

پیش‌بینی مدول برجهندگی خاک‌های ریزدانه با استفاده از شبکه عصبی مصنوعی، ماشین بردار پشتیبان و سیستم استنتاج تطبیقی عصبی-فازی بهینه‌سازی شده با الگوریتم ازدحام ذرات

علیرضا غنی‌زاده، استادیار، دانشکده مهندسی عمران، دانشگاه صنعتی سیرجان، سیرجان، ایران

امیر توانا املشی، دانش آموخته کارشناسی ارشد، دانشکده مهندسی عمران، دانشگاه صنعتی سیرجان، سیرجان، ایران

E-mail: ghanizadeh@sirjantech.ac.ir

دريافت: ۱۳۹۵/۰۴/۳۱ پذيرش: ۱۳۹۶/۰۵/۰۴

چکیده

مدول برجهندگی خاک بستر ازجمله پارامترهای بسیار مهم در تحلیل و طراحی رو سازی است. این پارامتر هم در روش‌های تجربی (مانند اشتو ۱۹۹۳) و هم در روش‌های مکانیستیک-تجربی (مانند MEPDG) به عنوان اصلی ترین پارامتر برای بیان مقاومت و خصوصیات مکانیکی خاک بستر مورد استفاده قرار می‌گیرد. برای تعیین این پارامتر نیاز است تا آزمایش بارگذاری سه محوری دینامیک تحت تنش‌های محدود کننده و تنش‌های انحرافی مختلف بر روی خاک انجام شود که انجام این آزمایش‌ها بسیار وقت‌گیر و پرهزینه است. در این مقاله عملکرد سه روش ترکیبی هوش محاسباتی شامل شبکه عصبی مصنوعی بهینه‌سازی شده با الگوریتم ازدحام ذرات (ANN-PSO)، ماشین بردار پشتیبان بهینه‌سازی شده با الگوریتم ازدحام ذرات (SVM-PSO) و سیستم استنتاج تطبیقی عصبی-فازی بهینه‌سازی شده با الگوریتم ازدحام ذرات (ANFIS-PSO) به منظور پیش‌بینی مدول برجهندگی مصالح خاک بستر ریزدانه مورد ارزیابی قرار گرفته است و نتایج این سه روش با یکدیگر مقایسه شد. در کلیه این مدل‌ها درصد عبوری از الک نمره ۲۰۰، حد روانی، شاخص خمیری، درصد رطوبت بهینه، درصد رطوبت، درجه اشباع، مقاومت فشاری تک محوری، تنش محدود کننده و تنش انحرافی به عنوان ورودی و مدول برجهندگی به عنوان پارامتر خروجی در نظر گرفته شد. نتایج این تحقیق نشان می‌دهد که روش ANN-PSO با پیش‌بینی دقت را در پیش‌بینی مدول برجهندگی خاک‌های ریزدانه فراهم می‌سازد. ضریب رگرسیون حاصل از این روش برای مجموع کل داده‌ها برابر با ۰/۹۹۲ است و این روش در اکثر موارد مقدار مدول برجهندگی را با درصد خطای کمتر از ۲۰ درصد پیش‌بینی می‌کند. ضریب رگرسیون حاصل از دو روش ANFIS-PSO و SVM-PSO به ترتیب برابر با ۰/۹۸۱ و ۰/۹۵۱ است. نتایج این تحقیق همچنین نشان داد که درصد مصالح عبوری از الک نمره ۲۰۰ بیشترین تأثیر و پارامتر تنش انحرافی کمترین تأثیر را بر روی مدول برجهندگی مصالح خاکی ریزدانه دارند.

واژه‌های کلیدی: مدول برجهندگی، شبکه عصبی مصنوعی، ماشین بردار پشتیبان، سیستم استنتاج تطبیقی عصبی-فازی، الگوریتم ازدحام ذرات

۱. مقدمه

Ozsahin and Oruc, 2008; Maalouf et al. 2008; Hu, 2011; Kezhen et al. 2011; Maalouf et al. 2012; Pourtahmasb et al. 2015; Shafabakhsh and Tanakizadeh, 2015; Vadood et al. 2015 [Ghanizadeh and Rahrovan, 2016] رگرسیونی و آماری [Mohammad et al. 1999; Solanki et al. 2008]، مدل به دست آمده از آنالیز نظریه الاستیک چندلایه^۳ [Khazanovich et al. 2006]، مدل‌های ارائه شده با استفاده از شبکه‌های عصبی [Hanittinan, 2007; Park et al. 2009; Solanki et al. 2010; Zaman et al. 2013; Kim et al. 2014] توسعه یافته با استفاده از سایر روش‌های یادگیری ماشینی و تکاملی [Coleri et al. 2010; Nazzal and Tatari, 2013; Pal and Deswal, 2014; Sadrossadat et al. 2016]. از جمله مدل‌هایی به شمار می‌روند که صرفاً جهت پیش‌بینی مدول برجهندگی خاک بستر ساخته شده‌اند.

هانیتینان (۲۰۰۷)، از شبکه‌های عصبی مصنوعی^۴ جهت ساخت مدل پیش‌بینی مدول برجهندگی سه نمونه از خاک‌های ریزدانه ایالت اوهايو (A-7-6, A-6, A-4) استفاده نمود. درصد ذرات خاک عبوری از الک نمره ۲۰۰، شاخص خمیری، حد روانی، مقاومت فشاری تک محوری، درصد رطوبت بهینه، درصد رطوبت، درجه اشباع، تنش محدودکننده، تنش انحرافی به عنوان پارامترهای ورودی و مدول برجهندگی به عنوان خروجی مدل ساخته شده توسط او و همکارانش بودند، [Hanittinan, 2007]

پارک و همکاران (۲۰۰۹) نیز از شبکه‌های عصبی مصنوعی برای پیش‌بینی مدول برجهندگی خاک ریزدانه بستر استفاده کردند. آن‌ها با ساخت مدل‌های گوناگون میزان تأثیرگذاری متغیرهای ورودی مدل را مورد بررسی قرار دادند. نتایج نشان داد که مدل‌های ساخته شده توسط آن‌ها بیشترین میزان وابستگی را به پارامتر تنش انحرافی دارند [Park et al. 2009].

سولانکی و همکاران (۲۰۰۹) در همان سال مدل‌هایی را جهت پیش‌بینی مدول برجهندگی خاک بستر معمول در ایالت اوکلاهما آمریکا ارائه نمودند. آن‌ها از ۶۳ نمونه مختلف خاک بستر جمع‌آوری شده از ۱۴ سایت مختلف در سرتاسر اوکلاهما، به منظور ساخت دو مدل چندجمله‌ای و فاکتوریلی به عنوان مدل‌های رگرسیونی و دو مدل پرسپترون چندلایه^۵ و تابع شعاع مبنای^۶ به عنوان شبکه‌های عصبی مصنوعی استفاده نمودند. نتایج

مدول برجهندگی مصالح خاکی نشان‌دهنده مدول الاستیک خاک در سطوح مختلف تش است [Zaman et al. 2010]. این پارامتر به صورت نسبت تنش انحرافی اعمال شده به کرنش محوری برگشت‌پذیر تحت بار دینامیکی تعریف می‌شود [Witzczak et al. 1995]. مدول برجهندگی، باهدف تعیین مقادیر سختی مصالح در سطوح مختلف تش و توصیف رفتار غیرخطی تنش - کرنش خاک‌ها تحت بارگذاری‌های تکراری اندازه‌گیری می‌شود. این پارامتر یکی از پارامترهای مهم و کلیدی برای طراحی روسازی است. راهنمای طراحی روسازی اشتو در سال ۱۹۸۶ [AASHTO, 1986]، توصیه کرد که به منظور توصیف خاک بستر، از مدول برجهندگی استفاده شود. از زمان انتشار راهنمای اشتو در سال ۱۹۸۶، مدول برجهندگی به عنوان یکی از اساسی‌ترین مشخصه‌های توصیف مصالح در تحلیل‌های مکانیکی و طراحی سازه‌ای روسازی‌های انعطاف‌پذیر مورد استفاده قرار می‌گیرد [Zaman et al. 2010]. به علاوه در روشهای مکانیستیک-تجربی (مانند روش MEPDG^۷) نیز برای توصیف مشخصات خاک و مصالح سنگدانه‌ای از پارامتر مدول برجهندگی استفاده می‌شود [NCHRP, 2004]. مدول برجهندگی عمده‌تاً به صورت مستقیم در آزمایشگاه و با استفاده از آزمایش‌های سه محوری دینامیک، ستون تشیدی، برش پیچشی و روشهای ژیراتوری^۸ [George, 1992; Kim et al. 1992]، یا به‌طور غیرمستقیم از طریق همبستگی با نتایج سایر آزمایش‌های استاندارد و یا با انجام محاسبه معکوس تعیین می‌شود [George, 2004]. متداول‌ترین روش برای تعیین مدول برجهندگی خاک و مصالح سنگدانه‌ای در آزمایشگاه انجام آزمایش سه محوری دینامیک تحت اثر تنش‌های محدودکننده و تنش‌های انحرافی مختلف است. انجام آزمایش سه محوری دینامیک بسیار زمان‌بر و پرهزینه است و لذا ارائه روشهایی که بتوانند بدون نیاز به انجام این آزمایش پیچیده تخمین دقیقی از مدول برجهندگی به دست دهنده، بسیار مفید خواهد بود.

اگرچه تاکنون تحقیقات بسیاری جهت به دست آوردن مقدار مدول برجهندگی مصالح لایه‌های مختلف روسازی‌های آسفالتی انجام شده است [Tutumluer and Meier, 1996]

را جهت پیش‌بینی مدول برجهندگی خاک بستر به همراه دارد [Kim et al. 2014]

پال و دسوال (۲۰۱۴) با استفاده از ۸۹۱ داده‌ی حاصل از مطالعات آزمایشگاهی دانشگاه اوهایو و با در نظر گرفتن ۹ متغیر ورودی به ساخت مدلی بر اساس یادگیری ماشین شدید^۹ برای پیش‌بینی مدول برجهندگی خاک‌های ریزدانه پرداختند. تحقیقات آن‌ها نشان داد که تابع کرنل چندجمله‌ای دارای بیشترین دقت است. همچنین نتایج تحلیل حساسیت نشان داد که دو پارامتر تنش محدودکننده و تنش انحرافی بیشترین تأثیر را بر روی مدول برجهندگی خاک‌های ریزدانه دارد [Pal and Deswal, 2014]

سر انجام صدرا سادات و همکاران (۲۰۱۶) در یکی از جدید ترین تحقیقات با بهره گیری از همان ۸۹۱ داده‌ی حاصل از مطالعات آزمایشگاهی دانشگاه اوهایو اذعان داشتند که به خدمت گرفتن مدل قدرتمند و قابل اعتماد ساخته شده با استفاده از سیستم استنتاج تطبیقی عصبی-فازی می‌تواند در مسائل پیچیده و پر اهمیت مهندسی مفید واقع شود [Sadraossadat et al. 2016]

همان‌گونه که ملاحظه می‌شود، در تحقیقاتی که تاکنون به‌منظور پیش‌بینی مدول برجهندگی صالح خاکی انجام شده است، عمده‌تاً شاهد به کارگیری یک روش و عدم مقایسه روش‌های گوناگون با یکدیگر هستیم. همچنین در تعیین پارامترهای بینه مدل‌های توسعه داده شده از روش‌های بهینه‌سازی فرا ابتکاری و تکاملی استفاده نشده است. به علاوه بیشتر تحقیقات بر کاربرد روش شبکه عصبی مصنوعی در پیش‌بینی مدول برجهندگی خاک‌های ریزدانه متمرکز شده‌اند. لذا در این مقاله سه روش شبکه عصبی مصنوعی، ماشین بردار پشتیبان^{۱۰} و سیستم استنتاج تطبیقی عصبی-فازی^{۱۱} که به کمک الگوریتم ازدحام ذرات^{۱۲} بهینه‌سازی شده‌اند، برای پیش‌بینی مدول برجهندگی خاک‌های ریزدانه مورد استفاده قرار گرفته‌اند و دقت آن‌ها با توجه به داده‌های آموزش و آزمون با یکدیگر مقایسه گردیده است.

۲. معرفی روش‌ها و الگوریتم‌ها

اگرچه تاکنون روش‌های یادگیری ماشینی مختلفی به‌منظور پیش‌بینی مدول برجهندگی خاک بستر مورد بررسی قرار

نشان‌دهنده برتری مدل پرسپترون چندلایه نسبت به سایر مدل‌ها بود [Solanki et al. 2009]

در ادامه زمان و همکاران (۲۰۱۰) با جمع‌آوری ۹۷ داده‌ی مربوط به ۱۶ بخش مختلف در ایالت اوکلاهاما آمریکا و با در نظر گرفتن پارامترهایی مانند توزیع اندازه سنگ‌دانه‌ها، حدود اتربرگ، وزن مخصوص، رطوبت بهینه و مقاومت فشاری تک‌محوری به عنوان متغیرهای ورودی و مدول برجهندگی به عنوان پارامتر خروجی، چهار مدل شبکه عصبی مصنوعی پس‌خور شامل: شبکه خطی، شبکه عصبی رگرسیون عمومی، شبکه تابع شعاع مبنا و شبکه پرسپترون چندلایه را برای پیش‌بینی مدول برجهندگی خاک ارائه دادند. تحقیقات آن‌ها نیز نشان از برتری مدل پرسپترون چندلایه نسبت به سایر مدل‌ها داشت [Zaman et al. 2010].

