلاس در داده‌های ورودی نسبت معکوس دارد، که طبقه‌بندی اشتباه کلاس اقلیت را سخت‌تر می‌کند [41]. میانگین عملکرد یک مدل در نمونه‌های اعتبارسنجی برای اندازه‌گیری عملکرد پیش‌بینی آن استفاده می‌شود. لازم به ذکر است که مجموعه داده در اعتبارسنجی متقاطع بر اساس سناریوهای انتخاب تقسیم بندی می‌شود تا گزینه‌های جایگزین. یک سناریوی انتخاب در جدول 2 به عنوان یک نقطه نمونه در فرآیند تقسیم تصادفی اعتبارسنجی متقابل در نظر گرفته شده است.

$$\text{Accuracy} = \frac{TP+TN}{TP+FP+FN+TN}$$

$$\text{Precision} = \frac{TP}{TP+FP} \quad (6)$$

$$\text{Recall} = \frac{TP}{TP+FN}$$

$$F1\text{-score} = 2 \cdot \frac{\text{Recall} \cdot \text{Precision}}{\text{Recall} + \text{Precision}}$$

بر اساس چارچوب پیشنهادی، شش مدل مختلف برای مقایسه کامل عملکرد آنها در پیش‌بینی تصمیم‌گیری سفر در سناریوهای انتخاب مختلف با تمرکز بر برون‌یابی مدل‌ها، توسعه و بررسی می‌شوند. ما از دو مجموعه داده آزمایشی دیگر که متفاوت از مجموعه داده‌های تخمینی هستند برای بررسی برون‌یابی مدل‌ها در پیش‌بینی سناریوهای انتخابی استفاده می‌کنیم که در مجموعه داده برآورد وجود ندارند و ویژگی‌هایی فراتر از محدوده ویژگی در مجموعه داده برآورد دارند.

• **RF-TOPSIS**: این مدل چارچوب پیشنهادی را اعمال می کند و از رویکرد مبتنی بر TOPSIS برای ادغام تئوری های تصمیم گیری مبتنی بر دانش استفاده می کند.

• **RF-RMT1** و **RF-RMT2**: دو مدل از چارچوب پیشنهادی استفاده می کنند و از RMT برای در نظر گرفتن مکانیسم های رفتاری بهره می برند. با این حال، همانطور که در معادله نشان داده شده است، تفاوت هایی در تبدیل ویژگی ها دارند. (2) و (3)

• **RF-UMT**: این مدل بر اساس چارچوب پیشنهادی بنا شده است و از UMT برای ادغام مکانیسم های رفتاری در الگوریتم های طبقه بندی ML استفاده می کند.

• **RF-UMT-RMT2**: این مدل ترکیبی از RF-UMT و RF-RMT2 است. در این مدل، یک ویژگی یک گزینه توسط معادله پردازش می شود. (3) و (4) برای به دست آوردن دو ویژگی مشتق، که هر دو در الگوریتم های ML استفاده می شوند. این ایده از این تصور سرچشمه می گیرد که قوانین تصمیم گیری زیربنای رفتار افراد ممکن است به حداکثر رساندن مطلوبیت یا به حداقل رساندن پشیمانی نباشد، بلکه ترکیبی از حداکثرسازی مطلوبیت و به حداقل رساندن پشیمانی باشد [42]. بنابراین، این مشخصات مدل برای آزمایش عملکرد در مقایسه با استفاده صرفاً UMT یا RMT استفاده می شود.

• **RF**: این مدل از روش موجود در ادبیات موجود پیروی می کند (به عنوان مثال، [4,6]) و مستقیماً از ویژگی های گزینه در مدل بدون در نظر گرفتن مکانیسم های رفتاری استفاده می کند. این مدل به عنوان معیار مقایسه در نظر گرفته می شود.

5. نتایج و بحث

این بخش نتایج دقت پیش بینی مدل های پیشنهادی را ارائه می کند. به ویژه، ما مدل های مبتنی بر رویکرد پیشنهادی از این مطالعه و روش موجود در ادبیات را که مستقیماً RF را برای مدل سازی تصمیم گیری سفر اعمال می کند، مقایسه می کنیم. در تجزیه و تحلیل، دقت پیش بینی در مجموعه داده های برآورد و در دو مجموعه داده آزمایشی به طور جداگانه مورد بحث قرار می گیرد. نتایج حاصل از مجموعه داده تخمین نشان دهنده توانایی مدل ها برای پیش بینی تصمیم گیری سفر در سناریوهای انتخابی است که در آن گزینه ها ویژگی های مشابهی با نمونه های آموزشی دارند. نتایج دو مجموعه داده آزمایشی برای آزمایش برون یابی مدل های پیشنهادی در سناریوهای انتخابی که در مجموعه داده برآورد وجود ندارند و دارای ویژگی های برون یابی هستند، سفارشی می شوند.

5.1. عملکردهای پیش بینی در مجموعه داده های برآورد

نتایج عملکردهای پیش بینی در مجموعه داده های برآورد در شکل 4 نشان داده شده است.

