

گسترش مدل شبکه عصبی گراف پیچشی در مدل‌سازی شدت تصادفات

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

صنعت ایران، ایران

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

E-mail: alitavakoli@iust.ac.ir

پذیرش: ۱۴۰۲/۰۷/۱۸

دریافت: ۱۴۰۲/۰۷/۰۹

چکیده

به علت خسارات اجتماعی و اقتصادی وارده توسط تصادفات، مطالعات ایمنی ترافیک در دهه‌های گذشته به شدت مورد توجه قرار گرفته‌اند. یکی از ابعاد مطالعات ایمنی ترافیکی، مدل‌سازی شدت تصادفات است که در آن رابطه بین شدت تصادفات و یک دسته متغیر توضیح مورد بررسی قرار می‌گیرد. علاوه بر مدل‌های آماری مختلفی که به این منظور مورد استفاده قرار گرفته‌اند، مدل‌های یادگیری ماشین نیز در سال‌های اخیر مورد توجه بوده‌اند. شبکه‌های عصبی یکی از این دسته الگوریتم‌های یادگیری ماشین است که در برخی از مطالعات مدل‌سازی شدت تصادفات استفاده شده. اما از آنجا که روش‌های یادگیری ماشین قابلیت مدل‌سازی مواردی مانند ناهمگونی مشاهده نشده را ندارند و به علت برخی مشکلات دیگر مانند توزیع غیرخطی داده‌ها، استفاده از داده‌های تصادفات به فرم اصلی‌شان همراه با کاستی‌هایی است. در نتیجه پژوهش حاضر با استفاده از الگوریتم نزدیک‌ترین همسایگی، یک ساختار پنهان گراف بر روی داده‌ها ایجاد می‌کند و سپس با استفاده از شبکه عصبی گراف پیچشی به مدل‌سازی شدت تصادفات می‌پردازد. سپس مدل پیشنهادی با چهار مدل یادگیری ماشین از جمله شبکه عصبی پرسپترون چندلایه مقایسه می‌شود نتایج نشان می‌دهد که مدل پیشنهادی در تمام شاخص‌ها از سایر مدل‌ها عملکرد بهتری داشته که می‌توان نتیجه گرفت ساختار پنهان گراف بر روی داده‌های تصادفات توانسته به استخراج روابط معنی‌دارتر از داده‌ها کمک کند.

واژه‌های کلیدی: مدل‌سازی شدت تصادفات، شبکه عصبی گراف پیچشی، ساختار پنهانی گراف داده

۱. مقدمه

مدل های طبقه بندی را با مشکلاتی مواجه کند. در سال های گذشته، شبکه های عصبی گراف پیچشی [Zhang, Tong et al. 2019] در زمینه های مختلفی از جمله بینایی ماشین و یادگیری ماشین به شدت مورد توجه قرار گرفته اند. علی رغم مدل های یادگیری عمیق معمول، این شبکه ها امکان نگاشت و مدل سازی ساختار گراف در داده های مختلف را دارند. در نتیجه پژوهش حاضر سعی دارد تا با استفاده از این شبکه ها مدلی کارآمدی برای پیش بینی شدت تصادفات ارائه کند. در این روش، به جای ورود داده ها در فرم اصلی به مدل، ساختار پنهان گراف داده ها توانایی استخراج روابط معنی دار تری برای داد های تصادفاتی دارد. به این منظور، پژوهش پیش رو با ایجاد یک گراف نزدیک ترین همسایگی سعی در استخراج اطلاعات همسایگی های محلی هر داده را دارد. در نتیجه، هدف پژوهش حاضر، استفاده از یک شبکه عصبی گراف پیچشی بر روی داده های تصادفاتی است، که با استفاده از ساختار پنهان گراف داده های حمل و نقل علاوه بر فرم اصلی داده ها، می تواند روابط معنی دارتر و در نتیجه پیش بینی دقیق تری ارائه کند.

۲. ادبیات پژوهش

۲-۱ روش های آماری در مدل سازی شدت تصادفات

در مطالعات مرتبط با مدل سازی شدت تصادفات، روش های آماری بیشترین استفاده را داشته اند. از آنجا که شدت تصادفات در سطوح گسته دسته بندی می شوند، استفاده از مدل های گسسته مورد بررسی قرار گرفته است. به عنوان نمونه از برخی از این روش ها می توان به مدل های لوجیت و پروبیت 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 2022] اشاره کرد. برای بررسی اثرات ترتیبی در شدت تصادفات، ناهمگونی مشاهده نشده، همبستگی بین تصادفات و درونزایی روش های پیشرفته آماری و اقتصادسنجی از جمله مدل های سلسله مراتبی [Rezapour, Wulff et al. 2020]، مدل لوجیت آشیانه ای

به علت افزایش جمعیت شهرها و گسترششان در بعد فضایی، و به تبع آن افزایش تقاضا برای حمل و نقل به دنبال افزایش جمعیت سکونت گاه ها از یک سو و توزیع فضایی گسترده تر کاربری ها از سوی دیگر، اهمیت مقوله حمل و نقل و به دنبال آن ایمنی سیستم های حمل و نقلی پیش از پیش مشهود است. در پی این افزایش تقاضا برای حمل و نقل، تصادفات در شبکه حمل و نقل جاده ای، از اصلی ترین عوامل تلفات تلقی می شوند. این مسئله تا جایی است که تصادفات ششمین عامل مرگ و میر با سالانه ۱/۲۴ میلیون کشته و پنجاه هزار مصدوم در دنیا و به عنوان دومین عامل مرگ و میر با سالانه ۱۷۹۹۴ تلفات در ایران هستند [Organization 2020].

