







Original Article

Prediction of traffic accidents based on weather conditions in Gilan province using artificial neural network

Shandiz Moslehi¹ , Arsalan Gholami² , Zahra Haghdoust³ , Hossien Aabed⁴ , Saman Mohammadpour⁵ , Mohammad Ashkan Moslehi⁶ 

¹ Assistant Professor, Department of Health in Disasters and Emergencies, School of Health Management and Information Sciences, Iran University of Medical Sciences, Tehran, Iran.

² M.Sc, Health Management and Economics Research Center, Health Management Research Institute, Iran University of Medical Sciences, Tehran, Iran.

³ Ph.D Student, Department of Health in Disasters and Emergencies, School of Health Management and Information Sciences, Iran University of Medical Sciences, Tehran, Iran.

⁴ M.Sc, Meteorological Research Center, General Meteorological Department of Gilan Province, Gilan, Iran.

⁵ Ph.D Student, Department of Health Information Management and Technology, School of Paramedical Sciences, Shahid Beheshti University of Medical Sciences, Tehran, Iran.

⁶ Assistant Professor, Department of Pediatrics, School of Medicine, Shiraz University of Medical Sciences, Shiraz, Iran.

ARTICLE INFO

Corresponding Author:
Zahra Haghdoust
e-mail addresses:
Haghdoust.z@tak.iums.ac.ir

Received: 28/Jun/2021
Modified: 15/Sep/2021
Accepted: 22/Sep/2021
Available online: 19/Dec/2021

Keywords:

Forecasting
Traffic Accidents
Artificial Neural Network
Disaster Health
Health Management

ABSTRACT

Introduction: Road traffic accidents are one of the leading causes of death worldwide, including Iran. There are several factors involved in the occurrence of them; using different models, these factors can be identified and the occurrence of road traffic accidents can be predicted. The purpose of this study was to predict road traffic accidents based on weather conditions using artificial neural network model.

Methods: In the present study, traffic data during the years 2014 to 2017, were examined using a multilayer perceptron network. Network input variables included minimum temperature, average temperature, average rainfall, maximum wind speed, glaciation, air pressure, fog concentration and output variable was the number of accidents.

Results: The designed network with seven neurons in the input layer, four neurons in the middle layer, and one neuron in the output layer with Lunberg-Marquardt optimization function and sigmoid tangent transfer function in the middle layer and linear transmission function in the output layer was selected as the optimal network. The results showed that the designed network with the correlation coefficient of 0.90 and mean square error of 0.01 has a high ability to predict road traffic accidents.

Conclusion: The results showed that the artificial neural network has a good performance for predicting road traffic accidents. Given the importance of predicting road traffic accidents and its role in promoting the health of people in such accidents, the results of this study can be used to expand more effective preventive measures for policy makers and researchers.

پیش بینی حوادث ترافیکی بر اساس وضعیت آب و هوا در استان گیلان با استفاده از شبکه عصبی مصنوعی

شاندیز مصلحی^۱، ارسلان غلامی^۲، زهرا حق دوست^۳، حسین عابد^۴، سامان محمدپور^۵، محمداشکان مصلحی^۶

^۱استادیار، گروه سلامت در بلايا و فوریت ها، دانشکده مدیریت و اطلاع‌رسانی پزشکی، دانشگاه علوم پزشکی ایران، تهران، ایران.
^۲کارشناس ارشد، مرکز تحقیقات علوم مدیریت و اقتصاد سلامت، پژوهشکده مدیریت سلامت، دانشگاه علوم پزشکی ایران، تهران، ایران.
^۳دانشجوی دکتری، گروه سلامت در بلايا و فوریت ها، دانشکده مدیریت و اطلاع‌رسانی پزشکی، دانشگاه علوم پزشکی ایران، تهران، ایران.
^۴کارشناس ارشد، مرکز تحقیقات هواشناسی، اداره کل هواشناسی استان گیلان، گیلان، ایران.
^۵دانشجوی دکتری، گروه مدیریت و فناوری اطلاعات سلامت، دانشکده پیراپزشکی، دانشگاه علوم پزشکی شهید بهشتی، تهران، ایران.
^۶استادیار، گروه کودکان، دانشکده پزشکی، دانشگاه علوم پزشکی شیراز، شیراز، ایران.

چکیده

مقدمه: حوادث ترافیکی یکی از دلایل اصلی مرگ و میر در سراسر جهان از جمله ایران محسوب می‌شود. عوامل متعددی در بروز حوادث ترافیکی نقش دارند که با استفاده از مدل‌های مختلف می‌توان این عوامل را شناسایی و بروز حوادث ترافیکی را پیش‌بینی کرد. هدف این مطالعه پیش‌بینی حوادث ترافیکی بر اساس وضعیت آب و هوا با استفاده از شبکه عصبی مصنوعی می‌باشد.

روش‌ها: پژوهش حاضر به روش کمی بین سال‌های ۱۳۹۳ تا ۱۳۹۶ انجام شد که داده‌های ترافیکی طی با استفاده از شبکه پرسپترون چندلایه بررسی شد. متغیرهای ورودی شبکه شامل حداقل دما، میانگین دما، متوسط بارش، حداکثر سرعت باد، یخبندان، فشار هوا، غلظت مه و متغیر خروجی نیز تعداد تصادفات در محیط مورد مطالعه بود.

یافته‌ها: شبکه طراحی شده، با هفت نورون در لایه ورودی، چهار نورون در لایه میانی و یک نورون در لایه خروجی با تابع بهینه‌سازی لونیگ-مارکواردت و تابع انتقال تانژانت سیگموئید در لایه میانی و تابع انتقال خطی در لایه خروجی به عنوان شبکه بهینه انتخاب شد. یافته‌ها نشان داد که شبکه طراحی شده با ضریب همبستگی ($R=0.90$) و میانگین مربع خطا ($MSE=0.01$) توانایی بالایی در پیش‌بینی حوادث ترافیکی دارد.

نتیجه‌گیری: با توجه به اهمیت پیش‌بینی حوادث ترافیکی و نقش آن جهت ارتقای سلامت افراد جامعه، نتایج حاصل از این مطالعه می‌تواند جهت گسترش اقدامات پیشگیرانه مؤثرتر برای سیاست‌گذاران و محققان قابل استفاده باشد. با توجه به نتایج بدست آمده شبکه عصبی کارایی خوبی برای پیش‌بینی کوتاه‌مدت جریان ترافیک از خود نشان داده است.