سولانکی (۲۰۱۳) در تحقیق دیگر خود ۱۶۰ نمونه حاصل از چهار خاک تثبیت شده به‌وسیله افزودن مصالح سیمانی در ایالات اوکلاهاما را مورد بررسی قرار داد. او بار دیگر از شبکه تابع شعاع مبنا و شبکه پرسپترون چندلایه برای ساخت مدل‌های پیش‌بینی مدول برجهندگی خاک بستر استفاده کرد [Solanki, 2013]

ژانگ (۲۰۱۳) به منظور ساخت مدل پیشگو خود پس از جمع‌آوری ۱۳۵ داده مربوط مدول برجهندگی خاک بستر روسازی استان شان شی^۷ چین از شبکه عصبی مبتنی بر تابع شعاع مبنا استفاده نمود. نتایج مربوط به آنالیز حساسیت در تحقیق او حاکی از این بود که دو پارامتر درصد رطوبت و وزن مخصوص خشک، نقشی حیاتی را در پیش‌بینی مدول برجهندگی ایفا می‌کنند [Zhang, 2013]

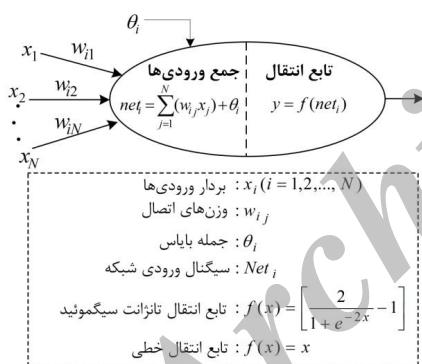
نزال و تاتاری (۲۰۱۳) از الگوریتم ژنتیک^۸ برای انتخاب متغیرهای ورودی شبکه عصبی مصنوعی استفاده کردند که این عمل افزایش دقت پیش‌بینی مدل‌های ارائه شده توسط آن‌ها به‌ویژه در مقایسه با مدل‌های رگرسیونی را به همراه داشت [Nazzal and Tatari, 2013]

کیم و همکاران (۲۰۱۴) با جمع‌آوری نتایج حاصل از آزمایش تعیین مدول برجهندگی از ۹ منبع مختلف در ایالت جورجیا با استفاده از شبکه‌های عصبی پس انتشار دریافتند که مدلی با معناری ۱۲-۹-۱، بهترین عملکرد یا کمترین میزان خطای

تعادل میان شناسایی راه حل‌ها و سرعت همگرایی آن‌ها در فرآیند بهینه‌سازی را برقرار می‌سازد. پس از محاسبه سرعت هر ذره، موقعیت آن مطابق با رابطه (۳) (بهروز خواهد شد. معمولاً برای از بین بردن نوسانات ناشی از سرعت‌های زیاد ذرات و دست‌یابی به شناسایی راه حل‌های بهتر، سرعت ذرات در طول فرآیند بهینه‌سازی محدود و تعدیل می‌شود.

۲-۲ شبکه عصبی مصنوعی

شبکه‌های عصبی مصنوعی (ANN) با الهام از ساختار مغز انسان و به عنوان یک ساختار ریاضی، بین مجموعه‌ای از اعداد ورودی و خروجی نگاشت برقرار می‌کنند [Haykin, 2001]. سلول‌های عصبی (نرون^۳) از اجزاء تشکیل‌دهنده‌ی شبکه‌های عصبی مصنوعی به شمار می‌آیند. نرون‌ها شامل مجموعه‌ای از ورودی و خروجی‌ها و تعداد زیادی گره یا واحد پردازشگر موسوم به تابع انتقال می‌باشند. شکل ۱، ساختار یک نرون و توابع انتقال را به صورت شماتیک نشان می‌دهد:



شکل ۱. ساختار یک نرون از شبکه عصبی مصنوعی.

مجموعه‌ای از نرون‌های موازی، یک لایه را تشکیل می‌دهند. هر شبکه عصبی مصنوعی می‌تواند برای تولید خروجی‌ها خود از چندین لایه تشکیل شود که شامل لایه‌های پنهان و لایه خروجی خواهد شد و این لایه‌ها به صورت سری به یکدیگر متصل می‌شوند.

هر ورودی در شبکه عصبی دارای وزن متناظر با خود بوده که با تأثیرپذیری از آن و باهدف اعمال پردازش و تولید ورودی‌های لایه‌های بعدی وارد تابع انتقال خواهد شد. تاکنون با توجه به نوع توابع انتقال لایه‌های تشکیل‌دهنده‌ی شبکه و نحوه‌ی تأثیرگذاری وزن‌ها بر ورودی‌ها، انواع مختلفی از

گرفته‌اند اما همچنان نمی‌توان گفت بهترین عملکرد متعلق به کدام روش است؛ زیرا عملکرد هر روش بسته به عوامل مختلفی مانند تعداد و محدود تغییرات مجموعه داده‌ها و سایر پارامترها قابل تغییر است. در این تحقیق از سه روش شبکه عصبی مصنوعی، ماشین بردار پشتیبان و سیستم استنتاج تطبیقی عصبی-فازی بهینه‌سازی شده با الگوریتم ازدحام ذرات به منظور پیش‌بینی مدول برجهندگی خاک بستر استفاده شده است و در پایان نتایج این سه روش با یکدیگر مقایسه گردیده است. در ادامه اصول نظری و روابط ریاضی مربوط به روش‌های به کاررفته در این تحقیق بیان خواهند شد.

۱-۲ بهینه‌سازی ازدحام ذرات

بهینه‌سازی ازدحام ذرات (PSO)، یک روش بهینه‌سازی فرا ابتکاری است که با ایجاد تصادفی مجموعه‌ای از ذرات یا راه حل‌ها در فضای جستجو، آغاز شده و سپس به جستجوی بهینه‌ترین حالت با استفاده از بهروزرسانی مکرر ذرات (نسل‌ها) می‌پردازد [Eberhart and Kennedy, 1995; Kennedy, 1995; Shi and Eberhart, 1998] روش که از حرکت دسته‌جمعی پرندگان الهام گرفته شده است، به علت بازدهی بالا در حل مسائل بهینه‌سازی پیچیده، هزینه‌بر و بعض‌اً غیرممکن، از شهرت بسیاری برخوردار است.

رفتار ذرات در روش فوق الذکر را می‌توان به زبان ریاضی و به شکل زیر بیان کرد:

$$\begin{aligned} v_i(t+1) &= w(t)v_i(t) + \varphi_1(t)(pbest_i(t) - \\ &x_i(t)) + \varphi_2(t)(gbest(t) - x_i(t)). \end{aligned} \quad (1)$$

$$\varphi_1(t) = c_1 r_1, \quad \varphi_2(t) = c_2 r_2(t). \quad (2)$$

$$x_i(t+1) = x_i(t) + v_i(t+1). \quad (3)$$

که $(t)_i x$ نشان‌دهنده‌ی بردار موقعیت ذره i ام در زمان t و $v_i(t)$ نشان‌دهنده‌ی بردار سرعت مرتبه با آن ذره است. $pbest_i$ بهترین موقعیت پیشین شناخته شده برای ذره i ام و $gbest$ بهترین موقعیت جمعی شناخته شده برای مجموع ذرات یا بهترین موقعیت شناخته شده همسایه‌های هر ذره است. c_1 و c_2 پارامترهای شتاب و r_1 و r_2 اعداد تصادفی ایجاد شده در بازه‌ی 0 تا 1 در هر تکرار هستند. علاوه بر این ضریب اینرسی w نشان‌دهنده‌ی مقدار جابجایی هر ذره بوده و

بهینه‌سازی فرا ابتکاری است. در این روش‌ها پارامترهای وزن و بایاس شبکه عصبی مصنوعی به کمک الگوریتم‌های بهینه‌سازی و به‌گونه‌ای تعیین می‌شوند که جذر میانگین مربعات خطا حاصل از مقادیر مشاهده شده و مقادیر پیش‌بینی شده با استفاده از شبکه عصبی مصنوعی حداقل گردد. در این تحقیق به‌منظور تعیین مقادیر بهینه پارامترهای وزن و بایاس شبکه عصبی مصنوعی از الگوریتم بهینه‌سازی از دحام ذرات بهره‌گیری شده است. روند آموزش شبکه عصبی مصنوعی با استفاده از الگوریتم بهینه‌سازی از دحام ذرات در شکل (۳) نشان داده شده است. به‌منظور انجام این فرایند یک برنامه کامپیوتی در محیط MATLAB توسعه داده شد.

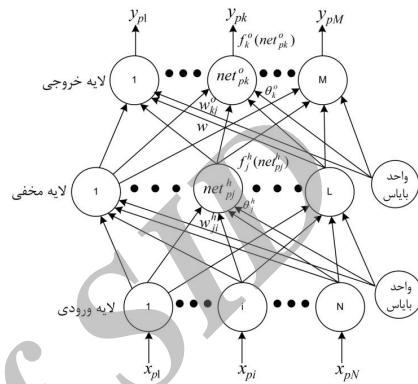
۳-۲ ماشین بردار پشتیبان

نظریه‌ی ماشین بردار پشتیبان (SVM) بر اساس نظریه یادگیری آماری و پنیک توسعه یافته است [Vapnik et al. 1997; Vapnik and Vapnik, 1998]. این روش می‌تواند در زمینه‌های طبقه‌بندی و رگرسیون مورد استفاده قرار گیرد. برای کمینه کردن خطای مدل در روش ماشین بردار پشتیبان، از کمینه‌سازی ریسک ساختاری استفاده گردیده است. در حالی که سایر روش‌ها مانند شبکه‌های عصبی مصنوعی از اصول کمینه‌سازی ریسک تجربی بهره می‌برند [Dibike et al. 2001].

ماشین بردار پشتیبان، تابع رگرسیون را با به کارگیری یک دسته تابع خطی تخمین می‌زند. در این تابع، انحراف مقادیر پیش‌بینی شده از مقادیر واقعی به میزان ϵ مجاز است و درنهایت بهترین جواب به کمک اصول کمینه‌سازی ریسک ساختاری بر روی ریسک اندازه‌گیری شده توسط تابع تلفات مورداستفاده، به دست می‌آید [Samui, 2008].

این روش نسبت به دیگر روش‌های محاسبات نرم چندین مزیت دارد که عبارت‌اند از: (۱) به کارگیری مجموعه‌ای از معادلات کرنل با فضای بزرگ ابعادی که شامل تبدیل غیرخطی می‌باشد، (۲) این روش یک راه حل منحصر به فرد برای مسئله بهینه‌سازی با توجه به ماهیت همگرایی آن است. فرض کنید که x_i بردار فضای داده‌های ورودی، d_i مقدار خروجی موردنظر و n

شبکه‌های عصبی مصنوعی معرفی شده است. یکی از انواع مختلف شبکه‌های عصبی مصنوعی در رابطه با حل مسائلی که نیاز به شناسایی الگوها و ایجاد توابع نگاشت پیچیده دارند، شبکه‌های عصبی پس خور با انتشار برگشتی^۱ است که در شکل ۲ نمایش داده شده است [Freeman and Skapura, 1992].



شکل ۲. معماری شبکه عصبی مصنوعی پس خور با انتشار برگشتی دارای یک لایه پنهان.

