



(یادداشت فنی)

تخمین مدول تغییر شکل پذیری سنگ آهک آسماری با استفاده از سیستم عصبی-ژنتیک

زینب علی‌آبادیان^۱، مصطفی شریف‌زاده^{۲*}

پذیرش مقاله: ۹۱/۱۰/۶

دریافت مقاله: ۹۰/۸/۴

چکیده

مدول تغییر شکل پذیری توده‌سنگ (E_m) به عنوان مهم‌ترین خصوصیت برای طراحی پروژه‌های مهندسی سنگ مطرح است و بهترین نماینده برای رفتار مکانیکی پیش از شکست توده‌سنگ است. به دلیل هزینه بالا و زمان‌بر بودن و مشکلات اجرایی در انجام دقیق آزمایش‌های برجا، روش‌های غیرمستقیم مانند روابط تجربی و شبکه‌های پس انتشار عصبی (BPN) جایگاه بهتری پیدا می‌کنند. از این میان BPN دارای کاربردی گسترده در تخمین خصوصیات توده سنگ از جمله E_m است. محققین متعددی از روش سعی و خطأ برای ایجاد یک BPN کارا بهره گرفته‌اند که نیاز به صرف زمان و مهارت کاربر دارد. اما در این مطالعه، از الگوریتم ژنتیک برای بهینه کردن پارامتری مؤثر BPN به منظور تخمین E_m در رشته کوه‌های زاگرس ایران استفاده شد. برای این منظور، یک بانک اطلاعاتی از پروژه‌های مختلف رشته کوه‌های زاگرس جمع‌آوری و Em سنگ آهک آسماری تخمین زده و در نهایت نتایج به دست آمده از روش عصبی-ژنتیک با روش عصبی سعی و خطأ مقایسه شد. که براساس نتایج به دست آمده روش عصبی-ژنتیک دارای دقت و سرعت بالاتر در تخمین Em است.

کلید واژه‌ها: الگوریتم ژنتیک، رشته کوه زاگرس، شبکه پس انتشار عصبی، مدول تغییر شکل پذیری توده سنگ

۱. کارشناس ارشد گرایش مکانیک سنگ، دانشگاه صنعتی امیرکبیر: aliabadian2000@gmail.com

۲. استادیار دانشکده مهندسی معدن و متالوژی، دانشگاه امیرکبیر: sharifzadeh@aut.ac.ir

* مسئول مکاتبات

ساخت جمع‌آوری و مدول تغییرشکل‌پذیری توده سنگ آسماری به کمک شبکه عصبی- ژنتیک تخمین زده شد.

۲. شبکه‌های عصبی - ژنتیک

متداول‌ترین الگوریتم استفاده شده جهت آموزش شبکه‌های چند لایه با تغذیه پیشرو، روش انتشار بازگشتی است. شبکه‌هایی که از این الگوریتم جهت یادگیری استفاده می‌کنند را شبکه‌های پس انتشار (BPN) گویند. شبکه‌های پس انتشار یک شکل از یادگیری تصحیح و خطأ هستند که سعی در به حداقل رساندن مقدار تابع خطأ دارند تا بتوانند ورودی‌های داده شده را بر خروجی‌ها منطبق کنند. الگوریتم‌های یادگیری مختلفی برای BPN وجود دارد که در این مطالعه از الگوریتم یادگیری مومنتم برای تخمین مدول تغییرشکل‌پذیری توده‌سنگ استفاده شد. این الگوریتم یکی از ساده‌ترین الگوریتم‌های آموزشی است که به طور گسترده مورد استفاده قرار می‌گیرد. در این الگوریتم وزن‌ها در جهت کاهش تابع انتقال یعنی خلاف شیب تغییر می‌کنند تا خطأ کاهش یابد.