برای مدل سازی رابطه میان شدت تصادفات و عوامل موثر بر آن مانند عوامل مربوط به راننده، عوامل محیطی و وسایل نقلیه، از مجموعه ای از روش ها پیشرفته آماری استفاده شده است. در حالی که استفاده از روش های مبتنی بر شبکه های عصبی و یادگیری عمیق نیاز به بررسی بیشتری دارد. شبکه های عصبی های عصبی در حوزه های متفاوتی در حمل و نقل مورد استفاده قرار گرفته اند [Li, Zhu et al. 2020, Zhou, Yang et al. 2020] که می توان به مطالعات برآورد داده های سنسور [Fang, Fei et al. 2017] و مطالعات پیش بینی جریان ترافیک [Do, Vu et al. 2019, Ali, Zhu et al. 2022] اشاره کرد، اما استفاده از روش های مبتنی بر یادگیری عمیق در مدل سازی شدت تصادفات محدود تر بوده است. یکی از این مشکلات، استفاده از داده های تصادفات در فرم اصلی به عنوان ورودی برای این مدل هاست. به علت برخی از مشکلات مانند ناهمگونی مشاهده نشده در داده های حمل و نقل [Islam, Zeng et al. 2023] و توزیع غیرخطی داده ها [Shirazi et al. 2017, and Huang 2014, Iranitalab and Khattak 2017] داده ها در فرم اصلی نمی توانند ارتباطات بین تصادفات را بیان کنند. همچنین وجود خطای اندازه گیری نیز می تواند عملکرد

[and Hassan 2021] نیز دقت عملکرد مدل‌های مبتنی بر شبکه‌های عصبی بالاتر از روش‌های آماری گزارش شده‌اند. شبکه‌های عصبی عمیق نیز در برخی مطالعات در مدل‌سازی شدت تصادفات مورد استفاده قرار گرفته‌اند [Rezapour, Nazneen et al. 2020, Rahim and Hassan 2021]. برخی از این شبکه‌های شامل شبکه‌های عصبی پیچشی [Yu, Li et al. 2021, Haghshenas, Guido et al. 2023] و شبکه‌های عصبی بازگشتی [Rezapour, Nazneen et al. 2020, Zuo, Qian et al. 2023] و همچنین شبکه‌های پیچشی-بازگشتی [Li, Abdel-Aty et al. 2020, Hu, Zhou et al. 2022] می‌باشند. اگرچه عملکرد این شبکه‌ها در مدل‌سازی شدت تصادفات بسیار امیدوارکننده بوده، استفاده از این شبکه‌ها بسیار محدود بوده است [Sameen and Pradhan 2017, Zeng, Gu et al. 2019].

۲-۳ شبکه عصبی گراف در ایمنی ترافیک

استفاده از شبکه‌های عصبی گراف در مدل‌سازی ایمنی ترافیک بسیار محدود بوده است. اگرچه به تازگی این روش در مدل‌سازی ترافیکی مورد توجه قرار گرفته است. به عنوان مثال [Bai, Yao et al. 2020] با استفاده از شبکه عصبی گراف پیچشی و بازگشتی مدلی مکانی-زمانی برای پیش‌بینی جریان ترافیک ارائه کردند. همچنین در پژوهش [Boukerche, Tao et al. 2020] از این شبکه‌ها برای پیش‌بینی جریان ترافیک استفاده شده است. همچنین برخی دیگر از این پژوهش‌ها شامل [Zhou, Yang et al. 2020, Bui, Cho et al. 2022] اشاره کرد.

همانطور که اشاره شد، استفاده از این روش‌ها در مدل‌سازی‌های ایمنی ترافیک به شدت محدود بوده است. همچنین این مطالعات معطوف به پیش‌بینی ریسک تصادفات هستند. این مطالعات شامل [Zhang, Dong et al. 2020, Zhou, Wang et al. 2020, Yu, Wang et al. 2020, Zhou, Wang et al. 2020, Yu, Du et al. 2021] هستند. در تمامی این مطالعات عملکرد

[Patil, Geedipally et al. 2012, Islam, Kelarestaghi et al. 2019] و همچنین مدل‌های پارامتر تصادفی [Zeng, Wen et al. 2017, Hou, Huo et al. 2022] اشاره کرد. این مدل‌ها پیش‌فرض‌هایی مانند روابط خطی مشخص بین متغیر مستقل و متغیرهای توضیحی، توابع اتصال و همچنین فرض توزیع مشخص بر روی داده‌های تصادفات دارند. در صورتی ارضا نشدن این مفروضات، استنباط آماری تحت تاثیر قرار خواهد گرفت [Silva, Andrade et al. 2020, Hou, Huo et al. 2022].

