

## یادداشت پژوهشی

## ارائه رابطه‌ای برای تخمین جابه‌جایی جانبی حاصل از روانگرایی با استفاده از بانک اطلاعاتی ژئوتکنیکی جدید

فرهنگ فرخی

استادیار، دانشکده مهندسی عمران، دانشگاه زنجان

علیرضا فیروزفر

استادیار، دانشکده مهندسی عمران، دانشگاه زنجان

محمدصادق مقصودی (نویسنده مسئول)

دانشجوی دکتری ژئوتکنیک، دانشکده مهندسی عمران، دانشگاه زنجان

m.s.maghsoodi@gmail.com

## چکیده

گسترش جانبی ناشی از روانگرایی یکی از عوامل اصلی به وجود آورنده خسارات عمده در طول زلزله به سازه‌های زمینی و سازه‌های مدفون در خاک می‌باشد. این نوع از جابه‌جایی‌های دائمی سطح زمین، که از چند سانتی‌متر تا ۱۰ متر و بیشتر متغیر می‌باشد، خسارات اساسی را به تأسیسات زیر بنایی و شالوده‌های شمعی سازه‌های بزرگ و پایه‌های پل‌ها در طول دهه‌های اخیر تحمیل کرده است. به همین علت، یک مدل جدید با توانایی بالا به منظور برآورد جابه‌جایی‌های جانبی ناشی از روانگرایی با استفاده از روش شبکه‌های عصبی نوع GMDH<sup>۱</sup> در تحقیق حاضر توسعه داده شده است. به این منظور، یک بانک اطلاعاتی جامع شامل ۵۲۶ الگور که در طول ۱۸ زلزله مهم ثبت شده است، به منظور مدل‌سازی و تحلیل جمع‌آوری گردید. به دلیل اینکه مدل حاضر بر پایه تعداد زیادی از زلزله‌ها و نیز ساخت‌گاه‌های مختلف توسعه یافته است، مدل جامع تر و قابل اعتمادتری از مدل‌های قبلی ارائه می‌کند. همچنین مقایسه عملکرد مدل توسعه داده شده در تحقیق حاضر با نتایج آزمایشگاهی موجود در متن بیانگر صحت پیش‌بینی مقادیر توسط مدل جدید می‌باشد.

**واژگان کلیدی:** جابه‌جایی جانبی، روانگرایی، شبکه‌های عصبی نوع GMDH، بانک اطلاعاتی ژئوتکنیکی.

## ۱- مقدمه

شد [۱] و بررسی موضوع گسترش جانبی ناشی از روانگرایی فزونی یافت.


محققین متعددی با روش‌های محاسباتی مختلف تلاش کرده‌اند تا روابطی به منظور پیش‌بینی جابه‌جایی جانبی ناشی از روانگرایی ارائه دهند. این روش‌ها را می‌توان در چهار دسته کلی طبقه‌بندی نمود: روش تحلیل ساده شده [۲-۸]، روش عددی [۹-۱۱]، روش تجربی [۱۲-۱۴] و روش محاسبات نرم [۱۵-۱۷].

نیومارک [۲] اولین مدل ساده شده برای تخمین جابه‌جایی جانبی شیب‌ها در حین زلزله را ارائه نمود. در مدل او، از روش تحلیل بلوک لغزان<sup>۴</sup> استفاده شد. در این روش، هنگامی که نیروی محرک (شتاب زلزله) از نیروی مقاوم بیشتر می‌شود بلوک شروع به لغزیدن می‌کند. سپس جابه‌جایی تجمعی از انتگرال‌گیری مضاعف رکورد شتاب پایه به دست می‌آید.

روانگرایی خاک‌ها به دلیل کاهش چشمگیر مقاومت برشی در اثر تنش‌های برشی سیکلی ناشی از بارهای دینامیکی در خاک‌های ماسه‌ای اشباع و در نتیجه افزایش فشار آب حفره‌ای به وقوع می‌پیوندد. خسارات عمده‌ای که در اثر روانگرایی در ساختگاه ممکن است به وجود آیند شامل جوشش ماسه، گسیختگی جریان‌های شیب‌ها، نوسانات سطح زمین، از دست رفتن ظرفیت باربری خاک، نشست زمین و جابه‌جایی جانبی می‌باشند.

به دلیل تأثیرات مهم و مخرب جابه‌جایی‌های جانبی ناشی از روانگرایی در طول زلزله در ساخت‌گاه‌های مستعد روانگرایی، تحقیق بر روی این موضوع در دهه‌های اخیر به زمینه‌ای مهم و در حال گسترش در حوزه ژئوتکنیک لرزه‌ای تبدیل شده است. به طور خاص، اهمیت این موضوع بعد از زلزله‌های سال ۱۹۶۴ نیگاتا<sup>۲</sup> ژاپن و پرنس ویلیام<sup>۳</sup> آلاسکا به مراتب بیشتر

ضخامت تجمعی لایه‌های ماسه‌ای اشباع با عدد SPT کمتر از ۱۵،  $F_{15}$  و  $D_{50_{15}}$  به ترتیب متوسط مقدار ریزدانه (ریزتر از ۷۵ میکرون) و متوسط سایز دانه‌های ماسه‌ای در حد فاصل  $T_{15}$  و  $S$  نیز شیب زمین بر حسب درصد می‌باشد. اگرچه دقت مدل فوق برای الگوهای موجود در ساخت‌گاه‌های ژاپن و ایالات متحده آمریکا قابل قبول می‌باشد (شکل ۱)، ولی در مقابل الگوهای با مقادیر جابه‌جایی کمتر از ۱/۲ متر پیش‌بینی‌های مدل منطبق با واقعیت نیست.



شکل (۱): عملکرد مدل MLR در مقابل الگوهای ژاپن و آمریکا [۱۴].

جوادی و همکاران [۱۶] با استفاده از بانک اطلاعاتی مورد استفاده در مدل MLR و با حذف تعدادی از الگوهای بانک اطلاعاتی که ایجاد خطا در مدل می‌کردند، مدلی مبتنی بر روش برنامه‌نویسی ژنتیک (GP) ارائه دادند. مشابه مدل MLR، مدل آنها نیز در دو حالت زمین با شیب ملایم و زمین با وجه آزاد به صورت زیر می‌باشد:

برای حالت زمین دارای وجه آزاد:

$$D_h = -163.1 \frac{1}{M^2} + 57 \frac{1}{R.F_{15}} - 0.0035 \frac{T_{15}^2}{W.D_{50_{15}}^2} + 0.02 \frac{T_{15}^2}{F_{15}.D_{50_{15}}^2} - 0.26 \frac{T_{15}^2}{F_{15}^2} + 0.0067T_{15}^2 - 0.0013W^2 + 0.0002M^2.W.T_{15} + 3.7 \quad (3)$$

در زمینه کارهای عددی نیز، مدل‌هایی از قبیل TARA-3 و TARA-3FL توسط فین و همکاران [۱۰] و مدل‌هایی مبتنی بر اصل کرنش صفحه‌ای توسط گیو و همکاران [۹] توسعه داده شد. به دلیل پیچیدگی‌های موجود در مدل‌سازی و نیز تدقیق پارامترهای مرتبط در مدل، مشهود است که در نظر گرفتن برخی ساده‌سازی‌ها در مدل، از دقت و توانایی آن خواهد کاست.