اطلاعات مقاله

نویسنده مسئول:

زهرا حق دوست

رایانامه:

Haghdoust.z@tak.ums.ac.ir

وصول مقاله: ۱۴۰۰/۰۴/۰۷

اصلاح نهایی: ۱۴۰۰/۰۶/۲۴

پذیرش نهایی: ۱۴۰۰/۰۶/۳۱

انتشار آنلاین: ۱۴۰۰/۰۹/۲۸

واژه‌های کلیدی:

پیش‌بینی

حوادث ترافیکی

شبکه عصبی مصنوعی

سلامت در بلايا

مدیریت سلامت

واضح، محققان دریافتند که این مدل‌ها قادر به تعیین موقعیت کامل تصادف نیستند. [۱۷] بنابراین، به‌روش‌های داده‌کاوی روی آوردند که به دلیل کاربرد گسترده، روش بسیار مفیدی در پیش‌بینی حوادث ترافیکی محسوب می‌شوند. [۱۸-۲۲] فنون داده‌کاوی یکی از بهترین ابزارها برای پردازش داده‌ها و یافتن الگوی روابط میان متغیرها از مجموعه داده است. در این روش برای بهره‌گیری بهتر از داده‌ها، از مدل‌های مختلف طبقه‌بندی استفاده می‌شود که یکی از بهینه‌ترین مدل‌ها، شبکه عصبی مصنوعی است. [۲۳] شبکه عصبی مصنوعی به‌عنوان زیرمجموعه‌ای از هوش مصنوعی، ابزاری برای مدل‌سازی داده و پردازش اطلاعات است که در یک روش مشابه مغز انسان روابط پیچیده را نشان می‌دهد. [۲۴] شبکه عصبی مصنوعی توانایی قابل توجهی برای تشخیص ارتباطات پیچیده در داده‌های مبهم را دارد. شبکه عصبی مصنوعی برای استخراج الگوها و شناسایی روندهایی استفاده می‌شود که برای انسان یا سایر فنون کامپیوتری بسیار پیچیده هستند. شبکه عصبی آموزش دیده می‌تواند به‌عنوان یک متخصص در مورد تحلیل داده‌ها فکر کند. [۲۵] مطالعات نشان داده است که این شبکه‌ها در مقایسه با سایر رویکردهای سنتی مانند مدل‌های رگرسیونی عملکرد بهتری داشته و به‌عنوان یکی از برترین پیشرفت‌ها در زمینه یادگیری ماشین [۲۶] به‌ویژه در مطالعات حمل‌ونقل [۲۷-۳۳] به‌شمار می‌روند. موسن (Musson) و همکاران [۳۴،۳۵] در دو مطالعه جداگانه با در نظر گرفتن عوامل تأثیرگذار مانند محل تصادف، ویژگی جاده، آب‌وهوا و موقعیت سطح و خطای انسانی، از رویکرد شبکه عصبی مصنوعی سه لایه برای تخمین احتمال تصادف استفاده کردند. نتایج مدل‌سازی نشان داد که شبکه عصبی مصنوعی می‌تواند روش جایگزین خوبی برای پیش‌بینی تصادفات در شهر میلان ایتالیا باشد. همچنین، یاسوینی (Yasaswini) و همکاران [۲۳] و لی (Li) و همکاران [۳۶] با استفاده از شبکه عصبی مصنوعی، ویژگی‌های مختلفی مانند نوع برخورد، شرایط نور، آب‌وهوایی، سطح جاده، سرعت و مست بودن راننده را به‌عنوان عوامل خطر مؤثر در بروز حوادث ترافیکی معرفی کردند. بنابراین، اخیراً پژوهشگران علاقه بسیاری به

حوادث ترافیکی با ۱/۳۵ میلیون مرگ سالانه در جهان، هشتمین علت اصلی مرگ به‌ویژه در گروه سنی پنج تا ۲۹ سال محسوب می‌شود. [۱] در ایران حوادث ترافیکی بعد از بیماری‌های قلبی عروقی رتبه دوم را به خود اختصاص داده است. میزان مرگ‌ومیر ناشی از تصادفات در کشور سالانه به بیش از ۲۳ هزار نفر می‌رسد که این آمار نسبت به کشورهای صنعتی با سطح درآمد مشابه بیشتر است. [۲] با توجه به آنکه در چشم‌انداز سال ۲۰۳۰ برای توسعه پایدار مقرر شده است که کل مرگ‌ومیرها و صدمات ناشی از حوادث ترافیکی به نصف کاهش یابد [۳]؛ لازم است تا دلایل متعددی از جمله انسان، وسیله نقلیه، محیط و جاده که در بروز این حوادث نقش داشته شناسایی شوند. [۴،۵] موقعیت‌های آب‌وهوایی از جمله عوامل تأثیرگذار محیطی هستند که مطالعات مختلف ارتباطات پیچیده‌ای را بین موقعیت‌های آب‌وهوایی و میزان حوادث ترافیکی نشان داده‌اند. [۶] امین و همکاران [۷] در مطالعه خود بیان داشتند که موقعیت‌های آب‌وهوایی نظیر درجه حرارت، بارندگی و سرعت باد از جمله عوامل مهم در ایجاد حوادث ترافیکی محسوب می‌شوند. نتایج لو و همکاران [۸] نیز نشان داد که تأثیر درجه حرارت بر حجم ترافیک در ایجاد حوادث ترافیکی نقش بسیار مؤثری دارد. با توجه به اینکه موقعیت‌های آب‌وهوایی می‌توانند تأثیرات منفی روی عملکرد شبکه حمل‌ونقل داشته باشند، [۹] درک بهتر این موقعیت‌ها می‌تواند در برنامه‌ریزی فعالیت‌های کاهش خطر مرگ‌ومیر به دولت و سازمان‌های مسئول یاری نماید. [۱۰] از دیرباز محققان بر آن شدند تا با استفاده از روش‌های آماری متفاوت ارتباط بین موقعیت‌های آب‌وهوایی و تصادفات ترافیکی را پیدا کنند و به پیش‌بینی این‌گونه حوادث بپردازند. [۱۱،۱۲] الگوریتم‌های زیادی برای پیش‌بینی حوادث ترافیکی پیشنهاد شده است؛ به‌عنوان مثال، در سال ۱۹۸۰ با استفاده از تحلیل جفت‌های جور شده، [۱۳-۱۶] به پیش‌بینی حوادث ترافیکی تحت تأثیر شرایط مختلف آب‌وهوا پرداختند. علیرغم مزایای این‌گونه روش‌های آماری از جمله تفسیر نظری و انجام محاسبات

برخورد با شیء ثابت)، علت تامه تصادف (مانند عدم رعایت حق تقدم، عدم توجه به جلو، تغییر مسیر ناگهانی، انحراف به چپ و راست، حرکت با دنده عقب و گردش در محل های غیرمجاز، عدم توانایی در کنترل وسیله نقلیه، عدم رعایت فاصله طولی)، وضع هندسی محل (مستقیم-مسطح، پیچ-مسطح، سربالایی، سرباينی، پیچ-سربالایی، پیچ-سرباينی، مستقیم-سربالایی، مستقیم-سرباينی)، شرایط سطح راه (خشک، لغزنده و برفی)، وضع روشنایی معبر (با روشنایی کافی، فاقد روشنایی)، جنسیت و سن راننده اشاره کرد. از آنجایی که هدف مطالعه حاضر پیش بینی تعداد تصادفات بود، فقط داده های مرتبط با تعداد تصادفات در محدوده زمانی چهار ساله (۱۳۹۶-۱۳۹۳) به صورت ماهانه وارد مطالعه شد. همچنین داده های آب و هوایی شامل حداقل و میانگین دما، متوسط بارش، حداکثر سرعت باد، یخبندان، فشار هوا و غلظت مه بود که وارد مطالعه شده و مدل سازی انجام شد (جدول یک).

