



Online ISSN: 2821-1782

**Journal of Land Ecology**

journal homepage: <http://www.landscapeecologyjournals.ir/>



Research Paper

## **Evaluation Of The Effectiveness Of Neural Network Models In The Modeling Of Intra-City Highway Accidents**

**Ebrahim moorvari**<sup>\*a</sup>

<sup>a</sup>Transportation Engineering Expert Of Garme Municipality, Garme , Iran.

### **ARTICLE INFO**

#### **Article history:**

Received: 2022-11-24

Accepted: 2023-01-17

#### **Keywords:**

Accidents Urban

Highways Modeling

Accidents Neural

Networks Models

### **ABSTRACT**

This paper discusses research evaluating the efficiency of neural network models in modeling inner-city highway accidents. As a case study, accident data from urban highways in Mashhad and variables related to traffic flow and road geometry are used as input variables for neural network modeling. Neural network modeling involves three steps: determining the neural network architecture, determining the transfer functions, training and errors, and creating neural network models. In this research, two neural network models were presented to estimate the number of financial and fatal accidents on inner-city highways. To evaluate the efficiency and accuracy of the models, the number of accidents estimated by the models was compared with the observed number and the value of R was used. On this basis, the presented models are suitable for estimating the number of financial and fatal accidents.

\*Corresponding Author.

Email Addresses: [moorvariebrahim@gmail.com](mailto:moorvariebrahim@gmail.com)

**To cite this article:**

moorvari, E. (2022). **Evaluation Of The Effectiveness Of Neural Network Models In The Modeling Of Intra-City Highway Accidents.**

.. *Land Ecology*, 1(1), 38-49.



Doi: [10.22034/el.2022.362191.1002](https://doi.org/10.22034/el.2022.362191.1002)





## ارزیابی کارایی مدل های شبکه عصبی در مدل سازی تصادفات بزرگراه های درون شهری

ابراهیم مرواری<sup>\*۱</sup>

<sup>\*۱</sup> کارشناس مهندسی حمل و نقل شهرداری گرمه، گرمه، ایران.

اطلاعات مقاله

چکیده

### دریافت مقاله:

۰۳ آذر ۱۴۰۱

پذیرش نهایی:

۲۷ دی ۱۴۰۱

در این مقاله به پژوهشی که برای ارزیابی کارایی مدل های شبکه عصبی در مدل سازی تصادفات بزرگراه های درون شهری انجام شده است پرداخته می شود. به عنوان مطالعه موردی از داده های تصادفات بزرگراه های شهری مشهد و از متغیرهای مربوط به جریان ترافیک و طرح هندسی راه به عنوان متغیرهای ورودی مدل ها برای مدل سازی با شبکه های عصبی استفاده می شود. مدل سازی با شبکه های عصبی شامل سه مرحله تعیین معماری شبکه عصبی، تعیین توابع انتقال، آموزش و خطا و ساخت مدل های شبکه عصبی می شود. در این پژوهش، دو مدل شبکه عصبی برای برآورد شمار تصادفات مالی و جانی در بزرگراه های درون شهری ارائه شده است. برای ارزیابی کارایی و دقت مدل ها، به مقایسه شمار برآورد شده تصادفات توسط مدل ها با شمار مشاهده شده پرداخته و از مقدار  $R^2$  استفاده شده است. براین پایه، مدل های ارائه شده برای برآورد شمار تصادفات مالی و جانی مناسب است. از این رو می توان کارایی مدل های شبکه عصبی را در مدل سازی تصادفات مالی و جانی در بزرگراه های درون شهری تأیید نمود.

### واژگان کلیدی:

تصادفات بزرگراه های

درون شهری مدل سازی

تصادفات مدل های شبکه

عصبی

## ۱. مقدمه

علت رخداد تصادفات ترافیکی می تواند یک عامل یا ترکیبی از عوامل مختلف باشد. عوامل شناخته شده ای که می توانند در رخداد تصادفات و شدت آنها مؤثر باشند را می توان به پنج دسته کلی جدا کرد: ۱- عوامل مربوط به جریان ترافیک شامل حجم ترافیک، سرعت، چگالی، نسبت حجم به گنجایش  $V/C$  و ... ۲- عوامل مربوط به طرح هندسی راه شامل شمار خطوط، پهنا، راه، شمار راه های دسترسی، شمار و درجه قوس های افقی، شمار و شیب قوس های قائم و ... ۳- عوامل مربوط به آب و هوا مانند وضع هوا (آفتابی، ابری، باران و...)، دما، میزان رطوبت، سرعت باد و ... ۴- عوامل مربوط به روسازی راه مانند شاخص خدمت پذیری حاضر (PSI)، شاخص بین المللی زبری (IRI)، عمق شیارشدگی، مقاومت لغزشی و ... ۵- عوامل مربوط به ویژگی ها و رفتارهای رانندگان مانند سن، جنس، خوردن نوشیدنی های الکلی، بستن کمربند ایمنی و ...

