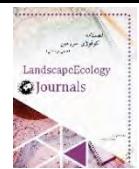




Online ISSN: 2821-1782

Journal of LandscapeEcology

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*^a

^a Transportation Engineering Expert Of Garme Municipality, Garme , Iran.

ARTICLE INFO

Article history:

Received: 2022-11-24

Accepted: 2023-01-17

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.

Keywords:

Accidents Urabn

Highways Modeling

Accidents Neural

Networks Models

*Corresponding Author.

Email Adresses: 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.

.. *Ecology of the Landscape*, 1(1), 38-49.



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



پژوهشگاه علوم انسانی و مطالعات فرهنگی
پرستال جامع علوم انسانی



شایعه الکترونیکی: ۱۷۸۲-۲۸۲۱

فصلنامه اکولوژی سرزمین

<http://www.landscapeecologyjournals.ir>



مقاله پژوهشی

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

ابراهیم مردادی^{۱*}

^۱* کارشناس مهندسی حمل و نقل شهرداری گرمه، گرمه، ایران.

اطلاعات مقاله

دربافت مقاله:

۱۴۰۱ آذر ۰۳

پذیرش نهایی:

۱۴۰۱ دی ۲۷

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 موردنی 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 دقیقت مدل ها، به مقایسه شمار برآورد شده تصادفات توسط مدل ها با شمار مشاهده شده پرداخته و از مقدار R 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.

وازگان کلیدی:

تصادفات بزرگراه های

درون شهری مدل سازی

تصادفات مدل های شبکه

عصبی

پژوهشگاه علوم انسانی و مطالعات فرهنگی
پرکال جامع علوم انسانی

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، پهنای راه، شمار راه های دسترسی، شمار و درجه قوس های افقی، شمار و شبیب قوس های قائم و ... ۳- عوامل مربوط به آب و هوای 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 شیارشده، مقاومت لغزشی و ... ۵- عوامل مربوط به ویژگی ها و رفتارهای رانندگان مانند سن، جنس، خودن نوشیدنی های الکلی، بستن کمربند اینمی 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 هوای 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 روتر 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 بیز امروزه در بحث مدل سازی تصادفات به یک امر رایج تبدیل 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. پرکاربرد ترین 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 پر صفر 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 یکتابع پیوندی لاجیت که لگاریتم نسبت تباين می باشد، تبدیل می یابد.

(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 دوچمله 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 پذیرفتی 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 بردن 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 مقدارهای آماری جذر میانگین مربع خطاهای (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 (جرحی و فوتی) در بزرگراه های درون شهری مشهد 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 جداشده 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 تو سط سازمان حمل و نقل و ترافیک م شده به کمک GIS و با استفاده از گزار شات 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 درنظر 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 درنظر گرفته شده است.

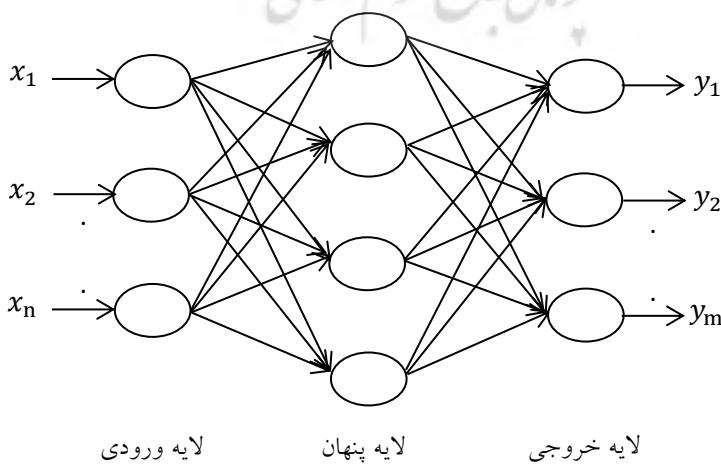
هدف پژوهشگر در این پژوهش، ارزیابی کارایی مدل های شبکه عصبی در مدل سازی تصادفات مالی و جانی در بزرگراه های درون شهری است. برای این کار از نرم افزار MATLAB، بسته شبکه عصبی استفاده می شود. مراحل ساخت مدل ها شامل تعیین معماری شبکه عصبی، تعیین توابع انتقال، آموزش و خطا و ساخت مدل های شبکه عصبی می باشد که 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 تو سط 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 سینکال 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 سینپس 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 خورانده 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 به نگام 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 یکتابع خطاب برای یافتن جهتی است که خطای شبکه را مینیمم و از آنچا 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 ام است. اگر انرژی خطاب 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 خطای 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 وزنهای با بارها ارائه مجموعه داده به شبکه در طی یک دوره است.