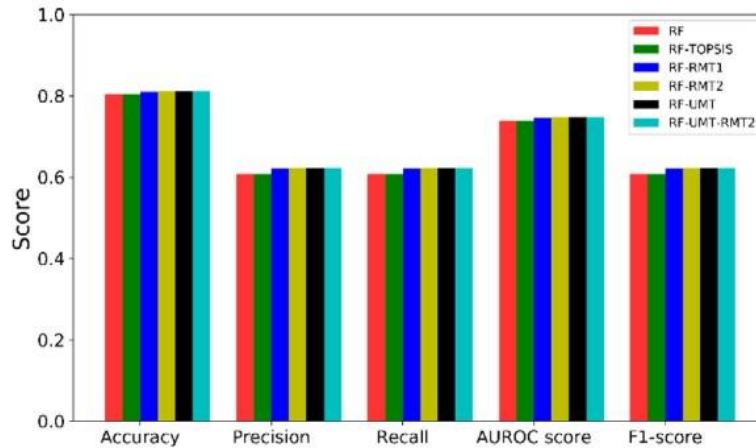


Fig. 4. Predictive performances in the estimation dataset.

میانگین دقت پیش بینی **accuracy**، دقت **precision** و نمرات یادآوری **recall scores** مدل های پیشنهادی شامل **RF-UMT-RMT2**، **RF-UMT**، **RF-RMT2**، **RF-RMT1** و **RF-UMT-RMT2** در اعتبارسنجی متقاطع 10 پوشه ای به ترتیب حدود 0.8، 0.6 و 0.6 است. امتیاز دقت نشان می دهد که مدل ها می توانند به درستی گزینه را برای انتخاب یا انتخاب نشدن در یک سناریوی انتخاب خاص با احتمال حدود 80٪ پیش بینی کنند. با این حال، در یک سناریوی انتخاب، بیش از یک گزینه قبلی (یعنی گزینه های انتخاب نشده) وجود دارد. به طور کلی، مدل سازان رفتار سفر بیشتر به احتمال پیش بینی صحیح گزینه انتخابی در سناریوی انتخابی اهمیت می دهند تا گزینه های انتخاب نشده. احتمال پیش بینی صحیح گزینه انتخاب شده در سناریوی انتخاب با دقت **precision** و امتیازات یادآوری **recall scores** منعکس می شود. دقت **precision** و نمرات یادآوری **recall scores** یک مدل یکسان است زیرا چارچوب پیشنهادی تنها اجازه می دهد تا یک گزینه در سناریوی انتخاب توسط تصمیم گیرنده انتخاب شود. اگر گزینه انتخاب شده در یک سناریوی انتخاب به درستی توسط مدل پیش بینی نشود، منجر به افزایش یک واحدی مقادیر هر دو مثبت کاذب و منفی کاذب به طور همزمان خواهد شد. بنابراین، مقادیر مثبت کاذب و منفی کاذب در تمام سناریوهای انتخاب برای یک مدل یکسان است، که منجر به دقت **precision** و امتیازهای یادآوری **recall scores** یکسان مطابق با معادله می شود. (6).

نمرات یادآوری **recall scores** مدل ها نشان می دهد که آنها می توانند گزینه انتخابی را در سناریوی انتخابی با احتمال حدود 60 درصد به طور متوسط پیش بینی کنند، که در زمینه مدل سازی تصمیم گیری سفر به دلیل

واریانس‌های رفتاری بزرگ بسیار خوب است. امتیاز AUROC مدل‌های پیشنهادی بیش از 0.7 است که نشان می‌دهد مدل‌ها عملکرد بسیار خوبی دارند [43].

هنگام مقایسه مدل‌های مبتنی بر چارچوب پیشنهادی ما با روش موجود در ادبیات (به عنوان مثال، RF)، عملکرد پیش‌بینی‌کننده رویکردهای پیشنهادی در مجموعه داده‌های تخمینی از نظر دقت، دقت، یادآوری و امتیازات AUROC مشابه RF است.

همانطور که در شکل 4 نشان داده شده است، RF-RMT1، RF-RMT2، RF-UMT، و RF-UMT- RMT2 فقط عملکردهای پیش‌بینی‌کننده کمی بالاتری ارائه می‌کنند.

به نظر می‌رسد که چارچوب پیشنهادی ادغام نظریه‌های تصمیم‌گیری مبتنی بر دانش در RF، برخلاف RF، قدرت پیش‌بینی قابل‌توجهی بهتری را در مجموعه داده‌های برآورد ارائه نمی‌کند. با این حال، اینها منطقی و حتی تا حدی قابل انتظار است.

دلایل اساسی سناریوهای انتخاب در مجموعه داده‌های برآورد و ساختار RF هستند. هجده سناریو انتخاب مختلف در داده‌های برآورد وجود دارد. در مجموعه داده برآورد، سناریوهای انتخاب در نمونه‌های آموزشی انتخاب شده توسط فرآیند اعتبارسنجی متقابل، اکثر سناریوهای انتخابی در نمونه اعتبارسنجی را پوشش می‌دهند.

