

ارائه روش یادگیری عمیق در مدل پیش‌بینی ایمنی در سیستم مترو (نمونه موردی):

مترو شهر تبریز

امیرحسین عامری، دانش‌آموخته کارشناسی ارشد راه و ترابری، دانشکده عمران، دانشگاه علم و صنعت ایران، تهران، ایران

حمید بیگدلی‌راد، دانشجوی دکتری حمل و نقل، دانشکده عمران، دانشگاه علم و صنعت ایران، تهران، ایران

حمید شاکر، دانشجوی دکتری راه و ترابری، دانشکده عمران، دانشگاه علم و صنعت ایران، تهران، ایران

محمود عامری (مسئول مکاتبات)، استاد گروه راه و ترابری، دانشکده عمران، دانشگاه علم و صنعت ایران، تهران، ایران

E-mail: ameri@iust.ac.ir

پذیرش: ۱۴۰۰/۰۳/۲۲

دریافت: ۱۳۹۹/۱۰/۱۲

چکیده

پیش‌بینی ایمنی سیستم حمل‌ونقل ریلی یک مشکل اساسی در مدل‌سازی و مدیریت حمل‌ونقل ریلی است. در این مقاله، یک مدل پیش‌بینی ایمنی بر اساس یادگیری عمیق برای ایمنی حمل‌ونقل ریلی پیشنهاد شد. این سیستم می‌تواند ویژگی‌های مؤثر برای پیش‌بینی حمل‌ونقل ریلی را به شیوه یادگیری عمیق بدون نظارت یاد بگیرد. داده‌ها از شرکت عملیاتی مترو جمع‌آوری شده و در مورد فاکتورهای مدل پیش‌بینی تصمیم‌گیری شد. از این فاکتورها به‌عنوان ورودی DBN استفاده شد. ساختار داده ورودی، تعداد گره‌های هر لایه را تعیین می‌کند. نمونه داده‌های جمع‌آوری شده شامل انواع رویداد مستعد تصادف، اطلاعات اولیه قطار و اطلاعات عملیاتی شرکت می‌باشد. عوامل پیش‌بینی از طریق تجزیه و تحلیل این داده‌های جمع‌آوری شده انتخاب شد. برای نشان دادن صحت این مدل، یک مجموعه داده (مترو تبریز) به‌عنوان مطالعه موردی مورد بررسی قرار گرفته است. آزمایش‌ها روی مجموعه داده‌ها عملکرد خوب پیش‌بینی مدل حاضر را نشان می‌دهد. پیش‌بینی ایمنی سیستم ریلی و ایمنی واقعی می‌توانند به خوبی باهم مطابقت داشته باشند. این نتایج نشان می‌دهد که یادگیری عمیق در یادگیری الگوهای یک سیستم ریلی مفید است. خطای پیش‌بینی و واقعیت بین $0/08$ تا $0/08$ - معرفی شد. این یک خطای قابل قبول است و نمی‌تواند باعث ایجاد سطح ایمنی نادرست در سیستم شود. بازه تراکم ایمنی چه در وضع موجود و چه در مدل پیش‌بینی، در سطح دوم یعنی نسبتاً ایمن می‌باشد. این بازه متناسب با حد $0/8$ تا $0/89$ می‌باشد. البته که تمایل تراکم پس از سطح دوم به سمت سطح یک است تا سطح سوم. نکته قابل توجه آن است که مدل پیش‌بینی (در سطوح بالا) مقادیر بالاتر از ایمنی موجود را نشان داد.

واژه‌های کلیدی: پیش‌بینی ایمنی، سیستم مترو، مدل‌سازی برخورد‌های ترافیکی، یادگیری عمیق

۱. مقدمه

این روش قابلیت استخراج اطلاعات قدرتمندی در داده‌ها دارد

[Zhang et al., 2017; Karagiannis et al., 2019]

تحقیقات زیادی در سال‌های اخیر بر روی روش پیش‌بینی ایمنی متمرکز شده‌اند. این مطالعه از نظر رویکرد شبکه عصبی برای پیش‌بینی ایمنی راه‌آهن مشابه مطالعه [Ye et al., 2018] است. در این مقاله، از معماری شبکه‌های عصبی مصنوعی برای رسیدگی به مشکل پیش‌بینی نقص سیستم یا معادل آن استفاده شده است. آن‌ها همچنین بهترین ساختار شبکه عصبی را پیدا کرده و عملکرد را هم از نظر میانگین مربع خطا و هم از نظر ضریب همبستگی ارزیابی کرده‌اند، اما آن‌ها تنها از ANN^۲ با دولایه پنهان به دلیل محدودیت الگوریتم آموزش شبکه‌های عصبی مصنوعی استفاده می‌کنند. با توسعه یادگیری عمیق [Zhao et al., 2019; Goodfellow et al., 2016]، روش‌های زیادی بر اساس آن پیشنهاد شده است. رویکرد حاضر، مدلی را بر اساس یادگیری عمیق ارائه داده است.

در سال ۲۰۱۴، دلیو هوانگ و همکاران [Huang et al., 2014] یک معماری عمیق را پیشنهاد دادند که شامل دو بخش است، به‌عنوان مثال، یک شبکه یادگیری عمیق در پایین و یک‌لایه رگرسیون چندمنظوره در بالا. این اولین مقاله‌ای است که رویکرد یادگیری عمیق را در تحقیقات حمل‌ونقل اعمال می‌کند. رویکرد این مطالعه از آن الهام گرفته شده و دارای کاربردی بر روی پیش‌بینی ایمنی سیستم مترو می‌باشد.

در تحقیق دیگری، هوانگ^۳ و همکاران در سال ۲۰۲۰ از تکنیک درخت خطای فازی در تحلیل ایمنی سیستم ترافیک ریلی استفاده کرده‌اند. علاوه بر این، در مدل درخت خطای فازی، امکان برخورد وجود دارد. با این حال، درخت خطا تنها می‌تواند به حوادث بایاس در هر واحد باحالت (۰، ۱) مرتبط باشد. لی^۴ و همکاران [Li et al., 2011] یک مدل ارزیابی ترکیبی فازی دودرجه‌ای از سیستم

امروزه سیستم مترو بسیار گسترش یافته و به یک سیستم حمل‌ونقل انبوه بر در ایران تبدیل شده است. زمانی که تصادف اتفاق می‌افتد، نتایج نامناسب پی‌درپی به بار می‌آورد [Li et al., 2017]. هدف پیش‌بینی ایمنی این سیستم تخمین سطح ایمنی سیستم با توجه به داده‌های گذشته است [Zhang et al., 2016]. رویکردهای جریان اصلی موجود عبارت‌اند از: تکنیک درخت خطای فازی [Huang et al., 2020; Jafarian and Rezvani, 2012]، مدل ارزیابی جامع فازی [Li et al., 2011]، رویکرد شبکه عصبی برای پیش‌بینی ایمنی راه‌آهن [Ye et al., 2018] و رویکرد استدلال فازی و فرآیند تحلیل سلسله مراتبی فازی [Huang et al., 2007] و غیره.