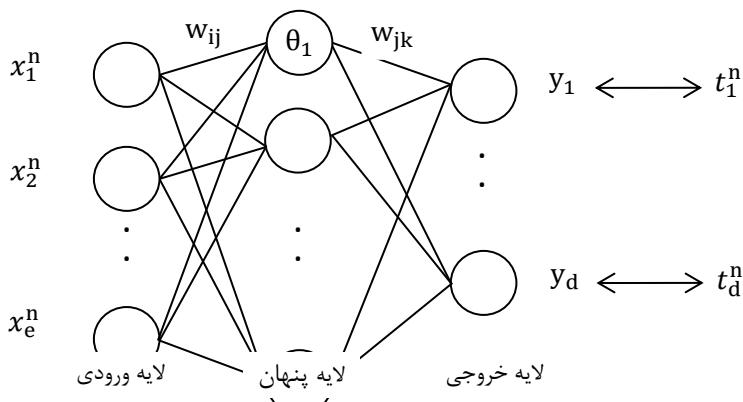
الگوریتم پس انتشار، وزن $W_{ij}(n)$ را به مقدار $\Delta W_{ij}(n)$ اصلاح می کند. این اصلاح وزن، با مشتق نسبی $E(n)$ نسبت به $W_{ij}(n)$ متناسب است. این مشتق نسبی برای یافتن جهتی در فضای وزن هاست که با کاهش گرادیان، خطای شبکه را کمینه و بدنبال آن وزن ها را بهنگام می کند. رابطه اصلاح وزن مانند زیر است:

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

که در آن η 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. عموماً شبکه های عصبی دارای دو نوع معماری به صورت پیش خور و پس خورند، 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. عموماً 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 می خواهیم یک شبکه عصبی با سازیم 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 آزمودن شبکه) $(\mathbf{t}^1, \dots, \mathbf{t}^N) = \mathbf{T}$ ، بر پایه متغیرهای ورودی x^n از مجموعه داده $(x^1, \dots, x^n) = X$ ، 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 می‌شوند دریافت می‌کند تا به بردار مقادیر خروجی $(y_1(x^n), \dots, y_d(x^n))$ تبدیل کند [۱۷]. برای نمونه در بحث مدل سازی ظرفیت، بردار متغیرهای ورودی شامل عوامل مربوط به جریان ترافیک، طرح هندسی راه و دیگر عواملی که به نظر می‌رسد در رخداد تصادفات و شدت آنها مؤثرند می‌باشد، در حالی که بردار مقادیر خروجی شامل شمار تصادفات با شدت‌های گوناگون است. در این مقاله شمار تصادفات به دو دسته تصادفات مالی (خساراتی) و جانی (جرحی و فوتی) جدا شده پس بردار مقادیر خروجی، دارای دو مؤلفه شمار تصادفات مالی و شمار تصادفات جانی است یا به بیان غیربرداری، 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 پیچیده‌تر می‌شود، ممکن است دقت عمل بالاتر نزود. عموماً برای اهداف مدل سازی تصادفات می‌توان به یک لایه پنهان بسته 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 ۷ متغیر ورودی شامل حجم خودروهای سواری، خودروهای سنگین، غیرسواری سبک، سرعت، شمار خطوط، قوس‌های افقی و راه‌های دسترسی در این پژوهش به عنوان عواملی که به نظر می‌رسد در رخداد تصادفات نقش داشته باشدند انتخاب شده‌اند، بردار مقادیر ورودی دارای هفت مؤلفه خواهد بود یا به بیان غیربرداری، لایه ورودی ۷ نرون خواهد داشت.

