

تعیین تابع آموزش مناسب مدل شبکه عصبی به منظور ارتقاء ایمنی

تردد جاده‌ای

مقاله پژوهشی

ابوالفضل خویشداری، دانش آموخته کارشناسی ارشد، دانشکده مهندسی عمران، دانشگاه یزد، یزد، ایران
حامد خانی سانجی*، استادیار، دانشکده مهندسی عمران، دانشگاه یزد، یزد، ایران
جواد ذاکر هرفته، دانش آموخته کارشناسی ارشد، دانشکده مهندسی عمران، دانشگاه پیام‌نور رضوانشهر، یزد، ایران
محسن دهقان بنادکی، دانش آموخته کارشناسی ارشد، دانشکده مهندسی عمران، دانشگاه آزاد اسلامی واحد بافق، یزد، ایران
*پست الکترونیکی نویسنده مسئول: khani@yazd.ac.ir

دریافت: ۹۹/۰۵/۲۷ - پذیرش: ۹۹/۱۰/۰۵

صفحه ۵۰-۳۵

چکیده

سالانه تعداد زیادی از مردم دنیا در اثر تصادفات جاده‌ای جان و مال خود را از دست می‌دهند. یکی از روش‌های مناسب به منظور کاهش تصادفات، پیش‌بینی وقوع تصادفات قبل از رخداد آن‌ها می‌باشد. در این مقاله به‌طور موردی تصادفات محور نائین-اردکان استان یزد با بهره‌گیری از مدل شبکه عصبی مورد ارزیابی قرار گرفت. تاکنون در هیچ مطالعه‌ای به بررسی تاثیر توابع مختلف آموزش مدل شبکه عصبی در دقت نتایج پیش‌بینی پرداخته نشده است. هدف این مقاله تعیین تابع آموزش دقیق‌تر شبکه عصبی به منظور پیش‌بینی تعداد تصادفات محور مورد بررسی بود. در این راستا تعداد ۸ تابع مختلف ارزیابی گردید. بررسی‌های این مقاله حاکی از برتری نسبی مدل شبکه عصبی با تابع آموزش از نوع trainlm بود. همچنین نتایج نشان داد که عوامل میزان تردد در هر خط و عدم رعایت فاصله ایمن به ترتیب بیشترین تأثیر را در وقوع تصادفات محور مورد مطالعه داشتند. کاربرد نتایج تحقیق در بیان دقیق‌تر اثر متغیرهای مستقل در وقوع تصادفات است. به بیان دقیق‌تر تاثیرگذاری متغیرهای مستقل می‌تواند به کارشناسان ایمنی جهت اعمال بهینه‌تر سناریوهای کاهش تصادفات کمک کند.

واژه‌های کلیدی: شبکه عصبی، تابع آموزش، پیش‌بینی، تعداد تصادفات

۱- مقدمه

۲۳٪ زن بوده‌اند (WHO, 2015). همچنین مطابق با آمار ۶ ماهه نخست سال ۱۳۹۵ مربوط به سازمان پزشکی قانونی کشور آمار متوفیان و مصدومان تصادفات کشور با لحاظ فاصله زمانی تصادف تا فوت برابر با ۳۰ روز، به ترتیب برابر با ۸۷۹۶ نفر و ۱۷۸۸۷ نفر بوده است که نسبت به بازه زمانی مشابه در سال ۱۳۹۴ به ترتیب رشد ۲/۳- درصدی و ۷/۲ درصدی داشته است (سازمان پزشکی قانونی کشور، ۱۳۹۵). علی‌رغم کاهش تصادفات فوتی باید توجه نمود که باز هم آمار متوفی تصادفات خصوصاً در مقایسه با سایر کشورهای دنیا زیاد است. هرچند متأسفانه آمار مصدومان نیز افزایش داشته است. تاکنون تلاش‌های گسترده‌ای توسط

سالانه شاهد سفر تعداد زیادی از وسایل نقلیه در شریان‌های جاده‌ای کشور هستیم. سفرهای صورت پذیرفته عمدتاً منشأ کاری و تفریحی دارند. یکی از مهم‌ترین مسائل مرتبط با راه‌های هر کشور، تأمین ایمنی تردد وسایل نقلیه از معابر موردنظر می‌باشد. متأسفانه علی‌رغم تلاش‌های نسبی مسئولین در خصوص ارتقاء ایمنی تردد وسایل نقلیه، سالانه شاهد آمار بالای تصادفات جاده‌ای هستیم که به سبب آن تعداد زیادی از هم‌میهنان جان و مال خود را ازدست‌داده‌اند. طبق جدیدترین آمار سازمان بهداشت جهانی در خصوص کشور ایران، در سال ۲۰۱۴ میلادی تعداد ۱۷۹۹۴ نفر در اثر تصادف جان خود را ازدست‌داده‌اند. از این تعداد ۷۷٪ مرد و

رگرسیون پواسون فرض بر مساوی بودن میانگین و انحراف استاندارد مقادیر مشاهدات تصادفات می‌باشد. فرض فوق عموماً رد می‌گردد. در مقابل مدل‌های رگرسیون دوجمله‌ای منفی با تأثیر دادن پارامتر پیش‌پراکندگی موجب بهبود فرایند مدل‌سازی می‌گردند و این محدودیت این فرض را ندارند. این دو مدل تاکنون توسط محققین زیادی مورد استفاده قرار گرفته است (Li, Wang, Gustavsson and Svensson, 1976; Liu, Bigham, and Ragland, 2013; Lord, Manar, and Vizioli, 2005; Meng and Qu, 2012; Milton and Mannering, 1998; Pirdavani, Brijs, Bellemans, Kochan, and Wets, 2013; Ye, Pendyala, Shankar, and Konduri, 2013).

یکی از ایراداتی که به مدل‌های رگرسیون پواسون و دوجمله‌ای منفی وارد است، عدم در نظر گرفتن شرایط وقوع تصادفات صفر است. بنابراین زمانی که تصادفات صفر در مقاطع و یا تقاطعات مورد بررسی داشته باشیم، خطای مدل‌سازی بیشتر می‌گردد. برای جلوگیری از این خطا در مدل‌سازی، از مدل‌های رگرسیونی پواسون با رشد صفر و رگرسیون دوجمله‌ای منفی با رشد صفر استفاده می‌گردد (Lee and Mannering, 2002; Kumara and Chin, 2003; Lord, Washington, and Ivan, 2005; Malyskhina and Mannering, 2010; Miaou, 1994). بررسی‌های محققین نشان داده است که شبکه‌های عصبی نیز می‌توانند به صورت بالقوه به منظور پیش‌بینی تعداد تصادفات به وقوع پیوسته در مقاطع راه مورد استفاده قرار بگیرند (Abdelwahab and Bayata, Hattatoglu, and Karsli, 2011; Abdel-Aty, 2001; Chang, 2005; Mark Dougherty, 1995).

