

پیش‌بینی فضای خالی مخلوط‌های آسفالتی در جاده‌های تحت سرویس با استفاده از شبکه‌های عصبی مصنوعی

علی حیدریپناه، استادیار، پژوهشکده مواد، پژوهشگاه علوم و تکنولوژی پیشرفته و علوم محیطی، دانشگاه تحصیلات تکمیلی صنعتی و فناوری پیشرفته، کرمان، ایران

E-mail: a.heidaripناه@gmail.com

پذیرش: ۱۴۰۴/۰۱/۲۴

دریافت: ۱۴۰۳/۱۱/۲۶

چکیده

فضای خالی مخلوط آسفالتی یکی از مهمترین پارامترها در طراحی و عملکرد آسفالت در فرایند طراحی، ساخت و تعمیر روسازها می باشد. تغییرات این پارامتر پس از ساخت جاده، تحت ترافیک و در طول زمان، باعث تغییر در عملکرد مخلوط های آسفالتی می شود. از این رو پیش بینی فضای خالی آسفالت در جاده تحت سرویس، نیازی اساسی برای پیش بینی تغییرات عملکرد آسفالت به شمار می رود. در این تحقیق، اولین مدل پیش بینی برای تخمین فضای خالی آسفالت، با استفاده از شبکه های عصبی مصنوعی (ANNs) پیشرو، با الگوریتم آموزش انتشار به عقب لونیگ-مارکواد (LMBP)، با موفقیت و دقت بالای $R^2 = 0.97$ ارائه شده است. الگوریتم LMBP یک روش دینامیک است که سرعت تکنیک گوس-نیوتن را با تضمین همگرایی تکنیک SD همراه می کند. همچنین، نحوه طراحی و تنظیم پارامتر های آموزش LMBP، برای افزایش امکان دستیابی به دقت بالاتر ارائه شده است.

واژه های کلیدی: شبکه عصبی مصنوعی، آسفالت، فضای خالی آسفالت

۱. مقدمه و ادبیات پژوهش

فضای خالی مخلوط های آسفالتی (V_a)، از مهمترین پارامترهای طرح مخلوط های آسفالتی می باشد. طرح مخلوط های آسفالتی چه در روش سوپر پیو و چه در روش مارشال بر اساس فضای خالی ۴٪ انجام می گیرد [AASHTO M323-2014, MS-2 2022, 22]. علاوه بر آن، V_a از مهمترین پارامترهای موثر بر عملکرد و خرابی های اساسی در مخلوط های آسفالتی شامل شیار افتادگی و ترکهای خستگی می باشد [MEPDG 2025].

تحقیقات انجام شده نشان می دهد که میزان فضای خالی مخلوط های آسفالتی (V_a)، بر میزان مقاومت آسفالت در برابر ترکهای خستگی (عمر خستگی آسفالت) تاثیر مستقیم دارد. هاروی و سای [Harvey and Tsai 1996] آنها در یک تحقیق آزمایش تیرچه خستگی با کرنش کنترل شده را روی نمونه های آسفالت با دانه بندی و نوع قیر یکسان، با پنج درصد مختلف قیر و سه V_a مختلف انجام دادند. نتایج بدست آمده نشان می داد که کاهش V_a ، باعث افزایش مقاومت آسفالت در برابر ترکهای خستگی می شود. همچنین افزایش میزان قیر، باعث کاهش سختی و افزایش مقاومت آسفالت در برابر ترکهای خستگی می شود. آنها همچنین با استفاده از تئوری الاستیک، اثر تغییرات میزان قیر و V_a را بر عمر خستگی راه، برای چندین روکش آسفالت ضخیم، با استفاده از آزمایشهای سختی و خستگی آسفالت، شبیه سازی کردند. نتایج نشان داد که در مخلوط های آسفالتی، افزایش درصد قیر و کاهش فضای خالی، باعث افزایش عمر خستگی آسفالت می شود.

در تحقیق دیگری، زیادا و همکاران [Zeida et al. 2022] تاثیر کلیدی تغییرات میزان درصد قیر و V_a آسفالت را بر عملکرد خستگی نمونه های آزمایشگاهی آسفالت و نیز خستگی آسفالت در بلند مدت نشان دادند. بدین منظور آنها ۴ ترکیب نمونه های آسفالت با درصد قیر های ۴/۲٪ و ۵/۲٪. نیز V_a با مقادیر ۴/۵٪ و ۹/۵٪ ساختند و آزمایشهای مدول دینامیکی E^*

برای تعیین سختی آسفالت و نیز آزمایشهای خستگی تک محوری را روی نمونه های آسفالتی انجام دادند. آنها نشان دادند که برای عملکرد خستگی نمونه های آزمایشگاهی، افزایش میزان درصد قیر و کاهش مقدار V_a آسفالت باعث افزایش قابل توجه در عمر خستگی آسفالت می شود. آنها برای ارزیابی تاثیر میزان درصد قیر و V_a در عملکرد خستگی دراز مدت، خستگی دراز مدت میدانی آسفالت را با استفاده از نرم افزار AASHTOWare (نرم افزار طراحی مکانیستیک-تجربی) و با استفاده از نتایج آزمایشهای خستگی تک محوری شبیه سازی کردند. آنها اظهار داشتند که بر اساس نتایج شبیه سازی، بنظر می رسد که در مناطق گرم و در آسفالت های با ضخامت کم، افزایش درصد قیر و کاهش V_a ، باعث افزایش عمر خستگی آسفالت یا همان کاهش میزان ترکهای خستگی در دوره طرح می شود. و برعکس آن در مناطق سرد و آسفالت های با ضخامت زیاد، کاهش درصد قیر و افزایش V_a باعث افزایش عمر خستگی آسفالت یا همان کاهش میزان ترکهای خستگی در دوره طرح می شود.

