پیش‌بینی شدت حوادث ترافیکی در جاده‌های برون‌شهری استان اصفهان با استفاده از شبکه‌های عصبی بازگشتی

مقاله علمی – پژوهشی

فرزاد میرزایی شنتال‌علیا، دانشجوی کارشناسی ارشد، گروه عمران، دانشکده مهندسی، دانشگاه زنجان، زنجان، ایران
امیرمسعود رحیمی*، دانشیار، گروه عمران، دانشکده مهندسی، دانشگاه زنجان، زنجان، ایران
*پست الکترونیکی نویسنده مسئول: amrahimi@znu.ac.ir

دریافت: ۱۴۰۲/۰۸/۰۵– پذیرش: ۱۴۰۳/۰۲/۰۱
صفحه ۱۶۸-۱۵۷

چکیده

تکنیک‌های یادگیری عمیق نقشی مهمی در دنیای مُدرن امروزی ایفا می‌کنند. در سال‌های اخیر شبکه عصبی بازگشتی منجر به تحقیقات گسترده‌ای برای پیش‌بینی سری‌های زمانی شده است. با این حال عملکرد و انتخاب این مدل در پیش‌بینی شدت تصادفات جاده‌ای برون‌شهری در کشور ایران گزارش نشده است لذا این مطالعه تلاش می‌کند تا با در نظر گرفتن وابستگی‌های سری زمانی با استفاده از شبکه عصبی بازگشتی مبتنی بر الگوریتم حافظه طولانی کوتاه‌مدت، جهت پیش‌بینی شدت صدمات رانندگی براساس ۱۰۲۶۹ سوابق تصادفی که از سال ۱۳۹۷ الی آذر ۱۴۰۰ در جاده‌های استان اصفهان رُخ داده است، طراحی و پیاده‌سازی شود. برای انجام این کار چندین معماری و پیکربندی شبکه از طریق جستجوی سیستماتیک شبکه برای تعیین یک شبکه بهینه برای پیش‌بینی شدت آسیب تصادفات ترافیکی مورد آزمایش قرار گرفتند. معماری شبکه انتخاب شده به طور کامل با هفت متغیر مستقل، یک لایه حافظه طولانی کوتاه مدت با ۶۴ گره ورودی و یک لایه خروجی با تابع بیشینه هموار تشکیل شده است. همچنین برای درک مزایا و مقایسه بهتر در این مدل، دو الگوریتم بهینه از جمله الگوریتم گرادیان نزولی تصادفی و الگوریتم بهینه آدام نیز باهم مقایسه شدند به‌طوری که نتایج حاصل از مدل روی شبکه، نشان داد که الگوریتم بهینه آدام بهتر از الگوریتم گرادیان نزولی تصادفی عمل می‌کند چرا که دقت مدل در هنگام استفاده از الگوریتم آدام برابر با ۷۳/۲۶ ٪ شد در حالی که برای الگوریتم گرادیان نزولی تصادفی دقت مدل به ۶۸/۲۰ ٪ رسید. یافته‌های این مطالعه نشان داد که مدل شبکه عصبی بازگشتی در چهارچوب یادگیری عمیق می‌تواند ابزار امیدوارکننده‌ای برای پیش‌بینی شدت تصادفات باشد.

واژه‌های کلیدی: یادگیری عمیق، شبکه عصبی بازگشتی، حافظه طولانی کوتاه مدت، تابع بیشینه هموار، الگوریتم بهینه آدام، الگوریتم بهینه گرادیان نزولی تصادفی

۱-مقدمه

افزایش استفاده از حمل و نقل جاده‌ای، آسیب‌های ناشی از تصادفات را به طور چشمگیری افزایش داده است(Zimmerman, Jinadasa et al. 2015) به طوری که تصادفات ترافیکی به دلیل تلفات جانی و خسارات اقتصادی فراوان، در سراسر جهان به یک نگرانی اصلی تبدیل شده است(Sameen and Pradhan 2017). آمارهای جهانی گویای این مسئله هستند که سالیانه ۱/۳۵ میلیون نفر در اثر تصادفات رانندگی جان خود را از دست می‌دهند و هر ساله ۵۰ میلیون نفر مجروح یا معلول می‌شوند(Organization 2019) اگرچه پیشرفت فناوری در وسایل‌نقلیه باعث رفاه نسبی برای انسان‌ها شده، اما مسئله جدیدی را به نام حوادث جاده‌ای ایجاد کرده است(Bargegol, Gilani et al. 2016). در کشور ما نیز، با توجه به توسعه شدید حمل و نقل جاده‌ای در

مقایسه با توسعه کمتر در سایر سیستم‌های حمل و نقل؛ آلودگی‌های شهری، اتلاف وقت کاربران جاده‌ای و بالاتر از همه خسارات ناشی از تصادفات رانندگی را افزایش داده است. به طوری که طبق گزارش سازمان بهداشت جهانی، سالانه حدود ۲۰ هزار فوتی و حدود ۳۰۰ هزار جراحت در تصادفات جاده‌ای ایران رخ می‌دهد که ٦۹ درصد آن مربوط به تصادفات جاده‌ای برون‌شهری است. به همین دلیل، تصادفات رانندگی در جاده‌های برون‌شهری به عنوان یکی از مسائل چالش برانگیز ایمنی در کشورهای در حال توسعه مانند ایران به حساب می‌آید(Ghasedi, Sarfjoo and Bargegol 2021).