کاربرد شبکه‌های عصبی در مهندسی حمل‌ونقل از دیرباز دارای جایگاه ویژه‌ای بوده است. از جمله این تلاش‌ها می‌توان به شناخت رفتار رانندگی و سیستم‌های اطلاعاتی هوشمند سفر وسایل نقلیه (M Dougherty and Joint, 1992; Yang, Kitamura, Jovanis, Vaughn, and Abdel-Aty, 1993). پیش‌بینی رخداد برخورد وسایل نقلیه در آزادراه‌ها (S. G Stephen G. Ritchie and Cheu, 1993; Ritchie, Cheu, and Recker, 1992; Zhang and Ritchie, 1997) پیش‌بینی و بررسی وضعیت ترافیکی معابر و تقاطعات درون‌شهری (M Burattini and De Gregorio, 1998) ارزیابی فاصله مابین دو وسیله نقلیه در تقاطعات چراغ‌دار (Pant, Fischer and Gopal, 1994) کاربرد در مقوله کاربری زمین (Rodrigue, 1997) اشاره نمود. یکی از کاربرد

ادارات راه و حمل‌ونقل جاده‌ای صورت پذیرفته است. با رشد روزافزون تردد از محورهای جاده‌ای و تقاضای سفر اقشار مختلف جامعه، اهمیت تأمین ایمنی تردد وسایل نقلیه اهمیت دوچندان دارد. یکی از راه‌های مناسب به منظور جلوگیری و کاهش تصادفات جاده‌ای، استفاده از تکنیک مدل‌سازی تصادفات به منظور شناخت مهم‌ترین عوامل تأثیرگذار در بروز تصادفات از میان چند عامل مورد بررسی است. هدف از این تحقیق بررسی مدل مناسب شبکه عصبی پیش‌خور به منظور ارتقاء ایمنی تردد تصادفات بر مبنای تعیین الگوریتم آموزش مناسب شبکه عصبی می‌باشد. بدین منظور در این تحقیق سعی گردید تا تعداد ۴ مورد از توابع رایج آموزش شبکه عصبی مورد بررسی و مقایسه قرار گیرند. روش به کار گرفته شده در این تحقیق می‌تواند منجر به شناخت هرچه دقیق‌تر عوامل مؤثر در بروز تصادفات گردد. قابل‌ذکر است، با توجه به اینکه هدف از مدل‌سازی تعیین تأثیرگذاری عوامل مختلف در بروز تصادفات می‌باشد، هرچه سطح دقت مدل‌سازی بیشتر باشد، بیان اهمیت تأثیر عوامل مختلف در رخداد تصادفات با دقت بیشتری صورت می‌گیرد که هدف اصلی این تحقیق نیز همین موضوع می‌باشد. آمار سازمان پزشکی قانونی بیانگر این مطلب است که استان یزد حدود ۱/۳۲٪ از تصادفات فوتی و ۲/۲۲٪ از مصدومان تصادفات را به خود اختصاص داده است (سازمان پزشکی قانونی کشور، ۱۳۹۵).

در این تحقیق به‌طور موردی محور نائین - اردکان استان یزد مورد بررسی قرار گرفت. در این راستا آمار یک‌ساله محور فوق مورد بررسی قرار گرفت و تصادفات محور فوق به همراه عوامل تأثیرگذار در بروز تصادفات مورد برداشت قرار گرفت. در ادامه سعی گردید تا با بهره‌گیری از مدل شبکه عصبی پیش‌خور، تعداد تصادفات محور فوق بر مبنای سایر عوامل تأثیرگذار مورد ارزیابی قرار گیرد.

۲- پیشینه تحقیق


تاکنون روش‌های مختلفی به‌منظور ارزیابی تعداد تصادفات به وقوع پیوسته در معابر مختلف درون‌شهری و برون‌شهری مورد استفاده گردیده است. مدل رگرسیون پواسون و دوجمله‌ای منفی ساده‌ترین نوع مدل‌های تصادفات می‌باشد که از دیرباز مورد استفاده محققین قرار گرفته است. در مدل

شبکه‌های عصبی، استفاده از آن به منظور پیش‌بینی تعداد و شدت تصادفات جاده‌ای می‌باشد. لیکن در این تحقیق از شبکه عصبی به منظور پیش‌بینی تعداد تصادفات استفاده گردید. مطالعات پیش‌بینی تصادفات نشان داده است که شبکه‌های عصبی دارای برتری نسبی نسبت به مدل‌هایی نظیر رگرسیون پواسون، دوجمله‌ای منفی، رگرسیون پواسون با رشد صفر و رگرسیون دوجمله‌ای منفی با رشد صفر هستند (Chang, 2005). اخیراً نیز تحقیقاتی در رابطه با استفاده از شبکه‌های عصبی مصنوعی در ارتقاء ایمنی راه‌ها انجام شده است. در تحقیقی با استفاده از شبکه‌های عصبی مصنوعی ارتباط غیرخطی میان تعداد تصادفات و فاکتورهای ریسک وقوع تصادفات مورد بررسی قرار گرفت. بررسی‌های این تحقیق نشان داد که استفاده از مدل شبکه عصبی پس از بهینه‌سازی و رفع خطاهای احتمالی آن، گزینه مناسب‌تری جهت پیش‌بینی تصادفات در مقایسه با مدل دوجمله‌ای منفی است (Zeng et al., 2016). در پژوهشی دیگر کاربرد مدل‌های شبکه عصبی در شناسایی فاکتورهای ریسک وقوع تصادفات در تقاطعات درون‌شهری مورد بررسی قرار گرفت. در این تحقیق علاوه بر مدل شبکه عصبی مصنوعی، مدل رگرسیون خطی تعمیم یافته نیز مورد استفاده قرار گرفت. بررسی‌های این مقاله نشان داد که عامل تردد، مهم‌ترین فاکتور تاثیرگذار در ریسک تصادفات تقاطعات درون‌شهری عامل تردد وسایل نقلیه است (Mussone, Bassani and Masci, 2017). البته برخی دیگر مطالعات نشان داده است که عامل تردد وسایل نقلیه از اهمیت بالایی برخوردار است (Gargoum, El-Basyouny, and Kim, 2016; Shi, Abdel-Aty, and Lee, 2016; Theofilatos and Yannis, 2014).

شبکه‌های عصبی، استفاده از آن به منظور پیش‌بینی تعداد و شدت تصادفات جاده‌ای می‌باشد. لیکن در این تحقیق از شبکه عصبی به منظور پیش‌بینی تعداد تصادفات استفاده گردید. مطالعات پیش‌بینی تصادفات نشان داده است که شبکه‌های عصبی دارای برتری نسبی نسبت به مدل‌هایی نظیر رگرسیون پواسون، دوجمله‌ای منفی، رگرسیون پواسون با رشد صفر و رگرسیون دوجمله‌ای منفی با رشد صفر هستند (Chang, 2005). اخیراً نیز تحقیقاتی در رابطه با استفاده از شبکه‌های عصبی مصنوعی در ارتقاء ایمنی راه‌ها انجام شده است. در تحقیقی با استفاده از شبکه‌های عصبی مصنوعی ارتباط غیرخطی میان تعداد تصادفات و فاکتورهای ریسک وقوع تصادفات مورد بررسی قرار گرفت. بررسی‌های این تحقیق نشان داد که استفاده از مدل شبکه عصبی پس از بهینه‌سازی و رفع خطاهای احتمالی آن، گزینه مناسب‌تری جهت پیش‌بینی تصادفات در مقایسه با مدل دوجمله‌ای منفی است (Zeng et al., 2016). در پژوهشی دیگر کاربرد مدل‌های شبکه عصبی در شناسایی فاکتورهای ریسک وقوع تصادفات در تقاطعات درون‌شهری مورد بررسی قرار گرفت. در این تحقیق علاوه بر مدل شبکه عصبی مصنوعی، مدل رگرسیون خطی تعمیم یافته نیز مورد استفاده قرار گرفت. بررسی‌های این مقاله نشان داد که عامل تردد، مهم‌ترین فاکتور تاثیرگذار در ریسک تصادفات تقاطعات درون‌شهری عامل تردد وسایل نقلیه است (Mussone, Bassani and Masci, 2017). البته برخی دیگر مطالعات نشان داده است که عامل تردد وسایل نقلیه از اهمیت بالایی برخوردار است (Gargoum, El-Basyouny, and Kim, 2016; Shi, Abdel-Aty, and Lee, 2016; Theofilatos and Yannis, 2014).

