

فصلنامه دانش انتظامی سمنان ، دوره چهاردهم ، شماره پنجاه و یکم ، بهار ۱۴۰۳

تاریخ دریافت مقاله: ۱۴۰۳/۰۴/۰۳

تاریخ پذیرش مقاله: ۱۴۰۳/۰۶/۱۱

صفحات: ۷۸-۹۷

بررسی کارایی مدل ماشین بردار پشتیبان در برآورد تصادفات ناشی از خستگی و

خواب آلودگی (مطالعه موردی: محور سمنان - شاهرود)

نویسندگان:

حمیدرضا قزوینیان*، حجت کرمی^۲

چکیده

خستگی و خواب آلودگی به عنوان عامل مهمی در تصادفات جاده ای در نظر گرفته می شود. سالانه تعداد کثیری از رانندگان وسایل نقلیه ی سنگین به علت خستگی و خواب آلودگی مصدوم و فوت می شوند و هزینه سنگینی در زمینه های مختلف به جامعه تحمیل می گردد. در این پژوهش به بررسی کارایی مدل ماشین بردار پشتیبان (SVM) در برآورد تصادفات ناشی از خستگی و خواب آلودگی محور سمنان - شاهرود پرداخته شد. داده های تصادف مورد مطالعه از سال ۱۳۹۵ الی ۱۴۰۱ می باشد. داده های ورودی به مدل شامل ماه، وضعیت روشنایی، ایام هفته، وضعیت جاده، وضعیت آب و هوا، نوع مسیله سواری، وضعیت ماشین، بسته بودن کمربند ایمنی، نوع صدمه وارد شده، جنسیت و میزان تحصیلات راننده در نظر گرفته شد. ۷۰ درصد داده ها برای آموزش و ۳۰ درصد دیگر برای آزمون مدل لحاظ شد. عملکرد مدل با معیارهای ارزیابی R^2 ، RMSE و MAE ارزیابی شد. نتایج نشان داد که مدل SVM می تواند در شبیه سازی داده های تصادفات ناشی از خستگی و خواب آلودگی محور سمنان - شاهرود کارایی مناسبی داشته باشد. مقادیر R^2 ، RMSE و MAE مدل در مرحله آزمون به ترتیب ۰/۹۱۵۳ و ۲/۶۷۴۵ و ۳/۸۵۱۲ حاصل شد که نشان از عملکرد خوب مدل را می دهد.

کلید واژه ها : تصادفات، خستگی و خواب آلودگی، SVM، محور سمنان - شاهرود

۱ : دکتری مهندسی و مدیریت منابع آب، دانشکده مهندسی عمران دانشگاه سمنان - hamidrezaghazvinian@semnan.ac.ir

۲ : دانشیار گروه آب و سازه های هیدرولیکی، دانشکده مهندسی عمران دانشگاه سمنان - hkarami@semnan.ac.ir

۱-مقدمه

تصادفات جاده‌ای یکی از عوامل اصلی مرگ و میر در ایران است (Kamboozia et al., 2020). عوامل متعددی باعث تصادفات برون‌شهری می‌باشد و یکی از مهم‌ترین عواملی که باعث تصادفات مرگبار در جاده‌های کشور می‌شود خستگی و خواب‌آلودگی رانندگان به خصوص رانندگان وسایل نقلیه سنگین است. خستگی حالتی است که در آن ظرفیت کار، رغبت به کار و فعالیت انسان کمتر می‌شود و شخص هیچ‌گونه تمایلی به انجام کار جسمانی و فکری را ندارد و احساس سنگینی می‌کند. کارها را به آهستگی انجام داده و کارایی‌اش کاهش می‌یابد. خستگی می‌تواند به صورت روانی و افسردگی، فیزیولوژی یا در اثر بیماری‌های مختلف باشد. شیوه زندگی امروزی شامل نامنظم بودن خواب ساعات کار طولانی و پیمایش مسیرهای طولانی از طریق حمل و نقل جاده ای تعداد تصادفات با علت اصلی یا مشارکتی خستگی راننده را افزایش داده است. خطای انسانی به دلیل بی توجهی، تخلفات و خواب‌آلودگی عامل اصلی مسئول بیش از ۹۰ درصد صدمات رانندگی در سراسر جهان است (Johnson et al., 2014). به دلیل عدم درک عوامل موثر در تصادفات، وضعیت ایمنی ترافیک در کشورهای در حال توسعه به مراتب بدتر است (Zhang et al., 2016). تجزیه و تحلیل علت و معقول در گزارشی نشان داد که حدود ۴۱ تلفات ناشی از تخلفات رانندگی مانند سرعت بیش از حد و ۳۲ درصد دیگر مدیون بی توجهی، رانندگی بی دقت یا رانندگی با خطر هستند. تخلفات جاده‌ای را انحراف از عملیات ایمن مورد نیاز هنگام رانندگی در جاده تعریف کردند. بی توجهی، خستگی و رفتارهای نقض شده به طور عمده مشخص می‌شود که با بروز بحران ایمنی در بین رانندگان کامیون همراه است (Mohamed et al., 2013). رانندگی از جمله مشاغلی است که کیفیت نامطلوب خواب، خواب‌آلودگی و خواب رفتن هنگام رانندگی منجر به اختلال در منطق و درک صحیح راننده شده و منجر به افزایش خطا و به دنبال آن افزایش احتمال حوادث و تصادفات در این حرفه می‌شود. به خصوص در رانندگان وسایل نقلیه سنگین نمود بیشتری دارد. علائم خستگی و خواب‌آلودگی در رانندگان باعث ایجاد حوادث و رفتار رانندگی خطرناک نیز ممکن است با تخلفات مرتبط باشد خستگی و خواب‌آلودگی رانندگان، بخصوص رانندگان وسایل نقلیه سنگین باعث بوجود آمدن تصادفات مرگبار در جاده های کشور می‌شود (Johnson et al., 2014).