بیان ریاضی شیوه محاسبه بردار مقادیر خروجی $y_d = (y_1, \dots, y_d)$ توسط شبکه عصبی پیش‌خور را می‌توان با برابری‌های زیر نمایش داد:

$$y_k(x) = f_0(\sum_{j=1}^h w_{jk} z_j) \quad z_j = f_h(\sum_{i=1}^e w_{ij} x_i) \quad (5)$$

که در آن w_{ij} و w_{jk} وزن‌های شبکه هستند که مقادیر آنها با هر بار ارائه داده‌های آموزشی به شبکه بهنگام می‌شوند. f_0 و f_h توابع فعال سازی برای گره‌های به ترتیب خروجی و پنهان هستند که مجموع وزن یافته خروجی‌ها را به سمت چپ گره انتقال می‌دهند. f_h می‌تواند تابع انتقال گوناگونی مانند توابع لجستیک، تانژنت هیپربولیک و سیگموید (S مانند) را اختیار کند. با توجه به کاربردهای گسترده تابع انتقال سیگموید، در این مقاله از آن برای لایه پنهان استفاده شده و با توجه به سادگی کار با تابع خطی، برای f_0 گره‌های 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 θ_j ، بایاس مربوط به گره پنهان j است که خود نیز با هر بار ارائه داده به شبکه اصلاح می‌شود. مقدار بایاس‌ها و وزن‌ها با هم بردار پارامترهای مدل W را شکل می‌دهند [۱۷].

تابع انتقال پرکاربرد لگاریتم سیگموید و تانژانت هیپربولیک سیگموید، دارای مقادیر اشباع به ترتیب ۰ تا ۱ و ۱ تا ۰ هستند. اگر مقادیر ورودی و خروجی داده‌های آموزشی در دامنه اشباع نباشند، نرون‌ها به نقاط اشباع خود رانده شده و توان پاسخگویی مناسب به تغییرات در داده‌های ورودی، برای بهنگام سازی وزن‌ها و اصلاح بایاس‌ها را نخواهند داشت و عملاً روند آموزش خواهد بود. از این رو داده‌های آموزشی (ونه داده‌های آزمودن) باید بین دو مقدار آستانه دامنه نرمال شوند. برای نرمال کردن داده‌ها از رابطه زیر استفاده می‌شود [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 داده‌ها

برای مدل سازی تصادفات بزرگراه‌های درون شهری از داده‌های تصادفات بزرگراه‌های شهر مشهد در سال‌های 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 زبان مالی (خساراتی) و زبان جانی (جرحی و فوتی) گردآوری شده است. متغیرهای ناوابسته مدل‌ها شامل متغیرهای مربوط به جریان ترافیک شامل حجم خودروهای سواری، غیرسواری سبک و سنگین و سرعت و متغیرهای مربوط به طرح هندسی راه شامل شمار خطوط، شمار قوس‌های افقی و شمار راههای دسترسی می‌شود. آمار تصادفات و متغیرهای ناوابسته مدل‌ها برای ۱۵۶ بخش بزرگراه‌های درون شهری مشهد در ۴۶۸ زیربخش گردآوری شده است. گفتنی است داده‌های مربوط به شمار تصادفات و حجم ترافیک برای هر زیربخش در ۲ سال میانگین گیری شده است. شمار کل تصادفات مالی، جرحی و فوتی رخ داده در بزرگراه‌های درون شهری مشهد در سال‌های ۹۸ و ۹۹ به ترتیب ۶۱۸، ۷۶۰ و ۱۴۸ می‌باشد. خلاصه آمار تصادفات و متغیرهای ناوابسته در جدول ۱ آمده است.