بنابراین، یک RF با اندازه 200 درخت، حداکثر 10 ویژگی در یک گره شکاف، و حداکثر عمق 10، می‌تواند به طور کامل تصمیم‌گیری سفر را در تمام سناریوهای انتخاب ممکن به روشی نزدیک به شمارش مطابقت دهد و بنابراین پیش‌بینی می‌شود که انجام شود. در پیش‌بینی سناریوهای انتخاب مشابه در نمونه اعتبارسنجی بسیار خوب است. بنابراین، استفاده مستقیم از RF برای مدل‌سازی تصمیم‌گیری سفر به روشی صرفاً مبتنی بر داده‌ها بدون در نظر گرفتن مکانیسم‌های رفتاری، همچنان قادر به پیش‌بینی انتخاب‌ها در نمونه‌های اعتبارسنجی است. در چنین مواردی، چارچوب پیشنهادی در این مطالعه مزیت قابل‌توجهی در قدرت پیش‌بینی در مقایسه با RF ارائه نمی‌کند. با این حال، همانطور که ذکر شد، نادیده گرفتن مکانیسم‌های رفتاری زیربنای رفتار انتخاب مشاهده شده منجر به کمبود مدل برای پیش‌بینی سناریوهای انتخابی خارج از محدوده در نمونه‌های آموزشی، یعنی مسائل برون‌یابی مدل می‌شود. انتظار می‌رود چارچوب پیشنهادی برتری خود را در برون‌یابی به دست

آمده از ادغام اصول تصمیم گیری مبتنی بر دانش نشان دهد. اینها ما را تشویق می کنند تا قدرت پیش بینی شش مدل در مجموعه داده های آزمایشی را بیشتر بررسی کنیم.

5.2. عملکرد پیش بینی در پیش بینی سناریوهای انتخاب برون یابی

5.2.1. عملکرد در اولین مجموعه داده آزمایشی

عملکرد پیش بینی کننده شش مدل در اولین مجموعه داده آزمایشی در جدول 6 خلاصه شده و در شکل 5 نشان داده شده است. در مجموعه داده های آزمایشی اول، هر سناریوی انتخابی دارای یک گزینه ترکیبی جدید است که دارای ویژگی های خارج از محدوده است در مقایسه با نمونه های آموزشی کاربرد مستقیم RF فقط دارای امتیاز دقت 0.2174 است، به این معنی که RF تنها می تواند گزینه انتخاب شده را در سناریوی انتخابی به درستی با احتمال 21.74٪ پیش بینی کند. با توجه به اینکه پنج گزینه در هر سناریوی انتخابی از مجموعه داده آزمایشی اول وجود دارد، یک پیش بینی تصادفی می تواند احتمال پیش بینی درستی در حدود 20٪ ارائه دهد. این نشان می دهد که کاربرد مستقیم RF عملکرد وحشتناکی را در پیش بینی سناریوهای انتخابی که خارج از محدوده نمونه های آموزشی هستند، ارائه می دهد. امتیاز AUROC RF 0.5108 است که نزدیک به 0.5 است و نشان می دهد که RF تقریباً هیچ ظرفیت تمایزی برای پیش بینی گزینه انتخاب شده در سناریوهای انتخاب مجموعه داده آزمایش ترکیبی ندارد.

Table 6

Predictive performances in two test datasets.

Models	Datasets	Accuracy	Precision	Recall	AUROC score	F1-score
RF	First test dataset	0.6869	0.2174	0.2174	0.5108	0.2174
RF-TOPSIS		0.8483	0.6208	0.6208	0.7630	0.6208
RF-RMT1		0.9014	0.7537	0.7537	0.8460	0.7537
RF-RMT2		0.9260	0.8151	0.8151	0.8844	0.8151
RF-UMT-RMT2		0.9110	0.7776	0.7776	0.8610	0.7776
RF-UMT		0.8257	0.5643	0.5643	0.7277	0.5643

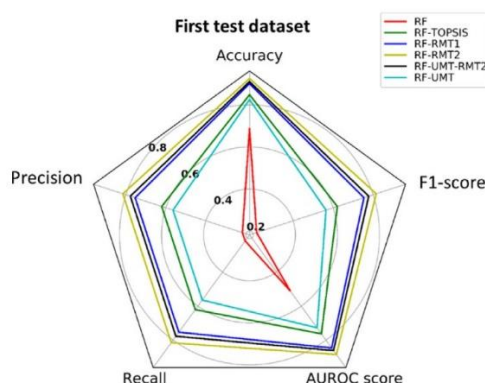


Fig. 5. The predictive performances in the first test dataset.

در مقابل، مدل‌های مبتنی بر چارچوب پیشنهادی از این مطالعه، همگی عملکردهای پیش‌بینی بسیار بهتری را در مجموعه داده آزمایشی اول در مقایسه با RF ارائه می‌کنند، همانطور که در شکل 5 نشان داده شده است.

