

چکیده

در این پژوهش، الگوریتم SHAP (SHapley Additive exPlanations) به عنوان ابزاری برای تفسیرپذیری مدل‌های یادگیری ماشین در حوزه راه و ترابری مورد استفاده قرار گرفته است. داده‌های ترافیک شهری شامل ۱۰۶۰۰۰ رکورد با متغیرهای ساعت روز، دما، بارندگی، نوع روز و سرعت متوسط، مبنای آموزش سه مدل Random Forest، Gradient Boosting و Linear Regression برای پیش‌بینی حجم ترافیک قرار گرفتند. نتایج نشان داد هر سه مدل با ضریب تعیین بالاتر از ۰.۹۵ عملکرد قابل قبولی دارند. تحلیل Permutation Importance به عنوان معادل محاسباتی SHAP نشان داد ساعت اوج (Rush Hour) و نوع روز (Day Type) مهم‌ترین متغیرهای مؤثر بر حجم ترافیک هستند. دوازده نمودار تفسیری تولید شد که جوانب مختلف رفتار مدل و اهمیت ویژگی‌ها را مستند می‌سازد.

۱. مقدمه

یکی از چالش‌های اساسی مدیریت ترافیک شهری، درک کمی عوامل مؤثر بر حجم ترافیک است. مدل‌های یادگیری ماشین قادرند روابط پیچیده و غیرخطی میان متغیرهای محیطی و ترافیکی را استخراج کنند؛ اما ماهیت «جعبه سیاه» این مدل‌ها اغلب مانع از تفسیر مستقیم نتایج می‌شود. الگوریتم SHAP، مبتنی بر نظریه بازی‌های کوپراتیو (Shapley 1953)، این محدودیت را با انتساب سهم کمی هر ویژگی به خروجی مدل برطرف می‌سازد.

در این پژوهش از Permutation Importance به عنوان تقریب محاسباتی SHAP استفاده شده است. این روش با جابه‌جایی تصادفی مقادیر هر ویژگی و اندازه‌گیری کاهش دقت مدل، اهمیت هر متغیر را کمی‌سازی می‌کند. هدف اصلی، شناسایی و تفسیر مهم‌ترین متغیرهای مؤثر بر حجم ترافیک شهری در قالب یک چارچوب تفسیرپذیر و قابل ارائه به مدیران حمل‌ونقل است.

۲. داده‌ها و متغیرها

داده‌های مورد استفاده شامل ۱۰۶۰۰۰ رکورد ترافیک شهری است. متغیر وابسته، حجم ترافیک (تعداد وسایل نقلیه در ساعت) و متغیرهای مستقل به شرح جدول ۱ هستند. علاوه بر متغیرهای اولیه، دو متغیر مهندسی شده (Rush Hour) و (Night Hour) برای بهبود قدرت تبیینی مدل اضافه شدند.

نوع	دامنه	نماد	متغیر
عددی پیوسته	۰ - ۲۳	hour	ساعت روز
عددی پیوسته	۱۰ تا ۴۰ °C	temperature_c	دمای هوا
عددی پیوسته	۰ - ۲۰ mm	rain_mm	بارندگی
اسمی دوارزشی	Weekday / Weekend	day_type	نوع روز
عددی پیوسته	۱۵ - ۱۱۰ km/h	avg_speed_kmh	سرعت متوسط
دوارزشی مهندسی شده	۰ / ۱	rush_hour	ساعت اوج *
دوارزشی مهندسی شده	۰ / ۱	night_hour	ساعت شب *

۳. روش شناسی

۳-۱. پیش پردازش داده

متغیر کیفی day_type با استفاده از Label Encoding به مقادیر عددی Weekday=1 ، Weekend=0 تبدیل شد. داده ها به نسبت ۲۰/۸۰ به مجموعه های آموزش (۸۰۰۰ رکورد) و آزمون (۲۰۰۰ رکورد) تقسیم شدند.

۳-۲. مدل های پیش بینی

سه مدل با پارامترهای زیر آموزش داده شدند Random Forest: با ۲۰۰ درخت تصمیم (n_estimators=200) ، Gradient Boosting با نرخ یادگیری ۰.۱ و عمق حداکثر ۵ لایه؛ و Linear Regression به عنوان مدل پایه. (baseline)

۳-۳. محاسبه اهمیت SHAP

اهمیت ویژگی ها با روش Permutation Importance معادل عملی SHAP محاسبه شد. در این روش برای هر ویژگی:

$$Importance(f) = R^2(baseline) - R^2(f_permuted)$$

عملیات جابه جایی با ۳۰ تکرار (n_repeats=30) انجام شد تا میانگین و انحراف معیار قابل اطمینان حاصل شود. اعتبارسنجی مدل ها با روش ۵ Fold Cross-Validation صورت گرفت.

۴. نتایج


۴-۱. عملکرد مدل‌ها

مدل	R^2	RMSE وسيله/ساعت	MAE
Random Forest	۰.۹۵۶۳	۱۹۰.۶	۱۵۲.۴
Gradient Boosting	۰.۹۵۸۰	۱۸۶.۹	۱۴۹.۸
Linear Regression	۰.۹۶۰۶	۱۸۰.۹	۱۴۴.۸


۴-۲. اهمیت ویژگی‌ها (SHAP/Permutation)

تحلیل Permutation Importance نشان داد Rush Hour با اختلاف قابل توجه مهم‌ترین متغیر، و Day Type در جایگاه دوم قرار دارد. متغیرهای دما، بارندگی، سرعت متوسط و ساعت روز خام اهمیت نسبتاً پایین‌تری داشتند.