در سال های اخیر مطالعات مختلفی در زمینه ایمنی تردد در جاده‌ها برای شناسایی متغیرهای موثر انجام شده است. هدف (Abdelwahab and Abdel-Aty, 2002) بررسی شدت جراحت راننده و عوامل مؤثر بر احتمال شدت جراحت بود. آنها از پرسپترون چندلایه و همچنین دیگر مدل های شبکه عصبی مصنوعی (ANN) برای تحقیقات خود استفاده کردند. آنها نشان دادند که محل تصادف، نقطه برخورد، نوع وسیله نقلیه، استفاده از کمربند ایمنی، سرعت وسیله نقلیه و جنسیت عوامل مؤثر در شدت آسیب تصادفات هستند. (Chong et al., 2004) مدلی را با استفاده از الگوریتم‌های یادگیری

ماشین برای دسته‌بندی شدت آسیب‌های تصادف، به پنج گروه توسعه دادند. این مدل با استفاده از ترکیبی از شبکه‌های عصبی مصنوعی (ANN)، ماشین‌های بردار پشتیبان (SVM) و درخت‌های تصمیم ایجاد شد. بر اساس یافته‌های آنها تخطی از سرعت مجاز یکی از علل اصلی تصادفات جدی و مرگبار است. علاوه بر این، (Al Najada and Mahgoub, 2016) با استخراج و تجزیه و تحلیل مقادیر زیادی از داده‌ها، روند پیش بینی حوادث را روشن کرد. نویسندگان همچنین بر اهمیت نمونه‌گیری داده‌ها در بازسازی مجموعه داده و همچنین استفاده از تکنیک‌های پیش فرض برای اطمینان از کامل و دقیق بودن داده‌ها تاکید کردند.

مطالعه پژوهشی انجام شده توسط (Elfar et al., 2018) از سه الگوریتم یادگیری ماشین استفاده کرد. رگرسیون لجستیک، جنگل تصادفی، و شبکه‌های عصبی برای پیش‌بینی حوادث ترافیکی و تراکم مورد استفاده قرار گرفت. دو مدل پیش‌بینی نیز برای استفاده در آموزش داده پیشنهاد شد. دقت مدل‌های پیشنهادی بالاتر از سه مدل طبقه‌بندی دیگر تست شده در این مطالعه بود. علاوه بر این، مشارکت نویسندگان نشان داد که چگونه مدل‌های پیشنهادی آن‌ها را می‌توان در کاربردهای مختلف وسایل نقلیه برای افزایش ایمنی جاده با ارائه اطلاعاتی پیشرفته از کاهش سرعت ترافیک آتی پیاده‌سازی کرد. (Iranitalab and Khattak (2017) نشان داد که رگرسیون خطی، Naive Bayes و Random Forest تنها چند نمونه از الگوریتم‌های ML هستند که در تجزیه و تحلیل مجموعه داده‌های بزرگ برای پیش‌بینی تصادفات رانندگی مؤثر بوده‌اند.

(Behbahani et al. (2018) چهار نوع روش شبکه عصبی مصنوعی (ANN) شامل MLPNN، RBFNN، شبکه عصبی احتمالی (PNN) و ماشین یادگیری افراطی (ELM) را مقایسه کرد. (نتایج این مطالعه نشان داد که تکنیک ELM به عنوان سریع‌ترین الگوریتم شناخته شد و همچنین این روش در پیش‌بینی تصادفات بسیار دقیق بود. همچنین الگوریتم RBFNN موثرترین عوامل را در پیش‌بینی تصادفات شناسایی کرد. (Abdel-Aty and Radwan, (2000) یک تصادف بلادرنگ در یک بزرگراه ساخت. آنها به این نتیجه رسیدند که مدل ماشین بردار پشتیبان (SVM) حتی با حجم نمونه کمتر بهتر عمل می‌کند، آموزش و آزمایش مدل SVM به تکنیک‌های انتخاب متغیر بستگی دارد، و عوامل توضیحی تأثیر یکسانی بر احتمال خرابی برای مدل‌های لجستیک و SVM دارد (Ali et al., 2024).

با توجه به پیشرفت روزافزون روش‌های هوش مصنوعی و محاسبات نرم در علوم مختلف، این موضوع در مدل‌سازی تصادفات جاده‌ای نیز حائز اهمیت می‌باشد. از این رو، در این تحقیق به بررسی کارایی مدل SVM در شبیه‌سازی میزان تصادفات ناشی از خستگی و خواب‌آلودگی در محور سمنان - شاهرود با کمک پارامترهای مؤثر بر تصادف پرداخته شد.

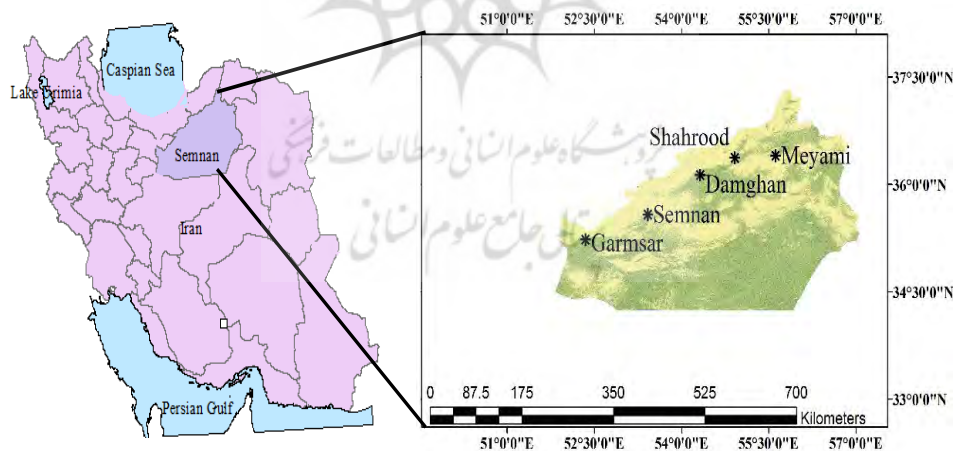
۲- مواد و روش‌ها

۲-۱- مشخصات کلی محور مورد مطالعه

محور سمنان-شاهرود به طول ۱۸۴ کیلومتر، در حوزه استحفاظی استان سمنان واقع گردیده است (شکل ۱). جاده فوق از شهرستان‌های سمنان، دامغان، شاهرود عبور می‌کند. طول دوره مطالعه از سال ۱۳۹۵ الی ۱۴۰۱ انجام شد.

