

بر آورد تخلخل سازند گازی کنگان در میدان پارس جنوبی با استفاده از ماشین کمیت‌های متشکل از شبکه‌های عصبی مصنوعی منفرد آموزش دیده به روش مرتب‌سازی

ابوالقاسم کامکار روحانی^۱ و محمود ذاکری^{*}

^۱دانشکده مهندسی معدن، نفت و ژئوفیزیک، دانشگاه صنعتی شاهرود، شاهرود، ایران

تاریخ پذیرش: ۱۳۸۹/۰۵/۰۹

تاریخ دریافت: ۱۳۸۸/۰۲/۲۲

چکیده

برای به دست آوردن نتایج دقیق تر از به کارگیری روش شبکه‌های عصبی مصنوعی، به جای انتخاب نتایج بهترین شبکه حاصل از فرایند سعی و خطا، نتایج چندین شبکه به روشی مناسب با هم ترکیب شده است تا شاید سامانه چندشبکه‌ای حاصل که از آن با عنوان ماشین کمیت‌های تعبیر می‌شود، خطا را کاهش و در نتیجه، دقت را افزایش دهد. در این پژوهش، برای برآورد تخلخل مؤثر سنگ مخزن گازی کنگان در میدان عظیم هیدروکربنی پارس جنوبی، از ترکیب آنسامبلی شبکه‌های عصبی مصنوعی که نوعی ماشین کمیت‌های با ساختار موازی است، استفاده شده است. به این منظور، داده‌های نگارهای صوتی، چگالی، پرتو گاما و تخلخل نوترونی به عنوان ورودی شبکه‌ها و تخلخل مؤثر به عنوان خروجی شبکه‌ها از ۴ چاه این میدان در بازه عمقی سازند کنگان انتخاب شدند. شبکه‌های عصبی پس‌انتشار خطا با ساختارهای متفاوت به روش مرتب‌سازی آموزش داده شد و توان تعمیم آنها ارزیابی شد. آنگاه شبکه‌هایی که بهترین نتایج، یعنی کمترین میانگین مربعات خطای برآورد در مرحله آزمون را داشتند، برای ساخت ترکیب‌های آنسامبلی انتخاب شدند. برای تعیین ضرایب شبکه‌های جزء ترکیب‌های آنسامبلی خطی، سه روش میانگین‌گیری ساده، روش ترکیب خطی بهینه هاشم و روش غیرتحلیلی ترکیب خطی بهینه با استفاده از الگوریتم ژنتیک به کار برده شده و نتایج آنها با هم مقایسه شد. از مقایسه نتایج ترکیب‌ها با بهترین شبکه عصبی مصنوعی منفرد حاصل، مشخص شد که بهترین ترکیب آنسامبلی حاصل، ترکیبی چهارشبکه‌ای است که ضرایب شبکه‌های جزء آن با استفاده از الگوریتم ژنتیک تعیین شده است. این ترکیب توانسته میانگین مربعات خطای برآورد الگوهای آموزش و آزمون را به ترتیب ۳/۶ درصد و ۱۱/۲ درصد نسبت به بهترین شبکه عصبی منفرد کاهش دهد.

کلیدواژه‌ها: سازند کنگان، تخلخل، نگارهای چاه، شبکه عصبی مصنوعی، روش آموزش مرتب‌سازی، ماشین کمیت‌های، ترکیب آنسامبلی، الگوریتم ژنتیک

E-mail:mahmood_zakery2006@yahoo.com

*نویسنده مسئول: محمود ذاکری

۱- مقدمه

نام‌گذاری شده است. در این ماشین، سعی می‌شود از همه اطلاعات مفید، بیشترین بهره برده شود و نه این که با انتخاب یک شبکه به عنوان بهترین شبکه، از اطلاعات مفید دیگر شبکه‌ها صرف نظر شود.

در علوم زمین و از جمله چاه‌نگاری، از رهیافت ماشین کمیت‌های، با توجه به جدید بودن آن، به مراتب کمتر از شبکه‌های عصبی مصنوعی منفرد استفاده شده است، به همین دلیل، هنوز نقاط قوت و ضعف این روش کاملاً شناخته شده نیست و در این مورد ابهام وجود دارد. نتیجه پژوهش‌ها بیشتر با هدف رفع این ابهامات ضروری است. در مطالعه حاضر، ابتدا تخلخل سنگ مخزن با استفاده از شبکه‌های عصبی مصنوعی پس‌انتشار خطا (Error back propagation) که به روش مرتب‌سازی (Regularization) آموزش دیده‌اند، برآورد شده و سپس نتایج آنها با استفاده از روش ترکیب آنسامبلی خطی (Linear ensemble combination) ترکیب می‌شود تا در نهایت با مقایسه نتایج، بررسی شود که آیا در این مورد مطالعاتی خاص، ترکیب آنسامبلی به عنوان نوعی از ماشین کمیت‌های می‌تواند نتایج روش شبکه‌های عصبی مصنوعی منفرد را بهبود دهد یا خیر، و در صورت مثبت بودن پاسخ، چه عواملی بر میزان بهبود نتایج تأثیر می‌گذارند.

۲- شبکه‌های عصبی مصنوعی

شبکه‌های عصبی مصنوعی در حل مسائل از عملکرد دستگاه عصبی موجودات زنده الهام می‌گیرند، به این مفهوم که ابتدا تجربه کسب کرده و سپس نتیجه تجربیات را تعمیم می‌دهند. این شبکه‌ها ساختار لایه‌ای دارند و واحدهای پردازش که نرون (Neuron) نامیده می‌شوند، در این لایه‌ها قرار گرفته‌اند.