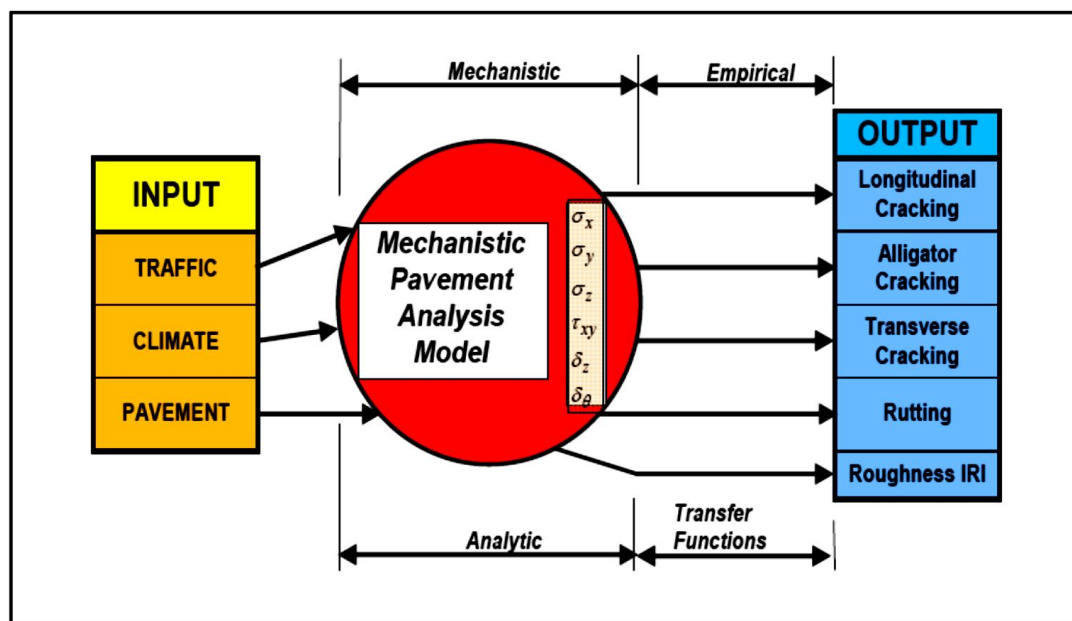
تحقیقات انجام شده نشان می دهد که میزان فضای خالی مخلوط های آسفالتی بر مقاومت آسفالت در برابر شیار افتادگی نیز تاثیر اساسی دارد. در گزارش تحقیق انجام شده در FHWA آمریکا، (FHWA-HRT-21-044) کاریگان و اندروود [Corrigan and Underwood, 2021]، شاخص RSI را برای ارزیابی میزان مقاومت مخلوط های آسفالتی در برابر شیار افتادگی، با استفاده از آزمایش SSR که با دستگاه AMPT انجام می شود طراحی کردند. آنها این شاخص را برای انواع دانه بندی ها و انواع گرید های قیر و نیز سطوح مختلف ترافیکی، تعیین کرده و نیز حدود لازم شاخص RSI را برای طراحی و ساخت مخلوط های آسفالتی ارائه کردند. آنها نشان دادند که برای مخلوط آسفالتی با یک دانه بندی مشخص، با افزایش مقدار قیر و کاهش V_a ، شاخص RSI افزایش یافته و شیار شدگی بیشتری در آسفالت ایجاد می شود.

پیش‌بینی فضای خالی مخلوط‌های آسفالتی در جاده‌های تحت سرویس با استفاده از شبکه‌های عصبی مصنوعی

اساس آزمایش‌های عملکرد روسازی شکل می‌گیرند. توابع انتقال برای پیش‌بینی شیار افتادگی و پیش‌بینی ترک‌های خستگی پوست سوسماری بر اساس آزمایش مدول دینامیکی ارائه شده است. و تابع انتقال برای پیش‌بینی ترک‌های عرضی حرارتی بر اساس آزمایش‌های کریپ کمپلینس و مقاومت کششی غیر مستقیم آسفالت شکل گرفته است. در سطح ۱ طراحی مکانیستیک-تجربی، برای انجام طراحی، ابتدا آزمایش‌های مدول دینامیکی، کریپ کمپلینس و مقاومت کششی غیر مستقیم روی نمونه‌های مخلوط‌های آسفالتی انجام می‌شوند. و سپس به کمک توابع انتقال، خرابی‌های روسازی در طول دوره طرح، پیش‌بینی می‌شوند [MEPDG 2025]. از آنجاییکه که پارامتر V_a ، بر مدول دینامیکی، کریپ کمپلینس و مقاومت کششی غیر مستقیم آسفالت تاثیر اساسی دارد، این پارامتر بر عملکرد آسفالت نیز نقش اساسی دارد.

در تحقیق دیگری فخری و محمودنیا با ساخت نمونه‌های مخلوط آسفالتی درشت دانه ۰-۳۷/۵ میلی‌متر، با درصد‌های مختلف قیر و V_a های مختلف، نشان دادند که با افزایش درصد قیر و کاهش V_a ، میزان شیار افتادگی افزایش می‌یابد [فخری و محمودنیا ۱۳۹۰].

در روش مکانیستیک-تجربی (M-E) که جدیدترین روش طراحی روسازی‌های آسفالتی می‌باشد نیز، V_a از پارامترهای اساسی طراحی و ارزیابی رفتار روسازی محسوب می‌شود [MEPDG 2025]. در روش M-E، خرابی‌های روسازی در دوره طراحی، شامل شیار افتادگی، ترک‌های خستگی، ترک‌های عرضی حرارتی و شاخص کیفی روسازی توسط توابع انتقال پیش‌بینی می‌شوند (شکل ۱) و اگر هر کدام از این خرابی‌ها از میزان مجاز در دوره طرح، بیشتر شوند، طرح آسفالت باید تغییر یابد تا زمانیکه خرابی‌های مورد نظر به میزان مجاز یا کمتر کاهش یابد [MEPDG 2025]. توابع انتقال طراحی روسازی بر



شکل ۱. فرآیند کلی روش طراحی مکانیستیک-تجربی برای طراحی روسازی انعطاف پذیر

کششی غیر مستقیم و کریپ کمپلینس آسفالت به کمک روابط ۱، ۲ و ۳ به شرح زیر تخمین زده می‌شوند. همانطور که در این روابط مشاهده می‌شود، پارامتر V_a در هر سه مقدار، نقش اساسی دارد [MEPDG 2025]. در طراحی M-E، مدول دینامیکی

از آنجاییکه تجهیزات انجام این آزمایشها از جمله دستگاه UTM و ژیراتوری کمپکتور گران قیمت هستند. در سطح ۲ طراحی M-E، در صورتیکه امکان انجام بعضی از این آزمایش‌ها وجود نداشته باشد، پارامترهای مدول دینامیکی آسفالت، مقاومت

آسفالت E^* ، به کمک رابطه ۱ تخمین زده می شود

: [MEPDG 2025]

$$\log E^* = -1.249937 + 0.02932 \rho_{200} - 0.001767 (\rho_{200})^2 - 0.002841 (\rho_4) - 0.058097 V_a - 0.802208 \left(\frac{V_{beff}}{V_{beff} + V_a} \right) + \frac{3.871977 - 0.0021 \rho_4 + 0.003958 \rho_{38} - 0.000017 (\rho_{38})^2 + 0.005470 \rho_{34}}{1 + e^{(-0.603313 - 0.313351 \log(f) - 0.3935321 \log(\eta))}} \quad (1)$$