۳- محدوده مورد مطالعه

در این تحقیق آمار تصادفات محور نائین - اردکان استان یزد اخذ گردید. در استخراج آمار سعی شد تا اطلاعات دقیق منطقه وقوع تصادف و پارامترهای مربوط به آن در لحظه تصادف مورد برداشت قرار گیرد. شکل (۱) شمایی از منطقه مورد مطالعه و همچنین جدول (۱) خصوصیات توصیفی آمار برداشت شده از تصادفات محور مورد بررسی را نشان می‌دهد.



شکل ۱. شمایی از محور مورد مطالعه

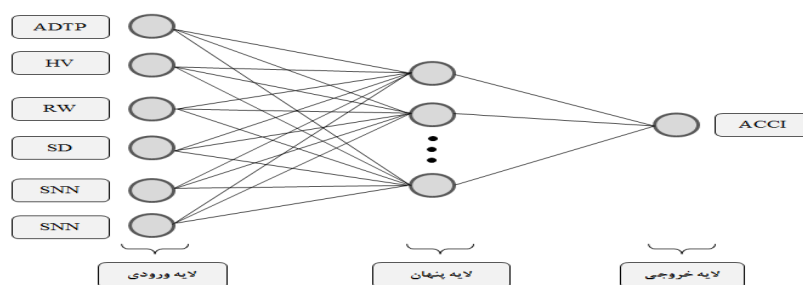
جدول ۱. آمار توصیفی متغیرهای مورد مطالعه

متغیر مورد بررسی	کد متغیر جهت آنالیز	واحد متغیر	حداقل متغیر	حداکثر متغیر	انحراف استاندارد متغیر
تعداد مجروحین-متوفی	ACCI	تعداد	۰	۳	۰/۸۶
تعداد تردد وسایل نقلیه در هر خط	ADTPL	تعداد	۲۰۴۶	۸۳۳۴	۸۶۱/۲۴
درصد وسایل نقلیه سنگین در ترکیب ترافیک	HV	(%)	۱۷	۷۰	۱۰/۸۱
عرض مورد تردد به همراه عرض شانه‌ها	RW	(متر)	۱۰/۳	۱۰/۸	۰/۱۴
متوسط سرعت تردد جریان ترافیک	SD	(کیلومتر بر ساعت)	۷۴	۱۰۱	۳/۵۵
تعداد خودروها با عدم رعایت سرعت مطمئنه	SNN	تعداد	۱۶۲	۱۱۱۱	۲۰۵/۴۵
تعداد خودروها با عدم رعایت فاصله ایمن	DNN	تعداد	۵۹	۵۴۳	۸۵/۱۷

۴- معرفی معماری شبکه عصبی تحقیق

خروجی برقرار می‌گردد. قابل ذکر است، گاهی اوقات به دلیل شرایط پیچیده مسئله ایجاب می‌گردد که از چند لایه پنهان استفاده گردد. هرچند با توجه به تکرار ساختار تک لایه‌ای پنهان در مطالعات قبلی، تعداد لایه پنهان در این تحقیق نیز ۱ لایه در نظر گرفته شد. همچنین تعداد لایه‌های ورودی و خروجی نیز ۱ لایه با توجه به تناسب تحقیق فوق در نظر گرفته شد. هر لایه شبکه عصبی از تعداد خاصی نرون تشکیل شده است. تعیین تعداد نرون‌ها در لایه پنهان امری است که از سعی و خطا به دست می‌آید. لیکن با توجه به برابر بودن تعداد متغیرهای ورودی و خروجی با تعداد نرون‌ها در لایه متناظر با آن‌ها، در این تحقیق تعداد ۶ نرون ورودی و همچنین ۱ نرون خروجی به منظور لحاظ نمودن متغیرهای ورودی و خروجی در نظر گرفته شد. شکل (۲) شمایی از معماری شبکه عصبی در نظر گرفته شده در این تحقیق را نشان می‌دهد.

در این تحقیق از مدل شبکه عصبی جلو رونده به منظور ساخت و پیش‌بینی تعداد تصادفات به وقوع پیوسته در محور مورد مطالعه بهره گرفته شد. شبکه‌های عصبی به‌طور معمول از سه لایه شامل لایه ورودی، لایه پنهان و لایه خروجی متشکل می‌باشند. به‌طور کلی شبکه‌های عصبی به دودسته شبکه‌های عصبی جلو رونده و شبکه‌های عصبی پیش‌خور تقسیم‌بندی می‌گردند. (Dreyfus, 2004). با توجه به کاربرد بیشتر شبکه‌های عصبی جلو رونده در مباحث حمل‌ونقل از این نوع ساختار در این تحقیق استفاده گردیده است. یک شبکه عصبی جلو رونده تابعی غیرخطی از ورودی‌ها می‌باشد که آن نیز ترکیبی از توابع وابسته به نرون‌ها است (Dreyfus, 2004). در این نوع شبکه‌ها ارتباطات به صورت جلو رونده است. به عبارتی از طریق آکسون‌ها، در ابتدا، ارتباطات میان نرون‌های لایه ورودی و نرون‌های لایه پنهان برقرار می‌گردد و سپس در گام بعدی از طریق آکسون‌های ثانویه، ارتباطات میان لایه پنهان با لایه



شکل ۲. شمایی از معماری شبکه عصبی تحقیق

۵- معرفی توابع آموزش مورد استفاده جهت ساخت شبکه عصبی

`net.trainFcn= 'trainbr'`
`[net,tr]=train(net, ...)`

که در عبارت کُد شده اخیر، `net.trainFcn` دستور تعیین فرم تابع آموزش، `trainbr` نوع تابع آموزش تخصیص داده شده است. همچنین خط بعدی کُد مورد نظر به منظور آموزش شبکه عصبی `net` تحت تابع آموزش تخصیص داده شده در خط اول استفاده می‌گردد.

یکی از مواردی که در میزان دقت نتایج به دست آمده از شبکه عصبی نقش مهمی را ایفا می‌کند، تابع آموزش شبکه عصبی می‌باشد. در این تحقیق تعداد ۴ تابع آموزش شامل: `trainlm`، `trainbr`، `trainscg` و `trainrp` مورد بررسی قرار گرفته است. در ادامه هر یک از توابع فوق توضیح داده شده است.

۵-۱- تابع آموزش `trainlm`

۵-۳- تابع آموزش `trainscg`

این نوع تابع آموزش وزن‌ها و خطاهای شبکه را مطابق با روش گرادیان مزدوج مقیاس شده به روزرسانی می‌کند (MATLAB, 2014). فرم دستوری این نوع تابع آموزش به شرح ذیل است:

`net.trainFcn= 'trainscg'` (۳)
`[net,tr]=train(net, ...)`

که در عبارت کُد شده اخیر، `net.trainFcn` دستور تعیین فرم تابع آموزش، `trainscg` نوع تابع آموزش تخصیص داده شده است. همچنین خط بعدی کُد مورد نظر به منظور آموزش شبکه عصبی `net` تحت تابع آموزش تخصیص داده شده در خط اول استفاده می‌گردد.

تابع آموزش شبکه `trainlm` نوعی تابع است که در آن وزن‌ها و خطاهای شبکه بر طبق الگوریتم بهینه‌سازی لونیگ-مارکواردت به روزرسانی می‌گردد. این تابع آموزش معمولاً سریع‌ترین روش (راه‌اندازی نرم‌افزاری در کوتاه‌ترین زمان) می‌باشد و به عنوان اولین الگوریتم پیشنهادی هوشمند به منظور بهینه‌سازی شبکه عصبی پیشنهاد می‌گردد (MATLAB, 2014). شیوه دستور این تابع آموزش در نرم‌افزار متلب به شکل ذیل است:

`net.trainFcn= 'trainlm'` (۱)
`[net,tr]=train(net, ...)`

که در عبارت کُد شده اخیر، `net.trainFcn` دستور تعیین فرم تابع آموزش، `trainlm` نوع تابع آموزش تخصیص داده شده است. همچنین خط بعدی کُد مورد نظر به منظور آموزش شبکه عصبی `net` تحت تابع آموزش تخصیص داده شده در خط اول استفاده می‌گردد.