بخش‌های مختلف نرون به شرح زیر است: (۱) سیناپس (Synapse)‌ها که همان اتصال‌های بین نرون‌ها هستند و هر یک با وزن (Weight) مختص به خودشان تعیین می‌شوند. (۲) یک جمع‌کننده که سیگنال‌های وزن‌دار را با هم جمع می‌کند. (۳) یک

تخلخل، یکی از ویژگی‌های بسیار مهم و اساسی در مطالعات جامع مخزن است و برآورد مقدار صحیح آن در ارزیابی میزان ذخیره مخزن از اهمیت خاصی برخوردار است. به طور معمول، برای تعیین تخلخل در یک مخزن دو روش وجود دارد: روش اول اندازه‌گیری مستقیم تخلخل با انجام آزمایش‌ها بر روی مغزه‌ها است که روشی مشکل، وقت‌گیر و بسیار پرهزینه است و با مسائل و محدودیت‌هایی همراه است. روش دوم که غیرمستقیم است، استفاده از نگارهای چاه است. این روش نسبت به روش اول آسان‌تر است و اطلاعات را به صورت پیوسته از چاه ثبت می‌کند و از نظر اقتصادی به صرفه است. با وجود این مزایا، پیچیدگی‌های طبیعت ناهمگون زمین و مشکلات و محدودیت‌های عملی ناشی از چاه در قرائت‌های دستگاه‌ها، وضعیتی را به وجود می‌آورد که برای دست‌یابی به نتیجه قابل قبول، باید تصحیحات لازم اعمال شود. برای انجام این تصحیحات به اطلاعات کافی از نقطه قرائت و زمین‌شناسی و سنگ‌شناسی آن، شامل ترکیب سنگ، سیالات سازند، لایه‌های ناخالص شیلی، وضعیت دیواره چاه و غیره نیاز است.

در مواردی که روابط بین داده‌ها، غیرخطی، مبهم و ناشناخته است و تصویر روشنی از آنها در دست نیست، روش شبکه عصبی مصنوعی در مقایسه با روش‌های متعارف، ابزاری توانمند برای حل مسئله است. معمولاً این شرایط در داده‌های مربوط به علوم زمین وجود دارد. به همین دلیل از این روش به طور روزافزون در این علوم استفاده می‌شود.

با توجه به اینکه توانایی روش شبکه عصبی برای حل تمام حالت‌هایی که پیش‌تر شبکه آنها را تجربه نکرده و به شبکه عرضه نشده‌اند، محدود و همراه با خطا است، بنابراین باید به دنبال روش‌هایی بود که با استفاده از آنها عملکرد شبکه‌های عصبی مصنوعی بهبود یابد. به این منظور، ترکیب نتایج چندین شبکه که به طور منفرد و مجزا آموزش دیده‌اند، پیشنهاد شده است. مجموعه حاصل، سامانه چندشبکه‌ای (Multiple networks systems) یا ماشین کمیت‌های (Committee machine (CM))

که با ایجاد یک جمعیت (Population) اولیه تصادفی از راه حل‌ها که اصطلاحاً به آنها کروموزوم‌ها (Chromosomes) گفته می‌شود، شروع می‌شود. با هدف دست‌یابی به یک راه‌حل بهینه، جمعیت جاری متحول می‌شود. به منظور ایجاد جمعیت جدید از جمعیت جاری، با استفاده از تابع خاصی، مقدار تابع هدف به ازای کروموزوم‌های جمعیت جاری مقیاس‌بندی می‌شود تا مقدار برازش (Fitness) هر یک از کروموزوم‌ها تعیین شود. آن‌گاه با استفاده از روش‌هایی خاص و بر اساس مقدار برازش، تعدادی از کروموزوم‌های جمعیت جاری به عنوان والد انتخاب می‌شوند. بنابر اصل نخبه‌گرایی (Elitism)، تعداد خاصی از کروموزوم‌های جمعیت جاری که بیشترین برازش را داشته‌اند بدون تغییر در نسل بعد حفظ می‌شوند و بقیه کروموزوم‌های جمعیت جدید با استفاده از والدین و بر اساس دو قانون زیستی تقاطع (Crossover) و جهش (Mutation) تولید شده و برازش آنها تعیین می‌شود. در تقاطع، کروموزوم‌های جدید که اصطلاحاً به آنها فرزندان (Offspring) گفته می‌شود، از ترکیب یک جفت از والدین تولید می‌شوند اما در جهش، یک فرزند از اعمال تغییرات در یک والد ایجاد می‌شود. پس از چندین بار تولید نسل، الگوریتم ژنتیک همگرا می‌شود و به یک راه‌حل بهینه کم و بیش مطلق با برازش خوب برای تابع هدف می‌رسد (Chen & Lin, 2006; MathWorks™, 2007). شکل ۱ نحوه تولید فرزندان را با استفاده از سه عملگر نخبه‌گرایی، تقاطع و جهش نشان می‌دهد.

۴- ماشین کمینه‌ای

چنان‌که گفته شد در روش شبکه عصبی تعدادی شبکه آموزش دیده تولید می‌شود. این شبکه‌ها با استفاده از یک معیار عملکرد مناسب (مثلاً MSE) سنجیده می‌شوند و بر این اساس، بهترین شبکه که کمترین MSE را دارد انتخاب می‌شود. انتخاب بهترین شبکه منفرد (NN₁)، اگر چه بهترین الگوی حاصل را تولید می‌کند اما باعث از دست رفتن اطلاعاتی می‌شود که در دیگر شبکه‌ها وجود داشته است. بنابراین ترکیب نتایج شبکه‌های آموزش دیده با استفاده از روشی مناسب پیشنهاد شده است، زیرا این کار ممکن است به تلفیق اطلاعات شبکه‌های جزء ترکیب و در نتیجه افزایش دقت و توان تعمیم کمک کند. دو روش معمول برای ترکیب نتایج شبکه‌های منفرد و ایجاد سامانه‌های چندشبکه‌ای وجود دارد: (۱) ترکیب آنسامبلی که در این مقاله از آن استفاده شده و در ادامه توضیح داده می‌شود. (۲) ترکیب مدوله‌ای که در آن، مسئله به تعدادی زیرمسئله تفکیک و هر زیرمسئله توسط یک شبکه عصبی یا آنسامبلی از آنها حل شده و در نهایت با تلفیق پاسخ‌ها، کل مسئله حل می‌شود. این دو نوع ترکیب با هم ناسازگار نیستند، به این مفهوم که یک سامانه چندشبکه‌ای می‌تواند شامل هر دو نوع ترکیب باشد (Bhatt, 2002; Bhatt & Helle, 2002).

