

# کاربرد روش ترکیبی شبکه عصبی موجک و الگوریتم بهینه‌سازی TLBO به منظور مدل‌سازی مدول برجهندگی مصالح زیراساس سنگدانه‌ای

مقاله علمی - پژوهشی

علیرضا غنی‌زاده\*، دانشیار، دانشکده مهندسی عمران، دانشگاه صنعتی سیرجان، سیرجان، ایران  
نسرین حیدرآبادی‌زاده، دانش آموخته کارشناسی ارشد، دانشکده مهندسی عمران، دانشگاه صنعتی سیرجان، سیرجان، ایران

\*پست الکترونیکی نویسنده مسئول: ghanizadeh@sirjantech.ac.ir

دریافت: ۱۴۰۲/۰۸/۱۰ - پذیرش: ۱۴۰۳/۰۲/۰۱

صفحه ۱۵۰-۱۲۷

## چکیده

مدول برجهندگی مصالح راه‌سازی یکی از پارامترهای مهم در تحلیل و طراحی روسازی چه در روش‌های تجربی و چه در روش‌های مکانیستیک-تجربی است. این پارامتر به‌عنوان اصلی‌ترین پارامتر برای بیان سختی و رفتار تنش-کرنش مصالح راه‌سازی تحت اثر تنش‌های تناوبی مورد استفاده قرار می‌گیرد. برای تعیین این پارامتر نیاز به انجام آزمایش بارگذاری سه محوری دینامیکی در تنش‌های محدودکننده و تنش‌های انحرافی مختلف است که بسیار وقت‌گیر و پرهزینه است. در این مقاله از روش ترکیبی شبکه عصبی موجک (WNN) و الگوریتم بهینه‌سازی مبتنی بر آموزش و یادگیری (TLBO) به منظور مدل‌سازی مدول برجهندگی مصالح زیراساس استفاده شده است. ورودی‌های مدل شامل حداکثر وزن مخصوص خشک، ضریب یکنواختی، ضریب انحناء، درصد عبوری از الک نمرة ۲۰۰، تنش محدودکننده و تنش انحرافی و خروجی مدول برجهندگی در نظر گرفته شده است. نتایج این تحقیق نشان می‌دهد که افزایش تعداد نرون‌ها در لایه مخفی به تعداد بیشتر از ۲۰ نرون تأثیر چندانی بر روی افزایش دقت شبکه عصبی موجک ندارد و تابع موجک Mexican Hat بهترین نتیجه را در پیش‌بینی مدول برجهندگی دارد. همچنین روش WNN-TLBO در مقایسه با روش ANN دارای دقت بیشتری در پیش‌بینی مدول برجهندگی مصالح زیراساس است. نتایج اعتبار سنجی خارجی نشان می‌دهد که روش WNN-TLBO همه معیارهای لازم را تأمین می‌کند که دلالت بر پتانسیل پیش‌بینی بالای این روش دارد. نتایج تحلیل حساسیت نشان می‌دهد که درجه اهمیت متغیر تنش محدودکننده نسبت به سایر متغیرها برای پیش‌بینی مدول برجهندگی بیشتر است. همچنین تحلیل پارامتریک تأثیر هر متغیر ورودی را روی مدول برجهندگی نشان می‌دهد.

واژه‌های کلیدی: مدول برجهندگی، شبکه عصبی موجک (WNN)، الگوریتم TLBO، زیراساس سنگدانه‌ای

## ۱- مقدمه

دینامیکی تکراری تعریف می‌شود که می‌توان از آن برای توصیف پاسخ لایه‌های روسازی تحت اثر بار ترافیکی استفاده کرد. این پارامتر مهم‌ترین ویژگی مصالح خاک بستر، زیراساس و اساس برای توصیف رفتار بارگذاری تکراری مصالح در سازه روسازی است. مدل‌های مختلفی برای پیش‌بینی مدول برجهندگی مصالح

مدول برجهندگی به‌عنوان یکی از مهم‌ترین مشخصات مصالح راه‌سازی هم در روش‌های تجربی (مانند روش اشتو ۱۹۹۳) و هم در روش‌های مکانیستیک-تجربی (مانند روش MEPDG) طراحی روسازی مورد نیاز است. مدول برجهندگی به‌صورت نسبت تنش انحرافی اعمال‌شده به کرنش محوری برگشت‌پذیر تحت بار

مطابق مطالعات گذشته، با افزایش تنش محدودکننده، مدول برجهندگی خاک‌های دانه‌ای افزایش می‌یابد (Lekarp, Isacsson, and Dawson 2000; Pezo and Hudson 1994; Rada and Witczak 1981; Saha et al. 2018b; Seed, Chan, and Lee 1962; Thompson and Robnett 1979). همچنین مدول برجهندگی مصالح دانه‌ای با افزایش تنش انحرافی ارتباط مستقیم دارد، که بیشتر نشان‌دهنده سخت‌شدگی کرنشی در نتیجه تغییر جهت دانه‌ها در حالت متراکم‌تر است (Maher et al. 2000).

تحقیقات زیادی در زمینه مهندسی روسازی با استفاده از روش‌های پیشرفته‌ای مانند مدل‌های رگرسیونی و آماری (Mohammad et al. 1999; Solanki, Ebrahimi, and M. 2008).

مدل‌های ارائه‌شده با استفاده از شبکه‌های عصبی (A R Ghanizadeh and Rahrovan 2016; S. H. Kim, Yang, and Jeong 2014; Solanki, Ebrahimi, and M. 2008; Vadood, Johari, and Rahai 2015)، و مدل‌های توسعه‌یافته با استفاده از سایر روش‌های هوش محاسباتی و تکاملی (Nazzal and Tatarsi 2013; Pal and Deswal 2014; Sadrossadat, Heidariapanah, and Ghorbani 2018). انجام‌شده است. همچنین مدل‌های آماری و هوش محاسباتی متعددی در زمینه پیش‌بینی مدول برجهندگی مصالح ریزدانه توسعه داده شده است (de Freitas, de Rezende, and Gitirana 2020; Ali Reza Ghanizadeh and Amlashi 2018; Khasawneh and Al-jamal 2019; S. H. Kim, Yang, and Jeong 2014; Nazzal and Mohammad 2010; Pezo and Hudson 1994; Yao et al. 2018) که تحقیقات کمتری در زمینه پیش‌بینی مدول برجهندگی مصالح درشت‌دانه انجام شده است (Gu et al. 2015, 2016; Ren and Vanapalli 2018; Saha et al. 2018b; Soliman and Shalaby 2016; Titi and Matar 2018).

پارک و همکاران (۲۰۰۹) از شبکه عصبی مصنوعی برای پیش‌بینی مدول برجهندگی بستر غیر چسبنده و زیراساس سنگدانه‌ای استفاده کردند. آن‌ها از ۱۹۰ داده برای زیراساس و ۲۷۲ داده برای بستر به منظور مدل‌سازی استفاده کردند و در مجموع ۹ مدل جداگانه بر اساس پارامترهای ورودی مختلف برای بستر و زیراساس ساخته شد (H. I. Park, Kweon, and Lee 2009). ساحا و همکاران (۲۰۱۸) مجموعه‌ای از مدل‌های شبکه عصبی مصنوعی را برای پیش‌بینی مدول برجهندگی مصالح سنگدانه‌ای توسعه دادند. مدل‌های ANN توسعه‌یافته از هفت متغیر ورودی، ده نرون در لایه پنهان و یک متغیر خروجی تشکیل شده بودند. مقادیر  $M_R$  برآورد شده با داده‌های تجربی جمع‌آوری شده از LTPP مقایسه شدند که مقدار  $R^2$  بیش از ۰/۹ را نشان می‌داد. این دقت بسیار

غیر چسبنده با استفاده از تنش حجمی، تنش انحرافی یا ترکیبی از آن‌ها پیشنهاد شده است (Dragos Andrei et al. 2004; Uzan 1985). متداول‌ترین آزمایش برای تعیین مدول برجهندگی در آزمایشگاه، آزمایش سه محوری دینامیکی تحت اثر تنش‌های محدودکننده و تنش‌های انحرافی مختلف است که بسیار وقت‌گیر و پرهزینه است. باین‌حال مطالعات زیادی برای تعیین مدول برجهندگی ( $M_R$ ) مصالح مختلف سنگدانه‌ای و خاک بستر انجام شده است (Ghanizadeh and Amlashi 2018; Khasawneh 2005; Nazzal and Mohammad 2010; Ozsahin and Oruc 2008; Pourtahmasb, Karim, and Shamsirband 2015; Shafabakhsh and Tanakizadeh 2015).

به‌طور کلی، مدل‌های تعیین  $M_R$  را می‌توان به دودسته تقسیم کرد: (۱) مدل‌های مبتنی بر همبستگی تجربی و (۲) مدل‌های وابسته به تنش. متداول‌ترین مدل‌های مبتنی بر همبستگی تجربی شامل رابطه بین  $M_R$  و CBR یا رابطه بین  $M_R$  و مقدار مقاومت ( $R$ -Value) هستند. از آنجاکه این مدل‌ها قادر به شبیه‌سازی بار دینامیکی ترافیک نیستند، منسوخ شده‌اند. مدل‌های  $M_R$  وابسته به تنش عمدتاً در قالب مدل‌های ریاضی مانند مدل تنش حجمی برای خاک‌های درشت‌دانه و مدل تنش انحرافی برای خاک‌های چسبنده به کار می‌روند. در اکثر این مدل‌ها، مدول برجهندگی به یک متغیر مانند تنش انحرافی (Moossazadeh and Witczak 1981)، تنش محدودکننده (Dunlap 1963) و یا تنش حجمی (Seed, Chan, and Lee 1962) یا به دو متغیر مانند تنش انحرافی و تنش محدودکننده (Ni et al. 2002)، تنش حجمی و تنش انحرافی (D. Andrei et al. 2004) و یا تنش حجمی و تنش برشی هشت‌وجهی (D. Andrei et al. 2004) مرتبط شده است.


درک عوامل مؤثر بر مدول برجهندگی برای برآورد دقیق این پارامتر به دلیل تغییر در الگوی ترافیک و شرایط محیطی بسیار مهم است (H. M. Park et al. 2013; Xiao and Amirkhani 2008; Zhou et al. 2015). بر این اساس، مطالعات زیادی انجام گرفته است که عمده پارامترهای تأثیرگذار بر روی مدول برجهندگی را به صورت بار اعمال‌شده، شرایط تنش و خصوصیات فیزیکی، درصد رطوبت و مکش خاک پیشنهاد کرده‌اند (Amiri, Nazarian, and Fernando 2009; Drumm, Boateng-Poku, and Pierce 1990; D. G. Kim 2014; Malla and Joshi 2008; Rahim 2005; Smart and Humphrey 1999; Yau and Quintus 2002; Zhou et al. 2015).

برجهنگی بهره گرفته شده است.

## ۲- معرفی روش ها و الگوریتم ها

### ۲-۱- روش شبکه عصبی موجک

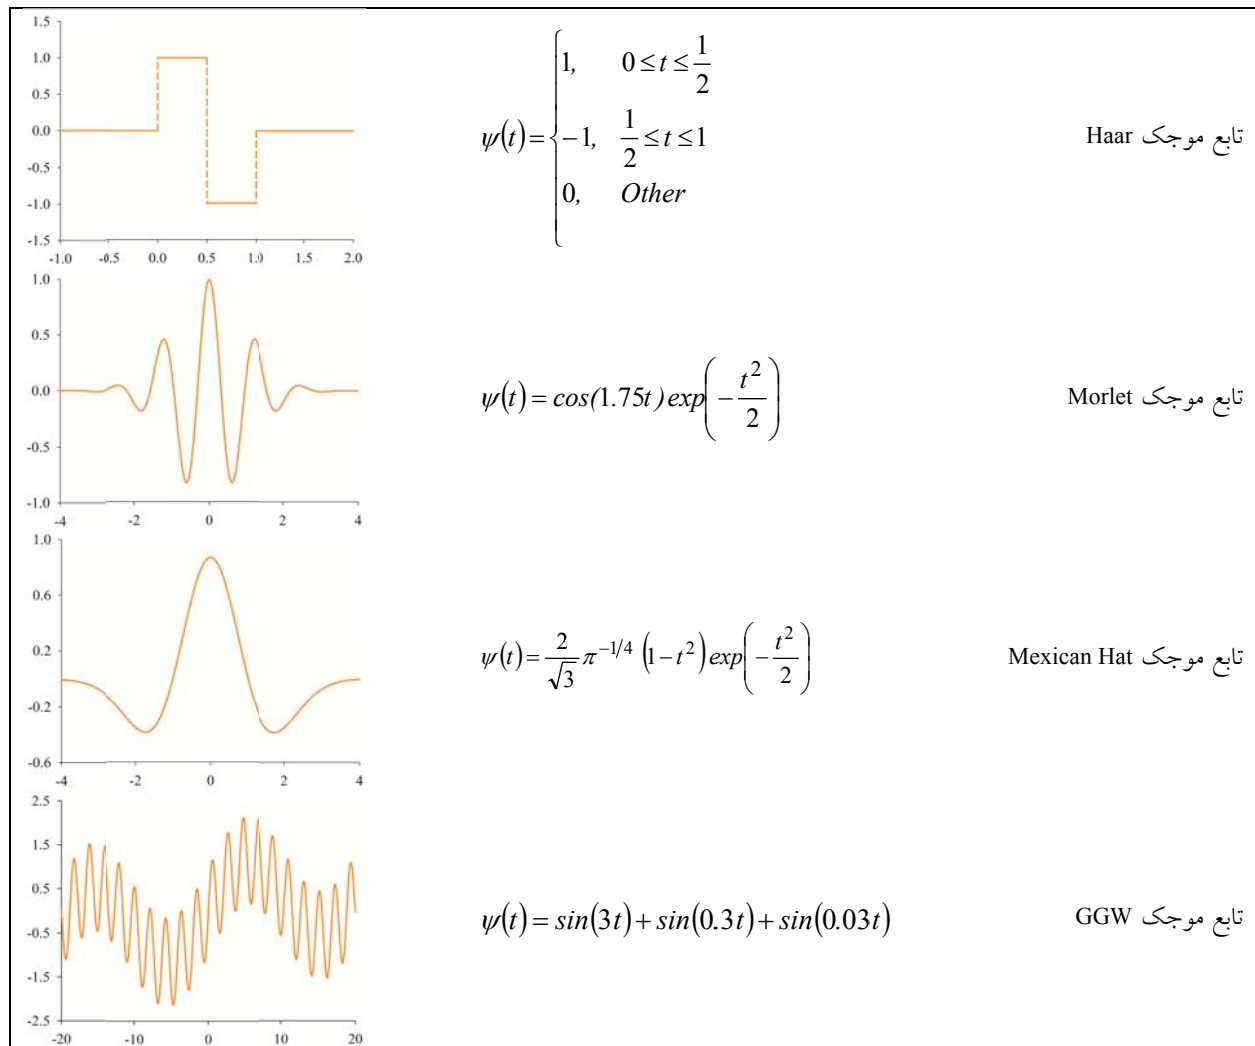
نظریه موجک نخستین بار در دهه ۱۹۸۰ توسط گروسمن و مورلت پیشنهاد شد (Grossmann and Morlet 1984). نظریه موجک یک نظریه و روش تجزیه و تحلیل ریاضی است تا کمبودهای تبدیل فوریه را برطرف کند. در زمینه پردازش سیگنال، بیشترین روش تجزیه و تحلیل استفاده شده، تبدیل فوریه است، اما نقص آشکار آن عدم تشخیص در دامنه زمان است؛ زیرا اطلاعات زمانی در نتایج تبدیل فوریه درج نمی شوند. اصطلاح شبکه عصبی موجک<sup>۴</sup> (WNN) یا شبکه موجک (WN) ترکیبی از شبکه عصبی تبدیل موجک است که مزایای شبکه عصبی و تبدیل موجک را به ارث می برد. WNN در سال ۱۹۹۲ توسط Zhang پیشنهاد شد (Zhang and Benveniste 1992)، که در آن به جای تابع فعال سازی Sigmoid از تابع موجک به عنوان تابع فعال سازی استفاده می شود. توپولوژی شبکه عصبی موجک در شکل (۱) نشان داده شده است.