استفاده از این مدل در زمینه حوادث ترافیکی نشان داده اند. [۳۹-۲۸،۳۷] هدف از انجام مطالعه حاضر، پیش بینی حوادث ترافیکی بر اساس وضعیت آب و هوا در استان گیلان با استفاده از شبکه عصبی مصنوعی بود.

روش ها

این مطالعه به صورت کمی - توصیفی در دو مرحله جمع آوری داده، پیاده سازی و مدل سازی شبکه عصبی مصنوعی انجام شد. **مرحله اول (جمع آوری داده):** در این مطالعه مجموعه ای از داده های مربوط به تصادفات و آب و هوا استفاده شد که داده ها به ترتیب از پایگاه تصادفات پلیس راه و اداره کل هواشناسی استان گیلان اخذ گردید. داده های بدست آمده از پایگاه پلیس راه دارای متغیرهای بسیاری به ازای هر تصادف بود که از جمله می توان به متغیر زمان و مکان تصادف، نوع تصادف (خسارتی، جرحی و فوتی)، نوع وسیله نقلیه درگیر، نحوه برخورد وسیله نقلیه (جلو به جلو، جلو به عقب، پهلو به پهلو، جلو به پهلو، برخورد با عابر، برخورد با حیوان،

جدول ۱: متغیرهای ورودی بکار گرفته شده در طراحی مدل اولیه

داده های مدل	متغیرها	نوع متغیر	واحد	کد متغیر
متغیر ورودی ۱	حداقل دما	عددی	درجه سانتی گراد	-
متغیر ورودی ۲	میانگین دما	عددی	درجه سانتی گراد	-
متغیر ورودی ۳	متوسط بارش	عددی	میلی متر	-
متغیر ورودی ۴	حداکثر سرعت باد	عددی	مایل بر ساعت	-
متغیر ورودی ۵	یخبندان	اسمی	-	بله=۱، خیر=۰
متغیر ورودی ۶	فشار هوا	عددی	میلی متر جیوه	-
متغیر ورودی ۷	غلظت مه	اسمی	-	بله=۱، خیر=۰

جدول ۲: اطلاعات توصیفی داده های مربوط به تصادفات و وضعیت آب و هوایی

متغیر آماره	کمی						کیفی					
	حداقل دما	میانگین دما	متوسط بارش	حداکثر سرعت باد	فشار هوا	غلظت مه	متغیر فراوانی	یخبندان		تصادفات		
								بله	خیر	فوتی	خسارتی	جرحی
میانگین	۱۳/۲	۱۷	۴	۴/۷	۱۰۱۵/۸	۰/۱	فراوانی	۳۴۰	۹۷۱۶	۷۰۱۶	۲۷۷۱	۲۶۹
میانه	۱۴	۱۷/۵	۰	۵	۱۰۱۴/۹	۰						
انحراف معیار	۷/۴۱	۷/۸۷	۱۰/۶	۲/۱۱	۱۲/۰۲	۰/۵۱						
مینیمم	-۹/۲	-۹/۲	۰	۰	۷۱۵/۳	۰	درصد فراوانی	۳/۴	۹۶/۶	۶۹/۷	۲۷/۵	۲/۶
ماکزیمم	۳۰	۳۰/۵	۷۶/۴	۲۰	۱۰۸۴	۳۱/۵						
Q1	۷	۱۰	۰	۳	۱۰۱۰/۵	۰						
Q3	۲۰	۲۴/۲	۱/۹	۵	۱۰۲۰/۹	۰						

آماده سازی داده ها قبل از ساخت مدل انجام شد. از بین ۱۰۰۶۹ نمونه مربوط به محورهای مختلف استان گیلان، تمامی نمونه ها با ارزش های گم، پرت و متناقض در ویژگی های انتخابی حذف شدند که شامل ۱۳ نمونه بودند. گزارش توصیفی ۱۰۰۵۶ نمونه استفاده شده که در جدول دو ارائه شده است.

آماده سازی و تقسیم داده ها: ابتدا لازم است پیش از آغاز آموزش شبکه، ورودی ها و مخصوصاً خروجی ها توسط روش های آماری به بازه خاصی محدود شوند. هدف از این تصحیح کاهش خطای مدل سازی شبکه است. این عمل استاندارد سازی یا نرمال سازی داده ها نامیده می شود. برای این منظور تمام داده ها وارد نرم افزار اکسل گردید و از رابطه یک برای نرمال سازی استفاده شد.

رابطه یک
$$a_i = 0.1 + 0.8 \left(\frac{A_i - A_{min}}{A_{max} - A_{min}} \right)$$

 A_i مقدار نرمال شده داده ها، A_i مقدار واقعی داده ها، A_{min} حداقل و A_{max} حداکثر داده های مربوط به پارامتر مورد نظر هستند. با استفاده از رابطه بالا داده ها بین صفر تا یک استاندارد و برای ورود به نرم افزار مدل سازی آماده شدند. به طور کلی داده ها، به صورت کاملاً تصادفی در سه گروه زیر طبقه بندی و استفاده شدند:

الف) داده های آموزشی: بیشترین حجم نمونه مربوط به این داده هاست و نقش مهمی در آموزش شبکه دارند. در این پژوهش ۷۵ درصد داده ها به عنوان داده های آموزشی در نظر گرفته شدند.

ب) داده های آزمون: این مجموعه معمولاً به صورت تصادفی و به منظور ارزیابی کارایی شبکه استفاده می شود، ۱۵ درصد داده های استفاده شده در این پژوهش نیز به داده های آزمون اختصاص داده شدند.

ج) داده های اعتباری: کمترین حجم داده ها (۱۰ درصد) در این مجموعه قرار دارند که این داده ها به منظور اعتبارسنجی مدل برای کنترل نهایی یا به عبارتی برای جلوگیری از بیش برآزش استفاده می شوند. بیش برآزش به حالتی اطلاق می گردد که شبکه طراحی شده به جای یادگیری روابط منطقی بین داده ها، شروع به حفظ کردن سطحی این روابط

می کند. به طوری که در مرحله شبیه سازی، مقدار خطای شبکه عصبی بیش از حد و غیر قابل قبول خواهد بود. برای جلوگیری از وقوع چنین حالتی در این پژوهش نرخ یادگیری به صورت نرخ هوشیارانه برابر ۰/۰۰۱ و تعداد دفعات تکرار در آموزش به صورت پیش فرض برابر ۱۰۰۰ بار انتخاب شد.