تاکنون پژوهش های فراوانی برای مدل سازی شمار و شدت تصادفات ترافیکی به روش های گوناگون صورت گرفته است تا عوامل مؤثر بر رخداد تصادفات و شدت آنها را شناسایی و میزان تأثیر هر یک را در رخداد تصادفات تعیین کنند. اما همیشه نتایج و مدل های ساخته شده در برآورد این عوامل و وزن آنها با یکدیگر تفاوت هایی داشته است که گاه بحث برانگیز است. این تفاوت ها همیشه ناشی از تفاوت در نوع راه (آزادراه، بزرگراه، شریانی، دوخطه دوطرفه و ...)، طرح هندسی، ترافیک، روسازی راه، آب و هوا، کاربری حریم و اطراف راه و حتی زمان یا دوره زمانی گردآوری داده های تصادفات و معیارهایی از این دست نیست. بلکه این تفاوت ها ناشی از ناهمسانی در روش های مدل سازی است. چهار روش کلی شناخته شده برای ساخت مدل های پیش بینی تصادفات عبارتند از [۱]: روش های تحلیل چندمتغیره [۲ و ۳ و ۴]، روش های بیز [۵ و ۶ و ۷]، روش های شبکه عصبی [۸ و ۹] و روش های برپایه منطق فازی [۱۰ و ۱۱ و ۱۲]. از میان این روش ها، روش های تحلیل چندمتغیره سالیان درازی بطور موفقیت آمیز برای مدل سازی تصادفات بکار رفته است اما امروزه این روش ها جای خود را به روش های مدل سازی به روزتر و کارآمدتر مانند روش های مدل سازی با استفاده از شبکه های عصبی، منطق فازی، روش های بیز تجربی و کامل و روش های تلفیقی توانمند مانند شبکه های عصبی فازی، شبکه های عصبی بیز داده اند. هر چند استفاده از شبکه های عصبی، منطق فازی و روش های بیز تجربی و کامل و روش های تلفیقی توانمند مانند شبکه های عصبی فازی، شبکه شده و در حوزه های مختلف مدل سازی تصادفات به بررسی و اثبات کارایی آنها در مدل سازی تصادفات پرداخته می شود، اما روش های مدل سازی تازه تر مانند روش های تلفیقی، با وجود اینکه از توانایی بالایی در پیش بینی تصادفات برخوردار است، اما پیشینه زیادی ندارد و مدت های زیادی نیست که در عرصه مدل سازی مطرح شده است. از این رو این روش ها هنوز در مرحله تکامل است و برای کاربرد گسترده تر آنها در تحلیل و مدل سازی تصادفات نیاز به تحقیقات بیشتری است. اکثر روش های تحلیل چندمتغیره با مدل های رگرسیونی سروکار دارد و اساساً مدل های رگرسیونی، پرکاربردترین مدل های چند متغیره هستند. پرکاربردترین مدل های رگرسیونی در مدل سازی تصادفات، برآورد میزان ریسک رخداد تصادفات و تعیین نقاط حادثه خیز، مدل رگرسیون لجستیک (لاجیت دوتایی) و مدل های رگرسیون پرفر است. مدل رگرسیون لجستیک یک روش آماری است که اغلب برای تحلیل داده های تصادفات خودرویی بکار می رود. این مدل را می توان یک مدل رگرسیون تبدیل یافته دانست که در آن متغیر وابسته با یک تابع پیوندی لاجیت که لگاریتم نسبت تباین می باشد، تبدیل می یابد.

Chang (۲۰۰۵) از شبکه عصبی مصنوعی برای تحلیل فراوانی تصادفات آزادراهها استفاده کرد و با نشان دادن این حقیقت که در روش شبکه عصبی مصنوعی، برخلاف روش های تحلیل چندمتغیره بویژه مدل رگرسیون دوجمله ای منفی، نیازی به ارتباط از پیش تعریف شده ای بین متغیرهای ورودی مدل و متغیرهای وابسته وجود ندارد، کارایی و توانمندی این روش را در برابر روش های تحلیل چندمتغیره ثابت کرد [۸]. در سال های نزدیک، منطق فازی به عنوان یک ابزار سودمند برای فرآیندهای مدل سازی نمود یافته است، فرآیندهایی که برای تکنیک های مقداری مرسوم پیچیده اند یا وقتی دانسته های بدست آمده از فرآیند، کیفی، مبهم یا غیر قطعی باشند. منطق فازی، دانسته های کیفی را به گونه ای بیان می کند که برای تصمیم گیری و استدلال منطقی انسان پذیرفتنی و قابل درک باشد. Meng و همکارانش (۲۰۰۹) از منطق فازی برای پیش بین فراوانی تصادفات راه های درون شهری از روی ویژگی های هندسی و ترافیکی راهها استفاده کردند و پی بردند که ترافیک متوسط روزانه در سال (AADT) و بارهای ترافیکی نقش عمده ای در رخداد تصادفات ایفا می کنند [۱۰]. به روز ترین روش برای مدل سازی تصادفات روش توانمند شبکه عصبی فازی است که در واقع تلفیقی از دو روش اشاره شده است. Meng و Zheng (۲۰۱۱) برای ارزیابی کارایی مدل تلفیقی شبکه عصبی فازی در برابر مدل های منطق فازی و شبکه عصبی، از مقایسه مقادیر آماری جذر میانگین مربع خطاها (RMSE)، بیشینه خطای نسبی (MRE) و ضریب همبستگی  $R^2$  بهره گرفتند و به این نتیجه رسیدند که مدل تلفیقی با ساختار و روش کار ساده تر، جایگزین مطمئنی برای مدل شبکه عصبی با ساختاری پیچیده و روش کاری زمان بر است، در حالی که نتایج بسیار بهتری نسبت به مدل منطق فازی هم بدست می دهد [۱۳].

در این پژوهش از متغیرهای مربوط به جریان ترافیک شامل حجم و سرعت و متغیرهای مربوط به طرح هندسی راه شامل شمار خطوط، شمار قوس های افقی و شمار راههای دسترسی به عنوان متغیرهای ورودی مدل ها استفاده شده است. در پژوهش پیش رو تصادفات مالی و تصادفات جانی (جرعی و فوتی) در بزرگراه های درون شهری مشهود با استفاده از شبکه های عصبی مدل سازی شده است. در این پژوهش حجم کل ترافیک (معادل

سواری) به حجم خودروهای سواری، حجم خودروهای سنگین (معادل سواری) شامل تریلی، کامیون، اتوبوس و مینی بوس و حجم خودروهای غیر سواری سبک (معادل سواری) شامل تاکسی، وانت و موتورسیکلت جدا شده است.

برای مدل سازی تصادفات بزرگراه های درون شهری از داده های تصادفات بزرگراه های شهر مشهد در سال های ۹۸ و ۹۹ استفاده شده است. این اطلاعات توسط سازمان حمل و نقل و ترافیک مشهد به کمک GIS و با استفاده از گزارشات پلیس گردآوری شده است. برای گردآوری آمار تصادفات، بزرگراه ها به بخش هایی با حجم ترافیک ثابت تقسیم می شود، همچنین در هر بخش شمار تصادفات برای ساعت های مختلف شبانه روز گردآوری می شود. در واقع داده های تصادفات داده هایی دو سطحه در نظر گرفته می شوند؛ سطح اول، بخش های راه با حجم ترافیک ثابت و سطح دوم، ساعت های شبانه روز می باشد بطوری که ساعتهای اوج ترافیک به عنوان زیرسطح اول، ساعت های غیراوج روز، زیرسطح دوم و ساعت های غیر اوج شب به عنوان زیرسطح سوم در نظر گرفته شده است.