بیشتر روش‌ها دارای نقاط ضعفی هستند. تحلیل درخت خطا تنها می‌تواند رویدادهای (۰، ۱) را تحلیل کند. FAHP^۱ می‌تواند با توجه به عمق و وسعت دانش متخصصان، داده‌های در دسترس، سوگیری متخصصین و اولویت حرفه‌ای محدود شود. مدل پیش‌بینی ماکرو بر اساس روش تحلیل رگرسیون آماری می‌تواند خطای بیشتری داشته باشد و تولید نتایج مطلوب به‌وسیله آن دشوار است. شبکه عصبی کم‌عمق می‌تواند ایمنی سیستم را به‌طور مؤثرتری پیش‌بینی کند [Alawad et al., 2020]. که فقط دارای سه لایه کلی و یک‌لایه پنهان است. بنابراین بیان توابع پیچیده توسط آن دشوار است. با این حال، به‌عنوان نوعی روش جدید یادگیری هوش مصنوعی، یادگیری عمیق می‌تواند بر این کاستی غلبه کند و با تعداد لایه‌های پنهان بیشتر، عملکرد بهتری نسبت به شبکه عصبی سطحی داشته باشد [Heidarysafa et al., 2018]. از طریق یادگیری یک شبکه غیرخطی عمیق، می‌تواند تخمین تابع پیچیده را تحقق بخشد و نمایش توزیعی داده‌های ورودی را مشخص کند.

از آن برای پیش‌بینی جریان ترافیک استفاده شده است [Huang et al., 2014].

جدول ۱. خلاصه ای از مطالعات پیشین

نام و سال	مدل مورد استفاده	هدف
Zhang et al., 2016	درخت تصمیم	تخمین ایمنی سیستم
Li et al., 2011	ارزیابی جامع فازی	تخمین ایمنی سیستم
Ye et al., 2018	شبکه عصبی مصنوعی	پیش بینی ایمنی
Huang et al., 2007	فرآیند تحلیل سلسله مراتبی فازی و استدلال فازی	پیش بینی ایمنی
Goodfellow et al., 2016	شبکه عصبی مصنوعی	پیش‌بینی نقص سیستم
Zhao et al., 2019	یادگیری عمیق	توسعه مدل های پیش بینی تصادفات
Huang et al., 2014	شبکه عصبی عمیق	ارزیابی ریسک و پیش بینی تصادفات ریلی
Huang et al., 2020	درخت خطای فازی	تحلیل ایمنی سیستم ترافیک ریلی
Zhang et al., 2013	شبکه عصبی عمیق- درخت تصمیم	ارزیابی ریسک برای سیستم سیگنال راه‌آهن

در مطالعات گذشته (مطابق جدول ۱)، ایمنی سیستم معمولاً با فراوانی یا شدت تصادفات اندازه‌گیری شده است. برای یک سیستم ریلی، مانند یک سیستم پیچیده معمولی، DBN می‌تواند در یادگیری و گرفتن ویژگی‌های مؤثر بدون دانش قبلی کمک کند. علاوه بر این، در این پژوهش برای پیش‌بینی دقیق‌تر، بهبودهایی در عوامل مدل پیش‌بینی ایجاد شد. رضایت کاربر و احتمال وقوع

ایمنی قطار برای ارزیابی ایمنی پیشنهاد کرده‌اند. آن‌ها عوامل مختلف مؤثر بر ایمنی سیستم را تحلیل کردند. سپس شاخص‌های سیستم ارزیابی ایمنی حمل و نقل ریلی از طریق تلفیق روش‌های کمی و کیفی از چهار بخش انتخاب شدند.

در زمینه آنالیز ایمنی در سیستم ریلی، فرآیند سلسله مراتبی تحلیلی یک روش کلاسیک در مهندسی تحلیل ایمنی است [Ding et al., 2012]. هوانگ^۵ و همکاران روش ارزیابی ریسک ایمنی جدیدی را برای انجام ارزیابی ریسک ایمنی سیستماتیک با استفاده از روش استدلال فازی و فرآیند تحلیل سلسله مراتبی فازی ارائه کرده‌اند [Huang et al., 2007]. این روش می‌تواند هم داده‌های ریسک کیفی و هم اطلاعات مرتبط با عملیات راه‌آهن را به‌طور مؤثر و مؤثر ارزیابی کند. ژانگ و همکاران [Zhang et al., 2013] یک روش جدید ارزیابی ریسک برای سیستم سیگنال راه‌آهن با استفاده از حالت شکست، اثرات و تحلیل بحرانی و فرآیند سلسله مراتبی تحلیل فازی ارائه کرده‌اند. اگرچه این کار نتیجه خوبی دارد، اما بر اساس قضاوت ذهنی هستند، بنابراین نمی‌توانند تضمین کنند که مقدار محاسبه‌شده ارزش عینی هر عامل از سیستم پیچیده است. برخلاف روش سنتی، روش پیشنهادی این مطالعه تلاش می‌کند تا ایمنی را از دیدگاه تحلیل داده‌های عینی، به‌استثنای عوامل ذهنی و ترکیب با روش‌های یادگیری عمیق پیش‌بینی کند.

در این مقاله، تلاش شد تا از یادگیری عمیق برای پیش‌بینی ایمنی سیستم ریلی استفاده شود که ویژگی‌هایی با دانش قبلی محدود را یاد می‌گیرد. این امر از طریق آموزش شبکه یادگیری عمیق بر اساس مطالعه هینتون و همکاران به دست می‌آید [Goodfellow et al., 2016]. مشخص شده است که DBN در یادگیری ویژگی‌های نماینده از داده‌ها به روش بدون نظارت بسیار مؤثر است [Krizhevsky et al., 2017; Lee et al., 2007]. که

۲-۱ استفاده از DBN^۲

یادگیری عمیق توسط هیتون و همکارانش [Hinton et al., 2006] در سال ۲۰۰۶ پیشنهاد شده است که یک شبکه عصبی با چندلایه در مقایسه با یک شبکه عصبی سطحی است. این روش با موفقیت در طبقه‌بندی، رگرسیون، تشخیص تصویر و استخراج ویژگی مورد استفاده قرار گرفته است [Krizhevsky et al., 2017; Kim et al., 2019]

DBN رایج‌ترین و مؤثرترین رویکرد در میان تمام مدل‌های یادگیری عمیق است که یک دسته از RBM ها می باشد. RBM یک‌لایه از واحدهای پنهان تصادفی دودویی و یک‌لایه از واحدهای موردنظر تصادفی دودویی دارد. وزن‌های روی اتصالات و سوگیری‌های واحدهای منفرد یک توزیع احتمال را روی بردارهای حالت دوتایی φ از واحدهای قابل مشاهده از طریق یک تابع انرژی تعریف می‌کند [Teh and Hinton, 2000]. انرژی پیکربندی اتصال (φ, q) به صورت زیر است:

$$E(\varphi, q, \theta) = -\sum_{i=1}^{|D|} \sum_{j=1}^{|G|} w_{ij} \varphi_i q_j - \sum_{i=1}^{|D|} m_i \varphi_i - \sum_{j=1}^{|G|} y_j q_j \quad (4)$$

