

## مقایسه عملکرد چهار الگوریتم یادگیری ماشین در مدل سازی شدت تصادفات

امید عبدالحسین پور محجوبیان، دانش آموخته کارشناسی ارشد، گروه مهندسی حمل و نقل، دانشکده مهندسی عمران، دانشگاه علم و صنعت ایران، تهران، ایران

علی توکلی کاشانی (مسئول مکاتبات)، استادیار، گروه مهندسی حمل و نقل، دانشکده مهندسی عمران، دانشگاه علم و صنعت ایران، تهران، ایران

**E-mail: alitavakoli@iust.ac.ir**

پذیرش: ۱۴۰۲/۰۷/۰۸

دریافت: ۱۴۰۲/۰۶/۱۳

### چکیده

تصادفات جاده ای خسارات اجتماعی و اقتصادی زیادی را به جوامع تحمیل می کنند. از این حیث مطالعات ایمنی ترافیک در دهه های اخیر مورد توجه قرار گرفته است. در این راستا مطالعات مختلفی در راستای مدل سازی شدت ترافیک انجام شده که اکثریت این مدل ها از روش های آماری استفاده کرده اند و استفاده از روش های مبتنی یادگیری ماشین در این زمینه محدود بوده است. روش های آماری فرضیات مشخصی در رابطه با داده ها و متغیرها دارند که در صورت تخطی مساله از آنها، استنباط آماری تحت تاثیر قرار خواهد گرفت. این در حالی است که روش های مبتنی بر یادگیری ماشین این فرضیات را نداشته و از این حیث نسبت به روش های آماری برتری دارند. طیف وسیعی از روش های یادگیری ماشین می توانند در امر مدل سازی شدت تصادفات مورد استفاده قرار گیرند، از این حیث پژوهش پیش رو به بررسی عملکرد چهار مدل مبتنی بر یادگیری ماشین شامل روش درخت تصمیم، شبکه عصبی مصنوعی، ماشین بردار پشتیبان و نزدیک ترین همسایگی پرداخته است. نتایج نشان دادند عملکرد درخت تصمیم هم از حیث دقت مدل و هم از حیث دسته بندی تصادفات جرحی/فوتی بهتر بوده است. همچنین پژوهش حاضر با استفاده از روش SHAP به بررسی تاثیر متغیرهای مختلف پرداخته. نتایج نشان دادند متغیرهای سن راننده مقصر، روشنایی راه و سرعت مجاز در تمامی مدل ها تاثیر گذاری معناداری داشته اند.

واژه های کلیدی: مدل سازی شدت تصادفات، یادگیری عمیق، شبکه عصبی پیچشی بیزی، نظم دهی حذف تصادفی تغییراتی

## ۱. مقدمه

شامل مدل های مدل شبکه های عصبی مصنوعی، ماشین بردار پشتیبان، نزدیکترین همسایگی و درخت تصمیم، این پژوهش سعی در ارائه تحلیل مقایسه ای بین عملکرد و نتایج حاصل از این مدل ها را دارد. یافته های حاصل از این تحقیق می تواند بر مطالعات آینده در حوزه ایمنی راه های جاده ای و پیش بینی شدت تصادفات تأثیر قابل توجهی داشته باشد. با روشن شدن فواید نسبی انواع الگوریتم های یادگیری ماشین، پژوهش پیش رو در جهت بهبود مطالعات ایمنی ترافیک قرار گرفته است.

در پژوهش پیش رو اهداف زیر تعریف شده اند:

۱. تحلیل مقایسه ای بین عملکرد مدل های شبکه های عصبی

مصنوعی، ماشین بردار پشتیبان، نزدیکترین همسایگی و روش

درخت تصمیم در مدل سازی شدت تصادفات

۲. مقایسه نتایج حاصل از تحلیل حساسیت متغیر ها برای

هرکدام از الگوریتم های یادگیری ماشین. این مقایسه این

امکان را می دهد تا درک بهتری نسبت به تفسیر هر یک از این

مدل ها نسبت به متغیر های توضیحی ارائه شود.

در طیف وسیعی از مطالعاتی که عملکرد الگوریتم های یادگیری

ماشین در مدل سازی شدت تصادفات را بررسی کرده اند، مقایسه

بین تعداد محدودی از این روش ها انجام گرفته است. در نتیجه

پژوهش حاضر با مقایسه پراستفاده ترین روش های یادگیری

ماشین در مطالعات ایمنی ترافیک سعی در ارائه فهم بهتری از

عملکرد هر یک دارد.

## ۲. ادبیات پژوهش

مرور ادبیات در پژوهش پیش رو با تمرکز بر مدل سازی شدت

تصادفات انجام شده است. تعداد قابل توجهی از مطالعات ایمنی

ترافیک در رابطه با مدل سازی شدت تصادفات انجام شده اند.

اکثریت این مطالعات از روش های آماری بهره گرفته اند. انواع

روش های آماری مورد استفاده شامل مدل های لجیت و

پروبییت دوگانه [Do, Vu et al. 2019, Fanyu, Sze et al. 2021, Zubaidi, Obaid et al. 2021]

و چند گانه [Vajari, Aghabayk et al. 2020, Park and Park]

در سال های اخیر نقش مطالعات ایمنی ترافیک به عنوان یکی از اصلی ترین ارکان مطالعات حمل و نقل به شدت مورد توجه قرار گرفته است. تصادفات جاده های نه تنها باعث تلفات جانی می شوند، بلکه خساراتی اقتصادی زیادی را نیز به جامعه تحمیل می کنند. در این بین پیش بینی دقیق شدت تصادفات نقش به سزایی در رفع زیان های ناشی از تصادفات دارد. با پیشرفت یادگیری ماشین، محققان سعی در استفاده از این روش ها در مدل سازی شدت تصادفات دارند. این مدل ها هم توان استخراج اطلاعات در رابطه با ارتباط بین شدت تصادف و متغیر های تأثیر گذار دارند و هم می توانند پیش بینی های دقیقی در این رابطه ارائه کنند.

در دهه های گذشته، روش های متعددی برای مدل سازی شدت

تصادفات ارائه شده اند. اما مدل سازی های آماری در اکثر این

مطالعات مورد توجه قرار گرفته اند [Wen, Xie et al. 2021].

علی رغم اینکه این روش ها دارای مشکلاتی هستند که

امر مدل سازی را تحت تأثیر قرار می دهند. برخی از این

مشکلات در مطالعات [Silva, Andrade et al. 2020, Tang, Zheng et al. 2020]

بررسی شده اند. برخی از این

ایرادات عبارتند از مفروضات راجع به فرم خطی توابع مدل

سازی و همچنین مفروضاتی در رابطه با توزیع داده. در صورتی

که این مفروضات صحیح نباشند استنباط آماری تحت تأثیر قرار

خواهد گرفت. همچنین مطالعاتی نیز در رابطه با مزیت های

روش های مبتنی بر یادگیری ماشین انجام شده. این مطالعات

بیان می کنند که روش های یادگیری ماشین به علت آنکه این

پیش فرض ها را ندارند، انعطاف پذیر تر هستند و می توانند

عملکرد بهتری نسبت به مدل های آماری داشته باشند [Tang,

Liang et al. 2019].