۲-۲- مسیر مورد مطالعه


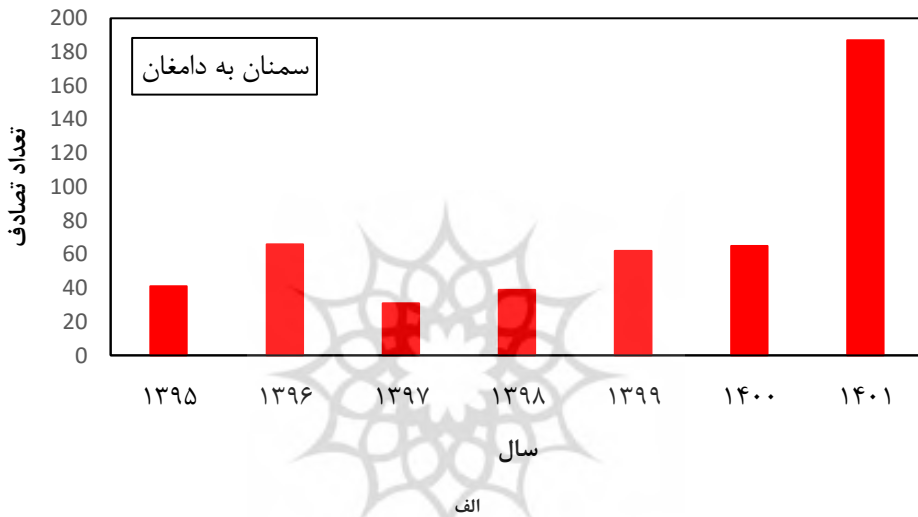
با توجه به شکل ۱، استان سمنان با قرار گرفتن در مسیر کریدور شرق به غرب علاوه بر افتخار میزبانی به زائران حرم مطهر رضوی، محور مواصلاتی اصلی در پیوند شرق و غرب کشور را بر عهده داشته و از جنبه مسافری و اقتصادی نقش مهمی را دارد. محور سمنان - شاهرود یکی از پر ترددترین محورهای کشور محسوب می‌شود که بخش عمده آن در استان سمنان واقع شده است. سمنان تا شاهرود با طول ۱۸۴ کیلومتر تشکیل شده است. دو بخش اولیه این محور به دلیل واقع شدن بر مسیر دو کلان شهر تهران و مشهد و به تبع آن ترانزیت کالا، در واقع یکی از با اولویت‌ترین محورهای حمل و نقلی در کشور برای توسعه به شمار می‌رود.




شکل ۱: نقشه استان سمنان (Karami et al., 2023; Karami and Ghazvinian, 2022)


۲-۳- داده‌های مورد مطالعه

داده‌های تصادفات ناشی از خواب آلودگی و خستگی برای محور سمنان - شاهرود و برعکس از پلیس راهور استان سمنان دریافت شد. در شکل ۲ نیز نمودار تصادفات ناشی از خواب آلودگی و خستگی از محور سمنان - دامغان، دامغان - سمنان، شاهرود - دامغان و دامغان - شاهرود به تفکیک سال‌های مورد مطالعه نشان داده شده است. براساس این نمودارهای ارائه شده، در سال ۱۴۰۱ در محورهای سمنان - دامغان، دامغان - سمنان و سمنان و دامغان - شاهرود بیشترین تصادفات گزارش شده است. محور شاهرود - دامغان بیشترین تصادف در سال ۱۳۹۸ می‌باشد.





ج



شکل ۲: تعداد تصادفات ناشی از خستگی و خواب‌آلودگی محور، الف) سمنان - دامغان، ب) دامغان - سمنان، ج) شاهرود به دامغان و د) دامغان به شاهرود

۲-۴- مدل‌سازی با روش هوشمند

به طور کلی به منظور طراحی مدلی برای پیش‌بینی، می‌توان از مدل‌های یادگیری ماشین استفاده کرد. الگوریتم‌های مورد استفاده در مدل‌های یادگیری ماشین به طور کلی به دو دسته الگوریتم‌های سنتی و شبکه عصبی مصنوعی تقسیم می‌شوند. با توجه به تعداد داده‌ها در این تحقیق، استفاده از مدل‌های سنتی مناسب‌تر است. برای این منظور، بعد از انجام مراحل مورد نیاز برای پیش‌پردازش و آماده‌سازی داده‌ها از مدل SVM به منظور انجام پیش‌بینی استفاده می‌شوند. در نهایت بعد از پیدا

کردن مناسب‌ترین فرا پارامترها (hyperparameter) برای هر یک از مدل‌ها، بهترین مدل در پیشبینی "عامل تصادف" به عنوان مدل برتر انتخاب می‌شود. تمامی مراحل گفته شده با استفاده از زبان برنامه‌نویسی پایتون و در محیط Google Colab انجام می‌شود. در ادامه هر یک از مراحل گفته شده شرح داده شده است.

۲-۴-۱- آماده‌سازی مجموعه‌داده

آماده سازی داده قبل از پردازش آن یکی از مراحل مهم و ضروری در داده‌کاوی است. این مرحله شامل آماده‌سازی فایل اکسل یا CSV مناسب برای انجام پیش‌برازش‌های لازم، انتخاب فیچرهای قابل استفاده به منظور پیشبینی‌های مورد نیاز، بررسی آماری شاخص‌ها و تبدیل داده‌های موجود به داده‌های کاربردی‌تر می‌شود. در ادامه هر یک از مراحل گفته شده شرح داده می‌شود. در این تحقیق به منظور آماده‌سازی داده‌ها ابتدا ردیف داده‌هایی که دارای داده گمشده هستند حذف می‌شوند. سپس، اشکالات نگارشی در هنگام وارد کردن داده‌ها در فایل اکسل اصلاح می‌شوند. پس از اصلاح فایل، تعداد ۷۱۳۷ ردیف داده باقی می‌ماند.

۲-۴-۲- فیچرهای استفاده شده در مدل

در ابتدا شاخص‌های مؤثر بر علت تصادف از بین سایر شاخص‌های موجود در مجموعه‌داده آماده شده با توجه به تحقیقات گذشته انتخاب می‌شوند. پس از اجرای مدل مشخص شد که شاخص‌های "روز" و "سال" همبستگی قابل قبولی با علت تصادف ندارند. در نتیجه، از مجموعه‌داده حذف شدند. همچنین، شاخص ماه به طور ماهیانه همبستگی مناسبی با علت تصادف ندارد. در نتیجه، داده‌ها به صورت فصلی مرتب شدند. در نهایت شاخص‌های ماه (month)، وضعیت روشنایی (lighting)، ایام هفته (weKday)، وضعیت جاده (passcondition)، وضعیت آب و هوا (weather)، نوع مسیله سواری (vehicle)، وضعیت ماشین (fire)، بسته بودن کمربند ایمنی (seatbelt)، نوع صدمه وارد شده (injurytype)، جنسیت (gender) و میزان تحصیلات راننده (education) به عنوان ورودی مدل انتخاب شدند.