اولین مرحله در آموزش BPN، طراحی ساختمان شبکه است، برای این منظور باید پارامترهایی از قبیل تعداد نورون‌های لایه پنهان، نوع تابع انتقال و غیره مشخص گردد. تعیین تعداد بهینه نورون‌ها در لایه‌های پنهان امری مهم برای طراحی ساختار شبکه است، که محققین متعدد (Hush, 1989; Hecht 1987; Wang, 1994; Nielsen 1987) برای تعیین تعداد نورون‌های لایه پنهان از آزمون و خطأ استفاده کردند. علاوه بر ساختمان شبکه، قوانین یادگیری نیز یکی از انتخاب‌های مهم برای افزایش کارایی شبکه است. این قوانین برای الگوریتم مومنتم، یک مجموعه از وزن‌ها، ضریب مومنتم و نرخ یادگیری را مشخص می‌کند و همچنین چگونگی به روز شدن این مجموعه را در طی آموزش برای افزایش کارایی شبکه نشان می‌دهد. مقدار اولیه مناسب برای وزن‌ها، تأثیر به سزاگی در سرعت همگرایی دارد. مقادیر متفاوتی برای وزن‌های اولیه Staufer, Sietsma and Dow, 1991; (Fisher and Paola, 1994 1997; پیشنهاد شده است. کارایی

۱. مقدمه

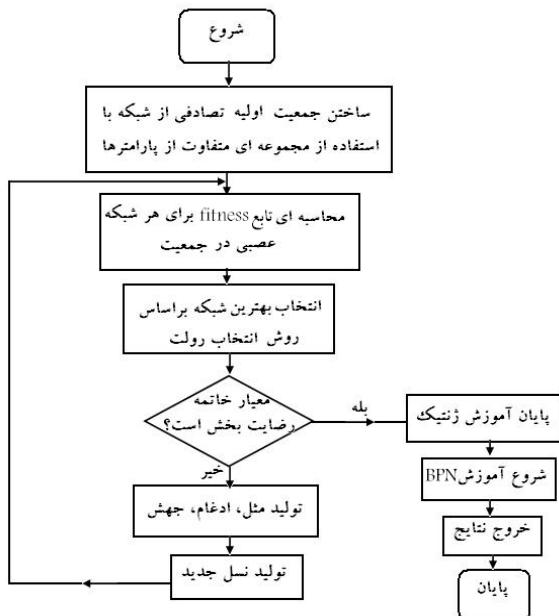
روش‌های مستقیمی برای تخمین مدول تغییر شکل‌پذیری مانند آزمایش‌های برجا وجود دارد. گرچه آزمایش‌های برجا، نسبت به سایر روش‌های موجود نتایج واقعی‌تری می‌دهند اما به دلیل صرف هزینه و زمان زیاد و مشکلات اجرایی در بعضی از محل‌ها، برخی از روش‌های غیرمستقیم مانند روابط تجربی، جایگاه بهتری پیدا می‌کنند. روابط تجربی متعددی برای تخمین مدول تغییر شکل‌پذیری توده‌سنگ توسعه یافته است. این روابط، روشنی ساده و ارزان هستند، اما به دلیل تغییرات نوع سنگ و طبیعت هتروژن توده‌سنگ، استفاده از روابط تجربی در مناطق دیگر جهان عمدهاً همراه با خطأ خواهد بود.

در سال‌های اخیر به منظور تعیین خواص توده‌سنگ، علاوه بر Serafim and Pereira, 1983; Read et al., 1999; Hoek and Brown, 1997; Mitri et al., 1994; Grimstad and Barton, 1993, تخمین ویژگی‌های سنگ و توابع حاکم بین آن‌ها و همچنین سرعت بالاتر از شبکه‌های عصبی استفاده شده است (Singh et al., 2001; Alvarez Meulenkamp and Alvarez Sonmez et al., 2002; and Babuska, 1999; Gokceoglu, 2002; and 2006).

در شبکه عصبی با وجود قوانین مختلف جهت یادگیری و کاهش مقدار خطای حاصله از شبکه‌های عصبی، همواره اکثر روش‌ها جهت رسیدن به بهترین ساختار و پارامترها مبتنی بر سعی و خطأ است که خود نیازمند صرف هزینه و زمان زیاد برای طراحی بوده است. همچنین این امکان وجود دارد که شبکه طراحی شده بهینه‌ترین شبکه موجود برای حل مسئله نباشد.