مطالعه پیش رو در پاسخ به نیاز به بررسی و مقایسه عملکرد

روش های یادگیری ماشین در مدل سازی شدت تصادفات انجام

شده است. با بررسی عملکرد چهار الگوریتم یادگیری ماشین که


در مدل سازی شدت تصادفات بسیار امیدوار کننده بوده، استفاده از این شبکه ها بسیار محدود بوده است [ Sameen and Pradhan 2017, Zeng, Gu et al. 2019]. شبکه های عصبی امکان مدل سازی روابط غیر خطی پیچیده را فراهم می کنند و از این جهت می توانند مورد توجه باشند.

الگوریتم ماشین بردار پشتیبان نیز در مطالعات مدل سازی شدت تصادفات مشاهده مورد استفاده قرار گرفته است. در مقایسه با الگوریتم های شبکه عصبی مصنوعی، ماشین بردار پشتیبان دارای زمینه ریاضیات مستحکم تری است و همچنین از حیث پیچیدگی محاسباتی نیز بر این شبکه ها مزیت دارد. در مدل سازی شدت تصادفات ماشین بردار پشتیبان با هسته گاوسی شعاعی بیشتر مورد استفاده قرار گرفته است [ Li, Liu et al. 2012, Yu and Abdel-Aty 2014, Chen, Zhang et al. 2016].

در مطالعه [Li, Liu et al. 2012] این الگوریتم برای مدل سازی پنج سطحی تصادف مورد استفاده قرار گرفت، اما به علت تولید پیش بینی های نامتعادل، پژوهش گران پنج سطح را به دو سطح کاهش دادند. نتایج حاصل نشان داد که عملکرد ماشین بردار پشتیبان به نسبت روش پروبیت بهتر بوده است. همچنین در مطالعه ای دیگر [Chen, Zhang et al. 2016] پژوهشگران با شناسایی عوامل مهم تاثیر گذار بر شدت تصادف توسط درخت تصمیم، متغیر های با اهمیت بیشتر را شناسایی کرده و با استفاده از ماشین بردار پشتیبان به پیش بینی شدت تصادف پرداختند. نتایج نشان داد عملکرد هسته چند جمله ای به نسبت هسته گاوسی شعاعی بهتر بوده است. در مطالعه [Gu, Li et al. 2018] عملکرد ماشین بردار پشتیبان توسط الگوریتم ش از دحام ذرات و الگوریتم بهینه سازی ژنتیکی بهبود یافت و نتیجتاً این الگوریتم به نسبت شبکه عصبی مصنوعی در مدل سازی شدت تصادفات به دقت بالاتری رسید. همچنین ایراداتی نیز در رابطه با این الگوریتم مطرح شده است، این ایرادات به حساسیت عملکرد ماشین بردار پشتیبان بر انتخاب هسته و عدم ارایه روشی

2022] اشاره کرد. برای بررسی اثرات ترتیبی در شدت تصادفات، ناهمگونی مشاهده نشده، همبستگی بین تصادفات و درونزایی روش های پیشرفته آماری و اقتصاد سنجی از جمله قابلیت پیش بینی مدل در این مطالعات به عنوان شاخصی برای مقایسه در نظر گرفته شده و هدف اصلی این مطالعات نبوده است. در برخی دیگر از مطالعات، روش های یادگیری ماشین استفاده شده است. به طور مثال شبکه های عصبی مصنوعی عبدالوهاب و عبدالعاطی در مطالعه ای با استفاده از شبکه پرسپترون چند لایه شدت تصادفات را مدل سازی کردند. نتایج نشان داد که عملکرد مدل مبتنی بر شبکه عصبی به نسبت روش آماری مدل لوجیت ترتیبی بهتر بوده است [ Abdelwahab and Abdel-Aty 2001]. همچنین در سایر مطالعاتی که از شبکه های پرسپترون چند لایه استفاده کرده اند، نتایج مشابهی گزارش شده است. دلتن و همکاران با استفاده از چند شبکه پرسپترون چند لایه به شناسایی عوامل موثر در شدت تصادفات پرداختند [Delen, Sharda et al. 2006]. همچنین چیمبا و ساندو در مقایسه عملکرد مدل پرسپترون چند لایه با روش های آماری لوجیت و پروبیت ترتیبی دقت بالاتری را برای مدل های شبکه عصبی گزارش کردند [Chimba and Sando 2009]. همچنین در مطالعات [Zeng and Huang 2014, Rahim and Hassan 2021] نیز دقت عملکرد مدل های مبتنی بر شبکه های عصبی بالاتر از روش های آماری گزارش شده اند. شبکه های عصبی عمیق نیز در برخی مطالعات در مدل سازی شدت تصادفات مورد استفاده قرار گرفته اند [Rezapour, Nazneen et al. 2020, Rahim and Hassan 2021]. برخی از این شبکه های شامل شبکه های عصبی پیچشی [Yu, Li et al. 2021, Haghshenas, Guido et al. 2023] و شبکه های عصبی بازگشتی [Rezapour, Nazneen et al. 2020, Zuo, Qian et al. 2023] و همچنین شبکه های پیچشی-بازگشتی [Li, Abdel-Aty et al. 2020, Hu, Zhou et al. 2022] می باشند. اگرچه عملکرد این شبکه ها

شبکه های عصبی مصنوعی پرسپترون چند لایه از مورد استفاده ترین انواع شبکه های مصنوعی هستند. همانطور که مشخص است این شبکه ها بر مبنای پرسپترون بنا شده. پرسپترون اصولاً از یک ورودی و یک خروجی تشکیل شده، و در شبکه های عصبی، تعداد بالایی از این پرسپترون ها در تعاملات موازی با یکدیگر هستند. تصویر یک، نمونه از یک شبکه عصبی با یک لایه ورودی، یک لایه خروجی و همچنین دو لایه پنهان را نشان می دهد.



شکل ۱. شبکه عصبی چند لایه

دقت شود که شبکه های عصبی از حداقل یک لایه تشکیل شده اند و تمامی نورون ها در یک لایه با وزن  $w_{ij}$  به نورون های لایه بعدی متصل هستند.

برای نورون  $j$  در یک لایه، مقدار فعال سازی داریم:

$$z_j = \sum_{i=1}^n w_{ij} a_i + b_j \quad (1)$$

که در آن  $n$  تعداد نورون های لایه قبلی،  $w_{ij}$  وزن متناظر بین نورون  $i$  در لایه قبلی و نورون مد نظر و همچنین  $b_j$  مقدار بایاس برای نورون مد نظر است. همچنین تابع فعال ساز برای این مقدار اعمال می شود:

$$a_j = f(z_j) \quad (2)$$

توابع متفاوتی به عنوان توابع فعال ساز معرفی شده اند. برخی از این توابع در شکل دو نشان داده شده. همچنین آموزش در این مدل، توسط الگوریتم پس انتشار و کمینه کردن یک تابع هزینه با توجه به خروجی مدل و مشاهدات واقعی و با استفاده از

برای مشخص کردن اهمیت متغیر ها اشاره کرده اند [Li, Lord et al. 2008].


