

## پیش‌بینی سرعت موج برشی در سنگ آهک با استفاده از روش‌های نوین هوشمند

سیدرحیم معین‌السادات\*، کاوه آهنگری، دانیال بهنیا؛  
گروه مهندسی معدن، دانشگاه آزاد اسلامی، واحد علوم و تحقیقات،  
تهران، ایران

تاریخ: دریافت ۹۱/۷/۳ پذیرش ۹۲/۳/۱۱

### چکیده

هدف از این پژوهش، توسعه مدلی هوشمند، برای تخمین سرعت موج برشی در سنگ آهک است. سرعت موج برشی، از مهم‌ترین پارامترهای دینامیکی سنگ است. با توجه به پیچیدگی ساختار سنگ، تعیین مستقیم این پارامتر مستلزم زمان، هزینه و دقت است. از طرفی برای تعیین غیرمستقیم آن، روابط دقیقی در دسترس نیست و بیش‌تر روابط، تجربی هستند. در این تحقیق سعی می‌شود با استفاده از مجموعه داده‌های چندین سد در ایران، به کمک روش آنفیس (سیستم استنتاج عصبی-فازی تطبیقی) و جپ (GEP) مدل و رابطه‌ای برای پیش‌بینی سرعت موج برشی در سنگ آهک تهیه شود. در مجموع، از ۱۷۰ دسته داده برای مدل‌سازی استفاده شد. ۱۳۶ دسته داده برای ساخت مدل هوشمند و ۳۴ داده دیگر برای ارزیابی عمل‌کرد آن به کار گرفته شد. پارامترهایی مانند سرعت موج فشاری، چگالی و تخلخل به عنوان پارامترهای ورودی در نظر گرفته شدند. در پیش‌بینی‌های صورت گرفته به این منظور، میزان  $R^2$  و RMSE برای مدل آنفیس به ترتیب ۰/۹۵۸ و ۱۱۳/۶۲۰ است. این مقادیر برای رابطه جپ ۰/۹۲۸ و ۱۱۰/۰۰۶ است. با توجه به دقت این نتایج، می‌توان آن‌ها را برای پیش‌بینی سرعت موج برشی در مقاصد آینده پیشنهاد کرد.

واژه‌های کلیدی: سرعت موج برشی، سدهای ایران، سنگ آهک، آنفیس، جپ

### مقدمه

امروزه استفاده از روش‌های دینامیکی برای برآورد دقیق و سریع ثابت‌های الاستیک در مهندسی سنگ کاملاً پذیرفته شده است و از آن‌جاکه این آزمایش‌ها غیرمخرب هستند، از آن‌ها زیاد استقبال می‌شود [۱]. مهم‌ترین امواج مکانیکی برای این منظور، امواج فشاری و برشی هستند. پیچیدگی ساختار سنگ، مسائل مربوط به آن را تحت تأثیر قرار داده است. تهیه مغزه برای انجام آزمایش، همیشه آسان و ممکن نیست و برای انجام آزمایشی مطلوب به نمونه‌هایی با کیفیت زیاد نیاز است. تهیه نمونه در سنگ‌های به شدت هوازده یا خردشده اهمیت بیش‌تری خواهد داشت [۲]. در نتیجه می‌توان گفت که تعیین غیرمستقیم یک پارامتر، اهمیت ویژه‌ای پیدا می‌کند. از طرفی، برای تعیین غیرمستقیم آن، روابط دقیقی در دسترس نیست و بیش‌تر روابط، تجربی و آزمایشگاهی هستند. پارامترهای متعددی بر روی سرعت موج برشی تأثیر می‌گذارند که تمامی این پارامترها در روابط تجربی گنجانده نمی‌شوند. از آن‌جاکه مدل‌های تجربی برای پیش‌بینی سرعت موج برشی، غالباً مدل‌های ریاضی هستند که از داده‌های موجود در یک سازند خاص ایجاد شده‌اند، فاقد قدرت تعمیم برای هر نوع سازندی هستند. اکثر این روابط، برای سازندهای ماسه‌ای ارائه شده‌اند و برای تمام لیتولوژی‌ها به‌خوبی پاسخگو نیستند. در نتیجه روابط ارائه شده جامع نیستند و هر یک از مدل‌های تجربی در مقایسه با دیگری جواب‌هایی کاملاً متفاوت می‌دهند. که این امر، انتخاب بین آن‌ها را مشکل می‌کند [۳]، [۴]. از این رو، از سال‌ها قبل، محققان متعددی برای نیل به این هدف کوشیده‌اند و روابط گوناگونی را توسعه داده‌اند. با توجه به قدرت روش‌های هوشمند در حل مسائلی با مکانیزم پیچیده، از این روش‌ها اخیراً، برای پیش‌بینی سرعت امواج الاستیک استفاده شده است. روش‌هایی مانند شبکه‌های عصبی مصنوعی، سیستم‌های فازی، الگوریتم ژنتیک و ... به کار گرفته شده‌اند. از این قبیل می‌توان به کادی<sup>۱</sup> (۱۹۹۸)، محقق (۲۰۰۰)، سگاف و نبريجا<sup>۲</sup> (۲۰۰۳) و رضایی و همکاران (۲۰۰۷، ۲۰۰۸) اشاره کرد [۵]، [۶]، [۷]، [۸]، [۹]. به‌طور مثال رجبی و همکاران (۲۰۱۰) با استفاده از روش‌های هوشمندی مانند منطق فازی، آنفیس و الگوریتم ژنتیک سرعت موج برشی

و فشاری را در مخزن ساروک ایران پیش‌بینی کرده‌اند [۴]. نتایج همه این بررسی‌ها مطلوب است و به‌روشنی قدرت و مزایای به‌کارگیری روش‌های هوشمند مشهود است.