۲-۴-۳- ماشین بردار پشتیبان

ماشین بردار پشتیبان (Support Vector Machine) یا به اختصار SVM یک مدل یادگیری ماشین با ناظر (supervised learning) است که با توجه به داده‌های برچسب‌دار آموزشی، یک مدل بهینه را ارائه می‌کند تا داده‌های جدید را به دسته‌های مختلف طبقه‌بندی کند. ماشین بردار پشتیبان یک الگوریتم دسته‌بندی بسیار قدرتمند است. وقتی از آن همراه با الگوریتم‌های جنگل تصادفی و دیگر ابزارهای یادگیری ماشین استفاده کنیم، این الگوریتم می‌تواند مدلی بسیار قابل توجه برای دسته‌بندی داده‌ها ارائه کند. برای این منظور ابتدا داده‌های موجود در مجموعه‌داده به صورت عددی در آمدند.

سپس، داده‌های عددی شده فیچرها وان هات شدند. one hot encoding یک روش برای تبدیل متغیرهای غیر عددی (categorical variables) به داده‌های عددی است که می‌تواند توسط الگوریتم‌های یادگیری ماشین استفاده شود. این روش به ویژه برای مدل‌هایی که نمی‌توانند مستقیماً با داده‌های دسته‌ای کار کنند، مفید است. این hyperparameters به طور مشترک برای تنظیم دقت و جلوگیری از overfitting یا underfitting در مدل SVM استفاده می‌شوند. فرا پارامترهای مورد استفاده در SVM در ادامه توضیح داده شده است:

RBF: kernel=rbf یکی از رایج‌ترین توابع هسته است و می‌تواند به خوبی با داده‌هایی که به صورت خطی جدا نمی‌شوند، کار کند.

C=1.0: پارامتر C میزان جریمه‌ای را که برای نقاط داده‌ای که درست طبقه‌بندی نشده‌اند، اعمال می‌کند، تعیین می‌کند. مقدار بالاتر C به معنای جریمه بیشتر برای طبقه‌بندی اشتباه است و می‌تواند منجر به مدلی با واریانس بالاتر و بایاس پایین‌تر شود.

gamma=scale: زمانی که scale, gamma است، گاما به صورت خودکار بر اساس تعداد ویژگی‌های داده‌ها تنظیم می‌شود.

class_weight=class_weights: این پارامتر اجازه می‌دهد تا وزن‌های مختلفی به کلاس‌های مختلف اختصاص داده شود، که می‌تواند در مواقعی که داده‌ها متعادل نیستند (یعنی یک کلاس بیشتر از کلاس‌های دیگر نمونه دارد) مفید باشد. وزن‌های در نظر گرفته شده در مدل ساخته شده به صورت زیر است:

{0: 1.1, 1: 0.5, 2: 0.15}

0 occurs 305 times

1 occurs 2058 times

2 occurs 4774 times

عجله و شتاب بی مورد ۴۷۷۴

خستگی و خواب‌آلودگی ۲۰۵۸

بی توجهی به مقررات ۳۰۵

***** 0 *****

The train score is 0.9809073392888422

The test score is 0.9782913165266106

F1-score: 0.978463613626749

	precision	recall	f1-score	support
0	0.96	1.00	0.98	68
1	0.94	0.99	0.96	364
2	1.00	0.97	0.98	996
accuracy			0.98	1428
macro avg	0.96	0.99	0.98	1428
weighted avg	0.98	0.98	0.98	1428

***** 1 *****

The train score is 0.976528288667017

The test score is 0.969187675070028

F1-score: 0.9693056770291216

	precision	recall	f1-score	support
0	0.96	1.00	0.98	78
1	0.93	0.96	0.95	399
2	0.99	0.97	0.98	951
accuracy			0.97	1428
macro avg	0.96	0.98	0.97	1428
weighted avg	0.97	0.97	0.97	1428

***** 2 *****

The train score is 0.975831873905429

The test score is 0.9705676243868255

F1-score: 0.970791880245906

	precision	recall	f1-score	support
0	0.96	0.99	0.97	69
1	0.92	0.97	0.94	334

	2	0.99	0.97	0.98	1024
accuracy				0.97	1427
macro avg	0.96	0.98	0.97		1427
weighted avg	0.97	0.97	0.97		1427

***** 3 *****

The train score is 0.9802101576182136

The test score is 0.9789768745620182

F1-score: 0.9791779540144425

	precision	recall	f1-score	support
0	0.93	1.00	0.96	74
1	0.94	1.00	0.97	350
2	1.00	0.97	0.98	1003
accuracy			0.98	1427
macro avg	0.95	0.99	0.97	1427
weighted avg	0.98	0.98	0.98	1427

***** 4 *****

The train score is 0.9826619964973731

The test score is 0.979677645409951

F1-score: 0.979862988155395

	precision	recall	f1-score	support
0	0.99	1.00	0.99	74
1	0.93	0.99	0.96	348
2	1.00	0.97	0.99	1005
accuracy			0.98	1427
macro avg	0.97	0.99	0.98	1427

weighted avg 0.98 0.98 0.98 1427

The average of TrainScore is: 0.9792279311953751

The average of TestScore is: 0.9753402271910867

The average of F1-score is: 0.9755204226143228

۳-۶- معیارهای ارزیابی

برای ارزیابی روش های کریجینگ و IDW، در درجه اول، داده های برآورد شده برای هر یک از داده های مشاهده شده با استفاده از روش ارزیابی متقابل محاسبه شد. سپس با استفاده از معیارهای ارزیابی که معادلات ۱ تا ۳ است، مقدار خطای هر روش محاسبه شد. جهت ارزیابی نتایج، شاخص های آماری ضریب تبیین (R^2)، ریشه ی میانگین مربعات خطا (RMSE) و میانگین خطای مطلق (MAE) محاسبه شدند. برای ارزیابی نتایج استفاده شد. شاخص R^2 هر چه به یک نزدیکتر باشد، دقت بالای روش را نشان می دهد. شاخص های MAE و RMSE نیز میزان خطای آزمایش را نشان می دهد و بنابراین هر چه به صفر نزدیک شوند، مطابقت داده ها دقیق تر است.

$$R^2 = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \quad (1)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - x_i)^2}{N}} \quad (2)$$

$$MAE = \frac{1}{N} \sum_{i=1}^n |y_i - x_i| \quad (3)$$

در روابط ۱ الی ۳، x_i مقدار اندازه گیری شده، y_i مقدار برآورد شده همان روز، \bar{x} میانگین مقادیر اندازه گیری شده و \bar{y} میانگین نظیر برای مقادیر برآورد شده می باشد.