۲-۲ شبکه‌های عصبی در برآورد شدت تصادفات

در برخی از مطالعات، شبکه‌های عصبی برای مدل‌سازی شدت تصادفات مورد استفاده قرار گرفته‌اند. برخی از مزایای استفاده از این الگوریتم‌ها به اختصار مورد بحث قرار می‌گیرد. شبکه‌های عصبی پیش‌فرض‌های مدل‌ها آماری را ندارند، همچنین این شبکه‌ها می‌توانند روابط غیرخطی را نیز مدل‌سازی کنند. برخی از پژوهش‌هایی که از شبکه‌های عصبی برای مدل‌سازی شدت تصادفات استفاده کرده‌اند در ادامه مورد بررسی قرار گرفته‌اند. عدالوهاب و عبدلعاطی در مطالعه‌ای با استفاده از شبکه پرسپترون چندلایه شدت تصادفات را مدل‌سازی 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 شبکه‌های پرسپترون چندلایه استفاده کرده‌اند، نتایج مشابهی گزارش شده است. دلتن و همکاران با استفاده از چند شبکه پرسپترون چندلایه به شناسایی عوامل موثر در شدت تصادفات پرداختند [Delen, Sharda et al. 2006]. همچنین چیمبا و ساندو در مقایسه عملکرد مدل پرسپترون چندلایه با روش‌های آماری لوجیت و پروبیت ترتیبی دقت بالاتری را برای مدل‌های شبکه عصبی گزارش کردند [Chimba and Sando 2009]. همچنین در مطالعات [Zeng and Huang 2014, Rahim

پژوهش پیشرو با استفاده از ایده نزدیک‌ترین همسایگی، این ساختار پنهان گراف را در داده‌ها ایجاد می‌کند. به این منظور گراف $G(V, E, A)$ را برای داده‌ها تعریف کرده‌ایم. همانطور که اشاره شد، در این تعریف، هر نود را برابر یک مشاهده در داده‌ها تعریف کرده‌ایم. برای یافتن یال‌های گراف و ماتریس مجاورت خواهیم داشت:

$$A_{ij} = \begin{cases} 1 & \text{if } X_i \sim X_j \\ 0 & \text{otherwise} \end{cases} \quad (1)$$

که در این رابطه از \sim برای نشان دادن رابطه همسایگی استفاده شده. در ادامه برای استخراج رابطه همسایگی، ابتدا فاصله دو داده دلخواه را طبق رابطه فاصله اقلیدسی حساب می‌کنیم:

$$d(X_i, X_j) = \sum_{d=1}^D (X_{di} - X_{dj})^2 \quad (2)$$

سپس با تعیین پارامتر k ، طبق رابطه ۲، نزدیک‌ترین همسایگان برای هر داده را به ترتیب فاصله اقلیدسی به صورت نزولی مشخص کرده و k مشاهده اول را انتخاب می‌کنیم. برای این مشاهدات داریم $X_i \sim X_j$. در نتیجه طبق این رابطه یال‌های گراف داده و همچنین ماتریس مجاورت ساخته خواهد شد.

۳-۲ شبکه عصبی گراف پیچشی

شبکه‌های عصبی گراف پیچشی سعی در پیدا کردن تابع غیرخطی $f(X, Y, A)$ دارند که با استفاده از آن به پیش‌بینی مشاهدات داده‌های تست بپردازند. برای انجام داده عملیات پیچش در گراف‌ها داریم:

$$\begin{cases} H^1 = \sigma(\hat{A}H^0W^l) \\ \vdots \\ H^l = \sigma(\hat{A}H^{l-1}W^l) \\ H^{l+1} = \hat{A}H^lW^{l+1} \end{cases} \quad (3)$$

در رابطه ۳، $\hat{A} = \tilde{D}^{-\frac{1}{2}} \tilde{A} \tilde{D}^{-\frac{1}{2}}$ که در آن $\tilde{A} = A + I$ ماتریس مجاورتی است که در آن هر نود به خودش متصل شده و I ماتریس همانی با ابعاد N است. همچنین $\tilde{D} = \text{diag}(\text{sum}(\tilde{A}, 2))$ همچنین W^l ماتریس وزن‌ها در هر لایه است. σ نیز تابع فعالسازی در لایه مورد نظر است. همچنین برای ماتریس تعبیه شده داریم:

بهتر مدل‌های شبکه عصبی گراف پیچشی به نسبت سایر روش‌ها گزارش شده است.

باتوجه به مطالب ارائه شده، پژوهش پیشرو اهداف زیر را مدنظر قرار داده است:

۱. باتوجه به مرور ادبیات حوزه پژوهش، استفاده از شبکه‌های عصبی گراف در مطالعات ایمنی ترافیک محدود بوده است. همچنین این مطالعات تنها به مطالعه و بررسی ریسک تصادفات پرداخته‌اند.

۲. شبکه‌های عصبی گراف می‌توانند با استخراج روابط معنی‌دار از داده‌ها، عملکرد مدل را افزایش دهند.

۳. در نتیجه پژوهش پیشرو با ارائه یک ساختار گراف پنهان بر روی داده‌های تصادفات، و با استفاده از شبکه‌های عصبی مبتنی بر گراف، سعی در مدل‌سازی شدت تصادفات کرده است. به نظر می‌رسد که استخراج روابط معنی‌دارتر با استفاده از گراف داده‌های می‌تواند منجر به افزایش عملکرد مدل شود.

۳. روش پژوهش

در این قسمت ابتدا به تشریح مسئله به صورت کلی پرداخته‌ایم. داده‌های ترافیکی با $X = [X_1, X_2, \dots, X_N] \in \mathbb{R}^{D \times N}$ نشان می‌دهیم. همانطور که مشخص است تعداد N مشاهده موجود است که هر یک دارای D متغیر است. همچنین برای متغیر مستقل که در این مسئله شدت تصادفات است داریم:

$Y = [Y_1, Y_2, \dots, Y_N] \in \mathbb{R}^{C \times N}$ که در آن C تعداد کلاس‌های شدت تصادفات است.