۵-۴- تابع آموزش `trainrp`

این نوع تابع آموزش وزن‌ها و خطاهای شبکه را مطابق با روش الگوریتم پس‌انتشار ارتجاعی به روزرسانی می‌کند (MATLAB, 2014). فرم دستوری این تابع آموزش به شرح رابطه ۴ است.

`net.trainFcn= 'trainrp'` (۴)
`[net,tr]=train(net, ...)`

که در عبارت کُد شده اخیر، `net.trainFcn` دستور تعیین فرم تابع آموزش، `trainrp` نوع تابع آموزش تخصیص داده شده است. همچنین خط بعدی کُد مورد نظر به منظور آموزش شبکه عصبی `net` تحت تابع آموزش تخصیص داده شده در خط اول استفاده می‌گردد.

۵-۲- تابع آموزش `trainbr`

این تابع آموزش نیز همانند تابع `trainlm` مقدار وزن‌ها و خطاها را مطابق با الگوریتم بهینه‌سازی لونیگ-مارکواردت به روزرسانی می‌کند. تفاوت این تابع آموزش با قبلی در این است که، این تابع به‌طور ترکیبی، وزن‌ها و مجذور خطاها را حداقل می‌کند و سپس ترکیبی از ساختار شبکه را در نظر می‌گیرد که بتواند به‌خوبی تعمیم داده شود. این پروسه در واقع تنظیم بیزی نامیده می‌شود (MATLAB, 2014). فرم دستوری این تابع در نرم‌افزار متلب به شرح رابطه ۲ است.

(۲)


بی‌بعد گشته و عددی متعلق به بازه [۰،۱] می‌گردند. مطابق با آنچه گفته شد، شبکه‌های عصبی با توابع آموزش مختلف مورد بررسی عملکردی قرار گرفتند. در ادامه نتایج شبکه‌های عصبی با توابع آموزش مختلف بر مبنای آنچه اشاره شد، آمده است. در ادامه برای هر تابع آموزش دو نمودار مورد بررسی قرار گرفته است. در ابتدا تغییرات مقدار ریشه میانگین مربعات خطاها برحسب تعداد نرون مختلف در لایه پنهان ترسیم گردیده است. به‌طورکلی هرچه میزان ریشه میانگین مربعات خطاها کمتر باشد، دقت شبکه موردنظر در پیش‌بینی بیشتر است. در ادامه نتایج پیش‌بینی شبکه عصبی از مقدار حقیقی (در اینجا تعداد تصادفات نرمالیزه شده می‌باشد) کسر گردید و نمودار مقادیر باقیمانده برای داده‌های ثبت‌شده و پیش‌بینی‌شده به دست آمد.

نتایج شبکه عصبی با تابع آموزش trainlm

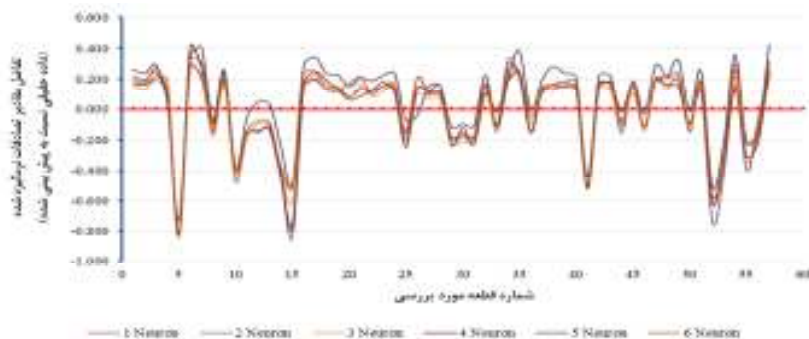
شکل (۳) شمایی از تغییرات ریشه میانگین مربعات خطاها برای تعداد نرون مختلف در لایه پنهان و همچنین شکل (۴) مقدار باقیمانده (یعنی تفاضل مقدار حقیقی از مقدار تخمین زده‌شده) را پس از ساخت شبکه‌های عصبی نشان می‌دهند.

ساخت و بررسی نتایج شبکه‌های عصبی با توابع آموزش مختلف

در این قسمت نتایج عملکردی شبکه‌های عصبی مورد بررسی قرار می‌گیرد. در ساخت و بررسی شبکه‌های عصبی باید توجه شود، تعیین تعداد نرون بهینه در لایه پنهان بر مبنای یک فرایند تکراری است. در این تحقیق با توجه به اینکه تعداد ۶ متغیر ورودی به‌عنوان تأثیرگذار در وقوع تصادفات در نظر گرفته شد، تعداد نرون‌ها در لایه پنهان از ۱ نرون تا ۶ نرون متغیر منظور گردید. معمولاً در ساخت شبکه‌های عصبی دسته داده‌ها به سه بخش کلی شامل: آموزش، تست و اعتبارسنجی تقسیم‌بندی می‌گردند. انتخاب سهم مناسب داده‌ها جهت آموزش، تست و اعتبارسنجی نیز امری است که از سعی و خطا به دست می‌آید. در این مطالعه با توجه به پیشنهاد نرم‌افزار متلب مقدار نسبت آموزش، تست و اعتبارسنجی به ترتیب برابر با ۰/۷۰، ۰/۱۵ و ۰/۱۵ در نظر گرفته شد (MATLAB, 2014). همچنین با توجه به اینکه متغیرها دارای واحدهای مختلفی می‌باشند، سعی گردید تا پیش از ساخت شبکه‌های عصبی، داده‌ها نرمالیزه و بی‌بعد گردند. بدین منظور مقادیر هر یک از داده‌ها از مقدار مینیمم آن متغیر کسر گردید و سپس حاصل به‌دست‌آمده بر تفاضل ماکزیمم مقدار متغیر و مینیمم مقدار متغیر تقسیم گردید. با این عمل تمامی داده‌ها



شکل ۳. تغییرات ریشه میانگین مربعات خطاها برحسب تعداد نرون در لایه پنهان (تابع آموزش از نوع trainlm)




شکل ۴. تغییرات مقدار باقیمانده برحسب شماره قطعه موردبررسی برای تعداد نرون مختلف (تابع آموزش از نوع trainlm)

لایه پنهان ۳ بوده است (به شکل (۳) مراجعه شود)، تعداد نرون بهینه ساختار شبکه عصبی با تابع آموزش از نوع trainlm، ۳ نرون تعیین می‌گردد.


نتایج شبکه عصبی با تابع آموزش trainbr

شکل‌های (۴) و (۵) به ترتیب نتایج ریشه میانگین مربعات خطاها برحسب تعداد نرون در لایه پنهان و همچنین مقادیر باقیمانده برحسب شماره مقطع مورد مطالعه را زمانی که تابع آموزش از نوع trainbr باشد، نشان می‌دهند.