۳- نتایج و بحث

۳-۱- ماتریس درهم‌ریختگی^۱

Confusion matrix نشان داده شده در شکل ۳ نمایشی بصری از عملکرد مدل در پیش‌بینی علت تصادفات ارائه می‌دهد. هر خانه (سلول) در این ماتریس تعداد پیش‌بینی‌هایی را نشان می‌دهد که در آن علت واقعی یک تصادف (ردیف‌ها) با علت پیش‌بینی شده (ستون‌ها) مطابقت دارد یا ندارد.

- سلول‌های قطری (از بالا-چپ به پایین-راست) نشان‌دهنده مواردی هستند که به درستی برای هر علت تصادف طبقه‌بندی شده‌اند.

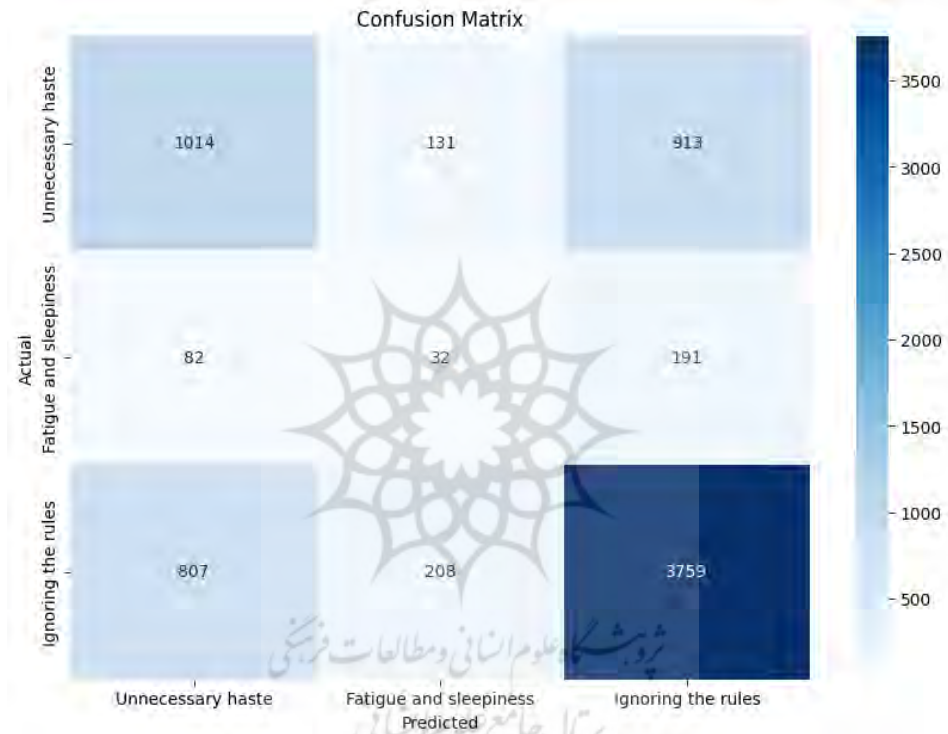
- سلول‌های غیر قطر نشان‌دهنده تعداد موارد اشتباه طبقه‌بندی شده هستند، جایی که علت واقعی با علت پیش‌بینی شده متفاوت است.

شدت رنگ در نقشه حرارتی به شناسایی سریع عملکرد خوب مدل (سایه‌های تیره‌تر بر روی قطر) و جایی که ممکن است اشتباهات بیشتری داشته باشد (سایه‌های تیره‌تر خارج از قطر) کمک می‌کند. نوشته‌های داخل سلول‌ها تعداد دقیق این طبقه‌بندی‌ها را ارائه می‌دهند.

درک ماتریس اغتشاش برای ارزیابی مدل طبقه‌بندی بسیار مهم است، به ویژه در شناسایی دسته‌های خاصی که ممکن است مدل نیاز به بهبود داشته باشد. ماتریس درهم‌ریختگی خلاصه‌ی پیش‌بینی مدل یادگیری ماشین را در یک ماتریس نشان می‌دهد. این ماتریس تعداد پیش‌بینی‌های درست و نادرست را برای هر گروه نشان می‌دهد. جدول ۱ نمونه‌ای از ماتریس درهم‌ریختگی را برای مسئله‌ی طبقه‌بندی دودوئی نشان می‌دهد. در این جدول، TP و FP به ترتیب، تعداد پیش‌بینی‌های مثبت درست پیش‌بینی شده و تعداد پیش‌بینی‌های مثبت نادرست پیش‌بینی شده توسط مدل را نشان می‌دهد. همچنین، TN و FN به ترتیب، تعداد پیش‌بینی‌های منفی درست پیش‌بینی شده و تعداد پیش‌بینی‌های منفی نادرست پیش‌بینی شده توسط مدل را نشان می‌دهد. در مدل پیشنهاد شده منظور از پیش‌بینی‌های مثبت پیش‌بینی‌هایی است که نشان می‌دهد عامل کشاورز تمایل به حفظ منابع آب دارد. همچنین، منظور از پیش‌بینی‌های منفی پیش‌بینی‌هایی است که نشان می‌دهد عامل کشاورز تمایل به حفظ منابع آب ندارد.

جدول ۱: ماتریس درهم‌ریختگی

مدل		کلاس پیش‌بینی	
		+	-
کلاس واقعی	+	TP	FP
	-	FN	TN



شکل ۳: ماتریس اغتشاش برای پیش‌بینی علت تصادفات

۳-۲- شاخص ۱F

شاخص F ترکیبی از دو معیار دقت^۲ و بازخوانی^۳ است. این شاخص به‌عنوان معیاری جامع به منظور ارزیابی عملکرد مدل استفاده می‌شود، به‌ویژه در مسائلی که تعادل بین دقت و بازخوانی اهمیت دارد.

- 1: F-score
- 2: Precision
- 3: Recall

شاخص F بر اساس مقادیر دقت و بازخوانی محاسبه می‌شود و با استفاده از رابطه ۴ محاسبه می‌شود.

$$F = 2 \times \frac{(\text{بازخوانی} + \text{دقت})}{\text{بازخوانی} \times \text{دقت}} \quad (4)$$

دقت، نشان‌دهنده‌ی میزان تشخیص صحیح نمونه‌های مثبت و بازخوانی، نشان‌دهنده‌ی میزان شناسایی صحیح تمام نمونه‌های مثبت است. شاخص F به صورت یک عدد بین صفر و یک است و هرچه مقدار آن نزدیک‌تر به یک باشد، دقت مدل بیشتر است. در ادامه، معیارهای دقت و بازخوانی شرح داده می‌شوند.