۴-۱. ترکیب آنسامبلی

در یک ترکیب آنسامبلی، هر یک از شبکه‌های جزء به تنهایی راه‌حلی را برای مسئله مورد نظر ارائه می‌دهند و نتایج به روشی مناسب با هم ترکیب می‌شوند. آشکار است که ترکیب شبکه‌های یکسان فایده‌ای ندارد، زیرا به طور یکسان تعمیم می‌یابند. بنابراین به منظور ایجاد شبکه‌های سازنده ترکیب می‌توانیم یکی از موارد زیر را تغییر دهیم: پارامترهای اولیه شبکه، الگوهای آموزشی، ساختار شبکه‌ها و یا الگوریتم آموزش (Bhatt, 2002).

در مسائل برآورد تابع، ترکیب آنسامبلی می‌تواند به طور خطی یا غیر خطی انجام شود. در شکل ۲ نمایی از ترکیب خطی شبکه‌ها نشان داده شده است. با توجه به این شکل، ترکیب خطی خروجی شبکه‌های مختلف، مشابه ایجاد یک شبکه بزرگ است که شبکه‌های سازنده آن به طور موازی با هم عمل می‌کنند و ضرایب ترکیب، همان وزن‌های سیناپسی لایه خروجی هستند. برای ورودی x ،

تابع انتقال یا فعال‌ساز (Activation function) که مقدار خروجی جمع‌کننده را به خروجی نرون تبدیل می‌کند. (۴) همچنین هر نرون یک بایاس (Bias) دارد که وظیفه آن کاهش و یا افزایش ورودی تابع انتقال است. به مجموعه وزن‌های سیناپسی و بایاس نرون‌ها، پارامترهای شبکه گفته می‌شود (Bhatt, 2002).

برای حل هر مسئله، شبکه‌های عصبی سه مرحله را طی می‌کنند: آموزش، تعمیم (Generalization) و اجرا (Operation). آموزش، فرایندی است که طی آن، شبکه الگوی موجود در ورودی‌ها و ارتباط بین ورودی‌ها و خروجی‌های مجموعه الگوهای آموزشی را فرا می‌گیرد و منجر به دست‌یابی به پارامترهای بهینه برای هر نرون شبکه می‌شود. تعمیم، توانایی شبکه برای ارائه جواب قابل قبول برای ورودی‌هایی است که در مجموعه آموزشی نبوده‌اند (Unseen data). استفاده از شبکه برای انجام عملکردی که به آن منظور طراحی شده است را اجرا گویند (حسنی پاک و شرف الدین، ۱۳۸۰). بدیهی است که شبکه‌ای که در مرحله کاربرد و اجرا مورد استفاده قرار می‌گیرد، باید به خوبی آموزش دیده و توان تعمیم مناسبی داشته باشد. یکی از مشکلاتی که ممکن است در حل مسئله با استفاده از روش شبکه عصبی پیش بیاید، بیش‌برازش (Overfitting) و یا همان حفظ کردن الگوهای آموزشی توسط شبکه است که قابلیت تعمیم دهی شبکه را کاهش می‌دهد. به عبارت بهتر، در مرحله آموزش شبکه عملکرد خوبی دارد و خطا به مقدار بسیار کوچکی می‌رسد، اما وقتی با الگوهایی به غیر از الگوهای آموزشی آزموده می‌شود، عملکرد ضعیفی دارد و خطای پاسخ زیاد است. یکی از راه‌حل‌هایی که برای رفع این مشکل پیشنهاد شده، استفاده از آموزش به روش مرتب‌سازی است. با توجه به اینکه در این مقاله از روش مرتب‌سازی برای آموزش شبکه‌های عصبی مصنوعی منفرد استفاده شده است، در ادامه این روش با جزئیات بیشتری توضیح داده می‌شود.

۲-۱. آموزش به روش مرتب‌سازی

در روش شبکه عصبی مصنوعی، تابع عملکرد شبکه معمولاً میانگین مربعات خطا (Mean of squares of errors (MSE)) انتخاب می‌شود. در آموزش به روش مرتب‌سازی این تابع عملکرد تغییر می‌کند و به صورت زیر انتخاب می‌شود (Demuth & Beale, 2002):

$$F = \gamma MSE + (1 - \gamma) MSW \quad (1)$$

که در آن

$$MSW = \left(\frac{1}{n} \right) \sum_{j=1}^n w_j^2 \quad (2)$$

در این دو رابطه، MSW میانگین مربعات پارامترهای شبکه (Mean of squares of weights and biases) و γ پارامتر مرتب‌سازی است که مقدار آن بین صفر و یک انتخاب می‌شود. انتخاب تابع عملکرد به این شکل باعث می‌شود که پارامترهای شبکه مقادیر کوچک‌تر و در نتیجه، پاسخ‌های آن هموارتر شوند و احتمال بیش‌برازش کاهش یابد. باید دقت شود که مقدار مناسب و بهینه‌ای برای γ در نظر گرفته شود، زیرا اگر مقدار آن خیلی بزرگ فرض شود، ممکن است بیش‌برازش به وجود آید و اگر خیلی کوچک فرض شود، شبکه به اندازه کافی با الگوهای آموزشی برازش نخواهد داشت. در نرم‌افزار MATLAB، تابع آموزشی مرتب‌سازی بیزین (Bayesian) که به طور خلاصه Trainbr نامیده می‌شود، γ بهینه را به طور خودکار تعیین می‌کند. در استفاده از این تابع، زمانی که مجموع مربعات خطا (Sum of squares of errors (SSE))، مجموع مربعات پارامترهای شبکه (Sum of squares of the network weights and biases (SSW)) و تعداد مؤثر پارامترهای شبکه (Effective number of parameters) در چندین تکرار به مقدار نسبتاً ثابتی برسند، شبکه همگرا شده است و آموزش پایان می‌یابد (Demuth & Beale, 2002).