#### ۱. Cuddy      ۲. Saggaf and Nebrija

با توجه به محدودیت‌های موجود و پیشنهاد روشی ساده‌تر و دقیق‌تر، می‌توان از روش‌های هوش مصنوعی استفاده کرد. برای پیش‌بینی سرعت موج برشی در این تحقیق، از دو روش هوشمند نوین با نام‌های آنفیس<sup>۱</sup> (ANFIS) و جپ<sup>۲</sup> (GEP) که برای حل مسائل پیچیده و متنوع مهندسی، از روش‌های پرکاربرد هستند، استفاده شد. برای ساخت مدل‌های هوشمند، پارامترهایی مانند سرعت موج فشاری (Vp)، چگالی (γ) و تخلخل (n) به‌عنوان پارامترهای ورودی در نظر گرفته شدند. ۱۷۰ دسته داده از چندین سد مهم ایران از جمله خرسان ۱، ۲ و ۳، تلمبه‌خانه ایلام، کارون ۴، رودبار لرستان، ماشکید، ژان، سیمره و تنگ معشوره جمع‌آوری شدند [۱۰]. ۱۷۰ دسته داده موجود به‌صورت تصافی به دو دسته آموزش<sup>۳</sup> و آزمایش<sup>۴</sup> تقسیم شدند. لیتولوژی این داده‌ها نیز سنگ آهک است.

### تئوری روش‌های استفاده شده

#### ۱. سیستم استنتاج عصبی فازی تطبیقی (آنفیس)

آنفیس تلفیق منطق فازی<sup>۵</sup> و شبکه‌های عصبی مصنوعی<sup>۶</sup> است که یانگ<sup>۷</sup> در سال ۱۹۹۳ معرفی کرد [۱۱]. هر کدام از سیستم‌های فازی و شبکه‌های عصبی مصنوعی، مزایا و معایبی دارند. سیستم فازی قادر به استفاده از زبان بشری است و می‌تواند از تجربیات بشری و افراد متخصص و خبره استفاده کند در حالی‌که قادر به یادگیری نیست. اما شبکه‌های عصبی با استفاده از مجموعه داده‌ها، قابلیت خودآموزی دارند. در عین حال، شبکه‌های عصبی غیرصریح هستند و قادر به استفاده از زبان بشری نیستند [۱۲]. در نتیجه می‌توان گفت آنفیس از مزایای هر دو سیستم عصبی و فازی برخوردار است [۱۳]، [۱۴]. غالباً سیستم‌های آنفیس را با استفاده از سیستم فازی تاکاگی سوگنو (TSK)<sup>۸</sup> به‌کار می‌برند. هدف اصلی مدل سوگنو ساخت مدل‌سازی فازی به‌صورت اتوماتیک از داده‌های اندازه‌گیری شده است. در روش فازی TSK، قوانین

اگر-آن‌گاه برای یک سیستم با دو ورودی  $x, y$  که هر کدام با دو تابع عضویت توصیف می‌شوند، به صورت رابطه (۱) و (۲) ارائه می‌شوند.

۱. Adaptive Neuro-Fuzzy Inference System      ۲. Gene Expression Programming  
 ۳. Training      ۴. Test      ۵. Fuzzy Logic      ۶. Artificial Neural Network  
 ۷. Jang      ۸. Takagi-Sugeno

$$\text{If } x = A_1 \text{ and } y = B_1 \text{ then } f_{1(x,y)} = p_1 x + q_1 y + k_1 \quad (1)$$

$$\text{If } x = A_2 \text{ and } y = B_2 \text{ then } f_{2(x,y)} = p_2 x + q_2 y + k_2 \quad (2)$$

که در این روابط،  $x$  (و یا  $y$ ) ورودی گره  $i$  و  $p, q, k$  پارامترهای پیامد<sup>۲</sup> به دست آمده از آموزش،  $A$  و  $B$  تابع عضویت است. مطابق شکل ۱، فرآیند آنفیس در ۵ مرحله انجام می‌شود [۱۵]، [۱۶]، [۱۷]. در مرحله اول پارامترهای اولیه توابع عضویت مشخص می‌شوند.

برای مثال، تابع عضویت<sup>۳</sup> زنگوله‌ای شکل<sup>۴</sup> بدین صورت تعریف می‌شود:

$$A(x) = \frac{1}{1 + \left| \frac{x - c_i}{a_i} \right|^{2b}} \quad (3)$$

که در این رابطه،  $\eta$  تابع عضویت زنگوله‌ای شکل،  $a, b, c$  پارامترهای این تابع (زنگوله‌ای) هستند. با تغییر هر یک از این پارامترها، تابع عضویت زنگوله‌ای شکل نیز متناسب با آن تغییر می‌کند که در واقع موجب اشکال گوناگونی از تابع عضویت برای مجموعه فازی می‌شود، پارامترهایی که در این لایه قرار دارند به عنوان پارامترهای ابتدایی<sup>۵</sup> معرفی می‌شوند.