۳-۳ - معیار دقت

در طبقه‌بندی نامتعادل با دو کلاس، معیار دقت با تقسیم تعداد پیش‌بینی‌های مثبت درست پیش‌بینی شده بر مجموع تعداد پیش‌بینی‌های مثبت درست پیش‌بینی شده و تعداد پیش‌بینی‌های مثبت نادرست پیش‌بینی شده به دست می‌آید. در صورتی که دقت مدل ساخته شده بسیار پایین باشد، مقدار این معیار به عدد صفر نزدیک است. همچنین، در صورتی که دقت مدل بسیار بالا باشد مقدار این معیار به عدد یک نزدیک می‌شود (رابطه ۵).

$$\text{دقت} = \frac{TN}{(TN + FN)} \quad (5)$$

۳-۴ - معیار بازخوانی

معیار بازخوانی از تقسیم تعداد پیش‌بینی‌های منفی درست پیش‌بینی شده بر حاصل جمع تعداد پیش‌بینی‌های منفی درست پیش‌بینی شده و تعداد پیش‌بینی‌های منفی نادرست پیش‌بینی شده به دست می‌آید. در صورتی که دقت مدل ساخته شده بسیار پایین باشد، مقدار این معیار به عدد صفر است. همچنین، در صورتی که دقت مدل بسیار بالا باشد، مقدار این معیار به عدد یک نزدیک می‌شود (رابطه ۶).

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

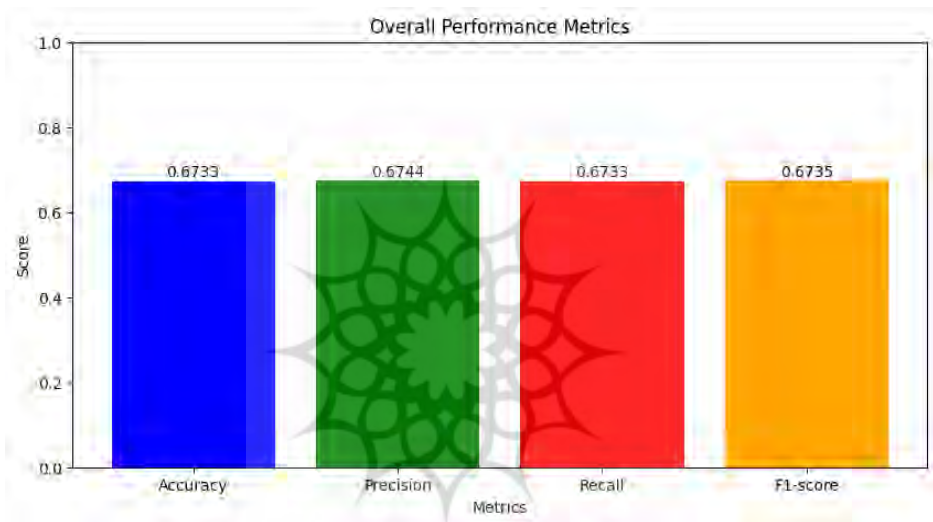
شکل ۴ نمایی کلی از معیارهای عملکرد مدل برای پیش‌بینی علت تصادفات را نشان می‌دهد. این معیارها شامل دقت، دقت پیش‌بینی (Precision)، بازیابی (Recall) و امتیاز $(F1)$ هستند که به صورت نمودار میله‌ای نمایش داده شده‌اند. هر میله در نمودار نشان‌دهنده مقدار هر معیار است که با استفاده از رنگ‌های مختلف برای وضوح بیشتر نشان داده شده‌اند.

- دقت (Accuracy): نسبت تعداد پیش‌بینی‌های صحیح به کل پیش‌بینی‌ها

- دقت پیش‌بینی (Precision): نسبت تعداد پیش‌بینی‌های صحیح برای یک کلاس به تعداد کل پیش‌بینی‌های انجام‌شده برای آن کلاس.

- بازیابی (Recall): نسبت تعداد پیش‌بینی‌های صحیح برای یک کلاس به تعداد کل نمونه‌های واقعی آن کلاس.

- امتیاز F1: میانگین موزون دقت پیش‌بینی و بازیابی که به تعادل بین این دو معیار کمک می‌کند. اعداد نوشته‌شده بالای هر میله مقدار دقیق هر معیار را نشان می‌دهند. این معیارها برای ارزیابی کلی عملکرد مدل و تعیین اینکه مدل در چه حد به درستی عمل می‌کند، بسیار مفید هستند.



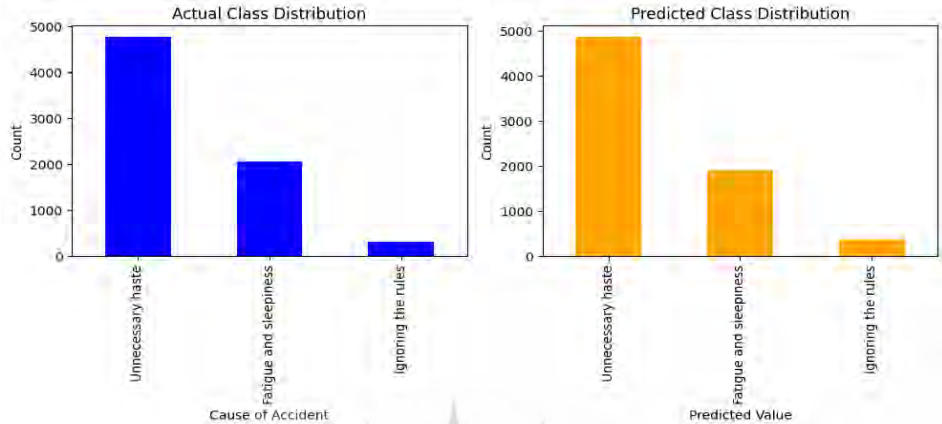
شکل ۴: معیارهای عملکرد کلی

شکل ۵ توزیع کلاس‌های واقعی و پیش‌بینی شده در داده‌ها را به صورت نمودار میله‌ای نمایش می‌دهد. این شکل شامل دو نمودار جداگانه است:

- توزیع کلاس واقعی (نمودار سمت چپ): این نمودار تعداد موارد برای هر علت تصادف واقعی را نشان می‌دهد. هر میله نمایانگر تعداد حوادث مربوط به یک علت خاص است و با رنگ آبی مشخص شده است.