۳- الگوریتم ژنتیک

الگوریتم ژنتیک (Genetic algorithm (GA)) روش بهینه‌یابی قدرتمندی است

۵- مطالعه موردی: برآورد تخلخل سنگ مخزن گازی کنگان با استفاده از ماشین کمیت‌های

به منظور بررسی قابلیت و توانایی شبکه‌های عصبی مصنوعی کمیت‌های در بهبود نتایج حاصل از شبکه‌های عصبی مصنوعی منفرد، مطالعه موردی در میدان عظیم هیدروکربنی پارس جنوبی در بخش‌های گازدار k-1 و k-2 سازند کنگان انجام شد و تخلخل مؤثر ابتدا با استفاده از شبکه‌های عصبی مصنوعی منفرد آموزش دیده به روش مرتب‌سازی و سپس با استفاده از ترکیب آنسامبلی خطی نتایج آنها برآورد شد.

۵-۱. زمین‌شناسی مخزن گازی کنگان در میدان پارس جنوبی

با توجه به اطلاعات به دست آمده از چاه‌های میدان پارس جنوبی و بر اساس آزمایش‌های انجام شده بر روی نمونه‌های سنگی برداشت شده به هنگام حفاری و نمودارهای چاه‌نگاری گرفته شده از این چاه‌ها، از نظر زمین‌شناسی، سازند کنگان که از نظر سنی متعلق به دوران تریاس زیرین است، با یک ناپوستگی موازی بر روی سازند دالان به سن پرمین قرار گرفته و در بالا توسط شیل‌های سازند دشتک پوشیده شده است. از نظر زمین‌شناسی ساختاری، مخزن گازی کنگان تاقدیس نامتقارنی با امتداد شمال باختر- جنوب خاور است که دامنه جنوب خاوری آن برگشته است. با ظاهر شدن اولین لایه دولومیت نخودی مایل به خاکستری رس‌دار در زیر شیل‌های آغار، شروع سازند کنگان مشخص می‌شود. بخش بالایی شامل دولومیت خاکستری- نخودی مایل به خاکستری- بلورین و تخریبی آلی و لایه‌های نازکی از شیل به رنگ‌های سبز و سبز مایل به خاکستری است. این بخش در چاه‌های مختلف پارس جنوبی ۲۵ تا ۳۰ متر ستبراً دارد. پس از این بخش، ناحیه گازدار سازند کنگان قرار دارد که به طور کلی از سنگ‌آهک و آهک دولومیتی سفید و سفید مایل به نخودی تا قهوه‌ای روشن بلورین شبه تخمکی متخلخل و تخریبی آلی تشکیل شده است. این بخش متخلخل مناسبی دارد و یکی از بخش‌های مهم گازدار میدان پارس جنوبی است. ستبرای این بخش در چاه‌های مختلف به طور میانگین ۱۵۵ متر است (رحیمی، ۱۳۸۱، افشارحرب، ۱۳۸۱ و خسرو تهرانی، ۱۳۸۳). براساس توصیف مغزه و اطلاعات پتروفیزیکی و تلفیق مطالعات میکروسکوپی و ماکروسکوپی و با به کار بردن ویژگی‌هایی همچون سنگ‌شناسی، رخساره و ویژگی‌های مخزنی، و با توجه به تقسیم‌بندی توالی کربنات خوف (Khuff) در سپر عربستان، ناحیه گازدار سازند کنگان به دو واحد مخزنی مشخص و مجزا به نام k-1 و k-2 تقسیم شده است (زارعی و همکاران، ۱۳۸۶).

۵-۲. الگوهای آموزش و آزمون

از داده‌های چاه‌نگاری چاه‌های SP1, SP3, SP6, SP13 میدان پارس جنوبی در بازه ژرفی سازند کنگان (کمترین ژرفا کم و بیش ۲۶۰۰ متر در چاه SP1 و بیشترین ژرفا کم و بیش ۳۰۰۰ متر در چاه SP13) به منظور طراحی، آموزش و آزمون شبکه‌ها استفاده شد. شکل ۳ موقعیت جغرافیایی چاه‌ها را نشان می‌دهد. به علت مشترک بودن میدان پارس جنوبی بین کشورمان و قطر و محرمانه بودن موقعیت دقیق چاه‌ها، مقیاس شکل و مختصات چاه‌ها در اختیار قرار نگرفت. برای آموزش شبکه‌ها از ۲۱۵ الگوی منتخب از داده‌های چاه‌نگاری چاه‌های SP1, SP3, SP13 و برای آزمون توان تعمیم شبکه‌ها از ۸۹ الگوی انتخاب شده از چاه SP6 استفاده شد. در هر الگوی آموزشی و آزمون، داده‌های نگارهای صوتی (DT)، چگالی (RHOB)، پرتو گاما (GR) و تخلخل نوترونی (NPHI) به عنوان ورودی و تخلخل مؤثر (PHIE) به عنوان خروجی شبکه‌ها در نظر گرفته شد.

تخلخل مؤثر با استفاده از بسته نرم‌افزاری (Geoframe petrophysics) محاسبه شده است. نرم‌افزارهای موجود در این بسته نرم‌افزاری، توان محاسبه تخلخل مؤثر از روی داده‌های یک و یا دو و یا سه نگار تخلخل را دارند. با استفاده از داده‌های نگارها و اطلاعات مغزه‌ها و زمین‌شناسی مخزن، تصحیحات مورد نیاز اعم از تصحیح

خروجی ترکیب، \bar{y} ، جمع وزنی خروجی‌های متناظر شبکه‌های جزء (y_j) است و α_j ها ضرایب مربوط به آنها است. در ترکیب، این ضرایب (α_j) ها ثابت هستند ولی در شبکه عصبی بزرگ معادل، این ضرایب که نقش وزن‌های سیناپسی لایه آخر را دارند، در طول آموزش تغییر می‌کنند، بنابراین زمان آموزش زیادتر است و از طرفی به خاطر افزایش پارامترها، احتمال بیش‌برازش بیشتر می‌شود (Hashem et al., 1994).