هدف پژوهشگر در این پژوهش، ارزیابی کارایی مدل های شبکه عصبی در مدل سازی تصادفات مالی و جانی در بزرگراه های درون شهری است. برای این کار از نرم افزار MATLAB، بسته شبکه عصبی استفاده می شود. مراحل ساخت مدل ها شامل تعیین معماری شبکه عصبی، تعیین توابع انتقال، آموزش و خطا و ساخت مدل های شبکه عصبی می باشد که در بخش ۲ و ۴ بطور مفصل به آن پرداخته خواهد شد. پس از ساخت مدل های شبکه عصبی برای برآورد شمار تصادفات در بزرگراه های درون شهری، شمار برآورد شده تصادفات مالی و جانی توسط دو مدل، با شمار مشاهده شده تصادفات مقایسه می گردد. نتایج مقایسه، دقت و کارایی مدل های شبکه عصبی ساخته شده را در برآورد شمار تصادفات مالی و جانی در بزرگراه های درون شهری نشان می دهد.

## ۲. معرفی مدل های شبکه عصبی

### ۲-۱ معرفی شبکه های عصبی مصنوعی و کاربردهای آن

شبکه های عصبی مصنوعی (ANN)، الگوریتم های رایانه ای هستند که برگرفته از ساختار و رفتار نرون های واقعی هستند. ANN از مجموعه ای از واحدهای پردازش تشکیل یافته اند که نرون ها را شبیه سازی می کنند و با مجموعه ای از پیوندها به یکدیگر متصل هستند که به سیگنال ها اجازه می دهد که هم بطور موازی و هم بطور سری حرکت کنند. هر پیوند، خروجی هر واحد را در یک عامل وزنی، که به واقع قدرت اتصال در هر سیناپس است، ضرب می کند. پس از آن پیوند، مقدار خروجی وزن داده شده را به واحد دیگر منتقل می کند که مقادیر وارد شده را با مقادیر پیوندهای دیگر جمع می کند. اگر مقدار کل ورودی از مقدار آستانه تعیین شده فراتر رود، آن واحد از بین می رود. اصلاحات در الگوهای از بین رفتن، آموزش را تشکیل می دهد. ANN از لایه هایی تشکیل شده است که به سه دسته تقسیم می شوند (شکل ۱): ۱- لایه ای از واحدهای ورودی؛ اطلاعاتی که به شبکه خورنده می شود را نمایش می دهد. ۲- لایه ای از واحدهای خروجی؛ خروجی شبکه را نمایش می دهد. ۳- یک یا چند لایه پنهان بین دو لایه قبلی [۱۴].

برای آموزش شبکه عصبی مصنوعی (ANN)، با یک هدف مشخص برای نمونه مدل سازی تصادفات، نخست باید نحوه چینش و پیوند واحدها به یکدیگر در قالب معماری شبکه تعیین شود. آموزش، ارائه شبکه عصبی با نمونه های مشخص است که مجموعه داده ها گفته می شود. این مجموعه داده ها شامل الگویی از فعالیت های ورودی برای واحدهای ورودی همراه با الگوی مطلوب فعالیت ها برای واحدهای خروجی است. مجموعه داده ها بارها به شبکه ارائه می شوند و وزن ها پس از هر بار ارائه بهنگام می شوند تا آموزش را شکل دهند.



شکل ۱. مدل شبکه عصبی پس انتشار

یکی از موفق ترین روش های آموزش با سرپرستی، الگوریتم پس انتشار است. مفهوم اساسی، استفاده از مشتق یک تابع خطا برای یافتن جهتی است که خطای شبکه را مینیمم و از آنجا وزن ها را بهنگام می کند [۱۵]. از این رو در این پژوهش نیز از الگوریتم پس انتشار استفاده می شود.

### ۲-۲ بیان ریاضی الگوریتم پس انتشار

هنگام ارائه نمونه آموزشی  $n$  ام به شبکه، خطای خروجی نرون  $i$  ام لایه خروجی در تکرار  $n$  ام مانند زیر است:

$$e_i(n) = d_i(n) - y_i(n) \quad (1)$$

که در آن  $d_i(n)$  پاسخ مطلوب و  $y_i(n)$  خروجی واحد  $i$  ام است. اگر انرژی خطا برای نرون  $i$  ام برابر  $\frac{1}{2} e_i^2(n)$  باشد، انرژی خطای کل برای تمام نرون های لایه خروجی برابر خواهد بود با:

$$E_{av} = \frac{1}{N} \sum_{n=1}^m e_i^2(n) \quad (2)$$

که در آن  $m$  شمار واحدهای لایه خروجی است. اگر  $N$  نمونه آموزشی به عنوان مجموعه داده ها به شبکه عصبی ارائه شود، میانگین مربعات انرژی خطا با جمع کردن  $E(n)$  ها و  $N$  بار نرمال کردن آن مانند زیر خواهد بود:

$$E_{av} = \frac{1}{N} \sum_{n=1}^N E(n) \quad (3)$$

برای یک مجموعه داده آموزشی،  $E_{av}$  معرف تابع هزینه است. هدف از فرآیند آموزش، کمینه کردن  $E_{av}$  است. روش ساده آموزش، بهنگام سازی وزن ها با بارها ارائه مجموعه داده به شبکه در طی یک دوره است.