در مرحله دوم، گره‌هایی که در این لایه قرار می‌گیرند به عنوان گره‌هایی در نظر گرفته می‌شوند که خروجی آن‌ها بدین صورت محاسبه می‌شود:

$$U_{r,i} = w_i = A_i(x) B_i(y), \quad i = 1, 2 \quad (4)$$

در مرحله سوم، گره‌هایی که در این لایه قرار می‌گیرند گره‌هایی با عنوان  $N$  هستند.  $\hat{a}_i$  گره نسبت به قدرت آتشین<sup>۶</sup>  $\hat{a}_i$  قانون به قدرت آتش مجموع قوانین را محاسبه می‌کند. به منظور سادگی، خروجی این لایه با عنوان قدرت آتش نرمالایز شده، طبق این رابطه معرفی می‌شود:

$$U_{r,i} = \bar{W}_i = \frac{w_i}{w_1 + w_2}, \quad i = 1, 2 \quad (5)$$

در مرحله چهارم، هر گره  $i$  در این لایه یک گره تطبیقی با تابع گره است (رابطه (۶)):


$$U_{r,i} = \bar{W}_i f_i = \bar{W}_i (p_i x + q_i y + k_i) \quad (6)$$

۱. Nod      ۲. Consequence      ۳. Member Function      ۴. Bell-Shaped  
۵. Premise Parameters      ۶. Firing Strength

که در این رابطه،  $\bar{W}$  قدرت آتش نرمالایز شده که در مرحله ۳ محاسبه شده است و  $q_i$ ،  $p_i$  و  $k_i$  پارامترهای پی‌آمد آن هستند. در انتها خروجی نهایی مدل آنفیس در مرحله ۵ از این رابطه محاسبه می‌شود:

$$U_{o,i} = \sum_i \bar{W}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i} \quad (7)$$

در واقع مفهوم آموزش سیستم مذکور این است که با استفاده از داده‌های آموزشی پارامترهای غیرخطی مربوط به توابع عضویت فازی در لایه اول و پارامترهای خطی لایه چهارم طوری تعیین شوند که به‌زای ورودی دل‌خواه، خروجی مطلوب حاصل شود. در طی این فرآیند فازی-عصبی، پارامترهای توابع عضویت، از طریق الگوریتم پس‌انتشار<sup>۱</sup> یا ترکیب آن با روش کم‌ترین مربعات<sup>۲</sup> تنظیم می‌شوند [۱۸].



شکل ۱. الف) مکانیزم استدلال برای مدل فازی سوگنو؛ ب) مدل آنفیس متناظر با مدل فازی سوگنو [۱۵]، [۱۶]، [۱۷]

۱. Back Propagation      ۲. Least Squares

برای ساخت مدل آنفیس روش‌های گوناگونی وجود دارد که شامل بخش‌بندی شبکه‌ای<sup>۱</sup>، خوشه‌بندی کاهشی<sup>۲</sup> و خوشه‌بندی میان‌مرکز فازی<sup>۳</sup> است [۱۵]. در این مقاله برای شناسایی توابع عضویت ابتدایی، از خوشه‌بندی میان‌مرکز فازی استفاده شد. خوشه‌بندی میان‌مرکز فازی عمومی‌ترین روش خوشه‌بندی فازی است. این روش داده‌ها را بر اساس مقدار درجه عضویت آن‌ها در گروه‌های مربوط قرار می‌دهد. این روش را بزدرک<sup>۴</sup> در سال ۱۹۸۱ معرفی کرد و در واقع نوع بهبود یافته‌ای از روش‌های خوشه‌بندی دیگر مانند ک-مینز<sup>۵</sup> است [۱۹]، [۲۰].

۲. چپ


کاندیدا فریرا<sup>۶</sup> الگوریتمی جدید بر اساس الگوریتم‌های ژنتیک<sup>۷</sup> (GAs) و برنامه‌نویسی ژنتیک<sup>۸</sup> (GP) پیشنهاد کرد که چپ نام داشت. چپ الگوریتمی تکاملی جدید است که برای غلبه بر بسیاری از محدودیت‌های الگوریتم ژنتیک و برنامه‌نویسی ژنتیک ایجاد شده است

[۲۱]. الگوریتم ژنتیک مدلی از یادگیری ماشین است که رفتار آن از مکانیسم تکامل در طبیعت الهام گرفته شده است. اما برنامه‌نویسی ژنتیک برای خودکارسازی برنامه‌نویسی و استقرا داده شده است. کوزا<sup>۹</sup> در اواخر ۱۹۸۰ بعد از آزمایش بر روی رگرسیون نمادین GP را معرفی کرد. GP نوع خاصی از الگوریتم‌های ژنتیک به حساب می‌آید. که در آن اندازه کروموزوم‌ها با اپراتورهای ژنتیک اصلاح‌شده، تغییر می‌کند. تفاوت اصلی بین این دو این است که تکامل برنامه‌ها در GP به صورت درختان تجزیه (تجزیه درختی)<sup>۱۰</sup> است اما در GA به صورت رشته‌های باینری با طول ثابت است [۲۲]. جپ را می‌توان زیرمجموعه جدیدی از GP دانست و تفاوت بین این دو در ارائه راه‌حل‌ها است. جپ دو قسمت اصلی به نام‌های کروموزوم‌ها و درختان بیان (ET)<sup>۱۱</sup> دارد. هرگونه اطلاعات ریاضی در ژن کروموزوم‌ها با روش دو زبانه و قطعی زبان کاروا<sup>۱۲</sup> کدگذاری شده است و هم‌چنین درخت بیان با استفاده از زبان ET ترجمه می‌شود. شکل ۲ الگوریتم جپ را نشان می‌دهد که شروع انتخاب با ۵ عنصر، مجموعه تابع، مجموعه (ترمینال) خروجی، تابع برازش، پارامترهای کنترل و شرایط توقف است [۲۳].