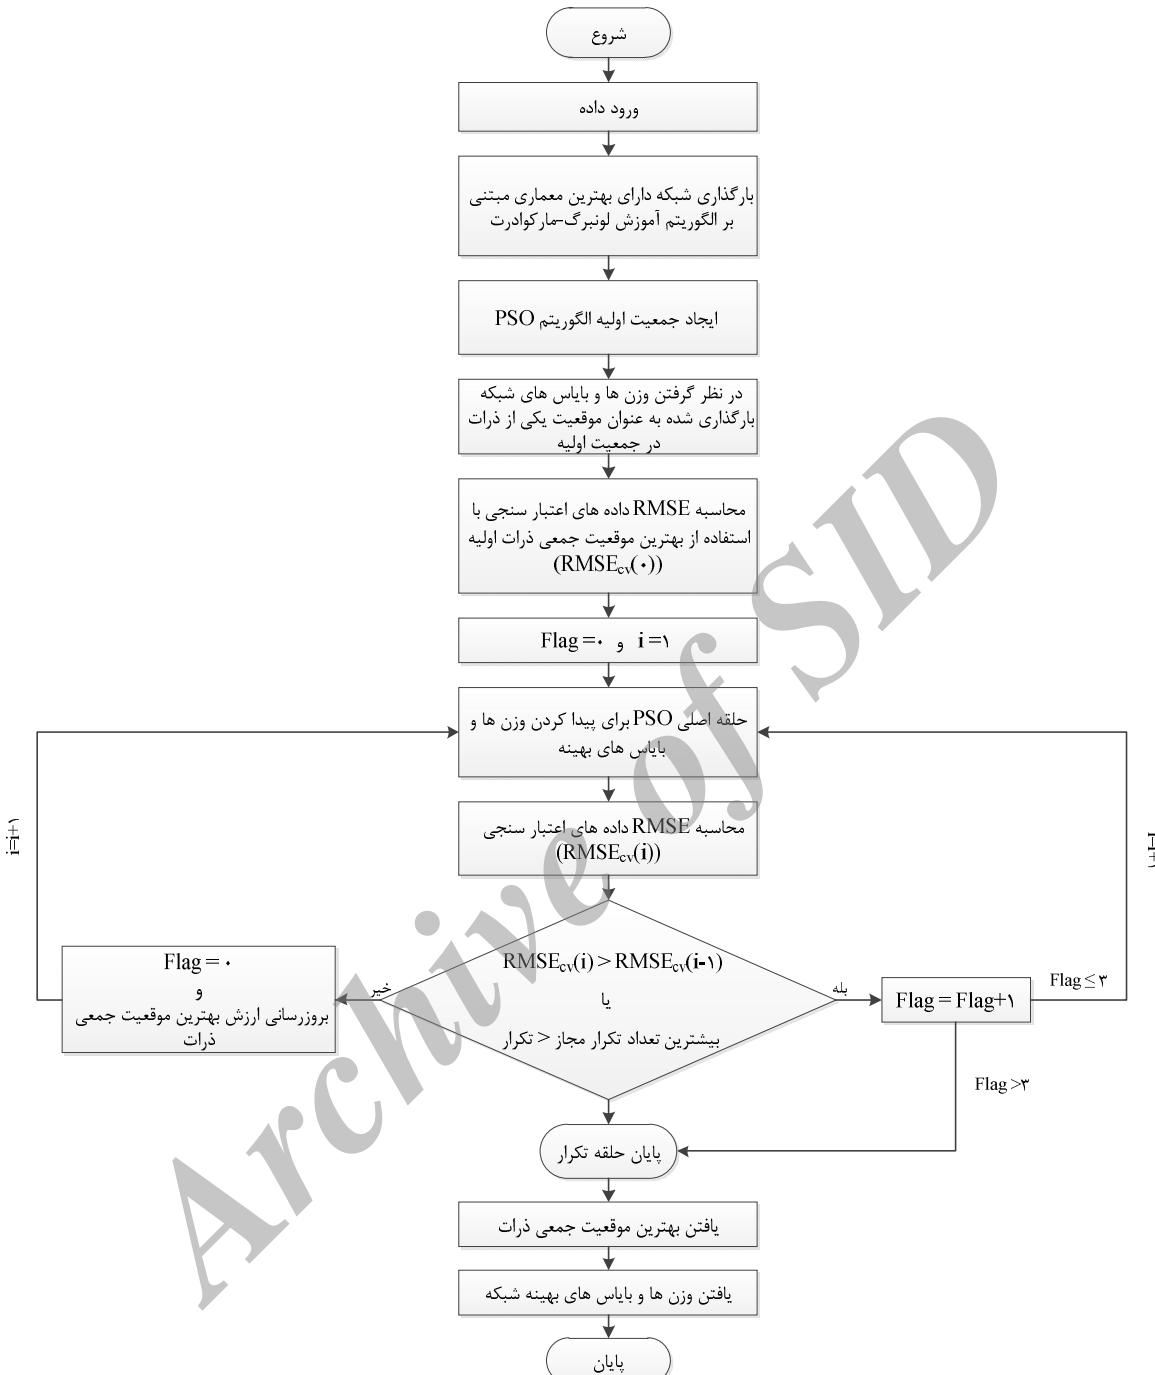
آموزش شبکه‌های عصبی پس خور با استفاده از الگوریتم انتشار برگشتی دارای دو مرحله اصلی است [Werbos, 1974; Rumelhart et al. 1986]

۱. در فاز اول که فاز روبه‌جلو نامیده می‌شود، بردار ورودی به شبکه اعمال شده و تأثیرات آن از طریق لایه پنهان به لایه خروجی منتشر می‌شود و بردار خروجی ارائه شده در لایه خروجی پاسخ واقعی شبکه را تشکیل می‌دهد. در این مسیر پارامترهای شبکه، ثابت و بدون تغییر در نظر گرفته می‌شود.

۲. در فاز دوم که فاز برگشتی یا رو به عقب نامیده می‌شود، پارامترهای شبکه تغییر پیدا کرده و تنظیم خواهد شد. این تنظیم بر اساس قانون اصلاح خطای صورت می‌گیرد و سیگنال خطای در لایه خروجی شبکه تشکیل می‌شود.

شبکه‌ها با همگرایی پاسخ‌های آن‌ها با مقادیر متناصر واقعی، حالت آموزش دیده پیدا خواهند کرد و انتظار می‌رود تا در صورت ورود داده‌های دارای تنوع و تعداد مطلوب، پاسخ‌های پیش‌بینی شده توسط شبکه با مقادیر واقعی متناصر خود کمترین میزان اختلاف ممکن را داشته باشند. یکی دیگر از روش‌های نوین برای آموزش شبکه عصبی مصنوعی استفاده از روش‌های

پیش‌بینی مدول برجهندگی خاک‌های ریزدانه با استفاده از شبکه عصبی....



شکل ۳. روند آموزش شبکه عصبی مصنوعی با استفاده از الگوریتم بهینه‌سازی ازدحام ذرات.

تعداد داده‌ها را نشان می‌دهد. ماشین بردار پشتیبان رابطه میان

داده‌ها را به صورت زیر تخمین می‌زنند:

در این روابط، $\phi(x)$ نشان‌دهنده مشخصه‌های با

فضای بزرگ ابعادی است که بردار فضای مربوط به ورودی x را در حالتی که w و b به ترتیب بردارهای اسکالر و نرمال باشند، تصویر می‌کند.

$$f(x) = w\phi(x) - b. \quad (4)$$

$$R_{SVM}(C) = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n L(x_i, d_i). \quad (5)$$

$K(x, x_i)$ در این معادله از رابطه‌ی $K(x, x_i) = \varphi(x_i)\varphi(x_j)$ به دست خواهد آمد. (۱۴) تابع کرnel نامیده می‌شود که وابسته به دو بردار داخلی x_i و x_j است که به ترتیب در فضای مشخصه $(x_i\varphi)$ و $(x_j\varphi)$ قرار می‌گیرند.

مهم‌ترین توابع کرnel عبارت‌اند از تابع سیگموئید، خطی، چندجمله‌ای و تابع RBF در این تحقیق از تابع RBF به عنوان کرnel استفاده شده است. شکل کرnel RBF به صورت زیر است..

$$K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2). \quad (8)$$

که در آن x_i و x_j بردارها در فضای ورودی (بردار مشخصه محاسبه شده از آموزش و یا آزمون) است. علاوه بر این، دقت پیش‌بینی رگرسیون ماشین بردار پشتیبان با استفاده از کرnel RBF بستگی به انتخاب سه پارامتر γ ، ϵ و C دارد. به‌منظور تعیین پذیری مناسب روش ماشین بردار پشتیبان، مقادیر این سه پارامتر باید به درستی انتخاب شود. در این تحقیق به‌منظور تعیین بهینه‌ترین مقدار برای این پارامترها از الگوریتم ازدحام ذرات استفاده شده است. روند تعیین مقادیر بهینه γ ، ϵ و C با استفاده از الگوریتم ازدحام ذرات در شکل ۴ نشان داده شده است

همچنین $C \frac{1}{n} \sum_{i=1}^n L(x_i, d_i)$ برای در نظر گرفتن ریسک خطای تجربی در نظر گرفته شده است.

w و b از کمینه‌سازی یک معادله‌ی ریسک مشخص به دست خواهد آمد که این معادله با معرفی متغیرهای مثبت (ξ_i و ξ_i^*) به آن، میزان خطای بیش از حد بالا یا پایین را نشان می‌دهد. رگرسیون ماشین بردار پشتیبان سعی می‌کند تابعی از w و b برای هر i و y_i بیابد که اندازه w را کمینه کند و با یک انحراف کمتر از ϵ ، داده‌ها را بازش نماید. مورد اخیر

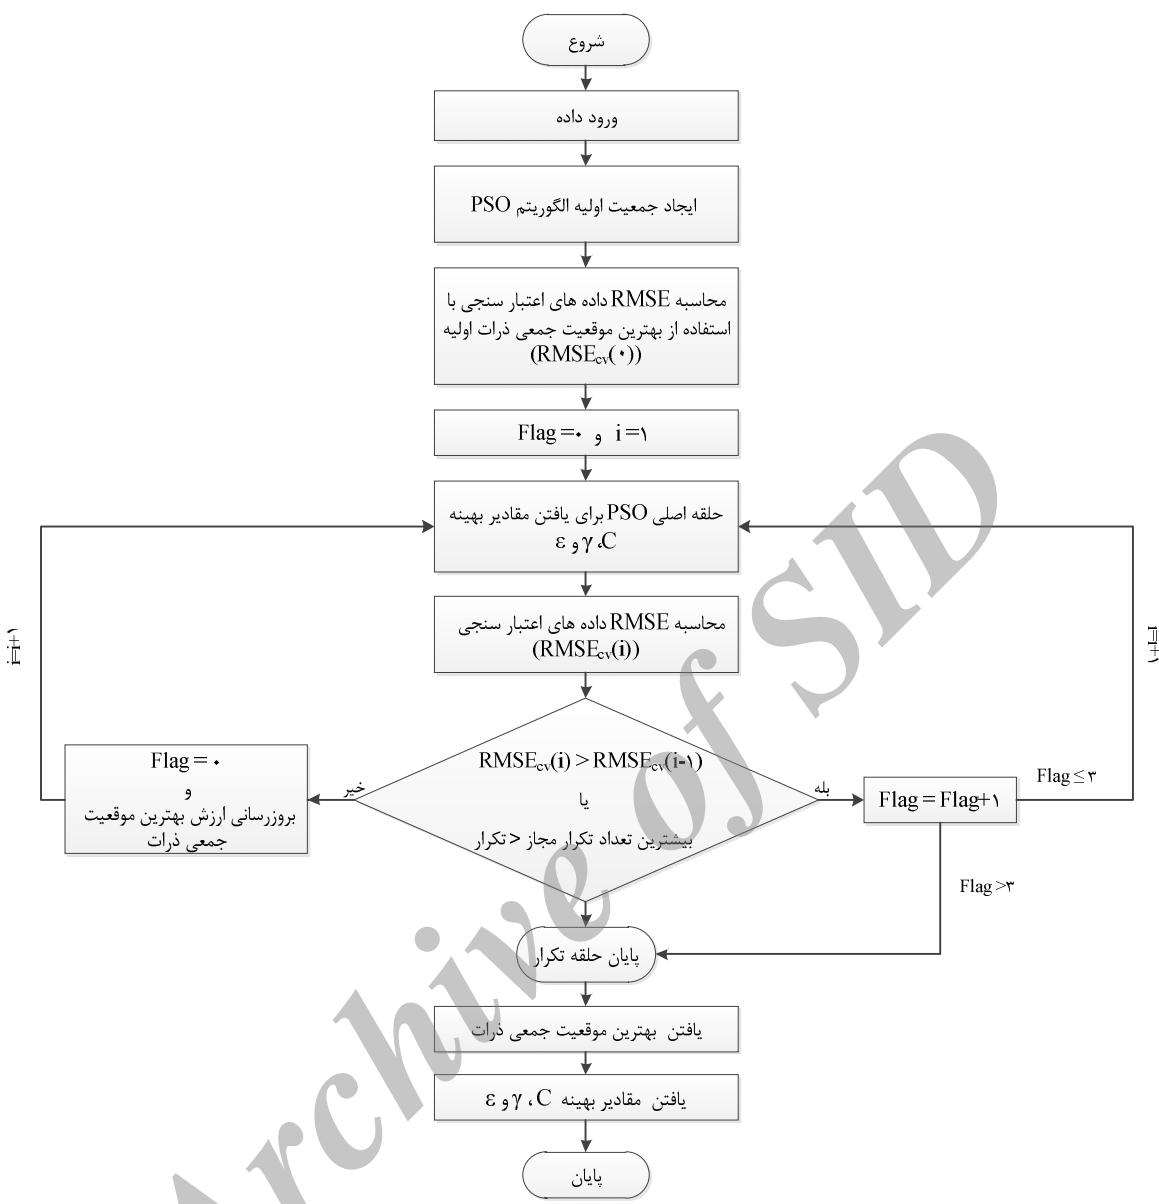
شامل حل مسئله بهینه‌سازی زیر می‌شود:

$$\text{Minimize } R_{\text{SVMs}}(w, \xi^{(*)}) = \frac{1}{2} \|w\|^2 + C \frac{1}{n} \sum_{i=1}^n L(\xi_i, \xi_i^*). \quad (6)$$

$$\text{Subject to} \begin{cases} d_i = w\varphi(x_i) + b_i \leq \epsilon + \xi_i \\ w\varphi(x_i) + b_i - d_i \leq \epsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0, i = 1, \dots, n \end{cases}$$

که در آن $\frac{1}{2} \|w\|^2$ ، جزء تنظیمی معادله، C پارامتر جریمه خطای جهت ایجاد تعادل میان ریسک تجربی و جزء تنظیمی ϵ حد مجاز خطای i نشان‌دهنده‌ی تعداد داده‌های آموزش است. می‌توان از قیود بهینگی و ضرایب لاغرانژ برای حل رابطه (۶) استفاده نمود که درنتیجه معادله زیر به دست می‌آید:

$$f(x, a, a_i^*) = \sum_{i=1}^n (a_i - a_i^*) K(x, x_i) + b. \quad (7)$$



شکل ۴. روند تعیین پارامترهای بهینه ماشین بردار پشتیبان با استفاده از الگوریتم ازدحام ذرات.