جدول ۱. خلاصه آمار تصادفات و متغیرهای ناویسته

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

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 ساعت اوج ترافیک را برآورده می کند، از روی این حجم کل معادل و با داشتن ضریب همسنگ انواع خودروها و درصد هریک در ترکیب ترافیک در ساعت های مختلف شبانه روز و نسبت حجم کل ترافیک در ساعتهای 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	تاكسي	وات	ميني بوس	اتوبوس غيرواحد	اتوبوس واحد	موتوردوچرخه	وسائل سانگين
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 e_i حجم معادل سواری و N_i به ترتیب ضریب همسنگ و شمار خودروهای نوع i می باشد.

داده های سرعت در بخش های مختلف بزرگراه ها برای ساعت اوج همراه با داده های حجم توسط سازمان ترافیک و برای ساعت غیراوج روز و شب با حرکت در جریان ترافیک در ساعت 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 سیگموید 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 [۰، ۱] 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 ناویسته، 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 خطای 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 ۳-۲ 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 بسند 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 بررسیم. 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

$$\text{سیگموید : } \text{LOGSIG} = \frac{1}{1+e^{-x}}$$

$$2-\text{تابع انتقال تانژانت هیپربولیک سیگموید : } \text{TANSIG} = \frac{e^x - e^{-x}}{e^x + e^{-x}}$$

$$3-\text{تابع انتقال خطی : } \text{PURELIN} = f(x) = x$$

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 ۱-۲ شاره گردید، الگوریتم پس انتشار با تابع آموزشی Levenberg-Marquardt

TRAINLM، و برای ساخت شبکه های عصبی مختلف از تابع میانگین مریع 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 ناوایسته 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 آزمودن 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، سنجنگ، 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 ۱-۱ شاره گردید، در برنامه MATLAB، چندین شبکه عصبی با شمار افزایشی نرون های لایه پنهان مطابق با روش تجربی که در بخش ۱-۴ به آن اشاره شد ساخته می شود. نتایج مدل سازی در جدول ۳ آمده است.

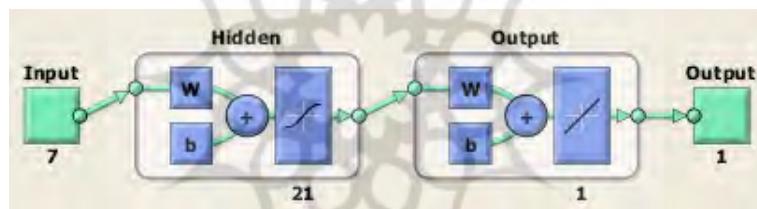
جدول ۳. تعیین شبکه عصبی بهینه برای برآورد شمار تصادفات مالی