شکل ۱. توپولوژی شبکه عصبی موجک  
(Wang, Guo and Duan 2013)

بیشتر از دقت  $M_R$  محاسبه شده با استفاده از مدل های رگرسیون بود (Saha et al. 2018a). رن و همکاران (۲۰۱۸) یک مدل رگرسیونی با تابع هایپربولیک را برای پیش بینی مدول برجهنگی مصالح دانه ای در شرایط دمایی زیر صفر توسعه دادند. ۱۸ داده آزمایشگاهی مختلف شامل مصالح ریزدانه و درشت دانه، در هر دو شرایط اشباع و غیراشباع برای اعتبارسنجی مدل پیشنهادی استفاده شد. نتایج این تحقیق نشان داد که مدل پیشنهادی می تواند به خوبی مدول برجهنگی خاک های مورد بررسی را در حالت منجمد پیش بینی کند (Ren and Vanapalli 2018). الاشوا و همکاران (۲۰۱۹) مدل Master Surface-2018 را برای پیش بینی مدول برجهنگی مصالح درشت دانه، مصالح تثبیت شده و مصالح بستر توسعه دادند. در مجموع ۲۷۵۴ مدول برجهنگی آزمایشگاهی برای ۵ نوع مصالح درشت دانه، ۴ نوع مصالح بستر، یک مصالح خرده بتنی بازیافتی و سه نوع خاک تثبیت شده با سیمان تهیه گردید تا مدل پیشنهادی ارزیابی و اعتبارسنجی گردد. نتایج به دست آمده از روش پیشنهادی و روش های موجود گویای آن بود که مدل مذکور دقیق ترین و بی طرفانه ترین پیش بینی را دارد (El-Ashwah et al. 2019).

همان گونه که ملاحظه می شود، در تحقیقاتی که تاکنون به منظور پیش بینی مدول برجهنگی مصالح خاکی انجام شده است، عمدتاً شاهد به کارگیری یک روش و عدم مقایسه روش های گوناگون با یکدیگر هستیم. همچنین در تعیین پارامترهای بهینه مدل های توسعه داده شده از روش های بهینه سازی فرا ابتکاری و تکاملی استفاده نشده است. به علاوه بیشتر تحقیقات بر کاربرد روش شبکه عصبی مصنوعی در پیش بینی مدول برجهنگی خاک های ریزدانه و درشت دانه متمرکز شده اند. در تحقیق حاضر از ترکیب روش شبکه عصبی موجک و الگوریتم مبتنی بر آموزش و یادگیری به منظور پیش بینی مدول برجهنگی مصالح زیراساس استفاده شده است. همچنین از روش اعتبارسنجی خارجی<sup>۲</sup> برای تعیین دقت پیش بینی مدل ها و از تحلیل عدم قطعیت مونت کارلو برای تعیین عدم قطعیت تصادفی مدل ها استفاده شده است. به علاوه در این تحقیق از تحلیل حساسیت به روش دامنه کسینوس<sup>۳</sup> (CAM) برای شناسایی مهم ترین پارامترها در پیش بینی مدول



شکل ۲. توابع موجک

که  $(j)$  مقدار خروجی برای گره  $z$  در لایه مخفی،  $\omega_j$  وزن اتصال گره  $z$  از لایه مخفی به لایه خروجی و  $m$  تعداد گره‌ها در لایه مخفی است (Wang, Guo and Duan 2013).

هنوز انتخاب توابع موجک مادر به صورت یک نظریه استاندارد شکل نگرفته است. توابع موجکی که معمولاً مورد استفاده قرار می‌گیرند عبارت‌اند از Haar, Mexican Hat, Morlet, GGW, Coiflet, Meryer و غیره. رابطه و شکل برخی از توابع ویولت در شکل (۲) آورده شده است.

## ۲-۲- الگوریتم مبتنی بر آموزش و یادگیری TLBO<sup>۷</sup>

در حالت کلی روش‌های بهینه‌سازی را می‌توان به دو گروه روش‌های ریاضی و الگوریتم‌های فرا ابتکاری تقسیم کرد. معمولاً

در شکل ۱ بردارهای  $x_1, x_2, \dots, x_n$  بردار متغیرهای ورودی،  $y$  مقدار پیش‌بینی شده،  $\omega_{kj}$  و  $\omega_{ij}$  وزن اتصال هر لایه و  $h_j$  تابع موجک مادر است. برای بردار ورودی  $x = (x_1, x_2, \dots, x_n)$  خروجی لایه پنهان مطابق رابطه (۱) محاسبه می‌شود.

$$h(j) = h_j \left[ \frac{\sum_{i=1}^n \omega_{ij} x_i - \tau_j}{d_j} \right], \quad j = 1, 2, \dots, m \quad (1)$$

که در آن  $(j)$  مقدار خروجی برای گره  $z$  در لایه پنهان،  $h_j$  تابع موجک مادر،  $\omega_{ij}$  وزن اتصال لایه ورودی و لایه پنهان،  $\tau_j$  مقدار پارامتر انتقال<sup>۸</sup> و  $d_j$  مقدار پارامتر اتساع<sup>۹</sup> برای تابع موجک  $h_j$  است. خروجی لایه خروجی به صورت رابطه (۲) محاسبه می‌شود:

$$y = \sum_{j=1}^m \omega_j h(j) \quad (2)$$

بین میانگین نتایج موجود در هر موضوع و نتیجه مربوط به معلم برای هر موضوع توسط رابطه (۳) محاسبه می‌شود:

$$Difference\_Mean_{j,k,i} = r_i (X_{j,kbest,i} - T_F M_{j,i}) \quad (3)$$

که،  $X_{j,kbest,i}$  نتیجه بهترین دانش‌آموز برای موضوع  $Z$  است.  $T_F$  ضریب آموزش است که مقدار تغییر میانگین را کنترل می‌کند و  $r_i$  عدد تصادفی در محدوده  $[0, 1]$  است. بر اساس  $Difference\_Mean_{j,k,i}$  جواب به‌دست‌آمده در مرحله معلم مطابق رابطه (۴) به‌روزرسانی می‌شود:

$$X'_{j,k,i} = X_{j,k,i} + Difference\_Mean_{j,k,i} \quad (4)$$

اگر مقدار تابع هدف به ازای  $X'_{j,k,i}$  بهتر از  $X_{j,k,i}$  باشد، این مقدار پذیرفته می‌شود. تمام مقادیر تابع پذیرفته‌شده در پایان مرحله معلم حفظ و این مقادیر ورودی مرحله دانش‌آموز می‌شوند.

دومین فاز از الگوریتم، فاز دانش‌آموز است که دانش‌آموزان با تعامل میان خود دانش خود را افزایش می‌دهند. در این مرحله هر دانش‌آموز به‌منظور افزایش دانش خود به‌طور تصادفی با دیگر دانش‌آموزان در تعامل است و در صورتی‌که سایر دانش‌آموزان دانش بیشتری داشته باشند، دانش‌آموز موردنظر چیزهای جدیدی از آن‌ها فرامی‌گیرد. فرض کنید در یک جمعیت  $n$  تایی، به‌طور تصادفی دو دانش‌آموز  $P$  و  $Q$  انتخاب می‌شوند که  $X'_{total-P,i} \neq X'_{total-Q,i}$  است، به‌طوری‌که  $X'_{total-P,i}$  و  $X'_{total-Q,i}$  به ترتیب جواب به‌روزرسانی شده  $X_{total-P,i}$  و  $X_{total-Q,i}$  برای  $P$  و  $Q$  در پایان مرحله معلم است.

در این حالت جواب به‌دست‌آمده در مرحله دانش‌آموز مطابق رابطه (۵) و (۶) به‌روزرسانی می‌شود:

$$X''_{j,P,i} = X'_{j,P,i} + r_i (X'_{j,P,i} - X'_{j,Q,i}) \quad (5)$$

$$\text{if } X'_{total-P,i} < X'_{total-Q,i}$$

$$X''_{j,P,i} = X'_{j,P,i} + r_i (X'_{j,Q,i} - X'_{j,P,i}) \quad (6)$$

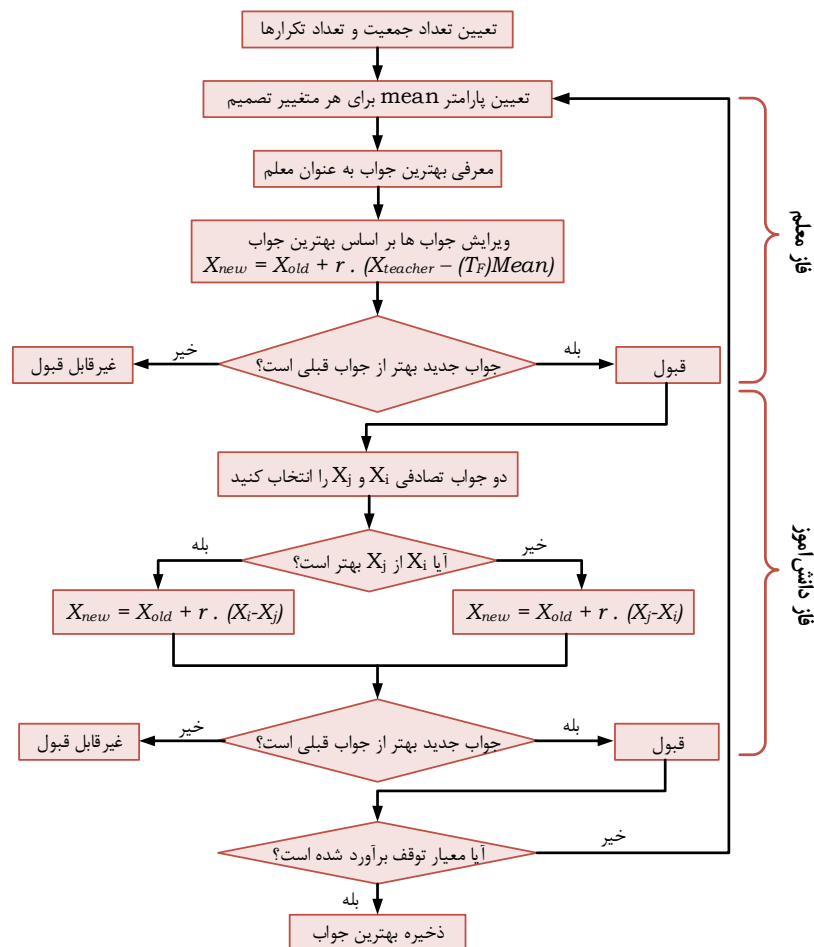
$$\text{if } X'_{total-Q,i} < X'_{total-P,i}$$

اگر مقدار تابع هدف به ازای  $X''_{j,P,i}$  بهتر از  $X'_{j,k,i}$  باشد، این مقدار پذیرفته می‌شود (Venkata Rao 2016). شکل ۳ فلوجارت الگوریتم بهینه‌سازی مبتنی بر آموزش و یادگیری را نشان می‌دهد.