مرحله دوم (روند پیاده سازی و مدل سازی): در مطالعه حاضر از شبکه پرسپترون چند لایه برای مدل سازی رابطه غیر-خطی زمینه ای بین تعداد حوادث ترافیکی با عوامل هواشناسی استفاده شد؛ زیرا شبکه پرسپترون چند لایه به عنوان محبوب-ترین شبکه عصبی برای داده کاوی معرفی شده است. [۳۱] مدل استفاده شده برای شبکه پرسپترون چند لایه به صورت جلو رونده با روال تعلیم انتشار به عقب بود. منظور از شبکه های جلو رونده، شبکه هایی هستند که ورودی های لایه اول نورون های آن به لایه های بعدی متصل بوده و در هر سطح این مسئله صادق بوده تا به لایه خروجی برسند. روال انتشار به عقب بدین معنی است که پس از مشخص شدن خروجی شبکه، ابتدا وزن های لایه آخر تصحیح شده، بعد به ترتیب اوزان لایه های قبلی تصحیح می شوند. شبکه های پرسپترون از یک لایه ورودی، تعدادی لایه های میانی و یک لایه خروجی تشکیل شده است. روش استفاده شده برای یادگیری شبکه عصبی مصنوعی به صورت یادگیری با ناظر بود. این نوع یادگیری با تمرکز بر روی یک موضوع خاص و ارائه مثال های مختلفی از آن صورت می گیرد. شبکه اطلاعات ورودی ها و مثال ها را تحلیل کرده، به طوری که پس از مدتی قادر خواهد بود یک نوع جدید (مشاهده نشده) را شناسایی کند. لایه های شبکه عصبی طراحی شده در این پژوهش به صورت سه نوع لایه نورونی بود. به طوری که لایه ورودی برای دریافت اطلاعات خامی استفاده شده است که به شبکه تغذیه می شود. عملکرد لایه های پنهان، به وسیله ورودی ها و وزن ارتباط بین آن ها با لایه های پنهان تعیین شد. وزن های بین لایه های ورودی و پنهان مشخص می کند که چه زمانی یک واحد پنهان باید فعال شود. عملکرد لایه خروجی نیز وابسته به فعالیت واحد پنهان و وزن ارتباط بین واحد پنهان

مارکوآرت (Levenberg-marquardt)، کاهش شیب (Gradient descent with momentum) و گرادیان توأم (Conjugate gradient) اشاره کرد. انتخاب هر یک از این توابع بستگی به کاهش خطای شبکه دارد. از این رو، انتخاب از طریق آزمون و خطا صورت می‌پذیرد. شبکه‌های عصبی مصنوعی نیز همانند نورون‌های طبیعی دارای گره‌های پردازشگری می‌باشند که داده‌های ورودی آن‌ها از گره‌های قبلی وارد می‌شود و توسط تابع انتقال به سمت گره بعد منتقل می‌شود. توابع انتقال (فعال‌ساز) متنوعی در پردازش گره‌های شبکه بکار می‌رود که می‌توان از توابع خطی، لگاریتم سیگموئید و تانژانت سیگموئید به‌عنوان شاخص‌ترین و پرکاربردترین آن‌ها نام برد. ایده‌آل-ترین توابع انتقال، توابع پیوسته، مشتق‌پذیر و یکساخت هستند که موجب تسهیل یافتن وزن‌های شبکه می‌شوند. توابع در لایه‌های میانی و خروجی از طریق آزمون و خطا انتخاب می‌شوند. در جدول سه جزئیات آزمون و خطاهای صورت گرفته برای تعیین توابع بهینه ارائه شده است.

و خروجی است. در این مطالعه برای پیاده‌سازی مدل شبکه عصبی مصنوعی و آموزش و ارزیابی آن از جعبه ابزار متلب (MATLAB) استفاده شد. به‌منظور پیش‌بینی تعداد حوادث ترافیکی هفت متغیر (ویژگی) وارد مدل شدند، متغیرهای مستقل به‌عنوان ورودی (حداقل دما، میانگین دما، متوسط بارش، حداکثر سرعت باد، یخبندان، فشار هوا و غلظت مه) و متغیر وابسته (تعداد تصادفات) به‌عنوان خروجی در نظر گرفته شدند.

انتخاب مناسب‌ترین تعداد نورون‌ها و لایه‌های پنهان:
انتخاب نورون‌ها در لایه ورودی و لایه خروجی در اختیار محقق است؛ اما انتخاب تعداد لایه‌های میانی و تعداد نورون‌های آن از طریق آزمون و خطا صورت می‌پذیرد. کم بودن تعداد نورون‌ها در لایه میانی باعث می‌شود تا پردازش بسیار کند انجام پذیرد؛ بیشتر از حد بودن آن‌ها نیز باعث کاهش تعمیم‌پذیری مدل خواهد شد. از این رو، در پژوهش حاضر تعداد نورون‌های استفاده‌شده در لایه میانی نباید از دو برابر تعداد نورون لایه ورودی تجاوز کند. [۴۰]

انتخاب مناسب‌ترین تابع بهینه‌سازی و فعال‌سازی:

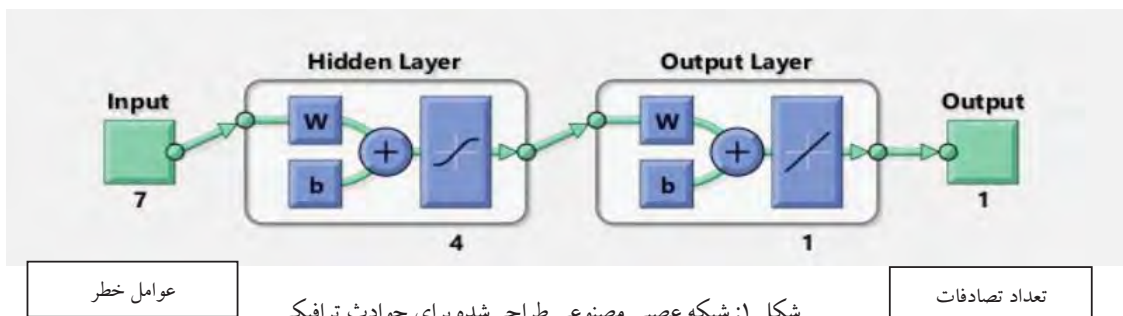
از انواع مختلف توابع بهینه‌سازی می‌توان به تابع لوببرگ-

جدول ۳: جزئیات آزمون و خطاهای صورت گرفته برای تعیین توابع بهینه

ردیف	تعداد نورون‌های لایه ورودی	تعداد نورون‌های لایه میانی	تعداد نورون‌های لایه خروجی	تابع بهینه‌سازی		تابع فعال‌سازی		ضریب همبستگی
				در لایه میانی	در لایه خروجی	میانگین مجذور خطا	میانگین	
۱	۷	۱	۱	کاهش شیب	خطی	خطی	۰/۲۵	۰/۱۱
۲	۷	۲	۱	کاهش شیب	خطی	خطی	۰/۲۹	۰/۱۸
۳	۷	۳	۱	لونیبرگ-مارکوآرت	تانژانت سیگموئید	خطی	۰/۰۷	۰/۶۶
۴	۷	۴	۱	لونیبرگ-مارکوآرت	تانژانت سیگموئید	خطی	۰/۰۱	۰/۹۰
۵	۷	۵	۱	لونیبرگ-مارکوآرت	تانژانت سیگموئید	خطی	۰/۰۳	۰/۷۲
۶	۷	۶	۱	لونیبرگ-مارکوآرت	تانژانت سیگموئید	خطی	۰/۰۹	۰/۵۸
۷	۷	۷	۱	لونیبرگ-مارکوآرت	تانژانت سیگموئید	خطی	۰/۰۹	۰/۵۹
۸	۷	۸	۱	لونیبرگ-مارکوآرت	تانژانت سیگموئید	خطی	۰/۰۷	۰/۶۵
۹	۷	۹	۱	گرادیان توأم	لگاریتم سیگموئید	تانژانت سیگموئید	۰/۱۲	۰/۲۶
۱۰	۷	۱۰	۱	گرادیان توأم	لگاریتم سیگموئید	تانژانت سیگموئید	۰/۱۰	۰/۲۹
۱۱	۷	۱۱	۱	کاهش شیب	خطی	خطی	۰/۳۶	۰/۱۲
۱۲	۷	۱۲	۱	کاهش شیب	خطی	خطی	۰/۲۹	۰/۱۸
۱۳	۷	۱۳	۱	کاهش شیب	خطی	خطی	۰/۳۱	۰/۱۵
۱۴	۷	۱۴	۱	کاهش شیب با مومنتم	لگاریتم سیگموئید	لگاریتم سیگموئید	۰/۱۶	۰/۱۹