## ۲- روابط تجربی متداول

به دلیل پیچیدگی‌ها و محدودیت‌های ذکر شده برای روش‌های تحلیلی و عددی، بسیاری از محققین به توسعه مدل‌هایی مبتنی بر روش تجربی برای تخمین جابه‌جایی‌های جانبی حاصل از روانگرایی روی آورده‌اند. روش‌های تجربی معمولاً بر پایه رابطه بین جابه‌جایی‌های مشاهده شده میدانی و پارامترهای متعدد با استفاده از رگرسیون بنا شده است. معتبرترین رابطه تجربی در این زمینه، رابطه پیشنهادی یود و همکاران [۱۴] با نام اختصاری MLR می‌باشد که به‌طور وسیعی مورد استفاده و مقبولیت قرار گرفته است. این مدل برای دو حالت زمین با شیب ملایم<sup>۵</sup> و زمین با وجه آزاد<sup>۶</sup> به صورت زیر می‌باشد:

برای حالت زمین دارای وجه آزاد:

$$\text{Log } D_h = -16.713 + 1.532M_w - 1.406 \text{Log } R^* - 0.012R + 0.592 \text{Log } W + 0.540 \text{Log } T_{15} + 3.413 \text{Log} (100 - F_{15}) - 0.795 \text{Log} (D_{50_{15}} + 0.1 \text{ mm}) \quad (1)$$

برای حالت زمین با شیب ملایم:

$$\text{Log } D_h = -16.213 + 1.532M_w - 1.406 \text{Log } R^* - 0.012R + 0.338 \text{Log } S + 0.540 \text{Log } T_{15} + 3.413 \text{Log} (100 - F_{15}) - 0.795 \text{Log} (D_{50_{15}} + 0.1 \text{ mm}) \quad (2)$$

در روابط فوق  $D_h$  جابه‌جایی جانبی زمین به متر،  $R^*$  برابر  $R + 10^{(0.89M - 5.64)}$ ، فاصله افقی از منبع انرژی زلزله به کیلومتر،  $M_w$  بزرگای گشتاوری زلزله،  $W$  نسبت وجه آزاد،  $T_{15}$

برای حالت زمین با شیب ملایم:

$$D_h = -0.8 \frac{F_{15}}{M} + 0.0014F_{15}^2 + 0.16 T_{15} + \quad (4)$$

$$-0.026R D_{50_{15}} + 1.14 \quad 0.112 S + 0.04 \frac{S \cdot T_{15}}{D_{50_{15}}}$$

در تحقیق حاضر، ابتدا بانک اطلاعاتی مورد استفاده محققین قبلی [۱۴] با اضافه نمودن الگوهای از چند ساختگاه مختلف به‌روز رسانی و سپس با استفاده از شبکه عصبی نوع GMDH که توسط الگوریتم ژنتیک بهینه شده است، مدل جدید برای تخمین جابه‌جایی جانبی ناشی از روانگرایی توسعه داده می‌شود و نتایج آن با مدل‌های محققین قبلی (روابط ۱ تا ۴) مقایسه می‌گردد.

### ۳- شبکه‌های عصبی مصنوعی نوع GMDH بهینه شده با الگوریتم ژنتیک

مدل‌سازی سیستم‌های پیچیده نیازمند یافتن یک رابطه ریاضی دقیق بین پارامترهای ورودی و خروجی است. این موضوع برای سیستم‌های پیچیده امری دشوار و وقت‌گیر می‌باشد؛ بنابراین، استفاده از روش محاسبات نرم یا هوش مصنوعی در سال‌های اخیر به‌عنوان جایگزینی مطمئن برای یافتن این روابط اهمیت بسزایی یافته است.

شبکه‌های عصبی مصنوعی با الگوریتم آموزشی پس‌انتشار خطا دارای محدودیت‌هایی در تعیین ساختار بهینه شبکه مواجهند. در طراحی این شبکه‌ها باید تعداد لایه‌ها و نیز ساختار نرونی از قبیل تعداد وزن‌ها و مقادیر اولیه آنها، تابع تحریک هر نرون، نرخ آموزش و ضریب شتاب و معیار توقف آموزش به‌منظور جلوگیری از آموزش بیش از حد شبکه به‌درستی توسط کاربر انتخاب شوند تا یک نگاهشت مناسب و ایده‌آل میان داده‌های ورودی و خروجی برقرار شود [۱۸].

مزیت شبکه‌های عصبی نوع GMDH در مقایسه با شبکه‌های عصبی متداول از قبیل پرسپترون تک‌لایه و چند لایه‌ای است که شبکه عصبی GMDH یک شبکه خودسامانده<sup>۷</sup> بوده و متغیرهای مؤثر ورودی، تعداد لایه‌ها و

نرون‌ها در لایه پنهان و ساختار بهینه‌ی مدل به‌صورت خودکار تعیین می‌شوند. این کار بر اساس کمیته‌سازی معیار خارجی در حین کامل شدن ساختار انجام می‌پذیرد [۱۸]. شبکه عصبی GMDH در برگیرنده مجموعه‌ای از نرون‌ها بوده که از پیوند جفت‌های مختلف از طریق یک چندجمله‌ای درجه دوم به وجود می‌آید. اگر مجموعه‌ای از  $m$  متغیر شامل  $x_1, x_2, \dots, x_m$  و یک متغیر  $y$  وجود داشته باشد، الگوهای مربوط به هر کدام از  $x_i$ ها و متغیر هدف  $y$  متغیر خروجی نیز برای یک دوره زمانی وجود دارد. به عبارتی هر یک از متغیرها به‌صورت یک بردار می‌باشد که شامل اعداد سری زمانی مربوط به آن متغیر است. اطلاعات اولیه‌ای که جهت ساخت الگوریتم GMDH باید جمع‌آوری شود مجموعه‌ای از  $n$  مشاهده است که در ماتریس زیر نشان داده شده است:

$$\begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_{\eta t} \\ \vdots \\ y_n \end{bmatrix} = \begin{bmatrix} x_{11} & x_{12} & \dots & \vdots & x_{1m} \\ x_{21} & x_{22} & \dots & \vdots & x_{2m} \\ \vdots & \vdots & \dots & \vdots & \vdots \\ x_{\eta 1} & x_{\eta 2} & \dots & \vdots & x_{\eta m} \\ \vdots & \vdots & \dots & \vdots & \vdots \\ x_n & x_{n2} & \dots & \vdots & x_{nm} \end{bmatrix}$$

در الگوریتم فوق، رابطه‌ای که متغیر خروجی را به متغیرهای ورودی  $x_i$ ها مرتبط می‌کند تشخیص داده شده و سپس  $y$  به‌ازای مقادیر معلوم  $x_i$ ها پیش‌بینی می‌شود [۱۸]. مبنای الگوریتم GMDH عبارت است از فرآیندی جهت ساخت یک چندجمله‌ای با مراتب بالا که به سری تابع ولتر<sup>۸</sup> یا سری ایواخنینکو<sup>۹</sup> معروف است و به‌صورت رابطه (۵) ارائه می‌گردد:

$$\hat{y} = a_0 + \sum_{i=1}^m a_i x_i + \sum_{i=1}^m \sum_{j=1}^m a_{ij} x_i x_j + \sum_{i=1}^m \sum_{j=1}^m \sum_{k=1}^m a_{ijk} x_i x_j x_k + \dots \quad (5)$$

برای غلبه بر این مشکل، محققین زیادی تاکنون با استفاده از روش‌های بهینه‌سازی تکاملی سعی در بهبود عملکرد شبکه‌های عصبی GMDH نموده‌اند. تلفیق الگوریتم ژنتیک (GA) و شبکه عصبی GMDH یکی از این تلاش‌هاست.