اما با توجه تحقیقات انجام شده (Tahmasebi and Majdi and Beiki, Hezarkhani, 2009; Palonen et al., 2009; 2010;)، می‌توان از الگوریتم‌های ژنتیک در تعیین پارامترهای بهینه شبکه عصبی استفاده کرد. در این مطالعه با توجه به اهمیت رشته‌کوه زاگرس برای ساخت پروژه‌های عمرانی و انرژی در ایران، مدول تغییرشکل‌پذیری توده‌سنگ سازند آسماری در این منطقه مورد بررسی قرار گرفت. برای این کار، یک بانک اطلاعاتی از پروژه‌های ساخته شده و در حال

نورون‌ها در لایه مخفی بین ۱ تا ۳۰ انتخاب می‌شود. طرح کلی الگوریتم ژنتیک بکار رفته در شبکه عصبی در شکل ۱ نشان داده شده است.



شکل ۱. طرح شماتیک از کاربرد الگوریتم ژنتیک در شبکه عصبی [۱۷]

۳. داده‌های توده سنگ سازندآسماری در رشتہ کوه زاگرس
داده‌های مورد تحقیق در این مطالعه مربوط به شش سد به نام‌های کارون^۴، سیمراه، سازbin، خرسان^۱، خرسان^۲، خرسان^۳ گرفته شده است که ساختگاه این شش سد بر روی سازند آسماری می‌باشد. این سازند مربوط به دوره زمین‌شناختی الیگومیوسن بوده و در منطقه غرب و جنوب غرب ایران شکل گرفته و شامل آهک‌های کرم رنگ تا قهوه‌ای و دارای فسیل‌های صدف است. شکل ۲ جایگاه این سدها را بر روی نقشه ایران نشان می‌دهد. داده‌های جمع‌آوری شده به منظور تخمین مدول تغییرشکل پذیری توده‌سنگ شامل مقاومت فشاری تک محوره ماده‌سنگ (ucS)، مدول الاستیسیته ماده‌سنگ (E_i)، شاخص کیفیت توده‌سنگ (RQD)، چگالی (ρ)، عمق (h) و مدول تغییر شکل پذیری توده‌سنگ (E_m) است. داده‌های مقاومت فشاری تک محوره، مدول الاستیسیته ماده‌سنگ، شاخص کیفیت توده‌سنگ و دانسیته از نتایج

الگوریتم مومنتم وابسته به مقدار نرخ یادگیری و ضریب مومنتم است.

نرخ یادگیری برای تعیین وزن‌ها و بایاس‌ها در شبکه مورد استفاده قرار می‌گیرد که اگر این مقدار خیلی بزرگ انتخاب شود موجب نوسان الگوریتم می‌شود و آن را ناپایدار می‌کند و اگر خیلی کوچک انتخاب شود، زمان همگرایی شبکه بسیار طول خواهد کشید. ضریب مومنتم، نیز تأثیر پایداری در الگوریتم دارد که افراد مختلفی (Hassoun, 1995; Henseler, 1995; Fu, 1995; Hertz et al., 1995) به ارائه مقادیر برای این ضریب پرداخته‌اند.