جملات آگر-آنگاه^{۱۶} بر اساس مدل درجه اول سوگنو^{۱۷} [Takagi and Sugeno, 1985] می‌شوند. داشتن روشی که با استفاده از آن بتوان اطلاعات موجود برای ساخت این قواعد را استفاده کرد به عنوان ابزاری کارآمد به شمار می‌رود. از طرفی، شبکه‌های عصبی مصنوعی به دلیل قابلیت‌های آموزش پذیری با استفاده از الگوهای مختلف آموزشی می‌توانند ارتباط مناسبی بین متغیرهای ورودی و خروجی ایجاد نمایند. لذا استفاده ترکیبی از سیستم استابتاط فازی و شبکه عصبی مصنوعی به عنوان ابزاری قدرتمند که قابلیت پیش‌بینی نتایج با استفاده از داده‌های عددی موجود را

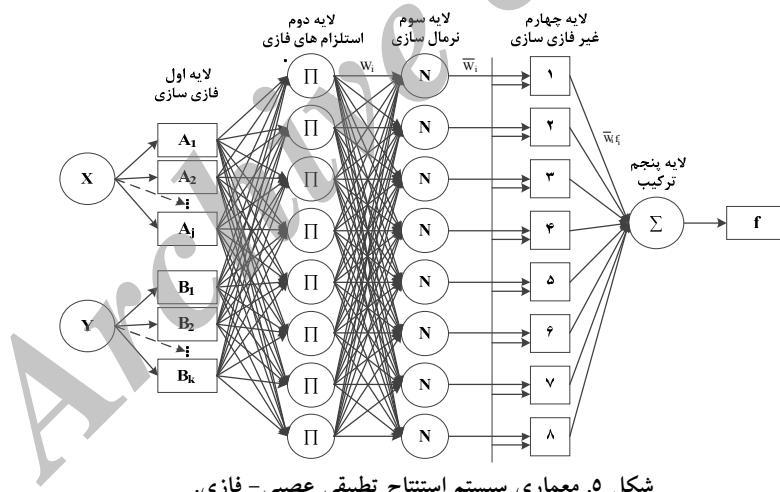
۴- سیستم استتابج تطبیقی عصبی - فازی

سیستم استتابج تطبیقی عصبی - فازی (ANFIS) که نخستین بار توسط جانگ معرفی شد [Jang, 1993] دارای ویژگی‌هایی از جمله توانایی پیاده‌سازی دانش بشری با استفاده از مفاهیم برجسب‌های زبانی و قواعد فازی، غیرخطی بودن، قابلیت سازش‌پذیری این سیستم‌ها و دقت بهتر آن‌ها در مقایسه با سایر روش‌ها در شرایط محدودیت داده‌ها است. نکته مهم منطق فازی امکان برقراری ارتباط بین فضای ورودی به فضای خروجی است و سازوکار اولیه برای انجام این کار فهرستی از

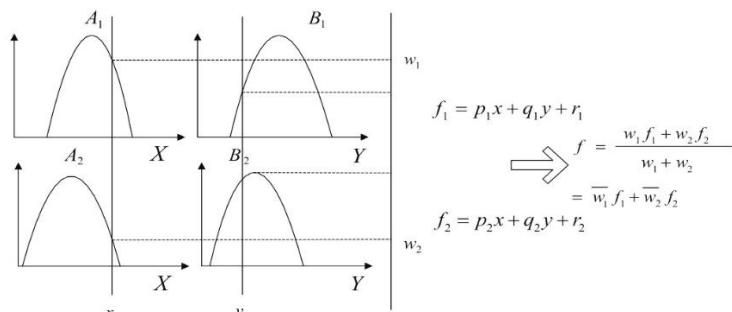
(\bar{w}_i) انجام می‌گیرد. لایه چهارم لایه قوانین است که انجام عملیات بر روی پیام‌های ورودی به این لایه حاصل می‌شود $(\bar{w}_i f_i)$. لایه آخر خروجی (f) است که هدف آن حداقل نمودن اختلاف خروجی به دست آمده از شبکه و خروجی حقیقی است.

در مرحله آموزش، با اصلاح پارامترهای درجه عضویت بر اساس میزان خطای قابل قبول، مقادیر ورودی به مقادیر حقیقی نزدیک‌تر می‌شوند. روش آموزش اصلی در این سامانه، روش پس انتشار خطای است. در این روش با استفاده از الگوریتم شبیه نزولی خطای، مقدار خطای به سمت ورودی‌ها پخش می‌گردد و پارامترهای تصحیح می‌شوند. در این تحقیق برای دستیابی به پارامترهای بهینه توابع عضویت، از الگوریتم بهینه‌سازی ازدحام ذرات استفاده گردید. روند تعیین پارامترهای بهینه توابع عضویت سیستم استنتاج تطبیقی عصبی-فازی با استفاده از الگوریتم ازدحام ذرات در شکل (۷) نشان داده شده است

دارند، تحت عنوان سیستم استنتاج تطبیقی عصبی-فازی معرفی می‌شود. لذا این سیستم از الگوریتم‌های شبکه عصبی و منطق فازی به منظور طراحی نگاشت غیرخطی بین فضای ورودی و خروجی استفاده می‌کند. سیستم استنتاج تطبیقی عصبی-فازی شبکه ۵ لایه‌ای، متشکل از گره‌ها و کمان‌های اتصال‌دهنده گره‌ها است. ساختار مناسب سیستم عصبی-فازی متناسب با داده‌های ورودی، درجه عضویت، قوانین و توابع درجه عضویت خروجی انتخاب می‌شود. شکل ۵ نمایشی از معماری شبکه عصبی-فازی با دو ورودی، یک خروجی است. در لایه اول (ورودی) میزان تعلق هر ورودی به بازه‌های مختلف فازی توسط کاربر مشخص می‌شود. در این لایه همه گره‌ها، گره تطبیقی به همراه تابع گره (مانند تابع گوسی در این مقاله) هستند. سازوکار تابع عضویت گوسی^{۱۸} در مدل فازی درجه اول تاکاگی-سوگنو^{۱۹} با دو قانون و دو پارامتر ورودی به صورت شماتیک در شکل ۶ نشان داده شده است. با ضرب مقادیر ورودی به هر گره در یکدیگر، وزن قانون‌ها (w_i) در لایه دوم به دست می‌آید. در لایه سوم عمل محاسبه وزن نسبی قوانین

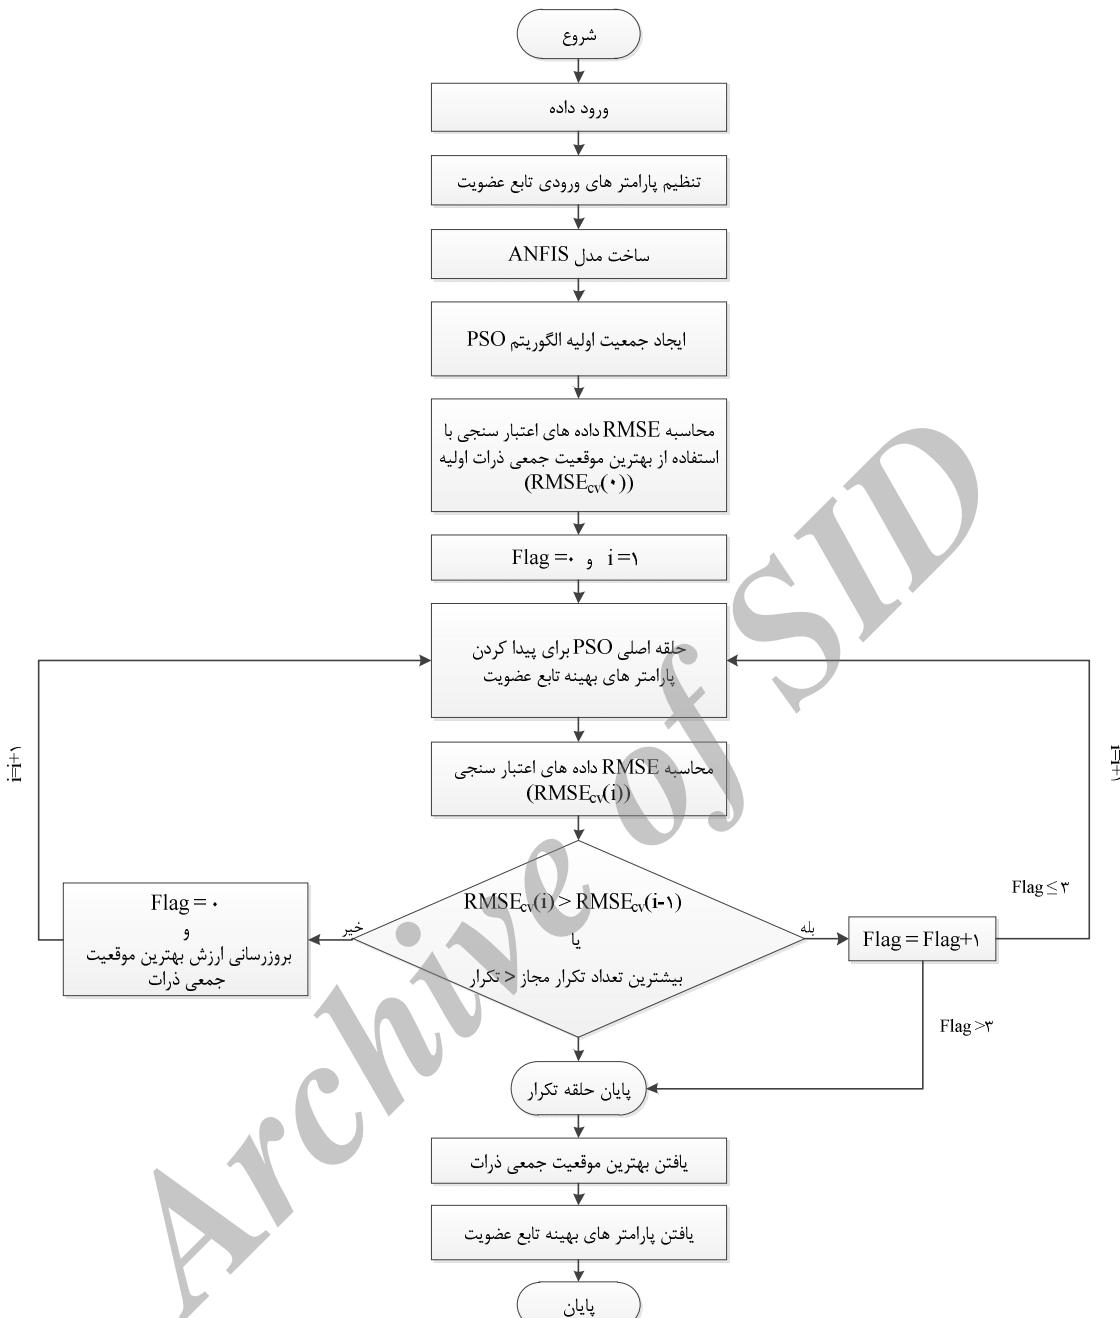


شکل ۵. معماری سیستم استنتاج تطبیقی عصبی-فازی.



شکل ۶. مدل فازی درجه اول تاکاگی-سوگنو با دو قانون و دو پارامتر ورودی [Yuan et al. 2014]

پیش‌بینی مدل برجهندگی خاک‌های ریزدانه با استفاده از شبکه عصبی....



شکل ۷. روند تعیین پارامترهای بهینه توابع عضویت سیستم استنتاج تطبیقی عصبی - فازی با استفاده از الگوریتم ازدحام ذرات.