۳-۱ ساختمان گراف داده‌ها

شبکه گراف پیچشی برای داده‌هایی که به صورت طبیعی به فرم گراف هستند پیشنهاد شده است. از جمله این داده‌ها می‌توان به داده‌های شبکه‌های اجتماعی اشاره کرد. در نگاه اول، داده‌های شدت تصادفات چنین ویژگی ندارند. به این منظور که اگر هر داده تصادف را یک گره برای گراف در نظر بگیریم، تعریف یال برای این گراف فاقد معنی است. در نتیجه در ابتدا می‌بایست روشی برای یافتن ساختار پنهان گراف در این داده‌ها یافت.

گسترش مدل شبکه عصبی گراف پیچشی در مدل‌سازی شدت تصادفات

فوتی و جرحی به نسبت تصادفات خسارتی، تصادفات این دو دسته با هم جمع شدند و یک سطح در نظر گرفته شده‌اند. ابتدا عملیات پیش پردازش بر روی این داده‌ها انجام شد. داده‌هایی که مقادیر نامشخص و ثبت نشده داشتند حذف شدند. پس از حذف داده‌های ثبت نشده، تعداد ۴۱۱۲۰ داده باقی ماند. برای تطبیق بهتر با معماری مدل‌های شبکه عصبی پیچشی، متغیرهای طبقه‌ای به صورت متغیر ساختگی درآمدند و همچنین با توجه به مطالعات پیشین، داده‌ها به دو مجموعه آموزش و تست با نسبت ۲۰:۸۰ تقسیم شدند. در ادامه بر روی متغیرهای پیوسته عملیات استاندارد سازی هم برای داده‌ای آموزش و هم برای داده‌های تست و به صورت جداگانه انجام شد.

۴. تحلیل داده‌ها

در این قسمت، نتایج حاصل از مدل‌های توضیح داده شده را گزارش کرده‌ایم. لازم به ذکر است پیاده‌سازی تمامی مدل‌ها با استفاده از زبان برنامه‌نویسی پایتون انجام شده است. برای مدل‌سازی‌ها از کتابخانه Scikit-Learn و برای مدل‌های شبکه عصبی گراف از کتابخانه TensorFlow و Keras استفاده شده است. مدل ارائه شده با استفاده از برنامه‌نویسی شی گرا و با تولید لایه‌های شخصی در Keras انجام شده است. در این قسمت عملکرد ۴ مدل با هم مقایسه شده است:

۱. مدل شبکه عصبی گراف پیچشی با استفاده از ساختمان

گراف نزدیک‌ترین همسایگی در داده‌ها

۲. شبکه پرسپترون چندلایه

۳. جنگل تصادفی

۴. ماشین بردار پشتیبان

۴-۱ مشخصات مدل

برای یافتن بهترین ابر پارامترها برای هر یک از این مدل‌ها، از عملیات اعتبارسنجی متقابل با ۱۰ لایه استفاده شده است. در ادامه فضای جستجوی مورد استفاده برای هر یک از ابر پارامترهای هریک از مدل‌ها توضیح داده می‌شوند. ابتدا برای مدل پرسپترون چندلایه، ابر پارامترهای مورد بررسی به این شرح

$$H^l = [h_1^l, h_2^l, \dots, h_n^l] \in \mathbb{R}^{D^l \times N} \quad (4)$$

همچنین داریم $H^0 = X$. در نهایت از آنجایی که مسئله طبقه بندی مد نظر است، ماتریس تعبیه شده در لایه نهایی بعدی برابر با تعداد کلاس‌ها داشته و همچنین از تابع سافت‌مکس به عنوان فعال ساز استفاده می‌شود. داریم:

$$z_i = \text{softmax}(h_i^{(l+1)}) \\ = \frac{1}{\sum_{p=1}^c \exp(h_{pi}^{(l+1)})} \exp(h_i^{(l+1)}) \quad (5)$$

که c تعداد کلاس‌هاست.

۳-۳ مدل پیشنهادی

برای توضیح مدل پیشنهادی، می‌بایست به رابطه ۳ که رابطه اصلی شبکه‌های عصبی گرافی است توجه شود. ابتدا مفهوم ماتریس همجواری در رابطه با داده‌ها را مورد بررسی قرار می‌دهیم. دقت شود که با استفاده فاصله اقلیدسی، نزدیک‌ترین مشاهدات به یکدیگر مشخص شده‌اند. ماتریس مجاورت برای هر دو مشاهده اگر در همسایگی یکدیگر باشند، یک اتصال در نظر می‌گیرد. برای توضیح آنچه در ادامه اتفاق می‌افتد به شرح زیر است. ابتدا وضعیت تعبیه شده برای هر لایه در یک ماتریس وزن ضرب می‌شود. در مرحله بعد، ضرب ماتریس همجواری، مقادیر محاسبه شده برای تمامی نقاطی که در همسایگی یکدیگر هستند را با یکدیگر جمع می‌کند.