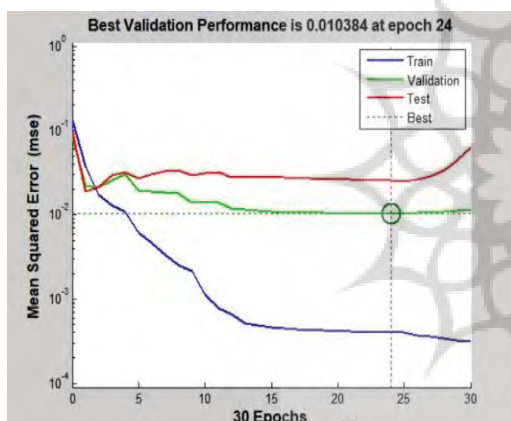
مفروضات ذکر شده و طراحی های متعدد بر اساس آزمون و خطا، مدل شبکه عصبی مصنوعی برای حوادث ترافیکي طراحی شد که در شکل یک نشان داده شده است.

همچنین در این پژوهش تعداد دفعات تکرار در آموزش به صورت پیش فرض برابر ۱۰۰۰ و تعداد چک کردن اعتبار به صورت پیش فرض برابر شش انتخاب گردید. پس از اعمال




برازش نباشد. در نهایت، مدل بهینه شبکه عصبی به صورتی که در جدول چهار نشان داده شده، طراحی و انتخاب گردید.

با توجه به شکل یک، لایه ورودی با هفت نورون، لایه پنهان با چهار نورون، تابع فعال سازی تانژانت سیگموئید، لایه خروجی با یک نورون و تابع فعال سازی خطی به عنوان مدل شبکه عصب مصنوعی طراحی گردید.



نمودار ۱: عملکرد شبکه پیش بینی حوادث ترافیکي بر اساس وضعیت آب و هوا نسبت به عملکرد بهینه در مرحله آموزش



نمودار ۲: عملکرد شبکه عصبی مصنوعی در خصوص جلوگیری از بیش برازش داده ها

جدول ۴: شبکه عصبی طراحی شده بهینه برای پیش بینی حوادث ترافیکي

ساختار	تابع بهینه سازی	تابع انتقال لایه میانی	تابع انتقال لایه خروجی	تعداد تکرار آموزش	MSE	R ²
۷-۴-۱	LM	Tansig	Purelin	۲۴	۰/۰۱۰۳۸۴	۰/۹۰

نتایج آموزش شبکه

با اعمال مفروضات یاد شده، شبکه آموزش داده شد. همان طور که در نمودار یک نشان داده است می توان دریافت که پس از ۲۴ مرحله، شبکه همگرا شده و آموزش پایان یافت. شبکه طراحی شده با تعداد تکرار آموزش ۲۴، دارای میانگین مجذور خطا ۰/۰۱۰ و ضریب همبستگی ۰/۹۰ در مرحله آموزش به عنوان شبکه بهینه انتخاب گردید. نحوه عملکرد شبکه عصبی مصنوعی در خصوص جلوگیری از بیش برازش داده ها در نمودار دو نشان داده شده است. مطابق نمودار دو، شبکه در تعداد تکرار ۲۴ بیش برازش داده ها را به صورت متوالی شروع کرد. در این زمان که تعداد حفظ کردن روابط بین داده ها به جای یادگیری به بیش از شش مرحله متوالی رسید، آموزش شبکه به صورت خودکار قطع شد تا مدل طراحی شده دارای مشکل بیش

۱۳۹۵	مهر	۰/۴۷	۰/۵۰۳۷۷۲	-۰/۰۳۳۷۱۸
	آبان	۰/۴۹	۰/۵۱۹۹۸۱	-۰/۰۲۹۹۸۱۳
	آذر	۰/۶۶	۰/۶۵۷۷۷۱	۰/۰۰۲۲۲۸۹
	دی	۰/۴	۰/۴۰۲۹۱۳	-۰/۰۰۲۹۱۲۵
	بهمن	۰/۶۱	۰/۶۱۲۳۸۷	-۰/۰۰۲۳۸۷۳
	اسفند	۰/۴۵	۰/۴۲۳۸۵۳	۰/۰۲۶۱۴۷۲
	فروردین	۰/۷۸	۰/۷۷۸۸۸۶	۰/۰۰۱۱۱۴۴
	اردیبهشت	۰/۶۹	۰/۵۶۳۸۵۳	۰/۱۲۶۱۴۶۵
	خرداد	۰/۱۸	۰/۱۸۲۶۱۸	-۰/۰۰۲۶۱۷۷
	تیر	۰/۹	۰/۸۹۹۵۶۱	۰/۰۰۰۴۳۸۵
۱۳۹۶	مهر	۰/۸۳	۰/۶۱۶۵۳۹	۰/۳۰۸۰۹۸۳
	آبان	۰/۶۵	۰/۶۱۶۵۳۹	۰/۰۳۳۶۰۷
	آذر	۰/۶۶	۰/۶۵۷۰۷۷	۰/۰۰۲۹۲۳۱
	دی	۰/۵۵	۰/۵۴۳۹۵۵	۰/۰۰۶۰۴۴۶
	بهمن	۰/۶	۰/۴۹۸۸۱۳	۰/۱۰۱۱۸۷۱
	اسفند	۰/۵۲	۰/۴۳۹۰۴۵	۰/۰۸۰۹۵۴۹
	فروردین	۰/۶۲	۰/۴۹۹۶۶۴	۰/۱۵۰۳۳۶۱
	اردیبهشت	۰/۲۹	۰/۲۸۸۳۵۹	۰/۰۰۱۶۴۰۸
	خرداد	۰/۴۹	۰/۴۸۶۱۲۷	۰/۰۰۳۸۷۲۷
	تیر	۰/۵۶	۰/۵۶۴۷۴۳	-۰/۰۰۴۷۴۳۳
۱۳۹۷	مهر	۰/۷۹	۰/۷۸۹۶۴۴	۰/۰۰۰۳۵۶۲
	آبان	۰/۵۶	۰/۵۵۹۲۴	۰/۰۰۰۷۶۰۰
	آذر	۰/۵۲	۰/۴۲۱۳۶۸	۰/۰۹۸۶۳۲۴
	دی	۰/۵۱	۰/۵۲۱۳۶۸	-۰/۰۱۲۱۱۴۴
	بهمن	۰/۵۶	۰/۵۸۳۷۴۹	-۰/۰۲۳۷۴۹۳
	اسفند	۰/۴	۰/۳۸۲۲۸۱	۰/۰۱۷۷۱۹۱
	فروردین	۰/۶	۰/۵۱۱۷	۰/۰۸۸۲۹۹۷
	اردیبهشت	۰/۵۲	۰/۳۸۹۶۲۴	۰/۱۳۰۳۷۵۹
	خرداد	۰/۱	۰/۱۰۱۱۵۱	-۰/۰۰۱۱۵۱۳
	تیر	۰/۵۱	۰/۵۸۵۶۸۵	-۰/۰۷۵۶۸۴۸
۱۳۹۸	مهر	۰/۵۷	۰/۵۰۷۳۲۴	۰/۰۶۲۶۷۵۷
	آبان	۰/۷۳	۰/۷۳۰۷۲۲	-۰/۰۰۰۷۲۳۰
	آذر	۰/۷۳	۰/۷۳۰۷۲۲	-۰/۰۰۰۷۲۳۰