۲- ضریب رگرسیون (R^2) :

$$R^2 = \left[\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y}) \right]^2 \quad (10)$$

که N تعداد داده‌های مشاهده شده، x_i ارزش X برای مشاهده‌ی آم، y_i ارزش y برای پیش‌بینی آم، \bar{x} میانگین X و \bar{y}

۵-۲ بررسی عملکرد مدل‌ها

در این تحقیق از روابط آماری زیر برای محاسبه میزان عملکرد و مقایسه‌ی مدل‌ها با هم استفاده شده است:

۱- جذر میانگین مربعات خطای $(RMSE)$:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \bar{y})^2} \quad (9)$$

خاک‌های A-6 و A-7 تا ۱۰۰ درصد برای خاک‌های متغیر بود. کلیه نمونه‌های خاک جمع‌آوری شده ابتدا در گرمانه و در دمای ۶۰ درجه‌ی سانتی‌گراد گرم و پس از آن در هوای آزاد آزمایشگاه خشک شده و در نهایت ساییده شده‌اند. انجام آزمایش‌های مدول برجهندگی بر اساس استاندارد آشتو [Hanittin (AASHTO D T294)] صورت گرفته است [Hanittin, 2007]. نه پارامتر که در تحقیق هانیتان نشان‌دهنده بهترین نتایج در ساخت مدل توسط شبکه عصبی بودند، به عنوان پارامترهای ورودی در نظر گرفته شدند [Hanittinan, 2007]. این نه پارامتر ورودی عبارت بودند از: درصد ذرات عبوری از الک نمره ۲۰۰، حد روانی (LL)، شاخص خمیری (PI)، درصد رطوبت بهینه (%)، درصد رطوبت خاک (%)، درجه اشباع (%)، مقاومت فشاری تک محوری (q_u)، تنش محدودکننده (σ_3) و تنش انحرافی (σ_d). مشخصات آماری مجموعه داده‌های مدول برجهندگی خاک‌های ریزدانه برای ایجاد پایگاه داده در جدول ۱ نشان داده شده است.

جدول ۱. مشخصات آماری مجموعه داده‌ی مدول برجهندگی خاک بستر [Hanittinan, 2007]

M_R (MPa)	σ_d (KPa)	σ_3 (KPa)	q_u (KPa)	DS (%.)	SM (%.)	OM (%.)	PI	LL	$P_{#200}$ (%.)	مشخصات آماری
۷/۴	۱۰	۰	۵۴/۳	۴۲/۹۲	۷/۵۳	۹/۴	۲	۲۱	۴۲	کوچکترین داده
۱۷۹/۴۴	۷۱/۶۹	۴۱/۴	۷۱۵/۷۴	۱۰۰	۲۷/۲	۲۴/۲	۳۶	۵۹	۱۰۰	بزرگترین داده
۵۴/۹۶	۴۰/۳	۲۱/۰۲	۳۱۱/۴۴	۸۱/۴	۱۵/۳۲	۱۵/۱۹	۱۲/۶۸	۳۲/۶	۷۵/۲	میانگین
۲۹/۶۶	۱۸/۲۴	۱۶/۳۶	۱۶۲/۳۴	۱۱/۱۷	۳/۵۲	۳/۰۳	۸/۶۷	۹/۹	۱۷/۶۴	انحراف معیار
۵۳/۸۲	۴۱/۳۷	۲۰/۶۹	۳۰۲/۶۸	۸۳/۸	۱۴/۸۹	۱۴/۴	۱۰	۲۹	۷۶	میانه

: DS: درصد عبوری از الک نمره ۲۰۰، LL: حد روانی، PI: شاخص خمیری، OM: رطوبت بهینه، SM: رطوبت خاک، q_u : درصد اشباع، M_R : مدول برجهندگی، σ_d : تنش محدودکننده، σ_3 : تنش انحرافی، $P_{#200}$: مقاومت فشاری تک محوری.

میانگین y و σ_y به ترتیب برابر انحراف معیار x و y است. ۶-۲ مشخصات پایگاه داده

برای ساخت و بررسی عملکرد مدل‌های مختلف، از ۸۸۷ داده مدول برجهندگی خاک بستر ایالت اوهایو که برگرفته از تحقیق هانیتان هستند، استفاده گردید [Hanittinan, 2007]. بیشتر مصالح بستر در اوهایو از خاک‌های ریزدانه بوده و می‌توان آن‌ها را مطابق با طبقه‌بندی اشتو به صورت A-4، A-6 و A-7 طبقه‌بندی کرد. در تحقیق هانیتان، نمونه‌های خاک، از سایت‌های راه‌سازی اداره راه و ترابری اوهایو (DOT) جمع‌آوری گردید. آزمایش‌های مدول برجهندگی در شرایط خاک خشک، خاک با رطوبت بهینه، خاک مرطوب و خاک اشباع انجام شد [Hanittinan, 2007].

مدول برجهندگی خاک‌های ریزدانه، بهشت به میزان رطوبت خاک حساس بوده و مقادیر آن با افزایش میزان رطوبت خاک، کاهش می‌یابد. درجه اشباع در این تحقیق از ۶۳/۷ تا ۱۰۰ درصد برای خاک‌های A-4، ۴۲/۹ تا ۱۰۰ درصد برای

الگوریتم بهینه‌سازی ازدحام ذرات به منظور بهینه‌سازی وزن‌ها و بایاس‌های شبکه با معناری ۹-۳۸-۱ استفاده شد. پارامترهای در نظر گرفته شده برای الگوریتم بهینه‌سازی ازدحام ذرات در جدول ۲ نشان داده شده است.

عملکرد مدل ترکیبی شبکه عصبی مصنوعی-بهینه‌سازی ازدحام ذرات (ANN-PSO) برای پیش‌بینی مدول برجهندگی با توجه به داده‌های آموزش و آزمون در شکل ۸ نشان داده شده است.

جدول ۲. پارامترهای الگوریتم بهینه‌سازی ازدحام ذرات به منظور بهینه‌سازی شبکه عصبی.

پارامترها	
۵۰۰	تعداد ذرات
۲۰۰	تعداد تکرارها
۱	شتاب شناسایی (C_1)
۲	شتاب جمعی (C_2)
۱	وزن اینرسی اولیه (w)
۰/۹۹	نسبت میرایی وزن اینرسی (Ω_{damp})

همچنین مقادیر جذر میانگین مربعات خطأ (RMSE) و ضریب رگرسیون (R^2) در جدول ۳ داده شده است.

همان‌گونه که در جدول (۳) ملاحظه می‌شود، ضریب رگرسیون بین مقادیر مشاهده شده و مقادیر پیش‌بینی شده مدول برجهندگی خاک بستر برای داده‌های آموزش و آزمون به ترتیب برابر با $0/999$ و $0/983$ است. در مجموع می‌توان دید که روش شبکه عصبی مصنوعی این توانایی را دارد که میزان مدول برجهندگی خاک بستر را با ضریب رگرسیون پیش از $0/98$ پیش‌بینی کند.

SVM-PSO روش ۲-۳

در این روش هم به منظور آموزش، اعتبارسنجی و آزمون مدل، به ترتیب از 60% و 30% مجموعه‌ی کلی داده‌های مدول برجهندگی استفاده شد. ارزیابی انجام شده نشان داد که شبکه بهینه دارای معناری ۹-۳۸-۱ است که در آن، ۹ و ۱ به ترتیب تعداد متغیرهای ورودی و خروجی شبکه و 38 تعداد نرون‌ها در لایه‌ی پنهان است. در این معناری تابع انتقال لایه‌ی پنهان به صورت هایپربولیک تائزانت سیگموئید^۳ و تابع انتقال لایه‌ی خروجی به صورت خطی^۴ در نظر گرفته شد. درنهایت از

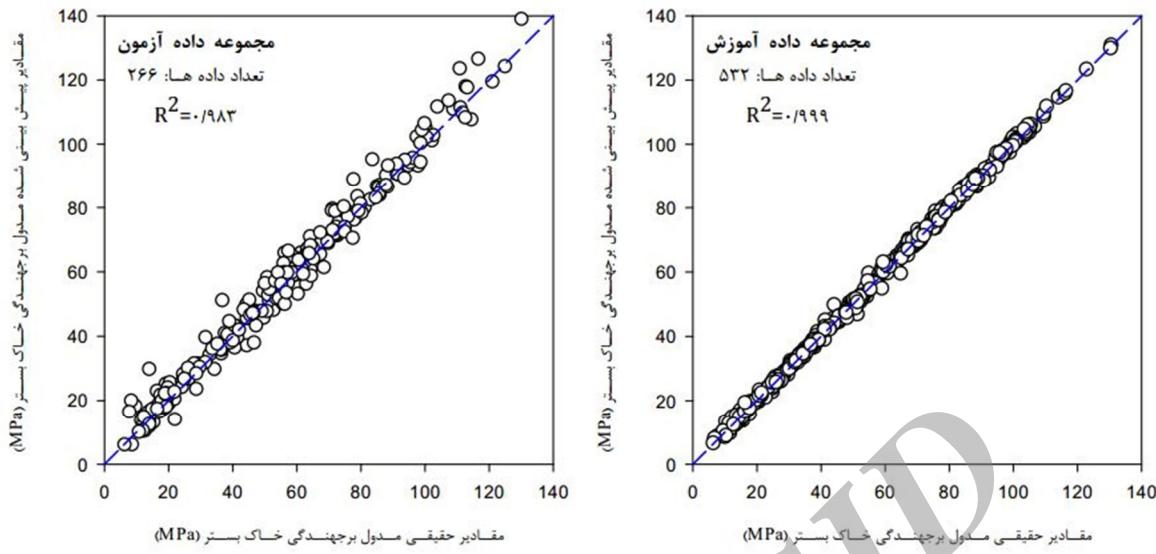
۳. نتایج و بحث

۱-۳ ANN-PSO روش

داده‌های ورودی و خروجی پیش از پیاده‌سازی شبکه عصبی مصنوعی، بین ۰ تا ۱ نرم‌مال‌سازی شد و فرآیند آموزش و آزمون این شبکه با استفاده از مقادیر نرم‌مال شده انجام شد. جعبه‌ایزار شبکه‌های عصبی مصنوعی نرم‌افزار MATLAB به منظور پیاده‌سازی شبکه عصبی مصنوعی مورد استفاده قرار گرفت. این جعبه‌ایزار در هر بار اجرا، مقادیر وزن و بایاس اولیه‌ای را به صورت تصادفی به شبکه اختصاص می‌دهد. اختصاص مقادیر وزن‌ها و بایاس‌ها یکی از عوامل بسیار تأثیرگذار بر میزان عملکرد آموزش شبکه عصبی مصنوعی حتی با فرض ثابت بودن معناری و سایر پارامترها شبکه عصبی است. در این تحقیق از روش سعی و خطأ به منظور تعیین معناری بهینه شبکه عصبی استفاده شد.

بدین منظور، برنامه‌ای در نرم‌افزار MATLAB نوشته شد که فرآیند سعی و خطأ را به صورت خودکار و با هدف تعیین بهترین معناری شبکه انجام می‌داد. با توجه به دقت بالای شبکه عصبی تک لایه در این تحقیق و پیچیده‌شدن مدل در صورت استفاده از تعداد لایه‌های مخفی بیشتر، از شبکه عصبی با یک لایه مخفی استفاده شد. برنامه توسعه داده شده با ارزیابی تعداد مختلف نرون‌ها در لایه مخفی، بهترین معناری را با توجه به شرط کمینه‌سازی میزان جذر مربع متوسط (RMSE)، داده‌های آزمون پیدا می‌کند. شبکه بهینه دارای یک لایه مخفی و 38 نرون در این لایه مخفی است.

به منظور آموزش، اعتبارسنجی و آزمون شبکه، به ترتیب از 60% ، 10% و 30% مجموعه‌ی کلی داده‌های مدول برجهندگی استفاده شد. ارزیابی انجام شده نشان داد که شبکه بهینه دارای معناری ۹-۳۸-۱ است که در آن، ۹ و ۱ به ترتیب تعداد متغیرهای ورودی و خروجی شبکه و 38 تعداد نرون‌ها در لایه‌ی پنهان است. در این معناری تابع انتقال لایه‌ی پنهان به صورت هایپربولیک تائزانت سیگموئید^۳ و تابع انتقال لایه‌ی خروجی به صورت خطی^۴ در نظر گرفته شد. درنهایت از



شکل ۸. عملکرد مدل پیش‌بینی ANN-PSO

جدول ۳. دقت مدل پیش‌بینی ANN-PSO

داده‌های آزمون		داده‌های آموزش	
R ²	RMSE (MPa)	R ²	RMSE (MPa)
۰/۹۸۳	۳/۸۸۱	۰/۹۹۹	۱/۰۶۶

جدول ۶ نشان می‌دهد که ضریب رگرسیون مقادیر پیش‌بینی شده مدول برجهندگی خاک بستر با استفاده از روش SVM-PSO برای داده‌های آموزش و آزمون به ترتیب برابر با ۰/۹۷۶ و ۰/۹۹۸ است.