- |                             |                                  |                        |                     |           |
|-----------------------------|----------------------------------|------------------------|---------------------|-----------|
| ۱. Grid Partitioning        | ۲. Subtractive Clustering Method |                        |                     |           |
| ۳. Fuzzy C-Means clustering | ۴. Bezdek                        | ۵. K-means             |                     |           |
| ۶. Candida Ferreira         | ۷. Genetic Algorithms            | ۸. Genetic Programming |                     |           |
| ۹. Koza                     | ۱۰. Parse                        | ۱۱. Trees              | ۱۲. Expression Tree | ۱۳. Karva |

در این روش تابعی ریاضی به عنوان کروموزوم با چند ژن تعریف می‌شود که با استفاده از داده‌های ارائه شده به آن توسعه می‌یابد. در جپ کدگذاری به عنوان رشته‌های ساده با طول ثابت است که پس از آن درختان بیان، با اندازه‌ها و شکل‌های مختلف بیان می‌شود. این الگوریتم به طور تصادفی یک کروموزوم اولیه می‌سازد که نشان‌دهنده تابعی ریاضی است و سپس آن را به درخت بیان (ET) تبدیل می‌کند. به عبارت دیگر می‌توان گفت در این روش کاراکتری رشته‌ای با طول ثابت برای ارائه راه‌حل‌ها ایجاد می‌کند که این راه‌حل‌ها، ساختاری درخت‌مانند دارند. این درخت‌های بیان را می‌توان به صورت معادلات ریاضی نوشت. هر عبارت درختی متشکل از دو بخش به نام‌های مجموعه تابع<sup>۱</sup> و مجموعه خروجی<sup>۲</sup> است. نمونه‌ای از آن‌ها را می‌توان در شکل ۳ مشاهده کرد. سپس در مرحله بعد مقادیر پیش‌بینی شده با مقادیر واقعی


مقایسه می‌شود. چنانچه نتایج به‌دست آمده در توافق با معیارهای خطا که در ابتدا معین شده، باشند، فرآیند جپ متوقف می‌شود [۲۴].



شکل ۲. الگوریتم جپ [۲۵]

۱. Function set

۲. Terminal set



معادله ریاضی معادل این درخت:  $\ln\left(\sqrt{d1} + \frac{d0+d3}{2}\right)^3$

شکل ۳. نمونه‌ای از نمودار درختی به‌دست آمده در جپ و تابع ریاضی مربوط به آن [۲۳]



چپ چهار اپراتور اصلی دارد که عبارتند از: انتخاب<sup>۱</sup>، جهش<sup>۲</sup>، ترانسپوزیشن<sup>۳</sup> تلفیق<sup>۴</sup> (ترکیب). عمل‌گر انتخاب با استفاده از روش نمونه‌گیری چرخ رولت<sup>۵</sup> با نخبه‌گرایی برای به‌دست آوردن احتمال بیش‌تر تولید فرزندان، هر کروموزوم را انتخاب می‌کند. در مرحله رمزگذاری، در کروموزوم انتخاب شده با عمل‌گر جهش تغییر ایجاد می‌شود یا به‌عبارت دیگر کروموزوم انتخاب شده، جهش می‌یابد. با این حال ساختار کروموزوم تغییر نمی‌کند. اپراتور ترانسپوزیشن به‌طور تصادفی بخشی از کروموزوم را کپی کرده و آن را در موقعیت دیگری قرار می‌دهد. سپس کدگذاری در کروموزوم‌ها (که به‌طور تصادفی انتخاب شده‌اند) بین آن‌ها از طریق تلفیق عوض می‌شود. این اساس کار چپ است [۲۶].

### تحلیل داده‌ها و تعیین پارامترهای ورودی برای مدل‌سازی

در صورتی‌که در مدل‌سازی، پارامترهای ورودی به‌درستی انتخاب شوند، با در اختیار داشتن داده‌های کافی برای آموزش، مدل قادر است روابط پیچیده بین ورودی‌ها و خروجی‌ها را به‌خوبی فراگیرد. به‌عبارتی، خروجی مدل، باید متأثر از پارامترهای ورودی انتخاب شده باشند تا مدل بتواند با توجه به داده‌های آموزشی، بهترین ارتباط را بین پارامترها برقرار و مناسب‌ترین جواب را تخمین بزند. از عوامل مؤثر بر سرعت انتشار امواج صوتی سنگ می‌توان