روش‌های تکاملی از قبیل الگوریتم ژنتیک در طراحی پارامترهای مختلف شبکه‌های عصبی کاربرد گسترده‌ای دارند؛ زیرا یکی از قوی‌ترین روش‌ها برای پیدا کردن بهینه‌ی سراسری در فضاهای جستجو هستند که مشتق‌پذیر نیستند. این قبیل روش‌های تصادفی عموماً برای آموزش شبکه‌های عصبی در بهینه‌سازی وزن‌ها یا ضرایب، نسبت به روش‌های کلاسیک گرادینان بهتر عمل می‌کنند [۱۹].

در تحقیق حاضر، ساختار شبکه‌های عصبی و وزن‌های آن به‌طور هم‌زمان توسط الگوریتم ژنتیک و حل معادلات جزئی بهینه می‌شوند. کاربرد هم‌زمان الگوریتم ژنتیک و معادلات جزئی در طراحی بهینه شبکه‌های عصبی نوع GMDH منجر به یافتن ساختاری بهینه و با معادلات بهینه می‌گردد [۱۹].

شبکه‌های عصبی GMDH برای ساخت نرون در لایه‌ی جدید از نرون‌ها در تمامی لایه‌های قبلی استفاده می‌کنند. برای نشان دادن چگونگی بهینه‌سازی لایه‌های شبکه، از کدگذاری الگوریتم ژنتیک استفاده می‌شود. ژنوم یا نمایش کروموزوم که جزئیات ساختاری شبکه GMDH را نشان می‌دهد، از رشته‌هایی که اجزای آن حروف الفبا هستند، ساخته شده است. در این روش کدگذاری، داده‌های مختلف ورودی با حروف الفبا نام‌گذاری می‌شوند و هر کروموزوم رشته‌ای است که از به هم پیوستن داده‌های ورودی نام‌گذاری شده ایجاد شده است [۲۰].

بنابراین داده‌های ورودی را می‌توان به‌صورت رشته‌ای به‌هم‌پیوسته از نشانه‌های  $\alpha_i \in \{a, b, c, d, \dots\}$  و جمعیت‌ها را به‌صورت  $\text{chromosome} = (\alpha_1, \alpha_2, \alpha_3, \dots, \alpha_n)$  معرفی کرد. برای مثال کروموزومی مانند  $abbcadb$  شبکه‌ی GMDH منحصر به فردی را ایجاد می‌کند که شامل چهار داده‌ی ورودی و یک داده‌ی خروجی می‌باشد (شکل ۲).

برای این منظور در الگوریتم GMDH ابتدا سری توابع ولترا به چند جمله‌ای‌های دو متغیره درجه دوم تجزیه می‌شود:

$$G(x_i, x_j) = a_0 + a_1 x_i + a_2 x_j + a_3 x_i^2 + a_4 x_j^2 + a_5 x_i x_j \quad (6)$$

در این تجزیه سری ولترا به مجموعه‌ای از معادلات بازگشتی زنجیره‌ای تبدیل می‌شود به‌گونه‌ای که مجدداً با جایگذاری جبری هر یک از روابط بازگشتی در این رابطه سری ولترا برقرار می‌گردد.

$$y_i = f(x_{i1}, x_{i2}, x_{i3}, \dots, x_{im}) \quad i = 1, 2, 3, \dots, m \quad (7)$$

و توسط تابع  $f$  تقریب زده می‌شود:

$$\hat{y}_i = \hat{f}(x_{i1}, x_{i2}, x_{i3}, \dots, x_{im}) \quad i = 1, 2, 3, \dots, m \quad (8)$$

$$\hat{y} = a_0 + \sum_{i=1}^m a_i x_i + \sum_{i=1}^m \sum_{j=1}^m a_{ij} x_i x_j + \sum_{i=1}^m \sum_{j=1}^m \sum_{k=1}^m a_{ijk} x_i x_j x_k + \dots \quad (9)$$

بعد از تجزیه سیستم اصلی به تعداد  $C_m^2$  سیستم جزئی، مدلی با دو متغیر ورودی برای هر یک از این سیستم‌ها محاسبه می‌شود. سپس مدل‌های جزئی ایجاد شده دوبه‌دو با هم ترکیب شده و تعداد  $\frac{C_m^2(C_m^2 - 1)}{2}$  مدل جزئی جدید با حداقل سه و چهار متغیر ورودی به دست می‌آید. قابل ذکر است که تعداد متغیرهای وابسته به مدل و یا به عبارتی تعدادی ورودی‌ها تنها دقت تخمین واقعی سیستم اصلی توسط مدل‌های ایجاد شده را افزایش می‌دهند. لذا با در نظر گرفتن این قاعده برای کاهش محاسبات مضاعف و زائد و افزایش راندمان و دقت مدل‌سازی تعدادی از مدل‌های جزئی تشکیل شده که از دقت و تخمین بالایی نسبت به مدل‌های دیگر برخوردار هستند انتخاب و مابقی حذف می‌شوند.

در شبکه‌های عصبی GMDH مرسوم، از روش انتخاب پرخور<sup>۱</sup> برای یافتن تعداد نرون‌ها، لایه‌ای مخفی و وزن‌ها استفاده می‌شود [۱۸]. این روش در برخی موارد منجر به عدم یافتن بهینه سراسری<sup>۱۱</sup> و ایجاد بایاس شدید می‌گردد [۱۸].

۲۰۰۳ آمریکا [۲۷] و ۲۰۰۳ ژاپن [۲۸] می‌باشند. همچنین تعداد ۲۱ الگو از بانک اطلاعاتی به دلیل فقدان گزارش برخی از پارامترهای مورد نیاز جهت استفاده در رابطه (۶) از بانک اطلاعاتی حذف شد. در مجموع، ۵۲۶ الگو از ۱۸ زلزله و هفت ساختگاه مختلف گردآوری گردید.

جدول (۱): زلزله‌های موجود در بانک اطلاعاتی تحقیق حاضر.