الگوریتم پس انتشار، وزن  $W_{ij}(n)$  را به مقدار  $\Delta W_{ij}(n)$  اصلاح می کند. این اصلاح وزن، با مشتق نسبی  $E(n)$  نسبت به  $W_{ij}(n)$  متناسب است. این مشتق نسبی برای یافتن جهتی در فضای وزن هاست که با کاهش گرادیان، خطای شبکه را کمینه و بدنبال آن وزن ها را بهنگام می کند. رابطه اصلاح وزن مانند زیر است:

$$\Delta W_{ij}(n) = -\eta \frac{\partial E(n)}{\partial W_{ij}(n)} \quad (4)$$

که در آن  $\eta$  ضریب یادگیری است و علامت منفی نشان دهنده کاهش گرادیان در فضای وزن هاست [۱۶].

### ۲-۳ معماری شبکه عصبی

در این مرحله از مدل سازی با شبکه های عصبی، تعداد لایه ها و گره های شبکه، نوع شبکه و توابع آموزش و انتقال، انتخاب می شوند. معمولاً شبکه های عصبی دارای دو نوع معماری به صورت پیش خور و پس خورد، بطوری که در شبکه های عصبی پیش خور از گره های لایه های بالاتر به گره های لایه های پایین تر سیگنال منتقل نمی شود، اما در شبکه های عصبی پس خور از گره های لایه های بالاتر به گره های لایه های پایین تر سیگنال منتقل می شود. معمولاً در بحث مدل سازی تصادفات شبکه های چندلایه پیش خور بیشترین کاربرد را دارند از این رو در این مقاله نیز از شبکه های عصبی پیش خور استفاده شده است. فرض کنیم یک شبکه عصبی بسازیم برای مدل کردن بردار مقادیر هدف  $t^n = (t_1^n, \dots, t_d^n)$  که از میان  $N$  داده در مجموعه داده هدف (آموزش یا آزمون شبکه)  $T = (t^1, \dots, t^N)$ ، بر پایه متغیرهای ورودی  $x^n = (x_1^n, \dots, x_e^n)$  از مجموعه داده  $X = (x^1, \dots, x^N)$ ، انتخاب شده است. معماری یک شبکه عصبی پیش خور با ویژگی های اشاره شده مانند زیر است:



شکل ۲. مدل شبکه عصبی چندلایه پیش خور

مطابق شکل (۲) لایه ورودی  $e$  گره ورودی، لایه پنهان  $h$  گره و لایه خروجی  $d$  گره دارد. لایه ورودی، بردار مقادیر ورودی  $x^n$  را که در شبکه پردازش می شوند دریافت می کند تا به بردار مقادیر خروجی  $y(x^n) = (y_1(x^n), \dots, y_d(x^n))$  تبدیل کند [۱۷]. برای نمونه در بحث مدل سازی تصادفات، بردار متغیرهای ورودی شامل عوامل مربوط به جریان ترافیک، طرح هند سی راه و دیگر عواملی که به نظر می رسد در رخداد تصادفات و شدت آنها مؤثرند می باشد، در حالی که بردار مقادیر خروجی شامل شمار تصادفات با شدت های گوناگون است. در این مقاله شمار تصادفات به دو دسته تصادفات مالی (خسارتی) و جانی (جرچی و فوتی) جدا شده پس بردار مقادیر خروجی، دارای دو مؤلفه شمار تصادفات مالی و شمار تصادفات جانی است یا به بیان غیر برداری، لایه خروجی ۲ نرون خواهد داشت. لایه پنهان شبکه در واقع هسته اصلی برآورد مدل است. ممکن است اهداف مدل سازی یا طراحی شبکه اقتضا کند که شبکه چندین لایه پنهان داشته باشد. در این صورت هر چند عملکرد شبکه پیچیده تر می شود، ممکن است دقت عمل بالاتر نرود. معمولاً برای اهداف مدل سازی تصادفات می توان به یک لایه پنهان بسنده کرد. اما تعیین اینکه آن لایه پنهان چند نرون باید داشته باشد، موضوعی است که در بخش ۴ به آن خواهیم پرداخت. همچنین با توجه به اینکه  $Y$  متغیر ورودی شامل حجم خودروهای سواری، خودروهای سنگین، غیر سواری سبک، سرعت، شمار خطوط، قوس های افقی و راه های دسترسی در این پژوهش به عنوان عواملی که به نظر می رسد در رخداد تصادفات نقش داشته باشند انتخاب شده اند، بردار مقادیر ورودی دارای هفت مؤلفه خواهد بود یا به بیان غیر برداری، لایه ورودی ۷ نرون خواهد داشت.

بیان ریاضی شیوه محاسبه بردار مقدارهای خروجی  $Y = (y_1, \dots, y_d)$  توسط شبکه عصبی پیش خور را می توان با برابری های زیر نمایش داد:

$$y_k(x) = f_0\left(\sum_{j=1}^n w_{jk}z_j\right) \quad z_j = f_h\left(\sum_{i=1}^p w_{ij}x_i\right) \quad (5)$$

که در آن  $w_{jk}$  و  $w_{ij}$  وزن های شبکه هستند که مقادیر آنها با هر بار ارائه داده های آموزشی به شبکه بهنگام می شوند.  $f_0$  و  $f_h$  توابع فعال سازی برای گره های به ترتیب خروجی و پنهان هستند که مجموع وزن یافته خروجی ها را به سمت چپ هر گره انتقال می دهند.  $f_h$  می تواند توابع انتقال گوناگونی مانند توابع لوج ستیک، تانژانت هیپربولیک و سیگموئید ( $S$  مانند) را اختیار کند. با توجه به کاربردهای گسترده تابع انتقال سیگموئید، در این مقاله از آن برای لایه پنهان استفاده شده و با توجه به سادگی کار با توابع خطی، برای  $f_0$  گره های خروجی از تابع فعال سازی خطی استفاده شده است:

$$f_h(x) = \frac{1}{1 + e^{-\theta_j x}} \quad f_0(x) = x \quad (6)$$

که در آن  $\theta_j$ ، بایاس مربوط به گره پنهان  $j$  است که خود نیز با هر بار ارائه داده به شبکه اصلاح می شود. مقدار بایاس ها و وزن ها با هم بردار پارامترهای مدل  $W$  را شکل می دهند [۱۷].