ترکیب خطی خروجی‌های p شبکه به کار رفته در ساختار ترکیب، عبارت است از:

$$\bar{y}(\bar{x}; \bar{\alpha}) = \sum_{j=1}^p \alpha_j y_j(\bar{x}) \quad (3)$$

که خطای آن:

$$\delta(\bar{x}; \bar{\alpha}) = r(\bar{x}) - \bar{y}(\bar{x}; \bar{\alpha}) \quad (4)$$

در این رابطه، $\bar{\alpha}$ بردار ضرایب شبکه‌ها و $r(\bar{x})$ مقدار مطلوب برای ورودی \bar{x} است. بنابراین لازم است مقادیر مناسبی برای ضرایب α_j ها پیدا کنیم. یک روش، میانگین‌گیری ساده است که به طور گسترده به کار می‌رود. روش دیگر، یافتن ضرایب بهینه (Optimum linear combination (OLC)) است به گونه‌ای که تابع عملکرد را که معمولاً MSE در نظر گرفته می‌شود، کمینه کند. به این منظور، هاشم روشی تحلیلی پیشنهاد کرد. در این روش، به منظور تصحیح بایاس y_j ها، جمله دیگری نیز به معادله (۳) افزوده می‌شود. این جمله $(\bar{x}) \alpha_0 y_0$ است که در آن $y_0(\bar{x}) = 1$ است. بنابراین، خروجی ترکیب به صورت زیر در خواهد آمد:

$$\bar{y}(\bar{x}; \bar{\alpha}) = \sum_{j=0}^p \alpha_j y_j(\bar{x}) = \bar{\alpha}' \bar{y}(\bar{x}) \quad (5)$$

که $\bar{y}(\bar{x})$ و $\bar{\alpha}$ بردارهای $1 \times (p+1)$ هستند. برای رابطه (۵) که حالت کلی را نشان می‌دهد، سه حالت خاص نیز می‌توان در نظر گرفت. بنابراین، در مجموع ۴ حالت خواهیم داشت که تفاوت آنها به وجود یا عدم وجود جمله ثابت α_0 و شرط $\sum_{j=1}^p \alpha_j = 1$ مربوط می‌شود. اگر مجموع ضرایب شبکه‌ها ۱ باشد ترکیب را مقید (Constrained) و در غیر این صورت نامقید (Unconstrained) می‌نامند. بنابراین این ۴ حالت عبارتند از: ۱- نامقید با جمله ثابت (حالت کلی) ۲- مقید با جمله ثابت ۳- نامقید بدون جمله ثابت ۴- مقید بدون جمله ثابت.

ضرایب بهینه با انجام یک سلسله عملیات ماتریسی و با استفاده از مجموعه‌ای از الگوهای تحقق‌یافته که در آن به ازای ورودی \bar{x}_n ، مقدار تابع هدف و خروجی هر یک از شبکه‌های جزء آنسامبل، مشخص است و با $\{K_n : K_n = (\bar{x}_n, r(\bar{x}_n), \bar{y}(\bar{x}_n)), n = 1, \dots, K\}$ نشان داده می‌شود. به طور معمول K همان مجموعه الگوهای آموزشی شبکه‌ها انتخاب می‌شود (Hashem, 1993).

افزون بر روش تحلیلی هاشم، الگوریتم ژنتیک نیز می‌تواند به منظور تعیین ضرایب بهینه با استفاده از سری الگوهای ترکیب به کار رود. به طور مشابه با شبکه‌های عصبی مصنوعی منفرد، توان تعمیم MSE-OLC عبارت است از کارایی آن برای الگوهایی که در سری ترکیب نبوده‌اند و در برآورد ضرایب بهینه نقشی نداشته‌اند. ترکیب حاصل زمانی مفید است که افزون بر الگوهای سری ترکیب، خطای برآورد را برای الگوهای سری آزمون نیز کاهش دهد (Sharkey et al., 2000).

در این مقاله از روش‌های میانگین‌گیری ساده، روش‌های چهارگانه ترکیب خطی بهینه هاشم و روش غیرتحلیلی ترکیب خطی بهینه با استفاده از الگوریتم ژنتیک برای ساخت ترکیب‌های آنسامبلی شبکه‌های عصبی به منظور برآورد تخلخل استفاده شده است.

۰/۸ تغییر داده شد. به دیگر گزینه‌های قابل انتخاب مربوط به الگوریتم ژنتیک (یعنی تابع مقیاس‌بندی برازش (Scaling function)، تابع انتخاب (Selection function)، تابع نسل (Stall generation)، تابع تقاطع (Crossover function) و تابع جهش (Mutation function)) نیز مقادیر و موارد مختلفی نسبت داده شد و فرایند سعی و خطا با جمعیت‌های اولیه تصادفی مختلف انجام شد. در نهایت در هر یک از ۶ حالت منتخب، بهترین نتیجه که کمترین میانگین مربعات خطای برآورد تخلخل الگوهای آزمون را داشت، ثبت شد.