همان‌طور که در جدول چهار نشان داده شده است شبکه طراحی شده، با هفت نورون در لایه ورودی، چهار نورون در لایه میانی و یک نورون در لایه خروجی با تابع بهینه‌سازی لونیگ-مارکواردت و تابع انتقال تانژانت سیگموئید در لایه میانی و تابع انتقال خطی در لایه خروجی و همچنین با تعداد تکرار آموزش ۲۴، دارای میانگین مجذور خطا ۰/۰۱۰۳۸۴ و ضریب تعیین ۰/۹۰، در مرحله آموزش به‌عنوان شبکه بهینه انتخاب شد. خلاصه‌ای از نتایج اهداف، خروجی‌ها و خطاها در جدول پنج نشان داده شده است.

جدول ۵: اهداف، خروجی‌ها و خطاها با استفاده از شبکه عصبی

خطا	خروجی	هدف	سال
-۰/۰۰۰۳۰۶۱	۰/۸۳۰۳۰۶	۰/۸۳	فروردین
-۰/۰۰۲۲۵۵۹	۰/۵۵۲۲۵۶	۰/۵۵	اردیبهشت
۰/۰۰۱۹۱۰۱	۰/۶۱۸۰۹	۰/۶۲	خرداد
-۰/۰۰۱۵۶۳۶	۰/۴۳۱۵۶۴	۰/۴۳	تیر
-۰/۰۰۰۰۷۶۷	۰/۶۵۰۰۷۷	۰/۶۵	مرداد
۰/۰۰۰۸۳۱۰۱	۰/۷۱۱۶۹	۰/۷۲	شهریور
-۰/۰۰۱۳۱۳۰	۰/۴۰۱۳۱۳	۰/۴	مهر
۰/۰۶۸۷۵۷۸	۰/۵۴۱۲۴۲	۰/۶۱	آبان
-۰/۰۳۸۵۰۱۹	۰/۵۲۸۵۰۲	۰/۴۹	آذر
-۰/۰۲۱۷۴۷۶	۰/۵۸۱۷۴۸	۰/۵۶	دی
۰/۱۸۹۱۱۴۲	۰/۴۳۰۸۸۶	۰/۶۲	بهمن
-۰/۱۵۵۳۰۸۸	۰/۷۱۵۳۰۹	۰/۵۶	اسفند
۰/۱۵۰۳۳۶۱	۰/۴۹۹۶۶۴	۰/۶۲	فروردین
۰/۰۰۱۶۴۰۸	۰/۲۸۸۳۵۹	۰/۲۹	اردیبهشت
۰/۰۰۳۸۷۲۷	۰/۴۸۶۱۲۷	۰/۴۹	خرداد
-۰/۰۰۴۷۴۳۳	۰/۵۶۴۷۴۳	۰/۵۶	تیر
۰/۰۰۰۳۵۶۲	۰/۷۸۹۶۴۴	۰/۷۹	مرداد
۰/۰۰۰۷۶۰۰	۰/۵۵۹۲۴	۰/۵۶	شهریور
۰/۰۹۸۶۳۲۴	۰/۴۲۱۳۶۸	۰/۵۲	مهر
-۰/۰۱۲۱۱۴۴	۰/۵۲۱۳۶۸	۰/۵۱	آبان
-۰/۰۲۳۷۴۹۳	۰/۵۸۳۷۴۹	۰/۵۶	آذر
-۰/۰۱۳۶۷۸۲	۰/۳۸۳۶۷۸	۰/۳۷	دی
-۰/۰۰۰۰۹۲۴	۰/۵۱۰۰۹۲	۰/۵۱	بهمن
۰/۰۱۷۷۱۹۱	۰/۳۸۲۲۸۱	۰/۴	اسفند
۰/۰۸۸۲۹۹۷	۰/۵۱۱۷	۰/۶	فروردین
۰/۱۳۰۳۷۵۹	۰/۳۸۹۶۲۴	۰/۵۲	اردیبهشت
-۰/۰۰۱۱۵۱۳	۰/۱۰۱۱۵۱	۰/۱	خرداد
-۰/۰۷۵۶۸۴۸	۰/۵۸۵۶۸۵	۰/۵۱	تیر
۰/۰۶۲۶۷۵۷	۰/۵۰۷۳۲۴	۰/۵۷	مرداد
-۰/۰۰۰۷۲۳۰	۰/۷۳۰۷۲۲	۰/۷۳	شهریور

از آنجایی که شبکه عصبی مصنوعی روشی انعطاف‌پذیر و آسان برای مدل‌سازی داده‌های حوادث ترافیکی است و برخلاف مدل‌های آماری سنتی قادر به ارزیابی و مقایسه تمام ویژگی‌های حوادث رانندگی است، در این مطالعه با استفاده از شبکه پرسپترون چندلایه ارتباط غیرخطی بین تعداد حوادث ترافیکی استان گیلان با عوامل هواشناسی (حداقل دما، میانگین دما، متوسط بارش، حداکثر سرعت باد، یخبندان، فشار هوا، غلظت مه) در محدوده زمانی چهار ساله (۱۳۹۶-۱۳۹۳) مدل‌سازی شد. این مدل با استفاده از یک مجموعه بزرگ از پایگاه داده پلیس و هواشناسی گسترش پیدا کرد و آزمایش شد. سنجش دقت روش شبکه عصبی مصنوعی چندلایه نشان داد که این روش دارای دقت ۹۰ درصد در پیش‌بینی تعداد حوادث ترافیکی در استان گیلان است که نشان‌دهنده اعتبار بالای این روش جهت برآورد و تخمین روند در حوزه سیستم‌های ترافیکی است. نتایج این پژوهش با مطالعه کی‌منش و رحمانیان [۴۱] که به بررسی شدت تصادفات جاده‌ای را با استفاده از شبکه عصبی مصنوعی و روش تحلیل چند متغیره پرداخته همخوانی دارد. در این مطالعه مدل شبکه عصبی مصنوعی نسبت به تحلیل چند متغیره نتایج