۳-۴ 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 از سیستم‌های اطلاعات مکانی به دست آمده‌اند. در این داده‌ها متغیرهای مربوط به ویژگی‌های راننده در کنار مجموعه‌ای از متغیرهای که در مطالعات پیشین موثر تشخیص داده شده‌اند قرار گرفته است. متغیرهای موجود در این داده در جدول یک گردآوری شده‌اند. شدت تصادفات در سه سطح خسارتی، جرحی و فوتی ارزیابی شده است. با توجه به تعداد کم مشاهدات تصادفات

فصلنامه مهندسی حمل و نقل / سال هفدهم / شماره اول (۶۶) / پاییز ۱۴۰۴

هستند. اول تعداد لایه‌ها و همچنین تعداد نورون‌ها در هر لایه بررسی شده‌اند. با توجه به ادبیات پژوهش فضای جستجو به ترتیب برابر با $[۱, ۵]$ و $[۸, ۳۲]$ در نظر گرفته شده است. همچنین برای تابع فعالساز در لایه توابع Tanh, Sigmoid, Leaky ReLU, ReLU

جدول ۱. توصیف متغیرها

کد متغیر	نام متغیر	توصیف متغیر
Y	شدت تصادف	۰=خسارتی ۱=جرحی فوتی
X_1	سن راننده مقصر	
X_2	جنسیت راننده مقصر	۰=مرد ۱=زن
X_3	تحصیلات راننده مقصر	۰=بیسواد ۱=ابتدایی ۲=دیپلم ۳=لیسانس و بالاتر
X_4	روشنایی	۰=روز ۱=شب
X_5	هوا	۰=صاف ۱=باری/بارانی ۲=برفی
X_6	نوع منطقه	۰=هموار ۱=کوهستانی
X_7	شرایط سطح راه	۰=تر ۱=خشک
X_8	هندسه محل	۰=پیچ/سربالایی سرپایینی ۱=پیچ مسطح ۲=مستقیم سربالایی/سرپایینی ۳=مستقیم مسطح
X_9	نوع شانه راه	۰=شانه آسفالت ۱=شانه خاکی ۲=شانه ندارد
X_{10}	طول راه	
X_{11}	عرض راه	
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

برای الگوریتم ماشین بردار پشتیبان، ابر پارمترهای مورد بررسی به شرح زیر هستند. ابتدا برای مشخص کردن هسته این توابع هسته های خطی، چند جمله ای و تابع شعاعی مورد بررسی قرار گرفتند. برای پارمترهای هسته چند جمله ای d و تابع شعاعی r از مجموعه های زیر استفاده شده است.

$$r = \{10^{-2}, 5 \times 10^{-2}, 10^{-1}, 10^{-1}, 10^{-1}, 20, 50, 100, 200, 500\}$$

و همچنین

$$d = \{1, 2, 3, 4, 5\}$$

Parametric ReLU مد نظر قرار گرفته اند. در نهایت تعداد ۳ لایه پنهان با تابع فعالساز Parametric ReLU مورد استفاده قرار گرفت. همچنین تعداد نورون ها برای هر یک از لایه های پنهان برابر با $[۱۶, ۲۴, ۲۴]$ محاسبه شد. برای پارامترهای چنگل تصادفی از تابع آنتروپی برای اندازه گیری کیفیت تقسیمات استفاده شد. همچنین پارامتر بوتسروپ نیز برای ساخت درخت‌ها مورد استفاده قرار گرفت. در ادامه نیز برای تعیین تعداد درخت‌ها در فضای $[1, 10^4]$ جستجو انجام شد.

گسترش مدل شبکه عصبی گراف پیچشی در مدل‌سازی شدت تصادفات

همانطور که در جدول ۲ مشخص است، از حیث شاخص عملکرد مدل پیشنهادی در تمامی شاخص‌ها به نسبت سایر مدل‌ها بهتر است. از مقایسه عملکرد هر یک از این مدل‌ها می‌توان نتیجه گرفت که ایجاد ساختار پنهانی گراف از داده‌ها توانسته به استخراج روابط معنی‌دارتر از داده‌ها کمک کند. برای بررسی دقیق‌تر می‌بایست به عملکرد مدل پرسپترون چندلایه توجه کرد. اگرچه که تفاوت‌هایی بین مدل پیشنهادی و مدل پرسپترون چندلایه موجود است، اما باید توجه کرد که تفاوت اصلی این دو مدل، در نظر گرفتن ماتریس مجاورت برای داده است. می‌بایست توجه کرد که در نظر گرفتن ساختمان پنهانی گراف بر روی داده‌ها توانسته عملکرد مدل پیشنهادی را به صورت قابل توجهی افزایش دهد. این امر در ساختمان و معماری مدل پرسپترون چندلایه نیز مشهود است. با توجه به مطالب توضیح داده شده در قسمت قبل، تعداد سه لایه پنهان برای مدل پرسپترون چندلایه انتخاب شد. در آزمایشات اعتبارسنجی مشخص شد که افزایش تعداد لایه‌های پنهان عملکرد مدل را کاهش می‌دهد. علت این امر را باید در بیهنه سازی نابالغ جست. این در حالی است که مدل پیشنهادی توانسته با استفاده از ساختار گراف داده‌ها، اطلاعات بیشتر و معنی‌دارتری در رابطه با این داده‌ها استخراج کند. این امر در تعداد لایه‌های مدل پیشنهادی مشهود است.