نتایج حاصل، در جدول‌های ۲ تا ۷ آورده شده است. برای نمونه مقادیر جدول ۲ شرح داده می‌شود. از بین ۷ شبکه جدول ۱، ۲۱ انتخاب دوشبکه‌ای صورت گرفت و برای هر یک از این ۲۱ حالت، با استفاده از ۵ روش تحلیلی، ترکیب‌های آنسامبلی خطی ساخته شد. از بین ۱۰۵ ترکیب دوشبکه‌ای حاصل، ترکیب شبکه‌های ۱ و ۳ با استفاده از ترکیب خطی بهینه نامقید بدون جمله ثابت، کمترین میانگین مربعات خطای برآورد تخلخل الگوهای آزمون و بهترین نتیجه را داشته است. برای ترکیب این دو شبکه، ضرایب بهینه با استفاده از الگوریتم ژنتیک نیز به دست آمد. در جدول‌های ۲ تا ۷، کاهش MSE برآورد تخلخل الگوهای آموزش از تقسیم MSE برآورد ترکیب بر MSE برآورد بهترین شبکه منفرد (شبکه ۱ جدول ۱) برای الگوهای آموزش و تفریق مقدار حاصل از مقدار ۱ به دست آمده است. کاهش MSE برآورد تخلخل الگوهای آزمون نیز از تقسیم MSE برآورد ترکیب بر MSE برآورد شبکه ۱ جدول ۱ برای الگوهای آزمون و تفریق مقدار حاصل از مقدار ۱ به دست می‌آید. همان‌گونه که در جدول ۲ دیده می‌شود، ترکیب آنسامبلی خطی بهینه شبکه‌های ۱ و ۳ با استفاده از الگوریتم ژنتیک بهترین ترکیب دوشبکه‌ای است که در این پژوهش به دست آمده است به این علت که در آن، کاهش MSE برآورد تخلخل الگوهای آزمون نسبت به بهترین شبکه منفرد، بیشترین مقدار یعنی ۷/۷ درصد است.

در شکل ۵، فرایند الگوریتم ژنتیک در تعیین ضرایب ترکیب خطی بهینه چهار شبکه‌ای شبکه‌های ۱، ۲، ۳ و ۴ نشان داده شده است. با توجه به این شکل، فرایند تولید نسل در نسل ۹۴ متوقف شده است، زیرا معیارهای توقف تولید نسل به گونه‌ای تعیین شده‌اند که اگر تغییر میانگین وزنی MSE در طی ۵۰ نسل به صفر برسد، الگوریتم متوقف می‌شود و در اینجا نیز در نسل ۹۴ چنین اتفاقی رخ داده است. شکل ۵ - الف، فاصله میانگین بین کروموزوم‌ها (بردارهای ضرایب) در نسل‌ها را نشان می‌دهد که معیاری برای کمیت تنوع (Diversity) بین کروموزوم‌های جمعیت در یک نسل است. شکل ۵ - ب در هر نسل دو مقدار را نشان می‌دهد. یک مقدار مربوط به بهترین (کمترین) MSE برآورد تخلخل الگوهای آموزش به ازای بهترین کروموزوم در آن نسل است که در طی ۹۴ نسل این مقدار در دفعاتی انگشت شمار به میزان بسیار کمی کاهش و بهبود یافته و به مقدار نهایی ۱/۰۹۷۹ رسیده است. همچنین میانگین MSE برآورد تخلخل الگوهای آموزش به ازای ۵۰ کروموزوم موجود در هر نسل در این شکل نشان داده شده است. شکل ۵ - ج، ضرایب شبکه‌ها در بهترین ترکیب خطی آنسامبلی بهینه حاصل از به کارگیری الگوریتم ژنتیک را نشان می‌دهد که می‌توان این ضرایب را به صورت بردار زیر نشان داد: [۰/۲۰۵۹، ۰/۰۷۷۱، ۰/۲۸۳۸، ۰/۴۴۵۱] به این معنی که در این ترکیب خطی بهینه، ضرایب شبکه‌های شماره ۱، ۲، ۳ و ۴ جدول ۱، به ترتیب ۰/۲۸۳۸، ۰/۰۷۷۱ و ۰/۲۰۵۹ است.

۶- نتیجه‌گیری

در یک جمع‌بندی، به طور خلاصه می‌توان نتایج زیر را عنوان کرد:
- به طور کلی نتایج به دست آمده از این پژوهش نشان می‌دهد که در این مورد مطالعاتی، ترکیب آنسامبلی توانسته است نتایج شبکه‌های عصبی مصنوعی منفرد آموزش دیده به روش مرتب‌سازی را بهبود دهد.

ناخالصی شیلی، تصحیح گاز و تصحیحات محیطی در محاسبه تخلخل مؤثر اعمال شده است.

۳-۵. برآورد تخلخل با استفاده از شبکه‌های عصبی پس‌انتشار خطای آموزش دیده به روش مرتب‌سازی و ترکیب آنسامبلی خطی نتایج آنها

کلیه برنامه‌های مورد استفاده در این پژوهش و همچنین کارهای محاسباتی در محیط نرم‌افزار MATLAB تهیه و انجام شده است. برای آموزش شبکه‌های عصبی مصنوعی منفرد پس‌انتشار خطا از روش مرتب‌سازی استفاده شد. به این منظور، تابع آموزش مرتب‌سازی به روش بیزین (Trainbr) در MATLAB مورد استفاده قرار گرفت. پیش‌پردازش داده‌ها به وسیله تابع Prestd که مقادیر داده‌ها را به توزیع گوسی استاندارد تبدیل می‌کند، انجام شد. تعداد دوره‌های تکرار برای آموزش شبکه‌ها ۴۰۰ مرتبه انتخاب شد. شبکه‌هایی با ساختارهای گوناگون شامل یک یا دو لایه میانی با تعداد نرون‌های مختلف در این لایه‌ها و در مجموع ۹۲ ساختار، مورد استفاده قرار گرفت. تابع انتقال نرون‌های لایه‌های میانی، تابع تانزانت هیپربولیک و تابع انتقال نرون‌های لایه خروجی، تابع خطی انتخاب شد. در مورد هر ساختار خاص شبکه، یک مرحله آزمون و خطای طولانی با شرایط اولیه مختلف انجام شده است و بهترین نتیجه که کم‌ترین میانگین مربعات خطای برآورد تخلخل الگوهای آزمون را داشت، ثبت شد. سپس نتایج ساختارها بر اساس این کمیت مرتب شدند و در نهایت از بین ۹۲ شبکه با ساختارهای مختلف، ۷ شبکه که کمترین میانگین مربعات خطای برآورد تخلخل الگوهای آزمون را داشتند برای ساخت ترکیب‌های آنسامبلی انتخاب شدند. جدول ۱ نتایج این ۷ شبکه را نشان می‌دهد.