بهتری دارد؛ زیرا جمع کل مقدار باقیمانده که تفاوت بین میزان واقعی مشاهده شده و میزان پیش‌بینی شده مدل نشان می‌دهد در مدل شبکه عصبی مصنوعی کمتر است. همچنین، نتایج مطالعه فارسانی و تفتی [۴۲] برای پیش‌بینی کوتاه‌مدت جریان ترافیک از شبکه عصبی مصنوعی استفاده کرد که نتیجه پژوهش مذکور با یافته‌های این پژوهش همخوانی دارد. در این پژوهش از الگوریتم انتشار برگشتی برای آموزش شبکه و از روش لونبرگ - مارکوارت برای کمینه کردن تابع خطا استفاده شد. همچنین، جهت ساخت مدل شبکه عصبی نرم‌افزار متلب به کار گرفته شد. یافته‌ها نشان داد که این مدل با ضریب همبستگی ۹۵ درصد کارایی خوبی برای پیش‌بینی ترافیک دارد. ماشین و همکاران [۴۳] نیز که در مطالعه خود کارایی روش‌های هوش مصنوعی را در کنترل و پیش‌بینی ترافیک، ایمنی جاده و پیش‌بینی تصادفات بررسی کردند. نتایج این پژوهش نشان داد که استفاده از شبکه عصبی مصنوعی، برای مدیریت و تحلیل حجم عظیم داده‌های تولید شده در حمل و نقل بسیار امیدوارکننده به نظر می‌رسد. کانت و همکاران [۴۴] نیز که برای پیش‌بینی شدت تصادف با استفاده از متغیرهای مرتبط (مانند ویژگی‌های راننده، ایمنی وسیله نقلیه، سطح جاده، نوع تصادف و شرایط آب‌وهوایی) از مدل‌های مختلف شبکه عصبی مصنوعی، الگوریتم ژنتیک و الگوریتم فرا ابتکاری ژنتیک ترکیبی استفاده شد و سپس روش‌های جستجوی الگو با همدیگر مقایسه شد. نتایج پژوهش نشان داد که شبکه عصبی مصنوعی بهترین پیش‌بینی را ارائه می‌دهد. در این پژوهش شبکه عصبی مصنوعی از معماری پرسپترون چندلایه استفاده شد. این شبکه در طول آموزش، آزمایش و اعتبارسنجی استفاده شد و دارای ۱۲ ورودی، ۲۵ نورون در لایه‌های پنهان و ۳ نورون در لایه

خروجی بود. بهترین مدل با توجه به مقدار R، خطای جذر میانگین مربعات، میانگین خطاهای مطلق و مجموع مربع خطا انتخاب شد. همچنین، بالاترین مقدار R برای شبکه عصبی مصنوعی در حدود ۰/۸۷ بدست آمد. در کل می‌توان چنین بیان داشت که پیش‌بینی حوادث ترافیکی برای استان گیلان به دلیل موقعیت گردشگری و دارا بودن حجم بالایی از حوادث ترافیکی امری ضروری است؛ که این مهم جزء با دسترسی به داده‌های معتبر و رویکردهای قابل اعتماد مانند شبکه عصبی مصنوعی امکان‌پذیر نیست. نتایج حاصل از این مطالعه جهت گسترش اقدامات پیشگیرانه مؤثرتر برای سیاست‌گذاران و محققان قابل استفاده است. از نقاط قوت این پژوهش استفاده از مدل شبکه عصبی مصنوعی برای تحلیل مشکلات ترافیکی است که کمتر از این روش در پیش‌بینی و تخمین روند داده‌های سری زمانی مربوط به سیستم‌های ترافیکی در استان گیلان استفاده می‌گردد. یکی از محدودیت‌های این مطالعه دسترسی نداشتن به اطلاعاتی مانند مصرف الکل یا مواد مخدر توسط رانندگان است که می‌تواند به‌عنوان متغیر مخدوش‌کننده در بروز حوادث ترافیکی تأثیر داشته باشد. پیشنهاد می‌گردد که در مطالعات آینده ویژگی‌های مختلف دیگری نظیر ویژگی‌های مربوط به راننده، جاده و یا وسیله نقلیه به‌عنوان داده‌های ورودی برای پیش‌بینی حوادث ترافیکی استفاده شود. همچنین، با تنظیم متغیرهای ورودی، پیش‌بینی شدت حوادث ترافیکی بر اساس ویژگی‌های مختلف تصادفات برای سال‌های آینده انجام گیرد. در نهایت با توجه به اینکه نتایج مدل‌سازی موجود با استفاده از داده‌های چهار ساله انجام شد، پیشنهاد می‌شود تحقیقات آینده با مجموعه داده‌های وسیع‌تری صورت گیرد.

تضاد منافع: نویسندگان مقاله اظهار داشتند که تضاد منافی

وجود ندارد.

تشکر و قدردانی: نویسندگان مراتب سپاس و قدردانی خود را از مرکز تحقیقات تروما جاده‌ای دانشگاه علوم پزشکی گیلان و اداره کل هواشناسی استان گیلان جهت فراهم‌سازی داده اعلام می‌نمایند.

ملاحظات اخلاقی

رعایت دستورالعمل‌های اخلاقی: در طول پژوهش حاضر، تمامی ملاحظات اخلاقی از جمله شرط صداقت و رعایت امانت در پژوهش در نظر گرفته شده است.

حمایت مالی: این پژوهش بدون حمایت مالی انجام شده است.