۱. Selection      ۲. Mutation      ۳. Transposition      ۴. Crossover  
۵. Roulette Wheel

به‌خواص الاستیک ذرات تشکیل‌دهنده سنگ، نوع سنگ، نوع مواد سیمانی سنگ، بافت، چگالی سنگ، چگالی سیال منفذی، میزان ترک‌های موجود در سنگ، تخلخل، ناهم‌سان‌گردی، سطح تنش، درصد رطوبت، درجه حرارت و غیره اشاره کرد [۱]، [۲۷]. سرعت امواج صوتی در سنگ متناسب با سرعت صوت در کانی‌های تشکیل‌دهنده آن است، البته در صورتی‌که تأثیر عواملی مثل اندازه یا جهت‌گیری دانه‌ها در نظر گرفته نشود. با ریزدانه شدن بافت سنگ، سرعت امواج صوتی افزایش می‌یابد. چگالی با امواج صوتی رابطه مستقیم داشته در حالی‌که با تخلخل رابطه غیرمستقیم دارد. رطوبت سنگ باعث بالا رفتن سرعت امواج فشاری می‌شود

ولی از آن‌جا که امواج برشی از بخش جامد سنگ عبور می‌کند، میزان رطوبت تأثیر چندانی روی سرعت آن‌ها ندارند. معمولاً با افزایش درجه حرارت، سرعت موج کاهش می‌یابد [۱]. با توجه به تحقیقات گذشته، محققان مختلفی بر اساس پارامترهایی چون تخلخل، چگالی، سرعت امواج فشاری روابطی را برای پیش‌بینی سرعت موج برشی ارائه داده‌اند. در تحقیق حاضر برای ساخت مدل‌های هوشمندی که قادر به پیش‌بینی سرعت موج برشی سنگ ( $V_s$ ) باشند، ۳ پارامتر سرعت موج فشاری ( $V_p$ )، چگالی ( $\gamma$ ) و تخلخل ( $n$ ) به‌عنوان پارامترهای ورودی در نظر گرفته شدند. برای نیل به این هدف ۱۷۰ دسته داده از چندین سد مهم ایران از جمله خرسان ۱، ۲ و ۳، تلمبه‌خانه ایلام، کارون ۴، رودبار لرستان، ماشکید، ژان، سیم‌ره و تنگ معشوره جمع‌آوری شدند. لیتولوژی این داده‌ها نیز سنگ‌آهک است. محدوده تغییرات این دسته داده‌ها در جدول ۱ آمده است.

جدول ۱. پارامترها و محدوده تغییرات‌شان در مدل‌سازی


پارامترها	حداقل	حداکثر	میانگین
$\gamma$ (gr/cm <sup>3</sup> )	۲/۳۵۱	۲/۹۲	۲/۶۳۹
n (%)	۰/۲۱	۱۷/۸۹	۳/۴۶۸
$V_p$ (m/s)	۲۶۴۶	۶۵۲۹	۴۵۶۳/۴
$V_s$ (m/s)	۱۴۹۶	۴۰۰۹	۲۷۱۳/۸

## برآورد سرعت موج برشی

### ۱. برآورد سرعت موج برشی با استفاده از آنفیس

برای ساخت آنفیس، از نرم‌افزار متلب<sup>۱</sup> استفاده شد. قبل از شروع مدل‌سازی، برای کاهش بازه تغییرات پارامترهای ورودی و خروجی نسبت به هم، این داده در بازه [۱، -۱] نرمالیزه شدند. ساختار آنفیس که شامل تعداد و نوع توابع عضویت، الگوریتم آموزش و تعداد دورهای آموزش<sup>۲</sup> است، همگی بر اساس روش سعی و خطا به‌دست آمدند. با ۱۳۶ دسته داده، فاز آموزش مدل تکمیل شد و پس از آن، با ۳۴ دسته داده خام، عمل‌کرد مدل‌های آنفیس ارزیابی

شد. بهترین ساختار آنفیس به کمک روش سعی و خطا به دست آمد. ملاک سنجش و مقایسه مدل‌های ساخته شده، مقادیر  $RMSE^3$  در دو فاز آموزش و آزمایش بود. خصوصیات بهترین مدل آنفیس در جدول ۲ مشخص است. سامانه ساخته شده شامل پنج لایه و ۸ قانون اگر-آنگاه<sup>۴</sup> است که با عملگر "and" با یکدیگر ارتباط داده شده‌اند (شکل ۴). مقادیر خطاها و ضریب تعیین<sup>۵</sup> این مدل، برای دو فاز آموزش و آزمایش در جدول ۳ و شکل ۵ قرار دارد. چنان‌که در شکل ۶ مشاهده می‌شود مقادیر پیش‌بینی شده با آنفیس در هر دو فاز آموزش و آزمایش بسیار به مقادیر واقعی سرعت موج برشی نزدیک هستند. نزدیکی یا هم‌پوشانی این خطوط نشان می‌دهد که پیش‌بینی‌های آنفیس نسبت به مقادیر واقعی سازش خوبی دارند. البته تعدادی نقاط دیده می‌شوند که خطای ناچیزی دارند. هم‌چنین نزدیکی نتایج در هر دو فاز آموزش و آزمایش نشان‌دهنده مناسب بودن میزان آموزش مدل است. زیرا فاز آموزش قابلیت تعمیم آن را ثابت می‌کند.