مطابق با منحنی درجه سه برازش شده در شکل (۳) بر داده‌های به‌دست‌آمده، مشخص است که در ابتدا مقدار ریشه میانگین مربعات خطاها کاهش می‌یابد، در ادامه شدت کاهش این مقدار، کمتر شده و سپس با شدت بیشتری مجدداً کاهش می‌یابد. این تغییرات بیانگر چگونگی تغییر عملکرد مدل‌ها نیز می‌باشد. همچنین مطابق با نتایج شکل (۴) عملکرد شبکه عصبی به ازای تعداد نرون‌های مختلف نزدیک به هم می‌باشد. تعیین تعداد نرون بهینه شبکه‌های عصبی معمولاً بر اساس دو معیار عملکرد و سادگی (یا به عبارتی پیچیده نبودن) صورت می‌پذیرد، مطابق با شکل (۴) و نزدیکی نتایج نسبی شبکه‌ها و همچنین عملکرد مناسب شبکه زمانی که تعداد نرون در



شکل ۵. تغییرات ریشه میانگین مربعات خطاها برحسب تعداد نرون در لایه پنهان (تابع آموزش از نوع trainbr)



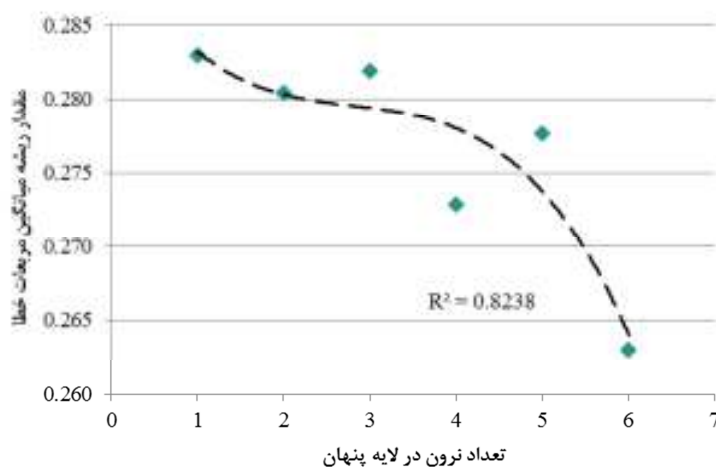
شکل ۶. تغییرات مقدار باقیمانده برحسب شماره قطعه موردبررسی برای تعداد نرون مختلف (تابع آموزش از نوع trainbr)

نشان می‌دهند. مطابق با نمودار شکل (۷) که در ادامه آمده است، مشخص است که با تقریب خوبی، مقدار ریشه میانگین مربعات خطاها با افزایش تعداد نرون در لایه پنهان روند نزولی دارد. این موضوع به معنای سیر صعودی عملکرد شبکه به دلیل افزایش تعداد نرون در لایه پنهان می‌باشد. همچنین مطابق با شکل (۸) به نظر می‌رسد که تفاوت غیرقابل توجهی میان نتایج باقیمانده (مقادیر حقیقی نسبت به پیش‌بینی شده) وجود دارد. با توجه به تغییرات عملکردی شکل (۷) به نظر می‌رسد که انتخاب تعداد ۴ نرون به‌عنوان تعداد نرون بهینه با رعایت همزمان دو معیار سادگی و عملکرد، رضایت‌بخش می‌باشد.

مطابق با شکل (۵) به نظر می‌رسد که عملکرد شبکه عصبی تحت افزایش تعداد نرون وضعیت غیرخطی دارد. با این وجود مطابق با شکل (۶) تفاوت کمی میان نتایج شبکه‌های عصبی با تعداد نرون مختلف وجود دارد. با توجه به این موضوع و همچنین دقت در نتایج شکل (۵) به نظر می‌رسد که شبکه عصبی با تعداد ۳ نرون در لایه پنهان وضعیت بهینه می‌باشد.

نتایج شبکه عصبی با تابع آموزش `trainscg`

شکل‌های (۷) و (۸) به ترتیب نتایج عملکرد و باقیمانده شبکه عصبی ساختاری با تابع آموزش از نوع `trainscg` را



شکل ۷. تغییرات ریشه میانگین مربعات خطاها برحسب تعداد نرون در لایه پنهان (تابع آموزش از نوع `trainscg`)




شکل ۸. تغییرات مقدار باقیمانده برحسب شماره قطعه موردبررسی برای تعداد نرون مختلف (تابع آموزش از نوع `trainscg`)

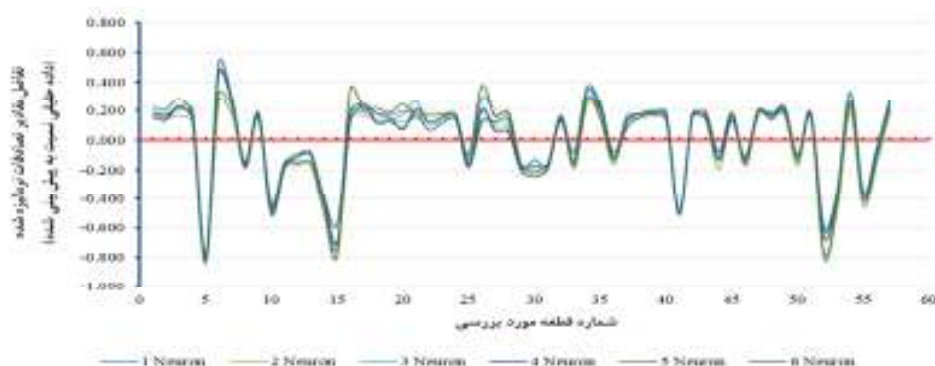
نتایج شبکه عصبی با تابع آموزش trainrp

عصبی بهبود پیدا می‌کند. لیکن با توجه به عدم بهبود قابل توجه پس از تعداد ۴ نرون در لایه پنهان، میزان نرون بهینه در لایه پنهان، ۴ نرون انتخاب می‌گردد. همچنین مطابق با شکل (۱۰) به نظر می‌رسد که علی‌رغم تغییر در عملکرد شبکه‌ها، نتایج مقادیر باقیمانده شبکه برای قطعات مختلف مورد مطالعه نزدیک به هم می‌باشد.

مشابه با موارد قبلی، شکل‌های (۹) و (۱۰) بیانگر عملکرد شبکه‌ها نسبت به تعداد مختلفی از نرون در لایه پنهان و همچنین مقدار باقیمانده برای مقاطع مورد مطالعه را نشان می‌دهد. مطابق با شکل (۹) که در ادامه آمده مشخص است که با افزایش تعداد نرون در لایه پنهان مکرراً به دلیل کاهش مقدار ریشه میانگین مربعات خطاها، عملکرد شبکه



شکل ۹. تغییرات ریشه میانگین مربعات خطاها برحسب تعداد نرون در لایه پنهان (تابع آموزش از نوع trainrp)



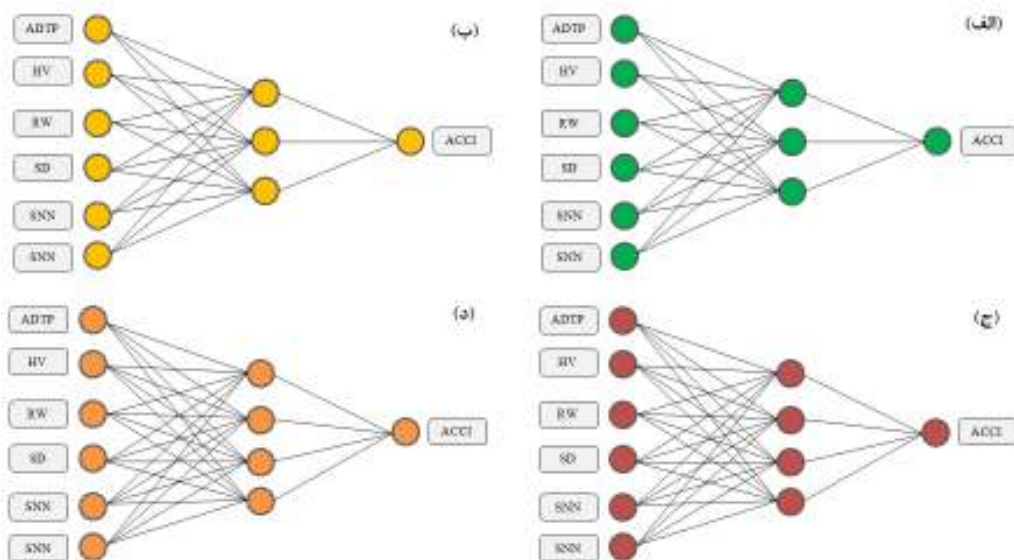
شکل ۱۰. تغییرات مقدار باقیمانده برحسب شماره قطعه مورد بررسی برای تعداد نرون مختلف (تابع آموزش از نوع trainrp)

مقایسه نتایج عملکردی توابع مختلف آموزش شبکه عصبی

معماری شبکه‌های عصبی با توابع آموزش مختلف را نشان می‌دهند.