که در آن $\theta = (m, w, y)$ مجموعه پارامترها، w_{ij} وزن متقارن بین واحد قابل رؤیت i و واحد پنهان j ، و m_i و y_j انحراف آن‌ها است. تعداد واحدهای قابل مشاهده و پنهان به ترتیب D و G نمایش داده می‌شوند. احتمال اینکه مدل به بردار قابل مشاهده D تخصیص یابد به صورت زیر است:

$$P(\varphi; \theta) = \frac{\sum_q e^{-E(\varphi, q)}}{\sum_u \sum_q e^{-E(u, q)}} \quad (5)$$

این پیکربندی محاسبه توزیع‌های احتمال شرطی را آسان می‌کند. سپس می‌توان چندین RBM^۴ را باهم به یک DBN پیوند داد. هر لایه از واحدهای پنهان یاد می‌گیرد که ویژگی‌هایی را نشان دهد که همبستگی‌های مرتبه بالاتری را در داده‌های ورودی اصلی به دست آورد. ایده کلیدی در پشت آموزش یک شبکه یادگیری عمیق

تصادفات نادر به‌عنوان عوامل جدید معرفی شده است. در این مطالعه تحلیلی در مورد انتخاب عوامل مدل پیش‌بینی، روش محاسباتی احتمال وقوع حوادث و برای نخستین بار مدل پیش‌بینی ایمنی سیستم ریلی بر اساس DBN معرفی شد. در انتها نتایج تجربی و تحلیل آن‌ها ارائه شده است.

۲. روش تحقیق

به‌منظور اندازه‌گیری تأثیر تصادف بر عملکرد سیستم، این مقاله به تئوری قابلیت اطمینان اشاره دارد و بیان ایمنی عملیاتی سیستم ریلی را به شکل زیر مطرح می‌کند.

تعریف ۱: ایمنی سیستم عملیاتی، احتمال سیستم برای جلوگیری از وقوع حوادث در شرایط مشخص و در زمان مقرر است.

$$Sa(t) = 1 - \frac{\sum_{i=1}^N A_i z_i}{t} \quad (1)$$

که در آن t چرخه ارزیابی است، N تعداد تصادفات رخ داده در دوره t ، A_i زمان حادثه i ام، و Z ضریب انحراف حادثه i ام است. ایمنی عملیاتی سیستم تابعی از فراوانی تصادفات است.


تعریف ۲: تصادف عملیاتی، تمام انواع حوادث رخ داده در سیستم است. حوادث را می‌توان به شکل زیر بیان کرد.

$$k = \Gamma\{L, R, I, F\} \quad (2)$$

که در آن L تلفات را نشان می‌دهد، R آسیب تجهیزات را نشان می‌دهد، I خسارات اموال را معرفی می‌کند و F آسیب‌های محیط‌زیست را بیان می‌کند. یکی دیگر از مسائل مقدماتی، اندازه‌گیری خطا برای پیش‌بینی ایمنی سیستم ریلی است. به این منظور از میانگین خطای درصد مطلق (MAPE^۵) برای نشان دادن خطا استفاده شد. هنگامی که معماری مدل تعیین شد، MAPE به‌عنوان اندازه‌گیری پایه در مطالعه مدنظر استفاده شد. این مقدار به‌صورت زیر محاسبه شد:

$$MAPE(\delta, \delta') = \frac{1}{n} \sum_{i=1}^N \frac{|\delta_i - \delta'_i|}{\delta_i} \quad (3)$$

شد. تعداد گره‌ها در هر لایه و تعداد لایه پنهان از طریق برخی آزمایش‌ها تعیین شد. در آخر، از نمونه داده‌ها برای آموزش مدل DBN و استفاده از نمونه آزمایش برای تأیید دقت مدل پیش‌بینی استفاده شد.



شکل ۱. چارچوب مدل پیش‌بینی سیستم ترانزیت ریل

۲-۲-۱ تعیین فاکتورهای مدل پیش‌بینی

فاکتورهای پیش‌بینی متشکل از بسیاری از عناصر کیفی و کمی پیچیده هستند. بنابراین، انسان، تجهیزات، محیط و مدیریت چهار جنبه اصلی در بسیاری از روش‌های تحلیلی هستند. در بعد "انسان"، عمدتاً میانگین سن کارکنان و رضایت کاربر به‌عنوان عوامل موثر انتخاب شد. در این تحقیق، افراد در سنین مختلف قضاوت متفاوتی در مورد ایمنی دارند. رابطه مشخصی بین ایمنی سیستم و میانگین سنی کارکنان وجود دارد. رضایت کاربر بیشتر در محیط اجتماعی نمایان می‌شود. رضایت کاربر می‌تواند به رضایت عملکردی و رضایت غیر عملکردی تقسیم شود. همچنین تجربه کاربران از عملکرد سیستم، مانند رضایت از تعامل کاربر و

با آموزش یک توالی از RBM ها این است که پارامترهای مدل، که توسط یک RBM یاد گرفته شده‌اند، هر دو $p(\varphi, q, \theta)$ و توزیع پیشین روی بردارهای پنهان، $p(q/\theta)$ را تعریف می‌کنند. بنابراین احتمال تولید متغیرهای قابل مشاهده را می‌توان به شکل زیر نوشت:

$$P(\varphi) = \sum_q p(q/\theta) p(\varphi/q, \theta) \quad (6)$$

پس از طی مراحل یادگیری θ از یک RBM، $p(\varphi, q, \theta)$ ذخیره شد. علاوه بر این، $p(q/\theta)$ می‌تواند با RBM متوالی جایگزین شود، که لایه پنهان RBM قبلی را به‌عنوان داده آموزش در نظر می‌گیرد. به این ترتیب، همان‌طور که در [Hinton et al., 2006] نشان داده شد، می‌تواند یک کران پایین متغیر بر روی احتمال داده‌های آموزشی را بهبود بخشد. در صورتی که هیچ دلیلی ارائه نشود، DBN می‌تواند به‌عنوان یک روش یادگیری ویژگی بدون نظارت مورد استفاده قرار گیرد.

۲-۲ چارچوب مدل پیش‌بینی

چارچوب مدل پیش‌بینی در شکل ۱ نشان داده شده است. مدل به‌طور کلی به سه بخش تقسیم شد. یک سیستم مترو در این چارچوب در نظر گرفته شد. اول، داده‌ها از شرکت عملیاتی مترو جمع‌آوری شده و در مورد فاکتورهای مدل پیش‌بینی تصمیم‌گیری شد. از این فاکتورها به‌عنوان ورودی DBN استفاده شد. علت استفاده از یادگیری عمیق آن است که از تعداد لایه های پنهان بالاتری می‌توان استفاده نمود، بنابراین دقت مدل افزایش یافته و بیانگر برتری آن نسبت به شبکه های عصبی کم عمق می‌باشد. ساختار داده ورودی، تعداد گره‌های هر لایه را تعیین می‌کند. نمونه داده‌های جمع‌آوری شده شامل انواع رویداد مستعد تصادف، اطلاعات اولیه قطار و اطلاعات عملیاتی شرکت می‌باشد. عوامل پیش‌بینی از طریق تجزیه و تحلیل این داده‌های جمع‌آوری شده انتخاب شد. دوم، DBN بر اساس داده‌های پردازش شده ایجاد

به‌راحتی می‌توانند باعث بلایای ثانویه شوند. مورد دوم بر روی تأثیر عامل انسان متمرکز است، مانند بسیاری از افراد خاطی که تصمیم می‌گیرند در مترو خودکشی کنند یا توسط ایجاد حادثه از جامعه انتقام بگیرند، یا نیروهای تروریستی که با انفجار و تیراندازی در قطار باعث تخریب می‌شوند.