توابع انتقال پرکاربرد لگاریتم سیگموئید و تانژانت هیپربولیک سیگموئید، دارای مقادیر اشباع به ترتیب ۰ تا ۱ و -۱ تا ۱ هستند. اگر مقادیر ورودی و خروجی داده های آموزشی در دامنه اشباع نباشند، نرون ها به نقاط اشباع خود رانده شده و توان پاسخگویی مناسب به تغییرات در داده های ورودی، برای بهنگام سازی وزن ها و اصلاح بایاس ها را نخواهند داشت و عملاً روند آموزش خواهد ایستاد. از این رو داده های آموزشی (و نه داده های آزمون) باید بین دو مقدار آستانه دامنه نرمال شوند. برای نرمال کردن داده ها از رابطه زیر استفاده می شود [۱۸]:

$$X = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (7)$$

که در آن  $X$  مقدار نرمال شده  $x$ ،  $x_{max}$  و  $x_{min}$  به ترتیب کمترین و بیشترین داده است.

### ۳. گردآوری داده ها

برای مدل سازی تصادفات بزرگراه های درون شهری از داده های تصادفات بزرگراه های شهر مشهد در سال های ۹۸ و ۹۹ استفاده شده است. این اطلاعات توسط سازمان حمل و نقل و ترافیک مشهد به کمک GIS و با استفاده از گزارشات پلیس گردآوری شده است. آمار تصادفات در دو گروه با زیان مالی (خسارتی) و زیان جانی (جرچی و فوتی) گردآوری شده است. متغیرهای ناوابسته مدل شامل متغیرهای مربوط به جریان ترافیک شامل حجم خودروهای سواری، غیرسواری سبک و سنگین و سرعت و متغیرهای مربوط به طرح هندسی راه شامل شمارخطوط، شمار قوس های افقی و شمار راههای دسترسی می شود. آمار تصادفات و متغیرهای ناوابسته مدل ها برای ۱۵۶ بخش بزرگراه های درون شهری مشهد در ۴۶۸ زیر بخش گردآوری شده است. گفتنی است داده های مربوط به شمار تصادفات و حجم ترافیک برای هر زیر بخش در ۲ سال میانگین گیری شده است. شمار کل تصادفات مالی، جرچی و فوتی رخ داده در بزرگراه های درون شهری مشهد در سال های ۹۸ و ۹۹ به ترتیب ۶۶۱۸، ۷۶۰ و ۱۴۸ می باشد. خلاصه آمار تصادفات و متغیرهای ناوابسته در جدول ۱ آمده است.

جدول ۱. خلاصه آمار تصادفات و متغیرهای ناوابسته

Max	Min	S.D.	Mean	متغیر
				متغیرهای وابسته
۸۰	۰	۸/۸۶	۷/۰۷	شمار تصادفات با زیان مالی
۱۲	۰	۱/۴۳	۰/۹۷	شمار تصادفات با زیان جانی
				ویژگی های جریان ترافیک
۴۵۹۳	۳۳	۸۰۷	۱۰۴۶	حجم خودروهای سواری
۲۴۲۵	۲۹	۴۲۷	۵۶۲	حجم خودروهای سنگین
۲۲۲۵	۴۲	۴۱۹	۵۵۱	حجم خودروهای غیرسواری سبک
۱۰۰	۰	۱۸/۷	۵۵/۳	سرعت
				ویژگی های طرح هندسی
۵	۲	۰/۵۸۶	۳/۳۲	شمار خطوط
۴	۰	۰/۷۱۸	۰/۵۶۴	شمار قوس های افقی
۸	۰	۱/۴۱۹	۰/۹۷۴	شمار راه های دسترسی

سازمان هر چند سال یکبار یک طرح جامع آمارگیری حمل و نقل و ترافیک در آبان ماه انجام می دهد و در آن حجم عبوری انواع خودروها از بخش عمده ای از راه های شهری در ساعت های شبانه روز را بدست می آورد. در آبان ماه وضعیت ترافیک مشهد عادی است و اساساً مدل هایی که در این پژوهش ساخته شده اند تغییرات فصلی ترافیک را در نظر نمی گیرند، زیرا آمار مربوط به حجم ترافیک در فصل های مختلف سال در دسترس نبود و داده های حجم ترافیک به ساعت های مختلف شبانه روز مربوط می شود. از روی این آمارها می توان به ترکیب ترافیک و درصد انواع خودروها پی برد. سازمان همچنین هر سال حجم کل ترافیک در بخش های مختلف راهها بویژه بزرگراهها در ساعات اوج ترافیک را برآورد می کند، از روی این حجم کل معادل و با داشتن ضریب همسنگ انواع خودروها و درصد هر یک در ترکیب ترافیک در ساعت های مختلف شبانه روز و نسبت حجم کل ترافیک در ساعت های غیراوج به ساعت اوج می توان حجم هر یک را در ساعت اوج و ساعت نماینده غیراوج در روز و در شب بدست آورد و از روی آن حجم خودروهای سواری و حجم معادل خودروهای غیر سواری سبک و سنگین در ساعت اوج و ساعت های غیراوج در روز و در شب بدست خواهد آمد، این محاسبات توسط برنامه Excel انجام شده است. ضریب همسنگ سواری انواع خودروها در جدول ۲ آمده است [۱۹]:

جدول ۲. ضریب همسنگ سواری انواع خودروها

سواری	تاکسی	وانت	مینی بوس	اتوبوس غیرواحد	اتوبوس واحد	موتورودوچرخه	وسایل سنگین
۱	۲	۱	۲	۲/۵	۵	۰/۵	۲/۵

حجم کل (معادل سواری) از بستگی زیر بدست می آید:

$$V_{te} = e_1 N_1 + \dots + e_n N_n \quad (8)$$

که در آن  $V_{te}$ ، حجم معادل سواری و  $e_i$  و  $N_i$  به ترتیب ضریب همسنگ و شمار خودروهای نوع  $i$  می باشد. داده های سرعت در بخش های مختلف بزرگراه ها برای ساعات اوج همراه با داده های حجم توسط سازمان ترافیک و برای ساعات غیراوج روز و شب با حرکت در جریان ترافیک در ساعات موردنظر گردآوری شده است. اطلاعات مربوط به شمار خطوط، راه های دسترسی و قوس های افقی در بخش های مختلف بزرگراه های درون شهری از روی نقشه مسیر بزرگراه ها گرد آمده است. با توجه به استفاده از توابع انتقال غیر خطی سیگموئید برای گره های پنهان، همان گونه که پیش تر اشاره شد لازم است داده های ورودی و خروجی نرمال شوند یعنی مقدار حجم ترافیک، سرعت، پارامترهای هندسی و شمار تصادفات مالی و جانی در بازه [۰و۱] نرمال شوند. مقدار کمینه و بیشینه متغیرها در جدول ۱ آمده است.