از روش‌های ریاضی برای حل مسائل مهندسی استفاده نمی‌شود، چراکه این روش‌ها به یک نقطه شروع خوب برای همگرایی نیاز دارند تا در دام بهینه محلی نیفتند (Kaveh and Mahdavi 2013). در مقابل الگوریتم‌های فرا ابتکاری در دامنه وسیعی از مسائل مهندسی به کار گرفته‌شده‌اند (Fatemi Aghda and Mirfakhraei 2020; Ghanizadeh and Heidarabadi 2018; Ghanizadeh, Heidarabadi, and Mahmoodabadi 2020; Hanandeh, Ardah, and Abu-Farsakh 2020; Panda and Swamy 2018; Vaitkus et al. 2019). از جمله مهم‌ترین الگوریتم‌های فرا ابتکاری می‌توان به الگوریتم ژنتیک (Holland 1975)، الگوریتم ازدحام ذرات (Eberhart and James Kennedy 1999)، الگوریتم کلونی مورچه (Dorigo, Maniezzo, and Colomi 1996) و الگوریتم کرم شب‌تاب (X. Yang 2010) اشاره کرد.

الگوریتم بهینه‌سازی مبتنی بر آموزش و یادگیری اولین بار در سال ۲۰۱۱ توسط رائو و همکاران ارائه شد (Rao, Savsani, and Vakharia 2011). این الگوریتم از فرآیند آموزش-یادگیری الهام گرفته شده است و بر اساس تأثیر معلم بر خروجی دانش‌آموزان یک کلاس پایه‌ریزی شده است. این الگوریتم دو شیوه اصلی یادگیری را توصیف می‌کند که شامل یادگیری از طریق معلم (معروف به فاز معلم) و یادگیری از طریق تعامل با سایر دانش‌آموزان (معروف به فاز دانش‌آموز) است. در این الگوریتم، گروهی از دانش‌آموزان به‌عنوان یک جمعیت در نظر گرفته‌شده و موضوعات مختلفی که به دانش‌آموزان ارائه می‌شود به‌عنوان متغیرهای تصمیم مسئله بهینه‌سازی در نظر گرفته می‌شوند. نتیجه دانش‌آموزان به‌عنوان تابع هدف مسئله بهینه‌سازی در نظر گرفته می‌شود. بهترین جواب در کل جمعیت به‌عنوان معلم در نظر گرفته می‌شود. همان‌گونه که پیش‌تر گفته شد، الگوریتم TLBO از دو فاز "معلم" و "دانش‌آموز" تشکیل شده است.

در فاز معلم، یک معلم سعی می‌کند بسته به توانایی خود، دانش کلاس را در موضوعی که توسط او تدریس می‌شود، افزایش دهد. در هر تکرار،  $t$  فرض بر این است که تعداد  $m$  متغیر تصمیم وجود داشته باشد و تعداد دانش‌آموزان (جمعیت) برابر با  $n$  باشد ( $k=1, \dots, n$ ) و  $M_{j,i}$  میانگین نتیجه دانش‌آموزان در یک موضوع خاص  $Z$  ( $j=1, \dots, m$ ) باشد؛ بهترین نتیجه کلی  $X_{total-kbest}$  با توجه به کلیه موضوعاتی که در کل جمعیت دانش‌آموزان به‌دست‌آمده می‌تواند نتیجه بهترین دانش‌آموز  $k_{best}$  باشد. تفاوت



شکل ۳. فلوجارت الگوریتم مبتنی بر آموزش و یادگیری (Venkata Rao 2016)

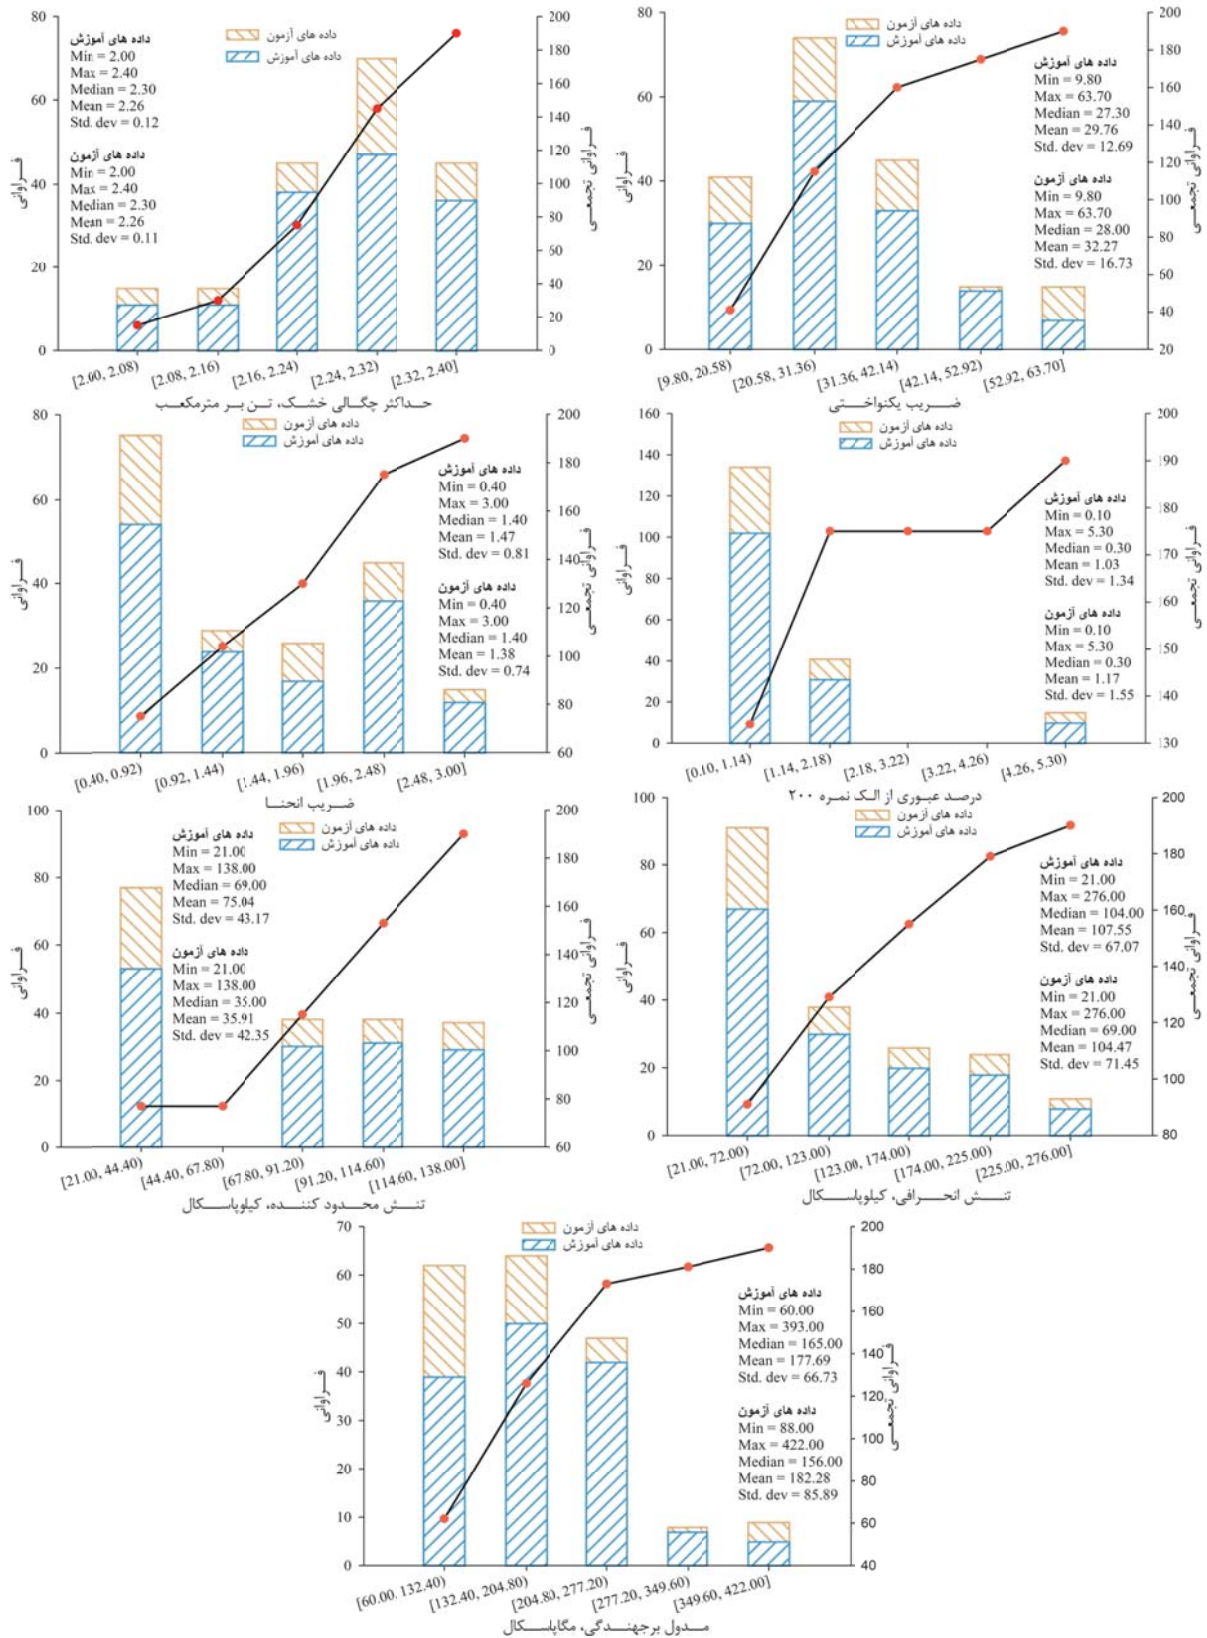
### ۳- پیش‌بینی مدول برجهندگی با استفاده از روش

#### WNN-TLBO

#### ۳-۱- داده‌های مورد استفاده در مدل‌سازی

در این تحقیق از داده آزمایشگاهی ارائه شده توسط پارک و همکاران استفاده شده است (H. I. Park, Kweon, and Lee 2009). در این تحقیق به منظور اندازه‌گیری مدول برجهندگی مصالح زیراساس از یک آزمایش بارگذاری سه محوری استاتیک مطابق پروتکل پیشنهادی کیم و همکاران استفاده شد (D. S. Kim, Kweon, and Rhee 2001). در روش پیشنهادی، مدول استاتیک یانگ با استفاده از تجهیزات آزمایش سه محوری در حالت کنترل کرنش با LVDT خارجی و یک سیستم سلول بارگذاری تعیین شد. در اندازه‌گیری‌ها از منحنی‌های بارگذاری - باربرداری استفاده شد. مقدار مدول سکانت با توجه به شیب خط و اصل بین مبدأ و منحنی

بارگذاری یا باربرداری تنش - کرنش در مقادیر کرنش‌های مختلف تعیین شد. کیم و همکاران نشان دادند که در محدوده مدول برجهندگی کمتر از ۳۵۰ مگاپاسکال، هر دو سیستم بارگذاری سه محوری استاتیک و بارگذاری دینامیکی نتایج قابل اطمینانی را برای مدول برجهندگی ارائه می‌دهند (D. S. Kim, Kweon, and Rhee 2001). به منظور تهیه نمونه‌ها، هر نمونه در ۵ لایه با وزن برابر به صورت استاتیکی مطابق با روش تراکم خاک‌های نوع II متراکم شدند (AASHTO, 1992). قطر نمونه‌ها تقریباً ۷۰ میلی‌متر با ارتفاع ۱۵۰ میلی‌متر بود (D. S. Kim, Kweon, and Rhee 2001). به‌طور کلی ۱۹۰ رکورد از ۱۳ نوع مختلف مصالح زیراساس در دسترس بود. ورودی‌های مدل‌سازی به صورت حداکثر چگالی خشک ((MDD (t/m3)، ضریب یکنواختی (Cu)،



شکل ۴: هیستوگرام فراوانی، فراوانی تجمعی و مشخصات آماری مصالح زیراساس

در حقیقت پارامترهای مربوط به شبکه عصبی موجک شامل وزن‌های اتصال لایه ورودی به لایه مخفی، وزن‌های اتصال لایه مخفی به لایه خروجی و پارامترهای *انتقال* و *انتقال* مربوط به هر نرون در لایه مخفی توسط الگوریتم TLBO و بر اساس داده‌های آموزش تعیین می‌شوند. این پارامترها به گونه‌ای تعیین می‌شوند که میانگین ریشه مربعات خطا بین مقادیر اندازه‌گیری شده و مقادیر پیش‌بینی شده توسط شبکه عصبی موجک حداقل گردد و از این طریق شبکه عصبی موجک بر اساس داده‌های آموزش و الگوریتم TLBO آموزش می‌بیند. ماتریس وزن‌های ورودی و خروجی و پارامترهای *انتقال* و *انتقال* مربوط به هر نرون در ضمیمه (ب) آورده شده است.