که در رابطه ۳، t زمان بارگذاری بر حسب ثانیه و m و D_1

که در رابطه ۱:

پارامترهای شکست هستند و باید توجه داشت که حداکثر مقدار

E^* = مدول دینامیکی آسفالت، 10^5 پوند بر اینچ مربع

m باید به مقدار ۰/۱ محدود شود و عبارتند از:

η = ویسکوزیته آسفالت، 10^6 پواز

$$\log D_1 = -8.5241 + 0.01306T + 0.7975 \log V_a + 2.0103 \log VFA - 1.923 \log A_{RTFO} \quad (4)$$

f = فرکانس بارگذاری، هرترز

V_{beff} = قیر موثر، %

V_a = فضای خالی آسفالت، %

$$m = 1.1628 - 0.00185T - 0.04596V_a - 0.01126VFA + 0.00247Pen_{77} + 0.001683Pen_{77}^{0.4605T} \quad (5)$$

ρ_{34} = درصد تجمعی مصالح سنگی مانده روی الک ۳/۴ اینچ

ρ_{38} = درصد تجمعی مصالح سنگی مانده روی الک ۳/۸ اینچ

ρ_4 = درصد تجمعی مصالح سنگی مانده روی الک شماره ۴

ρ_{200} = درصد تجمعی مصالح سنگی مانده روی الک شماره

۲۰۰

$$Pen_{77} = 10^{290.5013 - \sqrt{81177.288 + 257.0694 \times 10^{(A+2.72973V)}}} \quad (6)$$

در طراحی M-E، مقاومت کششی آسفالت S_t ، که با استفاده

از رگرسیون با ۳۱ داده، با دقت $R^2 = 0/61$ بدست آمده، به

کمک رابطه ۲ تخمین زده می شود [MEPDG 2025]:

$$S_t(psi) = 7416.712 - 114.016 V_a - 122.592 VFA + 0.704 VFA^2 + 405.711 \log(Pen 77) - 2039.296 \log(A) \quad (2)$$

که در رابطه ۲:

V_a = فضای خالی آسفالت، %

Pen_{77} = درجه نفوذ قیر در ۷۷ درجه فارنهایت یا ۲۵ درجه

سانتیگراد می باشد.

A = برابر با عرض از مبدا نمودار ویسکوزیته - دمای قیر بعد

از آزمایش RTFO می باشد.

و کریپ کمپلینس آسفالت با رابطه ۳ تخمین زده می شود

: [MEPDG 2025]، که دقت آن $R^2 = 0/89$ است:

$$D(t) = D_1 \times t^m \quad (3)$$

T = دمای آزمایش که ۰، ۱۰ و ۲۰ - سانتیگراد می باشد.

V_a = فضای خالی آسفالت، %

VTS = شیب منحنی ویسکوزیته - دمای قیر

بنابراین با توجه به اینکه V_a ، تاثیر مسقیم بر عملکرد آسفالت می

گذارد، پیش بینی تغییرات V_a در طول زمان در جاده های تحت

ترافیک، یکی از نیازهای اساسی در عملکرد آسفالت می باشد.

از سوی دیگر در سالهای اخیر، تکنیکهای هوش مصنوعی بدلیل

توانمندی آنها در مدلسازی مورد توجه محققین قرار گرفته اند

[Izadi et. al 2023], [Heidaripناه and Hassani ASCE 2021]

[Mirbaha et. al 2018].

شبکه های عصبی مصنوعی (ANNs)، از جمله تکنیکهای

هوش مصنوعی هستند که به دلیل دارا بودن قابلیت پردازش

موازی و نگاشت در فضای n بعدی، قابلیت مدلسازی پدیده

های پیچیده را دارا بوده [Hagan et. al 2014] و با گذر

زمان بیشتر و بیشتر مورد توجه محققین در زمینه های مختلف

از جمله مهندسی عمران و راهسازی قرار گرفته اند

فصلنامه مهندسی حمل و نقل / سال هفدهم / شماره دوم (۶۷) / زمستان ۱۴۰۴

[Heidaripناه and Hassani Materials & Structures 2021]

در این تحقیق، اولین مدل برای پیش‌بینی فضای خالی مخلوط‌های آسفالتی در جاده‌های تحت سرویس، با دقت بالا، با استفاده از شبکه‌های عصبی مصنوعی ارائه شده است. برای ساخت و ارزیابی مدل، از داده‌های پروژه LTPP که پروژه ارزیابی رفتار روسازیها در دراز مدت در آمریکا می‌باشد، استفاده شده است [LTPP 2025].

۲. مدل‌سازی V_a با شبکه عصبی مصنوعی

۱-۲ تعیین ساختار مدل

در این تحقیق برای ارائه مدل پیش‌بینی V_a ، از شبکه‌های عصبی مصنوعی پیشرو، با تکنیک آموزش LMBP استفاده شده است. الگوریتم LMBP در واقع یک روش دینامیک و پیشرفته است که سرعت آموزش تکنیک گوس نیوتن را با تضمین همگرایی روش Steepest Decent یا SD همراه می‌کند [Hagan et. al 2014].

مقدار V_a برای طرح مخلوط آسفالتی گرم حدود ۳٪ تا ۶٪ می‌باشد. مقدار V_a برای طرح آسفالت‌های متخلخل حداقل ۲۰٪ می‌باشد. مقدار V_a برای آسفالت اجرا شده حدود ۳٪ تا ۵٪ از مقدار V_a طرح بیشتر است. مقدار V_a آسفالت اجرا شده، در اثر عبور ترافیک، خصوصاً در هوای گرم، به مرور زمان کاهش می‌یابد و به حدود مقدار V_a طرح می‌رسد. برای پیش‌بینی V_a بعد از گذشت مدت t ماه از زمان ساخت، فضای خالی اولیه مخلوط آسفالتی در زمان اجرای آسفالت V_a original بر حسب درصد، زمان سپری شده از اجرای آسفالت (t) بر حسب ماه، ترافیک عبوری از زمان اجرای آسفالت بر حسب EAL، ویسکوزیته قیر مورد استفاده (Viscosity) بر حسب پواز و درجه حرارت متوسط روزانه (MAAT) بر حسب فارنهایت، بعنوان عوامل موثر بر تغییرات فضای خالی مخلوط آسفالتی V_a و در نتیجه ورودیهای شبکه در نظر گرفته شده‌اند. بنابراین شبکه دارای ۵ نرون در لایه ورودی می‌باشد. خروجی شبکه نیز فضای