جدول (۲)، نتایج آنالیز واریانس یک‌طرفه جهت مقایسه نتایج مقدار باقیمانده (تفاضل تعداد پیش‌بینی شده تصادفات از مقدار واقعی) را نشان می‌دهد. مطابق با نتایج جدول فوق با توجه به مقدار P-value و کمتر بودن از مقدار حد بحرانی (در اینجا حد بحرانی برابر با ۰/۰۵ به معنای دقت ۹۵٪ در نظر گرفته شد) می‌توان به نزدیکی نتایج کلی نسبت به هم پی برد.

در این بخش مقایسه‌ای میان نتایج عملکردی شبکه‌های عصبی که تحت ۴ تابع مختلف مورد مطالعه آموزش دیدند، ارائه شده است. در یک نگاه کلی باید توجه شود که عملکرد توابع مختلف آموزش شبکه عصبی نزدیک به هم می‌باشد. لیکن در یک نگاه دقیق‌تر می‌توان بر اساس معیارهایی نظیر معماری شبکه عصبی، میزان دقت در پیش‌بینی و همچنین زمان آنالیز در مورد شبکه با دقت بالاتر تصمیم‌گیری نمود. شکل (۱۱-الف) الی (۱۱-د)



شکل ۱۱. معماری شبکه‌های عصبی با توابع آموزش مختلف؛ الف) trainlm، ب) trainbr، ج) trainscg، د) trainrp

جدول ۲. نتایج آنالیز واریانس یک‌طرفه مقایسه نتایج دقت پیش‌بینی

ANOVA						
Source of Variation	SS	df	MS	F	P-value	F crit
Between Groups	0.01143	3	0.00381	0.052042	0.984297	2.644903
Within Groups	16.39852	224	0.073208			
Total	16.40995	227				

با مشخصات cpu برابر با ۲/۱ گیگاهرتز و همچنین حافظه رم ۲ گیگابایتی صورت پذیرفت. مطابق با نتایج جدول فوق مشخص است که شبکه عصبی با تابع آموزش از نوع trainlm در رتبه نخست قرار می‌گیرد که به منزله دقت نسبی بالاتر نتایج پیش‌بینی شبکه عصبی ساخته‌شده با این نوع تابع آموزش می‌باشد.


با نگاهی دقیق‌تر به مقایسه نتایج توابع آموزش مختلف می‌توان جدولی به شرح جدول (۳) را تنظیم نمود. هدف از جدول فوق بررسی چندجانبه شبکه عصبی ساخته‌شده با توابع آموزش مختلف می‌باشد. در این جدول علاوه بر عملکرد مدل‌ها، ساختار آن‌ها و همچنین زمان آنالیز جهت راه‌اندازی شبکه عصبی نیز مورد مقایسه قرار گرفته است. قابل ذکر است که نتایج محاسبه زمان بر اساس یک سیستم

جدول ۳. نتایج آنالیز واریانس یک‌طرفه مقایسه نتایج دقت پیش‌بینی

رتبه کلی	زمان محاسبه شده آنالیز (ثانیه)		ریشه میانگین مربعات خطاها (rmse)		میانگین مربعات خطاها (mse)		تعداد نرون بهینه در لایه پنهان		تابع آموزش دهنده شبکه عصبی
	رتبه	زمان	رتبه	rmse	رتبه	mse	رتبه	تعداد نرون	
	۱	۱	۰/۶۰۳۹	۱	۰/۲۵۵۰	۱	۰/۰۶۵۰	۱	
۴	۴	۴/۱۱۶۴	۴	۰/۲۷۶۰	۴	۰/۰۷۶۲	۱	۳	trainbr
۳	۳	۰/۶۶۵۸	۳	۰/۲۷۲۸	۳	۰/۰۷۴۴	۲	۴	trainscg
۲	۲	۰/۴۳۰۱	۲	۰/۲۶۹۱	۲	۰/۷۲۴	۲	۴	trainrp

کاربرد نتایج مدل شبکه عصبی در ارتقاء ایمنی راه

متغیر X_i مورد استفاده قرار می‌گیرد. سپس مقادیر پیش‌بینی شده شبکه عصبی را تحت ماتریس متشکله به دست می‌آوریم. در این تحقیق این فرآیند برای تمامی متغیرها صورت پذیرفت و تأثیرات جزئی هر یک از متغیرها به دست آمد. قابل ذکر است پس از محاسبه تأثیرات جزئی و نتایج پیش‌بینی شبکه‌ها مقدار ریشه میانگین مربعات خطاها (rmse) به دست می‌آید. بر این اساس با توجه به مفهوم ریشه میانگین مربعات خطاها می‌توان تأثیرات به دست آمده به ازای متغیرها را نسبت به کمترین میزان rmse که بیانگر بالاترین تأثیر در وقوع تصادفات است، نرمالیزه نمود. شکل (۱۲) شمایی از نتایج تحلیل حساسیت نرمالیزه شده متغیرهای مختلف را نشان می‌دهد.



شکل ۱۲. نتایج تأثیر نسبی متغیرها در بروز تصادفات (نرمالیزه شده)

۶- نتیجه گیری

سازای شبکه عصبی انجام گرفت. یکی از موارد مهم مرتبط با شبکه‌های عصبی توابع آموزش آن‌هاست. زمانی که یک شبکه به ازای تعداد دسته داده‌های ثابت بهتر آموزش دیده شود، عملکرد آن طبعاً مطلوب‌تر خواهد بود. عملکرد بهتر مدل شبکه عصبی به منزله دقت بالاتر پیش‌بینی تصادفات است. هرچه دقت پیش‌بینی بیشتر باشد، بهتر می‌توان اهمیت نسبی متغیرهای مؤثر در بروز تصادفات که در ساخت مدل‌سازی مورد استفاده قرار می‌گیرند را شناخت. در این تحقیق سعی گردید این مهم از طریق بررسی تابع آموزش مختلف شامل: `trainlm`، `trainbr`، `trainscg` و

یکی از مهم‌ترین معضلات کشور، شمار بالای تصادفات به وقوع پیوسته در معابر درون‌شهری و برون‌شهری می‌باشد. اهمیت این موضوع باعث شده است تا ادارات مختلف راهداری و حمل‌ونقل جاده‌ای تلاش‌های زیادی پیرامون ارتقاء ایمنی تردد جاده‌ای داشته باشند. علی‌رغم تلاش‌های صورت پذیرفته، بررسی‌ها نشان داده است که باز هم آمار تصادفات جاده‌ای زیاد است. هدف از این مقاله پیش‌بینی تعداد تصادفات جاده‌ای با مطالعه موردی محور نائین-اردکان استان یزد بود. در این راستا در این تحقیق با تکیه بر آمار اخذشده از مراجع زیر ربط، مدل-

۹- مراجع

-سایت سازمان پزشکی قانونی کشور، (۱۳۹۵).
به نشانی: www.lmo.ir.