در این تحقیق از پارامترهای میانگین ریشه مربعات خطا (RMSE)، میانگین انحراف مطلق (MAE) و میانگین درصد خطای مطلق (MAPE)، به منظور ارزیابی عملکرد روش WNN-TLBO و از پارامتر  $R^2$  (ضریب تعیین) به منظور مقایسه مدول برجهدگی پیش‌بینی شده با مدول برجهدگی اندازه‌گیری شده استفاده شده است. این پارامترها به صورت زیر قابل تعیین می‌باشند.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (m_i - p_i)^2} \quad (7)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |m_i - p_i| \quad (8)$$

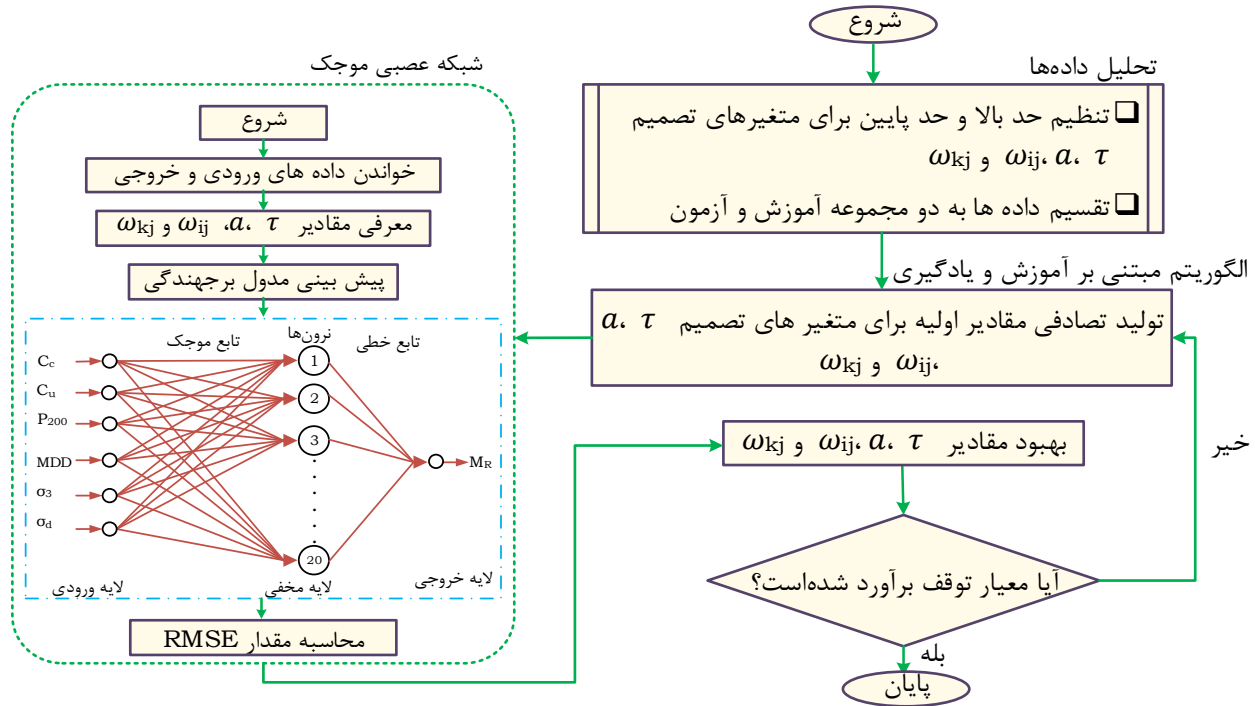
$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{m_i - p_i}{m_i} \right| \times 100 \quad (9)$$

$$R^2 = \left[ \frac{\frac{1}{N} \sum_{i=1}^N (m_i - \bar{m})(p_i - \bar{p})}{\sigma_m \cdot \sigma_p} \right]^2 \quad (10)$$

ضریب انحنای (Cc)، درصد عبوری از الک نم‌۲۰۰ (P<sub>200</sub>)، تنش محدودکننده ( $\sigma_3$  (kPa)) و تنش انحرافی ( $\sigma_d$  (kPa)) و خروجی مدل به صورت مدول برجهدگی ( $M_R$  (MPa)) در نظر گرفته شد. شکل (۴) نمودار فراوانی و فراوانی تجمعی را برای داده‌های زیراساس نشان می‌دهد.

### ۳-۲- مدل‌سازی مدول برجهدگی با استفاده از روش WNN-TLBO

در این مطالعه به منظور آموزش و آزمون شبکه عصبی موجک، برنامه‌ای در محیط MATLAB توسعه داده شد. برای این منظور ۷۵ درصد از داده‌ها به عنوان مجموعه آموزش و ۲۵ درصد از داده‌ها به عنوان مجموعه آزمون مورداستفاده قرار گرفت. به منظور تعیین توپولوژی بهینه شبکه عصبی موجک، تعداد نرون‌ها در لایه مخفی بین ۵ الی ۳۰ نرون در نظر گرفته شد. همچنین در لایه مخفی از چهار تابع فعال‌سازی Mexican Hat، Morlet، GGW و Haar و در لایه خروجی از تابع خطی استفاده گردید. نتایج مطالعات انجام‌شده نشان می‌دهد که افزایش تعداد نرون‌ها در لایه مخفی به تعداد بیشتر از ۲۰ نرون تأثیر چندانی بر روی افزایش دقت شبکه عصبی موجک ندارد. بنابراین شبکه عصبی با توپولوژی ۱-۲۰-۶ دارای دقت کافی جهت پیش‌بینی مدول برجهدگی است. ورودی‌های شبکه عصبی موجک شامل حداکثر چگالی خشک، ضریب یکنواختی، ضریب انحنای، درصد عبوری از الک نم‌۲۰۰، تنش محدودکننده و تنش انحرافی (۶ ورودی) و خروجی‌های شبکه عصبی شامل مدول برجهدگی (۱ خروجی) می‌باشد. فرایند مدل‌سازی با روش ترکیبی WNN-TLBO به همراه معماری بهینه شبکه در شکل (۵) آورده شده است. مقادیر ورودی، خروجی و خروجی پیش‌بینی شده در ضمیمه (الف) آورده شده است.



شکل ۵. دیاگرام فرایند ارائه شده برای مدل ترکیبی WNN-TLBO

شکل (۶) عملکرد روش WNN-TLBO را جهت پیش‌بینی مدول برجهندگی مصالح زیراساس بر اساس شبکه عصبی موجک بهینه بر اساس تابع انتقال Mexican Hat نشان می‌دهند. ملاحظه می‌شود که روش پیشنهادی امکان محاسبه مدول برجهندگی مصالح زیر اساس را با دقت بیش از ۰/۹۸ فراهم می‌کند.

### ۳-۳- مقایسه نتایج حاصل از WNN-TLBO با ANN

پارک و همکاران به منظور پیش‌بینی مدول برجهندگی مصالح زیراساس، ۱۰ مدل مختلف به ازای ورودی‌های مختلف توسط شبکه عصبی مصنوعی توسعه دادند که ورودی‌های بهترین مدل آن‌ها شامل حداکثر چگالی خشک (MDD (t/m<sup>3</sup>))، ضریب یکنواختی (Cu)، ضریب انحناء (Cc)، درصد عبوری از الک نمرة ۲۰۰ (P<sub>200</sub> (%))، تنش محدودکننده (σ<sub>3</sub> (kPa)) و تنش انحرافی (σ<sub>d</sub> (kPa)) و خروجی مدل، مدول برجهندگی (M<sub>R</sub> (MPa)) بود (H. I. Park, Kweon, and Lee 2009). جدول (۲) مقادیر R<sup>2</sup> را برای بهترین مدل شبکه عصبی توسعه داده شده توسط پارک و همچنین مدل ارائه شده در این تحقیق نشان می‌دهد.

N: تعداد داده‌ها جهت ارزیابی روش موردنظر.

m<sub>i</sub>: مقدار اندازه‌گیری شده برای داده i ام.

p<sub>i</sub>: مقدار پیش‌بینی شده برای داده i ام.

σ<sub>m</sub>: انحراف معیار داده‌های m.

σ<sub>p</sub>: انحراف معیار داده‌های p.

جدول (۱) مقادیر R<sup>2</sup> و RMSE را به ازای توابع موجک مختلف نشان می‌دهد.

جدول ۱. مقادیر R<sup>2</sup> و RMSE برای توابع مختلف موجک.

	آموزش		آزمون		
	R <sup>2</sup>	RMSE	R <sup>2</sup>	RMSE	
GGW	۰/۹۹۸۹	۲/۲۱۱۶	۰/۹۸۱۲	۱۲/۷۷۱۸	
Hat Mexican	۰/۹۹۹۲	۱/۸۸۰۳	۰/۹۸۲۵	۱۱/۹۰۸۷	
Morlet	۰/۹۹۸۵	۲/۶۰۹۳	۰/۹۷۴۶	۱۳/۷۱۴۱	
Haar	۰/۹۰۰۳	۲۱/۰۶۹۱	۰/۵۲۰۵	۶۰/۹۵۷۲	

همان‌طور که مشخص است دقت توابع موجک جهت پیش‌بینی مدول برجهندگی به صورت Morlet < GGW < Mexican Hat < Haar است.

## ۴- اعتبارسنجی مدل ها

### ۴-۱- اعتبارسنجی خارجی

در این تحقیق از روش اعتبارسنجی خارجی توسعه داده شده توسط تروپشا و همکاران برای تعیین دقت پیش‌بینی مدل موردنظر بر اساس عملکرد داده‌های آزمون استفاده شده است (Tropsha, Gramatica, and Gombar 2003). این روش رفتار نمونه‌های مستقل را برای ساخت یک مدل ارزیابی می‌کند. باین‌حال، شرطی وجود دارد که باید برآورده شود و آن وجود حداقل یک گرادیان خط رگرسیون بین داده‌های پیش‌بینی شده و مشاهده شده با مقدار نزدیک به ۱ است (Ashrafiyan et al. 2020).

$$K = \sum_{i=1}^n (MR_{obs} \times MR_{pre}) / MR_{pre}^2 \quad (11)$$

$$K' = \sum_{i=1}^n (MR_{obs} \times MR_{pre}) / MR_{obs}^2 \quad (12)$$

که  $MR_{pre}$  و  $MR_{obs}$  مقادیر مشاهده شده و پیش‌بینی شده مدول برجهندگی می‌باشند. با دانستن این واقعیت که ضریب تعیین خط باید کمتر از ۰/۱ باشد، پس پارامترهای  $m$  و  $n$  باید کمتر از ۰/۱ باشند.

$$m = (R^2 - R_0^2) / R^2 \quad (13)$$

$$n = (R^2 - R_0'^2) / R^2 \quad (14)$$

پارامتر  $R_m$  برای افزایش دقت پیش‌بینی خارجی مدل‌ها، مورد استفاده قرار می‌گیرد. طبق معادله (۱۵)، مقادیر  $R_m$  بیشتر از ۰/۵ قابل قبول است.

$$R_m = R^2 \times \left( 1 - \sqrt{|R^2 - R_0^2|} \right) > 0.5 \quad (15)$$

ضرایب تعیین بین داده‌های پیش‌بینی شده ( $R_0^2$ ) و داده‌های مشاهده شده ( $R_0'^2$ ) مطابق روابط (۱۶) و (۱۷) محاسبه می‌شوند.



$$R_0^2 = 1 - \frac{\sum_{i=1}^n MR_{pre}^2 (1 - K)^2}{\sum_{i=1}^n (MR_{pre} - \overline{MR}_{pre})^2} \quad (16)$$

$$R_0'^2 = 1 - \frac{\sum_{i=1}^n MR_{obs}^2 (1 - K')^2}{\sum_{i=1}^n (MR_{obs} - \overline{MR}_{obs})^2} \quad (17)$$

جدول ۲. مقایسه مقادیر  $R^2$  تعیین شده بر اساس روش شبکه عصبی

مصنوعی و روش شبکه عصبی موجک-TLBO		
مدل	$R^2$	
	آموزش	آزمون
شبکه عصبی مصنوعی	۰/۹۹۰۰	۰/۹۶۴۰
شبکه عصبی موجک-TLBO	۰/۹۹۹۲	۰/۹۸۲۵

همان‌طور که ملاحظه می‌شود روش WNN-TLBO در مقایسه با روش ANN دارای دقت بیشتری در پیش‌بینی مدول برجهندگی مصالح خاک بستر غیر چسبنده و مصالح زیراساس است.



شکل ۶. عملکرد شبکه عصبی موجک برای پیش‌بینی مدول برجهندگی مصالح اساس (الف) مجموعه آموزش، (ب) مجموعه آزمون

میانه ( $MADM$ ) را می‌توان با استفاده از معادله زیر به دست آورد.

$$MADM = \frac{1}{n} \sum_{i=1}^n |P_i - Median(P)| \quad (21)$$

$MADM$  محاسبه شده برای یافتن عدم قطعیت مدل با توجه به معادله زیر استفاده می‌شود (Walker 1929):

$$Uncertainty = \frac{100 \times MADM}{Median(P)} \quad (22)$$

جدول (۴) نتایج تحلیل عدم قطعیت در این مطالعه را نشان می‌دهد. در تحلیل عدم قطعیت، مقدار متوسط منفی به پیش‌بینی دست پایین پارامتر موردنظر و مقدار مثبت به پیش‌بینی دست بالای پارامتر موردنظر در تخمین اشاره دارد (Ashraffian et al. 2020). مقدار  $MADM$  برای هر مدل خاص درصدی از مقدار متوسط آن است. وربیک و همکاران (2006) نشان دادند که مقادیر کمتر از ۳۵ درصد برای تخمین عدم قطعیت مدل‌ها قابل قبول است (Verbeeck et al. 2006).

جدول ۴. تحلیل عدم قطعیت مونت کارلو

پارامتر	اختصار	مقدار
میانگین محاسبه شده	$\bar{e}$	۰/۱۴۲۶
انحراف معیار	$S_e$	۰/۱۴۳۱
میانه	$Median$	۱۶۷/۱۶۲۷
میانگین انحراف مطلق از میانه	$MADM$	۵۵/۷۶۲۰
عدم قطعیت	$Uncertainty$	۳۳/۳۵۸۰

## ۵- تجزیه و تحلیل پارامترهای ورودی از نظر آماری

### ۵-۱- تحلیل حساسیت

در این تحقیق از روش دامنه کسینوس (CAM) برای تعیین تأثیر هر یک از متغیرها بر خروجی پیش‌بینی شده با استفاده از شاخص درجه حساسیت مربوط به هر متغیر ورودی استفاده شده است (Y. Yang and Zhang 1997). این شاخص را می‌توان با استفاده از رابطه (۲۳) بین داده‌های ورودی و خروجی به دست آورد. درجه حساسیت را می‌توان با استفاده از معادله زیر محاسبه کرد:

$$R_i = \frac{\sum_{j=1}^n x_{ij} y_j}{\sqrt{\sum_{j=1}^n x_{ij}^2 \sum_{j=1}^n y_j^2}} \quad (23)$$

که  $x_{ij}$  مقدار  $i^{th}$  مین متغیر مستقل را برای  $i^{th}$  داده نشان می‌دهد

جدول (۳) نتایج اعتبارسنجی خارجی پارامترهای آماری را برای مدل توسعه داده شده نشان می‌دهد. همان‌گونه که ملاحظه می‌شود، کلیه معیارهای مربوط به اعتبارسنجی خارجی در محدوده قابل قبول ذکر شده قرار دارند و بنابراین مدل توسعه داده شده بر اساس روش WNN-TLBO قابل اطمینان است.