الگوریتم درخت تصمیم نیز در مطالعات متعددی مورد استفاده قرار گرفته است. این الگوریتم، یکی از ابتدایی ترین روش های یادگیری ماشین در مدل سازس شدت تصادفات است [Sohn and Shin 2001, Sohn and Lee 2003, Chong, Chang and Abraham et al. 2005]. به طور مثال [Chien 2013] با استفاده از درخت تصمیم عوامل موثر بر شدت تصادفات را شناسایی کرد. همچنین این مطالعه نشان داد که عملکرد درخت تصمیم به نسبت مدل لجوجیت بهتر بوده است. همچنین در مطالعه [Pakgozar, Tabrizi et al. 2011] نشان داده شد که عملکرد الگوریتم درخت تصمیم برای سطوح مختلف ترافیکی متفاوت است که علت را باید در نامتعادل بودن مشاهدات سطوح مختلف شدت جست. در مطالعه [Kashani and Mohaymany 2011] پژوهشگران برای بطرف سازی این مساله، شدت تصادف سه سطحی را به دو سطح کاهش دادند که نتیجه عملکرد بهتر مدل بوده است.

روش دیگر مورد استفاده، روش نزدیک ترین همسایگی بوده است. این روش بر اساس نزدیکی بین مشاهدات عمل می کند. به اینگونه که دسته بندی هر مشاهده، میانگین دسته نزدیک ترین مشاهدات است. این روش در مطالعات مختلفی با سایر روش های یادگیری ماشین مقایسه شده است. به طور مثال [Iranitalab and Khattak 2017] نشان داد که عملکرد این روش به نسبت درخت تصمیم در مدل سازی شدت ترافیک ضعیف تر بوده است. از ایرادات این روش یکی حساسیت به پارامتر تعداد همسایگان است و دیگر حساسیت این روش به داده ای پرت در دسته بندی است، به این معنی که در صورتی که تعداد متغیر های پرت در داده های ورودی زیاد باشد، احتمال تولید نتایج اریب توسط این روش بالاست.

### ۳. مبانی نظری پژوهش

#### ۳-۱ شبکه عصبی مصنوعی

الگوریتم های مبتنی بر گرادینان کاهش می شود. ابتدا مشتق تابع هزینه با توجه به تمامی وزن های شبکه محاسبه می شود.



شکل ۲. انواع توابع فعالساز

از نزدیکترین نقاط هر دسته یا به اصطلاح حاشیه صورت می گیرد. تصویر ۳ نشان دهنده عملکرد این الگوریتم است. همچنین برای نقاطی که به صورت خطی قابل جدا سازی نیستند، این الگوریتم نقاط را در فضایی با ابعاد بالاتر جاسازی می کند. تصویر چهار نشان دهنده این مساله است. برای افزایش کارایی و کاهش حجم محاسبات به علت ابعاد بالای مساله، از ترفند هسته بهره گیری می شود. در مطالعات مختلف، هسته های متفاوتی برای این امر پیشنهاد شده که برخی از آنها هسته شعاعی گاوسی و هسته چند جمله ای هستند.

رابطه ۳ نشان دهنده این موضع است:

$$\frac{\partial Loss}{\partial w_{ij}} = \frac{\partial Loss}{\partial a_j} \cdot \frac{\partial a_j}{\partial z_j} \cdot \frac{\partial z_j}{\partial w_{ij}} \quad (3)$$

و سپس بروز رسانی وزن ها طبق رابطه زیر انجام می شود:

$$w_{ij} \leftarrow w_{ij} - \eta \cdot \frac{\partial Loss}{\partial w_{ij}} \quad (4)$$

همچنین این عملیات برای مقادیر بایاس هر نورون نیز انجام می شود. برای روابط این قسمت از [ Delen, Sharda et al. 2006 ] استفاده شده است.

### ۳-۲ ماشین بردار پشتیبان

ماشین بردار پشتیبان یک الگوریتم دسته بندی و رگرسیون است. ایده اصلی ماشین بردار پشتیبان یافتن ابر صفحه ای است که به بهترین نحو ممکن نقاطی که به دسته های مختلف متعلق هستند را جدا کند. این عمل توسط بیشینه سازی فاصله این ابر صفحه

همسایگی  $k$  و دیگری معیار سنجش فاصله بین نقاط. مقدار  $k$  عموماً با آزمون خطای عملیات اعتبار سنجی انجام می‌شود. همچنین در این پژوهش از فاصله اقلیدسی برای اندازه‌گیری فاصله بین نقاط استفاده شده است. برای فاصله بین دو نقطه  $i$  و  $j$  داریم:

$$d_{ij} = \sum_{k=1}^p (x_{ik} - x_{jk})^2 \quad (5)$$

که در آن  $p$  تعداد ویژگی‌های هر نقطه است.

### ۳-۴ نزدیک‌ترین همسایگی


روش درخت تصمیم هم برای مسایل دسته‌بندی و هم برای مسایل رگرسیون مورد استفاده قرار گرفته است. این روش به صورت بازگشتی به جدا سازی داده‌ها می‌پردازد. به این صورت که ابتدا داده‌های آموزش به نودهای ورودی داده می‌شوند. سپس نود ورودی به دو نود تقسیم شده و هر یک از این نودها خود به صورت بازگشتی به نودهای دیگر تقسیم می‌شوند. تقسیم شدن این نودها با معیارهای مختلفی صورت می‌گیرد که هدفشان، بیشینه‌سازی همگنی داده‌ها در هر نود است. تقسیم بندی تا جایی ادامه پیدا می‌کند که تقسیم بندی‌های آتی ممکن نباشد. در آخر هر نود، نشان دهنده یک سطح از شدت تصادفات است. دو نمونه از شاخص‌های تقسیم درخت‌های تصمیم‌گیری معیار ناخالصی جینی و آنتروپی هستند، که پژوهش‌پیش‌رو از معیار آنتروپی استفاده کرده است.

$$Entropy(D) = - \sum_{i=1}^c p_i \log(p_i) \quad (6)$$



که در آن  $c$  تعداد کلاس‌ها،  $D$  داده‌های درون نود و  $p_i$  نسبت داده‌های متعلق به کلاس  $i$  در آن نود است.

### ۳-۵ داده‌های مورد استفاده

در این پژوهش داده‌های تصادفات جاده‌های دوخطه دوطرفه جدا نشده بین سال‌های ۹۴ تا ۹۸، در کشور ایران استفاده شد. این داده‌ها از گزارشات تصادفات پلیس استخراج شده است. همچنین سایر اطلاعات از سازمان راهداری و همچنین با استفاده



شکل ۳. ماشین بردار پشتیبان



شکل ۴. جداسازی نقاط در ابعاد بالاتر

### ۳-۳ نزدیک‌ترین همسایگی

روش نزدیک‌ترین همسایگی، هر نقطه را با توجه به نزدیک‌ترین همسایگانش دسته‌بندی می‌کند. به این معنی که دسته هر نقطه در داده‌های تست، رای اکثریت نزدیک‌ترین نقاط همسایه نقطه مورد نظر است. برای پیاده‌سازی و استفاده از این الگوریتم، دو ابرپارامتر می‌بایست مشخص شوند. یکی تعداد نقاط

متقابل انتخاب شد. همچنین در رابطه با شبکه عصبی مصنوعی، برای تعداد نرون ها برای لایه پنهان مقادیر ۱ تا ۳۲ مورد بررسی قرار گرفت، در نهایت مقدار ۲۴ برای این ابر پارامتر انتخاب شد. شخص های اندازه گیری عملکرد مدل با توجه به مطالعات گذشته در ادامه آورده شده اند.