Number of Patterns	Mw	Earthquake
3	7.9	1906 San Francisco - USA
275	7.5	1964 Niigata - Japan
6	9.2	1964 Alaska
26	6.4	1971 San Fernando - USA
3	7.5	1976 Guatemala
4	7.4	1977 Argentina
27	6.5	1979 Imperial Valley - USA
4	6.9	1983 Borah Peak - USA
68	7.7	1983 Nihonkai-Chubu - Japan
6	6.6	1987 Superstition Hills - USA
4	7	1989 Loma Prieta - USA
4	7.6	1990 Luzon - Phillipines
4	6.7	1994 Northridge - USA
22	6.9	1995 Hyogoken-Nambu - Japan
38	7.6	1999 Chi Chi - Taiwan
24	7.4	1999 Kocaeli (Izmit) - Turkey
6	6.5	2003 San Simeon - USA
2	7.9	2003 Tokachi-Oki - Japan
<i>sum = 526</i>		

با توجه به پارامترهای موجود در بانک اطلاعاتی، تابع ورودی و خروجی طبق رابطه (۱۰) تشکیل شده و توسط شبکه عصبی نوع GMDH و الگوریتم ژنتیک بهینه خواهد شد.

$$D=f(M_w, a_{max}, S, W, T_{15}, F_{15}, \quad (10)$$

$$D50_{15}, \varphi'_{eqv, liq}, z_{cr}, a_y/a_{max}, \tan\beta/\tan\varphi'_{eqv, liq}$$

که در آن  $a_{max}$  شتاب بیشینه زمین،  $\varphi'_{eqv, liq}$  زاویه اصطکاک داخلی معادل در شرایط روانگرایی،  $\beta$  زاویه شیب سطح زمین،  $a_y$  شتاب تسلیم معادل  $g(\varphi'_{eqv, liq} - \beta)$ ،  $z_{cr}$  عمق از سطح زمین تا لایه مستعد روانگرایی می‌باشند. شکل (۳) به‌طور شماتیک برخی از پارامترهای هندسی مربوط را نشان می‌دهد.



شکل (۲): نمونه‌ای از کدگذاری الگوریتم ژنتیک در ساختار شبکه‌های عصبی نوع GMDH.

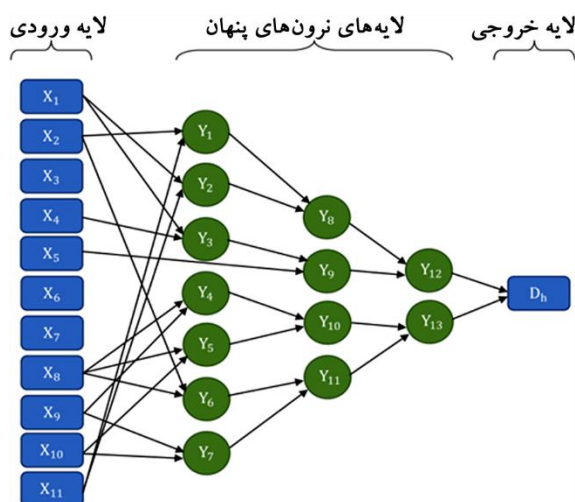
اکنون می‌توان از ژنوم شبکه عصبی GMDH برای دو عملگر مهم به نام‌های تقاطع<sup>۱۲</sup> (Cross-Over) و جهش<sup>۱۳</sup> استفاده کرد. دلیل استفاده از این عملگرها، جستجو در تمام فضای جواب و پیدا کردن بهترین جواب در میان مجموعه جواب‌ها می‌باشد. برای اعمال عملگر تقاطع با استفاده از یکی از روش‌های انتخاب تصادفی، دو والد<sup>۱۴</sup> برای تولید دو فرزند<sup>۱۵</sup> انتخاب می‌شود. تقاطع، ساختار اطلاعاتی شبکه GMDH را عوض می‌کند [۲۰]. جهش نیز با تغییر یک بایت اطلاعاتی در کروموزوم باعث تغییر و تنوع در جمعیت<sup>۱۶</sup> می‌گردد و شکل جدیدی را ایجاد می‌کند.

نتایج به‌دست‌آمده از این روش نمایانگر این موضوع است که کاربرد و قدرت الگوریتم ژنتیکی با استفاده از حروف الفبا، در یافتن جواب‌های بهینه در فضاهایی که مشتق‌پذیر و یا گسسته هستند به‌خوبی الگوریتم ژنتیکی با استفاده از اعداد در سیستم دودویی می‌باشد [۲۰].

#### ۴- نتایج و بحث

خلاصه‌ای از بانک اطلاعاتی جمع‌آوری شده در تحقیق حاضر در جدول (۱) نشان داده شده است. در این بانک اطلاعاتی، ۶۲ الگو از هشت زلزله به بانک اطلاعاتی مورد استفاده قبلی [۱۴] اضافه شد که شامل زلزله‌های ۱۹۷۶ گواتمالا [۲۱]، ۱۹۷۷ آرژانتین [۲۲]، ۱۹۹۰ فیلیپین [۲۳]، ۱۹۹۴ آمریکا [۲۴]، ۱۹۹۹ ترکیه [۲۵]، ۱۹۹۹ تایوان [۲۶]،


پس از انجام تحلیل، ساختار بهینه شبکه مطابق شکل (۴) و وزن‌های بهینه چندجمله‌ای‌ها مطابق جدول (۲) به دست آمده است.



شکل (۴): ساختار بهینه شبکه به دست آمده توسط الگوریتم GMDH.

در شکل فوق، پارامترهای ورودی عبارتند از:

$$X_1 = M_w, X_2 = a_{max}, X_3 = S, X_4 = W, X_5 = T_{15}, \\ X_6 = F_{15}, X_7 = D50_{15}, X_8 = \varphi'_{eqv,liq}, X_9 = z_{cr}, X_{10} = \\ a_y/a_{max}, X_{11} = \tan\beta/\tan\varphi'_{eqv,liq}$$



شکل (۳): پارامترهای هندسی مربوط به الگوهای ورودی.

به‌منظور مدل‌سازی و ارزیابی نتایج، الگوهای موجود در بانک اطلاعاتی به دو دسته آموزش<sup>۱۷</sup> و آزمایش<sup>۱۸</sup> تقسیم‌بندی شدند. بدین ترتیب که از مجموع ۵۲۶ الگو در بانک اطلاعاتی، ۷۰ درصد (شامل ۳۶۸ الگو) برای آموزش و ۳۰ درصد (شامل ۱۵۸ الگو) برای آزمایش مدل در نظر گرفته شد. به دلیل خودسامانده بودن الگوریتم GMDH، رابطه‌نهایی دارای پارامترهایی است که بیشترین تأثیر را بر خروجی داشته‌اند و بالطبع پارامترهای با تأثیر کم به‌طور خودکار از رابطه حذف شده‌اند؛ بنابراین، پارامترهای موجود در رابطه‌نهایی به‌صورت زیر می‌باشند:

$$D=f(M_w, a_{max}, W, F_{15}, D50_{15}, z_{cr}, \\ a_y/a_{max}, \tan\beta/\tan\varphi'_{eqv,liq}) \quad (11)$$

جدول (۲): وزن‌های بهینه به دست آمده توسط الگوریتم GMDH برای چندجمله‌ای‌ها.