References

1. World Health Organization. Global status report on road safety 2018: Summary. Geneva: World Health Organization; 2018. 403 p.
2. Nazmfar H, Eshghei Char Borj A, Alavi S, Jasaraty A. Spatial analysis of road accidents resulting in death approach to climate case study: Ardabil province. *Geographical Data (SEPEHR)*. 2017;26(103):83-97. [In Persian]
3. Zhao Y, Andrey J, Deadman P. Whether conversion and weather matter to roundabout safety. *J Safety Res*. 2018 Jul 17;66:151-9.
4. Haddon W. Advances in the epidemiology of injuries as a basis for public policy. *Public Health Rep*. 1980;95(5):411-21.
5. Ivajnsic D, Pintaric D, Grujic VJ, Zibera I. A spatial decision support system for traffic accident prevention in different weather conditions. *Acta geogr slov*. 2021;61(1):75-92.
6. Zou Y, Zhang Y, Cheng K. Exploring the impact of climate and extreme weather on fatal traffic accidents. *Sustainability*. 2021 Jan 14;13(1):1-14.
7. Amin MSR, Zareie A, Amador-Jiménez LE. Climate change modeling and the weather-related road accidents in Canada. *Transport Res Transport Environ*. 2014;32:171-83.
8. Luo Z, Li J, Zhong M. Prediction of seasonal variation in traffic collisions on rural highways using neural network regression models: A case study in the province of british columbia. *Proceedings of the 5th International Conference on Transportation Information and Safety (ictis 2019)*; 2019 Jul 14-17; Liverpool, UK. New York: IEEE; 2019 Oct 28. p. 281-5.
9. Bartlett A, Lao W, Zhao Y, Sadek AW. Impact of inclement weather on hourly traffic volumes in Buffalo. *Proceedings of the Transportation Research Board 92nd Annual Meeting [Internet]*; 2013 Jan 13-17; Washington DC, United States. New York; 2013. p. 1-16. Available from: <https://trid.trb.org/view/1241923>
10. Sathiaraj D, Pankasem TO, Wang F, Seedah DPK. Data-driven analysis on the effects of extreme weather elements on traffic volume in Atlanta, GA, USA. *Comput Environ Urban Syst*. Forthcoming 2018.
11. Hosseini M, Najafi Moghaddam Gilani V, Tahmasbi Amoli H, Nikookar M, Oruei A. Presentation of analytical methods for better decision making about the most important factor influencing rural accidents. *Math Probl Eng*. 2021 Mar 20;2021:1-16.
12. Hou G, Chen S. Study of work zone traffic safety under adverse driving conditions with a microscopic traffic simulation approach. *Accid Anal Prev*. 2020 Sep;145:1-46.
13. Johal H, Schemitsch EH, Bhandari M. Why a decade of road traffic safety? *J Orthop Trauma*. 2014 Jun;28(6):S8-10.
14. Andrey J, Olley R. The relationship between weather and road safety: Past and future research directions. *Climatological Bulletin*. 1990;24(3):123-37.
15. Andrey J, Yagar S. A temporal analysis of rain-related crash risk. *Accid Anal Prev*. 1993;25(4):465-72.
16. Bertness J. Rain-related impacts on selected transportation activities and utility services in the chicago area. *J Appl Meteorol Climatol*. 1980 May;19(5):545-56.
17. Irfan A, Rasyid RA, Handayani S. Data mining applied for accident prediction model in Indonesia toll road. *AIP Conference Proceedings 1977 [Internet]*. 2018. AIP Publishing LLC; 2018 Jun 26. p. 060001-9. Available from: <https://aip.scitation.org/doi/10.1063/1.5043013>
18. Brodsky H, Hakkert AS. Risk of a road accident in rainy weather. *Accid Anal Prev*. 1988 Jun;20(3):161-76.
19. Brijs T, Karlis D, Wets G. Studying the effect of weather conditions on daily crash counts using a discrete time-series model. *Accid Anal Prev*. 2008;40(3):1180-90.
20. Caliendo C, Guida M, Parisi A. A crash-prediction model for multilane roads. *Accid Anal Prev*. 2007 Jul;39(4):657-70.

21. Eisenberg D. The mixed effects of precipitation on traffic crashes. *Accid Anal Prev.* 2004 Jul;36(4):637-47.
22. Jung S, Qin X, Noyce DA. Rainfall effect on single-vehicle crash severities using polychotomous response models. *Accid Anal Prev.* 2010 Jan;42:213-24.
23. Yasaswini LNS, Mahesh G, Shankar RS, Srinivas LV. Identifying road accidents severity using convolutional neural networks. *J Comput Sci Eng.* 2018 Jul;6(7):354-60.
24. Alkheder S, Taamneh M, Taamneh S. Severity prediction of traffic accident using an artificial neural network. *J Forecast.* 2016 Apr 27;36:100-8.
25. Ertugrul S, Hizal NA. Neuro-fuzzy controller design via modeling human operator actions. *J Intell Fuzzy Syst.* 2005;16(2):133-40.
26. Adeli H, Park HS. Optimization of space structures by neural dynamics. *Neural Network.* 1995;8(5):769-81.
27. Dougherty MS. Guest editorial applications of neural networks in transportation. *Transport Res C Emerg Tech.* 1997;5(5):255-7.
28. Chang LY. Analysis of freeway accident frequencies: Negative binomial regression versus artificial neural network. *Saf Sci.* 2005;43(8):541-57.
29. Zeng Q, Huang H, Pei X, Wong SC. Modeling nonlinear relationship between crash frequency by severity and contributing factors by neural networks. *Anal Methods Accid Res.* 2016 Jun;10:12-25.
30. Behbahani H, Amiri AM, Imaninasab R, Alizamir M. Forecasting accident frequency of an urban road network: A comparison of four artificial neural network techniques. *J Forecast.* 2018 Aug;37(7):1-14.
31. Deka L, Quddus M. Network-level accident-mapping: Distance based pattern matching using artificial neural network. *Accid Anal Prev.* 2014;65:105-13.
32. Xie Z, Klionsky DJ. Autophagosome formation: Core machinery and adaptations. *Nat Cell Biol.* 2007 Oct;9(10):1102-9.
33. Jadaan KS, Al-Fayyad M, Gammoh HF. Prediction of road traffic accidents in Jordan using artificial neural network (ANN). *Journal of Traffic and Logistics Engineering.* 2014 Jun;2(2):92-4.
34. Mussone L, Ferrari A, Oneta M. An analysis of urban collisions using an artificial intelligence model. *Accid Anal Prev.* 1999 Nov;31(6):705-18.
35. Mussone L, Rinelli S, Reitani G. Estimating the accident probability of a vehicular flow by means of an artificial neural network. *Environ Plann B Plann Des.* 1996;23(6):667-75.
36. Li L, Shrestha S, Hu G. Analysis of road traffic fatal accidents using data mining techniques. *Proceedings of the 15th International Conference on Software Engineering Research, Management and Applications (SERA);* 2017 Jun 7-9; London, UK. IEEE; 2017 Jul 3. p. 363-70.
37. Sameen MI, Pradhan B. Severity prediction of traffic accidents with recurrent neural networks. *Appl Sci.* 2017 Jun 8;7(6):1-17.
38. Chiou YC. An artificial neural network-based expert system for the appraisal of two-car crash accidents. *Accid Anal Prev.* 2006 Jul;38(4):777-85.
39. El Tayeb AA, Pareek V, Araar A. Applying association rules mining algorithms for traffic accidents in Dubai. *International Journal of Soft Computing and Engineering.* 2015 Sep;5(4):1-12.
40. Najjarzadeh M, Korkeh Abadi Z, Kamyabi S. Modeling physical effective factors in promoting good governance through neural network (MLP)-case study of pedestrian roads in district 12 of Tehran. *J Geogr Sci.* 2020;16(32):93-106. [In Persian]
41. Keymanesh M, Baradaran Rahmanian N. Prediction of the road accidents severity using artificial neural network and comparing with multivariate analysis method. *Road.* 2021;106:1-9. [In Persian]

42. Asadi Farsani P, Fallah Tafti M. Artificial neural network model for short-term prediction of traffic flow and its application in Tehran-Karaj freeway. Proceedings of the International Conference on Civil Engineering, Architecture and Urban Infrastructure; 2015 Aug 28-29; Tabriz. Yazd University; 2015. [In Persian]
43. Machin M, Sanguesa JA, Garrido P, Martinez FJ. On the use of artificial intelligence techniques in intelligent transportation systems. Proceedings of the Wireless Communications and Networking Conference Workshops (WCNCW); 2018 April 15-18; Barcelona, Spain. IEEE; 2018 May 31. p. 332-7.
44. Kunt MM, Aghayan I, Noii N. Prediction for traffic accident severity: Comparing the artificial neural network, genetic algorithm, combined genetic algorithm and pattern search methods. Transport. 2011;26(4):353-66.