-Abdelwahab, H. T., and Abdel-Aty, M., (2001), "Development of Artificial Neural Network Models to Predict Driver Injury Severity in Traffic Accidents at Signalized Intersections", *Transportation Research Record, Journal of the Transportation Research Board*, No. 1746, pp. 6-13.
doi: <http://dx.doi.org/10.3141/1746-02>.

-Bayata, H. F., Hattatoglu, F., and Karsli, N., (2011), "Modeling of monthly traffic accidents with the artificial neural network method", *International Journal of the Physical Sciences*, No. 6, pp. 244-254.

-Burattini, E., and De Gregorio, M., (1998), "A neural network to evaluate congestion levels. In: Mussoni, L., Marescotti, L. (eds.)", *Urban traffic: control possibility, tools and their effectiveness*, Milano .

- Can Yilmaz, A., Aci, C., and Aydin, K. (2016). Traffic accident reconstruction and an approach for prediction of fault rates using artificial neural networks: A case study in Turkey. *Traffic Injury Prevention*, 17(6), pp.585-589.

doi: 10.1080/15389588.2015.1122760.

-Chang, L. Y., (2005), "Analysis of freeway accident frequencies: Negative binomial regression versus artificial neural network", *Safety Science*, No. 43, pp. 541-557.
doi: dx.doi.org/10.1016/j.ssci.2005.04.004.

-Dougherty, M., (1995), "A review of neural networks applied to transport", *Transportation Research Part C: Emerging Technologies*, No. 3, pp. 247-260.
doi: [http://dx.doi.org/10.1016/0968-090X\(95\)00009-8](http://dx.doi.org/10.1016/0968-090X(95)00009-8).

-Dougherty, M., and Joint, M., (1992), "A behavioural model of driver route choice using neural networks", *International Conference on Artificial Intelligence Applications in Transportation Engineering*, San Buenaventura, California, USA, pp. 20-24.

-Dougherty, M., Kirby, H., and Boyle, R., (1992), "The use of neural networks to recognize and predict traffic congestion", *Congress on Transport Research*, Lyon, France, March, pp.10-12 .

trainrp محقق گردد. در این تحقیق در ابتدا شبکه‌های مختلف شامل تعداد نرون‌های مختلف در لایه پنهان ساخته شدند. سپس بر اساس دو معیار سادگی و عملکرد شبکه‌ها، تعداد نرون بهینه متناسب با هر شبکه عصبی (با تابع آموزش خاص) شناخته شد. در ادامه شبکه‌های عصبی ساخته‌شده در تعداد نرون بهینه از جنبه‌های مختلف عملکردی، سادگی و همچنین زمان موردنیاز جهت آنالیز مورد مقایسه قرار گرفتند. بررسی‌های این مقاله حاکی از آن است که تعداد نرون بهینه برای شبکه‌های عصبی با توابع آموزش trainbr، trainlm، trainbr، trainlm و trainrp به ترتیب برابر با ۳، ۳، ۴ و ۴ نرون می‌باشد. همچنین نتایج آزمون واریانس یک‌طرفه بیانگر تفاوت غیرقابل‌توجه عملکرد شبکه‌های ساخته‌شده از توابع مختلف بود. در مقیاس دقیق‌تر و بررسی چندجانبه، شبکه عصبی که با تابع trainlm آموزش دیده بود، عملکرد بهتری داشت. همچنین بررسی‌های میزان اهمیت نسبی متغیرها در بروز تصادفات جاده‌ای نشان داد که دو عامل میزان تردد جاده‌ای و تعداد وسایل نقلیه با عدم رعایت فاصله ایمن به ترتیب بیشترین اثر را در بروز تصادفات محور مورد مطالعه داشته‌اند. امید است که روش به کار گرفته‌شده در مقاله بتواند در آینده گامی مؤثر جهت کاهش تلفات جاده‌ای در بر داشته باشد.

۷- سیاست‌گذاری

نویسندگان این مقاله صمیمانه از اداره کل راهداری و حمل‌ونقل جاده‌ای استان یزد به جهت حمایت‌های خود در تهیه و تدارک دیدن آمار تصادفات جاده‌ای محور نائین-اردکان تشکر و قدردانی دارند.

۸- پی‌نوشت‌ها

- 1-Levenberg-Marquardt
- 2-Bayesian regularization
- 3- Scaled conjugate gradient method
- 4- Resilient back propagation algorithm
- 5-Train
- 6-Test
- 7-Validation
- 8- Root-mean-square-error

- Li, Z., Wang, W., Liu, P., Bigham, J. M., and Ragland, D. R., (2013), "Using Geographically Weighted Poisson Regression for county-level crash modeling in California", *Safety Science*, No. 58, pp. 89-97.
doi:<http://dx.doi.org/10.1016/j.ssci.2013.04.005>.
- Lord, D., Manar, A., and Vizioli, A., (2005), "Modeling crash-flow-density and crash-flow-V/C ratio relationships for rural and urban freeway segments", *Accident Analysis & Prevention*, No. 37, pp. 185-199.
doi:
<http://dx.doi.org/10.1016/j.aap.2004.07.003>.
- Lord, D., Washington, S. P., and Ivan, J. N., (2005), "Poisson, Poisson-gamma and zero-inflated regression models of motor vehicle crashes: balancing statistical fit and theory", *Accident Analysis & Prevention*, No. 37, pp. 35-46.
doi:<http://dx.doi.org/10.1016/j.aap.2004.02.004>.
- Malyshkina, N. V., and Mannering, F. L., (2010), "Zero-state Markov switching count-data models: An empirical assessment", *Accident Analysis & Prevention*, No. 42, pp. 122-130.
doi: <http://dx.doi.org/10.1016/j.aap.2009.07.012>.
- MATLAB., (2014), "Neural Network Toolbox", Natick, MA: MathWorks Inc .
- Meng, Q., and Qu, X., (2012), "Estimation of rear-end vehicle crash frequencies in urban road tunnels", *Accident Analysis & Prevention*, No. 48, pp. 254-263.
doi:<http://dx.doi.org/10.1016/j.aap.2012.01.025>.
- Miaou, S. P., (1994), "The relationship between truck accidents and geometric design of road sections: Poisson versus negative binomial regressions", *Accident Analysis & Prevention*, No. 26, pp. 471-482.
doi:[http://dx.doi.org/10.1016/001-4575\(94\)90038-8](http://dx.doi.org/10.1016/001-4575(94)90038-8)
- Milton, J., and Mannering, F., (1998), "The relationship among highway geometrics, traffic-related elements and motor-vehicle accident frequencies", *Transportation*, No. 25, pp. 395-413. doi: 10.1023/a:1005095725001.
- Mussone, L., Bassani, M., and Masci, P., (2017), Analysis of factors affecting the severity of crashes in urban road intersections. *Accident Analysis & Prevention*, 103, 112-122. doi: <https://doi.org/10.1016/j.aap.2017.04.007>.
- Najaf, P., Duddu, V. R., and Pulugurtha, S. S., (2017), Predictability and interpretability of
- Dougherty, M., Kirby, H., and Boyle, R., (1993), "The use of neural networks to recognize and predict traffic congestion", *Traffic Engineering and Control*, No. 34, pp. 311-314 .
- Dreyfus, G., (2004), "Neural Networks: Methodology and Applications". 2nd. Edition, Germany: Springer-Verlag Berlin Heidelberg.
- Fischer, M. M., and Gopal, S., (1994), "Artificial neural networks: a new approach to modelling interregional telecommunication flows", *Journal of Regional Science*, No. 4, pp. 503-527 .
- Gargoum, S. A., El-Basyouny, K., and Kim, A., (2016), "Towards setting credible speed limits: Identifying factors that affect driver compliance on urban roads. *Accident Analysis & Prevention*, 95, pp.138-148.
doi:
<http://dx.doi.org/10.1016/j.aap.2016.07.001>.
- Gustavsson, J., and Svensson, Å., (1976), "A Poisson Regression Model Applied to Classes of Road Accidents with Small Frequencies", *Scandinavian Journal of Statistics*, No. 3, pp. 49-60 .
- Hasheminejad, S. H.-A., Zahedi, M., and Hasheminejad, S. M. H., (2017), "A hybrid clustering and classification approach for predicting crash injury severity on rural roads. *International Journal of Injury Control and Safety Promotion*, pp.1-17.
doi: 10.1080/17457300.2017.1341933.
- Khishdari, A., and Fallah Tafti, M., (2017), "Development of crash frequency models for safety promotion of urban collector streets. *International Journal of Injury Control and Safety Promotion*, pp.1-15.
doi: 10.1080/17457300.2016.1278237.
- Kumara, S. S. P., and Chin, H. C., (2003), "Modeling Accident Occurrence at Signalized Tee Intersections with Special Emphasis on Excess Zeros", *Traffic Injury Prevention*, No. 4, pp. 53-57 .
- Lee, J., and Mannering, F., (2002), "Impact of roadside features on the frequency and severity of run-off-roadway accidents: an empirical analysis", *Accident Analysis & Prevention*, No. 34, pp. 149-161.
doi:[http://dx.doi.org/10.1016/S00014575\(01\)00009-4](http://dx.doi.org/10.1016/S00014575(01)00009-4).