خالی آسفالت پس از گذشت زمان t ماه از اجرای آسفالت می‌باشد، بنابراین یک نرون هم در لایه خروجی وجود دارد. نتایج بدست آمده نشان می‌دهد که استفاده از ۱۰ نرون در لایه پنهان برای حصول دقت لازم برای شبیه‌سازی داده‌ها کافی بوده و استفاده از نرونهای بیشتر تاثیر خاصی بر دقت پیش‌بینی مدل ندارد. برای لایه پنهان از تابع انتقال تانژانت سیگموئید و برای لایه خروجی از تابع انتقال خطی استفاده شده است. ورودیها و خروجی شبکه و دامنه تغییرات آنها در جدول ۱ و ساختار شبکه در شکل ۲ نشان داده شده است. برای مدل‌سازی از داده‌های پروژه LTPP استفاده شده است [LTPP 2025] و بدین منظور ۱۶۱ سری داده از آسفالت‌های مقاطع مختلف LTPP استخراج و مورد استفاده قرار گرفته‌اند.

در الگوریتم انتشار به عقب LMBP، در ابتدا وزنها و بایاسهای شبکه که در واقع پارامترهای آموزش برای تولید مدل هستند بصورت تصادفی مقدار دهی اولیه می‌شوند. سپس با شروع فرایند آموزش در هر سیکل آموزش، مقادیر بردارهای ورودی $V_{a in}$ به شبکه ارائه شده و بردار خروجیهای نظیر آنها $V_{a p}$ توسط شبکه پیش‌بینی می‌شود. سپس شاخص خطا MSE به کمک رابطه ۷ با مقایسه مقادیر واقعی فضای خالی مخلوط‌های آسفالتی $V_{a m}$ ، با مقادیر پیش‌بینی شده توسط شبکه $V_{a p}$ ، محاسبه می‌شود.

$$MSE = \frac{\sum_{i=1}^n (V_{a m} - V_{a p})^2}{n} \quad (7)$$

که در رابطه ۷:

$$MSE = \text{میانگین مجذور خطا}$$

$$V_{a m} = \text{مقادیر واقعی یا اندازه‌گیری شده } V_a$$

$$V_{a p} = \text{مقادیر پیش‌بینی شده } V_a \text{ توسط مدل ANN}$$

$$n = \text{تعداد داده‌ها}$$


در الگوریتم آموزش LMBP با استفاده از سیستم ترکیبی گوس-نیوتن و SD، در هر سیکل آموزش با پس انتشار خطا، وزن‌ها و بایاس‌ها بگونه‌ای تغییر می‌کنند که MSE کاهش یابد. باید توجه داشت که هدف از آموزش کاهش MSE تا جای

از آموزش بیش از حد مدل، با فرایند ارزیابی تغییرات MSE برای داده های Validation با تنظیم پارامتر Max fail صورت می پذیرد.

ممکن نمی باشد. چون کاهش بیش از حد MSE باعث آموزش بیش از حد شبکه یا Overfitting شده و در اینحالت دقت شبیه سازی شبکه برای داده های جدید یا تست که از آنها در آموزش شبکه استفاده نشده است، بسیار پایین می آید. جلوگیری

جدول ۱. ورودی ها و خروجی شبکه و دامنه تغییرات آنها

پارامتر	توضیح	حداقل	حداکثر
V_a original	فضای خالی مخلوط آسفالتی در زمان ساخت (%)	۴/۷	۲۰/۷
t	زمان سپری شده از ساخت (ماه)	۰	۲۲۸
Traffic	ترافیک عبوری از زمان ساخت EAL	۰	$۳/۲۹۱۰^۷$
Viscosity	ویسکوزیته قیر مورد استفاده (پواز)	۰/۱۲	۴/۱۳
MAAT	درجه حرارت متوسط سالانه هوا (فارنهایت)	۴۲/۵	۶۹/۵
V_a	فضای خالی مخلوط آسفالتی پس از گذشت زمان t (%)	۲/۶	۲۰/۴



شکل ۲. ساختار مدل شبکه عصبی مصنوعی

جدول ۲. مقادیر پیش فرض نرم افزار MATLAB برای پارامترهای تنظیم آموزش شبکه ها

مدل	مقادیر پیش فرض پارامترهای آموزش شبکه در نرم افزار MATLAB				
	mu (initial)	mu-inc	mu-dec	mu-max	Max fail
	۰/۰۰۱	۱۰	۰/۰۱	$۱۰e۱۰$	۶

ANN10-1 مدل ۲-۲ در این تحقیق، اولین مدل ساخته شده مدل ANN10-1 می باشد که برای آموزش آن از تکنیک LMBP استفاده شده است. مقادیر پیش فرض پارامترهای آموزش تکنیک LMBP شامل mu،

۲-۲ مدل ANN10-1

که برای آموزش آن از تکنیک LMBP استفاده شده است. مقادیر پیش فرض پارامترهای آموزش تکنیک LMBP شامل mu،

پیش‌بینی فضای خالی مخلوط‌های آسفالتی در جاده‌های تحت سرویس با استفاده از شبکه‌های عصبی مصنوعی

گاه مقدار μ کاهش یابد، الگوریتم آموزش LMBP به تکنیک عددی گوس-نیوتن نزدیک شده و در نتیجه سرعت آموزش افزایش می‌یابد و برعکس آن، هرگاه مقدار μ افزایش یابد، الگوریتم LMBP به تکنیک عددی SD نزدیک شده و در نتیجه سرعت آموزش شبکه کاهش می‌یابد.