RF-TOPSIS دقت پیش‌بینی و دقت RF را به ترتیب از 0.6869 تا 0.8483 و از 0.2174 تا 0.6208 بهبود می‌بخشد. امتیاز دقت 0.6208 به این معنی است که RF-TOPSIS می‌تواند جایگزین انتخابی را در سناریوهای انتخابی با احتمال 62 درصد به درستی پیش‌بینی کند. در مورد رویکردهای مبتنی بر RMT، RF-RMT1 و RF-RMT2 هر دو توانایی پیش‌بینی بهتری نسبت به RF-TOPSIS دارند. RF-RMT2 بهترین توانایی پیش‌بینی را در بین شش مدل ارائه می‌دهد. RF-RMT2 دارای امتیاز دقت 0.9260 و امتیاز دقت 0.8151 است که نشان می‌دهد RF-RMT2 می‌تواند پیش‌بینی‌های صحیحی از گزینه انتخاب شده در تمام سناریوهای انتخابی مجموعه داده آزمایشی اول با احتمال 81.51٪ انجام دهد. دقت پیش‌بینی RF-RMT2 دقت RF را از 21.74٪ به 81.51٪ با 274.79٪ بهبود می‌بخشد که بسیار قابل توجه است.

مدل مبتنی بر UMT RF-UMT نیز در مقایسه با RF نیز پیش‌بینی‌های بهتری ارائه می‌دهد، اما نسبت به مدل‌های مبتنی بر RMT و RF-TOPSIS پایین‌تر است. امتیاز دقت RF-UMT 0.8257 و امتیاز دقت 0.5643 است که امتیاز دقت RF را تا 159.56 درصد ارتقا می‌دهد. مدل RF-UMT-RMT2 با امتیاز دقت 0.911 و امتیاز دقت 0.7776 دارای دومین عملکرد پیشگویانه برتر است.

نتایج فوق‌نشان می‌دهد که کاربرد مستقیم RF بدون در نظر گرفتن مکانیسم‌های رفتاری پنهان انتخاب‌های تصمیم‌گیرندگان، توانایی برون‌یابی بسیار ضعیفی برای پیش‌بینی سناریوهای انتخاب با ویژگی‌هایی دارد که خارج از محدوده نمونه‌های آموزشی هستند. نتایج یک مفهوم مهم برای ادبیات مربوطه ارائه می‌دهد که فقط عملکردهای پیش‌بینی را بر اساس یک مجموعه داده برآورد و اعتبار متقابل آزمایش می‌کند. به طور کلی در ادبیات مربوطه گزارش شده است که الگوریتم‌های مجموعه‌ای مبتنی بر درخت مانند RF دقت پیش‌بینی بسیار بهتری را در مقایسه با مدل‌های مرسوم مانند مدل لوجیت چند اسمی (به عنوان مثال [4,6,8,10]) ارائه می‌کنند. با این حال، همیشه باید در نظر داشت که به اصطلاح دقت پیش‌بینی به عملکردهای پیش‌بینی‌کننده در نمونه‌های اعتبارسنجی از فرآیند اعتبارسنجی متقاطع اشاره دارد که سناریوهای انتخاب مشابهی با نمونه‌های آموزشی از نظر مقادیر ویژگی دارند. از طریق استنتاج نظری، RF که مکانیسم‌های رفتاری را نادیده می‌گیرد، نمی‌تواند تصمیم‌گیری در سفر را در سناریوهای انتخاب با ویژگی‌های خارج از محدوده به درستی پیش‌بینی

کند. نتایج تجربی ما این استنتاج را تایید می کند. کاربرد مستقیم RF در واقع در پیش بینی سناریوهای انتخاب خارج از محدوده ناقص است.

دلایل اساسی کمبود اساسی برون‌یابی الگوریتم‌های ML مانند مدل‌های مجموعه مبتنی بر درخت و نادیده گرفتن مکانیسم‌های رفتاری در تأسیسات مدل است. کاربرد دلخواه الگوریتم‌های ML مبتنی بر داده‌ها ممکن است در سناریوهای انتخابی که ویژگی‌های مشابهی با نمونه‌های آموزشی دارند، عملکرد قابل قبولی داشته باشد، اما اساساً در توانایی برون‌یابی کمبود دارند. در مقابل، مدل‌های مبتنی بر چارچوب پیشنهادی ما توانایی پیش‌بینی بسیار بالاتری را در مقایسه با RF ارائه می‌کنند. دلیلش سراسر است.

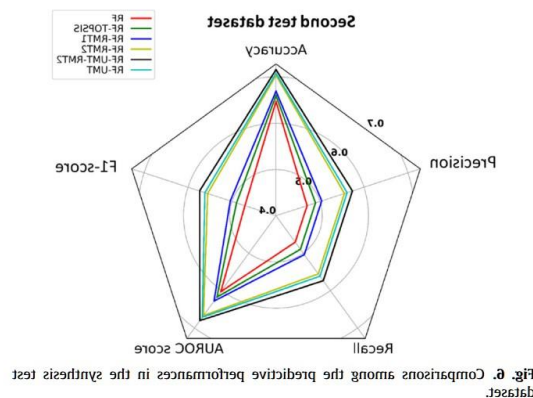
با ادغام نظریه‌های تصمیم‌گیری مبتنی بر دانش، چارچوب پیشنهادی مکانیسم‌های رفتاری در پس تصمیم‌گیری سفر را منعکس می‌کند که منجر به برون‌یابی قوی‌تر برای پیش‌بینی سناریوهای انتخاب فراتر از نمونه‌های آموزشی می‌شود.