در سال‌های اخیر، هوش مصنوعی در حوزه تحلیل، پیش‌بینی و مدیریت زیرساخت‌های حمل و نقلی، کاربردهای فزاینده‌ای پیدا کرده است(Vujanić, Lipovac et al. 2013). پیش‌بینی شدت تصادفات با استفاده از مدل‌ها، در صورتی که با متدولوژی‌های دارای مبانی علمی انجام گیرد بدون شک می‌تواند به عنوان ابزاری مهم در مدیریت ایمنی راه‌ها و مهندسی حمل و نقل محسوب شود(کی منش and برادران رحمانیان ۲۰۲۱). مدل‌های شدت تصادف از اهمیت بالایی برخوردار هستند(Rezaie Moghaddam, Afandizadeh and Ziyadi 2011) و برای افزایش عملکرد ایمنی سیستم‌های ترافیک جاده‌ای حیاتی می‌باشند. در سال‌های اخیر محققان برای پیش‌بینی شدت تصادفات از مدل‌های متفاوتی استفاده کرده‌اند؛ به طور مثال عبدالوهاب و عبدالعطی از شبکه عصبی مصنوعی برای پیش‌بینی شدت آسیب راننده از عوامل مختلف تصادف (یعنی راننده، وسیله‌نقلیه، جاده و ویژگی‌های محیطی) استفاده کردند. در مطالعه آنها، مدل شبکه عصبی مصنوعی بهتر از مدل پروبیت مرتب شده بود. در پژوهش دیگر، آلخدر و همکارانش از شبکه عصبی مصنوعی برای پیش‌بینی سطوح شدت تصادفات در ابوظبی استفاده کردند. دقت مدل برای داده‌های آموزش و آزمون براساس تجزیه و تحلیل ۵۹۷۳ سوابق تصادفات در یک دوره ٦ ساله به ترتیب ۸۱/٦ و ۷٤/٦ درصد شد. به طور مشابه امیری و همکاران در مطالعه خود برای پیش‌بینی شدت تصادفات جسم ثابت در بین رانندگان مُسن از مدل‌های شبکه عصبی مصنوعی و یک الگوریتم ژنتیک هوشمند ترکیبی استفاده کردند(Shiran, Imaninasab and Khayamim 2021). علاوه بر آن بیشاه و هیل عملکرد مدل‌های درخت تصمیم، بیزی ساده، کی-نزدیک‌ترین همسایه را برای پیش‌بینی شدت تصادفات ارزیابی کردند و نتایج نشان داد که کی-نزدیک‌ترین همسایه دقت بهتری نسبت به سایر مدل‌ها دارد(Shiran, Imaninasab and Khayamim 2021). زنگ و همکاران در سال ۲۰۱۹ در انگلیس از شبکه عصبی کانولوشنال برای پیش‌بینی شدت تصادفات رانندگی استفاده کردند(Zheng, Li et al. 2019). کانت و همکاران در سال ۲۰۱۱ در ایران از مدلسازی الگوریتم ژنتیک، جستجو الگو و شبکه عصبی مصنوعی برای پیش‌بینی شدت تصادفات استفاده کردند. نتایج آنها نشان داد که شبکه عصبی مصنوعی عملکرد بهتری نسبت به مدل‌های دیگر دارد(Kunt, Aghayan and Noii 2011). هائو یوآ و ژنینگ از یک شبکه عصبی کانولوشن تلفیقی برای پیش‌بینی شدت تصادفات استفاده کردند و نتایج رضایت‌بخشی از عملکرد مدل داشتند(Yu, Li et al. 2021).

آبیشک و دیپنجان از شبکه عصبی مصنوعی برای پیش‌بینی تصادفات مرگ‌بار عابرپیاده در تقاطع‌ها استفاده کردند(Chakraborty, Mukherjee and Mitra 2019). سیدمیرسجاد و جیسون سی‌اندرسون از شبکه عصبی مصنوعی و مدل پروبیت سفارشی برای بررسی رابطه غیرخطی بین متغیر وابسته و متغیرهای مستقل استفاده کردند. نتایج حاصل از مقایسه مدل‌ها نشان داد که شبکه عصبی مصنوعی نتایج بهتری را نسبت به روش‌های آماری ارائه می‌دهد(Mokhtarimousavi, Anderson et al. 2020). همچنین جونگک لی و تکوان‌یون در مطالعه خود از روش‌های آماری مانند رگرسیون خطی، رگرسیون لجستیک و رگرسیون دوجمله‌ای منفی که رایج‌ترین روش‌های تحلیل رگرسیون خطی و غیرخطی هستند،

استفاده کردند. همچنین از معماری یادگیری ماشین با استفاده از تکنیک‌های جنگل تصادفی، شبکه عصبی مصنوعی و درخت تصمیم برای تعیین نقاط ضعف و قوت روش‌های آماری استفاده کردند. در نتیجه به این پاسخ رسیدند که مدل جنگل تصادفی و معماری‌های یادگیری ماشین بهتر از روش‌های آماری عمل می‌کند(Lee, Yoon et al. 2019). جینگهوی یوان و محمدعبدالعطی با استفاده از رگرسیون لجستیک و شبکه عصبی بازگشتی برای پیش‌بینی شدت تصادفات استفاده کردند که مقایسه بین آنها نشان داد شبکه عصبی بازگشتی بهتر از رگرسیون لجستیک عمل می‌کند(Yuan, Abdel-Aty et al. 2019). یینینگ کیان و شوجون ژانگ در کشور چین از شبکه عصبی بازگشتی اِلمان برای پیش‌بینی شدت تصادفات استفاده کردند.

نتایج آنها نشان داد که این مدل می‌تواند برای مدلسازی و پیش‌بینی شدت تصادفات مورد استفاده قرار گیرد(Qian, Zhang et al. 2020). سامین و پرادان در سال ۲۰۱۷ در کشور مالزی(Sameen and Pradhan 2017)، یوان و همکاران در سال ۲۰۱۹ در آمریکا(Shaik, Islam and Hossain 2021) هونگلی رن و یوسونگ در کشور چین(Ren, Song et al. 2017) و همچنین رضاپور و همکارانش از شبکه‌های عصبی بازگشتی برای پیش‌بینی شدت تصادفات استفاده کردند.