1 از مقادیر پیش فرض تکنیک LMBP استفاده شده است. پارامتر $\max\ fail$ برای تعیین اکثر تعداد دفعاتی که فرایند آموزش بر اساس داده‌های ارزیابی آموزش به حداکثر دقت خود می‌رسد و توقف آموزش شبکه بر اساس آن جهت جلوگیری از آموزش بیش از حد بکار می‌رود. در فرایند آموزش شبکه، هر

جدول ۳. پارامترهای تنظیم آموزش و مشخصات مدل شبکه عصبی ANN10-1

مشخصات مدل ANN10-1		پارامترهای تنظیم آموزش شبکه					
مدل	تعداد نرون‌های لایه پنهان	تابع انتقال	Mu (initial)	mu-inc	mu-dec	mu-max	Max fail
ANN10-1	۱۰	Tansig-Purlin	۰/۰۰۱	۱۰	۰/۰۱	۱۰e۱۰	۶

ANN10-1 در هشتمین سیکل آموزش با $MSE = ۰/۶۱۹۱۲$ بدست آمده است. روند تغییرات پارامترهای آموزش در حین آموزش برای مدل ANN10-1 نیز در شکل ۴ ارائه شده است. همانطور که در شکل ۴ دیده می‌شود، تنظیم $\max\ fail$ برابر با ۶ بدین معنی است که در هنگام آموزش، اگر خطای (MSE) شبیه سازی Validation در ۶ سیکل متوالی افزایش یافت، الگوریتم LMBP برای جلوگیری از آموزش بیش از اندازه، آموزش شبکه را متوقف کرده و پارامترهای آموزش شبکه (وزنها و بایاسها) را در ۶ سیکل قبل که MSE شروع به افزایش کرده است را به عنوان پارامترهای نهایی و مدل آموزش یافته انتخاب می‌کند. همانطور که در شکل ۴ مشاهده می‌شود، MSE برای داده‌های Validation از سیکل ۸ در ۶ سیکل متوالی تا سیکل ۱۴ افزایش یافته است. بنابراین الگوریتم LMBP آموزش شبکه را در سیکل ۱۴ متوقف کرده و شبکه آموزش دیده در ۶ سیکل قبل که سیکل ۸ ام می‌باشد را بعنوان مدل بهینه انتخاب کرده است. در شکل ۳ هم مشاهده می‌شود که سیکل ۸ ام آموزش، بعنوان سیکل بهینه توسط الگوریتم LMBP انتخاب شده و وزنهای و بایاسهای شبکه در سیکل ۸ برای مدل ANN10-1 انتخاب شده‌اند.

۱-۲-۲ آموزش و ارزیابی دقت مدل ANN10-1

از ۱۶۱ سری داده، بصورت تصادفی، ۸۰٪ از داده‌ها برای آموزش مدل، ۱۰٪ برای ارزیابی روند آموزش توسط الگوریتم آموزش بگونه‌ای که زمانیکه مدل به حداکثر دقت خود دست می‌یابد روند آموزش متوقف شود و مدل آموزش بیش از اندازه پیدا نکند. و ۱۰٪ از داده‌ها برای ارزیابی دقت شبیه سازی مدل برای داده‌های جدید، مورد استفاده قرار گرفته‌اند.

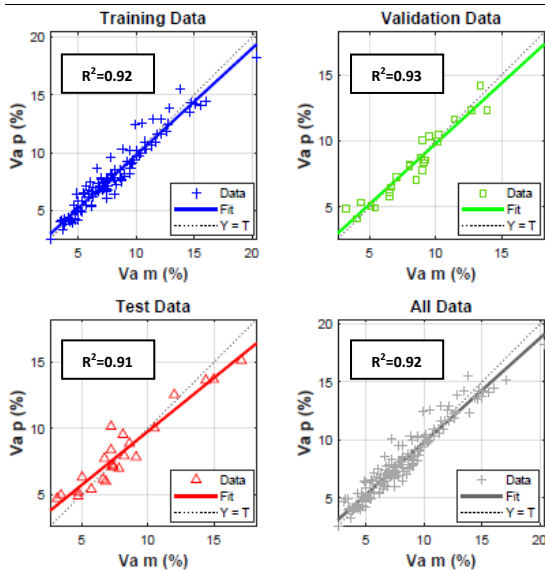
با چندین بار مقدار دهی اولیه وزن‌ها و آموزش مدل، مشاهده شد که سرعت آموزش شبکه ANN10-1 زیاد بوده و روند آموزش آن در زمان نزدیک به صفر ثانیه، با رسیدن به $\max\ fail =$ سریعا متوقف می‌شود و در نتیجه برای دستیابی به توان شبیه سازی بالا باید فرایند مقدار دهی اولیه به وزن‌ها و آموزش شبکه تکرار شود تا مدلی با دقت شبیه سازی بالا ایجاد شود. بنابراین آموزش مدل با داده‌های این تحقیق دشوار می‌باشد.

روند آموزش شبکه برای مدل ANN10-1 در شکل ۳ نشان داده شده است. در شکل ۳، نمودار آبی نشان‌دهنده تغییرات MSE برای دقت شبیه سازی داده‌های آموزش در حین فرایند آموزش مدل است. نمودار سبز نشان‌دهنده تغییرات MSE برای دقت شبیه سازی داده‌های ارزیابی آموزش (Validation) و نمودار قرمز نشان‌دهنده تغییرات MSE برای داده‌های تست، در حین سیکل‌های آموزش می‌باشند. همانطور که در شکل ۳ مشاهده می‌شود بیشترین توان شبیه سازی برای مدل

پس از آموزش های متعدد با مقدار دهی متفاوت برای وزنه های اولیه، نهایتاً مدل ANN10-1 به دقت خوب $R^2 = 0.91$ برای شبیه سازی داده های تست دست پیدا کرده است (جدول ۵). دقت شبیه سازی مدل ANN10-1 برای دسته های مختلف داده ها در شکل ۵ و جدول ۵ ارائه شده است.

جدول ۵. دقت مدل ANN10-1 برای داده های مختلف

دقت شبیه سازی مدل ANN10-1				
ضریب	دقت شبیه سازی مدل ANN10-1			
تست	همه	ارزیابی آموزش	آموزش	درونیابی
R^2	۰/۹۲	۰/۹۳	۰/۹۲	۰/۹۱



شکل ۵. نمودار های دقت شبیه سازی مدل ANN10-1


جدول ۶. پارامتر های تنظیم آموزش و مشخصات مدل ANN10-2

مشخصات مدل ANN10-2		پارامتر های تنظیم آموزش شبکه					
مدل	تعداد نرونها لایه پنهان	تابع انتقال	Mu (initial)	mu-inc	mu-dec	mu-max	Max fail
ANN10-2	۱۰	Tansig-Purlin	$1e-20$	۲	۰/۰۰۱	$1e10$	۶


پارامترهای $mu-inc$ از ۱۰ به ۲ و $mu-dec$ از ۰/۰۱ به ۰/۰۰۱ کاهش داده شده است.