علاوه بر روش سعی و خطأ در بهینه کردن پارامترهای BPN از قبیل تعداد نورون‌ها در لایه پنهان و پارامترهای الگوریتم یادگیری، می‌توان از الگوریتم ژنتیک (GA) بهره گرفت. روش‌های متعددی به منظور بهینه کردن مسائل مهندسی وجود دارد اما الگوریتم ژنتیک به عنوان یک روش جستجوی مؤثر در فضای بسیار وسیع که در نهایت منجر به جهت‌گیری به سمت پیدا کردن یک جواب بهینه می‌شود، شناخته شده است. یک جمعیت الگوریتم ژنتیک شامل افرادی به نام کروموزوم است. هر کروموزوم دارای ژن‌هایی است که انتقال دهنده ویژگی‌های نسل خود هستند. الگوریتم ژنتیک، کار خود را با یک جمعیت اولیه با کروموزوم‌های تصادفی آغاز می‌کند و در هر گام به وسیله عملگرهای اصلی و فرعی از نسل حاضر برای تولید فرزندان که نسل بعدی را تشکیل می‌دهند، استفاده می‌کند. در هر نسل، لیاقت کروموزوم‌ها برای انتقال به نسل بعدی توسط تابعی به نام fitness سنجیده می‌شود. با افزایش تعداد نسل‌ها، تعداد افراد در جمعیت هر نسل کمتر شده و در نهایت در نسل آخر یک کروموزوم که بهترین ویژگی‌ها را دارد باقی می‌ماند(Osman, 2004). هریک از ژن‌ها در الگوریتم ژنتیک نماینده یکی از پارامترهای شبکه عصبی مانند بهترین داده ورودی، تعداد نورون‌ها در لایه پنهان و همچنین ویژگی‌های الگوریتم یادگیری (نرخ یادگیری و ضریب مومنتم) در لایه پنهان و لایه خروجی است. در این بهینه‌سازی، مقدار نرخ یادگیری و ضریب مومنتم بین مقادیر صفر و یک و تعداد

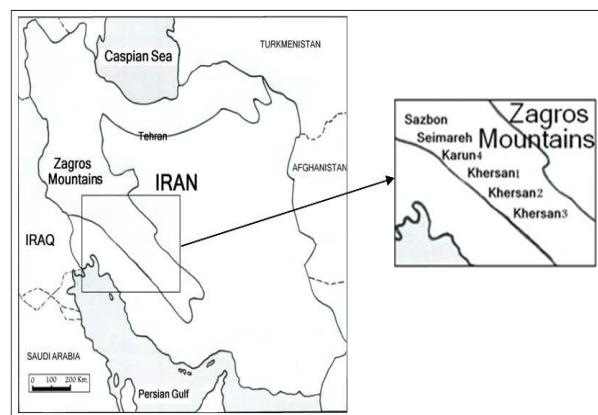
تعداد نورون‌ها در لایه مخفی و ژن‌های باقیمانده، مشخص کننده ویژگی‌های الگوریتم یادگیری (نرخ یادگیری و ضریب مومنت) در لایه پنهان و لایه بیرونی است. جدول ۳ مقادیر پارامترهای بهینه شده توسط الگوریتم ژنتیک در شبکه عصبی را نشان می‌دهد. همان‌طور که مشاهده می‌شود از بین پارامترهای ورودی به سیستم (شامل مقاومت فشاری تک محوره ماده سنگ، مدول الاستیستیه، دانسیته، شاخص کیفیت سنگ و عمق) فقط دو پارامتر مدول الاستیستیه و شاخص کیفیت سنگ به عنوان پارامترهای ورودی مؤثر برای شبکه عصبی انتخاب شده است. با توجه به این جدول، شبکه بهینه شده ۲۳ نورون در لایه پنهان و مقادیر نرخ یادگیری و ضریب مومنت به ترتیب 0.187×10^{-4} و 0.111×10^{-4} برای لایه پنهان و همچنین 0.299×10^{-4} برای لایه خروجی است. علاوه بر استفاده از روش عصبی- ژنتیک در تخمین مدول تغییرشکل‌پذیری از روش سعی و خطای نیز استفاده شد و بهترین شبکه‌ای که می‌توان با تغییر دادن پارامترهای شبکه عصبی ساخت، به دست آمد و مدول تغییرشکل‌پذیری به کمک آن شبکه تخمین زده شد. برای ارزیابی مقادیر تخمین زده شده به وسیله روش‌های عصبی و عصبی- ژنتیک از میانگین مجذور خطا (MSE) و ضریب همبستگی (r) بین داده‌های تخمین زده شده و مقادیر واقعی استفاده شد که در جدول ۴ برای دو سری داده آموزش و آزمایش نشان داده شده است. همان‌طور که مشاهده می‌شود شبکه عصبی- ژنتیک دارای کمترین خطای و بیشترین ضریب همبستگی نسبت به روش عصبی است.