استفاده شده است. در نهایت تابع هسته شعاعی، با مقدار پارامترهای $r = 10$ استفاده شد. در نهایت برای مدل پیشنهادی ابتدا ابر پارامتر نزدیک‌ترین همسایگی را مد نظر قرار دادیم. مقدار ۱۵ برای این ابر پارامتر طبق عملیات اعتبارسنجی متقابل مقدار بهینه بدست آمد. همچنین سایر ابر پارامترها مانند نرخ یادگیری، تعداد لایه‌ها و ابعاد این لایه‌ها به ترتیب برابر با ۰/۰۰۱، ۵، [۱۶۸، ۲۴، ۳۲، ۶۴] بدست آمد.

۲-۴ نتایج

در این مرحله داده‌های مشروح بر روی هر یک از مدل‌ها برگذاری شده‌اند. در ادامه عملکرد هر یک از این مدل‌ها بررسی شده است. ابتدا عملکرد مدل پرسپترون چندلایه مورد بررسی قرار گرفته است. همانطور که توضیح داده شد در مطالعات مختلف، از این الگوریتم برای مدل‌سازی شدت تصادفات استفاده شده است. این مدل‌ها قابلیت در نظر گرفتن روابط غیرخطی در داده‌ها را دارند. مدل بعدی مورد بررسی مدل جنگل تصادفی است. همچنین مدل مبتنی بر ماشین بردار پشتیبان و در آخر مدل پیشنهادی نیز مورد بررسی قرار گرفته‌اند. ابر پارامترها و ساختار هر یک از این مدل‌ها در قسمت قبل مورد بررسی قرار گرفته است.

در جدول دو، RF مدل جنگل تصادفی، SVM مدل ماشین بردار پشتیبان، MLP مدل پرسپترون چندلایه و GCN مدل پیشنهادی هستند.

جدول ۲. مقایسه عملکرد مدل‌ها

F1 Score		Recall		Precision		دقت		
تست	آموزش	تست	آموزش	تست	آموزش	تست	آموزش	
۰/۶۴	۰/۶۷	۰/۶۶	۰/۶۸	۰/۶۴	۰/۶۷	۰/۶۶	۰/۶۸	MLP
۰/۶۵	۰/۶۶	۰/۶۷	۰/۶۹	۰/۶۵	۰/۶۶	۰/۶۷	۰/۶۹	RF
۰/۶۴	۰/۷۰	۰/۶۵	۰/۶۸	۰/۶۴	۰/۷۰	۰/۶۵	۰/۶۸	SVM
۰/۷۲	۰/۷۴	۰/۷۴	۰/۷۶	۰/۷۲	۰/۷۴	۰/۷۴	۰/۷۶	GCN

می‌شود، مدل پیشنهادی برای این شاخص‌ها به ترتیب ۰/۷۲، ۰/۴۹ و ۰/۵۹ را ثبت کرده. این مقدار به صورت قابل توجهی از سایر مدل‌ها بیشتر است. به عنوان مثال از حیث عملکرد در رابطه با این شاخص‌ها مدل جنگل تصادفی عملکرد دوم را دارد، که مقدار شاخص FI برای آن ۰/۵۶ گزارش شده است.

در ادامه برای بررسی دقیق‌تر این مسئله، ماتریس آشفتگی برای هر یک از این مدل‌ها ارائه شده است. لازم به ذکر است که برای افزایش ثبات نتایج گزارش شده، برای هر مدل ۱۰ بار فرایند آموزش و تست انجام شده و در نهایت میانگین نتایج در جدول ۲ و همچنین ماتریس‌های آشفتگی گزارش شده است.

همانطور که از اطلاعات این جدول‌ها و جدول شماره ۲ مشخص است، عملکرد مدل پیشنهادی در پیش‌بینی صحیح تصادفات جرحی/ فوتی که دارای مشاهدات کمتری نسبت به تصادفات خسارتی است، به نسبت سایر مدل‌ها بهتر است. مدل پیشنهادی از مجموع ۳۵۱۱ داده جرحی/ فوتی، تعداد ۲۰۳۰ تصادف را به درستی تشخیص داده است. این عدد برای مدل ماشین بردار پشتیبان برابر با ۱۶۱۵، برای جنگل تصادفی برابر با ۱۷۷۶ و برای پرسپترون چندلایه برابر با ۱۶۸۷ است.

در رابطه با دقت مدل‌ها، مشخص است که مدل پیشنهادی بهترین عملکرد را بر روی داده‌های تست داشته است. مدل پیشنهادی توانسته ۷۲ درصد از داده‌های تست را به درستی طبقه بندی کند. این مقدار برای مدل پرسپترون چندلایه برابر با ۶۶ درصد، برای مدل جنگل تصادفی برابر با ۶۷ درصد و برای مدل ماشین بردار پشتیبان برابر با ۶۵ درصد است. همانطور که مشخص است، ساختمان گراف داده‌ها توانسته عملکرد مدل را در این زمینه افزایش دهد.