- Theofilatos, A., and Yannis, G., (2017), "Investigation of powered 2-wheeler accident involvement in urban arterials by considering real-time traffic and weather data", *Traffic Injury Prevention*, 18(3), pp.293-298. doi: 10.1080/15389588.2016.1198871.
- WHO, (2015), "Global Status Report on Road Safety".
- Yan, Y., Wang, X., Shi, L., and Liu, H., (2017), "Influence of light zones on drivers' visual fixation characteristics and traffic safety in extra-long tunnels", *Traffic Injury Prevention*, 18(1), pp.102-110. doi: 10.1080/15389588.2016.1193170.
- Yang, H., Kitamura, R., Jovanis, P. P., Vaughn, K. M., and Abdel-Aty, M. A., (1993), "Exploration of route choice behavior with advanced traveler information using neural network concepts", *Transportation*, No. 20, pp.199-223.
- Ye, X., Pendyala, R. M., Shankar, V., and Konduri, K. C., (2013), "A simultaneous equations model of crash frequency by severity level for freeway sections", *Accident Analysis & Prevention*, No. 57, pp. 140-149. doi: <http://dx.doi.org/10.1016/j.aap.2013.03.025>.
- Yu, R., and Abdel-Aty, M., (2014), Analyzing crash injury severity for a mountainous freeway incorporating real-time traffic and weather data. *Safety Science*, 63, pp.50-56. doi: <http://dx.doi.org/10.1016/j.ssci.2013.10.012>.
- Zhang, H. M., and Ritchie, S. G., (1997), "Freeway ramp metering using artificial neural networks" *Transportation Research Part C: Emerging Technologies*, No. 5, pp. 273-286. doi: [http://dx.doi.org/10.1016/S0968-090X\(97\)00019-3](http://dx.doi.org/10.1016/S0968-090X(97)00019-3).
- Zeng, Q., Huang, H., Pei, X., Wong, S. C., and Gao, M., (2016), "Rule extraction from an optimized neural network for traffic crash frequency modeling. *Accident Analysis & Prevention*", 97, pp.87-95. doi: <http://dx.doi.org/10.1016/j.aap.2016.08.017>.
- hybrid link-level crash frequency models for urban arterials compared to cluster-based and general negative binomial regression models. *International Journal of Injury Control and Safety Promotion*, pp.1-11. doi: 10.1080/17457300.2017.1285789.
- Pant, E. D., (1994), "Neural network for gap acceptance at stop-controlled intersection", *Journal of Transportation Engineering*, No. 120, pp. 432-446 .
- Pirdavani, A., Brijs, T., Bellemans, T., Kochan, B., and Wets, G., (2013), "Evaluating the road safety effects of a fuel cost increase measure by means of zonal crash prediction modeling", *Accident Analysis & Prevention*, No. 50, pp. 186-195. doi: <http://dx.doi.org/10.1016/j.aap.2012.04.008>.
- Ritchie, S. G., and Cheu, R. L., (1993), "Simulation Of Freeway Incident Detection Using Artificial Neural Networks", *Transportation Research Part C: Emerging Technologies*, No. 1, pp. 203-217. doi: [http://dx.doi.org/10.1016/S0968-090X\(13\)80001-0](http://dx.doi.org/10.1016/S0968-090X(13)80001-0).
- Ritchie, S. G., Cheu, R. L., and Recker, W. W., (1992), "Freeway incident detection using artificial neural networks", *International Conference on Artificial Intelligence Applications in Transportation Engineering*, San Buenaventura, California, USA, pp.20-24.
- Rodrigue, J. P., (1997), "Parallel modelling and neural networks: An overview for transportation/land use systems", *Transportation Research Part C: Emerging Technologies*, No. 5, pp. 259-271. doi: [http://dx.doi.org/10.1016/S0968-090X\(97\)00014-4](http://dx.doi.org/10.1016/S0968-090X(97)00014-4).
- Shi, Q., Abdel-Aty, M., and Lee, J., (2016), "A Bayesian ridge regression analysis of congestion's impact on urban expressway safety", *Accident Analysis & Prevention*, 88, pp.124-137. doi:<http://dx.doi.org/10.1016/j.aap.2015.12.001>.
- Theofilatos, A., and Yannis, G., (2014), "A review of the effect of traffic and weather characteristics on road safety", *Accident Analysis & Prevention*, 72, pp.244-256. doi: <http://dx.doi.org/10.1016/j.aap.2014.06.017>.

Determining the Proper Training Algorithm of Artificial Neural Network Prediction Model as a Tool for Road Safety Promotion

Abolfazl Khishdari, M.Sc., Grad., Department of Civil Engineering, Yazd University, Yazd, Iran.

Hamed Khani Sanij, Assistant Professor, Department of Civil Engineering, Yazd University, Yazd, Iran.

Javad Zaker Harofteh, M. Sc., Grad., Department of Civil Engineering, Payam Noor Rezvanshahr University, Yazd, Iran.

Mohsen Dehghan Banadaki, M. Sc., Grad., Department of Civil Engineering, Bafgh Islamic Azad University, Yazd, Iran.

E-mail: khani@yazd.ac.ir

Received: September 2020-Accepted: January 2021

ABSTRACT

Numerous people have died and economically damaged due to the road accidents. One of the efficient ways of reducing crashes is to predict them before happening. This paper investigated the power of artificial-neural network (ANN) model to predict crash frequencies of Naein-Ardakan road, located in Yazd, Iran. To date, there seems no research done to compare the effects of ANN training functions on prediction performance. This research aimed to determine the proper ANN training algorithm for crash frequency prediction. In this regard, four different training algorithms were investigated. The results demonstrated the outperformance of 'trainlm' algorithm. Additionally, it was found that the average daily traffic per lane and gap lengths is the most influential factors in crash occurrences, respectively. The present study can be applied to more precisely explain the effects of independent variables on crash outcomes. An in-depth explanation of the effectiveness of independent variables can assist road safety experts in making better decisions for reducing accidents.

Keywords: Neural network, Training Function, Prediction, Crash Frequencies