یافته‌های آنها نشان داد که مدل شبکه عصبی بازگشتی در چهارچوب یادگیری عمیق، می‌تواند ابزار امیدوارکننده‌ای برای پیش‌بینی شدت آسیب تصادفات رانندگی باشد(Rezapour, Nazneen and Ksaibati 2020). به طور کلی در سال‌های اخیر، بسیاری از محققان و پژوهشگران تکنیک‌های مبتنی بر یادگیری عمیق و یادگیری ماشین را در کاربردهای مرتبط با حمل و نقل مانند جریان ترافیک و پیش‌بینی شدت تصادفات به کار برده‌اند(Sameen and Pradhan 2017).

۲ ـ معرفی مدل

مزیت شبکه‌های عصبی یادگیری عمیق نسبت به تکنیک‌های آماری این است که آنها شامل یک فرآیند نقشه‌برداری کلی‌تر هستند، یعنی یک تابع خاص در ساختمان مدل مورد نیاز نیست. با این حال، اگر معماری شبکه به دقت طراحی نشده باشد و پارامترهای آن بهینه نباشند، این تکنیک‌ها را می‌توان به عنوان روش‌های جعبه‌ای سیاه در نظر گرفت. در مقایسه با شبکه‌های عصبی سنتی، شبکه‌های عصبی بازگشتی برای داده‌های متوالی مؤثرتر است و انتظار می‌رود که همبستگی‌های زمانی بین سوابق تصادفات ترافیکی را ثبت کند. شبکه عصبی بازگشتی دسته‌ای از شبکه‌های عصبی مصنوعی هستند که در دهه ۱۹۸۰ توسعه یافتند. این شبکه‌ها، از شبکه‌های عصبی فیدفوروارد با ترکیب بازخورد به لایه‌های قبلی متمایز می‌شوند و به دلیل حافظه داخلی که در خود دارند می‌توانند اطلاعات مهمی را در ورودی به خاطر بسپارند(Sameen and Pradhan 2017). با این حال این شبکه‌ها، معمولاً زمان زیادی می‌برند یا اصلاً خوب کار نمی‌کنند به ویژه وقتی که تأخیر زمانی طولانی است، که ممکن است منجر به انفجار یا ناپدیدشدن گرادیان‌ها شوند. به همین خاطر، هوکرایتر و اشمیدوبر یک معماری شبکه بازگشتی جدید را در ارتباط با یک الگوریتم یادگیری مبتنی بر گرادیان مناسب پیشنهاد کردند که حافظه طولانی کوتاه مدت می‌باشد. این حافظه‌ها، مکانسیم‌های دروازه‌ای برای ذخیره اطلاعات مربوطه برای پیش‌بینی‌های آینده دارند که به صراحت برای جلوگیری از مشکلات وابستگی طولانی مدت، طراحی شده‌اند(Yuan, Abdel-Aty et al. 2019).

شکل ۱ ساختاری از یک حافظه طولانی کوتاه مدت را نشان می‌دهد. طبق شکل مربوطه، واحدهای پنهان با بلوک‌های حافظه جایگزین می‌شوند که شامل یک یا چند سلول حافظه متصل به خود و سه واحد ضربی (ورودی، خروجی، دروازه فراموشی) می‌باشد. این گیت‌ها امکان نوشتن، خواندن و تنظیم مجدد عملیات را در یک بلوک

حافظه فراهم می‌کنند و رفتار کلی را به صورت داخلی کنترل می‌کنند. فرض می‌شود c_t مجموعه ورودی‌ها در مرحله زمانی t باشد پس به‌روزرسانی‌های $LSTM$ برای مرحله زمانی i در ورودی‌های داده شده c_{t-1} و $x_{t,}h_{t-1}$ به صورت زیر می‌باشد:

$$i_t = \sigma(w_{xi}\cdot x_t + w_{hi}\cdot h_{t-1} + w_{ci}\cdot c_{t-1} + b_i) \quad (۱)$$

$$f_t = \sigma(w_{xf}\cdot x_t + w_{hf}\cdot h_{t-1} + w_{cf}\cdot c_{t-1} + b_f) \quad (۲)$$

(۳)

$$c_t = i_t\cdot \tanh(w_{xc}\cdot x_t + w_{hc}\cdot h_{t-1} + b_c) + f_t\cdot c_{t-1}$$

(٤)

$$o_t = \sigma(w_{xo}\cdot x_t + w_{ho}\cdot h_{t-1} + w_{co}\cdot c_t + b_o)$$

$$h_t = o_t\cdot \tanh(c_t) \quad (۵)$$

که در آن σ یک بردار غیرخطی مبتنی بر المان مانند تابع سیگموید است. w ماتریس وزن، x_t ورودی در مرحله زمانی t و β_t نشان‌دهنده بردار تعصب ورودی است(Sameen and Pradhan 2017).

۳ ـ مطالعه موردی و روش تحقیق

برای طراحی و پیاده‌سازی مدل در این مطالعه از داده‌های تصادفات استان اصفهان از سال ۱۳۹۷ الی آذر۱۴۰۰ استفاده شد که از سازمان راهداری و حمل و نقل جاده‌ای کشور گردآوری شده است.

همچنین داده‌های آب و هوایی نیز از سازمان هواشناسی کشور جمع‌آوری شد. به منظور رعایت پیش‌فرض (پیشامد ناسازگار) داده‌های مربوط به حالت هم فوتی و هم مجروح از بانک اطلاعات حذف شدند و شدت تصادفات به سه حالت (فوتی، مجروح، خسارتی) تقسیم شد.