شکل ۴. ساختار آنفیس برای فرمول‌بندی بین داده‌های ورودی و خروجی



۱. MATLAB Software      ۲. Epochs      ۳. Root Mean Square Error (RMSE)  
 ۴. IF-THEN      ۵. Determination of Coefficient

جدول ۲. انواع مقادیر پارامترهای مختلف مدل آنفیس ایجاد شده برای پیش‌بینی سرعت موج برشی

۸	تعداد تابع عضویت
گوسی	نوع تابع عضویت
خطی	تابع عضویت خروجی
هیبرید	روش بهینه‌سازی
۷۰	تعداد گره‌ها
۳۲	تعداد پارامترهای خطی
۴۸	تعداد پارامترهای غیرخطی
۸۰	تعداد کل پارامترها
۳۷	تعداد تکرار

جدول ۳. نتایج آنفیس برای پیش‌بینی سرعت موج برشی برای دو فاز آموزش و آزمایش

R <sup>2</sup>		σ		RMSE		نتایج
آموزش	آزمایش	آموزش	آزمایش	آموزش	آزمایش	مدل هوشمند
۰/۹۵۸	۰/۹۴۰	۱۱۴/۰۸۱	۱۲۱/۰۵۱	۱۱۳/۶۲۰	۱۲۰/۶۰۵	آنفیس




شکل ۵. ضریب تعیین ( $R^2$ ) بین مقادیر واقعی سرعت موج برشی و پیش‌بینی‌های آنفیس (الف: فاز آموزش؛ ب: فاز آزمایش)

## ۲. برآورد سرعت موج برشی با استفاده از روش جپ

در این پژوهش برای استفاده از روش جپ از نرم‌افزار ۴/۰ GenXProTools استفاده شد. به‌منظور توسعه مدل سرعت موج برشی و به‌دست آوردن مناسب‌ترین مدل برای حل مسئله، برای عملیات مدل‌سازی، مجموعه‌ای از تنظیمات در نرم‌افزار صورت گرفته است (جدول ۴) که (انحراف معیار) Standard Deviation ۱.

از مهم‌ترین مسائل موجود تعیین تعداد ژن‌ها است که بر اساس دقت، تعداد پارامترهای ورودی و کاربرد مدل ساخته شده، انتخاب می‌شود. با افزایش تعداد ژن‌ها دقت مدل ارائه شده بیش‌تر می‌شود. در این حالت تابع به‌دست آمده طولانی شده و باعث عدم کاربرد مدل می‌شود. البته باید همواره تعداد ژن‌ها را به‌صورتی انتخاب کرد که دقت تابع را کاهش ندهد. در مجموع با توجه به شرایط فوق در این تحقیق، از ۳ ژن استفاده شد.



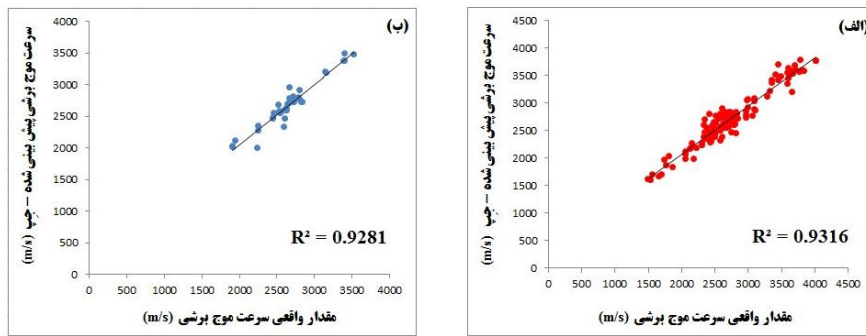
شکل ۶. مقایسه مقادیر واقعی سرعت موج برشی و پیش‌بینی‌های آنفیس در دو فاز آموزش و آزمایش

جدول ۴. تنظیمات نرم‌افزار جپ

عملگر ژنتیکی	تنظیمات عمومی			
	نرخ جهش	تابع اتصال	حد سایز	تعداد ژن
۰/۰۱	جمع	۸	۳	۸۵


ابتدا به کمک ۱۳۶ دسته داده، به وسیله جپ بر اساس سه پارامتر ورودی، رابطه (۸) ارائه شد. سپس برای ارزیابی این رابطه، از ۳۴ دسته داده خام استفاده شد. با توجه به شکل ۷، میزان  $R^2$  بین مقادیر واقعی سرعت موج برشی و نتایج حاصل از رابطه جپ، برای دو فاز آموزش و آزمایش مشخص است. چنان‌که در شکل ۸ مشاهده می‌شود مقادیر پیش‌بینی‌شده توسط این رابطه در هر دو فاز آموزش و آزمایش بسیار به مقادیر واقعی آن نزدیک هستند. در اکثر پیش‌بینی‌های صورت گرفته، دقت پیش‌بینی بسیار زیاد است به طوری که اکثر خطوط کاملاً هم‌پوشانی دارند. البته تعدادی نقاط دیده می‌شوند که خطای ناچیزی دارند. جدول ۵، مقادیر خطاها و ضریب تعیین این پیش‌بینی‌های انجام شده را برای دو فاز آموزش و آزمایش نشان می‌دهد.

$$V_s = \tan \left( \frac{\sin V_p + \gamma - V_p \cdot \gamma \cdot n}{3} \right) + \frac{1}{27} \left( 9 \tan^2 \sqrt{\frac{\gamma}{n}} + 16 V_p + 3 n^2 + 5 \gamma \right) \quad (8)$$