نکته دیگر حائز اهمیت، عملکرد بهتر مدل پیشنهادی در سایر شاخص‌هاست. این عملکرد بهتر نشان می‌دهد که مدل در شناسایی و طبقه‌بندی تصادفات جرحی و فوتی نیز به نسبت سایر مدل‌ها عملکرد بهتری دارد. آنچه در این زمینه حایز اهمیت است، اهمیت بالای این تصادفات است. اما به علت این که عموماً داده‌ها مشاهدات کمی با شدت تصادفات در سطوح بالاتر دارند، الگوریتم‌ها در دسته بندی این تصادفات عملکرد بهینه‌ای ندارند. آنچه که از شاخص‌های Recall، Precision و F1 Score مشخص افزایش قابل توجه عملکرد مدل پیشنهادی در رابطه با دسته‌بندی این تصادفات است. همانطور که از جدول دو برداشت

جدول ۳. ماتریس آشفتگی

برآورد			
خسارتی	جرحی / فوتی		
۳۸۱۸	۸۷۳	خسارتی	MLP
۱۸۴۶	۱۶۸۷	جرحی / فوتی	
۳۷۶۰	۹۳۱	خسارتی	RF
۱۷۵۷	۱۷۷۶	جرحی / فوتی	
۳۷۸۴	۹۰۷	خسارتی	SVM
۱۹۱۸	۱۶۱۵	جرحی / فوتی	
۳۹۸۹	۶۲۴	خسارتی	GCN
۱۵۸۱	۲۰۳۰	جرحی / فوتی	

گسترش مدل شبکه عصبی گراف پیچشی در مدل‌سازی شدت تصادفات

را دارد. چرا که در این ساختار جدید، مشاهدات می‌توانند با یکدیگر تبادل اطلاعات داشته باشند. در نتیجه، این پژوهش با الهام از الگوریتم نزدیک‌ترین همسایگی و با مشخص کردن نزدیک‌ترین مشاهدات به یکدیگر و با معرفی متریک اقلیدسی برای اندازه‌گیری این فاصله، ساختار گراف داده‌های تصادفات را ایجاد می‌کند. در نتیجه گراف مشاهدات که هر گره یک مشاهده است تشکیل می‌شود. در صورتی که دو مشاهده در همسایگی محلی یکدیگر تشکیل شدند، یک یال بین این دو مشاهده ایجاد می‌شود. در نهایت نیز با استفاده از ماتریس هم‌جواری شبکه عصبی گراف پیچشی تعریف می‌شود.

در ادامه داده‌های تصادفات جاده‌های دو خطه دوطرفه جدا نشده در ایران پس از پیش پردازش بر روی چهار مدل آزمایش شدند. این مدل‌ها به ترتیب مقابل هستند، مدل پرسپترون چندلایه، مدل جنگل تصادفی، مدل ماشین بردار پشتیبان و همچنین مدل پیشنهادی. نتایج نشان داد که عملکرد مدل پیشنهادی چه از حیث دقت و چه از حیث سایر شاخص‌های طبقه بندی که در این پژوهش **Recall, Precision** و **F1 Score** انتخاب شدند، به طور معناداری بیشتر بوده است.

در خصوص پیشنهادها برای مطالعات آتی موارد زیر قابل ذکر است:

۱. استفاده از سایر مدل‌های شبکه عصبی گراف مانند الگوریتم‌های **GAN**. این مدل‌ها به علت وزن‌دهی به یال‌های گراف و ماتریس مجاورت می‌توانند عملکرد کلی مدل را افزایش دهند.

۲. استفاده از لایه‌های حساس به هزینه در شبکه عصبی گراف. از این لایه‌ها می‌توان برای مقابله با مشکلات نامتعادل بودن مشاهدات استفاده کرد. به این صورت که این لایه‌ها می‌توانند تمرکز بیشتری بر روی کلاس‌هایی که داده‌های کمتری دارند داشته باشند. با استفاده از این روش می‌توان عملکرد مدل را در زمینه دسته‌بندی کلاس‌هایی که مشاهدات کمتری دارند افزایش داد.

آنچه در این قسمت می‌بایست مدنظر قرار گیر مقایسه عملکرد مدل پیشنهادی با شبکه عصبی پرسپترون چندلایه است. باتوجه به رابطه (۳)، تنها تفاوت رابطه مدل شبکه عصبی گراف با شبکه پرسپترون چندلایه تنها استفاده از ماتریس همبستگی در محاسبه لایه‌های پنهان در مدل است. با ضرب ماتریس همبستگی، عملاً مشاهداتی که در ساختار گراف داده‌ها، به علت تشابهشان، با یکدیگر در ارتباط هستند، با یکدیگر جمع می‌شوند. در نتیجه ساختار گردش اطلاعات بین داده‌ها برقرار خواهد شد. به این معنی که آن دسته از مشاهداتی که از حیث متغیرهای توضیحشان به یکدیگر نزدیک هستند، می‌توانند در این ساختار با یکدیگر تبادل اطلاعاتی داشته باشند. این مهم، تفاوت اصلی این مدل و مدل‌های پرسپترون چندلایه است. باتوجه به عملکرد مدل از یک طرف، و همچنین باتوجه به ساختار ابر پارامترهای مدل پیشنهادی و تفاوتشان با مدل پرسپترون چندلایه، مشخص است که مدل پیشنهادی با استفاده از ساختار گراف داده‌ها توانسته روابط معنی‌داری را از داده‌ها استخراج کند. توضیح آنکه، با توجه به ابر پارامترهای ارائه شده برای مدل پرسپترون چندلایه در قسمت قبل، مشخص می‌شود که دلیل کاهش عملکرد مدل پرسپترون چندلایه به‌ازای افزایش تعداد لایه‌های پنهان و افزایش تعداد نورون‌ها در هر لایه، مسئله بهینه‌سازی نابالغ است [Li et al. 2021]. به این معنی که این مدل نتوانسته با توجه به ممتغیرهای مستقل، روابط معنی‌داری را از داده‌ها استخراج کند. همانطور که مشخص است، مدل پیشنهادی توانسته با برطرف ساختن این ایراد، عملکرد مدل‌سازی را افزایش دهد.