جدول ۳-۲-۱ آموزش و ارزیابی دقت مدل ANN10-2

پس از چندین بار وزن دهی اولیه به مدل ANN10-2 و آموزش آن، مشخص شد که سرعت آموزش مدل ANN10-2 نسبت به مدل ANN10-1 کاهش یافته است و قابلیت مدل برای دستیابی به توان شبیه سازی بالاتر، در هر بار وزن دهی اولیه و فصلنامه مهندسی حمل و نقل / سال هفدهم / شماره دوم (۶۷) / زمستان ۱۴۰۴



شکل ۳. روند آموزش شبکه ANN10-1



شکل ۴. تغییرات پارامتر های آموزش برای آموزش مدل ANN10-1

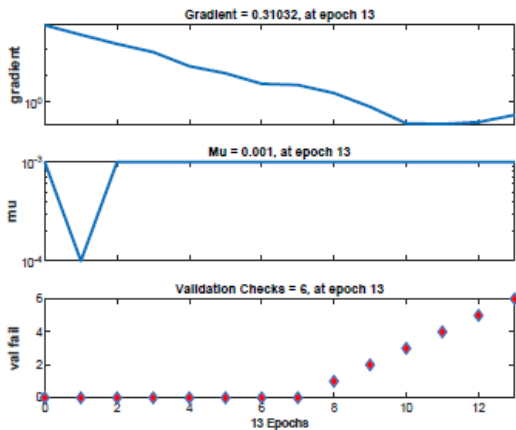
جدول ۴. نتایج آموزش شبکه ANN10-1

مدل	سایکل های آموزش	زمان (ثانیه)	MSE
ANN10-1	۱۴	۰	۰/۶۱۹۱۲

جدول ۳-۲-۳ مدل ANN10-2

برای کاهش سرعت آموزش جهت امکان دستیابی به توان شبیه سازی بالاتر، مدل ANN10-2 با پارامتر های آموزشی جدول ۶ طراحی شده است. بدین منظور همانطور که در جدولهای ۳ برای مدل ANN10-1 و ۶ برای مدل ANN10-2 دیده می شود برای ساخت مدل ANN10-2، مقدار اولیه پارامتر mu از ۰/۰۰۱ به $1e-20$ کاهش یافته است. همچنین مقدار

پیش‌بینی فضای خالی مخلوط‌های آسفالتی در جاده‌های تحت سرویس با استفاده از شبکه‌های عصبی مصنوعی



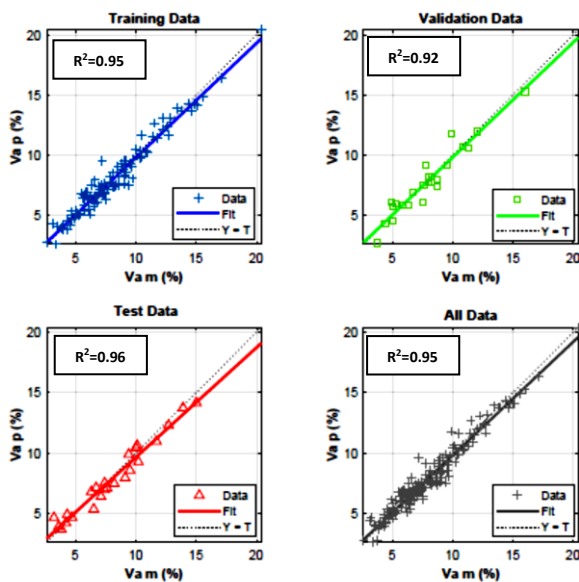
شکل ۷. تغییرات پارامترهای آموزش برای آموزش مدل

ANN10-2

جدول ۷. نتایج آموزش شبکه ANN10-2

مدل	سیکل‌های آموزش	زمان (ثانیه)	MSE
ANN10-2	۱۳	۲	۰/۶۱۸۶۱


پس از چندین بار آموزش، نهایتاً مدل ANN10-2 به دقت بسیار خوب $R^2 = 0/96$ دست پیدا می‌کند. دقت شبیه‌سازی مدل ANN10-2 برای دسته‌های مختلف داده‌ها در شکل ۸ و جدول ۸ ارائه شده است.



شکل ۸. نمودارهای دقت شبیه‌سازی مدل ANN10-2 برای

داده‌های مختلف

آموزش افزایش یافته است. روند آموزش مدل ANN10-2 در شکل ۶ نشان داده شده است. همانطور که در شکل ۶ مشاهده می‌شود بیشترین توان شبیه‌سازی برای مدل ANN10-2 در ۷امین سیکل آموزش در $MSE = 0/61861$ بدست آمده است. تغییرات پارامترهای آموزش در حین آموزش، برای مدل ANN10-2 نیز در شکل ۷ ارائه شده است. برای جلوگیری از آموزش بیش از حد، پارامتر Max fail برابر با ۶ انتخاب شده است. همانطور که در شکل ۷ مشاهده می‌شود، MSE برای داده‌های Validation از سیکل ۷ در ۶ سیکل متوالی تا سیکل ۱۳ افزایش یافته است. بنابراین الگوریتم LMBP آموزش شبکه را در سیکل ۱۳ متوقف کرده و شبکه آموزش دیده در ۶ سیکل قبل که سیکل ۷ام می‌باشد را بعنوان مدل بهینه انتخاب کرده است. در شکل ۶ هم مشاهده می‌شود که سیکل ۷ام آموزش بعنوان سیکل بهینه توسط الگوریتم LMBP انتخاب شده و وزن‌های و بایاس‌های شبکه در سیکل ۷ برای مدل ANN10-2 انتخاب شده‌اند.



شکل ۶. روند آموزش شبکه ANN10-2

ساخته شده است. همانطور که در جدولهای ۹ برای مدل ANN10-3 و ۶ برای مدل ANN10-2 دیده می شود برای مدل ANN10-3، مقدار اولیه پارامتر μ همان 20×10^{-1} و μ -dec همان 0.001 در نظر گرفته شده است و مقدار پارامتر μ -inc از ۲ به $1/1$ کاهش یافته است.