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

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

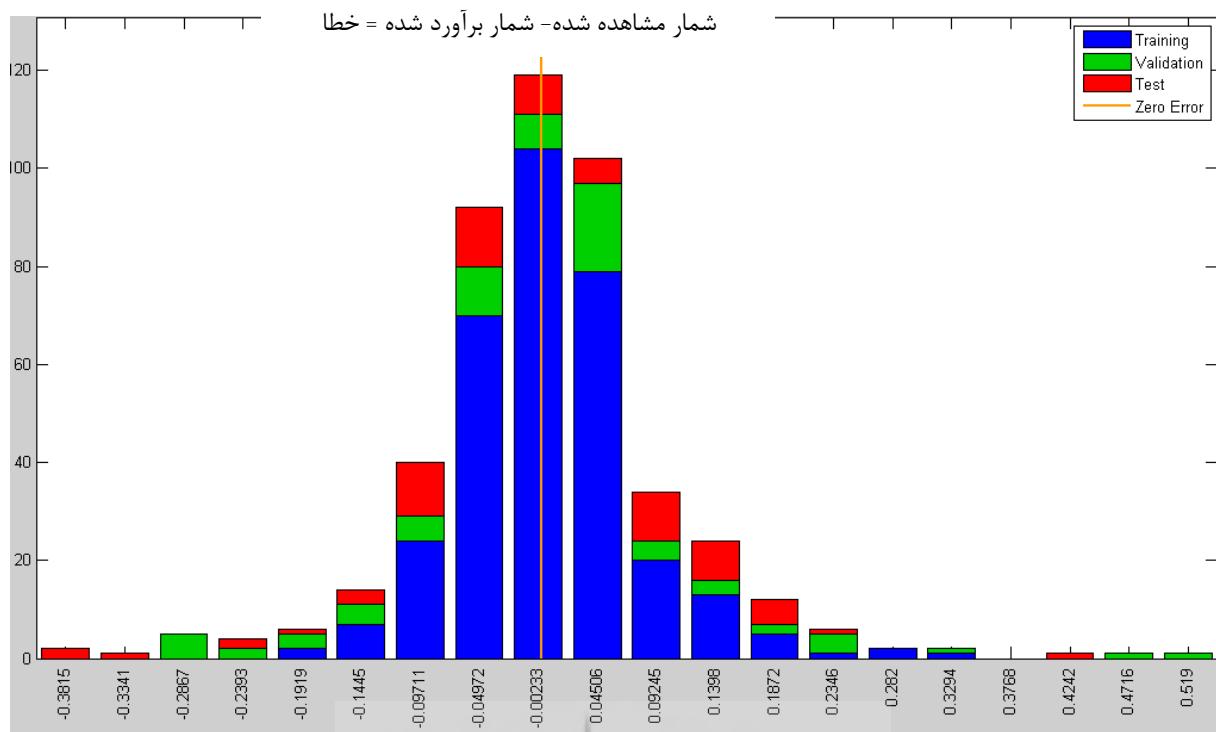
مطابق با جدول ۳-الف ، شبکه عصبی بهینه برای برآورد شمار تصادفات مالی، ۲۱ نرون در لایه پنهان با بیشترین مقدار R برابر ۰.۸۸ و طبق جدول ۳-ب ، شبکه عصبی بهینه برای برآورد شمار تصادفات جانی، ۲۵ نرون در لایه پنهان با بیشترین مقدار R برابر ۰.۸۹ خواهد داشت. ساختار شبکه عصبی بهینه برای برآورد (پیش بینی) شمار تصادفات 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.



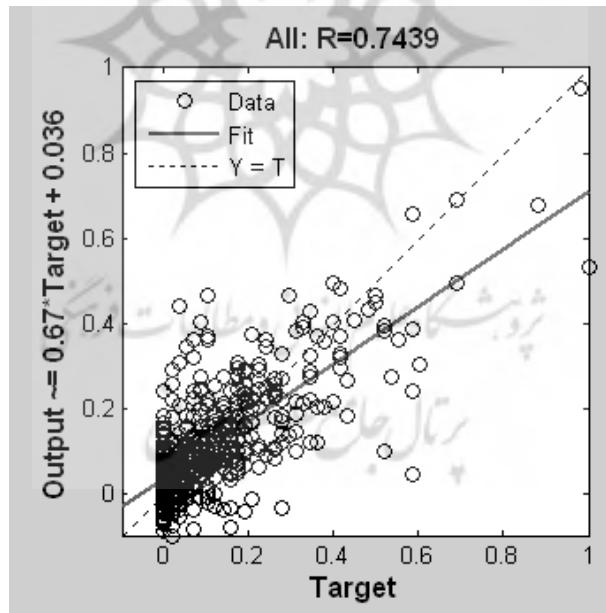
شکل ۳. ساختار شبکه عصبی بهینه برای برآورد شمار تصادفات مالی