جدول ۲: پارامترهای ژنتیک استفاده شده به منظور یافتن

مدول تغییر شکل‌پذیری

مقادیر	پارامترهای ژنتیک
MSE	تابع fitness
تولید مثل (0.09)	عملگرهای ژنتیکی
ادغام (0.09)	
جهش (0.01)	
Roulette	روش انتخاب
۱۰۰	تعداد نسل‌ها
۵۰	تعداد جمعیت در هر نسل

آزمایش‌های آزمایشگاهی که بر روی مغزه‌های حفاری شده از گمانه‌ها و مدول تغییرشکل‌پذیری توده‌سنگ ازنتایج آزمایش‌های دیلاتومتری انجام گرفته در گمانه‌ها، جمع‌آوری شد. تعداد داده‌هایی که دارای همه این خصوصیات باشند ۱۸۸ سری داده بود که متعلق به اعمق ۳۰۴ تا ۲۰۴ متری از سطح زمین است. جدول ۱، مشخصات آماری داده‌های جمع‌آوری شده را نشان می‌دهد.



شکل ۲. محل سدهای مورد مطالعه

جدول ۱. ویژگی‌های آماری خصوصیات فیزیکی و مکانیکی ۱۸۸ نمونه از توده‌سنگ آهک سازند آسماری

ویژگی‌ها	حداقل	حداکثر	میانگین	انحراف معیار
(gr/cm ³) ρ	۲.۳۶	۲.۹۷۵	۲.۶۲۴	۰.۰۰۷
(MPa)Ucs	۱۱.۵	۱۹۳	۷۳.۰۰۹	۳۶.۳۹
(GPa)E _i	۲.۸۲	۹۲	۳۳.۲۷۱	۱۸.۰۱۷
(%RQD	۴۵	۱۰۰	۸۵.۸۶۱	۱۳.۰۰۸
(GPa)E _m	۲.۰۵۱	۱۴.۰	۸.۱۱۳	۲.۷۱

۴. ارزیابی مدول تغییرشکل‌پذیری با استفاده از شبکه عصبی- ژنتیک

مشخصات الگوریتم ژنتیک به کار رفته برای بهینه کردن پارامترهای شبکه عصبی در جدول ۲ نشان داده شده است. در این بهینه‌سازی از 70% کل داده‌ها برای آموزش شبکه و از 30% برای آزمایش شبکه استفاده شد. هر یک از ژن‌ها در کروموزوم‌های الگوریتم ژنتیک مشخص کننده پارامترهای شبکه است. به طور مثال، هر کروموزوم در شبکه عصبی با یک لایه پنهان دارای ده ژن است که پنج ژن اول نشان دهنده شرکت یا عدم شرکت پنج داده ورودی، ژن ششم نشان دهنده

می‌گرفت اما امروزه از روش‌های هوشمند نیز به دلیل دقیق و سرعت بالاتر بهره گرفته می‌شود. از این بین، شبکه‌های عصبی جزو روش‌های پرکاربرد است. ایجاد یک شبکه عصبی مناسب نیاز به تجربه کاربر در تعیین پارامترهای بهینه برای شبکه داشته و زمانبر است. علاوه بر روش سعی و خطا برای ایجاد یک شبکه عصبی مناسب، می‌توان از الگوریتم ژنتیک جهت بهینه کردن پارامترهای شبکه استفاده کرد. ژن‌های این الگوریتم مشخص کننده هر یک از پارامترهای مهم شبکه مانند انتخاب داده‌های ورودی مؤثر، تعداد نورون‌ها در لایه پنهان، نرخ یادگیری و ضریب مومنت است. در این مطالعه مدول تغییرشکل پذیری توده‌سنگ آسماری به وسیله شبکه عصبی- ژنتیک تخمین زده و نتایج به دست آمده از این روش با نتایج حاصل از روش سعی و خطا مقایسه شد که براساس آن، روش عصبی- ژنتیک دارای دقیق‌تر و خطای کمتر نسبت به روش سعی و خطا است. بهترین شبکه ایجاد شده توسط الگوریتم ژنتیک با یک لایه پنهان شامل ۲۳ نورون در لایه پنهان خود و مقادیر نرخ یادگیری و ضریب مومنت ۰.۱۸۷ و ۰.۱۶۸ برای لایه پنهان و ۰.۲۹۹ و ۰.۱۱۱ برای لایه خروجی است. مقادیر MSE و این شبکه به ترتیب ۵.۹۰۵ و ۴.۴۱۹ برای داده‌های آموزش و ۴.۴۸ و ۰.۷۹۸ برای داده‌های آزمایش است. روش عصبی- ژنتیک علاوه بر خطای کمتر، دارای سرعت بسیار بیشتری نسبت به روش سعی و خطاست. به دلیل آنکه در روش سعی و خطا باید چندین شبکه با پارامترهای مختلف ایجاد و مورد ارزیابی قرار گیرند و بهترین شبکه از بین آن‌ها انتخاب شود، در صورتی که در شبکه عصبی- ژنتیک، الگوریتم ژنتیک به ارائه بهترین شبکه ممکن از اطلاعات موجود می‌پردازد.