5.2.2. عملکرد در مجموعه داده آزمایشی دوم

ما همچنین از مجموعه آزمایشی دیگری که در آزمایش‌های واقعی جمع‌آوری شده است برای بررسی عملکرد مدل‌های مختلف استفاده می‌کنیم. عملکرد پیش‌بینی شش مدل در مجموعه داده آزمایشی دوم در جدول 7 و شکل 6 نشان داده شده است.

Table 7
Predictive performances in the second test dataset.

Models	Datasets	Accuracy	Precision	Recall	AUROC score	F1-score
RF	Second test dataset	0.6471	0.4706	0.4706	0.6030	0.4706
RF-TOPSIS		0.6598	0.4898	0.4898	0.6173	0.4898
RF-RMT1		0.6693	0.5039	0.5039	0.6279	0.5039
RF-RMT2		0.7036	0.5555	0.5555	0.6666	0.5555
RF-UMT-RMT2		0.7158	0.5738	0.5738	0.6803	0.5738
RF-UMT		0.7078	0.5617	0.5617	0.6713	0.5617



مجموعه داده RF-TOPSIS و RF-RMT1 عملکرد پیش‌بینی کمی بهتری نسبت به RF ارائه می‌کنند، اما تفاوت‌های قابل توجهی ندارند. با این حال، RF-UMT، RF-RMT2، و RF-UMT-RMT2 در مقایسه با RF مزایای بیشتری در عملکردهای پیش‌بینی کننده دارند، همانطور که در شکل 6 نشان داده شده است. RF-UMT-RMT2 بهترین عملکرد را در بین سه مدل دارد و دارای امتیاز دقت 0.5738 است که 21.9٪ بزرگتر از امتیاز دقت RF (0.4706) است. RF-UMT و RF-RMT2 امتیاز دقت را به ترتیب 19.3٪ (از 0.4706 به 0.5617) و 17.9٪ (از 0.4706 تا 0.5555) در مقایسه با RF بهبود می‌بخشند. امتیازات AUROC RF-RMT2، RF-UMT، و RF-UMT-RMT2 مقادیر قابل توجهی بزرگتر را در مقایسه با RF نشان می‌دهد. همه اینها نشان می‌دهد که RF-UMT، RMT2، و RF-UMT-RMT2 توانایی‌های پیش‌بینی بسیار بهتری در سناریوهای انتخاب مجموعه داده آزمایشی دوم در مقایسه با RF دارند. بهترین مدل RF-UMT-RMT2 دارای احتمال 57.38 درصد برای پیش‌بینی صحیح جایگزین انتخابی در سناریوهای انتخاب مجموعه داده آزمایشی دوم و دارای امتیاز AUROC 0.6713 است که نشان می‌دهد طبقه‌بندی قابل قبولی برای تعیین جایگزین انتخابی در انواع مختلف است. سناریوهای انتخاب مدل‌های مبتنی بر چارچوب پیشنهادی عملکردهای پیش‌بینی بهتری را در مجموعه داده آزمایشی دوم در مقایسه با RF ارائه می‌کنند، اما به اندازه مجموعه داده‌های آزمایشی اول برتر نیستند.

دلیل بالقوه این است که دامنه ویژگی‌های گزینه‌های موجود در مجموعه داده آزمایشی دوم بسیار متمایز از نمونه‌های آموزشی نیست (جزئیات را در ضمیمه ببینید). از این رو، RF که با انتخاب‌های سفر به روشی صرفاً مبتنی بر داده مطابقت دارد، نسبت به چارچوب پیشنهادی در این مطالعه فرودستی آشکاری نشان نمی‌دهد. به طور خاص تر، در مقایسه با سناریوهای انتخاب در نمونه‌های آموزشی، سناریوهای انتخاب برون‌یابی شده زیادی در مجموعه داده آزمون دوم وجود ندارد. با این وجود، RF-UMT، RMT2، و RF-UMT-RMT2 هنوز مزایای قابل توجهی در پیش‌بینی رفتار انتخاب در مجموعه داده آزمون دوم نشان می‌دهند، که اثرات مثبت ادغام نظریه‌های تصمیم‌گیری مبتنی بر دانش را در بهبود توانایی پیش‌بینی و برون‌یابی نشان می‌دهد.

6. سخنان پایانی

رواج یادگیری ماشینی محققان را جذب کرده است تا از آنها برای مدل‌سازی تصمیم‌گیری در سفر با توجه به مزایای آنها در نظر گرفتن روابط پیچیده مانند اثرات و تعاملات غیرخطی استفاده کنند. با این حال، الگوریتم‌های طبقه‌بندی یادگیری ماشینی که با تصمیم‌گیری در سفر به شیوه‌ای صرفاً مبتنی بر داده مطابقت

دارند، مکانیسم‌های رفتاری زیربنای انتخاب‌های مسافران را نادیده می‌گیرند. چنین مدل‌هایی قادر به پیش‌بینی تصمیم‌گیری در سناریوهای انتخابی که دارای ویژگی‌های خارج از محدوده نمونه‌های آموزشی، یعنی مسئله برون‌یابی هستند، نیستند. با این حال، توانایی برون‌یابی در زمینه‌های مدل‌سازی تصمیم‌گیری سفر بسیار مهم است.