شکل ۷. ضریب تعیین ( $R^2$ ) بین مقادیر واقعی سرعت موج برشی و پیش‌بینی‌های جِب (رابطه ۸) (الف: فاز آموزش؛ ب: فاز آزمایش)

شکل ۸. مقایسه مقادیر واقعی سرعت موج برشی و پیش‌بینی‌های جِب (رابطه ۸) در دو فاز آموزش و آزمایش



جدول ۵. نتایج جِب (رابطه ۸) برای پیش‌بینی سرعت موج برشی برای دو فاز آموزش و آزمایش

$R^2$		$\sigma$		RMSE		نتایج روش هوشمند جِب (رابطه ۸)
آزمایش	آموزش	آزمایش	آموزش	آزمایش	آموزش	
۰/۹۲۸	۰/۹۳۲	۱۰۸/۱۲۰	۱۴۱/۲۱۰	۱۱۰/۰۰۶	۱۴۱/۴۲۰	

### نتیجه‌گیری

برای پیش‌بینی سرعت موج برشی سنگ‌آهک از دو روش آنفیس و جِب استفاده شد. ۱۷۰ دسته داده از چندین سد کشور با سازندهای مختلف جمع‌آوری شد. برای مدل‌سازی ۸۰ درصد داده‌ها برای ساخت (آموزش) و مابقی (۲۰ درصد) برای آزمایش (ارزیابی) مدل‌ها

به‌کارگرفته شدند. با توجه به این‌که دسته داده‌های به‌کار رفته برای ساخت مدل‌ها، هم از لحاظ اندازه و هم محدوده تغییرات بزرگ هستند و هم‌چنین با توجه به یک‌نواخت نبودن نوع سازند می‌توان گفت بانک داده‌ها بسیار مطلوب بوده است. بنا بر این مدل‌های ساخته شده جدا از دقت زیاد، از قابلیت تعمیم مناسبی برخوردارند که به‌روشنی در مرحله آزمایش روش‌ها دیده شد. هر دو روش هوشمند، جدا از فاز آموزش، در فاز آزمایش نیز، عمل‌کرد مناسبی داشتند و این قابلیت تعمیم آن‌ها را نشان می‌دهد.

مقایسه بین نتایج پیش‌بینی حاصل از ۲ روش (جدول‌های ۳ و ۵) نشان می‌دهد که بهترین میزان ضریب تعیین ( $R^2$ ) مربوط به روش آنفیس است. اما مقدار RMSE جپ کم‌تر از آنفیس است. هم‌چنین از آن‌جا که آنفیس بر خلاف جپ، رابطه خاصی را ارائه نمی‌دهد و تنها به‌صورت کدنویسی و در نرم‌افزار متلب به‌کار گرفته می‌شود، برای مقاصد آینده به‌اندازه رابطه جپ کاربرد نخواهد داشت. بنا بر این با این‌که میزان  $R^2$  جپ ضعیف‌تر از آنفیس است، با توجه به رابطه ریاضی موجود مزایای بیش‌تری دارد.

با توجه به نتایج به‌دست آمده از این تحقیق، روش‌های هوشمند ابزاری مناسب برای حل مسائلی با مکانیزم پیچیده و فاکتورهای تأثیرگذار متعدد، مانند پیش‌بینی سرعت موج برشی هستند. این روش‌ها هیچ محدودیتی در تعداد پارامترهای ورودی برای پیش‌بینی پارامترهای مکانیک سنگی ندارند. این ویژگی نسبت به سایر روش‌ها از نکات مثبت این روش است. در مجموع می‌توان گفت هر دو روش هوشمند به‌خوبی توانستند روابط بین پارامترهای ورودی و هم‌چنین تأثیراتشان را روی خروجی تشخیص دهند و به‌طور هوشمندانه‌ای نسبت به داده‌های جدید قابلیت تعمیم داشته باشند. مدل و رابطه ارائه شده آماده است تا به‌عنوان یک پیش‌گو برای مقاصد آینده برای پیش‌بینی سرعت موج برشی سنگ آهک، به‌کار گرفته شوند.

### منابع

۱. فهیمی‌فر ا.، سروش ح.، آزمایش‌های مکانیک سنگ (مبانی نظری و استانداردها)، جلد اول (آزمون‌های آزمایشگاهی)، دانشگاه صنعتی امیرکبیر (واحد تفرش) (۱۳۸۰).

2. Heidari M., Khanlari G. R., Momeni A. A., "Prediction of Elastic Modulus of Intact Rocks Using Artificial Neural Networks and non-Linear Regression Methods", Australian Journal of Basic and Applied Sciences, 4(12) (2010) 5869-5879.
3. Eskandari H., Rezaee M. R., Mohammadnia M., "Application of multiple regression and artificial neural network techniques to predict shear wave velocity from wireline log data for a carbonate reservoir, south Iran", Canadian Society of Exploration Geophysicists (CSEG) Recorder 29, (2004) 42-48.
4. Rajabi M., Bohlooli B., Gholampour Ahangar E., "Intelligent approaches for prediction of compressional, shear and Stoneley wave velocities from conventional well log data: A case study from the Sarvak carbonate reservoir in the Abadan Plain (Southwestern Iran)", Computers & Geosciences, 36 (2010) 647-664.
5. Cuddy S. J., "Litho-facies and permeability prediction from electrical logs using fuzzy logic", In: Eighth Abu Dhabi International Petroleum Exhibition and Conference, Abu Dhabi, UAE, Society of Petroleum Engineers (SPE) 65411 (49470) (1998) 1-12.
6. Mohaghegh S., "Virtual-intelligence applications in petroleum engineering: part I. artificial neural networks", Journal of Petroleum Technology 52 (2000) 64-73.
7. Saggaf M. M., Nebrija Ed. L., "A fuzzy approach for the estimation of facies from wireline logs", AAPG Bulletin 87 (2003) 1223-1240.