	$a_0$	$a_1$	$a_2$	$a_3$	$a_4$	$a_5$
$Y_{13}$	0.3705	0.1592	-0.1596	0.0185	0.2166	0.1273
$Y_{12}$	0.0327	1.9594	-0.8436	-0.9167	0.003	0.89534
$Y_{11}$	2.0816	-1.9653	-1.199	0.461	0.2082	0.8354
$Y_{10}$	2.1622	-0.0303	-1.8291	-0.4184	0.2489	1.0541
$Y_9$	-0.8627	0.6344	0.1974	0.0379	0.2035	0.0501
$Y_8$	9.1161	-2.1049	-7.7253	-0.4703	1.4801	2.0431
$Y_7$	2.9709	-0.6542	-1.7809	0.0214	0.236	0.0466
$Y_6$	2.882	0.129	-0.0602	-15.147	-0.002	0.4565
$Y_5$	3.328	-0.053	-2.094	0.0004	0.182	0.028
$Y_4$	2.513	-0.015	-0.526	-0.0001	0.055	-0.012
$Y_3$	-79.993	21.066	-0.1367	-1.357	-0.004	0.054
$Y_2$	-41.901	11.369	10.355	-0.73	0.732	-1.6846
$Y_1$	2.389	0.17	-4.138	-3.759	-3.744	12.226

ندارند. همچنین عدم اختلاف بین پارامترهای آماری (RMSE و  $R^2$ ) بین مرحله آموزش و اعتبارسنجی به دلیل ماهیت بهینه‌سازی چند هدفی استفاده شده می‌باشد و نشان‌دهنده‌ی مقاوم بودن مدل در برابر تغییرات پارامترهاست. استفاده از الگوریتم ژنتیک به‌عنوان یک جستجوگر بهینه هم‌زمان با شبکه عصبی یکی از مزیت‌های روش استفاده شده در تحقیق حاضر نسبت به مطالعات محققین پیشین است. به‌کارگیری الگوریتم ژنتیک به‌طور هم‌زمان با شبکه عصبی نوع GMDH باعث بهینه شدن ساختار و وزن‌های شبکه، تعداد لایه‌های مخفی و ضرایب بایاس<sup>۱۹</sup> و در نتیجه کاهش خطای مدل‌سازی می‌گردد [۱۹]. برای بررسی بیشتر این مزیت، عملکرد مدل پیشنهادی به‌طور جداگانه در مقابل الگوهای چند زلزله آزمایش شد. نتایج این بررسی به‌صورت شکل‌های (۶-الف) تا (۶-ج) به تصویر کشیده شده است.

مقدار  $R^2$  برای زلزله‌های نینگاتا، نیهوناکی و سان‌فرناندو به ترتیب برابر ۰/۹۳، ۰/۹۲ و ۰/۹۲ به دست آمد که نشان‌دهنده‌ی عملکرد مناسب مدل پیشنهادی در تخمین مقادیر جابه‌جایی جانبی ناشی از روانگرایی می‌باشد.

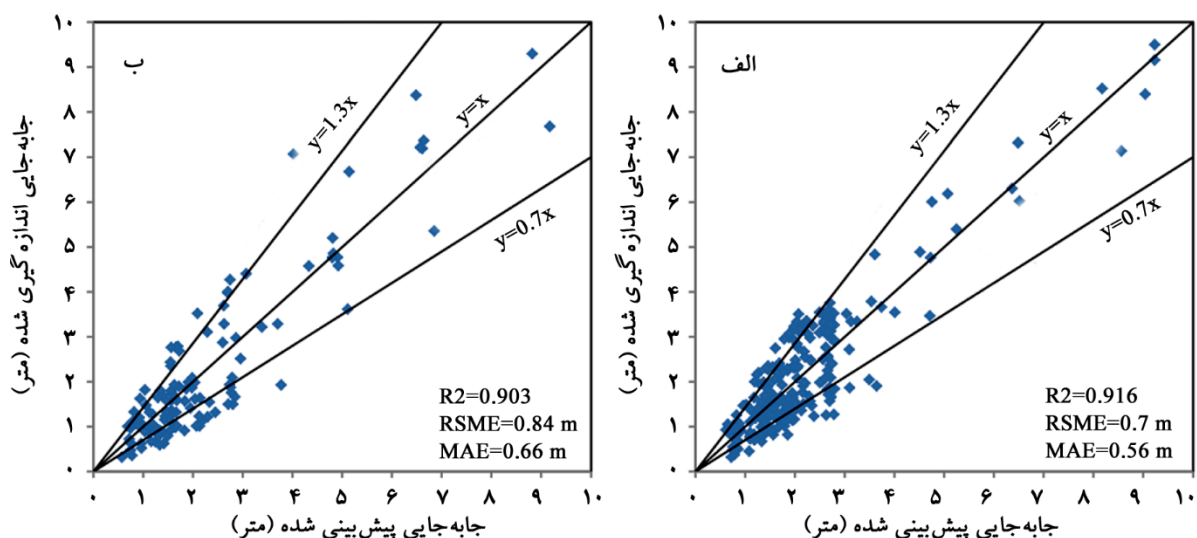
به‌منظور مقایسه مدل پیشنهادی با مدل‌های قبلی تخمین جابه‌جایی جانبی ناشی از روانگرایی، دو مدل [۱۴]MLR و [۱۶]GP

با در نظر گرفتن وزن‌های بهینه‌ی چندجمله‌ای‌ها و نیز ساختار شبکه بهینه که توسط الگوریتم ژنتیک به دست آمده است، رابطه زیر جهت تخمین جابه‌جایی جانبی حاصل از روانگرایی معرفی می‌شود:


$$D_h = 0.0493 + 0.1388Y_{12} + 0.4341Y_{13} + 0.011(Y_{12})^2 - 0.099(Y_{13})^2 + 0.2728Y_{12}Y_{13} \quad (12)$$

شکل (۵-الف) عملکرد مدل GMDH (رابطه ۱۲) را در خصوص یادگیری روابط پیچیده بین مشخصه‌های لرزه‌ای، پارامترهای خاک و ویژگی‌های توپوگرافی ساختگاه در مرحله آموزش نشان می‌دهد. همان‌طور که از این شکل می‌توان دید، مدل GMDH از دقت بالایی در مرحله آموزش برخوردار است ( $R^2 = 0.916$ ,  $RMSE = 0.70$  m).

همچنین مدل پیشنهادی توسط ۳۰ درصد الگوهای باقیمانده آزمایش شد. نتیجه این اعتبارسنجی در شکل (۵-ب) نشان داده شده است. از شکل فوق می‌توان نتیجه‌گیری نمود که مدل پیشنهادی در مرحله آزمایش (اعتبارسنجی) نیز عملکرد خوبی نشان داده است ( $R^2 = 0.903$ ,  $RMSE = 0.84$  m) و الگوهای پیش‌بینی شده با نتایج اندازه‌گیری شده اختلاف چندانی زیادی




شکل (۵). پیش‌بینی مقادیر جابه‌جایی جانبی توسط مدل GMDH در مراحل آموزش و آزمایش.



شکل (۶): عملکرد مدل GMDH برای زلزله‌های: (الف) نیگاتا، (ب) نیهوناکا و (ج) سان‌فرانسیسکو.