#### ۴. ساخت مدل های شبکه عصبی و نتایج

در این بخش از روی آمار گرد آمده تصادفات و اطلاعات مربوط به متغیرهای ناوابسته، مدل های شبکه عصبی مصنوعی برای تصادفات با زیان مالی و تصادفات با زیان جانی ساخته می شود. مدل سازی با شبکه های عصبی در چهار مرحله انجام می شود: ۱- تعیین معماری شبکه عصبی ۲- تعیین توابع انتقال، آموزش و خطا ۳- ساخت مدل های شبکه عصبی.



### ۱-۴ تعیین معماری شبکه عصبی

همان گونه که پیش تر نیز اشاره گردید، با توجه به توان بالای شبکه های پس انتشار، در این پژوهش از ساختار شبکه های عصبی پس انتشار پیش خور برای مدل سازی تصادفات با نرم افزار MATLAB بسته شبکه عصبی استفاده می شود. در شبکه های عصبی چند لایه پیش خور، در لایه ورودی باید به تعداد متغیرهای ورودی و در لایه خروجی به تعداد متغیرهای خروجی، نرون وجود داشته باشد. از این رو با توجه به داشتن ۷ متغیر ورودی و ۲ متغیر خروجی، شبکه عصبی پس انتشاری که قرار است برای پیش بینی شمار تصادفات ساخته شود، ۷ نرون در لایه ورودی و ۲ نرون در لایه خروجی خواهد داشت. همان طور که در بخش ۲-۳ بیان شد، با توجه به اهداف مدل سازی و دقت مورد نیاز، شبکه می تواند چندین لایه پنهان داشته باشد هر چند همیشه با افزایش تعداد لایه ها دقت برآورد شبکه بهتر نمی شود. چون معمولاً در مدل سازی تصادفات یک لایه پنهان بسنده است در این مقاله نیز برای آسانی کار و پرهیز از پیچیدگی موضوع یک لایه پنهان برای ساخت شبکه بکار می رود. تعیین شمار نرون های لایه پنهان، تجربی است بطوری که شبکه های عصبی مختلف با شمار نرون های لایه پنهان مختلف ساخته می شود تا به شبکه عصبی با بالاترین دقت برآورد برسیم. شمار نرون های لایه پنهان این شبکه، بهینه خواهد بود. روش تجربی کوتاه تر آن است که ساخت شبکه را با شمار کم نرون های لایه پنهان آغاز کنیم و با سنجش دقت برآورد شبکه آموزش یافته روی داده های آزمون، کم کم شمار نرون ها را افزایش دهیم تا هنگامی که دقت شبکه شروع به افت کند، در این حالت شمار نرون های لایه پنهان بهینه خواهد بود.

### ۲-۴ تعیین توابع انتقال، آموزش و خطا

سه نوع تابع انتقال هستند که در شبکه های عصبی کاربرد فراوان دارند و در برنامه MATLAB مانند زیر تعریف شده اند: ۱- تابع انتقال لگاریتم

$$f(x) = \frac{1}{1+e^{-x}} : \text{LOGSIG}$$

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} : \text{TANSIG}$$

$$f(x) = x : \text{PURELIN}$$

در این مقاله از تابع انتقال TANSIG در لایه پنهان و تابع انتقال PURELIN در لایه خروجی در برنامه MATLAB استفاده شده است. برای آموزش شبکه نیز همان طور که پیش تر در بخش ۱۲ اشاره گردید، الگوریتم پس انتشار با تابع آموزش Levenberg-Marquardt، TRAINLM، و برای ساخت شبکه های عصبی مختلف از تابع میانگین مربع خطا MSE استفاده می شود. هدف از مدل سازی با شبکه های عصبی، کمینه کردن مقدار MSE است و شبکه عصبی بهینه، آن شبکه ای است که کمترین مقدار MSE یا بیشترین دقت برآورد و بالاترین مقدار R همبستگی بین شمار پیش بینی شده و مشاهده شده تصادفات را بدست دهد.

### ۳-۴ ساخت مدل های شبکه عصبی

آمار تصادفات و متغیرهای ناوابسته مدل ها برای ۱۵۶ بخش بزرگراه های درون شهری مشهد در ۴۶۸ زیر بخش گردآوری شده است. از ۴۶۸ داده گرد آوری شده، ۳۲۸ داده برای آموزش شبکه های عصبی، ۷۰ داده برای آزمون شبکه و ۷۰ داده دیگر برای معتبر سازی بکار گرفته می شود. اطلاعات مربوط به ۷ متغیر ورودی به تعداد ۷ نرون لایه ورودی شامل حجم خودروهای سواری، سنگین، غیر سواری سبک، سرعت، شمار خطوط، قوس های افقی و راه های دسترسی و ۲ متغیر خروجی به تعداد ۲ نرون لایه خروجی شامل شمار تصادفات مالی و جانی برای ۴۶۸ داده گرد آمده برای برنامه MATLAB تعریف شده است. پس از تعریف معماری شبکه و توابع انتقال و آموزش، که پیش تر به آنها اشاره گردید، در برنامه MATLAB، چندین شبکه عصبی با شمار افزایشی نرون های لایه پنهان مطابق با روش تجربی که در بخش ۴-۱ به آن اشاره شد ساخته می شود. نتایج مدل سازی در جدول ۳ آمده است.