جدول ۳. نتایج آماری اعتبارسنجی خارجی.

پارامتر	مقدار قابل قبول	مقدار به دست آمده
R	(R>0.8)	۰/۹۹۱۲
K	(0.85<K<1.15)	۱/۰۰۶۲
K'	(0.85<K'<1.15)	۰/۹۹۰۴
M	(m<0.1)	-۰/۰۱۷۶
N	(n<0.1)	-۰/۰۱۷۳
R <sub>m</sub>	(R <sub>m</sub> >0.5)	۰/۸۵۳۴

### ۴-۲- تحلیل عدم قطعیت مونت کارلو<sup>۸</sup>

از تحلیل عدم قطعیت (MCS) می‌توان به‌طور مؤثر برای تعیین عدم قطعیت تصادفی یک مدل استفاده کرد. عدم قطعیت در مدل‌های پیش‌بینی می‌تواند ناشی از متغیرهای ورودی یا پارامترهای مدل باشد. معادلات (۱۸) الی (۲۰) نشان‌دهنده خطای هر یک از پارامترهای ورودی در پیش‌بینی مدول برچهندگی کل مجموعه داده‌ها به‌صورت میانگین محاسبه شده ( $\bar{e}$ ) و انحراف معیار ( $S_e$ ) خطای محاسبه شده می‌باشند (Ashraffian et al. 2020).

$$e_i = \log_{10}(MR_{pre}) - \log_{10}(MR_{obs}) \quad (18)$$

$$\bar{e} = \sum_{i=1}^n e_i \quad (19)$$


$$S_e = \sqrt{\sum_{i=1}^n \left( \frac{e_i - \bar{e}}{n-1} \right)^2} \quad (20)$$

که در این روابط،  $n$  تعداد داده‌ها،  $MR_{pre}$  و  $MR_{obs}$  به ترتیب مقدار  $MR$  پیش‌بینی شده و اندازه‌گیری شده برای تمامی داده‌ها می‌باشد. به‌منظور حذف فرایند تصحیح پیوستگی بر روی خطاهای به‌دست‌آمده، باید یک محدوده اطمینان برای خطاها تعریف شود. استفاده از مقادیر  $\bar{e}$  و  $S_e$  در روش امتیاز ویلسون می‌تواند این نیاز را برآورده کند (Newcombe RG 1998). میانگین انحراف مطلق از

## ۵-۲- تحلیل پارامتریک

محدودیت‌های زمانی و امکانات کم معمولاً موانع اصلی انجام مطالعات آزمایشگاهی هستند. ارزیابی تأثیر هر یک از متغیرها بر نتایج تجربی نیاز به ساخت نمونه‌های زیادی دارد که می‌تواند زمان‌بر بوده و هزینه زیادی را در پی داشته باشد. استفاده از مدل‌های پیش‌بینی کننده امکان انجام تحلیل پارامتریک را برای مطالعه تأثیر متغیرهای ورودی بر متغیر خروجی فراهم می‌کند. در این مطالعه، از طریق تحلیل پارامتریک، اندرکنش پارامتر حداکثر چگالی خشک (MDD) با پارامترهای ضریب یکنواختی (Cu)، درصد عبوری از الک نمره ۲۰۰ (P200) و ضریب انحنا (Cc) بر روی مدول برجهندگی مورد بررسی قرار داده شده، همچنین اثرات تنش محدودکننده و تنش انحرافی بر روی مدول برجهندگی با تغییر متغیرهای مورد نظر و قرار دادن سایر متغیرهای برابر با مقدار میانگین بررسی شده است. شکل (۸-الف) برهمکنش حداکثر چگالی خشک و ضریب یکنواختی را روی مدول برجهندگی نشان می‌دهد. همان‌طور که ملاحظه می‌شود هر دو پارامتر تأثیر افزایشی بر مدول برجهندگی دارند. همچنین دیده می‌شود که تأثیر حداکثر چگالی خشک بر مدول برجهندگی در مقادیر بالای ضریب یکنواختی کمتر از تأثیر در مقادیر پایین ضریب یکنواختی است. نیکرک و همکاران نشان دادند که مصالح خوب دانه‌بندی شده در مقایسه با مصالح با دانه‌بندی یکنواخت مدول برجهندگی بالاتری دارند (Niekerc et al. 1998). تأثیر حداکثر چگالی خشک و ضریب انحنا در شکل (۸-ب) نشان داده شده است. همان‌طور که ملاحظه می‌شود افزایش حداکثر چگالی خشک باعث افزایش مدول برجهندگی می‌شود. این افزایش در مقادیر بالای ضریب انحنا بیشتر است، اما افزایش ضریب انحنا سبب کاهش مدول برجهندگی می‌شود به گونه‌ای که کاهش مدول در مقادیر پایین حداکثر چگالی خشک بیشتر به چشم می‌خورد. شکل (۸-ج) تأثیر حداکثر چگالی خشک و درصد عبوری از الک نمره ۲۰۰ را روی مدول برجهندگی نشان می‌دهد. همان‌طور که ملاحظه می‌شود در مقادیر پایین حداکثر چگالی خشک افزایش درصد عبوری از الک نمره ۲۰۰ باعث افزایش مدول و در مقادیر بالای حداکثر چگالی خشک افزایش درصد عبوری از الک نمره ۲۰۰ باعث کاهش مدول می‌گردد. تحقیقات قبلی هم تأثیر منفی (Farrar and Turner 1994; Santha 1991) و هم تأثیر مثبت (Rahim, 2005; Drumm





و  $R_i$  مقدار متغیر وابسته برای  $i$  داده را نشان می‌دهد (مشابه  $x_{ij}$ ) (Ali Reza Ghanizadeh et al. 2019). برای تخمین ارتباط بین داده‌های ورودی و خروجی، مقدار  $R_i$  باید نزدیک به ۱ باشد، درحالی‌که  $R_i$  با مقدار صفر عملاً امکان استخراج یک همبستگی را از بین می‌برد. شکل ۷ میزان اهمیت متغیرها را بر اساس نتایج حاصل از مقادیر اندازه‌گیری شده و پیش‌بینی شده به روی مدول برجهندگی مصالح زیراساس را نشان می‌دهد. همان‌طور که ملاحظه می‌شود به ترتیب تأثیر  $\sigma_3 < MDD < Cu < \sigma_d < Cc < P_{200}$  بر روی مدول برجهندگی بیشتر است. بنابراین می‌توان دید که در بین متغیرهای مصالح زیر اساس، مهمترین پارامتر تأثیرگذار بر مدول برجهندگی وزن مخصوص خشک حداکثر و کم اهمیت ترین پارامتر درصد عبوری از الک نمره ۲۰۰ است. همچنین از بین دو پارامتر مرتبط با سطح تنش، تأثیر تنش محدود کننده بر روی مدول برجهندگی مصالح زیراساس بیشتر از پارامتر تنش انحرافی است. همچنین مقدار اختلاف  $R_i$  بین مقادیر پیش‌بینی شده با مقادیر اندازه‌گیری شده برای مدول برجهندگی به ترتیب برای پارامترهای MDD، Cu، Cc،  $P_{200}$ ،  $\sigma_3$  و  $\sigma_d$  برابر  $0/24$ ،  $0/07$ ،  $0/36$ ،  $0/15$ ،  $0/09$  و  $0/26$  درصد است که این اختلاف کم نشان دهنده دقت بالای مدل توسعه داده شده به منظور پیش‌بینی مدول برجهندگی مصالح زیراساس سنگدانه‌ای است.



شکل ۷. پارامتر  $R_i$  برای هر یک از متغیرهای ورودی

درصد عبور از الک نمرة ۲۰۰ تأثیر دارد. شکل (۸-د) تأثیر تنش محدودکننده و تنش انحرافی را بر مدول برجهندگی نشان می‌دهد. همان‌طور که ملاحظه می‌شود تنش محدودکننده همواره باعث افزایش مدول برجهندگی می‌شود، درحالی‌که تنش انحرافی باعث افزایش مدول برجهندگی تا مقدار مشخص و سپس باعث کاهش مدول برجهندگی می‌شود. لازم به ذکر است با فرض ثابت بودن تنش انحرافی و افزایش تنش محدودکننده، تنش حجمی همواره افزایش می‌یابد. بنابراین می‌توان ادعا کرد که در یک تنش انحرافی ثابت، تأثیر تنش حجمی و تنش محدودکننده باهم یکسان است. برای مصالح سنگدانه‌ای مشخص شده است که افزایش تنش حجمی باعث افزایش مدول ارتجاعی می‌شود (Huang 2004; Papagiannakis 2008).

(Boateng-Poku, 1990) and درصد عبوری از الک نمرة ۲۰۰ بر مدول برجهندگی را نشان می‌دهد. این موضوع را می‌توان با استفاده از معادله فولر توضیح داد. این رابطه بیان می‌کند که برای یک دانه‌بندی مشخص، حداکثر چگالی و حداقل تخلخل بستگی به حداکثر اندازه دانه‌ها دارد. در حقیقت اضافه کردن ریزدانه تا یک مقدار مشخص چگالی خاک را افزایش و تخلخل بین ذرات درشت را کاهش می‌دهد که تأثیر مثبتی بر مدول برجهندگی دارد، اما استفاده بیش از ریزدانه تأثیر منفی بر روی چگالی و مدول برجهندگی دارد. همچنین، باید توجه داشت که در تحلیل پارامتریک فرض بر آن است که تمام پارامترها به‌جز پارامتر موردنظر ثابت‌اند که در عمل امکان‌پذیر نیست؛ زیرا مقادیر پارامترهای دیگر مانند چگالی، ضریب انحنای و ضریب یکنواختی بر



شکل ۸ تأثیر متغیرهای ورودی روی مدول برجهندگی. (الف) حداکثر چگالی خشک و ضریب یکنواختی (ب) حداکثر چگالی خشک و ضریب انحنای (ج) حداکثر چگالی خشک و درصد عبوری از الک نمرة ۲۰۰ و (د) تنش محدودکننده و تنش انحرافی

## ۶- نتیجه گیری

-نتایج اعتبار سنجی خارجی نشان می‌دهد که روش WNN-TLBO همه معیارهای لازم را برآورد می‌کند که دلالت بر پتانسیل پیش‌بینی بالای این روش دارد.

-مقدار MAD برای هر مدل خاص درصدی از مقدار متوسط آن است. درصدهای ذکرشده معادل ۳۳/۴ درصد است. مقادیر کمتر از ۳۵ درصد در محدوده قابل قبول برای تجزیه و تحلیل عدم قطعیت است.

-نتایج تحلیل حساسیت نشان می‌دهد که به ترتیب تأثیر  $\sigma_3 < MDD < Cu < \sigma_d < Cc < P_{200}$  بر روی مدول برجهندگی بیشتر است. همچنین مقدار اختلاف  $R_i$  بین مقادیر پیش‌بینی شده با مقادیر اندازه‌گیری شده برای مدول برجهندگی در تمامی موارد کمتر از ۰/۳۶ درصد است.

-نتایج تحلیل پارامتریک نشان می‌دهد که حداکثر چگالی خشک و ضریب یکنواختی تأثیر افزایشی بر مدول برجهندگی دارد. افزایش حداکثر چگالی خشک در مقادیر بالای ضریب انحنای باعث افزایش بیشتر مدول برجهندگی می‌شود، اما افزایش ضریب انحنای سبب کاهش مدول برجهندگی می‌شود. در مقادیر پایین حداکثر چگالی خشک، افزایش درصد عبوری از الک نمره ۲۰۰ باعث افزایش مدول و در مقادیر بالای حداکثر چگالی خشک، افزایش درصد عبوری از الک نمره ۲۰۰ باعث کاهش مدول می‌گردد. تنش محدودکننده همواره باعث افزایش مدول می‌شود، درحالی‌که تنش انحرافی تا یک مقدار مشخص باعث افزایش مدول برجهندگی و پس از آن باعث کاهش مدول برجهندگی می‌شود.

مدول برجهندگی مصالح غیر چسبنده یک پارامتر مهم در تحلیل و طراحی روسازی به روش مکانیستیک تجربی و ارزیابی عملکرد است. این پارامتر به‌عنوان اصلی‌ترین پارامتر برای بیان مقاومت و رفتار مصالح راه‌سازی مورد استفاده قرار می‌گیرد. در تحقیق حاضر از روش ترکیبی WNN-TLBO به‌منظور پیش‌بینی مدول برجهندگی مصالح بستر استفاده شده است. نتایج این تحقیق به شرح زیر قابل بیان است:

-به‌منظور توسعه و اعتبار سنجی روش WNN-TLBO، ۷۵٪ داده‌ها به‌عنوان داده آموزش و ۲۵٪ داده‌ها برای آزمایش و اعتبار سنجی در نظر گرفته شدند. همچنین مدلی با استفاده از روش WNN-TLBO برای مصالح زیراساس توسعه داده شد. ورودی‌های مدل شامل حداکثر وزن مخصوص خشک، ضریب یکنواختی، ضریب انحنای، درصد عبوری از الک نمره ۲۰۰، تنش محدودکننده و تنش انحرافی و خروجی مدل، مدول برجهندگی در نظر گرفته شد.