جدول ۸. دقت شبیه سازی مدل ANN10-2 برای داده های مختلف

ضریب	دقت شبیه سازی مدل ANN10-2			
	آموزش	ارزیابی	همه	تست
R^2	۰/۹۵	۰/۹۲	۰/۹۵	۰/۹۶


۲-۴ مدل ANN10-3

مدل ANN10-3 برای داشتن سرعت آموزش کمتر از مدل ANN10-2 با پارامترهای آموزش که در جدول ۹ ارائه شده

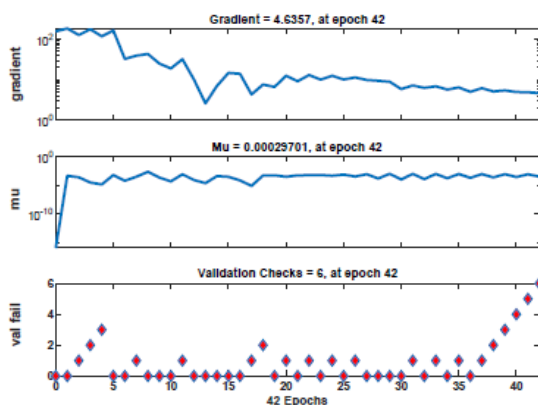
جدول ۹. پارامترهای تنظیم آموزش و مشخصات مدل ANN10-3

مشخصات مدل ANN10-3			پارامترهای تنظیم آموزش شبکه				
مدل	تعداد نرونهاي لایه پنهان	تابع انتقال	Mu (initial)	mu-inc	mu-dec	mu-max	Max fail
ANN10-3	۱۰	Tansig-Purlin	$1e-20$	۱,۱	۰,۰۰۱	۱۰e۱۰	۶

انتخاب شده و وزنهای و بایاسهای شبکه در سیکل ۳۶ برای مدل ANN10-3 انتخاب شده اند.



شکل ۹. روند آموزش شبکه ANN10-3



شکل ۱۰. تغییرات پارامترهای آموزش برای آموزش مدل

ANN10-3

۲-۴-۱ آموزش و ارزیابی دقت مدل ANN10-3

پس از چندین بار وزن دهی اولیه و آموزش مدل ANN10-3، مشخص شد که سرعت آموزش مدل ANN10-3 نسبت به مدل ANN10-2 کاهش یافته است و قابلیت مدل برای دستیابی به توان شبیه سازی بالاتر در هر بار وزن دهی اولیه و آموزش شبکه، نیز افزایش یافته است. روند آموزش مدل ANN10-3 در شکل ۹ نشان داده شده است. همانطور که در شکل ۹ مشاهده می شود بیشترین توان شبیه سازی برای مدل ANN10-3 در ۳۶ امین سیکل آموزش در $MSE = 0.36582$ بدست آمده است. تغییرات پارامترهای آموزش در حین آموزش برای مدل ANN10-3 نیز در شکل ۱۰ ارائه شده است. برای جلوگیری از آموزش بیش از حد، پارامتر Max fail برابر با ۶ انتخاب شده است. همانطور که در شکل ۱۰ مشاهده می شود، MSE برای داده های Validation از سیکل ۳۶ در ۶ سیکل متوالی تا سیکل ۴۲ افزایش یافته است. بنابراین الگوریتم LMBP آموزش شبکه را در سیکل ۴۲ متوقف کرده و شبکه آموزش دیده در ۶ سیکل قبل که سیکل ۳۶ ام می باشد را بعنوان مدل بهینه انتخاب کرده است. در شکل ۹ هم مشاهده می شود که سیکل ۳۶ ام آموزش بعنوان سیکل بهینه توسط الگوریتم LMBP

پیش‌بینی فضای خالی مخلوط‌های آسفالتی در جاده‌های تحت سرویس با استفاده از شبکه‌های عصبی مصنوعی

خروجی آن از تابع انتقال خطی استفاده شده است. برای آموزش و نیز تست مدل، از ۱۶۱ سری داده از آسفالت‌های مقاطع مختلف پروژه LTPP استفاده شده است. برای مدل‌سازی، داده‌ها به صورت تصادفی به ۳ گروه آموزش، ارزیابی آموزش و تست تقسیم می‌شوند. در هر بار فرایند آموزش مدل، بصورت تصادفی، ۸۰٪ از داده‌ها برای آموزش شبکه، ۱۰٪ برای ارزیابی فرایند آموزش و ۱۰٪ برای تست مدل مورد استفاده قرار گرفته‌اند.

همچنین برای دست‌یابی به دقت شبیه‌سازی بالاتر، با ساخت مدل‌های مختلف، تغییرات پارامترهای تکنیک LMBP در آموزش مدل مورد بررسی قرار گرفته و نتایج زیر حاصل شده است:

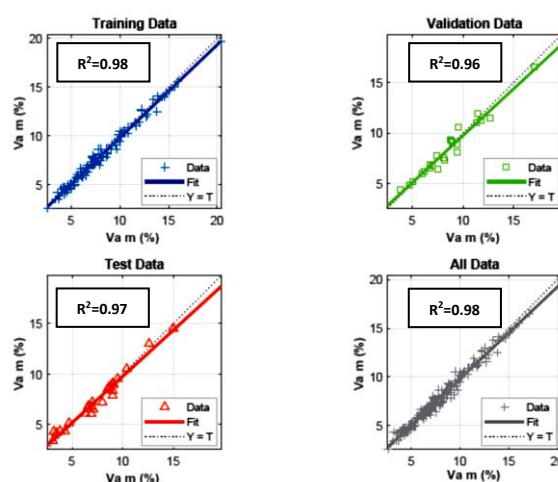
۱- اولین مدل ساخته شده، مدل ANN10-1 می‌باشد که برای آموزش آن از مقادیر پیش‌فرض پارامترهای تکنیک LMBP شامل $\mu = 0.001$ ، $\mu\text{-inc} = 10$ و $\mu\text{-dec} = 0.001$ استفاده شده است. نتایج بدست آمده نشان می‌دهد که برای این مطالعه، پس از چندین بار مقدار دهی وزنه‌های اولیه و آموزش، مدل ANN10-1 توانسته است به دقت خوب $R^2 = 0.91$ در هشتمین سیکل آموزش با $MSE = 0.61912$ و در زمان نزدیک به صفر ثانیه دست پیدا کند. اما از آنجاییکه سرعت آموزش با این پارامترها بسیار زیاد است، دستیابی به این دقت، مستلزم تعداد زیادی وزن دهی اولیه و آموزش مدل می‌باشد. بنابراین مدل‌های ANN10-2 و ANN10-3 با سرعت آموزش کمتر ساخته شده و مورد ارزیابی قرار گرفته‌اند.

۲- دومین مدل ساخته شده مدل ANN10-2 می‌باشد که برای ساخت آن و کاهش سرعت آموزش، مقدار اولیه پارامتر μ از 0.001 به $20 \times e^{-1}$ کاهش یافته است. همچنین مقدار پارامترهای $\mu\text{-inc}$ از ۱۰ به ۲ و $\mu\text{-dec}$ از 0.001 به 0.001 کاهش داده شده است. نتایج بدست آمده نشان می‌دهد که کاهش سرعت آموزش، این امکان را برای مدل

جدول ۱۰. نتایج آموزش شبکه ANN10-3

MSE	زمان (ثانیه)	سیکل‌های آموزش	مدل
۰/۳۶۵۶۲	۶۰	۳۶	ANN10-3

دقت شبیه‌سازی مدل ANN10-3 برای داده‌های مختلف در شکل ۱۱ و جدول ۱۲ ارائه شده است. همانطور که در جدول ۱۱ دیده می‌شود، نهایتاً دقت مدل ANN10-3 برای شبیه‌سازی داده‌های تست، به مقدار بسیار خوب $R^2 = 0.97$ افزایش یافته است.