در این مطالعه، ما یک رویکرد مبتنی بر برون‌یابی را برای مدل‌سازی تصمیم‌گیری سفر با ادغام نظریه‌های تصمیم‌گیری مبتنی بر دانش در الگوریتم‌های گروهی ML پیشنهاد کردیم، که طبق بهترین دانش ما، اولین کار ارائه چنین روشی برای مدل‌سازی تصمیم‌گیری سفر است. ساخت.

رویکرد پیشنهادی از الگوریتم‌های ML مجموعه مبتنی بر درخت برای پرداختن به روابط پیچیده و غیرخطی بین متغیر وابسته و متغیرهای توضیحی، و همچنین تعاملات پیچیده بین متغیرهای توضیحی استفاده می‌کند. همزمان، این رویکرد تئوری‌های تصمیم‌گیری مبتنی بر دانش شناخته‌شده را از علوم رفتاری ادغام می‌کند تا مکانیسم‌های رفتاری زیربنای تصمیم‌گیری سفر برای افزایش توانایی برون‌یابی مدل را به طور کامل در نظر بگیرد.

به این ترتیب، این رویکرد می‌تواند مکانیسم‌های رفتاری را منعکس کند که تصمیم‌گیرندگان با ایجاد معاوضه بین گزینه‌ها به جای بسته به ویژگی‌های یک جایگزین در یک سناریوی انتخاب خاص، گزینه بهینه ذهنی را انتخاب می‌کنند.

عملکردهای پیش‌بینی‌کننده رویکرد پیشنهادی با روش موجود از طریق سه مجموعه داده مختلف شامل یک مجموعه داده برآورد و دو مجموعه داده آزمایشی مقایسه می‌شوند. مجموعه داده برآورد برای آموزش مدل‌ها با اعتبارسنجی متقابل و آزمایش عملکرد پیش‌بینی مدل‌ها در پیش‌بینی تصمیم‌گیری در سناریوهای انتخاب در محدوده مشابهی از نمونه‌های آموزشی استفاده می‌شود.

مهمتر از آن، ما تمرکز ویژه‌ای بر توانایی پیش‌بینی مدل‌ها در سناریوهای انتخاب با ویژگی‌هایی خارج از محدوده نمونه‌های آموزشی، یعنی توانایی برون‌یابی داریم.

اینها به سختی در ادبیات مربوطه بررسی شده‌اند. دو مجموعه داده آزمایشی به ویژه برای آزمایش توانایی برون‌یابی مدل‌های مختلف استفاده می‌شود.

نتایج نشان می‌دهد که هر دو مدل پیشنهادی و روش موجود در ادبیات (یعنی کاربرد مستقیم RF) هر دو می‌توانند عملکردهای پیش‌بینی‌کننده بسیار خوبی را در سناریوهای انتخابی که محدوده ویژگی‌های مشابه با نمونه‌های آموزشی دارند، ارائه دهند.

با این حال، RF عملکردهای پیش‌بینی بسیار بدی دارد، که نزدیک به یک پیش‌بینی تصادفی است، در مجموعه داده‌های آزمایشی اول با سناریوهای انتخابی که دارای ویژگی‌های خارج از محدوده در مقایسه با نمونه‌های آموزشی هستند.

نتایج تجربی توانایی برون‌یابی ناقص استفاده مستقیم از الگوریتم‌های مجموعه مبتنی بر درخت را در مدل‌سازی تصمیم‌گیری سفر نشان می‌دهد. در مقابل، رویکرد پیشنهادی در مقایسه با کاربرد مستقیم RF در سناریوهای انتخابی که دارای ویژگی‌های خارج از محدوده هستند، یعنی توانایی برون‌یابی بسیار قوی‌تر، عملکردهای پیش‌بینی‌کننده قابل توجهی را ارائه می‌کند.

در مجموعه داده آزمایشی اول، مدل مبتنی بر رویکرد پیشنهادی ما (یعنی RF-RMT2) می‌تواند امتیاز دقت را به 81.51٪ افزایش دهد که 274.93٪ بزرگتر از RF است. در مجموعه آزمایشی دیگری، مدل مبتنی بر رویکرد پیشنهادی ما (یعنی RF-UMT-RMT2) می‌تواند امتیاز دقت را تا 21.9٪ در مقایسه با کاربرد مستقیم RF نیز بهبود بخشد. اینها برتری رویکرد پیشنهادی را از نظر برون‌یابی مدل برای مدل‌سازی تصمیم‌گیری سفر تایید می‌کنند.

اگرچه مطالعه حاضر رویکرد جدیدی را برای مدل‌سازی تصمیم‌گیری سفر برای حمایت از بهینه‌سازی سیستم حمل‌ونقل پیشنهاد می‌کند، برخی محدودیت‌ها و کارهای آینده وجود دارد که می‌تواند در کارهای آینده مورد توجه قرار گیرد.

تلاش در هر دو جنبه نظری و عملی برای بهبود مدل‌سازی دقیق تصمیم‌گیری سفر بر اساس تکنیک‌های یادگیری ماشین مورد نیاز است. روش‌های یادگیری ماشین اساساً برای اولویت‌بندی پیش‌بینی به جای تحلیل رفتاری طراحی شده‌اند.