- توزیع کلاس پیش‌بینی شده (نمودار سمت راست): این نمودار تعداد موارد برای هر علت تصادف پیش‌بینی شده را نشان می‌دهد. هر میله نمایانگر تعداد پیش‌بینی‌های مدل برای یک علت خاص است و با رنگ نارنجی مشخص شده است.

این دو نمودار به مقایسه توزیع علت‌های واقعی و پیش‌بینی شده کمک می‌کنند و نشان می‌دهند که مدل در تشخیص هر دسته چقدر موفق بوده است. از طریق این مقایسه می‌توان عدم تعادل‌های موجود در داده‌ها و همچنین بایاس‌های احتمالی مدل را شناسایی کرد.



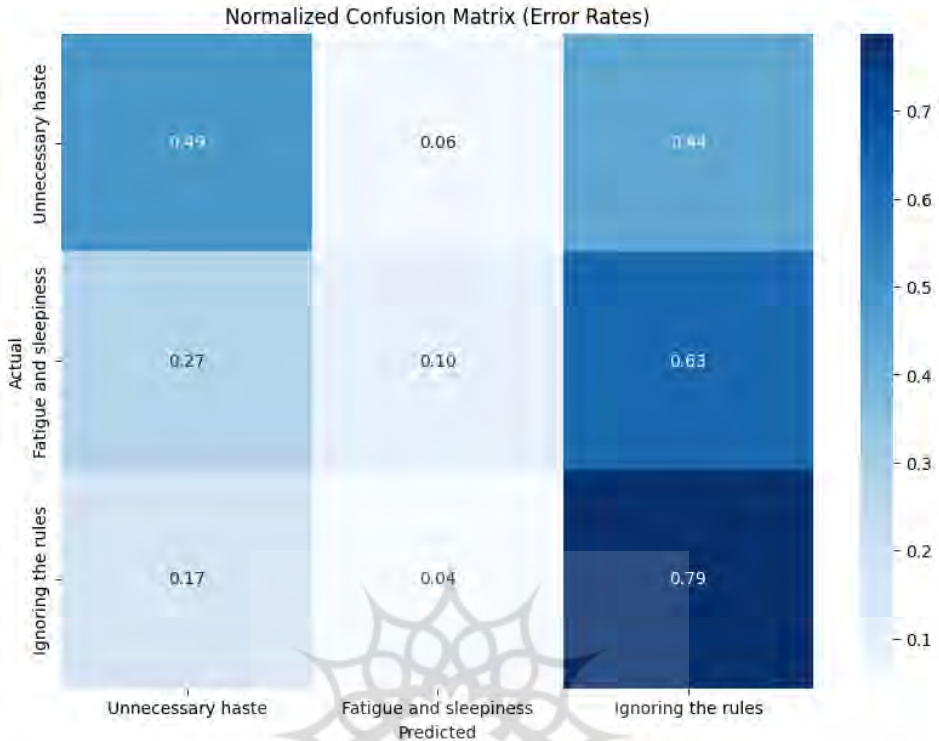
شکل ۵: توزیع کلاس واقعی و پیش‌بینی شده

شکل ۶ Confusion matrix نرمال‌شده را برای پیش‌بینی علت تصادفات نشان می‌دهد. در این ماتریس، هر سلول نشان‌دهنده درصد مواردی است که در آن علت واقعی یک تصادف (ردیف‌ها) با علت پیش‌بینی شده (ستون‌ها) مطابقت دارد یا ندارد. مقادیر نرمال‌شده به عنوان نرخ خطاها یا نسبت طبقه‌بندی‌های صحیح و غلط نمایش داده می‌شوند.

- سلول‌های قطری (از بالا-چپ به پایین-راست) نرخ طبقه‌بندی‌های صحیح برای هر علت تصادف را نشان می‌دهند.

- سلول‌های خارج از قطر نرخ مواردی را نشان می‌دهند که در آن علت واقعی با علت پیش‌بینی شده متفاوت است.

این ماتریس با رنگ‌بندی گرمایی (heatmap) ارائه شده است که شدت رنگ‌ها به شناسایی سریع نرخ‌های خطا کمک می‌کند. نوشته‌های داخل سلول‌ها مقادیر دقیق نرمال‌شده را نمایش می‌دهند. این نمایش بصری به تحلیل و ارزیابی عملکرد مدل در تشخیص صحیح یا غلط علت‌های مختلف تصادفات کمک می‌کند و نقاط ضعف احتمالی مدل را شناسایی می‌کند.



شکل ۶: ماتریس اغتشاش نرمال شده (نرخ خطاها)

شکل ۷ عملکرد مدل SVM را بر اساس دقت آموزش، دقت تست، و امتیاز F1 برای هر یک از پنج fold در اعتبارسنجی متقابل (Cross-Validation) نشان می‌دهد. این شکل شامل دو نمودار میله‌ای جداگانه است:

در نمودار بالا (Train and Test Accuracy per Fold):

- این نمودار دقت آموزش (Train Accuracy) و دقت تست (Test Accuracy) را برای هر یک از پنج fold نمایش می‌دهد.

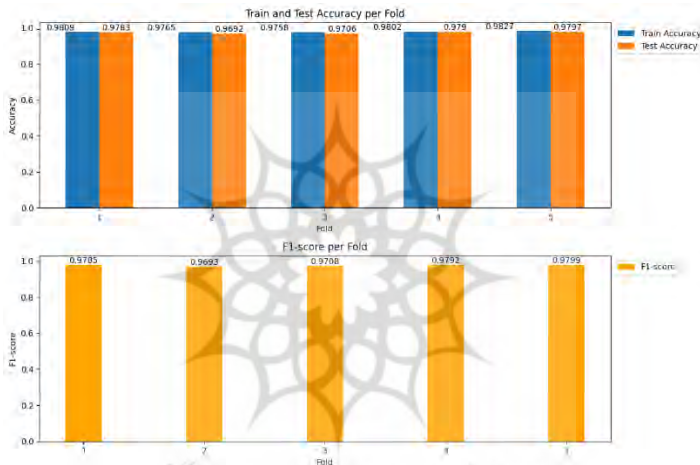
- دقت آموزش با رنگ آبی و دقت تست با رنگ نارنجی نشان داده شده است.

- اعداد بالای هر میله مقدار دقت مربوطه را نشان می‌دهند.