در "مدیریت" میزان عملیات به‌موقع قطار و احتیاط‌های ایمنی کارکنان به‌عنوان فاکتورها انتخاب شد. عامل نخست را می‌توان با نسبت تعداد قطارهایی که به‌موقع می‌رسند و همچنین کل قطارها در طول یک سال بیان کرد. مورد دوم کلید اصلی اجرای مدیریت ایمن است. این سیستم می‌تواند کنترل مؤثر تصادفات را تضمین کرده و به عملکرد ایمن سیستم ریلی بیفزاید.

۲-۲-۲ احتمال رخداد حوادث

CBTC^{۱۱} سیستم ارتباطی اصلی در مترو است. کنترل‌کننده منطقه (ZC^{۱۲}) مهم‌ترین زیرسیستم جانبی مسیر است. هنگامی که یک قطار به سمت یک مسیر کنترل ZC حرکت می‌کند، ZC با جلوگیری از ورود قطارهای دیگر، از قطار موردنظر محافظت می‌کند، و به‌قطار فاصله‌ای را اعلام می‌کند که می‌تواند بدون خطر حرکت کند. منطقه‌ای که ZC برای قطار حفظ می‌کند، قدرت حرکت نامیده می‌شود. بنابراین یک مورد حادثه در MA در نظر گرفته شد. حادثه یک مشکل مهم در سیستم ایمنی ریلی است. ویژگی‌های حادثه اغلب مهم هستند اما چالش خاصی را برای رویکردهای مبتنی بر شبیه‌سازی ایجاد می‌کنند. یکی از راه‌های اصلی برای حل این مشکل، بررسی مدل آماری (SMC^{۱۳}) است [Clarke and Zuliani, 2011]. این تکنیک شبیه‌سازی تصادفی (یعنی مونت کارلو)، بررسی مدل و تحلیل آماری را باهم ترکیب می‌کند و از مقیاس‌پذیری بهتری نسبت به دیگر تکنیک‌ها برخوردار است. با بررسی مدل آماری می‌توان تقریب‌هایی را محاسبه کرد که یک سیستم ترکیبی تصادفی با مشخصات منطق

تجهیزات را نشان می‌دهد. مورد دوم بر فاکتور هدف سیستم، مانند جریان مسافر متمرکز می‌کند. جریان مسافر در سیستم ریلی به مجموع جهت و تعداد جریان مسافر بر روی خط ریلی در واحد زمان اشاره دارد، که مهم‌ترین ویژگی منعکس‌کننده ایمنی مسافر است. رضایت کاربر به‌صورت زیر تعریف شد: $\xi = \alpha_c * \xi_R + \alpha_h * \xi_0$ که در آن ξ_R رضایت عملکردی را نشان می‌دهد، که شامل رضایت از پلت فرم (شامل ویژگی‌های سخت افزاری راه آهن) و رضایت از تعامل کاربر و تجهیزات است؛ α_c و α_h ضرایب وزنی هستند. $\xi_R = \mu + e$ که در آن μ رضایت از پلت فرم را نشان می‌دهد. و e رضایت از تعامل را نشان می‌دهد. هرکدام متناظر با مقدار بین ۰ تا ۱ هستند. با توجه به رضایت غیر عملکردی ξ_0 به‌صورت زیر تعریف شد: که در آن $\xi_0 = R$ نشان‌دهنده جریان مسافر است (سمت و سوی حرکت مسافر و احجام مربوط به آن).

در بخش "تجهیزات"، احتمال وقوع حوادث در سیستم کنترل ریلی به‌عنوان یک فاکتور انتخاب شد. مقالات قبلی نرخ شکست تمام بخش‌های سیستم را بر اساس نمونه و داده‌های جمع‌آوری‌شده به‌جای شبیه‌سازی سیستم انتخاب می‌کنند. این سیستم نمی‌تواند امنیت را از خود سیستم تحلیل کند، و داده‌های خارجی به‌ناچار ایجاد خطا خواهند کرد. سیستم کنترل قطار عمدتاً از سیستم کنترل قطار مبتنی بر ارتباطات (CBTC^{۱۴}) استفاده می‌کند. قدرت حرکت (MA^{۱۵}) در زیرسیستم کنترل‌کننده منطقه شبیه‌سازی‌شده و بر اساس عملیات تصادفی سیستم، احتمال وقوع حوادث به دست می‌آید. احتمال رویداد تصادف با استفاده از روش بررسی مدل آماری که در بخش قبل معرفی شد، محاسبه شد.

در بخش "محیط‌زیست"، تعداد بلایای طبیعی و بلایای ساخت بشر در بخش اجرا به‌عنوان فاکتور انتخاب شد. ابتدا تأثیر محیط طبیعی مانند طوفان، سیل و زلزله را نشان می‌دهد. آن‌ها همچنین

$$Var(\hat{\theta}) = \frac{1}{N}(E[O^2(X)] - \theta^2) \quad (10)$$

چنانچه یک توزیع دیگر برای X در نظر گرفته شود، با چگالی متناظر β ، به طوری که نسبت $\frac{\beta}{\beta^*}$ به خوبی تعریف شده است. $\gamma(X) = \frac{\beta}{\beta^*}$ به عنوان تابع وزن دار یا نسبت درست‌نمایی نشان داده شد. برآورد کننده نمونه‌گیری اهمیت به صورت زیر است:

$$Var(\hat{\theta}_{IS}) = \frac{1}{N}(E_*[O^2(X)\Delta^2(X)] - \theta^2) \quad (11)$$

و واریانس آن به صورت زیر است:

$$\hat{\theta}_{IS} = \frac{1}{N}(\sum_{i=1}^N O(X_i)\Delta(X_i)) \quad (12)$$

حال که مشکل، پیدا کردن چگالی است که می‌تواند $Var(\hat{\theta}_{IS})$ را تا حد ممکن کوچک کند. در واقع، تایید می‌شود که وقتی تابع Δ غیر منفی است، چگالی بهینه زیر منجر به یک تخمین زننده واریانس صفر می‌شود:

$$\beta_*(x) = \frac{O(x)\beta(x)}{c} \quad (13)$$

با این حال، از آنجاکه حالت بهینه به $\theta = E[O(X)]$ بستگی دارد سعی در تخمین آن می‌شود. بنابراین باید از چگالی نزدیک به چگالی بهینه به جای چگالی بهینه استفاده شود. این روشی است که توسط روش آنترابی مقاطع اتخاذ شده است. روش آنترابی مقاطع در سال ۱۹۹۹ توسط رابین اشتین معرفی شد. این روش چگالی بایاس را طوری انتخاب می‌کند که واگرایی کولبک - لیبلر بین چگالی بایاس بهینه و چگالی انتخابی حداقل است. این مقوله دو مرحله اساسی دارد:

(۱) با حداقل واگرایی کولبک - لیبلر با توجه به چگالی بایاس

بهینه، چگالی محاسبه شود؛

(۲) نمونه‌گیری با چگالی بایاس محاسبه شده در مرحله ۱

برای تخمین $E[O(X)]$ انجام شود.