به منظور دستیابی به هدف مطالعه، هفت متغیر مستقل برای ایجاد شبکه شامل موارد: نوع برخورد که دارای شش زیر گروه، علت‌تامه دارای شش زیر گروه، نوع وسیله‌نقلیه دارای ۸ زیر گروه، بارش باران در چهار حالت بر حسب میلی‌متر، سرعت وزش باد در سه حالت بر حسب مایل، دید افقی در سه حالت برحسب متر و محل سانحه دارای سه زیرگروه به ساختار مدل وارد شدند. جدول ۱ متغیرهای مستقل را براساس زیرگروه آنها نشان می‌دهد.

شکل ۲ معماری پیشنهادی برای مدل پیش‌بینی شدت تصادفات، براساس یادگیری عمیق باتوجه به ورودی متغیرها و خروجی شبکه را نشان می‌دهد.

برای پردازش سریع‌تر شبکه عصبی بازگشتی ابتدا داده‌ها طبقه‌بندی شده به طوری که برای انجام این کار از روش *one-hot* استفاده گردید که از کتابخانه *sklearn* سرچشمه می‌گیرد. سپس برای ساخت شبکه از کتابخانه معروف هوش مصنوعی در حوزه یادگیری عمیق یعنی *tensorflow* کمک گرفته شد که قسمتی از کد مربوط به ساختار شبکه با استفاده از کتابخانه *tensorflow* به شکل زیر می‌باشد.

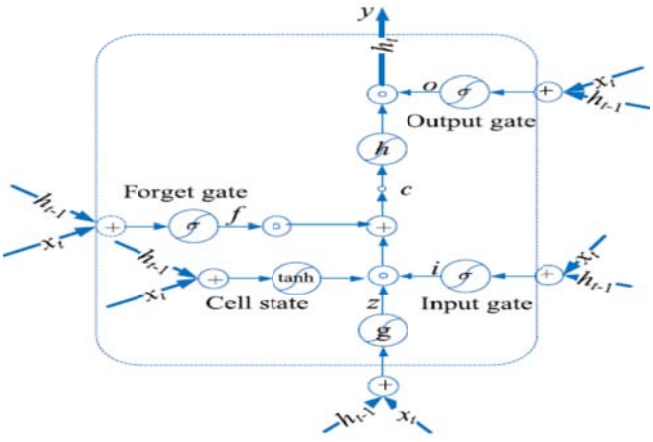

شکل ۱. ساختار حافظه طولانی کوتاه مدت (Bai, Xie et al. 2021)

جدول ۱. متغیرهای ورودی

علت تصادف	*نوع برخورد*
۱- عدم توانایی در کنترل وسیله نقلیه ۲- عدم هوشیاری راننده ۳- عدم توجه به جلو ٤- عدم رعایت مسیر یا فاصله ایمن ٥- تخطی از سرعت مطمئنه ٦-سایر	۱- واژگونی و سقوط ۲- وسیله‌نقلیه با شی ثابت ۳- وسیله‌نقلیه با چند وسیله ٤- هرنوع وسیله‌ای با وسایل دوچرخ ٥- جانداران ٦- وسیله‌نقلیه با یک وسیله
دید افقی	*بارش باران*
۱-ضعیف ۲-خوب ۳-عالی	۱-بی بارش ۲-ملایم ۳-متوسط ٤-سنگین
سرعت باد	*محل سانحه*
۱-ملایم ۲-متوسط ۳-سنگین	۱- تقاطع‌ها ۲- قطعه عادی راه ۳-سایر
نوع وسیله‌نقلیه	
۱- سواری ۲- بارکش سنگین ۳- بارکش سبک ٤- مسافری سنگین ٥- ماشین‌آلات کشاورزی ٦- وسایل دوچرخ ۷-جانداران ۸-سایر	

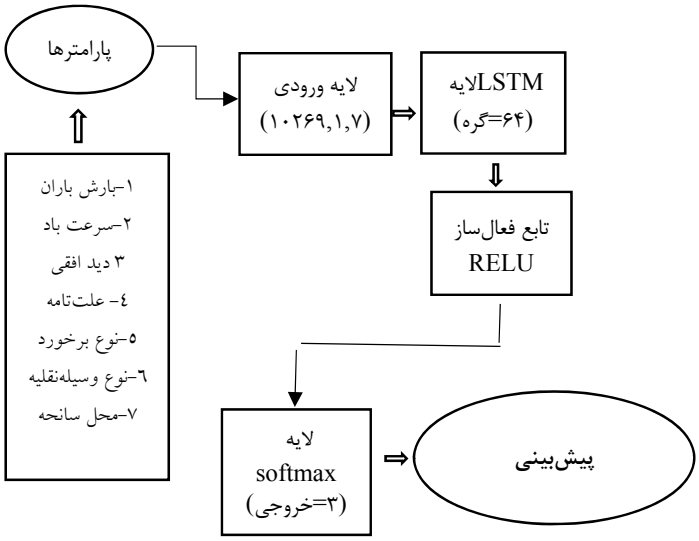

شکل ۲. معماری پیشنهادی

```
model = tensorflow.keras.models.Sequential([    tensorflow.keras.layers.LSTM(64,
        activation='relu',          return_sequences=False),
        tensorflow.keras.layers.Flatten(),
        tensorflow.keras.layers.Dense(3, 'softmax')])

model.compile (loss = 'categorical_crossentropy',  optimizer = 'adam', metrics='acc')

history = model.fit(rnn_data, severity,    batch_size=110, epochs=90,      validation_split=0.15)
```