-برای تعیین تعداد نرون بهینه، تعداد آن‌ها از ۵ تا ۳۰ نرون در لایه مخفی تغییر یافت. نتایج مطالعه نشان داد که افزایش تعداد نرون‌ها به تعداد بیشتر از ۲۰ نرون تأثیر چندانی بر روی افزایش دقت شبکه عصبی موجک ندارد؛ بنابراین شبکه عصبی با معماری ۱-۲۰-۶ دارای دقت کافی در پیش‌بینی مدول لایه‌های زیراساس است.

-همچنین برای انتخاب بهترین تابع فعال‌سازی در لایه مخفی از چهار تابع Mexican Hat، Morlet، Haar و GGW استفاده شد. نتایج مطالعه نشان داد که به ترتیب قدرت  $\text{Mexican Hat} < \text{Morlet} < \text{GGW} < \text{Haar}$  است.

-مقدار  $R^2$  به‌دست‌آمده از روش ترکیبی WNN-TLBO برای مجموعه آموزش و آزمایش به ترتیب برابر با ۰/۹۹۹۲ و ۰/۹۸۲۸ به دست آمد که نشان از توانمندی روش ذکرشده در پیش‌بینی مدول برجهندگی مصالح غیر چسبنده است.

-از مقایسه نتایج به‌دست‌آمده بر اساس تحقیقات پارک و همکاران با روش ANN و نتایج به‌دست‌آمده از روش WNN-TLBO گویا این مطلب است که روش WNN-TLBO در مقایسه با روش ANN دارای دقت بیشتری در پیش‌بینی مدول برجهندگی است و این روش در اکثر موارد مقدار مدول برجهندگی را با درصد خطای کمتر از ۲۰ درصد پیش‌بینی می‌کند.

## ۷- پی‌نوشت‌ها

1. Resilient Modulus
2. External Validation
3. Cosine Amplitude Method
4. Wave late Neural Network
5. Translation
6. Dilation
7. Teacher Learning Based Optimization
8. Monte-Carlo Uncertainty Analysis

El-Badawy, and Alaa R. Gabr. (2019). A New Approach for Developing Resilient Modulus Master Surface to Characterize Granular Pavement Materials and Subgrade Soils. *Construction and Building Materials*, Vol. 194, No. 1. 372–85.

**doi.org/10.1016/j.conbuildmat.2018.10.212**

-Farrar M.J, J.P. Turner, (1991). Resilient Modulus of Wyoming Subgrade Soils. MPC Report No. 91-1, Laramie, Wyoming.

-Fatemi Aghda, Seyed Ali, and Mahdi Mirfakhraei. (2020). Improved Routing in Dynamic Environments with Moving Obstacles Using a Hybrid Fuzzy-Genetic Algorithm. *Future Generation Computer Systems*, Vol. 112, No. 1. 250–57.

**doi.org/10.1016/j.future.2020.05.024**

-Freitas, Jeferson Barbosa de, Lilian Ribeiro de Rezende, and Gilson de F N Gitirana. (2020). Prediction of the Resilient Modulus of Two Tropical Subgrade Soils Considering Unsaturated Conditions. *Engineering Geology*, Vol. 270, No. 1. 105580.

**doi.org/10.1016/j.enggeo.2020.105580.**

-Ghanizadeh, Ali Reza, and Amir Tavana Amlashi. (2018). Prediction of Fine-Grained Soils Resilient Modulus Using Hybrid ANN-PSO, SVM-PSO and ANFIS-PSO Methods. *Journal of Transportation Engineering*, Vol. 9, No. 35. 159–82.

-Ghanizadeh, Ali Reza, and Rahrovan Morteza. (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. 37–47.

-Ghanizadeh, Ali Reza, Hakime Abbaslou, Amir Tavana Amlashi, and Pourya Alidoust. (2019). Modeling of Bentonite/Sepiolite Plastic Concrete Compressive Strength Using Artificial Neural Network and Support Vector Machine. *Frontiers of Structural and Civil Engineering*, Vol. 13, No. 1. 215–39. **doi.org/10.1007/s11709-018-0489-z**

-Ghanizadeh, Ali Reza, Nasrin Heidarabadizadeh, and Mohammad Javad Mahmoodabadi. (2020). Effect of Objective Function on the Optimization of Highway Vertical Alignment by Means of Metaheuristic Algorithms Effect of Objective Function on the Optimization of Highway Vertical Alignment by Means of Metaheuristic Algorithms. *Journal of Civil Engineering Infrastructure*, Vol. 53, No. 1. 115–36. **doi.org/10.22059/cej.2019.279837.1578**

-Ghanizadeh, AR, and N Heidarabadizadeh. (2018). Optimization of Vertical Alignment of Highways in Terms of Earthwork Cost Using Colliding Bodies.

-AASHTO. (1992). Resilient Modulus of Unbound Granular Base/Subbase Materials and Subgrade Soils. *SHRP Protocol P 46*, Washington D.C.

-Amiri, Hassan, Soheil Nazarian, and Emmanuel Fernando (2009). Investigation of Impact of Moisture Variation on Response of Pavements through Small-Scale Models.” *Journal of Materials in Civil Engineering*, Vol. 21. No. 10. 553–60.

**doi.org/10.1061/(asce)0899-1561(2009)21:10(553).**

-Andrei, D., M. Witczak, C. Schwartz, and J. Uzan. (2004). Harmonized Test Methods for Laboratory Determination of Resilient Modulus for Flexible Pavement Design. *Journal of the Transportation Research Board*, Vol. 1874, No. 1. 29–37.

-Andrei, Dragos, Matthew W. Witczak, Charles W. Schwartz, and Jacob Uzan. (2004). Harmonized Resilient Modulus Test Method for Unbound Pavement Materials. *Transportation Research Record*, Vol. 1874, No. 1. 29–37.

**doi.org/10.3141/1874-04**

-Ashrafian, Ali, Amir H. Gandomi, Mohammad Rezaie-Balf, and Mohammad Emadi. (2020). An Evolutionary Approach to Formulate the Compressive Strength of Roller Compacted Concrete Pavement.” *Measurement: Journal of the International Measurement Confederation*, Vol. 152. 107309.

**doi.org/10.1016/j.measurement.2019.107309**

-Dorigo, M, V Maniezzo, and A Colomi. 1996. “The Ant System: Optimization by a Colony of Cooperating Agents IEEE Transaction on Systems. *Man and Cybernetics-Part B*, Vol. 26, No. 1. 29–41.

-Drumm, E. C., Y. Boateng-Poku, and T. Johnson Pierce. (1990). Estimation of Subgrade Resilient Modulus from Standard Tests. *Journal of Geotechnical Engineering*, Vol. 116, No. 5. 774–89. **doi.org/10.1061/(ASCE)0733-9410(1990)116:5(774)**

-Dunlap, Wayne A. (1963). A Mathematical Model Describing the Deformation Characteristics of Granular Materials, Technical Report 1. *Project 2-8-62-27 (HPS-1-27)*. Texas. <https://static.tti.tamu.edu/tti.tamu.edu/documents/TTI-1963-ID1100.pdf>.

-Eberhart, Russell, and James Kennedy. (1999). A New Optimizer Using Particle Swarm Theory. In *Sixth International Symposium on Micro Machine and Human Science*, 0-7803-267, 39–43. Nagoya, Japan. <https://doi.org/10.1.1.470.3577>.

-El-Ashwah, Ahmed S., Ahmed M. Awed, Sherif M.

Model for Resilient Modulus of Cohesive Soils.

-Kim, Sung Hee, Jidong Yang, and Jin Hoon Jeong. (2014). Prediction of Subgrade Resilient Modulus Using Artificial Neural Network.” *KSCE Journal of Civil Engineering*, Vol. 18, No. 5. 1372–79.

**Doi.org/10.1007/s12205-014-0316-6**

-Kweon, G C. (1999). Alternative Testing Methods for Subgrade and Subbase Materials Considering Deformational Characteristics of Soils. Korea Advanced Institute of Science and Technology.

-Lekarp, Fredrick, Ulf Isacsson, and Andrew Dawson. (2000). State of the Art. I: Resilient Response of Unbound Aggregates. *Journal of Transportation Engineering*, Vol. 126, No. 1. 66–75.

**doi.org/10.1061/(ASCE)0733-947X(2000)126:1(66)**

-Maher, Ali, Thomas Bennert, Nenad Gucunski, and Walter J Papp. (2000). Resilient Modulus Properties of New Jersey Subgrade Soils. *Final Report FHWA NJ 2000-01*.

-Malla, Ramesh B., and Shraddha Joshi. (2008). Subgrade Resilient Modulus Prediction Models for Coarse and Fine-Grained Soils Based on Long-Term Pavement Performance Data. *International Journal of Pavement Engineering*, Vol. 9, No. 6. 431–44.

**doi.org/10.1080/10298430802279835**

-Mohammad, Louay N, Baoshan Huang, Anand J Puppala, and Aaron Allen. (1999). Regression Model for Resilient Modulus of Subgrade Soils. *Transportation Research Record*, Vol. 1687, No. 1. 47–54.

**doi.org/10.3141/1687-06**

-Moossazadeh, J, and M Witzak. (1981). Prediction of Subgrade Moduli for Soil That Exhibits Nonlinear Behavior. *Transportation Research Record*. <http://onlinepubs.trb.org/Onlinepubs/trr/1981/810/810-002.pdf>.

-Nazzal, Munir D, and Louay N Mohammad. (2010). Estimation of Resilient Modulus of Subgrade Soils for Design of Pavement Structures. *Journal of Materials in Civil Engineering*, Vol. 22, No. 7. 726–34.

**doi.org/10.1061/(ASCE)MT.1943-5533.0000073**

-Nazzal, Munir D, and Omer Tatari. (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. 364–73.

**https://doi.org/10.1080/10298436.2012.671944**

-Newcombe RG. (1998). Two-Sided Confidence Intervals for the Single Proportion: Comparison of Seven Methods. *Statistics in Medicine*, Vol. 17, No. 8. 857–72.

-Ni, B, TC Hopkins, Lijun Sun, and TL Beckham. (2002). Modeling the Resilient Modulus of Soils. *In*

*International Journal of Optimization in Civil Engineering*, Vol. 8, No. 4. 657–74.

-Grossmann, A., and J. Morlet. (1984). Decomposition of Hardy Functions into Square Integrable Wavelets of Constant Shape. *SIAM Journal on Mathematical Analysis*, Vol. 15, No. 4. 723–36.

-Gu, Fan, Hakan Sahin, Xue Luo, Rong Luo, and Robert L Lytton. (2015). Estimation of Resilient Modulus of Unbound Aggregates Using Performance-Related Base Course Properties. *Journal of Materials in Civil Engineering*, Vol. 27, No. 6. 04014188. **doi.org/10.1061/(ASCE)MT.1943-5533.0001147**.

-Gu, Fan, Xue Luo, Yuqing Zhang, Robert Lytton, and Hakan Sahin. 2016. “Modeling of Unsaturated Granular Materials in Flexible Pavements.” In *3rd European Conference on Unsaturated Soils*, Vol. 9. 1–6. Paris, France.

**doi.org/10.1051/e3sconf/20160920002**

-Hanandeh, Shadi, Allam Ardah, and Murad Abu-Farsakh (2020). Using Artificial Neural Network and Genetics Algorithm to Estimate the Resilient Modulus for Stabilized Subgrade and Propose New Empirical Formula. *Transportation Geotechnics*, Vol. 24, No. 1. 100358.

**doi.org/10.1016/j.trgeo.2020.100358**

-Holland, John H. (1975). *Adaptation in Natural and Artificial Systems*. *Adaptation in Natural and Artificial Systems*. University of michigan press, ann arbor. **doi.org/10.7551/mitpress/1090.001.0001**.

-Huang Y.H. (2004). *Pavement Analysis and Design*. 2nd edition, Pearson.

-Kaveh, Ali, and Vahid Reza Mahdavi. (2013). Optimal Design of Structures with Multiple Natural Frequency Constraints Using a Hybridized BB-BC/Quasi-Newton Algorithm. *Periodica Polytechnica Civil Engineering*, Vol. 57, No. 1. 27–38.

**doi.org/10.3311/PPci.2139**

-Khasawneh, Mohammad Ali, and Narjes Firas Al-jamal. (2019). Modeling Resilient Modulus of Fine-Grained Materials Using Different Statistical Techniques. *Transportation Geotechnics*, Vol. 21, No. 1. 100263.

**doi.org/10.1016/j.trgeo.2019.100263**

-Khasawneh, Mohammad Ali. (2005). Laboratory Characterization of Cohesive Subgrade Materials. University of Akron.

-Kim, D S, G C Kweon, and S Rhee. (2001). Alternative Method of Determining Resilient Modulus of Subbase Soils Using a Static Triaxial Test. *Canadian Geotechnical Journal*, Vol. 38, No. 1. 117–24. **doi.org/10.1139/cgj-38-1-117**.