در حالت یک‌بعدی داریم:

$$\hat{\psi}^* = \frac{E[O(X)X]}{E[O(X)]} \quad (14)$$

زمانی داده شده مطابقت دارد. با این حال، برآورد احتمالات حادثه دقیق با استفاده از تکنیک مونت کارلو استاندارد نیازمند تعداد نمونه بسیار بالا است، بنابراین یک هدف کلیدی برای SMC کاهش تعداد و طول شبیه‌سازی‌ها است. در مرور ادبیات، دو تکنیک برای کنار آمدن با این مشکل بیان شده‌اند که عبارت‌اند از اهمیت نمونه‌برداری و جامعه‌گرایی.

اهمیت نمونه‌گیری بر اساس روش مونت کارلو بوده که می‌تواند کمک کند تا واریانس روش مونت کارلو کاهش یابد. در اینجا اثرات اهمیت نمونه‌برداری نشان داده شده است. متغیر تصادفی برنولی B تعریف شد که ۱ یا ۰ می‌باشد. B یک احتمال خاص p دارد که تخمین زده می‌شود که آیا $B = 1$ هست یا نیست. در اینجا X به عنوان یک متغیر تصادفی نشان داده شد، یعنی مقدار $B=1$ یا نه، و $I(0)$ یک تابع شاخص است. برای یک دنباله متغیر داده شده X_1, \dots, X_N ، برآوردگر مونت کارلو p توسط قانون داده‌های زیاد به p به صورت $N \rightarrow \infty$ (با احتمال ۱) همگرا خواهد شد. در اینجا p به صورت زیر است:

$$\hat{p} = \frac{1}{N} \sum_{i=1}^N O(X_i) \quad (7)$$


و واریانس آن:

$$Var(\hat{p}) = \frac{Var(k_B(X_i))}{N} \quad (8)$$

برای اینکه کارایی نمونه‌برداری مؤثر باشد، یافتن توزیع نمونه‌برداری مناسب بدون در نظر گرفتن کل فضای حالت بسیار مهم است. اگر یک موقعیت کلی‌تر با یک متغیر تصادفی X ترکیب شود، یک تابع قابل اندازه‌گیری $O: \mathbb{R} \rightarrow \mathbb{R} \geq 0$ و یک متغیر تخمینی $\theta = E[O(X)]$ ، تخمین مونت کارلو به صورت زیر حاصل شد:

$$\hat{\theta} = \frac{1}{N} \sum_{i=1}^N O(X_i) \quad (9)$$

که در آن X_1, \dots, X_N متغیرهای تصادفی iid با چگالی β هستند. واریانس آن به صورت زیر محاسبه شد:



شکل ۲. مدل یادگیری عمیق پیش‌بینی سیستم ریلی

که در آن U متوسط سن کارمندان، A نشان‌دهنده رضایت کاربر، I احتمال رویداد حوادث، N نشان‌دهنده تعداد بلاای طبیعی، M به معنی تعداد بلاای ساخت بشر، R به معنی میزان عملیات به موقع قطار و F به معنی تست آموزش احتیاط‌های ایمنی کارکنان است. بنابراین تعداد گره‌ها در هفت لایه ورودی تنظیم شد. برخلاف RBM باینری، همان‌طور که در بخش قبل معرفی شد، با واحدهای با مقدار واقعی جایگزین شد که از توزیع نرمال برای مدل کردن سیستم ریلی پیروی می‌کنند زیرا داده‌های جمع‌آوری شده ۰ یا ۱ نیستند. مدل سیستم ریلی مشاهده شد و از نتایج تعداد زیادی شبیه‌سازی مدل λ تولید شد.

تابع انرژی و توزیع‌های احتمال شرطی به‌صورت زیر داده‌شده‌اند:

$$E(\varphi, q, \theta) = \sum_{i=1}^{|D|} \frac{(\varphi_i - \eta b_i)^2}{2\sigma_i^2} - \sum_{j=1}^{|G|} \lambda \beta_j q_j - \sum_{i=1}^{|D|} \sum_{j=1}^{|G|} \frac{\varphi_i}{\sigma_i} w_{ij} q_j \quad (17)$$

$$p = (q_j | \varphi_i; \theta) = \sigma \left(\sum_{i=1}^{|D|} w_{ij} \varphi_i + \lambda \beta_j \right) \quad (18)$$

که σ بردار انحراف معیار واحدهای قابل مشاهده توزیع نرمال، و $N(\mu, 2\sigma)$ توزیع نرمال با میانگین μ و واریانس σ است. می‌توانیم با DBN به‌عنوان یک مدل یادگیری برخوردار کرد. هر

باین‌حال، در بررسی مدل آماری $O(X_i)$ یا ۱ یا ۰ است. بعلاوه، در مواردی حوادث نادر بسیار بعید خواهد بود که نمونه‌ای را منطبق با ویژگی منطق زمانی ببیند، به این معنی که برای اندازه‌های مناسب نمونه $\hat{\psi}^*$ فقط مقدار ۰/۰ را خروجی می‌دهد. می‌توان مسئله را با معرفی پارامتر شیب Φ حل کرد، بنابراین نتیجه نهایی عبارت است از:

$$\hat{\psi}^* = \frac{\sum_{i=1}^N O(X_i) \Omega(X_i, \Phi) X_i}{\sum_{i=1}^N O(X_i) \Omega(X_i, \Phi)} \quad (15)$$

۲-۳-۲ مدل پیش‌بینی مبتنی بر DBS^{۱۴}

در بسیاری از روش‌های قبلی، پیش‌بینی ایمنی سیستم ریلی در معماری شبکه کم‌عمق انجام می‌شدند. در عوض، در این مقاله برای نخستین بار از روش یادگیری عمیق استفاده شد. برای سیستم ریلی مانند یک سیستم پیچیده، معمولاً یک‌لایه پنهان برای توصیف روابط پیچیده بین ورودی‌ها و خروجی‌ها کافی نیست. یادگیری عمیق می‌تواند برتری خود را در برخورد با این روابط پیچیده نشان دهد. علاوه بر این، می‌تواند ویژگی‌ها را به شکل عمیق‌تری یاد بگیرد. در این مقاله از DBN برای یادگیری بدون نظارت برای پیش‌بینی ایمنی سیستم ریلی استفاده شد. مطالعه حاضر بر روی یادگیری عمیق، آموزش شبکه‌های عصبی عمیق را از زمان پیشرفت Hinton در سال ۲۰۰۶ مؤثرتر کرده است [Hinton et al., 2006]. سپس، از رگرسیون سیگموئید در لایه بالایی در رویکرد موردنظر استفاده شد به‌طوری‌که می‌توان تنظیم دقیق تحت نظارت بر کل معماری شبکه را به‌راحتی انجام دهد. معماری مدل حاضر برای پیش‌بینی ایمنی سیستم ریلی در شکل ۲ خلاصه‌شده است. فضای ورودی X به‌طورکلی داده‌های خام جمع‌آوری شده می‌باشد. مدل پیش‌بینی دارای هفت داده ورودی شامل تمام عوامل پیش‌بینی است. هفت داده خام یک گروه از داده‌های ورودی را تشکیل می‌دهند. بردار ورودی X می‌تواند به شکل زیر نشان داده شود:

$$X = \{U, A, I, N, M, R, F\} \quad (16)$$

لایه در DBN فرآیند تغییر ویژگی غیرخطی است. ویژگی‌های آموخته شده در لایه بالایی DBN، بارزترین ویژگی‌ها برای مدل‌سازی داده‌ها هستند. ویژگی‌های نماینده به روش بدون نظارت یاد گرفته می‌شوند و می‌توانند برای کارهای مختلف، مانند طبقه‌بندی و رگرسیون استفاده شوند. در معماری مدل موردنظر، بهترین ویژگی‌ها به‌عنوان بردار ورودی برای پیش‌بینی استفاده می‌شوند (لایه رگرسیون بالایی). ویژگی‌های آموخته‌شده از DBN می‌تواند از طریق پشتیبان‌گیری خطا در کل ساختار با استفاده از داده‌های برجسب دار برای پیش‌بینی بهتر استفاده شود.