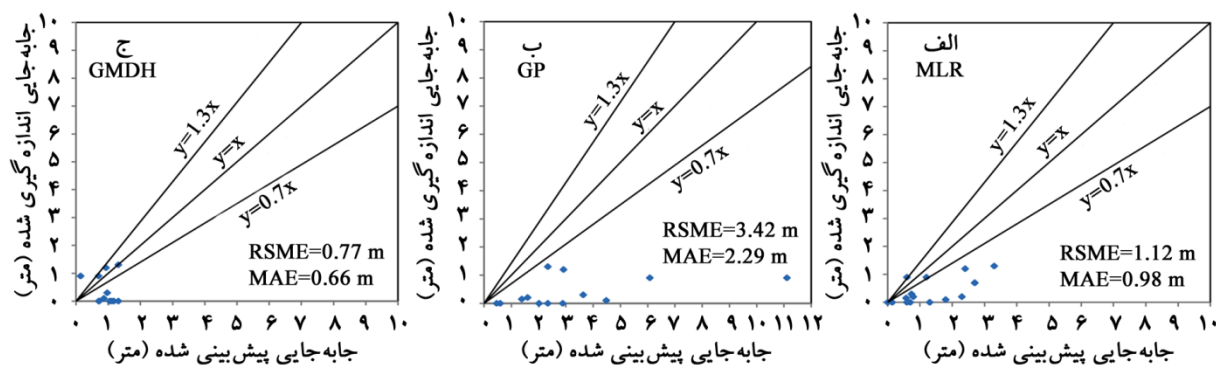
آزمایش‌های انجام شده توسط برخی محققین [۶، ۲۹-۳۰] استخراج شده است. مشخصات این آزمایش‌ها و نیز اندازه‌گیری‌های جابه‌جایی جانبی در جدول (۳) آورده شده است. به منظور مقایسه نتایج حاصل از تخمین مدل GMDH و نتایج آزمایش‌های سانتریفیوژ، لازم است که پارامترهای ورودی مدل GMDH در آزمایش‌های سانتریفیوژ معادل‌سازی شوند. از بین پارامترهای مدل، پارامترهای  $a_{max}$  و  $\beta$  مستقیماً از آزمایش‌های سانتریفیوژ به دست می‌آیند. با توجه به اینکه خاک مورد استفاده در تمامی آزمایش‌های سانتریفیوژ ماسه نوادا ۱۲۰ بود، با استفاده از مشخصات این نوع ماسه می‌توان پارامترهای  $F_{15}$ ،  $D_{50_{15}}$  و  $\tan\beta/\tan\phi'_{eq,liq}$  را نیز تعیین نمود. همچنین با توجه به شرایط هندسی آزمایش‌ها، پارامتر  $W$  به دست می‌آید. تنها پارامتر باقیمانده  $M_w$  است که می‌توان آن را از روابط موجود برای کاهش شتاب [۳۱] محاسبه نمود.

انتخاب شدند و به همراه مدل پیشنهادی تحقیق حاضر در برابر الگوهای موجود از زلزله‌های ۱۹۹۹ ترکیه و تایوان به آزمایش گذاشته شدند. ویژگی خاص زلزله‌های فوق این است که دارای مقادیر جابه‌جایی کوچک و یا حتی صفر می‌باشند. نتیجه این بررسی در شکل‌های (۷) و (۸) نشان داده شده است. همان‌گونه که از شکل‌های فوق می‌توان دید، مدل‌های MLR و GP مقادیر جابه‌جایی جانبی را بسیار بیشتر از مقدار اندازه‌گیری شده صحرائی پیش‌بینی کرده‌اند. در مقابل، مدل پیشنهادی حاضر، خطایی کمتر از ۳۰ درصد در پیش‌بینی‌های خود ایجاد نموده است که بیانگر توانایی مدل در پیش‌بینی مقادیر جابه‌جایی جانبی حتی در اندازه‌های کوچک و نزدیک به صفر می‌باشد. علاوه بر اعتبارسنجی مدل توسط الگوهای صحرائی، اعتبارسنجی توسط الگوهای حاصل از آزمایش‌های سانتریفیوژ نیز صورت پذیرفت. این الگوها از



شکل (۷): عملکرد مدل‌های مختلف در برابر زلزله ۱۹۹۹ تایوان، (الف) مدل MLR (ب) مدل GP و (ج) مدل پیشنهادی (GMDH).





شکل (۸): عملکرد مدل‌های مختلف در برابر زلزله ۱۹۹۹ ترکیه، الف) مدل MLR، ب) مدل GP و ج) مدل پیشنهادی (GMDH).

جابه‌جایی جانبی اندازه‌گیری شده در آزمایش‌های سانتریفیوژ مطابقت دارد. این موضوع نشان‌دهنده‌ی دقت مدل پیشنهادی در پیش‌بینی مقادیر جابه‌جایی جانبی حاصل از روانگرایی است که به دلیل استفاده از بانک اطلاعاتی جامع و کامل در توسعه مدل می‌باشد.

پس از معادله‌سازی پارامترهای مدل، محاسبات مدل GMDH برای تمامی آزمایش‌های صورت پذیرفته و نتایج آن در شکل (۹) نشان داده شده است. همان‌طور که از این شکل می‌توان دید، مقادیر محاسبه شده توسط مدل پیشنهادی GMDH به‌خوبی با مقادیر

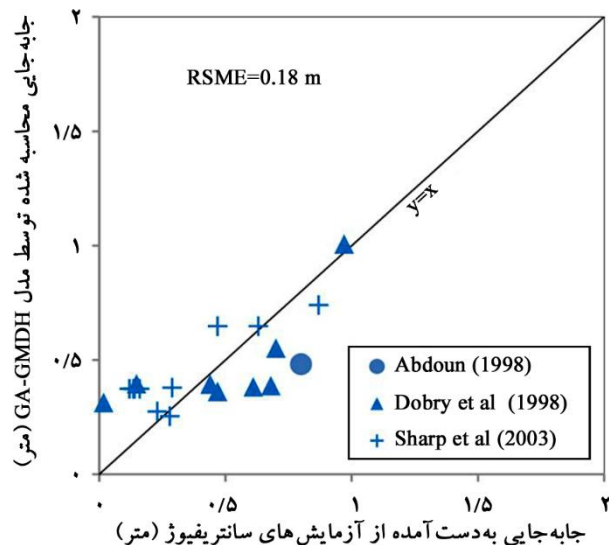
جدول (۳): مشخصات و نتایج آزمایش‌های سانتریفیوژ [۲۹-۳۰] به همراه نتایج پیش‌بینی شده توسط مدل GMDH.

Publication	Dr(%)	Slope Angle (Degree)	amax(in base) (g)	Thick. of Liq. Layer (m)	Dh from Centrifuge Test (m)	Dh from GA-GMDH Model (m)
Taboada & Dobry [۶]	40-45	0	0.23	10	0.017	0.312
Taboada & Dobry [۶]	40-45	4.96	0.18	10	0.44	0.394
Taboada & Dobry [۶]	40-45	4.8	0.23	10	0.47	0.361
Taboada & Dobry [۶]	40-45	5.44	0.46	10	0.97	1.007
Taboada & Dobry [۶]	40-45	5.16	0.19	10	0.61	0.404
Taboada & Dobry [۶]	40-45	4.96	0.25	10	0.68	0.381
Taboada & Dobry [۶]	40-45	1.3	0.26	10	0.148	0.387
Taboada & Dobry [۶]	40-45	10	0.17	10	0.7	0.395
Abdoun [۳۰]	40	2	0.3	10	0.8	0.48
Abdoun [۳۰]	40	2	0.3	10	0.8	0.48
Sharp et al. [۲۹]	45	2	0.41	10	0.87	0.739
Sharp et al. [۲۹]	65	2	0.2	10	0.28	0.253
Sharp et al. [۲۹]	65	2	0.38	10	0.63	0.647
Sharp et al. [۲۹]	75	2	0.21	10	0.23	0.274
Sharp et al. [۲۹]	75	2	0.38	10	0.47	0.647
Sharp et al. [۲۹]	75	5	0.22	6	0.12	0.373
Sharp et al. [۲۹]	75	5	0.21	6	0.14	0.373
Sharp et al. [۲۹]	45	5	0.2	6	0.29	0.379
Sharp et al. [۲۹]	45	5	0.21	6	0.135	0.373
Sharp et al. [۲۹]	45	5	0.21	6	0.16	0.373

مختلف انجام پذیرفته است، گردآوری شد و با معادل سازی پارامترهای مدل GMDH با استفاده از مشخصات آزمایش های سانتریفیوژ، محاسبات توسط رابطه پیشنهادی جدید صورت پذیرفت. نتیجه این بررسی نشان می دهد که مقادیر پیش بینی شده توسط مدل GMDH با مقادیر اندازه گیری شده در آزمایش ها مطابقت خوبی داشته و مدل از توانایی بالایی در پیش بینی مقادیر جابه جایی جانبی ناشی از روانگرایی برخوردار است.