۵. نتیجه‌گیری و پیشنهادات

پژوهش پیش رو سعی در ارائه مدلی مبتنی بر شبکه عصبی گراف پیچشی برای مدل‌سازی شدت تصادفات داشته است. اطلاعات داده‌های تصادفات در فرم اصلی خودشان به علت مسائلی مانند ناهمگونی مشاهده نشده و همچنین توزیع غیرخطی داده‌ها می‌تواند عملکرد مدل‌های یادگیری ماشین را مختل کند. از طرفی، ساختار پنهان گراف در داده‌ها، توانایی بهبود عملکرد این مدل‌ها

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.

-Fang, S.-H., Y.-X. Fei, Z. Xu and Y. Tsao (2017). "Learning transportation modes from smartphone sensors based on deep neural network." *IEEE Sensors Journal* 17(18): 6111-6118.

- 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.

- Haghshenas, 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.

- 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 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.

۳. در نظر گرفتن ابعاد زمانی در مدل‌سازی. مدل‌های زمانی- مکانی می‌توانند عملکرد طبقه بندی را افزایش دهند. به این منظور می‌توان ساختار زمانی داده‌ها را نیز به صورت جداگانه برای مدل‌سازی توسط شبکه عصبی گراف در نظر گرفت.

۶. مراجع

- 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.

- Ali, A., Y. Zhu and M. Zakarya (2022). "Exploiting dynamic spatio-temporal graph convolutional neural networks for citywide traffic flows prediction." *Neural networks* 145: 233-247.

- Bai, L., L. Yao, C. Li, X. Wang and C. Wang (2020). "Adaptive graph convolutional recurrent network for traffic forecasting." *Advances in neural information processing systems* 33: 17804-17815.

- Boukerche, A., Y. Tao and P. Sun (2020). "Artificial intelligence-based vehicular traffic flow prediction methods for supporting intelligent transportation systems." *Computer networks* 182: 107484.

- Bui, K.-H. N., J. Cho and H. Yi (2022). "Spatial-temporal graph neural network for traffic forecasting: An overview and open research issues." *Applied Intelligence* 52(3): 2763-2774.

- Chimba, D. and T. Sando (2009). "The prediction of highway traffic accident injury severity with neuromorphic techniques." *Advances in transportation studies* 19: 17-26.

- Delen, D., R. Sharda and M. Bessonov (2006). "Identifying significant predictors of injury severity in traffic accidents using a series of

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.

- 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.

- 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, L., B. Du, X. Hu, L. Sun, L. Han and W. Lv (2021). "Deep spatio-temporal graph convolutional network for traffic accident prediction." *Neurocomputing* 423: 135-147.

- Zeng, Q., W. Gu, X. Zhang, H. Wen, J. Lee and W. Hao (2019). "Analyzing freeway crash severity using a Bayesian spatial generalized

- Islam, A. M., M. Shirazi and D. Lord (2023). "Grouped Random Parameters Negative Binomial-Lindley for accounting unobserved heterogeneity in crash data with preponderant zero observations." *Analytic methods in accident research* 37: 100255.

- 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*.

- Li, L., J. Zhu, H. Zhang, H. Tan, B. Du and B. Ran (2020). "Coupled application of generative -- adversarial networks and conventional neural networks for travel mode detection using GPS data." *Transportation Research Part A: Policy and Practice* 136: 282-292.

- 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.

- Organization, W. H. (2020). *Road safety in the Eastern Mediterranean Region: facts from the global status report on road safety 2018*, World Health Organization. Regional Office for the Eastern Mediterranean.

- 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

- Zhou, F., Q. Yang, T. Zhong, D. Chen and N. Zhang (2020). "Variational graph neural networks for road traffic prediction in intelligent transportation systems." *IEEE Transactions on Industrial Informatics* 17(4): 2802-2812.
- Zhou, Z., Y. Wang, X. Xie, L. Chen and H. Liu (2020). RiskOracle: A minute-level citywide traffic accident forecasting framework. *Proceedings of the AAAI conference on artificial intelligence*.
- Zhou, Z., Y. Wang, X. Xie, L. Chen and C. Zhu (2020). "Foresee urban sparse traffic accidents: A spatiotemporal multi-granularity perspective." *IEEE Transactions on Knowledge and Data Engineering* 34(8): 3786-3799.
- 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.
- 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.
- Zhang, S., H. Tong, J. Xu and R. Maciejewski (2019). "Graph convolutional networks: a comprehensive review." *Computational Social Networks* 6(1): 1-23.
- Zhang, Y., X. Dong, L. Shang, D. Zhang and D. Wang (2020). A multi-modal graph neural network approach to traffic risk forecasting in smart urban sensing. *2020 17th Annual IEEE international conference on sensing, communication, and networking (SECON), IEEE*.
- Zhou, F., Q. Yang, K. Zhang, G. Trajcevski, T. Zhong and A. Khokhar (2020). "Reinforced spatiotemporal attentive graph neural networks for traffic forecasting." *IEEE Internet of Things Journal* 7(7): 6414-6428.