٤ ـ تحلیل ساختار کد شبکه

ورودی اصلی شبکه مجموعه‌ای از عوامل مرتبط با تصادفات ترافیکی است و خروجی آن، کلاس‌های شدت تصادفات می‌باشد که شامل سه کلاس از جمله فوتی، جرحی و خسارتی می‌باشد. بعد ورودی لایه *LSTM* برابر با هفت فاکتور با ٦٤ گره و خروجی هر گره در لایه *LSTM* از تابع فعال‌ساز واحد خطی اصلاح شده است. این تابع در مقایسه با توابع تانژانت هیپرلیک و سیگموئید، همگرایی شیب تصادف نزولی را سرعت می‌بخشد. در حقیقت اگر در شبکه‌های عصبی بزرگ‌تر به جای تابع سیگموید از تابع *ReLU* استفاده کنیم، سرعت مدل‌سازی بیشتر خواهد بود، به عبارت دیگر مدت زمان مدل‌سازی کم می‌شود. لایه خروجی یک لایه کاملاً متصل به جلو می‌باشد و برای ترسیم مستقیم ویژگی‌های آموخته شده به سه کلاس شدت تصادف تقسیم می‌شود. این لایه شامل یک تابع بیشینه هموار است که برای فعال کردن لایه خروجی استفاده شد. این شبکه با الگوریتم پس‌انتشار خطا در طول زمان و الگوریتم‌های *SGD* و *ADAM* در *Tensorflow* بر روی یک سیستم *CPU* شخصی (*core i7*, *ram* 8) آموزش داده شده است.

٤-۱- دقت مدل

به طور کلی آزمون صحیح خطا جهت بدست آوردن بهترین مقدار پیش‌بینی یکی از روش‌های ممکن می‌باشد. جدول ۲ و ۳ دقت مدل را در آزمون‌های مختلف با الگوریتم‌های *SGD* و *ADAM* نشان می‌دهد. باتوجه به ساختار شبکه و متغیرهای ورودی طبق جدول ۳، بهترین دقت مدل جهت پیش‌بینی پیامدهای تصادف در استان اصفهان، ۷۳/۲٦ ٪ با الگوریتم *ADAM* می‌باشد.

جدول ۲. دقت مدل با الگوریتم *SGD*

Validation	*Batch size*	*epochs*	*Radom state*	*Accuracy*
0.2	128	100	45	66.99
0.2	110	100	50	64.95
0.2	105	100	42	65.38
0.15	90	85	30	68.20

جدول ۳. دقت مدل با الگوریتم *ADAM*

Validation	*Batch size*	*epochs*	*Radom state*	*Accuracy*
0.2	128	100	45	69.28
0.2	100	100	50	70.67
0.2	105	100	40	70.52
0.15	110	90	32	73.26

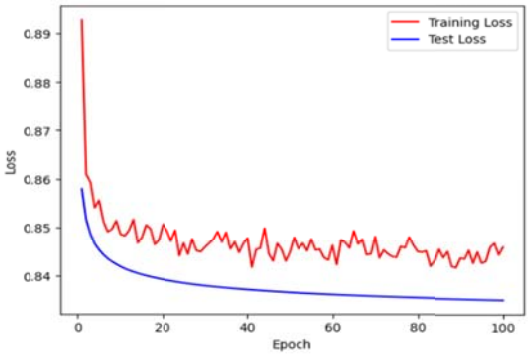

شکل ۳. میزان خطا برای آزمون ۱

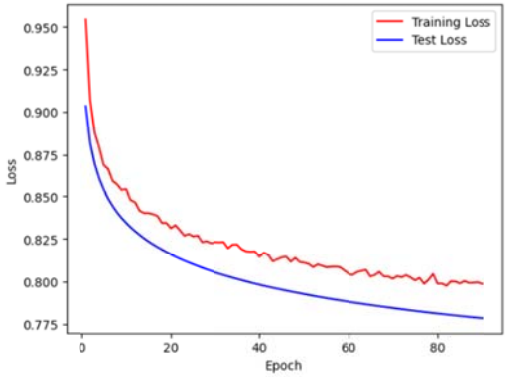

شکل ٦. میزان خطا برای آزمون ٤

٤-٢- نمودار میزان خطا مدل‌های تست شده با تابع بهینه SGD

با توجه به جدول ۲ که دقت مدل پیش‌بینی را نشان می‌دهد، نمودارهای مربوطه آنها، طبق خطای داده‌های آموزشی و داده‌های اعتبارسنجی به ترتیب در شکل‌های ۳، ٤، ٥ و ٦ نشان داده شد.

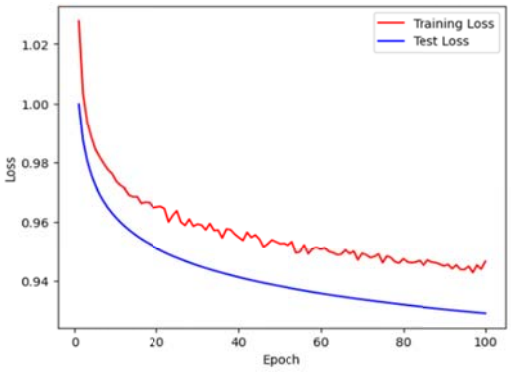

شکل ٤. میزان خطا برای آزمون ۲

٤-٣- نمودار میزان خطا مدل‌های تست شده با تابع بهینه ADAM

شکل‌های ۷، ۸، ۹ و ۱۰ نیز نمودارهای مربوط به الگوریتم بهینه ADAM را نشان می‌دهد.