### مراجع

1. Committee on Earthquake Engineering Research (1985) *Liquefaction of Soils During Earthquakes*. National Research Council, National Academy Press, Washington, D.C., 240 pp.
2. Newmark, N.M. (1965) Effects of Earthquakes on Embankments and Dams. *Géotechnique*, **15**(2), 139-160.
3. Makdisi, F.I. and Seed, H.B. (1978) Simplified procedure for estimating dam and embankment earthquake-induced deformations. *J. Geotech. Eng. Div.*, **104**(GT7), 849-867.
4. Towhata, I., Sasaki, Y., Tokida, K.I., Matsumoto, H., Tamari, Y., and Yamada, K. (1992) Prediction of Permanent Displacement of Liquefied Ground by means of Minimum Energy Principle. *Soils and Foundations*, **JSSMFE**, **32**(3), 97-116.
5. Elgemal, A.W., Zeghal, M., Taboada, V., and Dobry, R. (1996) Analysis of site liquefaction and lateral spreading using centrifuge testing records. *Soils and Foundations*, **36**(2), 111-121.
6. Taboada, V.M. and Dobry, R. (1998) Centrifuge modeling of earthquake-induced lateral spreading in sand. *J. Geotech. Geoenviron. Eng.*, **124**(12), 1195-1206.
7. Olson, S.M. and Johnson, C.I. (2002) Analyzing liquefaction-induced lateral spreads using strength ratios. *J. Geotech. Geoenviron. Eng.*, **134**(8), 1035-1049.
8. Sharp, K.M., Dobry, R., and Abdoun T. (2003) Centrifuge modeling of liquefaction and lateral



شکل (۹): مقایسه پیش بینی مدل GMDH در مقابل الگوهای حاصل از آزمایش سانتریفیوژ.

### ۵- نتیجه گیری

در تحقیق حاضر، یک مدل جدید بر پایه روش شبکه عصبی نوع GMDH بهینه شده با الگوریتم ژنتیک به منظور تخمین جابه جایی های جانبی ناشی از روانگرایی توسعه داده شد. برای این منظور، یک بانک اطلاعاتی وسیع شامل ۵۲۶ الگو که از ۱۸ زلزله مختلف در ۱۰ ساختمانگه جمع آوری گردید، مورد استفاده قرار گرفت تا مدلی جامع و قدرتمند به دست آید. پس از مدل سازی، رابطه ای بهینه شامل ۸ پارامتر ورودی به دست آمد و عملکرد آن در هر دو بخش آموزش و آزمایش از نظر معیارهای آماری قابل قبول بود.

همچنین عملکرد مدل پیشنهادی در مقابل الگوهای چند زلزله به طور جداگانه بررسی و با سایر مدل های موجود در متن مقایسه شد. نتیجه این بررسی و مقایسه نشان دهنده ای این است که مدل پیشنهادی در تحقیق حاضر علاوه بر پیش بینی دقیق تر مقادیر جابه جایی جانبی نسبت به مدل های سایر محققین (مدل های MLR و GP)، توانایی تخمین جابه جایی های کوچک و نزدیک به صفر را نیز دارا می باشد.

در انتها، به منظور اعتبارسنجی مدل پیشنهادی با استفاده از نتایج آزمایشگاهی، نتایج ۲۸ آزمایش سانتریفیوژ که توسط محققین

- Zadeh, G.R. (2003) Hybrid genetic design of GMDH-type neural networks using singular value decomposition for modeling and predicting of the explosive cutting process. *Inst. Mech. Eng.*, **217**(B), 779–790.
21. Seed, H.B., Arango, I., Chan, C.K., Gomez-Masso, A. and Ascoli, R.G. (1979) *Earthquake-Induced Liquefaction Near Lake Amatitlan, Guatemala*. Report No. UCB/EERC-79/27.
22. Rojahn, C., Brogan, G.E., and Siemmons, D.B. (1977) *Preliminary Report on the San Juan, Argentina Earthquake of November 23, 1977*. U.S. Geological Survey, Menlo Park, CA, USA.
23. Tokimatsu, K., Kojima, H., Kuwayama, S., Abe, A., and Midorikawa, S. (1994) Liquefaction-Induced Damage to Buildings in 1990 Luzon Earthquake. *J. Geotech. Eng.*, **120**(2), 290-307.
24. Holzer, T., Bennett, M.J., Ponti, D.J. and Tinsley, J.C. (1999) Liquefaction and Soil Failure during the 1994 Northridge Earthquake. *J. Geotech. Geoenviron. Eng.*, **125**(6), 438-452.
25. Cetin, K.O., Youd, T.L., Seed, R.B., Bray, J.D., Sancio, R., Lettis, W., Tolga, M.T., and Durgunoglu, H.T. (2002) Liquefaction-Induced Ground Deformations at Hotel Sapanca during Kocaeli (Izmit)-Turkey Earthquake. *Int. J. Soil Dyn. Earth. Eng.*, **22**, 1083- 1092.
26. Juang, C.H. and Jiang, T. (2000) *Assessing Probabilistic Methods for Liquefaction Potential Evaluation*. Geotechnical Special Publication No. 107, Soil Dyn. Liquefaction 2000, R.Y.S. Pak and J. Yamamura, eds., ASCE, Reston, VA. 148-162.
27. Holzer, T., Noce, T.E., Bennett, M.J., Alessandro, C., Boatwrite, J., Tinsley, J.C., Sell, R.W. and Rosenberg, L.I. (2004) *Liquefaction-Induced Lateral Spreading in Oceano, California, During the 2003 San Simeon Earthquake*. USGS Open-File Report No. 2004–1269, Version 1.0.
28. Sasajima, T., Kabouchi, A., Kohama, E., Watanabe, J., Miura, K., and Otsuka, N., (2005) Liquefaction induced deformation of test quay wall in Kushiro Port during the 2003 Tokachi-oki earthquake. spreading of virgin, over-consolidated and pre-shaken sand deposits. *Int. J. Phys. Model. in Geotechnics*, **2**, 11-20.
9. Gu, W.H., Morgenstern, N.R. and Robertson, P.K. (1993) Progressive Failure of Lower San Fernando Dam. *J. Geotech. Eng.*, **119**(2), 333-349.
10. Finn, W.D.L., Ledbetter, R.H., and Wu, G. (1994) Liquefaction in Silty Soils: Design and Analysis. Ground Failures under Seismic Conditions. *Geotec. Spec. Pub.*, **44**, 51-76.
11. Valsmais, A., Bouckovalas, G. and Papadimitriou, A. (2010) parametric investigation of lateral spreading of gently sloping liquefied ground. *J. Soil Dyn. Earthq. Eng.*, **30**, 490–508.
12. Youd, T.L. and Perkins, D.M. (1987) Mapping of liquefaction severity index. *J. Geotech. Eng.*, **113**(11), 1374–1391.
13. Bartlett, S.F. and Youd, T.L. (1995) Empirical prediction of liquefaction-induced lateral spread. *J. Geotechnical Eng. Div.*, **121**(4), 316–29.
14. Youd, T.L., Hansen, C.M. and Bartlett, S.F. (2002) Revised multilinear regression equations for prediction of lateral spread displacement. *J. Geotech. Geoenviron. Eng.*, **128**(12), 1007–1017.
15. Wang, J. and Rahman, M.S. (1999) A neural network model for liquefaction induced horizontal ground displacement. *J. Soil Dyn. Earthq. Eng.*, **18**, 555–68.
16. Javadi, A.A., Rezanian, M., and MousaviNezhad, M. (2006) Evaluation of liquefaction induced lateral displacements using genetic programming. *J. Comp. Geotech.*, **33**, 222-233
17. Garcia, S.R., Romo, M.P. and Botero, E. (2008) A neuro fuzzy system to analyze liquefaction-induced lateral spread. *Soil Dyn. Earth. Eng.*, **28**, 169–180.
18. Ivakhnenko, A.G. (1971) Polynomial theory of complex systems. *IEEE Trans. Sys. Mng. Cyber. SMC.*, **1**, 364–378.
19. Onwubolu, G.C. (2009) *Hybrid Self-Organizing Modeling Systems*. Springer-Verlag, Heidelberg.
20. Nariman-Zadeh, N., Darvizeh, A., and Ahmad-