بنابراین، توسعه روش‌هایی برای استخراج بینش‌های رفتاری بیشتر از نتایج الگوریتم‌های یادگیری ماشین، مانند کشش‌های تمایل به پرداخت و تقاضا برای تحلیل عملی ضروری است. در واقع، یکی از مزیت‌های RF به دست آوردن اهمیت ویژگی بعد از تمرین است. به دلیل محدودیت‌های متنی، نتایج در مقاله حاضر ارائه و بحث نشده است.

با این حال، دریافت تفسیرهای رفتاری بر اساس نتایج جالب است. علاوه بر این، استفاده از چارچوب پیشنهادی برای مدل‌سازی تجربی رفتار انتخاب در زمینه‌های دیگر مانند انتخاب مسیر، انتخاب‌های زمان عزیمت و سایر موقعیت‌های تصمیم‌گیری فراتر از انتخاب‌های سفر جالب است. بررسی مجدد عملکرد رویکرد پیشنهادی بر اساس مجموعه داده‌های کافی و متنوع‌تر نیز ضروری است.

بیانیه مشارکت نویسنده CRediT

Kun Gao: مفهوم سازی، جمع آوری داده ها، روش شناسی، تجزیه و تحلیل رسمی، نوشتن - پیش نویس اصلی.

یینگ یانگ: مفهوم سازی، روش شناسی، نوشتن - بررسی و ویرایش.

تیانشو ژانگ: جمع آوری داده ها، روش شناسی، تجزیه و تحلیل رسمی.

Aoyong Li: بازبینی نسخه خطی، نوشتن، پیشنهادات.

Xiaobo Qu: مفهوم‌سازی، روش‌شناسی، اعتبارسنجی، منابع، نظارت، نوشتن - بررسی و ویرایش.

اعلامیه منافع رقابتی

نویسندگان اعلام می کنند که هیچ منافع مالی رقیب یا روابط شخصی شناخته شده ای ندارند که به نظر می رسد بر کار گزارش شده در این مقاله تأثیر بگذارد.

تصدیق

این پروژه توسط پروژه JPI اتحادیه اروپا SMUrTS حمایت مالی می شود.

ضمیمه

ویژگی های مورد استفاده و سطوح آنها برای طراحی سناریوی اولویت اعلام شده (SP) در مجموعه داده برآورد در جدول A.1 فهرست شده است.

یک روش طراحی کارآمد برای تولید محتویات آماری سناریوها استفاده شد [37]. طراحی محتوای آماری به تعیین ویژگی‌های جایگزین در یک سناریوی SP از طریق روش‌های خاص مانند طراحی متعامد یا رویکردهای کارآمد اشاره دارد [44]. روش طراحی کارآمد، ابزارهای جایگزین‌های مختلف را متعادل می‌کند تا از تسلط بر گزینه‌ها در سناریوهای ارجاع به رز و همکاران جلوگیری کند. [44].

به عنوان مثال، در سناریوی انتخاب باید از این نکته صرف نظر کرد که ویژگی‌های یک جایگزین بهتر از سایرین است.

از گزینه غالب در یک سناریو باید اجتناب شود زیرا نمی‌تواند منعکس‌کننده مبادلات بین ویژگی‌ها باشد و اطلاعات ارزشمندی در مورد نحوه تصمیم‌گیری افراد ارائه دهد. شکل A.1 یک سناریوی SP مورد استفاده در نظرسنجی را نشان می‌دهد.

Table A.1

Features and levels used in SP scenario design of estimation dataset [37].

Transport mode	Features	Possible levels (values)
Car	Mean travel time	{15, 25, 35, 40} min
	Travel time unreliability	{4, 8, 12, 18} min
	Cost (oil, parking fare, and tolls)	{10, 25, 35, 45} CNY
	Crowding inside car	None
Metro	Mean travel time	{30, 40, 50, 60} min
	Travel time unreliability	{2, 4, 6, 8} min
	Cost (ticket)	{3, 4, 5} CNY
	Crowding inside metro	{Level 1, 2, 3}
Park&Ride	Mean travel time	{25, 35, 45, 55} min
	Travel time unreliability	{2, 6, 8, 10} min
	Cost (oil, parking fare, and ticket)	{12, 16, 18, 22} CNY
	Crowding inside transit	3 (Level 1, 2, 3)
Bus	Mean travel time	{30, 40, 50, 60} min
	Travel time unreliability	{4, 8, 14, 20} min
	Cost (ticket)	{1, 2, 3} CNY
	Crowding inside bus	{Level 1, 2, 3}

Note: The travel time reliability is measured by the standard deviation of travel time distribution. For the in-vehicle crowding, three levels reflecting three typical situations during commuting in Shanghai were set in the survey. Crowding Level 1, 2, 3 represent the standing passenger density is 0, 3 and 6 persons/m², respectively.