۳. منطقه مورد مطالعه

با ساخت راه‌آهن‌های سریع، از جمله راه‌آهن پرسرعت و مترو، نیاز مبرمی به‌دقت بیشتر و روش‌های تحلیل ایمنی قابلیت اطمینان وجود دارد. مترو نوعی حمل‌ونقل با فن‌آوری پیچیده و مسافران زیاد است، که همچنین یک سیستم استاندارد ریلی است. این سیستم به یک فرآیند بازگشتی ساختاریافته نیاز دارد که بهبود تحلیل ایمنی فعلی را بر اساس دانش حوادث گذشته تضمین می‌کند. اگر یک یا چند ایستگاه بر اثر تصادف دچار اختلال شوند، تأثیر زیادی نه تنها بر روی خط مترو به‌تنهایی بلکه بر روی کل شبکه مترو خواهد داشت. سیستم ارتباطی نرخ شکست بالایی دارد و تصادفات مسافر در جایگاه دوم است.

سیستم مورد مطالعه در این پژوهش، مترو تبریز می‌باشد. متروی شهر تبریز به‌صورت رسمی از ۵ شهریور ۱۳۹۴ با راه‌اندازی فاز نخست خط ۱، در حدفاصل ایستگاه ائل‌گلی تا ایستگاه استاد شهریار به بهره‌برداری رسید. فاز دوم این خط نیز در حدفاصل ایستگاه استاد شهریار تا ایستگاه میدان ساعت در ۲۸ بهمن ۱۳۹۵ راه‌اندازی شد. فاز سوم این خط نیز در تاریخ ۲۴ بهمن ۱۳۹۸ با چهار ایستگاه میدان کهن، امام حسین (ع)، شهید باکری و نور

راه‌اندازی شد. متروی تبریز از پنج خط (شامل چهار خط اصلی و یک خط حومه) به طول ۱۰۰ کیلومتر تشکیل شده است. تجهیزات سازمان قطار شهری تبریز شامل سیستم‌های OCS، مخابرات، پست‌های برق، مکانیک و تأسیسات می‌باشد. در این بخش، از نمونه داده‌های مترو تبریز در سال ۱۳۹۴ برای نشان دادن کاربرد مدل پیش‌بینی ایمنی در یک مترو واقعی استفاده شد.

۴. نتایج و تحلیل آن‌ها

۴-۱ معماری مدل

برای تمام آزمایش‌ها، پارامترهای متعددی وجود دارند. باید برای مدل پیش‌بینی سیستم ریلی تعریف شود. برای سادگی، تعداد گره‌ها در هر لایه یکسان تنظیم شده است. داده‌های مورد نظر با مساعدت تعدادی از همکاران در سیستم قطار شهری تبریز بدست آمد. همان‌طور که در بخش قبل گفته شد، بردار ورودی X یک هفت‌تایی با هفت عامل است. ساختار داده ورودی تعداد گره‌های هر لایه را تعیین می‌کند. بنابراین، گره‌ها در ۷ لایه قرار داده می‌شوند.

تعداد لایه‌های پنهان کلید مدل است. پارامتر تعداد لایه پنهان روی مجموعه داده‌های جمع‌آوری شده بهینه شد و سپس بهترین تنظیمات برای محاسبه MAPE برای مجموعه تست استفاده شد. از MAPE برای تست تأثیر پارامتر تعداد لایه پنهان بر معماری مدل استفاده شد درحالی‌که پارامترهای دیگر ثابت نگه‌داشته شده بودند.

مسئله اندازه شبکه یکی از مشکلات معمول در طراحی شبکه عصبی است. زمان یادگیری و قابلیت مدل خاص شبکه عصبی به‌شدت تحت تأثیر پارامترهای اندازه شبکه است. نتایج در جدول ۲ گزارش شده است.

عمیق در MATLAB2018a مدل‌سازی و آموزش داده شد. اگرچه هزینه یادگیری عمیق در ذخیره‌سازی و محاسبه بسیار زیاد است، اما اغلب آزمایش‌ها را می‌توان در کم‌تر از ۱ ساعت در یک کامپیوتر با واحد پردازش مرکزی هفت هسته ای، حافظه ۱۶ گیگابایت، انجام داد.

۴-۲ نتایج DBN

در این بخش، قابلیت‌های یادگیری و پیش‌بینی مدل بررسی شد. در ابتدا نمونه‌ای از عملکرد رویکرد موردنظر در شکل ۳ نشان داده شده است. استاندارد موردنظر در جدول ۳ آمده است. همان‌طور که به تصویر کشیده شده است، بازه متراکم ایمنی چه در وضع موجود و چه در مدل پیش‌بینی، در سطح دوم (یعنی نسبتاً ایمن) می‌باشد. این بازه متناسب با حد ۰/۸ تا ۰/۸۹ می‌باشد. البته که تمایل تراکم پس از سطح دوم به سمت سطح یک است تا سطح سوم. نکته قابل توجه آن است که خط قرمز رنگ یعنی مدل پیش‌بینی (در سطوح بالا) مقادیر بالاتر از وضع ایمنی موجود را نشان می‌دهد و در مقادیر پایین‌تر (سطوح پایین‌تر) مقادیر پایین‌تری را نشان می‌دهد. می‌توان این مقوله را به سوگیری مربوط دانست. کمی اغراق در پاسخ‌ها را می‌توان به این خروجی ارتباط داد که در سطوح بسیار بالای ایمنی و سطوح بسیار پایین، مدل پیش‌بینی مقادیر پراکنده‌تری را (مرکزگریزی) معرفی نموده است.