-Kim, D. G. (2014). Development of a Constitutive

- International Journal of Pavement Engineering*, Vol. 6, No. 3. 163–69.  
doi.org/10.1080/10298430500140891
- Rao, R. V., V. J. Savsani, and D. P. Vakharia. (2011). Teaching-Learning-Based Optimization: A Novel Method for Constrained Mechanical Design Optimization Problems. *CAD Computer Aided Design*, Vol. 43, No. 3. 303–15.  
**doi.org/10.1016/j.cad.2010.12.015**
- Ren, Junping, and Sai K Vanapalli. (2018). Empirical Model for Predicting the Resilient Modulus of Frozen Unbound Road Materials Using a Hyperbolic Function. *Transportation Geotechnics*, Vol. 17, No. 1. 66–74. **doi.org/10.1016/j.trgeo.2018.09.011**
- Sadrossadat, Ehsan, Ali Heidaripناه, and Behnam Ghorbani. (2018). Towards Application of Linear Genetic Programming for Indirect Estimation of the Resilient Modulus of Pavements Subgrade Soils. *Road Materials and Pavement Design*, Vol. 19, No. 1. 139–53. **doi.org/10.1080/14680629.2016.1250665**
- Saha, Sajib, Fan Gu, Xue Luo, and Robert L Lytton. (2018b). Use of an Artificial Neural Network Approach for the Prediction of Resilient Modulus for Unbound Granular Material. *Transportation Research Record*, Vol. 2672, No. 52. 23–33.  
**doi.org/10.1177/0361198118756881**
- Santha B.L. (1994). Resilient modulus of subgrade soils: Comparison of two constitutive equations, *Transp. Res. Rec.* 1462. 79-90.
- Seed, H B, C K Chan, and C E Lee. (1962). Resilience Characteristics of Subgrade Soils and Their Relation to Fatigue Failures in Asphalt Pavements. In *International Conference on the Structural Design of Asphalt Pavements*, 611–36. Ann Arbor, Michigan: University of Michigan.
- Shafabakhsh, Gholamali, and Amin Tanakizadeh. (2015). Investigation of Loading Features Effects on Resilient Modulus of Asphalt Mixtures Using Adaptive Neuro-Fuzzy Inference System. *Construction and Building Materials*, Vol. 76, No. 1. 256–63. **doi.org/10.1016/j.conbuildmat.2014.11.069**
- Smart, Aaron L, and Dana Norman Humphrey. (1999). Determination of Resilient Modulus for Maine Roadway Soils.
- Solanki, Pranshoo, Ali Ebrahimi, and Zaman Musharraf M. (2008). Statistical Models for Determination of the Resilient Modulus of Subgrade Soils. *International Journal of Pavement Research and Technology*, Vol. 1, No. 3. 85–93.
- Soliman, Haithem, and Ahmed Shalaby. (2016). Validation of Long-Term Pavement Performance Prediction Models for Resilient Modulus of Unbound
- 6th International Conference on the Bearing Capacity of Roads and Airfields*, 1131–42. LISBON, PORTUGAL: Transport Research Laboratory.
- Ozsahin, Talat Sukru, and Seref Oruc. (2008). Neural Network Model for Resilient Modulus of Emulsified Asphalt Mixtures. *Construction and Building Materials*, Vol. 22, No. 7. 1436–45.  
**doi.org/10.1016/j.conbuildmat.2007.01.031**
- Pal, Mahesh, and Surinder Deswal. (2014). Extreme Learning Machine Based Modeling of Resilient Modulus of Subgrade Soils. *Geotechnical and Geological Engineering*, Vol. 32, No. 2. 287–96.  
**doi.org/10.1007/s10706-013-9710-y**
- Panda, Tapas Ranjan, and Aravind Krishna Swamy. (2018). An Improved Artificial Bee Colony Algorithm for Pavement Resurfacing Problem. *International Journal of Pavement Research and Technology*, Vol. 11, No. 5. 509–16.  
**doi.org/10.1016/j.ijprt.2018.04.001**
- Papagiannakis A.T. Masad E.A. (2008). Pavement Design and Materials”, Hohn Wiley & Sons Inc, Hoboken, New Jersey.
- Park, H I, G C Kweon, and S R Lee. (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. 647–65.  
**doi.org/10.3166/rmpd.10.647-665**
- Park, Hee Mun, Moon Kyung Chung, Yong An Lee, and Boo Il Kim. (2013). A Study on the Correlation between Soil Properties and Subgrade Stiffness Using the Long-Term Pavement Performance Data. *International Journal of Pavement Engineering*, Vol. 14, No. 2. 146–53.  
**doi.org/10.1080/10298436.2011.633167**
- Pezo, R, and W R Hudson (1994). Prediction Models of Resilient Modulus for Nongranular Materials. *Geotechnical Testing Journal*, Vol. 17, No. 3. 349–55. **doi.org/10.1520/gtj10109j**
- Pourtahmasb, Mohammad Saeed, Mohamed Rehan Karim, and Shahaboddin Shamshirband. (2015). Resilient Modulus Prediction of Asphalt Mixtures Containing Recycled Concrete Aggregate Using an Adaptive Neuro-Fuzzy Methodology. *Construction and Building Materials*, Vol. 82, No. 1. 257–63.  
**doi.org/10.1016/j.conbuildmat.2015.02.030**
- Rada, G, and MW Witczak. (1981). Comprehensive Evaluation of Laboratory Resilient Moduli Results for Granular Material. *Transportation Research Record: Journal of the Transportation Research Board*. Vol. 810, No. 1. 23–33.
- Rahim, A. M. (2005). Subgrade Soil Index Properties to Estimate Resilient Modulus for Pavement Design.

*Physiology*, Vol. 26, No. 6. 807–17.

**doi.org/10.1093/treephys/26.6.807**

-Walker, H.M. (1929). Studies in the History of Statistical Method with Special Reference to Certain Educational Problems. *Williams & Wilkins Co.* **doi.org/10.1037/13379-000**

Wang Gaige, Guo Lihong and Duan Hong. (2013). Wavelet Neural Network Using Multiple Wavelet Functions in Target Threat Assessment. *The ScientificWorld Journal*. Vol. 2013. 1-7.

-Xiao, Feipeng, and Serji N. Amirkhanian. (2008). Resilient Modulus Behavior of Rubberized Asphalt Concrete Mixtures Containing Reclaimed Asphalt Pavement. *Road Materials and Pavement Design*, Vol. 9, No. 4. 633–49.

**doi.org/10.1080/14680629.2008.9690142**

-Yang, Xin-she. (2010). *Nature-Inspired Metaheuristic Algorithms. Nature-Inspired Metaheuristic Algorithms Second Edition*. University of Cambridge, United Kingdom: Luniver press. **doi.org/10.1016/B978-0-12-416743-8.00005-1**

-Yang, Y., and Q. Zhang. (1997). A Hierarchical Analysis for Rock Engineering Using Artificial Neural Networks. *Rock Mechanics and Rock Engineering*, Vol. 30, No. 4. 207–22.

**doi.org/10.1007/BF01045717**

-Yao, Yongsheng, Jianlong Zheng, Junhui Zhang, Junhui Peng, and Jue Li. (2018). Model for Predicting Resilient Modulus of Unsaturated Subgrade Soils in South China. *KSCE Journal of Civil Engineering*, Vol. 22, No. 6. 2089–98.

**doi.org/10.1007/s12205-018-1703-1**

-Yau, Amber, and Harold L Von Quintus. (2002). Study of LTPP Laboratory Resilient Modulus Test Data and Response Characteristics. No. FHWA-RD-02-051: 173.

<https://www.fhwa.dot.gov/publications/research/infrastucture/pavements/ltp/reports/02051/02051.pdf>.

-Zhang, Qinghua, and Albert Benveniste (1992). Wavelet Networks. *IEEE Transactions on Neural Networks*, Vol. 3, No. 6. 889–98.

**doi.org/10.1109/72.165591.**

-Zhou, Changjun, Baoshan Huang, Eric Drumm, Xiang Shu, Qiao Dong, and Sampson Udeh. (2015). “Soil Resilient Modulus Regressed from Physical Properties and Influence of Seasonal Variation on Asphalt Pavement Performance. *Journal of Transportation Engineering*, Vol. 141, No. 1. **doi.org/10.1061/(ASCE)TE.1943-5436.0000727**

Granular Materials. *Transportation Research Record*, Vol. 2578, No. 1. 29–37.

**doi.org/10.3141/2578-04**

-Thompson, Marshall R., and Quentin L. Robnett. (1979). Resilient Properties of Subgrade Soils. *ASCE Transp Eng J*, Vol. 105, No. 1. 71–89.

-Titi, Hani H, and Mohammad G Matar. (2018). Estimating Resilient Modulus of Base Aggregates for Mechanistic-Empirical Pavement Design and Performance Evaluation. *Transportation Geotechnics*, Vol. 17, No. 1. 141–53.

**doi.org/10.1016/j.trgeo.2018.09.014**

-Tropsha, Alexander, Paola Gramatica, and Vijay K. Gombar. (2003). The Importance of Being Earnest: Validation Is the Absolute Essential for Successful Application and Interpretation of QSPR Models. *QSAR and Combinatorial Science*, Vol. 22, No. 1. 69–77. **doi.org/10.1002/qsar.200390007**

-Uzan, Jacob. (1985). Characterization of Granular Materials\_1985.Pdf. *Transportation Research Record*, Vol. 1022, No. 1. 52–59.

-Vadood, Morteza, Majid Safar Johari, and Alireza Rahai. (2015). Developing a Hybrid Artificial Neural Network-Genetic Algorithm Model to Predict Resilient Modulus of Polypropylene/Polyester Fiber-Reinforced Asphalt Concrete. *Journal of the Textile Institute*, Vol. 106, No. 11. 1239–50.

**doi.org/10.1080/00405000.2014.985882**

-Vaitkus, Audrius, Judita Gražulytė, Ovidijus Šernas, Viktoras Vorobjovas, and Rita Kleizienė. (2019). An Algorithm for the Use of MSWI Bottom Ash as a Building Material in Road Pavement Structural Layers.” *Construction and Building Materials*, Vol. 212, No. 1. 456–66.

**doi.org/10.1016/j.conbuildmat.2019.04.014**

-Van Niekerk AA, LJM Houben, and AAA Molenaar. (1998). Estimation of mechanical behaviour of unbound road building materials from physical material properties. *Proceedings of the 5th International Conference on the Bearing Capacity of Roads and Airfields*. Trondheim, Norway.

-Venkata Rao, R. (2016). Review of Applications of Tlbo Algorithm and a Tutorial for Beginners to Solve the Unconstrained and Constrained Optimization Problems.” *Decision Science Letters*, Vol. 5, No. 1. 1–30. **doi.org/10.5267/j.dsl.2015.9.003**

-Verbeeck, Hans, Roeland Samson, Frederik Verdonck, and Raoul Lemeur. (2006). Parameter Sensitivity and Uncertainty of the Forest Carbon Flux Model FORUG: A Monte Carlo Analysis. *Tree*

ضمیمه الف: ماتریس ورودی‌ها، مدول برجهندگی اندازه‌گیری شده و مدول برجهندگی پیش‌بینی شده

MDD	Cu	Cc	P <sub>200</sub>	σ <sub>3</sub>	σ <sub>d</sub>	Actual M <sub>R</sub>	Predicted M <sub>R</sub>
2.1	27.3	0.4	0.2	104	69	221	222.3
2.1	27.3	0.4	0.2	138	138	263	264.9
2.2	15.9	1.2	0.3	138	276	155	156.6
2.2	24.3	0.4	0.2	35	69	206	206.5
2.1	27.3	0.4	0.2	104	207	240	241.6
2.4	37.5	0.8	5.3	69	207	180	179.7
2.4	37.5	0.8	5.3	35	104	145	144.2
2.3	28	3	0.9	21	41	115	117.9
2.4	50	0.7	2	138	104	258	259.3
2	33.3	1.7	0.2	69	207	187	186.9
2.3	63.7	0.9	0.3	69	69	248	245.9
2.3	28	3	0.9	104	69	208	209.2
2.3	17	2.1	1.8	69	207	171	170.4
2.2	15.9	1.2	0.3	69	69	93	91.9
2.4	35.3	2.4	0.7	35	104	121	117.6
2.3	21.8	1.4	0.1	35	69	134	137.8
2.4	35.3	2.4	0.7	21	21	124	122.3
2.3	63.7	0.9	0.3	21	61	158	159.1
2.4	50	0.7	2	104	207	246	246.0
2.3	28	3	0.9	35	35	139	137.3
2	33.3	1.7	0.2	21	21	94	93.4
2.1	27.3	0.4	0.2	138	104	256	256.3
2.3	63.7	0.9	0.3	69	207	247	249.8
2.2	24.3	0.4	0.2	104	104	329	329.8
2.4	37.5	0.8	5.3	138	138	225	223.5
2.2	24.3	0.4	0.2	21	21	194	193.2
2.1	27.3	0.4	0.2	69	138	200	197.5
2.1	27.3	0.4	0.2	35	69	140	139.2
2.3	21.8	1.4	0.1	21	21	123	119.4
2.3	28	3	0.9	138	276	307	307.3
2.4	50	0.7	2	35	35	140	142.8
2.2	25	2.3	0.3	104	69	191	192.4
2	33.3	1.7	0.2	21	41	99	99.0
2.3	28	3	0.9	35	69	137	137.3
2.2	15.9	1.2	0.3	138	104	136	135.1
2.3	17	2.1	1.8	21	41	119	119.5
2.3	21.8	1.4	0.1	21	61	117	116.9
2.1	27.3	0.4	0.2	21	61	112	112.7
2	33.3	1.7	0.2	138	276	258	257.9
2.2	25	2.3	0.3	138	138	232	231.1
2.4	50	0.7	2	69	69	187	187.1
2.2	15.9	1.2	0.3	69	138	100	101.8
2.3	9.8	1.5	1.7	138	104	159	158.1
2.4	35.3	2.4	0.7	69	138	126	124.1
2.2	24.3	0.4	0.2	69	207	259	258.7
2.2	24.3	0.4	0.2	35	104	205	202.6
2.2	24.3	0.4	0.2	35	35	223	223.6
2.2	24.3	0.4	0.2	69	138	258	260.7
2.3	28	3	0.9	21	21	131	130.3
2	33.3	1.7	0.2	138	104	235	234.4
2.3	63.7	0.9	0.3	21	41	159	158.6
2.2	15.9	1.2	0.3	35	69	64	69.4
2.3	17	2.1	1.8	21	61	124	121.9
2.4	50	0.7	2	69	138	203	203.5
2.3	17	2.1	1.8	138	138	227	227.5
2.2	25	2.3	0.3	21	21	85	86.2
2.2	15.9	1.2	0.3	21	21	60	60.8
2.1	27.3	0.4	0.2	104	104	226	227.3
2.3	63.7	0.9	0.3	104	207	339	334.9
2.3	28	3	0.9	104	207	250	249.2
2.2	25	2.3	0.3	138	276	253	252.2
2	33.3	1.7	0.2	69	69	179	180.0
2.3	17	2.1	1.8	35	69	128	129.3