جدول ۳. تعیین شبکه عصبی بهینه برای برآورد شمار تصادفات مالی

شمار نرون های لایه پنهان	مقدار R	شمار نرون های لایه پنهان	مقدار R	شمار نرون های لایه پنهان	مقدار R
۱	۰/۵۲	۱۱	۰/۸۱	۲۱	۰/۸۸
۲	۰/۵۶	۱۲	۰/۸	۲۲	۰/۸۴
۳	۰/۵۸	۱۳	۰/۸۱	۲۳	۰/۸۲
۴	۰/۶۳	۱۴	۰/۸	۲۴	۰/۸۵
۵	۰/۶۹	۱۵	۰/۷۹	۲۵	۰/۸۲
۶	۰/۶۸	۱۶	۰/۷۸	۲۶	۰/۸
۷	۰/۷۲	۱۷	۰/۸۲	۲۷	۰/۸۲
۸	۰/۷۵	۱۸	۰/۸۳	۲۸	۰/۸
۹	۰/۷۸	۱۹	۰/۸	۲۹	۰/۸۲
۱۰	۰/۸۱	۲۰	۰/۸۳	۳۰	۰/۷۹


جدول ۳. تعیین شبکه عصبی بهینه برای برآورد شمار تصادفات جانی

مقدار R	شمار نرون های لایه پنهان	مقدار R	شمار نرون های لایه پنهان	مقدار R	شمار نرون های لایه پنهان
۰/۸۷	۲۱	۰/۸۱	۱۱	۰/۵۳	۱
۰/۸۴	۲۲	۰/۸۰	۱۲	۰/۶۴	۲
۰/۸۶	۲۳	۰/۷۸	۱۳	۰/۶۵	۳
۰/۸۱	۲۴	۰/۷۹	۱۴	۰/۶۹	۴
۰/۸۹	۲۵	۰/۸۴	۱۵	۰/۷۳	۵
۰/۸۶	۲۶	۰/۸۳	۱۶	۰/۷	۶
۰/۸۵	۲۷	۰/۸۳	۱۷	۰/۷۶	۷
۰/۸۴	۲۸	۰/۸۲	۱۸	۰/۷۹	۸
۰/۸۶	۲۹	۰/۸	۱۹	۰/۷۸	۹
۰/۸۶	۳۰	۰/۸۳	۲۰	۰/۸	۱۰


مطابق با جدول ۳- الف ، شبکه عصبی بهینه برای برآورد شمار تصادفات مالی، ۲۱ نرون در لایه پنهان با بیشترین مقدار R برابر ۰/۸۸ و طبق جدول ۳- ب ، شبکه عصبی بهینه برای برآورد شمار تصادفات جانی، ۲۵ نرون در لایه پنهان با بیشترین مقدار R برابر ۰/۸۹ خواهد داشت. ساختار شبکه های عصبی بهینه برای برآورد (پیش بینی) شمار تصادفات مالی و جانی در برنامه MATLAB به ترتیب در شکل های ۳ و ۴ آمده است. نمودارهای رگرسیون و مقایسه برآورد شبکه عصبی بهینه با شمار مشاهده شده تصادفات، در شکل ۵ برای تصادفات مالی و شکل ۶ برای تصادفات جانی آمده است.




شکل ۳. ساختار شبکه عصبی بهینه برای برآورد شمار تصادفات مالی



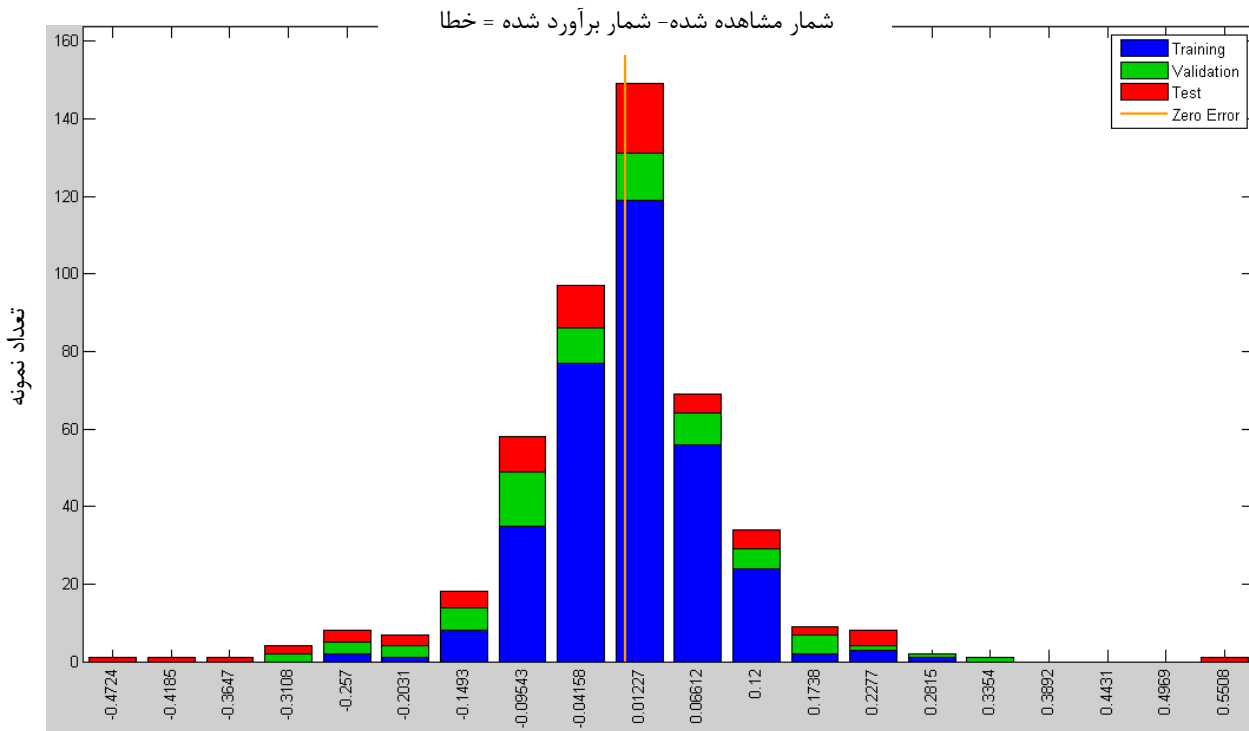
شکل ۴. ساختار شبکه عصبی بهینه برای برآورد شمار تصادفات جانی