سناریوی SP یک سناریوی فرضی را برای پاسخگو فراهم می‌کند که در آن ویژگی‌های همه گزینه‌ها ارائه می‌شود. از پاسخ‌دهنده خواسته می‌شود که گزینه مورد نظر خود را در سناریوی SP داده شده انتخاب کند. هجده سناریو ایجاد شد.

هر پاسخگو با شش سناریو به طور تصادفی انتخاب شده در یک پرسشنامه ارائه شد تا از تندروری جلوگیری شود. جزئیات بیشتر در مورد طرح نظرسنجی در [37] موجود است.

برای سناریوهای SP در مجموعه داده آزمایشی دوم، از

ویژگی ها و سطوح مربوطه در جدول A.2 خلاصه شده است.

Table A.2
The features and levels used for SP scenarios in the second test dataset [38].

Transport modes	Features	Possible levels (values)
Short-time commuting		
Car	Travel time	{10, 20, 30} min
	Cost (oil, parking fare, and tolls)	{5, 15, 25} CNY
	Crowding inside car	None
Metro	Travel time	{15, 25, 35} min
	Cost (ticket)	{3, 4, 5} CNY
	Crowding inside metro	{Level 1, Level 2, Level 3}
Bus	Travel time	{15, 25, 35} min
	Cost (ticket)	2 CNY
	Crowding inside bus	{Level 1, Level 2, Level 3}
Taxi	Travel time	{10, 20, 30} min
	Cost	{10, 20, 30} CNY
	Crowding inside taxi	None
Medium-time commuting		
Car	Travel time	{20, 30, 40} min
	Cost (oil, parking fare, and tolls)	{10, 20, 30} CNY
	Crowding inside car	None
Metro	Travel time	{25, 35, 45} min
	Cost (ticket)	{3, 4, 5} CNY
	Crowding inside metro	{Level 1, Level 2, Level 3}
Bus	Travel time	{25, 35, 45} min
	Cost (ticket)	2 CNY
	Crowding inside bus	{Level 1, Level 2, Level 3}
Taxi	Travel time	{20, 30, 40} min
	Cost	{15, 25, 35} CNY
	Crowding inside taxi	None
Long-time commuting		
Car	Travel time	{30, 40, 50} min
	Cost (oil, parking fare, and tolls)	{15, 25, 35} CNY
	Crowding inside car	None
Metro	Travel time	{35, 45, 55} min
	Cost (ticket)	{4, 5, 6} CNY
	Crowding inside metro	{Level 1, Level 2, Level 3}
Bus	Travel time	{40, 50, 60} min
	Cost (ticket)	2 CNY
	Crowding inside bus	{Level 1, Level 2, Level 3}
Taxi	Travel time	{30, 40, 50} min
	Cost	{25, 35, 45} CNY
	Crowding inside taxi	None

سناریوی SP فرض می کند که شرکت پاسخ دهنده محل کار را تغییر داده است. پاسخ دهندگان پاسخ دادند که کدام حالت حمل و نقل را در سناریوهای SP انتخاب می کنند. نمونه ای از سناریوی SP مورد استفاده در شکل A.2 نشان داده شده است. اگر پاسخ دهنده به ماشین شخصی دسترسی داشت، سه گزینه عبارت بودند از ماشین، مترو و اتوبوس. در غیر این صورت، سه گزینه تاکسی، مترو و اتوبوس بود. سناریوهای SP مطابق با زمینه های سفر واقعی یک پاسخ دهنده طراحی شده اند. یک پاسخ دهنده بر اساس زمان رفت و آمد مشترکشان به یکی از سه گروه تقسیم شد: رفت و آمد کوتاه مدت (>25 دقیقه)، رفت و آمد متوسط (25 تا

40 دقیقه)، رفت و آمد طولانی مدت (< 40 دقیقه). برای هر گروه، سناریوهای SP مربوطه با استفاده از روش طراحی کارآمد تولید شد. ویژگی ها و سطوح آنها برای سناریوهای SP هر گروه در جدول A.2 نشان داده شده است. دوازده سناریو برای هر گروه تولید می شود و پنج سناریو به طور تصادفی برای هر پاسخ دهنده در نظرسنجی انتخاب می شود. جزئیات بیشتر در مورد پاسخ دهندگان جمع آوری شده در [38] موجود است.

با مقایسه جداول A.1 و A.2، می توان دریافت که ویژگی های جایگزین در سناریوهای SP مجموعه داده تخمینی با ویژگی های موجود در سناریوهای SP مجموعه داده های آزمایشی دوم متفاوت است. بنابراین، زمینه های انتخاب در سناریوهای SP در مجموعه داده آزمایشی دوم با مجموعه داده های برآورد متفاوت است.

به عبارت دیگر، سناریوهای انتخاب در مجموعه داده آزمون دوم، نمونه های آزمایشی قابل قبول و خوبی برای بررسی برون یابی مدل هستند. با این حال، دامنه ویژگی های گزینه ها در تخمین و مجموعه داده آزمایشی دوم بسیار متفاوت نیست.

به عنوان مثال، محدوده زمان سفر در سناریوهای SP مجموعه داده برآورد از 15 تا 60 دقیقه است. محدوده زمان سفر در سناریوهای مجموعه داده آزمایشی دوم از 10 تا 55 دقیقه است.