در شکل ۳، روش مورد مطالعه نوسانات و تغییرات نتیجه واقعی را بیان می‌کند که به این معنی است که می‌تواند ایمنی سیستم ریلی را در هر مورد با توجه به ورودی دقیق پیش‌بینی کند. پیش‌بینی ایمنی سیستم ریلی و ایمنی واقعی می‌توانند به خوبی با هم مطابقت داشته باشند. این موضوع نشان می‌دهد که یادگیری عمیق در یادگیری الگوهای یک سیستم ریلی مفید است. خطای پیش‌بینی و مقادیر واقعی بین ۰/۰۸ تا ۰/۰۸- محاسبه شد و بیشتر آن‌ها بین

جدول ۲ MAPE و زمان آموزش را با تغییرات تعداد لایه‌ها نشان می‌دهد. در این آزمایش، تعداد گره‌ها در هر لایه به‌طور مشابه ثابت است (در اینجا ۸). نتایج می‌تواند با افزایش لایه‌ها از یک‌به‌پنج بهبود یابد. زمان آموزش، پیچیدگی فضایی - زمانی هر مدل را نشان می‌دهد که تقریباً به‌صورت خطی با افزایش لایه‌ها افزایش می‌یابد. بنابراین، اندازه لایه مخفی برابر ۵ تنظیم شد. خروجی که این مطالعه به دنبال آن است، مقدار پیش‌بینی ایمنی سیستم ریلی می‌باشد، بنابراین از رگرسیون سیگموئید در لایه رگرسیون استفاده شد.

جدول ۲. اثرات تعداد لایه‌ها

لایه‌ها	MAPE	زمان (ثانیه)
۱	۰/۸۲۱	۰/۱۵
۲	۰/۸۳۹	۰/۲۲
۳	۰/۸۷۶	۰/۴۳
۴	۰/۸۸۶	۰/۵۱
۵	۰/۹۲۸	۰/۵۹
۶	۰/۸۷۹	۰/۷۱
۷	۰/۸۵۱	۰/۸۱
۸	۰/۸۳۳	۰/۸۸

مجموعه‌های داده: یک مجموعه نمونه داده در این مطالعه مورد استفاده قرار گرفت. یک گروه از داده‌های X در زمان اجرا از سیستم موردنظر جمع‌آوری شد. ۶۰۰ گروه داده جمع‌آوری شد و همه نوع حادثه شمارش شد، سپس خروجی مدل به شکل یک احتمال بیان شد.

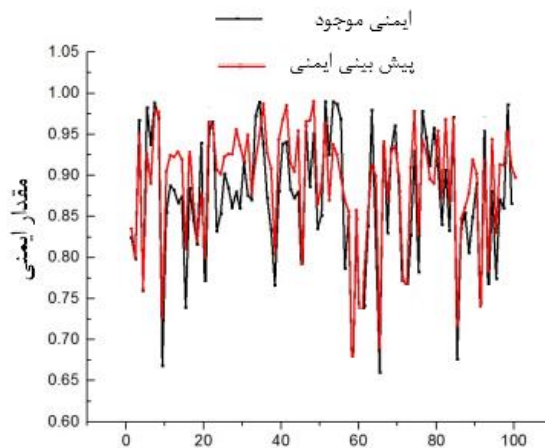
ورودی (بردار ویژگی X) مدل، ۵۰۰ داده گروهی است و خروجی مدل مقدار پیش‌بینی ایمنی سیستم ریلی با ورودی مربوطه است. از داده‌های مدنظر ۵۰۰ گروه به‌عنوان مجموعه آموزشی و ۱۰۰ گروه به‌عنوان مجموعه تست استفاده شد. معماری روش یادگیری

در این مقاله، یک مدل پیش‌بینی مبتنی بر یادگیری عمیق برای پیش‌بینی ایمنی ارائه شد، که به‌عنوان یک DBN پیاده‌سازی شده است. DBN برای یادگیری ویژگی بدون نظارت مؤثر است. در همین حال، پیشرفت‌هایی در عوامل پیش‌بینی ورودی یافت شد که عبارت‌اند از رضایت کاربر و احتمال وقوع مجدد. با توجه به آزمایش‌ها بر روی مجموعه داده‌ها، نشان داده شد که مدل پیش‌بینی موردنظر دارای دقت بالایی در پیش‌بینی ایمنی سیستم ریلی است. علاوه بر این، دو عاملی که معرفی شد می‌تواند به‌طور مؤثر ایمنی سیستم را منعکس کند و دقت پیش‌بینی را بهبود بخشند. این بدان معنی است که یادگیری عمیق صرفاً مربوط به حوزه‌های مرتبط با شبکه عصبی مانند تشخیص تصویر و صدا مؤثر نیست، بلکه برای سیستم‌های پیچیده دیگر نیز مفید است. به‌منظور ساخت یک مدل پیش‌بینی ایمنی بهتر، نمونه داده‌های سیستم ریلی می‌تواند افزایش یابد و کاربرد آن در سیستم‌های بزرگ‌تر نیاز به مطالعه بیشتر دارد. بازه متراکم ایمنی چه در وضع موجود و چه در مدل پیش‌بینی، در سطح دوم یعنی نسبتاً ایمن می‌باشد. این بازه متناسب با حد $0/8$ تا $0/89$ می‌باشد. البته که تمایل تراکم پس از سطح دوم به سمت سطح یک است تا سطح سوم. نکته قابل‌توجه آن است که خط قرمز رنگ یعنی مدل پیش‌بینی (در سطوح بالا) مقادیر بالاتر از ایمنی موجود را نشان می‌دهد و در مقادیر پایین‌تر (سطوح پایین‌تر) مقادیر پایین‌تری را نشان می‌دهد. می‌توان این مقوله را به سوگیری مربوط دانست. کمی اغراق در پاسخ‌ها را می‌توان به این خروجی ارتباط داد که در سطوح بسیار بالای ایمنی و سطوح بسیار پایین، مدل پیش‌بینی مقادیر پراکنده‌تری را (مرکزگرایی) معرفی نموده است.

۶. پی‌نوشت‌ها

1. Fuzzy Analytical Hierarchy Process
2. Artificial neural network
3. Huang
4. Li

۰/۰۰ تا ۰/۰۶- می‌باشد. این یک خطای قابل قبول است و نمی‌تواند باعث ایجاد سطح ایمنی نادرست در سیستم شود.



شکل ۳. مقایسه پیش‌بینی ایمنی سیستم و ایمنی واقعی سیستم در ۱۰۰ گروه داده

جدول ۳. سطوح ایمنی سیستم ریلی

سطح	وضعیت سطح	مقدار پیش‌بینی
۱	بسیار ایمن	۱-۰/۹
۲	نسبتاً ایمن	۰/۸۹-۰/۸
۳	ناایمن	۰/۷۹-۰/۷
۴	خطرناک	کمتر از ۰/۷

در نتیجه، مدل پیش‌بینی موردنظر در پیش‌بینی ایمنی سیستم ریلی بسیار مؤثر است. این مقوله می‌تواند به رابطه پیچیده یک سیستم ریلی اشاره کند. مزیت یادگیری ویژگی بدون نظارت، این مدل را برای استفاده آسان‌تر می‌کند. این امید وجود دارد که یادگیری عمیق در تحقیقات دیگر ریلی اعمال شود و بسیاری از مشکلات مرتبط با سیستم ریلی، مانند مدیریت سیستم، می‌تواند از روش عمیق یادگیری برای نتایج بهتر استفاده کنند.

۵. نتیجه‌گیری

- Hinton, G. E., Osindero, S., & Teh, Y. W. (2006). A fast learning algorithm for deep belief nets. *Neural computation*, 18(7), 1527-1554.

- Huang, S., An, M., Chen, Y., & Baker, C. (2007, October). Railway Safety Risk Assessment Using FRA and FAHP Approaches—A Case Study on Risk Analysis of Shunting at Waterloo Depot. In *Proceedings of the 2007 2nd Institution of Engineering and Technology International Conference on System Safety*, London, UK (pp. 22-24).