*Earthq. Eng. Soil Dyn.*, **133**, 1-15.

29. Sharp, K.M., Dobry, R., and Abdoun, T. (2003) Liquefaction centrifuge modeling of sands of different permeability. *J. Geotech. Geoenviron. Eng.*, **129**(12), 1083-1091.
30. Abdoun, T.H. (1997) Modeling of seismically induced lateral spreading of multi-layered soil and its effect on pile foundations. Ph.D. Thesis, Rensselaer Polytechnic Institute, Troy, New York.
31. Jonyer, W.J. and Boore, D.M. (1991) Strong earthquake ground motion and engineering design. *Geotech. News.*, **9**(1), 21-26.

### واژه‌نامه

Group Method of Data Handling	۱- شبکه عصبی نوع GMDH
Niigata	۲- نیگاتا
Prince William	۳- پرنس ویلیام
Sliding Block Analysis	۴- تحلیل بلوک لغزان
Gently Sloping	۵- شیب ملایم
Free Face	۶- وجه آزاد
Self-Organizing	۷- خودسامانده
Volterra Functional Series	۸- سری تابع ولترا
Ivakhnenko	۹- ایواخنینکو
Greedy Selection	۱۰- انتخاب پرخور
Global Optima	۱۱- بهینه سراسری
Cross-Over	۱۲- تقاطع
Mutation	۱۳- جهش
Parents	۱۴- والد
Offspring	۱۵- فرزند
Population	۱۶- جمعیت
Learning	۱۷- آموزش
Testing	۱۸- آزمایش
Bias	۱۹- بایاس

## Developing a Model to Estimate the Liquefaction Induced Lateral Displacement Using a New Geotechnical Database

Farhang Farrokhi<sup>1</sup>, Alireza Firoozfar<sup>1</sup> and Mohammad Sadegh Maghsoudi<sup>2\*</sup>

1. Assistant Professor, University of Zanjan, Zanjan, Iran

2. Ph.D. Candidate, University of Zanjan, Zanjan, Iran,

\*Corresponding Author, e-mail: m.s.maghsudi@gmail.com

The pore water pressure increase in saturated sands is a consequence of cyclic shear stresses induced by earthquake loads. Following this change, the shear strength of soil rapidly decreases and liquefaction of soil may be occurred. Most types of failure associated with the liquefaction phenomena are: sand boil, flow failure of slopes, ground oscillation, loss of bearing capacity, ground settlement, and lateral spreading.

Liquefaction-induced lateral spreading is one of the most important factors of major damage to Ground and underground structures during earthquakes. This type of permanent ground displacement, which has amplitudes ranging from a few centimeters to 10 meters and more, has caused substantial damages to lifelines and pile-foundations of buildings and bridge piers along the past earthquakes.

Although the mechanism of soil liquefaction is well recognized, the prediction of liquefaction-induced horizontal displacement is associated with the complexity and difficulty, due to the involvement of multiplex parameters. Several researches have been done to develop techniques for lateral ground displacement prediction. These techniques can be divided into four classes, including simplified analytical, numerical, empirical, and artificial neural network methods. Since the simplified analytical methods consider the shear strength of soil unchanged during an earthquake, these methods may not provide an accurate estimate of lateral displacements caused by liquefaction of soil. Besides, due to the complexities related to the accurate modeling and the difficulties in measuring the in-situ parameters of soil layers, it is obvious that the consideration of some simplifications in numerical methods is required, which may reduce their capabilities. Due to the limitations related to analytical and numerical methods, many researchers developed empirical models based on ground displacement records. Empirical methods detect the relationship between in-situ displacements and various effective parameters by regression method. It is believed that ANN models compared to the conventional regression methods can predict complex problems, such as liquefaction-induced lateral spreading more accurately.

In the present study, a new model with the ability to estimate the lateral displacement caused by liquefaction has been developed using the Group Method of Data Handling (GMDH) type neural networks. In this method, complicated relationships are developed according to their efficiency against a series of multi-input single-output data pairs. GMDH algorithms present a tool to find the appropriate relationship between data, recognize the optimal structure of the network, and improvement in accuracy of existing algorithms. In general, the GMDH type neural network includes certain advantages compared to other types of neural networks. In particular, it has the ability to find and select the most suitable input variables from a set of variables. By sorting different solutions, GMDH networks minimize the influence of the user on the structure and results of modeling. The computer automatically finds the optimal structure of the model and the laws acting on the system.

In this study, a comprehensive database containing 526 case histories and recorded over 18 major earthquakes was utilized to correlate the liquefaction-induced lateral spreading with the most effective parameters. Since the presented model has been developed based on numerous earthquakes and site conditions, it is more general and reliable than previous models. The obtained results indicate that the GMDH model has the ability to predict the lateral spreading with a high degree of accuracy. In order to validate the new proposed model, the displacements

obtained by 28 centrifuge tests were compared with the results of the GA-GMDH model. The comparison showed a high degree of accuracy of the new GA-GMDH model, indicating a good predictive capability of the model, even at small ground displacements. Moreover, comparing the performance of the model developed in the present study with experimental results in literature shows the accuracy of predicted values by the new model.

**Keywords:** Lateral Spreading, Liquefaction, GMDH Type Neural Network, Geotechnical Database.