همان‌گونه که ملاحظه می‌شود، روش SVM-PSO دقت بسیار بالا آموزش دیده است، با این وجود با توجه به کاهش مقادیر ضریب رگرسیون داده‌های آزمون در مقایسه با داده‌های آموزش می‌توان چنین نتیجه‌گیری نمود که این روش دارای تعمیم‌پذیری کمتری نسبت به مدل ANN-PSO است.

ANFIS-PSO روش ۳-۳

در این مدل نیز به ترتیب از ۰/۱۰٪ و ۳۰٪ مجموع کل داده‌های مدول برجهندگی به عنوان مجموعه آموزش، اعتبارسنجی و آزمون استفاده شد. تعداد قانون‌ها (Rules) و معمازی سیستم استنتاج تطبیقی عصبی-فازی پس از ارزیابی حالت‌های مختلف توسط جعبه‌ابزار سیستم استنتاج تطبیقی عصبی-فازی برنامه MATLAB، برابر با ۱۰ تعیین شد.

شکل ۹ نمایانگر عملکرد مدل SVM-PSO برای پیش‌بینی مدول برجهندگی با توجه به داده‌های آموزش و آزمون است. مقادیر جذر میانگین مربعات خطأ (RMSE) و ضریب همبستگی (R^2) این مدل نیز در جدول ۶ ارائه شده است.

جدول ۴. پارامترهای الگوریتم بهینه‌سازی ازدحام ذرات به‌منظور بهینه‌سازی ماشین بردار پشتیبان.

پارامترها
تعداد ذرات
تعداد تکرارها
شتاپ شناسایی (C ₁)
شتاپ جمعی (C ₂)
وزن اینرسی اولیه (w)
نسبت میرایی وزن اینرسی (Ω _{damp})

جدول ۵. مقادیر بهینه‌ی γ، ε و C.

γ	ε	C
۱	۰/۰۰۱	۸۶/۱۶۲۷

پیش‌بینی مدل برجهندگی خاک‌های ریزدانه با استفاده از شبکه عصبی....

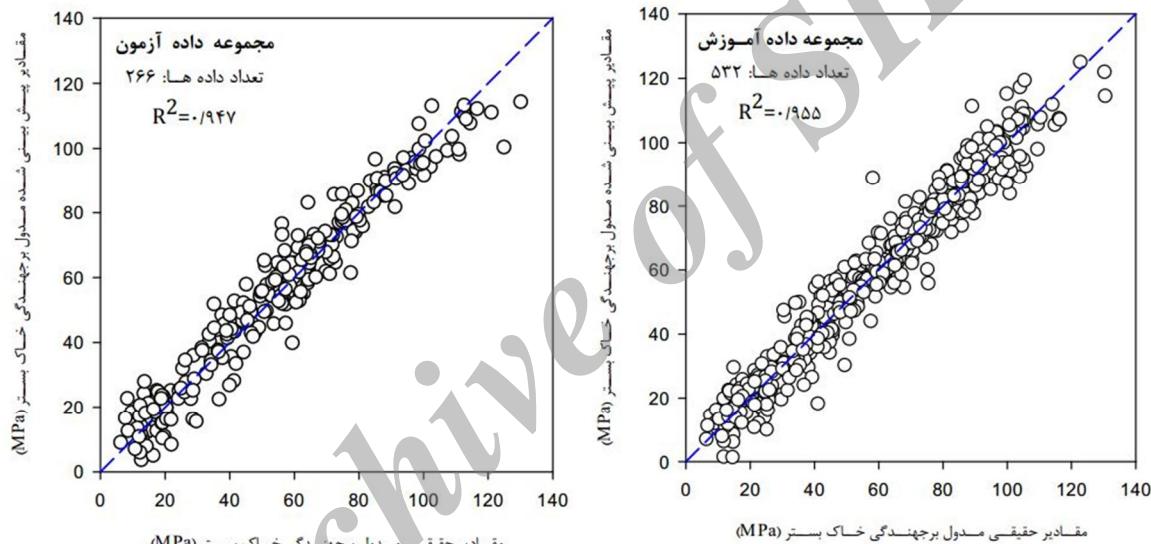
جدول ۷. پارامترهای الگوریتم بهینه‌سازی ازدحام ذرات به منظور بهینه‌سازی پارامترهای توابع عضویت سیستم استنتاج تطبیقی عصبی- فازی.

پارامترها	
۲۰۰	تعداد ذرات
۵۰۰	تعداد تکرارها
۱	شتاب شناسایی (C_1)
۲	شتاب جمعی (C_2)
۱	وزن اینرسی اولیه (w)
۰/۹۹	نسبت میرایی وزن اینرسی (Ω_{damp})

سپس از الگوریتم ازدحام ذرات به منظور تعیین پارامترهای بهینه توابع عضویت استفاده شد.

در جدول ۷ پارامترهای الگوریتم بهینه‌سازی ازدحام ذرات به منظور بهینه‌سازی پارامترهای توابع عضویت جعبه‌ابزار سیستم استنتاج تطبیقی عصبی- فازی ذکر شده است.

جدول ۸ نشان می‌دهد که ضریب رگرسیون مقادیر پیش‌بینی شده مدل برجهندگی خاک بستر با استفاده از روش ANFIS-PSO برای داده‌های آموزش و آزمون به ترتیب برابر با ۰/۹۴۷ و ۰/۹۵۵ است. در مجموع می‌توان دید که دقت روش ANFIS-PSO در مقایسه با دو روش ANN-PSO و SVM-PSO بسیار پایین‌تر است.



شکل ۱۰- عملکرد مدل پیش‌بینی ANFIS-PSO

جدول ۸ دقت مدل پیش‌بینی ANFIS-PSO

داده‌های آزمون		داده‌های آموزش	
R ²	RMSE (MPa)	R ²	RMSE (MPa)
۰/۹۴۷	۶/۶۵۷	۰/۹۵۵	۶/۵۰۴

ورودی با تعیین درجه همبستگی بین جفت داده‌های ورودی و خروجی و با استفاده از رابطه زیر تعیین می‌شود:

$$R_i = \frac{\sum_{k=1}^m x_{ik} y_k}{\sqrt{\sum_{k=1}^m x_{ik}^2 \sum_{k=1}^m y_k^2}} \quad (11)$$

که در این رابطه، x_{ik} مقدار متغیر مستقل آم برای داده k ام و y_k مقدار متغیر وابسته برای داده k آم (نظیر x_{ik}) و m تعداد کل داده‌ها است. در صورتی که مقدار R_i نزدیک به ۱ یا -۱ باشد، نشان دهنده این است که بین پارامتر ورودی و پارامتر خروجی همبستگی وجود دارد. همچنین در صورت عدم ارتباط پارامتر خروجی و ورودی، مقدار R_i برابر با صفر خواهد بود. شکل (۱۲) درجه اهمیت هر یک از پارامترها را بر روی مدلول برجهندگی خاک بستر نشان می‌دهد. این تحلیل حساسیت بر اساس ۸۸۷ داده موجود در پایگاه داده انجام شده است. با توجه به بالا بودن مقادیر R می‌توان دید که کلیه پارامترهای در نظر گرفته شده بر روی مدلول برجهندگی خاک بستر مؤثر می‌باشند. همچنین می‌توان دید که در محلوده داده‌های مورد ارزیابی در این مقاله، پارامتر ورودی درصد مصالح عوری از الک نمره ۲۰۰ بیشترین تأثیر و پارامتر تنفس انحرافی کمترین تأثیر را بر روی مدلول برجهندگی مصالح خاکی ریزدانه دارند.

۴. نتیجه‌گیری

نتایج حاصل از این تحقیق به طور خلاصه به صورت زیر قابل بیان می‌باشند:

۱. مدل‌های ترکیبی مبتنی بر هوش مصنوعی و روش‌های بهینه‌سازی فرا ابتکاری امکان پیش‌بینی دقیق مدلول برجهندگی خاک‌های ریزدانه بستر روسازی را فراهم می‌سازند.
۲. با بهره‌گیری از روش‌های هوش مصنوعی می‌توان مدلول برجهندگی خاک‌های ریزدانه را با داشتن پارامترهای فیزیکی و مکانیکی خاک و همچنین حالت تنفس و بدون انجام آزمایش سه محوری دینامیک با دقت بالا پیش‌بینی نمود.
۳. از بین مدل‌های ارزیابی شده در این مقاله، مدل

۴-۳ مقایسه سه روش SVM-PSO، ANN-PSO و ANFIS-PSO

در جدول زیر نتایج مربوط به پیش‌بینی مدلول برجهندگی خاک بستر برای کل داده‌ها با استفاده از سه روش ANN-PSO، ANFIS-PSO و SVM-PSO آورده شده است. همان‌گونه که ملاحظه می‌شود، از بین سه روش ارزیابی شده در این مقاله روش ANN-PSO در مقایسه با دو روش دیگر امکان پیش‌بینی دقیق‌تر مدلول برجهندگی خاک‌های ریزدانه را فراهم می‌سازد.

همچنین می‌توان دید که دقت روش SVM-PSO در مقایسه با دقت روش ANFIS-PSO بیشتر است. در مجموع با توجه به ارزیابی انجام شده در این مقاله روش ANN-PSO برای

پیش‌بینی مدلول برجهندگی خاک‌های ریزدانه پیشنهاد می‌شود و می‌توان انتظار داشت که مقادیر پیش‌بینی شده به استفاده از این روش دارای ضریب رگرسیون بیش از ۰/۹۸ باشند.

شکل (۱۱) مقادیر اندازه‌گیری شده مدلول برجهندگی را در مقابل مقادیر پیش‌بینی شده با استفاده از هر یک از روش‌های ANFIS-PSO، SVM-PSO، ANN-PSO همچنین در این نمودار خطوط مربوط به درصد خطای نسبت به خطای صفر (خط برابری) ترسیم شده است. همان‌گونه که ملاحظه می‌شود، روش ANN-PSO در مقایسه با دو روش دیگر با خطای کمتری مقدار مدلول برجهندگی را پیش‌بینی می‌کند، به طوری که در اکثر موارد درصد خطای پیش‌بینی مدلول برجهندگی با استفاده از این روش کمتر از ۲۰ درصد است. همچنین ملاحظه می‌شود که با افزایش مقدار مدلول برجهندگی، خطای پیش‌بینی مدلول برجهندگی کاهش می‌باید.

۵-۳ تعیین درجه اهمیت هر یک از پارامترهای ورودی بر روی مدلول برجهندگی

یکی از روش‌های تعیین درجه اهمیت هر یک از پارامترهای ورودی بر روی پارامتر خروجی، روش دامنه کسینوس^{۶۶} است که می‌تواند به منظور بررسی تأثیر هر یک از پارامترهای ورودی بر پارامتر خروجی مورد استفاده قرار گیرد [Yang and Zhang, 1997]. در این روش درجه حساسیت پارامتر

این معماری بر اساس داده‌های آموزش و آزمون به ترتیب برابر با ۰/۹۸۳ و ۰/۹۹۹ است.

۶. روش ANN-PSO در اکثر موارد امکان پیش‌بینی مدول برجهندگی خاک بستر را با درصد خطای کمتر از ۲۰ درصد فراهم می‌کند. درصد خطای پیش‌بینی مدول برجهندگی با افزایش مقادیر مدول برجهندگی کاهش می‌یابد.

۷. در محدوده داده‌های مورد ارزیابی در این مقاله، پارامتر ورودی درصد مصالح عبوری از الک نمره ۲۰۰ بیشترین تأثیر و پارامتر تنفس انحرافی کمترین تأثیر را بر روی مدول برجهندگی مصالح خاکی ریزدانه دارد.

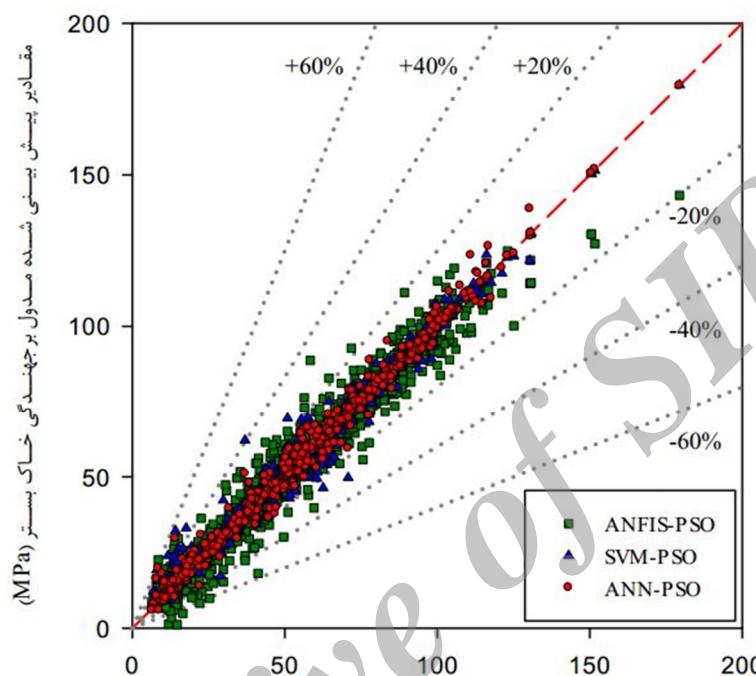
ANN-PSO با ضریب رگرسیون ۰/۹۹۲ دارای بیشترین دقت در پیش‌بینی مدول برجهندگی و مدل ANFIS-PSO با ضریب رگرسیون ۰/۹۵۱ دارای کمترین دقت در پیش‌بینی مدول برجهندگی خاک‌های بستر ریزدانه است.