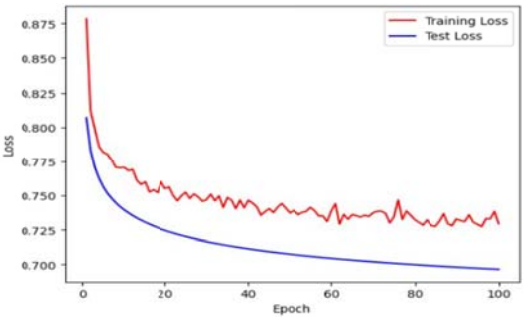

شکل ٥. میزان خطا برای آزمون ۳

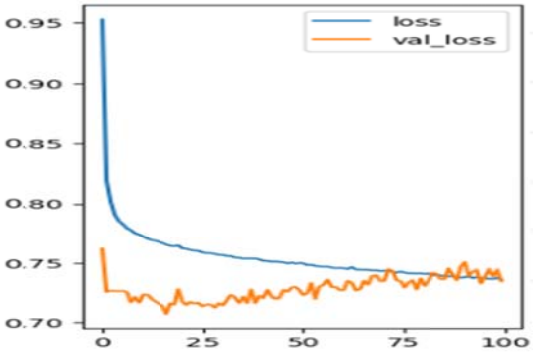

شکل ۷: میزان خطا برای آزمون ۱

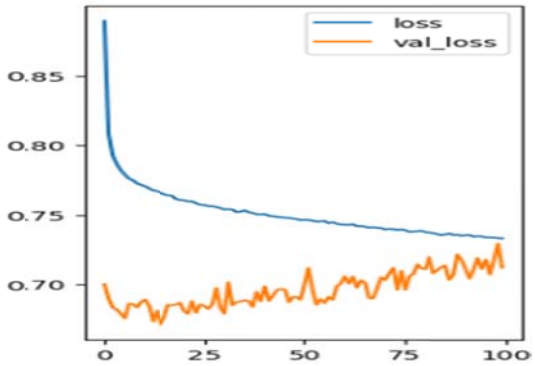

شکل ۸: میزان خطا برای آزمون ۲

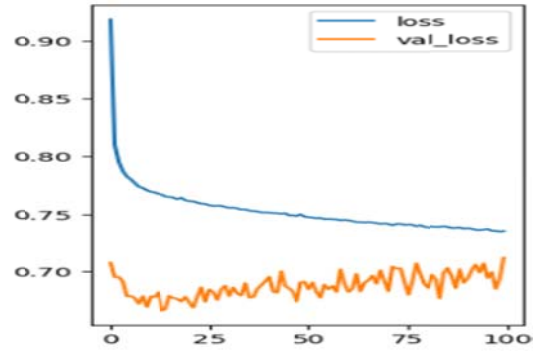

شکل ۹: میزان خطا برای آزمون ۳

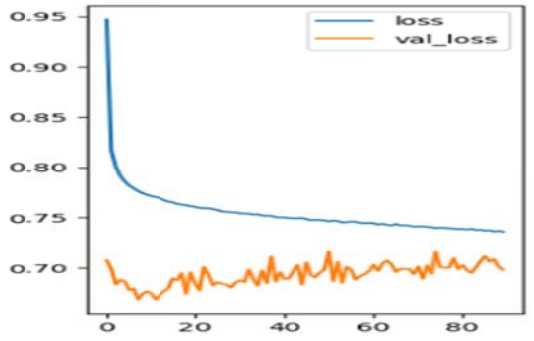

شکل ۱۰. میزان خطا برای آزمون ٤

٤-٤- تحلیل نمودارهای SGD و ADAM

انتخاب الگوریتم بهینه‌سازی مناسب برای مدل یادگیری عمیق بسیار مهم است و تأثیر زیادی روی زمان رسیدن به نتیجه مطلوب دارد. الگوریتم بهینه سازی *ADAM* نسخه تعمیم یافته‌ای از الگوریتم گرادیان نزولی تصادفی به حساب می‌آید که به تازگی برای کاربردهای یادگیری عمیق به طور گسترده‌تری به کار گرفته شده است. باتوجه به شکل‌های ۳ الی ۱۰ که از دو الگوریتم بهینه استفاده شده است می‌توان این مسئله را اینگونه بیان کرد که گرادیان نزولی تصادفی یک نرخ یادگیری واحد (به نام آلفا) را برای تمام به‌روزرسانی وزن‌ها حفظ می‌کند و این نرخ یادگیری در طول فرآیند آموزش مدل تغییر نمی‌کند. در حالی که در الگوریتم آدام، نرخ یادگیری برای هریک از وزن‌های شبکه (پارامترها) حفظ می‌شود و این نرخ با شروع فرآیند یادگیری به صورت جداگانه تطبیق داده می‌شود. باتوجه به شکل ۱۰ که مناسب‌ترین درصد پیش‌بینی و همچنین کمترین خطا مدل را نشان می‌دهد گویای این مسئله است که الگوریتم آدام بهتر از الگوریتم گرادیان نزولی تصادفی می‌باشد و بی‌جهت نیست که امروزه از محبوبیت بالایی برخوردار است این در حالی است که در هنگام استفاده از الگوریتم گرادیان نزولی تصادفی باتوجه به شکل ۳، درصد خطای مدل، رفته رفته در حال افزایش است و این مسئله باعث کاهش دقت مدل می‌گردد.

٥-نتیجه‌گیری

نتایج حاصل از شکل ۱۱ (باتوجه به بزرگی شکل و تعداد زیاد متغیرها، شکل به دو قسمت تقسیم شده است). همچنین محور افقی نوع متغیرها و محور عمودی میزان تاثیر متغیر بر شدت تصادفات را نشان می‌دهد تاثیر هرکدام از متغیرها بر شدت تصادفات را نشان می‌دهد. این مسئله گویای این که بارکش‌های سنگین، وسیله‌نقلیه سواری و موتورسیکلت اثر قابل توجهی بر شدت تصادفات دارند به طوری که رانندگان این وسایل‌نقلیه در صورت تخطی از سرعت مطمئنه، عدم توجه به جلو و عدم رعایت فاصله ایمن، پیامدهای ناگواری را ایجاد می‌کنند. متغیر نوع برخورد که به نوبه خود دارای سطح معناداری می‌باشد، نشان می‌دهد که در صورت برخورد وسیله‌نقلیه جانداران (عابر و حیوان) و برخورد هرنوع وسیله‌نقلیه‌ای به موتورسیکلت باعث افزایش شدت تصادفات خواهد شد.