فصلنامه علمی پژوهشنامه حمل و نقل، سال بیست و یکم، دوره دوم، شماره ۷۹، تابستان ۱۴۰۳

MDD	Cu	Cc	P <sub>200</sub>	$\sigma_3$	$\sigma_d$	Actual M <sub>R</sub>	Predicted M <sub>R</sub>
2.3	21.8	1.4	0.1	138	138	252	250.1
2.2	25	2.3	0.3	104	207	211	212.9
2.4	35.3	2.4	0.7	69	207	126	128.9
2.4	50	0.7	2	69	207	212	213.4
2.3	17	2.1	1.8	138	104	221	220.3
2.2	15.9	1.2	0.3	104	69	109	105.5
2.3	9.8	1.5	1.7	69	69	114	117.2
2.4	35.3	2.4	0.7	104	69	130	132.1
2.3	17	2.1	1.8	138	276	245	245.2
2.3	9.8	1.5	1.7	104	69	140	139.2
2.3	21.8	1.4	0.1	21	41	119	118.5
2.4	50	0.7	2	138	138	263	263.5
2.4	37.5	0.8	5.3	35	69	134	136.2
2.1	27.3	0.4	0.2	138	276	281	280.1
2.3	9.8	1.5	1.7	138	138	154	157.4
2.3	28	3	0.9	35	104	137	134.8
2	33.3	1.7	0.2	104	69	203	202.2
2.3	63.7	0.9	0.3	104	104	323	327.2
2.4	50	0.7	2	35	104	165	165.2
2.2	15.9	1.2	0.3	138	138	139	142.7
2.3	21.8	1.4	0.1	69	69	163	169.4
2.3	28	3	0.9	138	104	236	235.2
2.1	27.3	0.4	0.2	69	207	200	200.2
2.3	17	2.1	1.8	35	35	119	120.2
2	33.3	1.7	0.2	104	104	208	208.1
2.4	37.5	0.8	5.3	21	41	117	115.8
2.3	28	3	0.9	69	138	184	184.9
2.3	9.8	1.5	1.7	104	104	139	134.3
2.3	28	3	0.9	69	207	185	185.7
2.4	35.3	2.4	0.7	21	61	119	121.0
2.4	37.5	0.8	5.3	69	138	169	167.7
2.3	21.8	1.4	0.1	104	207	250	247.9
2.2	25	2.3	0.3	35	69	119	120.0
2.2	25	2.3	0.3	21	61	99	99.0
2.4	50	0.7	2	138	276	287	285.8
2.3	28	3	0.9	104	104	211	209.9
2.2	15.9	1.2	0.3	35	104	77	74.1
2.2	15.9	1.2	0.3	104	104	110	108.2
2.4	37.5	0.8	5.3	138	104	221	221.8
2.4	35.3	2.4	0.7	138	138	152	152.4
2.3	9.8	1.5	1.7	21	21	93	92.7
2.2	15.9	1.2	0.3	21	61	71	69.8
2.4	37.5	0.8	5.3	104	104	190	192.0
2.4	35.3	2.4	0.7	138	104	149	146.9
2.3	21.8	1.4	0.1	69	138	184	180.0
2.2	15.9	1.2	0.3	21	41	65	64.8
2.2	25	2.3	0.3	69	138	175	172.3
2.3	21.8	1.4	0.1	138	104	236	240.7
2.2	24.3	0.4	0.2	21	41	186	187.8
2.4	35.3	2.4	0.7	69	69	121	120.8
2.2	24.3	0.4	0.2	138	104	378	374.2
2.4	37.5	0.8	5.3	104	69	187	186.1
2.2	25	2.3	0.3	104	104	195	196.0
2.4	35.3	2.4	0.7	104	207	143	142.9
2.2	25	2.3	0.3	21	41	93	92.1
2.4	50	0.7	2	104	69	221	218.5
2	33.3	1.7	0.2	21	61	103	103.0
2.3	63.7	0.9	0.3	104	69	323	321.5
2.4	37.5	0.8	5.3	69	69	156	156.4
2.2	24.3	0.4	0.2	21	61	181	181.5
2.4	50	0.7	2	104	104	226	225.6
2.4	50	0.7	2	21	41	135	134.6
2.4	35.3	2.4	0.7	104	104	131	132.4
2	33.3	1.7	0.2	138	138	241	241.2
2.4	35.3	2.4	0.7	35	35	124	124.9

فصلنامه علمی پژوهشنامه حمل و نقل، سال بیست و یکم، دوره دوم، شماره ۷۹، تابستان ۱۴۰۳

MDD	Cu	Cc	P <sub>200</sub>	$\sigma_3$	$\sigma_d$	Actual M <sub>R</sub>	Predicted M <sub>R</sub>
2.2	24.3	0.4	0.2	104	207	333	332.7
2.3	17	2.1	1.8	104	69	187	186.6
2.4	50	0.7	2	21	61	145	142.8
2.2	25	2.3	0.3	69	207	175	176.1
2.2	24.3	0.4	0.2	138	276	393	391.8
2.2	25	2.3	0.3	35	104	124	122.4
2.4	50	0.7	2	21	21	124	123.6
2.3	17	2.1	1.8	69	138	165	166.7
2.1	27.3	0.4	0.2	21	41	107	105.8
2.2	15.9	1.2	0.3	35	35	63	61.8
2	33.3	1.7	0.2	35	35	123	124.2
2.2	25	2.3	0.3	69	69	165	163.4
2.3	17	2.1	1.8	69	69	161	160.9
2.3	21.8	1.4	0.1	104	69	207	203.0
2.3	21.8	1.4	0.1	35	104	139	140.0
2.2	24.3	0.4	0.2	104	69	341	328.0
2.3	9.8	1.5	1.7	21	41	88	91.3
2.3	28	3	0.9	21	61	114	108.5
2.3	17	2.1	1.8	21	21	112	121.7
2.3	9.8	1.5	1.7	35	69	103	101.8
2.3	63.7	0.9	0.3	35	35	171	174.9
2	33.3	1.7	0.2	35	104	135	158.2
2.4	37.5	0.8	5.3	21	21	108	100.9
2.3	17	2.1	1.8	104	207	203	218.9
2.4	37.5	0.8	5.3	21	61	125	126.4
2.3	21.8	1.4	0.1	69	207	191	201.3
2.4	35.3	2.4	0.7	35	69	126	121.3
2.2	25	2.3	0.3	35	35	113	118.4
2.3	9.8	1.5	1.7	35	35	124	98.8
2.2	25	2.3	0.3	138	104	228	226.0
2.3	28	3	0.9	69	69	184	180.0
2.1	27.3	0.4	0.2	21	21	98	102.4
2.2	24.3	0.4	0.2	138	138	366	381.0
2.4	37.5	0.8	5.3	104	207	206	201.3
2.4	37.5	0.8	5.3	35	35	119	120.5
2.3	21.8	1.4	0.1	35	35	127	136.9
2	33.3	1.7	0.2	69	138	187	187.7
2.4	35.3	2.4	0.7	138	276	169	187.0
2.1	27.3	0.4	0.2	69	69	191	196.9
2.3	63.7	0.9	0.3	138	104	413	383.4
2.3	63.7	0.9	0.3	35	104	187	174.3
2.3	63.7	0.9	0.3	35	69	183	174.8
2.3	9.8	1.5	1.7	21	61	90	91.0
2.3	21.8	1.4	0.1	104	104	211	208.0
2.3	63.7	0.9	0.3	138	276	411	393.7
2.3	17	2.1	1.8	35	104	134	143.5
2.2	15.9	1.2	0.3	104	207	123	130.4
2.1	27.3	0.4	0.2	35	35	136	147.4
2.3	63.7	0.9	0.3	21	21	150	157.7
2.4	35.3	2.4	0.7	21	41	121	122.0
2.3	28	3	0.9	138	138	252	241.0
2.4	50	0.7	2	35	69	156	156.5
2.2	24.3	0.4	0.2	69	69	252	272.2
2	33.3	1.7	0.2	35	69	130	141.2
2.3	63.7	0.9	0.3	138	138	422	389.7
2.4	37.5	0.8	5.3	138	276	244	243.3
2	33.3	1.7	0.2	104	207	221	233.8
2.3	9.8	1.5	1.7	69	138	107	113.8
2.2	15.9	1.2	0.3	69	207	104	94.3
2.1	27.3	0.4	0.2	35	104	143	135.1
2.3	63.7	0.9	0.3	69	138	259	248.0
2.3	17	2.1	1.8	104	104	189	193.8

ضمیمه ب: ماتریس وزنهای ورودی و خروجی و پارامترهای موجک در لایه پنهان

**[Dilation Matrix]<sub>(1×20)</sub>**

1	2	3	4	5	6	7	8	9	10
-74.286060	-278.181496	-24.316814	56.908636	167.416958	96.956985	103.817192	-75.526087	149.434136	-310.271709
11	12	13	14	15	16	17	18	19	20
-316.034020	-484.709555	121.110636	82.895517	20.533996	246.598802	293.680868	43.485790	210.378315	712.939024

**[Translation Matrix]<sub>(1×20)</sub>**

1	2	3	4	5	6	7	8	9	10
-156.803317	261.277552	908.305028	-208.651174	237.882601	353.130522	96.418422	-152.702542	-172.013063	-29.357955
11	12	13	14	15	16	17	18	19	20
-737.943414	-263.591429	-466.398888	218.234369	91.300302	871.437020	-550.953523	706.425224	8.735524	-159.889186

**[Input Weighting]<sub>(6×20)</sub>**

1	2	3	4	5	6	7	8	9	10
121.283699	-176.391265	104.670950	-337.511967	42.393690	355.373501	188.250451	-374.005599	-243.893397	104.134690
263.733706	258.425144	-997.824799	-299.447487	385.809068	32.090264	445.884045	181.206109	-664.626582	-76.973348
-14.993305	-36.716139	1000.000000	90.411752	-105.929921	-358.239843	-60.962006	6.421983	773.819828	33.543527
-78.111814	-639.226581	573.500513	-242.929059	-76.171955	-999.961083	257.888068	10.603547	445.520673	-93.395281
125.510409	5.825796	-129.906765	-491.710699	-88.350312	-175.724177	5.538957	-7.968145	326.202222	-213.055919
-299.485007	117.287693	110.257120	70.992133	-83.940852	23.453790	-6.403093	26.537656	-390.711956	-167.741270

11	12	13	14	15	16	17	18	19	20
747.671890	18.888173	-88.139329	-68.112620	298.750618	249.948910	33.386315	-169.442285	-552.858688	-109.754106
-221.541533	-61.990311	-33.313377	-185.688112	37.039498	-294.515073	999.901637	34.953523	-994.568080	205.359881
170.362962	-129.866729	544.726835	155.523901	87.784433	-276.612280	292.421438	726.721095	-151.493808	-703.724762
193.638244	38.188955	-93.573330	102.348394	227.429509	-999.920684	-365.120834	-105.563957	-638.376796	-51.698549
999.999976	-159.955938	42.083924	-104.892208	-786.962542	-78.158152	196.411411	64.621051	-256.507615	-55.040459
218.541093	127.625206	213.789863	-154.316293	102.091256	-112.005910	338.690519	-236.796138	-2.286789	-34.699080

**[Output Weighting]<sub>(20×1)</sub>**

1	-42.264627
2	84.494561
3	133.022160
4	-22.889238
5	41.410077
6	239.288648
7	-256.585120
8	90.078113
9	9.181932
10	-89.368094
11	206.209734
12	201.588271
13	773.901985
14	282.237490
15	-13.738238
16	999.914047
17	-261.983837
18	-95.212863
19	-146.949485
20	160.001760

# Application of Hybrid Wavelet Neural Network and TLBO Optimization Algorithm for Modeling the Resilient Modulus of Granular Subbase Materials

*Ali Reza Ghanizadeh, Associate Professor, Department of Civil Engineering,  
Sirjan University of Technology, Sirjan, Iran.*

*Nasrin Heidarabadizadeh, M.Sc., Grad., Department of Civil Engineering,  
Sirjan University of Technology, Sirjan. Iran.*

*E-mail: ghanizadeh@sirjantech.ac.ir*

Received: February 2024- Accepted: June 2024

## **ABSTACT**

The resilient modulus ( $M_R$ ) of road materials is one of the most important parameters in the analysis and design of pavement. This parameter is used in both empirical methods and mechanistic-empirical methods as the main parameter for expressing the stiffness and behavior of road construction materials. To determine this parameter in the laboratory, it is necessary to perform a dynamic tri-axial loading test under various confining and deviator stresses, which is a time- and cost-intensive approach. In this paper, a wavelet neural network (WNN) hybridized with the teacher learning based optimization (TLBO) algorithm was used to model the  $M_R$  of unbound subbase materials. The input variables included maximum dry density, uniformity coefficient, curvature coefficient, percent passing No. 200 sieve, confining stress, and deviator stress and output variable was resilient modulus of the unbound subbase materials. The results of this study indicate that increasing the number of neurons in the hidden layer to more than 20 neurons has little effect on increasing the accuracy of the wavelet neural network and the Mexican Hat wavelet function has the best result in predicting the resilient modulus. The results of this study also indicate that the WNN-TLBO method is more accurate than the ANN method in predicting the  $M_R$  of unbound subbase materials. External validation results indicate that the WNN-TLBO method satisfy all the necessary criteria, which indicates the high predictive potential of this method. The results of sensitivity analysis indicate that the degree of importance of the confined stress is higher than other variables for predicting the resilience modulus. A parametric analysis was also done to study the effects of each input variable on the  $M_R$ .

**Key Words:** Resilient Modulus, Wavelet Neural Network (WNN), TLBO Algorithm, Granular Subbase