- Huang, W., Liu, Y., Zhang, Y., Zhang, R., Xu, M., De Dieu, G. J., ... & Shuai, B. (2020). Fault Tree and Fuzzy DS Evidential Reasoning combined approach: An application in railway dangerous goods transportation system accident analysis. *Information Sciences*, 520, 117-129.

- Huang, W., Song, G., Hong, H., & Xie, K. (2014). Deep architecture for traffic flow prediction: deep belief networks with multitask learning. *IEEE Transactions on Intelligent Transportation Systems*, 15(5), 2191-2201.

- Jafarian, E., & Rezvani, M. A. (2012). Application of fuzzy fault tree analysis for evaluation of railway safety risks: an evaluation of root causes for passenger train derailment. *Proceedings of the Institution of Mechanical Engineers, Part F: Journal of Rail and Rapid Transit*, 226(1), 14-25.

- Karagiannis, G., Olsen, S., & Pedersen, K. (2019, April). Deep learning for detection of railway signs and signals. In *Science and Information Conference* (pp. 1-15). Springer, Cham.

5. Huang
6. Mean absolute percentage error
7. Deep belief network
8. Restricted Boltzmann machine
9. Communication Based Train Control System
10. Moving Average
11. Communications-based train control
12. Zone Controllers
13. Sheet Molding Compound
14. Deep brain stimulation

۷. منابع

- Alawad, H., Kaewunruen, S., & An, M. (2020). A deep learning approach towards railway safety risk assessment. *IEEE Access*, 8, 102811-102832.

- Clarke, E. M., & Zuliani, P. (2011, October). Statistical model checking for cyber-physical systems. In *International Symposium on Automated Technology for Verification and Analysis* (pp. 1-12). Springer, Berlin, Heidelberg.

- Ding, L. Y., Yu, H. L., Li, H., Zhou, C., Wu, X. G., & Yu, M. H. (2012). Safety risk identification system for metro construction on the basis of construction drawings. *Automation in construction*, 27, 120-137.

- Goodfellow, I., Bengio, Y., Courville, A., & Bengio, Y. (2016). *Deep learning* (Vol. 1, No. 2). Cambridge: MIT press.

- Heidarysafa, M., Kowsari, K., Barnes, L., & Brown, D. (2018, December). Analysis of Railway Accidents' Narratives Using Deep Learning. In *2018 17th IEEE International Conference on Machine Learning and Applications (ICMLA)* (pp. 1446-1453). IEEE.

- Zhang, Y. P., Xu, Z. J., & Su, H. S. (2013). Risk assessment on railway signal system based on fuzzy-FMECA method. *Sensors & Transducers*, 156(9), 203.
- Zhang, Y., Han, J., Liu, J., Zhou, T., Sun, J., & Luo, J. (2017, May). Safety prediction of rail transit system based on deep learning. In *2017 IEEE/ACIS 16th International Conference on Computer and Information Science (ICIS)* (pp. 851-856). IEEE.
- Zhao, Z. Q., Zheng, P., Xu, S. T., & Wu, X. (2019). Object detection with deep learning: A review. *IEEE transactions on neural networks and learning systems*, 30(11), 3212-3232.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2017). ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84-90.
- Lee, H., Ekanadham, C., & Ng, A. (2007). Sparse deep belief net model for visual area V2. *Advances in neural information processing systems*, 20, 873-880.
- Li, J., Song, R., & Jiang, J. L. (2011). Safety evaluation of rail transit based on comprehensive fuzzy evaluation model. *Journal of Transport Science and Engineering*, 27(2), 91-95.
- Li, Q., Song, L., List, G. F., Deng, Y., Zhou, Z., & Liu, P. (2017). A new approach to understand metro operation safety by exploring metro operation hazard network (MOHN). *Safety science*, 93, 50-61.
- Kim, B., Kim, H., Kim, K., Kim, S., & Kim, J. (2019). Learning not to learn: Training deep neural networks with biased data. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 9012-9020).
- Teh, Y. W., & Hinton, G. E. (2001). Rate-coded restricted Boltzmann machines for face recognition. *Advances in neural information processing systems*, 908-914.
- Ye, T., Wang, B., Song, P., & Li, J. (2018). Automatic railway traffic object detection system using feature fusion refine neural network under shunting mode. *Sensors*, 18(6), 1916.
- Zhang, X., Deng, Y., Li, Q., Skitmore, M., & Zhou, Z. (2016). An incident database for improving metro safety: The case of shanghai. *Safety science*, 84, 88-96.

امیرحسین عامری، درجه کارشناسی در رشته مهندسی عمران را در سال ۱۳۹۵ از دانشگاه تهران و درجه کارشناسی ارشد در رشته راه و ترابری را در سال ۱۳۹۸ از دانشگاه علم و صنعت ایران اخذ نمود. زمینه های پژوهشی مورد علاقه ایشان مهندسی ترافیک، مدلسازی و بهینه سازی در حمل و نقل، اصلاح مخلوط - های آسفالتی و بهینه یابی در مخلوط های آسفالتی می باشد.



حمید بیگدلی راد، درجه کارشناسی در رشته مهندسی عمران را در سال ۱۳۹۲ از دانشگاه زنجان و درجه کارشناسی ارشد در رشته برنامه ریزی حمل و نقل را در سال ۱۳۹۴ از دانشگاه بین المللی امام خمینی (ره) قزوین اخذ نمود. هم اکنون نیز دانشجوی دکتری رشته برنامه ریزی حمل و نقل در دانشگاه علم و صنعت ایران است. زمینه های پژوهشی مورد علاقه ایشان برنامه ریزی حمل و نقل، مهندسی ترافیک، مدلسازی و بهینه سازی در حمل و نقل، سیستم های حمل و نقل عمومی و ایمنی در ترافیک است



حمید شاکر، درجه کارشناسی در رشته مهندسی عمران را در سال ۱۳۹۳ از دانشگاه محقق اردبیلی و درجه کارشناسی ارشد در رشته راه و ترابری در سال ۱۳۹۵ را از دانشگاه علم و صنعت ایران اخذ نمود. هم اکنون نیز دانشجوی دکتری رشته راه و ترابری در دانشگاه علم و صنعت ایران است. زمینه های پژوهشی مورد علاقه ایشان مهندسی ترافیک، مدلسازی و بهینه سازی در حمل و نقل، مواد و مصالح روسازی آسفالتی، بهبود خصوصیات مخلوط های آسفالتی و مکانیک شکست است.



محمود عامری، درجه کارشناسی و کارشناسی ارشد در رشته مهندسی عمران - راه و ترابری را به ترتیب در سال های ۱۳۶۰ و ۱۳۶۲ از دانشگاه تگزاس اخذ نمود. در سال ۱۳۶۹ موفق به کسب درجه دکتری در رشته مهندسی عمران - راه و ترابری از دانشگاه تگزاس گردید. زمینه های پژوهشی مورد علاقه ایشان طراحی رو سازی، مواد و مصالح رو سازی و مدیریت رو سازی بوده و در حال حاضر عضو هیئت علمی دانشگاه علم و صنعت ایران است.