۴. مقدار RMSE به دست آمده بر اساس کل داده‌های ANN-PSO پیش‌بینی شده با استفاده از روش‌های ANFIS-PSO و SVM-PSO به ترتیب برابر با ۳/۱۳۵، ۲/۵۹۷ و ۶/۶۰۱ است.

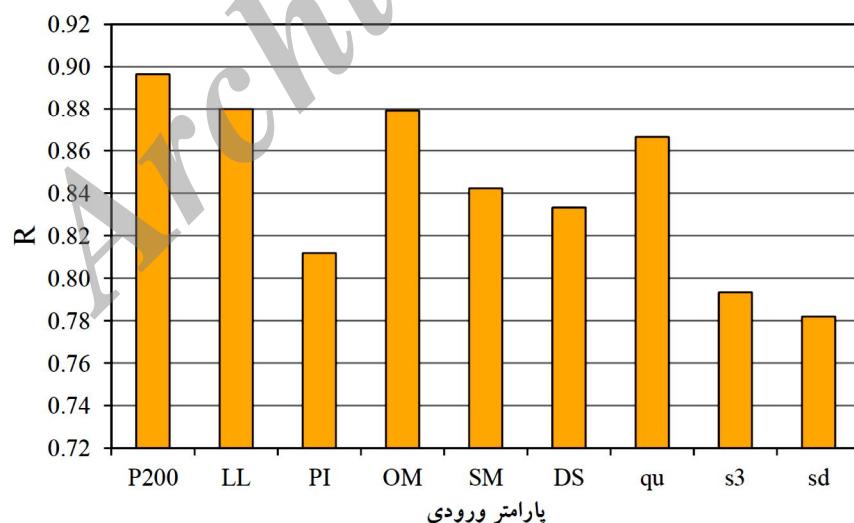
۵. معماری بهینه شبکه عصبی مصنوعی به منظور پیش‌بینی مدول برجهندگی خاک‌های ریزدانه به صورت ۹-۳۸-۱ است. ضریب رگرسیون بین مقادیر اندازه‌گیری شده و پیش‌بینی شده با استفاده از

جدول ۹. دقیقیت مدل‌های ساخته شده با در نظر گرفتن کل داده‌ها.

ANN-PSO		SVM-PSO		ANFIS-PSO	
R ²	RMSE (MPa)	R ²	RMSE (MPa)	R ²	RMSE (MPa)
۰/۹۹۲	۲/۰۹۷	۰/۹۸۹	۳/۱۳۵	۰/۹۵۱	۶/۶۰۱



شکل ۱۱. مقایسه عملکرد مدل‌های مختلف در پیش‌بینی مدول برجهندگی خاک بستر.



شکل ۱۲. درجه اهمیت هر یک از پارامترهای ورودی بر روی مدول برجهندگی.

constitutive models", Transportation Research Record, Journal of the Transportation Research Board, Vol. 2170, pp. 64-73.

-Dibike, Y. B., Velickov, S., Solomatine, D. and Abbott, M.B. (2001) "Model induction with support vector machines: introduction and applications", Journal of Computing in Civil Engineering, Vol. 15, No. 3 , pp. 208-216.

-Eberhart, Russ C. and Kennedy, James (1995) "A new optimizer using particle swarm theory", Proceedings of the sixth international symposium on micro machine and human science, New York, pp. 39-43.

-Freeman, James A. and Skapura, David M. (1992) "Neural Networks: Algorithms, Applications and Programming Techniques", Addison-Wesley Publishing Company.

George, K. (1992) "Resilient testing of soils using gyratory testing machine", Transportation Research Record, Journal of Transportation Research Board, Vol. 1369, pp. 63-72.

George, K.P (2004) "Prediction of resilient modulus from soil index properties", Washington, DC, Rep. No. FHWA/MS-DOT-RD-04-172, Federal Highway Administration, U.S. Department of Transportation.

Ghanizadeh, A..R. and Rahrovan, M. (2016) "Application of artificial neural network to predict the resilient modulus of stabilized base subjected to wet-dry cycles", Computations and Materials in Civil Engineering, Vol. 1, No. 1, pp. 37-47.

Hanittinan, Wichai (2007) "Resilient modulus prediction using neural network algorithm", (PhD Thesis),The Ohio State University.

Haykin, Simon S. (2001) "Neural networks: a comprehensive foundation", Tsinghua University Press.

Hu, C.H. (2011) "Prediction of resilient modulus for hot mix asphalt based on artificial neural network", Advanced Materials Research, Trans Tech Publ, Vol. 304, pp. 18-23.

۵. پی‌نوشت

- ۱-Mechanistic-empirical pavement design guide
- ۲- Gyratory methods
- ۳-Multilayer elastic theory
- ۴-Artificial neural network
- ۵-Multilayer perceptron
- ۶-Radial basis function
- ۷-Shanxi
- ۸-Genetic algorithm
- ۹-Extreme learning machine
- ۱۰-Support vector machine
- ۱۱-Adaptive neuro-fuzzy infrence system
- ۱۲-Particle swarm optimization
- ۱۳-Neuron
- ۱۴-Feed forward back propagation
- ۱۵-Kernel function
- ۱۶-If-then
- ۱۷- Sugeno
- ۱۸-Gaussian membership function
- ۱۹-Takagi-sugeno
- ۲۰-Root mean square error
- ۲۱-Coefficient of determination
- ۲۲-Ohio department of transportation
- ۲۳-Tansig
- ۲۴-Purelin
- ۲۵-Cosine Amplitude Method (CAM)

۶. منابع

- AASHTO (1986) "Standard specifications for transportation materials and methods of sampling and testing",Washington, DC: AASHTO.
- Coleri, E., Guler, M., Gungor, A. and Harvey, J. (2010) "Prediction of subgrade resilient modulus using genetic algorithm and curve-shifting methodology: Alternative to nonlinear

- Maalouf, M., Khoury, N., Trafalis, T.B. (2008) "Support vector regression to predict asphalt mix performance", International journal for numerical and analytical methods in geomechanics, Vol. 32, No. 16, pp. 1989-1996.
- Mohammad, L., Huang, B., Puppala, A. and Allen, A. (1999) "Regression model for resilient modulus of subgrade soils", Transportation Research Record, Journal of the Transportation Research Board, Vol. 1687, pp. 47-54.
- Nazzal, M. D. and Tatari, O. (2013) "Evaluating the use of neural networks and genetic algorithms for prediction of subgrade resilient modulus", International Journal of Pavement Engineering, Vol. 14, No. 4, pp. 364-373.
- NCHRP (2004) "Guide for mechanistic-empirical design of new and rehabilitated pavement structures", Washington, Dc, Final Report for Project 1-37a.
- Ozsahin, T.S. and Oruc, S. (2008) "Neural network model for resilient modulus of emulsified asphalt mixtures", Construction and Building Materials, Vol. 22, No. 7, pp. 1436-1445.
- Pal, M. and Deswal, S. (2014) "Extreme learning machine based modeling of resilient modulus of subgrade soils", Geotechnical and Geological Engineering, Vol. 32, No. 2, pp. 287-296.
- Park, H., Kweon, G. and Lee, S. (2009) "Prediction of resilient modulus of granular subgrade soils and subbase materials using artificial neural network", Road Materials and Pavement Design, Vol. 10, No. 3, pp. 647-665.
- Pourtahmasb, M. S., Karim, M. R. and Shamshirband, S. (2015) "Resilient modulus prediction of asphalt mixtures containing Recycled Concrete Aggregate using an adaptive neuro-fuzzy methodology", Construction and Building Materials, Vol. 82, pp. 257-263.
- Rumelhart, D.E., Hintont, G.E. and Williams, R.J. (1986) "Learning representations by back-propagating errors", Nature, Vol. 323, pp. 533-536.
- Jang, J. S. R. (1993) "ANFIS: adaptive-network-based fuzzy inference system", IEEE Transactions On Systems, Man, And Cybernetics, Vol. 23, No. 3, pp. 665-685.
- Kennedy James and Eberhart, Russ C. (1995) "Particle swarm optimization", Proceedings of IEEE international conference on neural networks, pp. 1942-1948.
- Kezhen, Y., Yin, H., Liao, H. and Huang, L. (2011) "Prediction of resilient modulus of asphalt pavement material using support vector machine", ASCE, Geotechnical Special Publication, Vol. 213, pp. 16-23.
- Khazanovich, L., Celauro, C., Chadbourn, B., Zollars, J. and Dai, S. (2006) "Evaluation of subgrade resilient modulus predictive model for use in mechanistic-empirical pavement design guide", Transportation Research Record, Journal of the Transportation Research Board, Vol. 1947, pp. 155-166.
- Kim, D.-S., Kweon, G.-C. and Lee, K. H. (1997) "Alternative method of determining resilient modulus of compacted subgrade soils using free-free resonant column test", Transportation Research Record, Journal of the Transportation Research Board, Vol. 1577, pp. 62-69.
- Kim, D. S., Stokoe, I. and Kenneth, H. (1992) "Characterization of resilient modulus of compacted subgrade soils using resonant column and torsional shear tests", Transportation Research Record, Advances in Geotechnical Engineering, Vol. 1369, pp. 83-91.
- Kim, S.-H., Yang, J., Jeong, J.H. (2014) "Prediction of subgrade resilient modulus using artificial neural network", KSCE Journal of Civil Engineering, Vol. 18, No. 5, pp. 1372-1379.
- Maalouf, M., Khoury, N., Laguros, J.G., Kumin, H. (2012) "Support vector regression to predict the performance of stabilized aggregate bases subject to wet-dry cycles", International journal for numerical and analytical methods in geomechanics, Vol. 36, No. 6, pp. 675-696.

Takagi, T. and Sugeno, M. (1985) "Fuzzy identification of systems and its applications to modeling and control", IEEE transactions on systems, man, and cybernetics, Vol. 1, pp. 116-132.

Tutumluer, E. and Meier, R. (1996) "Attempt at resilient modulus modeling using artificial neural networks", Transportation Research Record, Journal of the Transportation Research Board, Vol. 1540, pp. 1-6.

Vadood, M., Johari, M. S. and Rahai, A. (2015) "Developing a hybrid artificial neural network-genetic algorithm model to predict resilient modulus of polypropylene/polyester fiber-reinforced asphalt concrete", The Journal of The Textile Institute, Vol. 106, No. 11, pp. 1239-1250.

Vapnik, V., Golowich, S. E. and Smola, A. (1997) "Support vector method for function approximation, regression estimation, and signal Processing", Advances In Neural information Processing Systems, pp. 281-287.

Vapnik, Vladimir Naumovich and Vapnik, Vladimir (1998) "Statistical learning theory", New York, Wiley.

Werbos, Paul J. (1974) "Beyond regression: new tools for prediction and analysis in the behavioral sciences", (PHD Dissertation), Harvard University, Cambridge.

Witczak, M.W., Qi, X. and Mirza, M. W. (1995) "Use of nonlinear subgrade modulus in AASHTO design procedure", Journal of Transportation Engineering, Vol. 121, No. 3, pp. 273-282.

Yuan, Z., Wang, L. N. and Ji, X. (2014) "Prediction of concrete compressive strength: Research on hybrid models genetic based algorithms and ANFIS", Advances in Engineering Software, Vol. 67, pp. 156-163.

Zaman, M., Solanki, P., Ebrahimi, A. and White, L. (2010) "Neural network modeling of resilient modulus using routine subgrade soil properties", International Journal of Geomechanics, Vol. 10, No. 1, pp. 1-12.

Sadrossadat, E., Heidaripanah, A. and Osouli, S. (2016) "Prediction of the resilient modulus of flexible pavement subgrade soils using adaptive neuro-fuzzy inference systems", Construction and Building Materials, Vol. 123, pp. 235-247.

Sadrossadat, E., Heidaripanah, A. and Ghorbani, B. (2016) "Towards application of linear genetic programming for indirect estimation of the resilient modulus of pavements subgrade soils", Road Materials and Pavement Design, Vol. 17, pp. 1-15.

Samui, P. (2008) "Support vector machine applied to settlement of shallow foundations on cohesionless soils", Computers and Geotechnics, Vol. 35, No. 3, pp. 419-427.

Shafabakhsh, G. and Tanakizadeh, A. (2015) "Investigation of loading features effects on resilient modulus of asphalt mixtures using Adaptive Neuro-Fuzzy Inference System", Construction and Building Materials, Vol. 76, pp. 256-263.