دوازده نمودار تولید شده در پوشه shap_outputs ذخیره شده‌اند. هر نمودار جنبه خاصی از تحلیل مدل را پوشش می‌دهد:




شکل ۱. نمودار میله‌ای افقی اهمیت ویژگی‌ها بر اساس Permutation Importance در مدل Random Forest. هر میله میانگین کاهش R^2 ناشی از جابه‌جایی آن ویژگی را نشان می‌دهد و خط خطا (error bar) انحراف معیار ۳۰ تکرار را مستند می‌سازد. ویژگی Rush Hour با بیشترین مقدار در رأس رتبه‌بندی قرار دارد.




شکل ۲. نمودار Beeswarm که برای ۳۰۰ نمونه تصادفی رسم شده است. هر نقطه یک رکورد داده است؛ رنگ قرمز نشان‌دهنده مقدار بالای ویژگی و رنگ آبی مقدار پایین است. موقعیت افقی نقطه جهت و شدت تأثیر SHAP آن ویژگی بر پیش‌بینی را نشان می‌دهد. نقاط سمت راست صفر اثر افزایشی و سمت چپ اثر کاهشی بر حجم ترافیک دارند.




شکل ۳. مقایسه نتایج Permutation Importance در دو مدل Random Forest و Gradient Boosting به صورت میله‌های جفتی. همسویی الگوی اهمیت‌بندی ویژگی‌ها در هر دو مدل، پایداری و قابلیت تعمیم یافته‌ها را تأیید می‌کند.




شکل ۴. نمودار آبشاری (Waterfall) برای یک رکورد نمونه از مجموعه آزمون. هر نوار افقی سهم یک ویژگی در انحراف پیش‌بینی از مقدار پایه (میانگین مجموعه آموزش) را نشان می‌دهد. نوارهای قرمز اثر افزایشی و نوارهای آبی اثر کاهشی دارند. مجموع این سهم‌ها پیش‌بینی نهایی مدل را تشکیل می‌دهد.




شکل ۵. نمودار وابستگی جزئی (PDP) برای متغیر ساعت روز. منحنی میانگین پیش‌بینی مدل را در هر ساعت، با ثابت نگه داشتن سایر متغیرها در مقادیر واقعی‌شان، نشان می‌دهد. نواحی سایه‌دار قرمز و نارنجی به ترتیب اوج ترافیک صبح (۷-۹) و بعدازظهر (۱۶-۱۹) را مشخص می‌کنند.




شکل ۶. نمودار وابستگی جزئی برای متغیر سرعت متوسط. رابطه میان سرعت خودروها و حجم ترافیک پیش‌بینی‌شده را مستند می‌سازد. خط عمودی قرمز نشان‌دهنده میانگین سرعت در مجموعه آموزش است و به تفسیر محدوده متعارف کمک می‌کند.




شکل ۷. نمودار اثر تعاملی میان ساعت روز و نوع روز. دو منحنی مجزا برای روزهای کاری (آبی) و آخر هفته (قرمز) رسم شده‌اند. تفاوت معنادار الگوی زمانی ترافیک در این دو دسته، ضرورت در نظر گرفتن اثر تعاملی متغیرها در مدل‌سازی ترافیک را نشان می‌دهد.




شکل ۸. نمودار پراکندگی مقادیر واقعی در برابر مقادیر پیش‌بینی‌شده برای هر سه مدل. انحراف نقاط از خط ۴۵ درجه (خط ایده‌آل) معیار بصری سنجش دقت مدل است. تراکم بالای نقاط در مجاورت خط ایده‌آل در هر سه مدل، دقت بالای پیش‌بینی را تأیید می‌کند.




شکل ۹. هیستوگرام توزیع خطاهای پیش‌بینی ($\text{residual} =$ مقدار واقعی منهای مقدار پیش‌بینی) برای مدل‌های Random Forest و Gradient Boosting. تقارن توزیع حول صفر و عدم وجود تعصب سیستماتیک (systematic bias) قابل ملاحظه است. خط چین قرمز میانگین خطا را نشان می‌دهد.



شکل ۱۰. نقشه حرارتی ماتریس همبستگی پیرسون میان تمام متغیرها. مقادیر قرمز بیانگر همبستگی مثبت و مقادیر آبی بیانگر همبستگی منفی هستند. بررسی این ماتریس نشان می‌دهد بین متغیرهای مستقل همبستگی شدید (چندخطی) وجود ندارد که شرط مهمی برای اعتبار تحلیل اهمیت ویژگی‌هاست.



شکل ۱۱. نتایج ارزیابی ۵-Fold Cross-Validation برای هر سه مدل به صورت نمودار جعبه‌ای (boxplot). هر جعبه توزیع مقادیر R^2 در پنج بخش داده را نشان می‌دهد. محدود بودن پراکندگی جعبه‌ها نشان‌دهنده پایداری عملکرد مدل‌ها و عدم وابستگی نتایج به تقسیم‌بندی خاصی از داده‌هاست.



شکل ۱۲. داشبورد یکپارچه که پنج عنصر کلیدی را در یک تصویر ارائه می‌دهد: (الف) نمودار میله‌ای اهمیت ویژگی‌ها، (ب) منحنی PDP ساعت روز، (ج) نمودار پراکندگی واقعی-پیش‌بینی، (د) جدول معیارهای ارزیابی مدل‌ها، (ه) مقایسه دقت Cross-Validation این نمودار برای ارائه خلاصه نتایج به مخاطبان غیرمتخصص مناسب است.