$$Accuracy = \frac{TP + TN}{P + N} \quad (7)$$

$$Precision = \frac{TP}{TP + FP} \quad (8)$$

$$Recall = \frac{TP}{TP + FN} \quad (9)$$

$$F1\ Score = \frac{2TP}{2TP + FP + FN} \quad (10)$$

در مطالعات مختلف، شاخص دقت (رابطه ۷) اصلی ترین معیار سنجش عملکرد مدل است. همانطور که از رابطه پیداست، این شاخص برای داده های تست، نشان دهنده آن تعداد از پیش بینی هایی است که با مقادیر واقعی آن مشاهده یکسان بوده اند. همچنین رابطه ۸، شاخص precision را نشان می دهد. در یک مساله طبقه بندی دوسطحه، این شاخص، نسبت پیش بینی درست مدل برای داده های کلاس مثبت، که در این پژوهش تصادفات فوتی است را نشان می دهد. اهمیت این شاخص از آنجایی است که پیش بینی درست در این دسته بسیار حایز اهمیت است. معیار Recall در رابطه هشت نیز در ادبیات ایمنی ترافیک بسیار مورد استفاده قرار گرفته است. این معیار، نسبت واقعی داده های کلاس مثبت به کل داده هایی که در این کلاس دسته بندی شده اند را نشان می دهد. به این معنی که در بین تمامی داده های کلاس مثبت، چه تعدادی توسط مدل به درستی پیش بینی شده اند. همانطور که اشاره شد، به علت اهمیت بالای تصادفات جرحی و فوتی، این شاخص نیز از اهمیت بالایی برخوردار است. اهمیت این دو شاخص در مسایلی که نامتعادلی در دسته ها موجود است مشخص می شود. در این مسایل، با تلفیق این دو شاخص معیار F1 طبق رابطه ۱۰ ارایه می شود که به نوعی ترکیبی از دو معیار پیشین است. مقادیر بالاتر عملکرد بهتر مدل را نشان می دهد. نتایج حاصل از هر یک از این مدل ها

از سیستم های اطلاعات مکانی به دست آمده اند. در این داده ها متغیر های مربوط به ویژگی های راننده در کنار مجموعه ای از متغیر های که در مطالعات پیشین موثر تشخیص داده شده اند قرار گرفته است. متغیر های موجود در این داده در جدول یک گردآوری شده اند. شدت تصادفات در سه سطح خسارتی، جرحی و فوتی ارایه شده است. با توجه به تعداد کم مشاهدات تصادفات فوتی و جرحی به نسبت تصادفات خسارتی، تصادفات این دو دسته با هم جمع شدند و یک سطح در نظر گرفته شده اند. اطلاعات راجع به این متغیر ها در جدول ۱ گردآوری شده اند. ابتدا عملیات پیش پرداز بر روی این داده ها انجام شد. داده هایی که مقادیر نامشخص و ثبت نشده داشتند حذف شدند. پس از حذف داده های ثبت نشده، تعداد ۱۱۲۰ داده باقی ماند. با توجه به مطالعات پیشین، داده ها به دو مجموعه آموزش و تست با نسبت ۸۰:۲۰ تقسیم شدند. در ادامه بر روی متغیر های پیوسته عملیات استاندارد سازی هم برای داده ای آموزش و هم برای داده های تست و به صورت جداگانه انجام شد.

#### ۴. تحلیل داده ها


در این قسمت نتایج حاصل از مقایسه عملکرد مدل ها مورد بررسی قرار گرفته است. برای هر مدل ابتدا با استفاده از عملیات های اعتبار سنجی متقابل بهترین ابر پارامتر ها انتخاب شد. پس از مقایسه عملکرد مدل ها، نتایج بدست آمده از تحلیل حساسیت هر یک از مدل ها مورد بررسی قرار گرفت.

##### ۴-۱ برآورد مدل

در رابطه با مدل نزدیک ترین همسایگی برای پارامتر تعداد همسایگان از اعتبار سنجی متقابل استفاده شد. تصویر ۵ دقت مدل در اعتبار سنجی به ازای مقادیر مختلف پارامتر تعداد همسایگی را نشان می دهد. در آزمایشات اعتبار سنجی مقدار ۲۱ برای این پارامتر انتخاب شد. تصویر ۵، دقت مدل نزدیک ترین همسایگی برای مقادیر مختلف این پارامتر را نشان می دهد. برای مدل ماشین بردار پشتیبان همچنین، برای هسته شعاعی مقادیر  $c = 4$  و  $gamma = 32$  طی عملیات اعتبار سنجی

عملکرد مدل درخت تصمیم به نسبت سایر مدل ها بهتر بوده است. مقدار این شاخص در مدل درخت تصمیم برابر با ۰/۶۵ محاسبه شد که این مقدار در ماشین بردار پشتیبان و شبکه عصبی برابر با ۰/۶۴ و در مدل نزدیک ترین همسایگی کمترین مقدار خود برابر با ۰/۶۱ است. همچنین مشاهده در رابطه با معیار recall نیز پیداست. عملکرد درخت تصمیم به نسبت سایر مدل ها بالاتر است.

در جدول ۲ گردآوری شده است. همچنین ماتریس آشفتگی برای این مدل ها در جدول ۳ آمده است. در رابطه با معیار دقت، مدل درخت تصمیم گیری با ۶۷ درصد دقت بر روی داده های تست، بهترین عملکرد را داشته است. همچنین مدل شبکه عصبی مصنوعی با دقت ۶۶ درصد در رتبه بعدی است و به دنبال آن ماشین بردار پشتیبان و در انتها نیز الگوریتم نزدیک ترین همسایگی هستند. همچنین در رابطه با شاخص precision



شکل ۵. عملکرد الگوریتم نزدیک ترین همسایگی

جدول ۱. توصیف متغیرها

کد متغیر	نام متغیر	توصیف متغیر
Y	شدت تصادف	۰=خسارتی ۱=جرحی فوتی
X <sub>1</sub>	سن راننده مقصر	
X <sub>2</sub>	جنسیت راننده مقصر	۰=مرد ۱=زن
X <sub>3</sub>	تحصیلات راننده مقصر	۰=بیسواد ۱=ابتدایی ۲=دیپلم ۳=لیسانس و بالاتر
X <sub>4</sub>	روشنایی	۰=روز ۱=شب
X <sub>5</sub>	هوا	۰=صاف ۱=بری/بارانی ۲=برفی
X <sub>6</sub>	نوع منطقه	۰=هموار ۱=کوهستانی
X <sub>7</sub>	شرایط سطح راه	۰=تر ۱=خشک
X <sub>8</sub>	هندسه محل	۰=پیچ/سربالایی سرپایینی ۱=پیچ مسطح ۲=مستقیم سربالایی/سرپایینی ۳=مستقیم مسطح
X <sub>9</sub>	نوع شانه راه	۰=شانه آسفالت ۱=شانه خاکی ۲=شانه ندارد
X <sub>10</sub>	طول راه	
X <sub>11</sub>	عرض راه	

مقایسه عملکرد چهار الگوریتم یادگیری ماشین در مدل سازی شدت تصادفات

کد متغیر	نام متغیر	توصیف متغیر
$X_{12}$	سرعت مجاز	
$X_{13}$	ADT	اطلاعات برداشت شده از سازمان راه داری
$X_{14}$	HVP	نسبت تردد وسایل نقلیه سنگین به کل تردد سالانه
$X_{15}$	تعداد رمپ	
$X_{16}$	TRD	نسبت تعداد دسترسی های هر راه در دوطرف به کل طول راه