یکی از نکات مهمی که در آموزش شبکه‌های عصبی با روش مرتب‌سازی باید به آن توجه کرد، تعداد مؤثر پارامترهای شبکه، یعنی تعداد وزن‌های سیناپسی و بایاس‌هایی که به طور مؤثر در شبکه مورد استفاده قرار می‌گیرند، است. جدول ۱ نشان می‌دهد که به رغم اینکه تعداد کل پارامترهای شبکه‌ها زیاد است، اما تعداد مؤثر پارامترها بین ۲۰ تا ۲۵ پارامتر است.

با توجه به کمتر بودن MSE برآورد تخلخل شبکه شماره ۱ جدول ۱ در مرحله آزمون، این شبکه به عنوان بهترین شبکه عصبی مصنوعی منفرد حاصل در نظر گرفته می‌شود. پیشرفت روند آموزش و نمودار همبستگی بین مقدار تخلخل و مقدار برآوردی آن توسط این شبکه برای الگوهای آموزش و آزمون در شکل ۴ نمایش داده شده است. با استفاده از ۷ شبکه جدول ۱، ۱۲۰ ترکیب می‌توان ساخت که ۲۱ ترکیب دوشبکه‌ای، ۳۵ ترکیب سه‌شبکه‌ای، ۳۵ ترکیب چهارشبکه‌ای، ۲۱ ترکیب پنج‌شبکه‌ای، ۷ ترکیب شش‌شبکه‌ای و ۱ ترکیب هفت‌شبکه‌ای را شامل می‌شود. ضرایب شبکه‌ها در هر یک از این ۱۲۰ ترکیب، با استفاده از ۵ روش تحلیلی یعنی میانگین‌گیری ساده، ترکیب خطی بهینه نامقید با جمله ثابت، ترکیب خطی بهینه مقید با جمله ثابت، ترکیب خطی بهینه نامقید بدون جمله ثابت و ترکیب خطی بهینه مقید بدون جمله ثابت تعیین شد و نتایج ۶۰۰ ترکیب آنسامبلی خطی حاصل، برای الگوهای آموزش و آزمون مورد بررسی قرار گرفت. سپس از بین هر یک از دسته ترکیب‌های دو، سه، چهار، پنج، شش و هفت‌شبکه‌ای بهترین ترکیب حاصل از روش‌های تحلیلی که کمترین میانگین مربعات خطای برآورد تخلخل الگوهای آزمون را داشت، انتخاب شد. برای این ۶ ترکیب منتخب، افزون بر روش‌های تحلیلی، ضرایب ترکیب خطی بهینه با استفاده از روش الگوریتم ژنتیک نیز تعیین و ترکیب آنسامبلی خطی ساخته شد. در بهینه‌یابی با الگوریتم ژنتیک، تعداد کروموزوم‌های جمعیت‌ها ۵۰ کروموزوم انتخاب شد که از این تعداد، ۵ کروموزوم نخبه در جمعیت بعدی حفظ و بقیه با استفاده از تقاطع و جهش تولید شد. تعداد دفعات تولید نسل ۱۵۰ بار انتخاب شده است. مقادیر کمیت نسبت تقاطع (Crossover fraction) که درصد یا مقدار نسبی فرزندان تولید شده با استفاده از قانون تقاطع را تعیین می‌کند از ۰/۳ تا

که لازم است به آن اشاره شود آن است که در این مورد مطالعاتی خاص، ترکیب‌های آنسامبلی حاصل از بهینه‌سازی با الگوریتم ژنتیک توان تعمیم بسیار خوبی دارند به گونه‌ای که اگر چه الگوهای آزمون در فرایند تعیین ضرایب بهینه ترکیب نقشی نداشته‌اند، اما کاهش MSE برای آنها بیشتر از کاهش است که در مورد الگوهای آموزش وجود دارد. این قضیه در بیش از ۷۰۰ مورد فرایند آزمون و خطا که برای تعیین ضرایب بهینه با استفاده از الگوریتم ژنتیک در ۶ ترکیب منتخب انجام شده، دیده شد، البته هیچ تضمینی وجود ندارد که در مسائل مشابه چنین چیزی رخ دهد.


سپاسگزاری

از آقای مهندس ماشاء... رحیمی، کارشناس ارشد مدیریت اکتشاف شرکت ملی نفت به خاطر در اختیار قرار دادن داده‌های مورد نیاز این مقاله تشکر و قدردانی می‌شود.


- از روی نتایج ارائه شده در جداول این مقاله می‌توان گفت که به طور کلی روش ترکیب خطی بهینه هاشم بیشترین کاهش را در MSE برآورد تخلخل الگوهای آموزش ایجاد کرده است.

- از بین ۵ روش تحلیلی به کار رفته در این پژوهش، روش ترکیب خطی بهینه نامقید بدون جمله ثابت در مقایسه با چهار روش دیگر، کاهش بیشتری را در MSE برآورد تخلخل الگوهای آزمون ایجاد کرده است و نتایج بهتری داشته است.