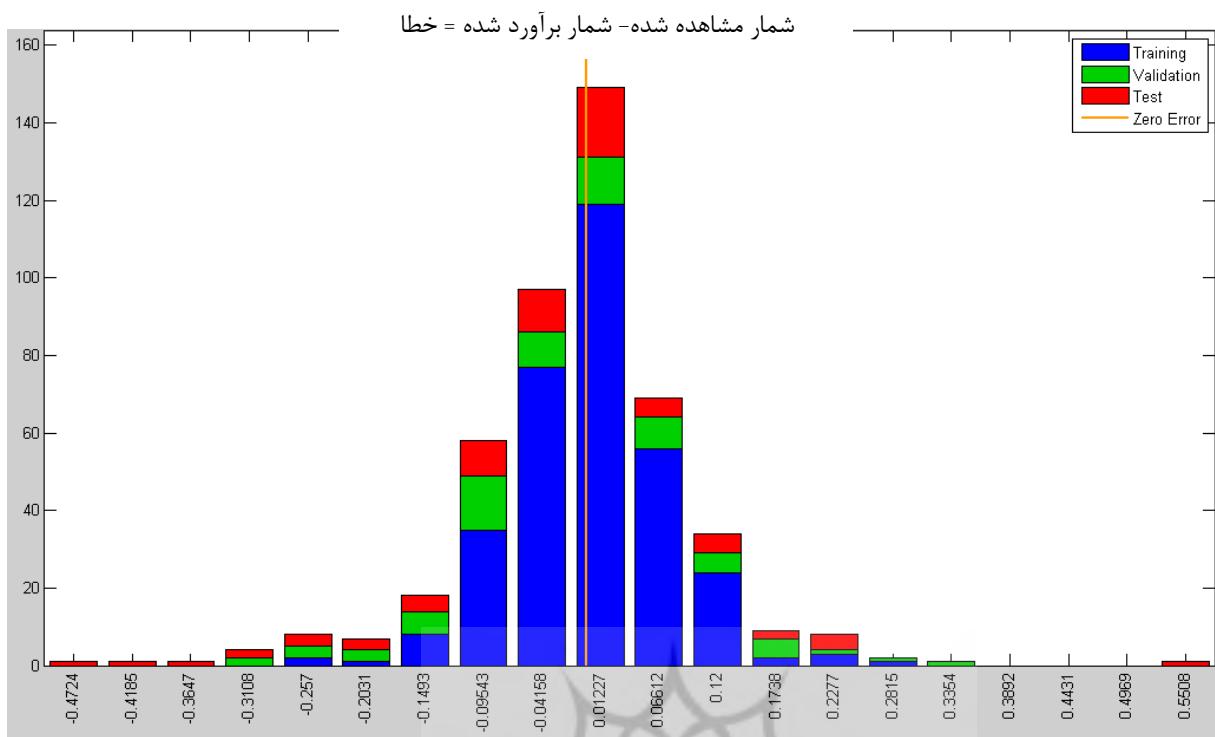
شکل ۴. ساختار شبکه عصبی بهینه برای برآورد شمار تصادفات جانی



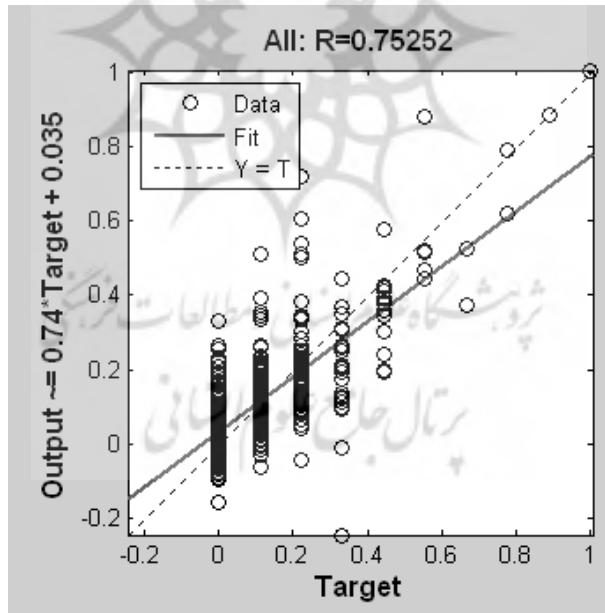
شکل ۵. تفاوت برآورد شبکه عصبی بهینه (Output) با شمار مشاهده شده تصادفات مالی (Target)



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



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 0.74 و 0.75 مناسبند. 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 Artifial 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.