جدول ۲. مقایسه عملکرد مدل ها

	دقت		Precision		Recall		F1 Score	
	آموزش	تست	آموزش	تست	آموزش	تست	آموزش	تست
شبکه عصبی	۰/۶۸	۰/۶۶	۰/۶۷	۰/۶۴	۰/۴۸	۰/۴۷	۰/۵۵	۰/۵۴
درخت تصمیم	۰/۶۹	۰/۶۷	۰/۶۶	۰/۶۵	۰/۵۰	۰/۴۸	۰/۵۶	۰/۵۶
ماشین بردار پشتیبان	۰/۶۸	۰/۶۵	۰/۷۰	۰/۶۴	۰/۴۷	۰/۴۵	۰/۵۷	۰/۵۳
نزدیک ترین همسایگی	۰/۸۰	۰/۶۲	۰/۸۴	۰/۶۱	۰/۶۷	۰/۳۴	۰/۷۵	۰/۴۴

جدول ۳. ماتریس آشفتگی مدل ها

	برآورد	
	خسارتی	جراحی / فوتی
شبکه عصبی	۳۸۱۸	۸۷۳
	۱۸۴۶	۱۶۸۷
درخت تصمیم	۳۷۶۰	۹۳۱
	۱۷۵۷	۱۷۷۶
ماشین بردار پشتیبان	۳۷۸۴	۹۰۷
	۱۹۱۸	۱۶۱۵
نزدیک ترین همسایگی	۳۹۲۵	۷۶۶
	۲۳۱۵	۱۲۱۸

مشاهداتی در رابطه با این شاخص نیز صدق می کند، به این صورت که مقدار این شاخص در مدل درخت تصمیم به نسبت سایر روش ها بیشتر بوده و کمترین مقدار خود را در مدل نزدیک ترین همسایگی دارد.

مقدار شاخص recall در درخت تصمیم برابر ۰/۴۸، در شبکه عصبی برابر با ۰/۴۷، در ماشین بردار پشتیبان برابر با ۰/۴۵ و در نزدیک ترین همسایگی برابر با ۰/۳۴ است. از آنجایی که شاخص F1 نیز میانگین هارمونیک این دو شاخص است، چنین

با بررسی ضرایب متغیرها و معنی داری آنها، تاثیر هر یک بر نتایج مدل را توضیح دهند. اما از آنجا که روش های مبتنی بر یادگیری ماشین بدون پیش فرضها و دانسته های قبلی عمل می کنند، در ارایه تاثیر هر متغیر اشکالاتی دارند. اگرچه که برخی از این روشها مانند روش درخت تصمیم، امکاناتی برای تحلیل حساسیت این متغیرها ارایه می کنند، برای یکپارچه سازی، پژوهش پیش رو از روش SHAP برای تحلیل حساسیت استفاده کرده است. این روش در مطالعات زیادی در زمینه حمل و نقل مورد استفاده قرار گرفته است [Asadi, Khattak et al. 2023, Li, Yang et al. 2023, Zhao, Qi et al. 2023]. این روش بر مبنای نظریه بازی طراحی شده است، به این صورت که هر متغیر یک بازیگر در بازی پیش بینی وارد می شود. برای هر ورودی در مدل، این روش نتیجه پیش بینی مدل را برای زیر تمام مجموعه های توانی مجموعه متغیرها محاسبه می کند. این روش هم برای سطوح محلی و هم برای سطوح کلی در مدل سازی به کار می رود. بعد از محاسبه مقادیر SHAP برای مشاهدات مختلف و محاسبه میانگین آنها، میزان تاثیر متغیرها توسط مقدار SHAP محاسبه می شود. هر چه مقدار SHAP بیشتر باشد، متغیر تاثیر گذار تر است. بدین منظور در تمامی مدل ها، بعد از محاسبه مقدار SHAP، این مقادیر نرمالایز شده اند و در انتها، متغیرهایی که مقدار بالای ۰/۵ دارند به عنوان متغیر معنی دار مشخص شده اند [Tang, Zheng et al. 2020]. برای بررسی تاثیر گذاری متغیرها در جدول شماره ۴، متغیرهای معنادار هر مدل گردآوری شده اند

نتایج نشان می دهند که سن راننده مقصر، در تمامی مدل ها به عنوان عامل معنادار مشخص شده است. نتایج نشان دادند که با کاهش سن راننده مقصر، احتمال تصادفات فوتی افزایش می یابد. علت این امر را می توان مسایلی مانند مهارت، ریسک پذیری و تبعیت از قوانین راهنمایی رانندگی جست [Abdel-Aty, Chen et al. 1998, Hanrahan, Layde et al. 2009].

برای بحث بیشتر در رابطه با این شاخصها می بایست به جدول دو رجوع کرد. از بین ۳۵۵۱ تصادف جرحی/فوتی، روش نزدیک ترین همسایگی تنها ۱۲۱۸ تصادف را به درستی پیش بینی کردی و تعداد ۲۳۱۵ تصادف به عنوان تصادف خسارتی دسته بندی شده. این امر به علت اهمیت بالای تصادفات جرحی/فوتی نامطلوب است. در عوض روش درخت تصمیم در رابطه با دسته بندی درست تصادفات جرحی/فوتی بهترین عملکرد را دارد. این روش تعداد ۱۷۷۶ تصادف جرحی/فوتی را به درستی پیش بینی کرده است.

علت عملکرد بهتر روش درخت تصمیم را می بایست در چند مساله جست. ابتدا تعداد بالای متغیرهای گسسته است. روش درخت تصمیم به علت ساختار کلیش، در مواجهه با این متغیرها عملکرد بهینه ای دارد. همچنین می بایست اشاره کرد که درخت تصمیم تمرکز بر ایجاد قوانین تصمیم گیری مشخصی دارد که می تواند به سادگی به مساله تطبیق شود. به طور کلی می توان گفت که سادگی الگوریتم درخت تصمیم در تصمیم گیری به نسبت روش های شبکه عصبی مصنوعی و ماشین بردار پشتیبان، امکان تطبیق بهتر با داده ها را به این روش داده اند و همان طور که نتایج نشان می دهند، عملکرد این روش در دسته بندی تصادفات جرحی/فوتی بهتر بوده است. این در حالی است که روش ماشین بردار پشتیبان و شبکه عصبی مصنوعی و به خصوص روش نزدیک ترین همسایگی، به تحت تاثیر مشاهده غالب که در این مساله تصادف خسارتی است قرار می گیرند و در نتیجه عملکرد کلی مدل را کاهش می دهند.

#### ۴-۲ تاثیر متغیرها

تمرکز مطالعات پیشین که مبتنی بر بکارگیری روش های یادگیری ماشین در مدل سازی شدت تصادفات بوده اند، بر روی پیش بینی مدل ها بوده است. این در حالی است که فهم درست از تاثیر متغیرها بر روی این پیش بینی از اهمیت بالایی برخوردار است. روش های آماری از آنجا که بر مبنای روابط مشخص و فرم های از پیش تعیین شده ریاضیاتی عمل می کنند، می توانند

است که در شدت تصادفات نقش دارد. نتایج پژوهش پیش رو نشان می دهد که عموماً با افزایش ADT شدت تصادفات کاهش داشته است که علت آنرا می توان در عواملی مانند کاهش سرعت و افزایش تعداد تصادفات از پشت دانست. اگرچه که مطالعات بیشتری در این زمینه می بایست به بررسی علی این رابطه پردازند.