Shi, Yuhui and Eberhart, Russell (1998) "A modified particle swarm optimizer", Evolutionary Computation Proceedings, IEEE World Congress on Computational Intelligence, The 1998 IEEE International Conference, pp. 69-73.

Solanki, P. (2013) "Artificial neural network models to estimate resilient modulus of cementitious stabilized subgrade soils", International Journal of Pavement Research and Technology, Vol.6, No. 3, pp. 155-164.

Solanki, P., Ebrahimi, A. and Zaman, M. M. (2008) "Statistical models for determination of the resilient modulus of subgrade soils", International Journal of Pavement Research and Technology, Vol. 1, No. 3, pp. 85-93.

Solanki, P., Zaman, M. and Ebrahimi, A. (2009) "Regression and artificial neural network modeling of resilient modulus of subgrade soils for pavement design applications", Intelligent and Soft Computing in Infrastructure Systems Engineering, Volume 259 of the series Studies in Computational Intelligence, pp. 269-304.

2013: Safety, Speediness, Intelligence, Low-Carbon, Innovation, pp. 1734-1739

Zhang, X. (2013) "Radial Basis Function Neural Network Predicting of Resilient Modulus for Shanxi Subgrade Soils", ICTE

که در آن Q_n مقدار نرمال‌سازی شده پارامتر Q ، Q_{Max} حداکثر مقدار حقیقی پارامتر Q و Q_{Min} حداقل مقدار حقیقی پارامتر Q است.

پس از مدل‌سازی شبکه، خروجی‌های حقیقی باید بر اساس مقادیر خروجی‌های نرمال‌سازی شده و با استفاده از رابطه (الف-۳) محاسبه گردد. مقادیر حداکثر و حداقل پارامترهای ورودی و خروجی در جدول ۱ نشان داده شده است.

ماتریس وزن‌های لایه پنهان و خروجی به ترتیب در جدول الف-۱ و الف-۲ ارائه شده‌اند.

بردار بایاس لایه پنهان و خروجی نیز به ترتیب در جدول الف-۳ و الف-۴ ارائه شده‌اند.

محققین محترم می‌توانند به کمک رابطه‌ی الف-۴، مدل ANN-PSO ارائه شده در این مقاله را به کمک مقادیر ماتریس وزن‌ها و بردار بایاس‌ها ساخته و از آن برای پیش‌بینی مدلول برجهنگی استفاده نمایند.

$$\{Out\} = tan sig \left(\begin{matrix} \{Inp\} \times [W_h]^T \\ + \{\theta_h\}^T \end{matrix} \right) \times [W_o]^T + \{\theta_o\}^T \quad (\text{الف-۴})$$

که در این رابطه، تابع انتقال $tansig(x)$ به صورت زیر تعریف می‌شود:

$$tansig(x) = \frac{2}{1+e^{-2x}} - 1 \quad (\text{الف-۵})$$

پیوست الف: ماتریس وزن‌ها و بردار بایاس‌های ANN-PSO مدل

این پیوست به بردار ورودی، بردار خروجی، فاکتورهای وزن و فاکتورهای بایاس شبکه عصبی مصنوعی پس انتشار بهینه‌سازی شده با الگوریتم ازدحام ذرات خواهد پرداخت که در بخش ۱-۳ مشخصات و نتایج مربوط به آن به تفصیل توضیح داده شده است.

با توجه به مقاله، معماری بهینه شبکه عصبی به صورت ۹-۳۸-۱ به دست آمد که در آن از تابع انتقال تائوزانت هایپربولیک سیگموئید در لایه پنهان و تابع انتقال خطی در لایه خروجی استفاده شده است.

بردار ورودی‌های نرمال‌سازی شده به صورت زیر تعریف می‌شود:

$$\{Inp\} = \{ P_{#200}, LL, PI, OM, SM, DS, q_1, q_2, q_3 \}_{1 \times 9} \quad (\text{الف-۱})$$

بردار پارامترهای خروجی نرمال‌سازی شده نیز به صورت زیر تعریف می‌شود:

$$\{Out\} = \{ M_R \}_{1 \times 1} \quad (\text{الف-۲})$$

پیش از مدل‌سازی شبکه عصبی، ورودی‌ها باید بر اساس رابطه‌ی زیر نرمال‌سازی شوند:

$$Q_n = \frac{(Max - Min)}{(Q - Min)} \quad (\text{الف-۳})$$

پیش‌بینی مدول برجهندگی خاک‌های ریزدانه با استفاده از شبکه عصبی.....

جدول الف-۱- ماتریس وزن‌های لایه پنهان $(W_h)_{38 \times 9}$

2.069198733	-0.898661094	-0.116463615	0.518005062	-0.149174748	-0.119123217	-1.489053715	-0.037445490	0.752122069
0.414904499	-0.454198596	0.319194531	-0.422782373	-0.287251862	0.737934586	-0.794461001	1.044343938	-0.335902716
-1.846203872	0.259743970	0.111423658	1.721670057	-1.015229052	-0.176594270	-0.941192848	0.229082502	-0.018608753
-1.885825235	-0.072892574	0.487960535	0.749245475	-0.916401811	-1.743202753	0.912495382	-0.207002983	0.738728209
-1.432816995	0.478423763	-0.088648694	-0.402119029	-1.796299003	0.893617027	-0.389531412	0.099694126	-0.007186549
-0.091903153	0.674422387	-0.891305774	-1.382421524	-0.131413673	1.469556434	0.317079570	0.312089895	0.009517404
-0.668274889	-0.526442007	0.872385057	0.242005156	-0.659475987	0.887893561	-0.856092898	-0.832311091	0.976743486
-0.680048270	-0.522025440	0.271952266	0.042458191	-0.674006015	-1.032783031	-0.013866510	-0.324893211	-0.147169277
1.811568571	0.118676595	-0.944668076	0.514466118	-1.019569976	0.022501095	-2.937693848	-0.158574270	0.114210459
-0.553434895	1.262170876	0.324330232	-0.239161162	1.287776715	2.133386454	0.323371930	-0.501718058	0.205788538
0.708056264	0.637908553	-0.948854482	0.044247589	0.415561549	-0.295868506	1.291707856	-0.105517438	0.431581312
0.776140006	-0.095621730	-0.142526992	0.121421571	-0.010684056	-0.786956878	0.434221359	0.935169077	0.405216311
-0.581869028	1.427065024	-0.691501554	-0.224188555	-0.174734884	0.251999661	-0.755213500	-1.128991280	0.205040610
-0.103172930	0.046115581	1.288757475	-1.063282500	-0.778005646	1.179846101	0.084768067	-0.195848334	0.487948524
-0.438108799	-1.489477412	0.761138873	0.030494997	-0.214119445	-1.010710190	0.410477549	-0.339684311	-0.092398720
-0.789491386	-1.075999662	-0.100346469	0.624918623	0.177899564	-0.912046725	-1.505162889	0.064935364	-0.177073667
-0.344776882	0.566636708	-1.246310752	0.722833705	0.137344531	0.532128558	-0.464011475	-0.087431482	0.574999790
-1.095100147	-0.263280483	-0.409597872	-1.338132288	0.280742553	0.076328333	-0.522605498	-0.252431168	-0.402835848
-1.409402221	1.107829219	1.385934723	2.285012177	1.274819934	1.636748524	-1.604291391	0.335780881	-0.636050330
-0.136956511	0.324273183	-0.920089735	-0.872858947	1.103203672	-1.667482798	-1.618900581	-0.003714734	0.130057323
-0.556715605	1.004474662	-0.593025680	-0.032991354	-0.262730341	0.201127204	-0.691685781	-1.441291570	0.576402513
-0.816474761	-0.288099821	-1.623486459	0.559228779	0.919840823	-0.179963672	-0.198447853	-0.122971957	0.284991650
0.284060892	-0.526569685	0.324041460	-0.000618262	2.016120884	1.564940674	-0.245869912	-1.533482314	0.197492889
-1.054580056	-1.731898302	-0.062912279	0.420111869	0.272853077	0.168805760	-0.594343827	0.625462080	-0.561572559
-1.656394204	-0.428169926	-0.161313831	0.134056557	-0.750681956	0.096764406	0.685553441	0.732006812	-0.624610021
-0.597369368	-0.115507272	0.735125544	0.709842407	-0.926347610	-0.606537320	-1.182508909	-0.198923936	-0.825766857
0.895623607	-1.176294897	0.083685860	-1.131327483	-1.048536747	-1.937430694	-2.271910173	0.322613576	-0.074450948
0.429918419	-1.985636913	1.515895841	0.099091218	0.320492091	2.298267588	0.743138722	-0.216228625	0.380004801
0.178671423	0.932666770	0.785462332	-2.277254074	0.637612061	-0.531704801	0.639339094	0.127619192	-0.518181202
-0.357801187	-0.980199729	0.482299261	-0.504642776	1.401675202	1.069906949	-0.177907187	-0.422192235	-0.553653374
0.535920139	1.016299045	0.787182697	0.658544062	2.009281283	0.121497610	-0.044849634	-0.110048302	0.205329372
1.139208698	-0.145657040	-1.485528744	-0.220850820	0.592047779	-0.667302043	-1.906304177	-0.219157746	0.032263709
-2.497618689	-0.974864939	-0.648225095	-0.394935389	0.093542379	0.429024975	-0.217567057	0.015288945	-0.416475272
-1.828432333	-0.487613328	0.510143021	-0.004625569	0.711622649	0.634535071	0.607044360	0.060102923	-0.157002803
-0.811277689	-1.110673040	0.461026432	-0.849147287	-3.043815439	-0.709295959	0.071518780	-0.004494532	-0.175970425
0.090993145	0.718242065	0.510087146	-0.122494352	1.433583699	0.324425928	-0.853389587	-0.159602636	0.617443265
-0.080379543	-0.097549827	-1.629152601	0.737735038	0.811018239	1.287975386	0.090376797	1.300119690	0.502476781
-1.412084963	-0.360976439	-0.087549679	-0.847789630	-0.117505179	-0.889046934	-1.413800397	-0.040346913	-0.199264751

جدول الف-۲. ماتریس وزن‌های لایه خروجی $(W_o)^T_{38 \times 1}$

-0.923029868	
-1.174332501	0.300534406
2.374666367	0.417621380
1.358132735	-0.827164522
-0.500764416	0.284729087
-0.156652848	1.428315866
-1.369844706	-0.898348321
-0.247029365	-0.251888370
-1.162702341	0.981502834
-0.155725221	-1.003635182
-0.229034541	0.422081026
0.170377128	1.027692546
-0.072380298	0.225002941
-0.685975569	0.498797709

0.451684084	0.793043568
0.113500610	1.331635060
0.724268180	-0.250855687
0.579405788	1.310381635
-0.547133637	1.254831020
1.120258110	0.737112839
0.343319008	-1.693361465
0.548437172	1.192255842
-0.292338980	0.589577778
0.561310495	0.826870296
-0.502806963	1.195685181
0.603451016	
-0.614317962	
1.157941509	
0.846066944	
-0.629006933	
-0.972636339	
1.860966994	
-1.330118512	
-0.967053024	

جدول الف-۲. بردار بایاس لایه پنهان $([\theta_h])_{38 \times 1}$.

جدول الف-۴- بردار بایاس لایه خروجی $([\theta_o])_{1 \times 1}$.

<u>-0.692523454</u>	
	-2.101041687
	1.195528486
	2.443601044
	2.847524018
	1.304225263
	0.791861034
	1.725891871
	0.598489721
	-1.939594596
	0.720427555
	-1.139940193
	-1.124632252
	0.931826177

پیش‌بینی مدول برجهندگی خاک‌های ریزدانه با استفاده از شبکه عصبی....

علیرضا غنی‌زاده، درجه کارشناسی در رشته مهندسی عمران را با رتبه ممتاز در سال ۱۳۷۹ از دانشگاه صنعتی خواجه نصیرالدین طوسی و درجه کارشناسی ارشد در رشته مهندسی عمران-راه و ترابری را با رتبه ممتاز در سال ۱۳۸۱ از دانشگاه تهران اخذ نمود. در سال ۱۳۹۲ موفق به کسب درجه دکتری در رشته مهندسی عمران-ژئوتکنیک از دانشگاه صنعتی خواجه نصیرالدین طوسی گردید. زمینه های پژوهشی مورد علاقه ایشان مهندسی روسازی و محاسبات نرم بوده و در حال حاضر استادیار دانشگاه صنعتی سیرجان است.



امیر توانا املشی، درجه کارشناسی در رشته مهندسی عمران-عمران را در سال ۱۳۹۳ از دانشگاه گیلان و درجه کارشناسی ارشد در رشته مهندسی عمران-سازه های هیدرولیکی در سال ۱۳۹۵ را از دانشگاه صنعتی سیرجان اخذ نمود. زمینه های پژوهشی مورد علاقه ایشان مطالعات آزمایشگاهی و عددی خاک و بتون بوده است.