8. Rezaee M. R., Kadkhodaie Ilkhchi A., Barabadi A., "Prediction of shear wave velocity from petrophysical data utilizing intelligent systems: an example from a sandstone reservoir of Carnarvon Basin, Australia", *Journal of Petroleum Science and Engineering* 55 (2007) 201-212.
9. Rezaee M. R., Kadkhodaie Ilkhchi A., Alizadeh P. M., "Intelligent approaches for the synthesis of petrophysical logs", *Journal of Geophysics and Engineering* 5 (2008) 12-26.
۱۰. حق‌نژاد دوشانلو ع.، بررسی رابطه بین پارامترهای ژئومکانیکی سنگ‌های موجود در ساخت‌گاه تعدادی از سدهای ایران به‌کمک روش‌های آماری و شبکه عصبی، پایان‌نامه کارشناسی ارشد، دانشگاه آزاد اسلامی واحد علوم و تحقیقات (۱۳۹۰).
11. Jang J. S. R., "ANFIS: Adaptive-Network-Based fuzzy inference systems", *IEEE Transactions on Systems, Man, and Cybernetics*, 23 (3) (1993) 665-685.
12. Kartalopoulos S. V., "Understanding Neural Networks and Fuzzy Logic", *Basic Concepts and Applications*, IEEE, Press (1996).
13. Jang J. S. R., Sun C. T., Mizutani E., "Neuro-Fuzzy and Soft Computing A Computational Approach to Learning and Machine Intelligence", Prentice Hall (1997).
14. Srinivasan K., Fisher D., "Machine Learning Approaches to Estimating Software Development Effort", *IEEE Transactions on Software Engineering* 21 (2) (1995) 126-137.
15. Jalalifar H., Mojedifar S., Sahebi A. A., Nezamabadi-pour H., "Application of the Adaptive Neuro-Fuzzy Inference System for Prediction of a Rock

Engineering Classification System", *Computers and Geotechnics* 38 (2011) 783-790.

16. Kayadelen C., "Soil Liquefaction Modeling by Genetic Expression Programming and Neuro-Fuzzy", *Expert Systems with Applications*, 38 (2011) 4080-4087.
17. Jang J. S. R., Sun C. T., "Neuro-Fuzzy Modeling and Control", *Proceedings IEEE*, 83 (3) (1997) 378-406.
18. Demuth H., Beale M., "Neural Network Toolbox for Use with MATLAB, Natick", Mass: The Math Works Inc. (2001).
19. Chintalapudi K. K., Kam M., "A Noise Resistant Fuzzy C-Means Algorithm for Clustering", *IEEE Conference on Fuzzy Systems Proceeding* (1998) 2327-2330.
20. Dave R. N., Krishnapuram R., "Robust Clustering Methods: a unified view", *IEEE Trans, Fuzzy System*, vol. 5 (1997) 270-293.
21. Ferreira C., "Gene Expression Programming (Mathematical Modeling by an Artificial Intelligence)", Springer-Verlag Berlin Heidelberg, (Second, revised and extended edition) (2006) 55-56.

۲۲. کیا س.م.، محاسبات نرم در متلب، انتشارات خدمات نشر کیان سبز رایانه، (چاپ اول ۱۳۸۹).

۲۳. آهنگری ک.، معین‌السادات س. ر.، بهنیا د.، بهنیا م.، معین‌السادات س.ح.، به‌کارگیری روش‌های نوین هوشمند *ANFIS ANN* و *GEP* برای پیش‌بینی مدول الاستیسیته استاتیکی سنگ آهک، کنفرانس بین‌المللی مدل‌های غیرخطی و بهینه‌سازی، مازندران، آمل، دانشگاه شمال (۷ و ۸ شهریور ماه ۱۳۹۱).

24. Mollahasani A., Alavi A. H., Gandomi A.H., "Empirical modeling of plate load test moduli of soil via gene expression programming", *Computers and Geotechnics*, 38 (2011) 281-286.
25. Teodorescu L., Sherwood D., "High energy physics event selection with gene expression programming", *Computer Physics Communications*, 178 (2008) 409-419.
26. Kose M. M., Kayadelen C., "Modeling of transfer length of prestressing strands using genetic programming and neuro-fuzzy", *Advances in Engineering Software*, 41 (2010) 315-322.

۲۷. نبی‌بیدهندی م.، کوثریان م.، سرعت انتشار امواج الاستیک در نمونه‌های سنگ آهک منطقه خوزستان در حالت‌های خشک و اشباع، نشریه فیزیک زمین و هوا (۱۳۷۷).