این مسئله گویای این است کـه همـواره موتورسـواران از خطـر جدی برخوردار هستند. در مواقع بارانی (سطح خیس) رانـندگان به دلیل ازدحام ترافیک سرعت خود را کاهش داده چرا که از دید خوبی برخوردار نیستند در نتیجـه میـزان شـدت آسـیب رانـنده، کاهش می‌یابد. در حالی که اگر شرایط جوی به نحوه‌ای باشد که رانندگان دید خوبی داشته باشند و سطح روسازی خشـک باشـد (بدون بارش)، رانندگان با توجه به این شرایط میل به سرعت بالا و سبقت‌های غیرمجاز داشته و در ایـن صـورت باعـث افـزایش شدت تصادفات و آسیب به رانندگان می‌شود. به طور کلی نتـایج حاکی از آن است، هنگامی که نوع وسیله‌نقلیـه سـواری، بـارکش سنگین و موتورسـیکلت در تصـادفات درگیـر باشـند و شـرایط جوی دارای دید خوب و سطح خشک باشد، رانندگان ایـن نـوع وسایل‌نقلیه بیشتر از وسایل‌نقلیه بارکش سبک و مسافری سـنگین در معرض خطر هستند.

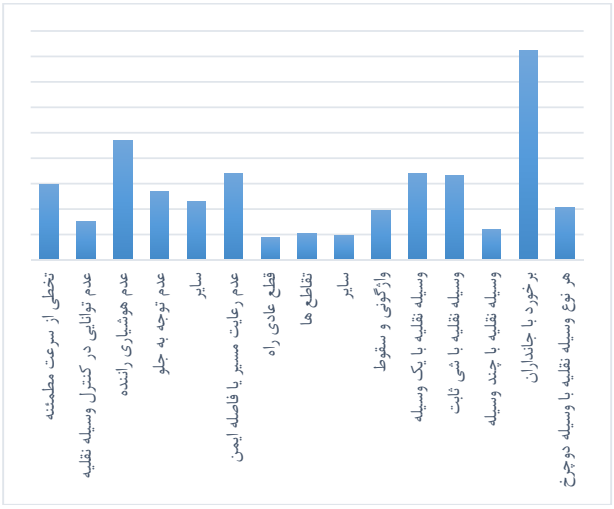

شکل ۱۱. تأثیر هرکدام از متغیرها بر شدت تصادفات

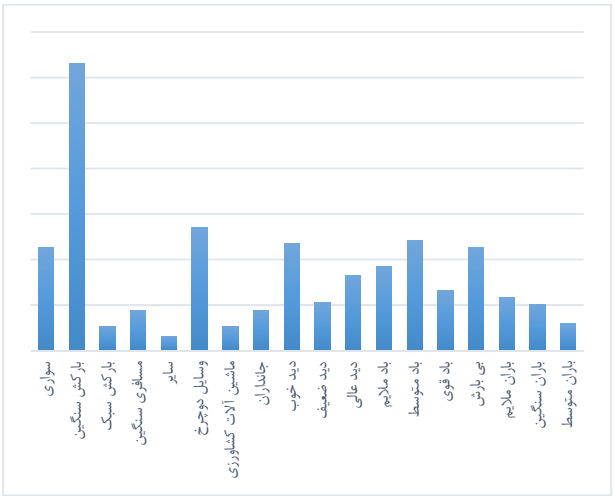

ادامه شکل ۱۱. تأثیر هرکدام از متغیرها بر شدت تصادفات

مقایسه نتایج با پژوهش‌های پیشین

بررسی نتایج بدست آمده با نتایج پژوهش‌های پیشین میزان اعتبارسنجی، دقت انجام کار و نوآوری بدست آمده از این پژوهش را نشان می‌دهد. این نتایج شامل موارد زیر می‌باشند:

الف: دقت مدل پژوهش ماهر ابراهیم و همکارش با استفاده از مدل شبکه عصبی بازگشتی ۷۱/۷۷ ٪ بود در حالی که این پژوهش با مدل شبکه عصبی بازگشتی مبتنی بر الگوریتم حافظه طولانی کوتاه مدت انجام شد و دقت مدل به ۷۳/۲۶ ٪ رسید که این مسئله به نوبه خود باعث نوآوری پژوهش شد و نیز منجر به بهینه شدن دقت مدل گردید.

ب: سطح خشک (بی‌بارش) نسبت به سطح مرطوب خطرناک‌تر است و اثر قابل توجهی بر شدت تصادفات دارد که منطبق با نتیجه حاصل از پژوهش ماهر ابراهیم و همکارش می‌باشد.

پ: رانندگان وسایل‌نقلیه موتورسیکلت و وسایل‌نقلیه سواری بیشتر از وسایل‌نقلیه مسافری سنگین در معرض آسیب احتمالی فوت هستند. این نتیجه نیز منطبق بر نتیجه حاصل از پژوهش ماهر ابراهیم و همکارش می‌باشد.

ت: عدم دید کافی باعث احتیاط رانندگان و کاهش پیامدهای احتمالی می‌شود که این نتیجه منطبق با نتایج پژوهش وهاب و جیانگ در سال ۲۰۱۹ می‌باشد.

٦- مراجع

- برادران رحمانیان و کی منش، محمودرضا (۲۰۲۱). پیش بینی شدت تصادفات جاده‌ای با استفاده از شبکه عصبی مصنوعی و مقایسه آن با روش آنالیز چند متغیره. *نشریه جاده*، دوره ۲۹، شماره(۱۰٦)، ۱-۱۰.

-Afandizadeh, M. Ziyadi Rezaie Moghaddam, F. (2011). Prediction of accident severity using artificial neural networks. *International Journal of Civil Engineering*, 9(1): 41-48.

-Aghayan, Kunt and N. Noii (2011). Prediction for traffic accident severity: comparing the artificial neural network, genetic algorithm, combined genetic algorithm and pattern search methods. *Transport* 26(4): 353-366.