جدول ۳: پارامترهای بهینه شده برای شبکه‌های عصبی به کمک الگوریتم ژنتیک

مقدار پارامتر	پارامترهای بهینه شده
۲۳	تعداد نورون در لایه پنهان
.	عمق
.	داده ورودی
۱	دانسیته
۱	RQD
.	= عدم شرکت داده
۰	σ_c
۱	وروودی
۰.۱۸۷	E _i
۰.۱۶۸	نرخ یادگیری لایه پنهان
۰.۲۹۹	ضریب مومنت لایه پنهان
۰.۱۱۱	نرخ یادگیری لایه خروجی
	ضریب مومنت لایه خروجی

جدول ۴: نتایج ارزیابی آماری هریک از روش‌ها

MSE	r	نوع داده	روش هوشمند به کار رفته برای آموزش داده‌ها
۵.۹۵۸	۰.۴۱۴	آموزش	شبکه عصبی
۴.۵۸۷	۰.۷۹۴	آزمایش	
۵.۹۰۵	۰.۴۱۹	آموزش	شبکه عصبی- ژنتیک
۴.۴۴۸	۰.۷۹۸	آزمایش	

۱- نتیجه‌گیری

- روابط تجربی متعددی برای تخمین مدول تغییر شکل پذیری توده سنگ توسعه یافته است. به دلیل تغییرات نوع سنگ و طبیعت هتروژن توده‌سنگ، استفاده از روابط تجربی در مناطق دیگر جهان به طور عمده با عدم قطعیت همراه خواهد بود. بنابراین، در این مطالعه مدول تغییرشکل پذیری توده‌سنگ سازند آسماری که به لحاظ ساخت پروژه‌های عمرانی و انرژی در آن با اهمیت است تخمین زده شد. برای این منظور یک بانک اطلاعاتی شامل ۱۸۸ داده سنگ آهکی از سدهای مختلف منطقه گردآوری شد. با وجود اینکه روش‌های آماری از دیرباز برای تخمین یک پارامتر مورد استفاده قرار