شکل ۵. تفاوت برآورد شبکه عصبی بهینه (Target) با شمار مشاهده شده تصادفات مالی (Output)



شکل ۵. نمودار رگرسیون رابطه برآورد شبکه عصبی بهینه (Target) با شمار مشاهده شده تصادفات مالی (Output)



شکل ۶. تفاوت برآورد شبکه عصبی بهینه (Target) با شمار مشاهده شده تصادفات جانی (Output)



شکل ۶. نمودار رگرسیون رابطه برآورد شبکه عصبی بهینه (Target) با شمار مشاهده شده تصادفات مالی (Output)

### ۵. نتیجه گیری

در پژوهشی که انجام شد و روش و مراحل انجام آن از نظر گذشت دو مدل شبکه عصبی برای برآورد شمار تصادفات مالی و جانی در بزرگراه های درون شهری ارائه گردید. برای ارزیابی کارایی و دقت مدل ها به مقایسه شمار برآورد شده تصادفات توسط مدل ها با شمار مشاهده شده مطابق با نمودارهای شکل های ۵ و ۶ پرداخته شد و از مقدار R استفاده گردید. با توجه به نمودارها و مقدار R، مدل های شبکه عصبی ارائه شده برای برآورد شمار تصادفات مالی و جانی با مقدار R به ترتیب ۰.۷۴ و ۰.۷۵ مناسب اند. از این رو می توان کارایی مدل های شبکه عصبی را در مدل سازی تصادفات بزرگراه های درون شهری تأیید نمود و از آنها برای برآورد شمار تصادفات مالی و جانی در بزرگراه های درون شهری بهره گرفت.

## ۶. مراجع

- [1] Caliendo, C., Guida, M. and Parisi, A. (2007) "A crash-prediction model for multilane roads", *Accident Analysis and prevention* 39, 657-6.
- [2] Ayati, E., Abbasi, E. (2011) "Investigation on the role of traffic volume in accidents on urban highways", *Safety research* 42, 209-214.
- [3] Lord, D., Guikema, S.D., Geedipally, S.R. (2008) "Application of the Conway-Maxwell-Poisson generalized linear model for analyzing motor vehicle crashes", *Accident Analysis and Prevention* 40(3), 1123-1134.
- [4] Lord, D., Park, Y.-J. (2008) "Investigating the effects of the fixed and varying dispersion parameters of Poisson-gamma models on empirical Bayes estimates", *Accident Analysis and Prevention* 40(4), 1441-1457.
- [5] Cafiso, S., Graziano, A.D., Silvestro, G.D., Cava, G.L., and Persaud, B. (2010) "Development of comprehensive accident models for two-lane rural highways using exposure, geometry, consistency and context variables", *Accident Analysis and Prevention* 42, 1072-1079.
- [6] EI-Basyouny, K., and Sayed, T. (2009) "Accident prediction models with random corridor Parameters", *Accident Analysis and Prevention* 41, 1118-1123.
- [7] Ozbay, K., and Noyan, N. (2006) "Estimation of incident clearance times using Bayes Network Approach", *Accident Analysis and Prevention* 38, 542-555.
- [8] Chang, L.-Y. (2005) "Analysis of freeway accident frequencies: Negative binomial regression versus artificial neural network", *Safety Science* 43, 541-557.
- [9] Delen, D., Sharada, R., and Bessonov, M. (2006) "Identifying significant predictors of injury severity in traffic accidents using a series of artificial neural networks", *Accident Analysis and Prevention* 38, 434-444.
- [10] Meng, X.H., Zheng, L., and Qing, G.M. (2009) "Traffic accidents prediction and prominent influencing factors analysis based on fuzzy logic", *Journal of Transportation Systems and Information Technology* 9(2), 87-92.
- [11] De Brabander, B., E. Nuyts and L. Vereeck. 2005. Road safety effects of roundabouts in Flanders. *Journal of Safety Research* 36(3): 289-296.
- [12] Quek, C., M.Pasquier, and B.Lim. 2009. A novel self-organizing fuzzy rule-based system for modelling traffic flow behaviour. *Expert Systems with Applications*.
- [13] Zheng, L., and Meng, X. (2011) "An approach to predict road accident frequencies: Application of Fuzzy Neural Network", 3rd International Conference on Road Safety and Simulation, September 14-16, 2011, Indianapolis, USA.
- [14] Liao, Z., Wang, B., Xia, X., and Hannam, P.M. (2012) "Environmental emergency decision support system based on Artificial Neural Network", *Safety Research* 50, 150-163.
- [۱۵] کاوه، علی؛ ثروتی، همایون (۱۳۸۰). "شبکه های عصبی مصنوعی در تحلیل و طراحی سازه ها"; انتشارات مرکز تحقیقات ساختمان و مسکن.
- [۱۶] افندی زاده، شهریار؛ احمدی نژاد، محمود و عبدالمنافی، سید ابراهیم (۱۳۸۶) "مقایسه نتایج مدل های آماری و شبکه عصبی در پیش بینی شمار تصادفات در تقاطعات"، پژوهشنامه حمل و نقل، سال چهارم، شماره ۴، ص. ۳۳۹-۳۵۵.
- [17] Mazloumi, E., Rose, G., Currie, G., and Moridpour, S. (2011) "Prediction intervals to account for uncertainties in neural network predictions: Methodology and application in bus travel time prediction", *Engineering Applications of Artificial Intelligence* 24, 534-542.
- [18] Ung, S. T., Williams, V., Wang, B. J. (2006) "Test case based risk predictions using artificial neural ", *Journal of Safety Research* 37, 245-260.
- [۱۹] دفتر مطالعات جامع حمل و نقل؛ هفتمین آمارنامه حمل و نقل شهر مشهد؛ سازمان حمل و نقل و ترافیک مشهد، ۱۳۹۰.