عوامل دیگر که از حیث برخی از مدل ها معنا دار شناخته شده اند شامل، شرایط آب و هوایی، نوع منطقه، نسبت وسایل نقلیه سنگین و هندسه راه هستند. نتایج نشان می دهند که احتمال وقوع تصادفات شدید تر در شرایط آب و هوایی ابری و بارانی بیشتر است. علت می تواند لغزندگی سطح راه و کاهش کنترل رانندگان در اثر آن باشد. همچنین تردد وسایل نقلیه سنگین نیز احتمال وقوع تصادفات شدید تر را افزایش می دهند. در رابطه با متغیر نوع منطقه، نتایج این مطالعه حاکی از آن است که تصادفات در مناطق هموار عموماً شدت بیشتری داشته اند. توضیح آنکه سرعت وسایل نقلیه در این راه ها عموماً بیشتر است و همانطور که پیشتر نیز توضیح داده شد، افزایش سرعت موجب افزایش شدت تصادفات می شود.

همچنین نتایج نشان می دهد که روش های یادگیری ماشین در رابطه با تفسیر و تحلیل اهمیت متغیرها ضعیف دارند. هیچ روش مشخصی برای ارائه چنین تحلیلی در روش های یادگیری ماشین موجود نیست. البته که روش های تحلیل حساسیت مانند روش SHAP توانسته اند تا حد زیادی این مشکل را برطرف کنند.

سرعت مجاز دیگر عاملی است که توسط هر چهار مدل موثر تشخیص داده شده است. نتایج نشان می دهند که با افزایش سرعت مجاز راه، شدت تصادفات افزایش خواهند داشت. عموماً در راه هایی که سرعت مجاز بالاتری دارند، تصادفات فوتی/جرحی به نسبت راه های با سرعت مجاز پایین تر بیشتر دیده می شوند. این نتایج همسو با مطالعاتی نظیر [Wilmot and Khanal 1999, Doecke, Kloeden et al. 2018] نیز گزارش شده اند.

همچنین روشی راه عامل دیگری است که توسط هر ۴ مدل موثر تشخیص داده شده است. مطالعات دیگری نظیر [Barbone, McMahon et al. 1998, Abdel-Aty 2003] نیز چنین مشاعده ای را گزارش کرده اند. روشی نامناسب راه، با کاهش میدان و مسافت دید و همچنین کاهش درک راننده از سرعت، می تواند باعث افزایش شدت تصادفات شود. برای یافتن رابطه علی بین شدت تصادفات و روشی راه به مطالعات بیشتری در این زمینه نیاز است.

سایر عوامل، تنها در تعدادی از مدل ها تاثیر گذار شناخته شده اند. در ادامه به بررسی این عوامل پرداخته شده است. نتایج تحلیل حساسیت نشان می دهد که نداشتن شانه خاکی باعث افزایش شدت تصادفات است [Wahab and Jiang 2019]. نتایج نشان می دهند که شانه آسفالت از شانه خامی در کاهش شدت تصادفات بهتر عمل کرده است. در کنار شانه خاکی، عرض راه نیز عاملی موثر در شدت تصادفات است. جاده های باریک تر عموماً شاهد تصادفاتی با سطح بالاتر هستند. ADT شاخص دیگری

جدول ۴. ماتریس آشفتگی مدل ها

متغیر	
شبکه عصبی	سن راننده مقصر، روشنایی راه، سرعت مجاز، عرض راه، هندسه راه، آب و هوا، ADT
درخت تصمیم	سرعت مجاز، روشنایی راه، سن راننده مقصر، TRD، عرض راه، شانه خاکی، ADT، نوع منطقه
ماشین بردار پشتیبان	سن راننده مقصر، سرعت مجاز، هندسه راه، روشنایی راه، شانه خاکی، عرض راه، نسبت وسایل نقلیه سنگین
نزدیک ترین همسایگی	سن راننده مقصر، سرعت مجاز، نوع سطح راه، نوع منطقه، روشنایی راه، شرایط آب و هوایی

۵. نتیجه گیری و پیشنهادات

طبقه بندی مورد بررسی قرار گرفت که درخت تصمیم با دقت ۶۷ درصد به نسبت سایر مدل ها عملکرد بهتری داشته است. همچنین در رابطه با معیار های دیگر نیز عملکرد این مدل بهتر است. برای معیار precision درخت تصمیم مقدار ۰/۶۶، برای recall مقدار ۰/۴۸ و برای F1 score مقدار ۰/۵۶ ثبت شد. در رده بعدی به ترتیب مدل شبکه عصبی مصنوعی، ماشین بردار پشتیبان و در آخر الگوریتم نزدیک ترین همسایگی قرار گرفتند. همچنین در رابطه با دسته بندی تصادفات جرحی/فوتی بحث شد. نتایج حاصل از ماتریس آشفتگی برای هر مدل نشان داد که روش درخت تصمیم از بین ۳۵۵۱ تصادف جرحی/فوتی، تعداد ۱۷۷۶ تصادف به درستی دسته بندی شدند، که این مقدار به نسبت سایر روش ها عملکرد بهتری را نشان می دهد. این عملکرد بهتر به علت اهمیت بالای تصادفات جرحی/فوتی می تواند اهمیت زیادی داشته باشد. همچنین بحث شد که عملکرد بهتر روش درخت تصمیم می تواند چند دلیل داشته باشد:

پژوهش پیش رو، عملکرد چهار الگوریتم یادگیری ماشین در مدل سازی سدت تصادفات را بررسی کرده است. این چهار روش شامل روش درخت تصمیم، روش نزدیک ترین همسایگی، شبکه عصبی مصنوعی و ماشین بردار پشتیبان هستند. همچنین عملکرد هر یک از این روش ها در بررسی تاثیر متغیر ها مورد بررسی قرار گرفته است. داده های مورد استفاده، تصادفات جاده های دوخطه دو طرفه جدا نشده کشور ایران بین سال های ۱۳۹۴ تا ۱۳۹۸ هستند. بعد از انجام پیش پردازش بر روی داده ها و با حذف داده هایی با متغیر های ثبت نشده، ۸۰ درصد داده ها برای آموزش و ۲۰ درصد آنها برای تست مورد استفاده قرار گرفتند. از ۸۰ درصد داده های آموزش، ۲۰ درصد نیز برای اعتبار سنجی در نظر گرفته شدند که توسط آنها ابر پارامتر های مربوط به هر مدل بهینه سازی شد. سپس با استفاده از این داده ها، عملکرد چهار مدل مورد بررسی قرار گرفت. این مقایسه نه تنها از حیث دقت پیش بینی مدل ها، بلکه از حیث شاخص های دیگری صورت پذیرفت، که این شاخص ها شامل precision, recall و F1 score هستند. اهمیت این شاخص ها به علت تفاوت معنا دار در تعداد مشاهدات در دو دسته شدت تصادفات است. از آنجایی که تصادفات خسارتی حجم زیادی از مشاهدات را تشکیل می دهند، این شاخص ها در بررسی عملکرد مدل در رابطه با تصادفات فوتی/جرحی مورد استفاده قرار گرفته اند.