- مدل به طور کلی دارای دقت بالایی است که در محدوده ۰.۹۷ تا ۰.۹۸ قرار دارد، که نشان‌دهنده عملکرد خوب مدل در هر دو مجموعه آموزش و تست است.

در نمودار پایین (F1-score per Fold):

- این نمودار امتیاز F1 را برای هر یک از پنج fold نمایش می‌دهد.
- امتیاز F1 با رنگ نارنجی نشان داده شده است.
- اعداد بالای هر میله مقدار امتیاز F1 را نشان می‌دهند.
- امتیاز F1 نیز بسیار بالاست و در محدوده ۰.۹۶ تا ۰.۹۸ قرار دارد، که نشان‌دهنده توازن خوب بین دقت پیش‌بینی و بازیابی مدل است.
- این شکل به خوبی نشان می‌دهد که مدل SVM در هر یک از پنج fold عملکرد پایداری دارد و قادر به پیش‌بینی دقیق علت تصادفات است. همچنین تفاوت کمی بین دقت آموزش و دقت تست مشاهده می‌شود، که نشان‌دهنده عدم وجود overfitting قابل توجه در مدل است.



شکل ۷: دقت آموزش و تست و امتیاز F1 برای هر Fold

در جدول ۲، به کارایی مدل SVM براساس معیارهای ارزیابی R^2 ، RMSE و MAE در دو مرحله آموزش و آزمون پرداخته شده است. براساس نتایج این جدول مدل SVM، از کارایی بالایی در برآورد تصادفات ناشی از خرابی آلودگی برخوردار است.

جدول ۲: ارزیابی مدل SVM در شبیه‌سازی تصادفات ناشی از خرابی آلودگی

مرحله	معیار ارزیابی		
	R^2	MAE	RMSE
آموزش	۰/۹۳۲۳	۲/۲۴۳۹	۳/۵۳۱۳
آزمون	۰/۹۱۵۳	۲/۶۷۴۵	۳/۸۵۱۲

۴- نتیجه گیری

یک سوم حوادث رانندگی که دومین علل مرگ و میر در کشور ما شامل می شود، به دلیل اختلالات خواب و خستگی ناشی از آن رخ می دهد. بعلاوه، در ایران هر ساله بیش از ۲۰ هزار نفر در تصادفات ترافیکی جان خود را از دست می دهند که در این بین خستگی و خواب آلودگی نقش ۳۰ درصدی را دارا می باشد. این مطالعه با در نظر گرفتن عوامل مختلف بر تصادفات محور سمنان - شاهرود که شامل، ماه، وضعیت روشنایی، ایام هفته، وضعیت جاده، وضعیت آب و هوا، نوع مسیله سواری، وضعیت ماشین، بسته بودن کمر بند ایمنی، نوع صدمه وارد شده، جنسیت و میزان تحصیلات راننده می باشد، به بررسی کارایی مدل هوشمند SVM در برآورد تصادفات ناشی از خستگی و خواب آلودگی پرداخته شد. به طور کلی نتایج نشان داد که مدل SVM می تواند در برآورد تصادفات ناشی از خستگی و خواب آلودگی عملکرد مناسبی داشته باشد.

مراجع:

- Abdel-Aty, M.A., Radwan, A.E., 2000. Modeling traffic accident occurrence and involvement. *Accid. Anal. Prev.* 32, 633–642.
- Abdelwahab, H.T., Abdel-Aty, M.A., 2002. Artificial neural networks and logit models for traffic safety analysis of toll plazas. *Transp. Res. Rec.* 1784, 115–125.
- Al Najada, H., Mahgoub, I., 2016. Anticipation and alert system of congestion and accidents in VANET using Big Data analysis for Intelligent Transportation Systems, in: 2016 IEEE Symposium Series on Computational Intelligence (SSCI). IEEE, pp. 1–8.
- Ali, Y., Hussain, F., Haque, M.M., 2024. Advances, challenges, and future research needs in machine learning-based crash prediction models: A systematic review. *Accid. Anal. Prev.* 194, 107378. <https://doi.org/10.1016/j.aap.2023.107378>
- Behbahani, H., Amiri, A.M., Imaninasab, R., Alizamir, M., 2018. Forecasting accident frequency of an urban road network: A comparison of four artificial neural network techniques. *J. Forecast.* 37, 767–780.
- Chong, M., Abraham, A., Paprzycki, M., 2004. Traffic accident data mining using machine learning paradigms, in: Fourth International Conference on Intelligent Systems Design and Applications (ISDA'04), Hungary. pp. 415–420.
- Elfar, A., Talebpour, A., Mahmassani, H.S., 2018. Machine learning approach to short-term traffic congestion prediction in a connected environment. *Transp. Res. Rec.* 2672, 185–195.
- Iranitalab, A., Khattak, A., 2017. Comparison of four statistical and machine learning methods for crash severity prediction. *Accid. Anal. Prev.* 108, 27–36.
- Johnson, K.D., Patel, S.R., Baur, D.M., Edens, E., Sherry, P., Malhotra, A., Kales, S.N., 2014. Association of sleep habits with accidents and near misses in United States transportation operators. *J. Occup. Environ. Med.* 56, 510–515.

Kamboozia, N., Ameri, M., Hosseinian, S.M., 2020. Statistical analysis and accident prediction models leading to pedestrian injuries and deaths on rural roads in Iran. *Int. J. Inj. Contr. Saf. Promot.* 27, 493–509. <https://doi.org/10.1080/17457300.2020.1812670>

Karami, H., Ghazvinian, H., 2022. A Practical and Economic Assessment Regarding the Effect of Various Physical Covers on Reducing Evaporation from Water Reservoirs in Arid and Semi-Arid Regions (Experimental Study). *Iran. J. Soil Water Res.* ISSN 53, 1297–1313.

Karami, H., Ghazvinian, H., Dadrasajirlou, Y., 2023. Application of statistical and geostatistical approaches in temporal and spatial estimations of rainfall. *J. Water Clim. Chang.* 14, 1696–1722. <https://doi.org/10.2166/wcc.2023.034>

Mohamed, M.G., Saunier, N., Miranda-Moreno, L.F., Ukkusuri, S. V, 2013. A clustering regression approach: A comprehensive injury severity analysis of pedestrian–vehicle crashes in New York, US and Montreal, Canada. *Saf. Sci.* 54, 27–37.

Zhang, G., Yau, K.K.W., Zhang, X., Li, Y., 2016. Traffic accidents involving fatigue driving and their extent of casualties. *Accid. Anal. Prev.* 87, 34–42.