منابع

- Alvarez Grima, M., Babuska, R., 1999. Fuzzy model for the prediction of unconfined compressive strength of rock samples. International Journal of Rock Mechanica and Mining Sciences, 36: 339–349.
- Bieniawski, Z.T ., 1993. Determining rock mass deformability : experience Fromcase histories. International Journal of Rock Mechanica and Mining Sciences, 15: 237–247.
- Fu, L., 1995. Neural Networks in Computer Intelligence New York:McGraw-Hill.
- Gokceoglu, C., 2002. A fuzzy triangular chart to predict the uniaxial compressive strength of the Ankara agglomerates from their petrographic composition. Engineering Geology, 66: 39–51.
- Grimstad, E., Barton, N ., 1993. Updating the Q-system for NMT. Proceedings of the International Symposium on Sprayed Concrete Modern Use of Wet Mix Sprayed Concrete for Underground Support, Oslo, Norwegian Concrete Association.
- Hassoun, M.H., 1995. Fundamentals of Artificial Neural Networks. CambridgeMA: MIT Press.
- Hecht-Nielsen, R., 1987. Kolmogorov's mapping neural network existence theorem; Proceedings of the first IEEE international conference on neural networks, San Diego CA, USA, pp. 11–14.
- Henseler, J., 1995, Backpropagation. In :Braspennin P.J., Thuijsman, F., Weijters, A.J.M.M. (Eds.), Artificial Neural Networks, an Introduction to ANN Theory and Practice. Lecture Notes in Computer Science, Berlin :Springer, pp. 37–66.
- Hertz, J., Krogh, A., Palmer, R.G., 1991. Introduction to the Theory of Neural Computation. Reading MA : Addison-Wesley.
- Hush, D.R., 1989, Classification with neural networks :a performance Analysis. Proceedings of the IEEE international conference on systems Engineering Dayton Ohio, USA, pp. 277–280.
- Hoek, E., Brown E.T., 1997. Practical estimates of rock mass strength. International Journal of Rock Mechanica and Mining Sciences, 34: 1165–1186.
- Majdi, A., Beiki, M., 2010. Evolving neural network using a genetic algorithm for predicting the Deformation modulus of rock masses. International Journal of Rock Mechanics and Mining Sciences, 47(2): 246–253.
- Meulenkamp, F., Alvarez Grima, M., 1999. Application of neural networks for the prediction of the unconfined compressive strength (UCS) from equotip hardness. International Journal of Rock Mechanica and Mining Sciences, 36:29–39.
- Mitri, H.S., Edrissi, R., Henning, J., 1994. Finite element modeling of cable bolted stops in hard rock ground mines; Presented at the SME Annual Meeting.New Mexico : Albuquerque, pp. 94–116.
- Osman, M.S., Abo-Sinna, M.A., Mousa, A.A., 2005. Combined genetic algorithm-fuzzy logic controller (GA-FLC) in nonlinear programming. Journal of Applied Mathematics and Computing, 170(2): 821–840.
- Palonen, M., Hasan, A., Siren, K., 2009. A genetic algorithm for optimization of building envelope and HVAC system parameters. Eleventh International IBPSA Conference Glasgow, Scotland, pp. 27–30.
- Paola, J.D., 1994. Neural Network Classification of Multispectral Imagery., MSc thesis, The University of Arizona, USA.
- Read S.A.L., Richard L.R., Perrin N.D., 1999. Applicability of the Hoek-Brown failure criterion to New Zealand gerywack rocks. In :Vouille G, berest, P. (Eds.): Proceeding of the Nineth International Congeress on Rock Mechanics; Paris, 2: pp. 655-660.
- Serafim, J.L., Pereira, J.P., 1983. Considerations on the geomechanical classification of Bieniawski. Proceedings of the Symposium on Engineering Geology and Underground Openings; Lisboa,Portugal, pp. 1133–1144.
- Sietsma, J., Dow, R.J.F., 1991. Creating artificial neural network that generalize. Neural Networks, 4: 67–69.
- Sonmez, H., Gokceoglu, C., Nefeslioglu, H.A., Kayabasi, A., 2006. Estimation of rock modulus for intact rocks with an artificial neural network and for rock masses with a new empirical equation. International Journal of Rock Mechanica and Mining Sciences, 43: 224–235.
- Staufer, P., Fisher, M.M ., 1997. Specral pattern recognition by a two-layer perceptron :effects of training set size. In :Kanellopoulos, I., Wilkinson, G.G., Roli F., Austin J. (Eds.): Neuro-Computation in Remote Sensing Data Analysis. London :Springer, pp. 105–116.
- Tahmasebi, P., Hezarkhani, A., 2009. Application of adaptive neuro-fuzzy inference system for grade estimation, case study, Sarcheshmeh porphyry copper deposit, Kerman, Iran. Australian Journal of Basic and Applied Sciences, 4(3): 408-420.
- Wang, C ., 1994. A Theory of Generalization in Learning Machines with Neural Application., PhD thesis, The University of Pennsylvania, US.