نتایج نشان دادند که عملکرد مدل درخت تصمیم، در مدل سازی شدت تصادفات به نسبت سایر مدل ها بهتر بوده است. ابتدا دقت

۱. اول آنکه درخت تصمیم به علت ساختارش، اساسا متغیر های گسسته را بهتر پشتیبانی می کند. با توجه به اینکه تعداد بالایی از متغیر های داده های تصادفات به صورت متغیر های گسسته هستند، این امر می تواند حائز اهمیت باشد.
۲. همچنین بحث شد که الگوریتم درخت تصمیم نسبت به روش های شبکه عصبی مصنوعی و ماشین بردار پشتیبان منعطف تر است و با سادگی بیشتری می تواند قوانین تصمیم گیری ایجاد کند. این سادگی و انعطاف پذیری در دسته بندی

عصبی مصنوعی می تواند کارآمد تر باشد. همچنین این روش می تواند تحلیل مناسبی از اهمیت متغیر ها ارایه کند.

در نتیجه پژوهش پیش رو، پیشنهاداتی برای مطالعات آتی ارایه کرده است:

۱. با توجه به عملکرد مدل درخت تصمیم، استفاده از الگوریتم درخت تصادفی می تواند نتایج قابل قبولی را به همراه داشته باشد.

۲. استفاده از روش های ایجاد نمونه مصنوعی مانند SMOTE می تواند در مدل سازی بهتر سطوح با مشاهدات کمتر، عملکرد مدل ها را افزایش دهد.

۳. با توجه به مشکلات روش های یادگیری ماشین در تحلیل اهمیت متغیر ها، روش های آماری می توانند مورد استفاده قرار گیرند. اما نیاز است که در رابطه با عملکرد این روش ها و مقایسه آنها با روش های یادگیری ماشین، مطالعاتی انجام شود.

۴. انواع روش های مختلفی برای تحلیلی حساسیت برای مدل های مبتنی بر یادگیری ماشین ارایه شده اند. استفاده از اینها در فهم بهتر اهمیت متغیر ها می تواند مورد توجه قرار گیرد.

## ۶. مراجع

- Abdel-Aty, M. (2003). "Analysis of driver injury severity levels at multiple locations using ordered probit models." *Journal of safety research* 34(5): 597-603.

- Abdel-Aty, M. A., C. L. Chen and J. R. Schott (1998). "An assessment of the effect of driver age on traffic accident involvement using log-linear models." *Accident Analysis & Prevention* 30(6): 851-861.

- Abdelwahab, H. T. and M. A. Abdel-Aty (2001). "Development of artificial neural network models to predict driver injury severity in traffic accidents at signalized intersections." *Transportation research record* 1746(1): 6-13.

صحیح تصادفات جرحی/فوتی نیز عملکرد مدل را بهبود بخشیده است.

۳. در ادامه اشاره شد که این روش به نسبت روش نزدیک ترین همسایگی، حساسیت کتری به داده های پرت دارد و از این حیث نیز عملکرد بهتری به نسبت روش نزدیک ترین همسایگی نشان داده است.

در مرحله بعد، با استفاده از روش SHAP، به بررسی تاثیر متغیر ها پرداخته شد. اگرچه روش های یادگیری ماشین برخلاف روش های آماری، روش مشخصی برای چنین تحلیلی ارایه نمی کنند، برخی الگوریتم ها مانند SHAP به منظور برطرف سازی این مساله پیشنهاد شده اند. در این مرحله، بعد از انجام تحلیل SHAP بر روی هر یک از مدل ها، مقادیر بدست آمده نرمالایز شد و با توجه به مطالعات پیشین، مقدار SHAP بالای ۰/۵ متغیر معنا دار را تعریف کرد. نتایج نشان داد هر مدل متغیر های متفاوتی را در سطوح مختلفی از معنا داری دسته بندی کرده است. اما برخی متغیر ها مانند سرعت مجاز، روشنایی راه و سن راننده مقصر بین تمام روش ها مشترک بودند. در ادامه بحث شد که هر یک از این متغیر ها چه تاثیری بر شدت تصادف گذاشته اند و همچنین مطالعات همسویی که چنین نتایجی را گزارش کرده اند، گزارش شد. همچنین سایر متغیر ها مانند عرض راه، شانه راه و وضعیت آب و هوایی نیز بر روی شدت تصادفات تاثیر گذاشته اند.

به طور کلی نتایج نشان می دهند، درخت تصمیم در مدل سازی تصادفات جاده های دوخطه دوطرفه ایران به نسبت سایر روش های یادگیری ماشین عملکرد بهتری داشته است. این روش محاسناتی دارد که با استفاده از آن در مدل سازی شدت تصادفات می تواند مورد استفاده قرار گیرد. یکی آن که این روش اساسا در برخورد با متغیر های گسسته عملکرد بهینه ای دارد. همچنین این روش امکان مدل سازی روابط غیر خطی را دارد، اما از این حیث به علت پیچیدگی محاسباتی کمتر به نسبت به شبکه های

- Doecke, S. D., C. N. Kloeden, J. K. Dutschke and M. R. Baldock (2018). "Safe speed limits for a safe system: The relationship between speed limit and fatal crash rate for different crash types." *Traffic injury prevention* 19(4): 404-408.
- Fanyu, M., N. Sze, S. Cancan, C. Tiantian and Z. Yiping (2021). "Temporal instability of truck volume composition on non-truck-involved crash severity using uncorrelated and correlated grouped random parameters binary logit models with space-time variations." *Analytic Methods in Accident Research* 31: 100168.
- Gu, X., T. Li, Y. Wang, L. Zhang, Y. Wang and J. Yao (2018). "Traffic fatalities prediction using support vector machine with hybrid particle swarm optimization." *Journal of Algorithms & Computational Technology* 12(1): 20-29.
- Haghsheenas, S. S., G. Guido, A. Vitale and V. Astarita (2023). "Assessment of the level of road crash severity: Comparison of intelligence studies." *Expert Systems with Applications* 234: 121118.
- Hanrahan, R. B., P. M. Layde, S. Zhu, C. E. Guse and S. W. Hargarten (2009). "The association of driver age with traffic injury severity in Wisconsin." *Traffic injury prevention* 10(4): 361-367.
- Hou, Q., X. Huo, J. Leng and F. Mannering (2022). "A note on out-of-sample prediction, marginal effects computations, and temporal testing with random parameters crash-injury severity models." *Analytic methods in accident research* 33: 100191.
- Hu, Z., J. Zhou, K. Huang and E. Zhang (2022). "A data-driven approach for traffic crash prediction: A case study in Ningbo, China." *International Journal of Intelligent*
- Asadi, R., A. Khattak, H. Vashani, H. R. Almujiabah, H. Rabie, S. Asadi and B. Dimitrijevic (2023). "Self-Paced Ensemble-SHAP Approach for the Classification and Interpretation of Crash Severity in Work Zone Areas." *Sustainability* 15(11): 9076.
- Barbone, F., A. McMahon, P. Davey, A. Morris, I. Reid, D. McDevitt and T. MacDonald (1998). "Association of road-traffic accidents with benzodiazepine use." *The Lancet* 352(9137): 1331-1336.
- Chang, L.-Y. and J.-T. Chien (2013). "Analysis of driver injury severity in truck-involved accidents using a non-parametric classification tree model." *Safety science* 51(1): 17-22.
- Chen, C., G. Zhang, Z. Qian, R. A. Tarefder and Z. Tian (2016). "Investigating driver injury severity patterns in rollover crashes using support vector machine models." *Accident Analysis & Prevention* 90: 128-139.
- Chimba, D. and T. Sando (2009). "The prediction of highway traffic accident injury severity with neuromorphic techniques." *Advances in transportation studies* 19: 17-26.
- Chong, M., A. Abraham and M. Paprzycki (2005). "Traffic accident analysis using machine learning paradigms." *Informatica* 29 (1).
- Delen, D., R. Sharda and M. Bessonov (2006). "Identifying significant predictors of injury severity in traffic accidents using a series of artificial neural networks." *Accident Analysis & Prevention* 38(3): 434-444.
- Do, L. N., H. L. Vu, B. Q. Vo, Z. Liu and D. Phung (2019). "An effective spatial-temporal attention based neural network for traffic flow prediction." *Transportation research part C: emerging technologies* 108: 12-28.