-Anderson, A. Mokhtarimousavi, Azizinamini and M. Hadi (2020). Factors affecting injury severity in vehicle-pedestrian crashes: A day-of-week analysis using random parameter ordered response models and Artificial Neural Networks. *International Journal of Transportation Science and Technology,* 9(2): 100-115.

-Antić, Jovanović, Lipovac, Vujanić and Pešić (2013). Bottom-Up" and" Top-Down" Approach for Defining Road Safety Strategy-Case Study: City of Belgrade. *International Journal for Traffic & Transport Engineering*, 3(2).

-Abdel-Aty, Cai, Gong and Yuan, J (2019). Real-time crash risk prediction using long short-term memory recurrent neural network. *Transportation Research Record,* 2673(4): 314-326.

-B. Pradhan and Sameen, M. I. (2017). Severity prediction of traffic accidents with recurrent neural networks. *Applied Sciences,* 7(6): 476.

-Bai, Y., J. Xie, C. Liu, Y. Tao, B. Zeng and C. Li (2021). Regression modeling for enterprise electricity consumption: A comparison of recurrent neural network and its variants. *International Journal of Electrical Power & Energy Systems*, 126: 106612.

-Bargegol, I., V. N. M. Gilani, M. Ghasedi and M. Ghorbanzadeh (2016). Delay modeling of un-signalized roundabouts using neural network and regression. *Computational Research Progress in Applied Science & Engineering,* 2(1): 28-34.

-Chakraborty, A., D. Mukherjee and S. Mitra (2019). Development of pedestrian crash prediction model for a developing country using artificial neural network. I*nternational Journal of Injury Control and Safety Promotion,* 26(3): 283-293.

-Chen, Cui, Zheng, Li, Zhu, M., Ma, Tang, and Wang (2019). Traffic accident's severity prediction: A deep-learning approach-based CNN network. *IEEE Access,* 7: 39897-39910.

-Ghasedi, M., M. Sarfjoo and I. Bargegol (2021). Prediction and analysis of the severity and number of suburban accidents using logit model, factor analysis and machine learning: a case study in a developing country. *SN Applied Sciences*, 3(1):1-16.

-Hossain, Islam and Shaik, M. E. (2021). A review on neural network techniques for the prediction of road traffic accident severity. *Asian Transport Studies 7,*100040.

-Lee, J., T. Yoon, S. Kwon and J. Lee (2019). Model evaluation for forecasting traffic accident severity in rainy seasons using machine learning algorithms: Seoul city study. *Applied Sciences*, 10(1): 129.

crashes. *Analytic Methods in Accident Research*, 30: 100157.

-Guerrero, Jinadasa, Maegga and Zimmerman, K. (2015). Road traffic injury on rural roads in Tanzania: measuring the effectiveness of a road safety program. *Traffic Injury Prevention,* 16(5): 456-460.

-Organization, W. H. (2019). Global status report on alcohol and health 2018, World Health Organization. Qian, Y., X. Zhang, G. Fei, Q. Sun, X. Li, L. Stallones and H. Xiang (2020). Forecasting deaths of road traffic injuries in China using an artificial neural network. Traffic injury Prevention, 21(6): 407-412.

-K. Ksaibati, S. Nazneen and Rezapour, M. (2020). Application of deep learning techniques in predicting motorcycle crash severity. *Engineering Reports* 2(7): e12175.

-Khayamim Imaninasab and Shiran, G.(2021). Crash Severity Analysis of Highways Based on Multinomial Logistic Regression Model, Decision Tree Techniques, and Artificial Neural Network: A Modeling Comparison. *Sustainability*, 13(10): 5670.

- Liu, Y. Hu and J. Lei ,Ren, H., Y. Song, J. (2017). A deep learning approach to the prediction of short-term traffic accident risk. *arXiv preprint arXiv,*1710.09543.

-G. Zhang,T. Ma, Yu, H., P. Liu and Z. Li, (2021). Fusion convolutional neural network-based interpretation of unobserved heterogeneous factors in driver injury severity outcomes in single-vehicle

Prediction of Traffic Accidents on Suburban Roads Isfahan Province Using Recurrent Neural Networks

Farzad Mirzaei Shenatalolia, M.Sc., Student, Civil Engineering Department, Faculty of Engineering, University of Zanjan, Zanjan, Iran.

Amir Masoud Rahimi, Associate Professor, Civil Engineering Department, Faculty of Engineering, University of Zanjan, Zanjan, Iran.

E-mail: amrahimi@znu.ac.ir

Received: February 2024- Accepted: June 2024

ABSTRACT

Deep learning techniques play crucial role in today's modern world. In recent years, the recurrent neural network has led to extensive research for predicting time series. However, the performance and selection of this model in predicting the severity of extra-urban road accidents in Iran has not been reported, so this study tries to take into account time series dependencies using recurrent neural network. Based on long-short-term memory algorithm, to predict the severity of driving injuries based on 10,269 random records that occurred on the roads of Isfahan province from 2018 to December 2021, it should be designed and implemented. To do this, several network architectures and configurations were tested through a systematic grid search to determine an optimal network for predicting the injury severity of traffic accidents. The selected network architecture is fully composed of seven independent variables, a long-short-term memory layer with 64 input nodes, and an output layer with a softmax function. Also, in order to understand the advantages and better comparison in this model, two optimal algorithms including the random gradient descent algorithm and Adam's optimal algorithm were also compared, So that the results of the model on the network showed that Adam's optimal algorithm works better than the random gradient descent algorithm because the accuracy of the model when using Adam's algorithm is equal to It became 73.26%, while for the random gradient descent algorithm, the accuracy of the model reached 68.20%. The findings of this study showed that the recurrent neural network model in the framework of deep learning can be a promising tool for predicting the severity of accidents.

Keywords: Deep Learning, Recurrent Neural Network, Long-Short-Term Memory, Softmax, Adam's Optimal Algorithm, Stochastic Gradient Descent Algorithm