شکل ۱۱. نمودارهای دقت شبیه‌سازی مدل ANN10-3 برای داده‌های مختلف

جدول ۱۱. دقت شبیه‌سازی مدل ANN10-3 برای داده‌های مختلف

دقت شبیه‌سازی مدل ANN10-3				
ضریب	تست			
درونیابی	آموزش	ارزیابی آموزش	همه	تست
R^2	۰,۹۸	۰,۹۶	۰,۹۸	۰,۹۷

۳. نتیجه‌گیری

در این تحقیق برای پیش‌بینی تغییرات فضای خالی مخلوط آسفالتی در جاده‌های تحت ترافیک، مدل شبکه عصبی مصنوعی با دقت بالای $R^2 = 0.97$ ارائه شده است. بدین منظور از شبکه‌های عصبی مصنوعی پیشرو با تکنیک آموزش LMBP استفاده شده است. این مدل دارای ۱۰ نرون در لایه پنهان بوده و برای لایه پنهان آن از تابع انتقال تانژانت سیگموئید و برای لایه

– AASHTO M 323-22 (2022) “Standard Specification for Superpave Volumetric Mix Design”.

– MS-2 (2014) “Mix Design Methods for Asphalt Concrete and Other Hot-Mix Types”. 7th Edition, 2014.

– AASHTO (2025), “Mechanistic-Empirical Pavement Design Guide”. (MEPDG).

– Harvey J. T. and Tsai TB. W. (2025) “Effect of Asphalt content and Air Void Content on Mix fatigue and Stiffness”. Transportation Research Record, Journal of Transportation Research Board, 1996, Vo. 1543, No. 1, pp. 38-45. <https://doi.org/10.3141/1543-05>

– Zeiada W., Dabous S. A., Ruzouq R. A., Hamed Kh, Souliman M. I., Mirou Sh. (2022) “Effect of air voids and asphalt content changes on laboratory and simulated long-term fatigue performance of asphalt concrete pavements”. Springer, Journal of Innovative Infrastructure Solutions, Vol. 8, No. 1. DOI: 10.1007/s41062-022-01023-3

– FHWA-HRT-21-044 (2021), Corrigan M. and Underwood Sh. “Rutting Strain Index (RSI) Parameter for Asphalt Performance Engineered Mixture Design”. DOI: <https://highways.dot.gov/research/publications/infrastructure/FHWA-HRT-21-044>

– Hagan M. T. , Demuth H. B., Beale M. H., De Jesús O. (2014) “Neural Network Design”. 2nd Edition, eBook.

– Heidaripناه A. and Hassani A. (2021), “Adaptive Neuro Fuzzy Inference System (ANFIS) approach to predict the dynamic modulus of Hot Mix Asphalt” ASCE, Journal of Transportation Engineering, Part B: Pavements, Vol 147, No. 3. DOI:

ANN10-2 فراهم می آورد که با تعداد کمتری وزن دهی اولیه و آموزش مجدد، به دقت های بالاتر دست پیدا کند. مدل ANN10-2 توانسته است در زمان ۲ ثانیه نهایتاً در هفتمین سیکل آموزش در $MSE = 0/61861$ به دقت بسیار خوب $R^2 = 0/96$ دست پیدا کند.

۳-مدل ANN10-3 برای کاهش بیشتر سرعت آموزش ساخته شده است. بدین منظور مقدار اولیه پارامتر μ همانند مدل ANN10-2 e^{-20} و μ -dec همان $0/001$ در نظر گرفته شده است و مقدار پارامتر μ -inc از 2 به $1/1$ کاهش یافته است. نتایج بدست آمده نشان می دهد که کاهش بیشتر سرعت آموزش مدل ANN10-3 موجب می شود که با تعداد کمتری وزن دهی اولیه و آموزش مجدد، توان دستیابی به دقت های بالاتر را پیدا کند. نهایتاً ANN10-3 در زمان 60 ثانیه به دقت بسیار خوب $R^2 = 0/97$ در 36 امین سیکل آموزش در $MSE = 0/36562$ دست پیدا کرده است.

۴. پی نوشت ها

1. ANNs: Artificial Neural Networks
2. LMBP: Levenberg-Marquardt Back Propagation
3. LTPP: Long Term Pavement Performance
4. SD: Steepest Decent
5. MEPDG: Mechanistic Empirical Pavement Design Guide
6. RSI: Rutting Strain Index
7. SSR test: Stress Sweep Rutting test
8. AMPT: Asphalt Mixture Performance Tester
9. M-E: Mechanistic-Empirical

۵. مراجع

– فخری م. و محمودی نیا ن. (۱۳۹۰) ، “ارزیابی مقاومت شیارافتادگی مخلوط های آسفالتی گرم با مصالح سنگی درشت دانه ”، نشریه مهندسی عمران، دانشگاه فردوسی مشهد، دوره ۲۳، شماره ۱، صفحه ۱۲۳-۱۳۵.

<https://doi.org/10.1061/JPEODX.0000269>

– Izadi A., Jamshidpour F., Bargegol I. (2023) “Study of Urban Taxi-related Accident Analysis Using the Multiple Logistic Regression and Artificial Neural Network Models”. Vol. 10, No. 4, pp. 1163-1173. DOI: 10.22119/ijte.2022.292868.1578

– Mirbaha B., Kordani A.A., Salehikalam A., Zareyi M. (2018). “Analyzing Stop Time Phase Leading to Congestion Based on Drivers’ Behavior Patterns”. Vol. 5, No. 20, pp. 383-400, DOI: 10.22119/ijte.2018.49734

– Heidaripناه A. and Hassani A. (2021) “A fundamental multiple-stage ANN-based sensitivity analysis to predict the dynamic modulus of Hot Mix Asphalt considering the effect of confining stress”. Springer, Materials and Structures, Vol. 54, No. 15. DOI: 10.1617/s11527-020-01581-x

– LTPP Info pave (2025) “Long Term Pavement Performance Project”. FHWA, <https://infopave.fhwa.dot.gov/>