- the CART and LR regression: a data mining approach." *Procedia Computer Science* 3: 764-769.
- Park, S. and J. Park (2022). "Multilevel Mixed-Effects Models to Identify Contributing Factors on Freight Vehicle Crash Severity." *Sustainability* 14(19): 11804.
  - Patil, S., S. R. Geedipally and D. Lord (2012). "Analysis of crash severities using nested logit model—accounting for the underreporting of crashes." *Accident Analysis & Prevention* 45: 646-653.
  - Rahim, M. A. and H. M. Hassan (2021). "A deep learning based traffic crash severity prediction framework." *Accident Analysis & Prevention* 154: 106090.
  - Rezapour, M., S. Nazneen and K. Ksaibati (2020). "Application of deep learning techniques in predicting motorcycle crash severity." *Engineering Reports* 2(7): e12175.
  - Rezapour, M., S. S. Wulff and K. Ksaibati (2020). "Bayesian hierarchical modelling of traffic barrier crash severity." *International journal of injury control and safety promotion* 28(1): 94-102.
  - Sameen, M. I. and B. Pradhan (2017). "Severity prediction of traffic accidents with recurrent neural networks." *Applied Sciences* 7(6): 476.
  - Silva, P. B., M. Andrade and S. Ferreira (2020). "Machine learning applied to road safety modeling: A systematic literature review." *Journal of traffic and transportation engineering (English edition)* 7(6): 775-790.
  - Sohn, S. Y. and S. H. Lee (2003). "Data fusion, ensemble and clustering to improve the classification accuracy for the severity of road traffic accidents in Korea." *Safety Science* 41(1): 1-14.
  - Transportation Systems Research 20(2): 508-518.
  - Iranitalab, A. and A. Khattak (2017). "Comparison of four statistical and machine learning methods for crash severity prediction." *Accident Analysis & Prevention* 108: 27-36.
  - Islam, M. R., K. B. Kelarestaghi, A. Ermagun and S. Banerjee (2019). "Gender Differences in Injury Severity Risk of Single-Vehicle Crashes in Virginia: A Nested Logit Analysis of Heterogeneity." *arXiv preprint arXiv:1901.03289*.
  - Kashani, A. T. and A. S. Mohaymany (2011). "Analysis of the traffic injury severity on two-lane, two-way rural roads based on classification tree models." *Safety science* 49(10): 1314-1320.
  - Li, J., Y. Yang, Y. Hu, X. Zhu, N. Ma and X. Yuan (2023). "Using Multidimensional Data to Analyze Freeway Real-Time Traffic Crash Precursors Based on XGBoost-SHAP Algorithm." *Journal of Advanced Transportation* 2023.
  - Li, P., M. Abdel-Aty and J. Yuan (2020). "Real-time crash risk prediction on arterials based on LSTM-CNN." *Accident Analysis & Prevention* 135: 105371.
  - Li, X., D. Lord, Y. Zhang and Y. Xie (2008). "Predicting motor vehicle crashes using support vector machine models." *Accident Analysis & Prevention* 40(4): 1611-1618.
  - Li, Z., P. Liu, W. Wang and C. Xu (2012). "Using support vector machine models for crash injury severity analysis." *Accident Analysis & Prevention* 45: 478-486.
  - Pakgohar, A., R. S. Tabrizi, M. Khalili and A. Esmaeili (2011). "The role of human factor in incidence and severity of road crashes based on

incorporating real-time traffic and weather data." *Safety science* 63: 50-56.

- Zeng, Q., W. Gu, X. Zhang, H. Wen, J. Lee and W. Hao (2019). "Analyzing freeway crash severity using a Bayesian spatial generalized ordered logit model with conditional autoregressive priors." *Accident Analysis & Prevention* 127: 87-95.

- Zeng, Q. and H. Huang (2014). "A stable and optimized neural network model for crash injury severity prediction." *Accident Analysis & Prevention* 73: 351-358.

- Zeng, Q., H. Wen, H. Huang, X. Pei and S. Wong (2017). "A multivariate random-parameters Tobit model for analyzing highway crash rates by injury severity." *Accident Analysis & Prevention* 99: 184-191.

- Zhao, X., H. Qi, Y. Yao, M. Guo and Y. Su (2023). "Traffic Order Analysis of Intersection Entrance Based on Aggressive Driving Behavior Data Using CatBoost and SHAP." *Journal of Transportation Engineering, Part A: Systems* 149(6): 04023037.

- Zubaidi, H. A., I. A. Obaid, A. Alnedawi and S. Das (2021). "Motor vehicle driver injury severity analysis utilizing a random parameter binary probit model considering different types of driving licenses in 4-legs roundabouts in South Australia." *Safety science* 134, 105083.

- Zuo, D., C. Qian, D. Xiao, X. Xu and H. Wang (2023). "Data-driven crash prediction by injury severity using a recurrent neural network model based on Keras framework." *International Journal of Injury Control and Safety Promotion*: 1-10.

- Sohn, S. Y. and H. Shin (2001). "Pattern recognition for road traffic accident severity in Korea." *Ergonomics* 44(1): 107-117.

- Tang, J., J. Liang, C. Han, Z. Li and H. Huang (2019). "Crash injury severity analysis using a two-layer Stacking framework." *Accident Analysis & Prevention* 122: 226-238.

- Tang, J., L. Zheng, C. Han, W. Yin, Y. Zhang, Y. Zou and H. Huang (2020). "Statistical and machine-learning methods for clearance time prediction of road incidents: A methodology review." *Analytic Methods in Accident Research* 27: 100123.

- Vajari, M. A., K. Aghabayk, M. Sadeghian and N. Shiwakoti (2020). "A multinomial logit model of motorcycle crash severity at Australian intersections." *Journal of safety research* 73: 17-24.

- Wahab, L. and H. Jiang (2019). "A comparative study on machine learning based algorithms for prediction of motorcycle crash severity." *PLoS one* 14(4): e0214966.

- Wen, X., Y. Xie, L. Jiang, Z. Pu and T. Ge (2021). "Applications of machine learning methods in traffic crash severity modelling: current status and future directions." *Transport reviews* 41(6): 855-879.

- Wilmot, C. G. and M. Khanal (1999). "Effect of speed limits on speed and safety: a review." *Transport Reviews* 19(4): 315-329.

- Yu, H., Z. Li, G. Zhang, P. Liu and T. Ma (2021). "Fusion convolutional neural network-based interpretation of unobserved heterogeneous factors in driver injury severity outcomes in single-vehicle crashes." *Analytic methods in accident research* 30, 100157.

- Yu, R. and M. Abdel-Aty (2014). "Analyzing crash injury severity for a mountainous freeway