- در همه مواردی که مورد بررسی قرار گرفته است، ترکیب‌های آنسامبلی خطی بهینه حاصل از روش الگوریتم ژنتیک نسبت به روش‌های تحلیلی، MSE برآورد تخلخل الگوهای آزمون کمتر و نتایج بهتری داشته‌اند. بهترین ترکیب آنسامبلی حاصل در این پژوهش، ترکیب آنسامبلی خطی بهینه شبکه‌های ۱، ۲، ۳ و ۴ با استفاده از الگوریتم ژنتیک است که کمترین MSE برآورد تخلخل الگوهای آزمون و بیشترین کاهش مقدار MSE برآورد تخلخل الگوهای آزمون نسبت به بهترین شبکه عصبی منفرد حاصل به میزان ۱۱/۴٪ را داشته است. نکته‌ای



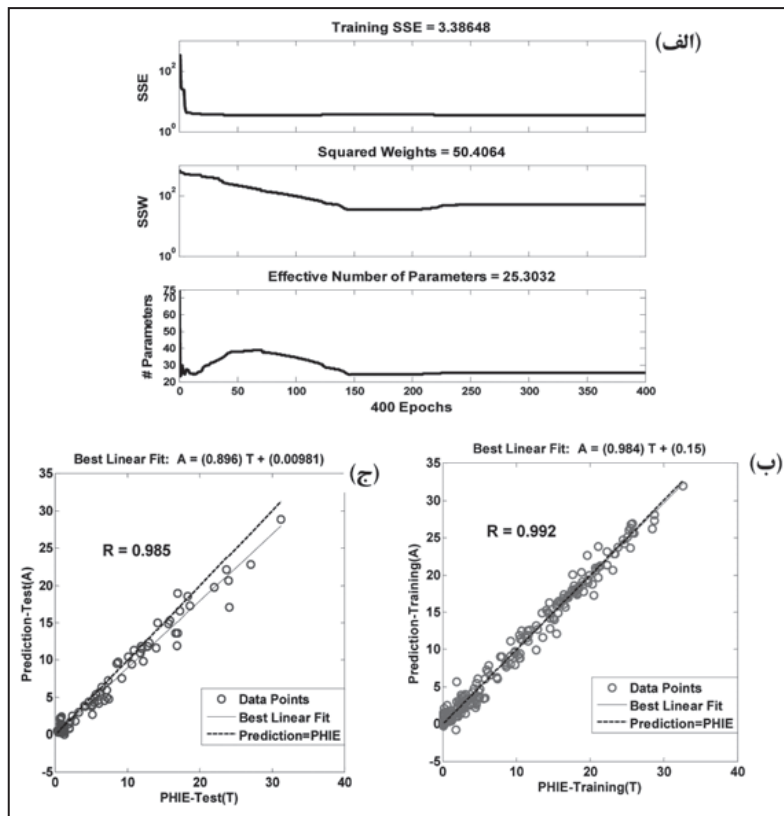
شکل ۱- الف) عملگر نخبه‌گرایی، ب) عملگر تقاطع، ج) عملگر جهش (MathWorks™, 2007).



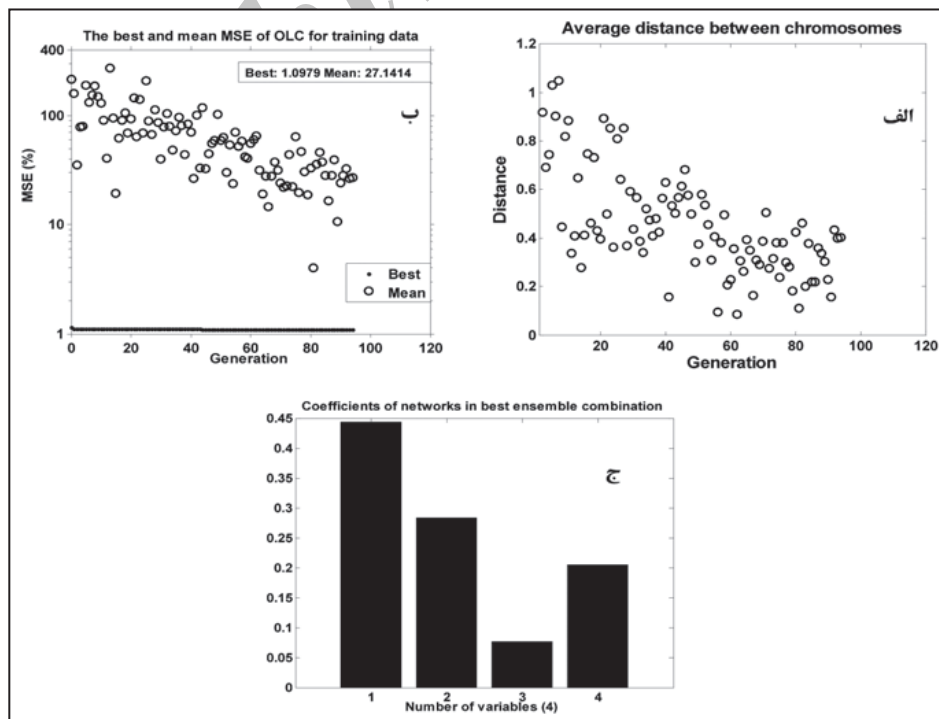
شکل ۳- موقعیت چاه‌های میدان پارس جنوبی (رحیمی، ۱۳۸۱).



شکل ۲- ترکیب آنسامبلی خطی شبکه‌های آموزش دیده (Hashem et al., 1994).



شکل ۴- الف) نمایش پیشرفت روند آموزش و همگرایی SSE، SSW و تعداد مؤثر پارامترهای شبکه در آموزش شبکه شماره ۱ جدول ۱، ب) نمودار همبستگی بین تخلخل و برآورد شبکه ۱ جدول ۱ برای الگوهای آموزش، ج) نمودار همبستگی بین تخلخل و برآورد شبکه ۱ جدول ۱ برای الگوهای آزمون.



شکل ۵- فرایند الگوریتم ژنتیک در تعیین ضرایب ترکیب خطی بهینه چهار شبکه‌ای شبکه‌های ۱، ۲، ۳ و ۴. الف) فاصله میانگین بین کروموزوم‌ها (بردارهای ضرایب) در نسل‌ها، ب) بهترین (کمترین) MSE برآورد الگوهای آموزش به ازای بهترین کروموزوم در هر نسل و میانگین MSE برآورد الگوهای آموزش به ازای ۵۰ کروموزوم موجود در هر نسل، ج) ضرایب شبکه‌ها در بهترین ترکیب خطی آنسامبلی بهینه.

جدول ۱-۷ شبکه منفرد آموزش دیده به روش مرتب سازی با بهترین نتایج.

شماره ردیف	ساختار شبکه	MSE (الگوهای آموزش)	ضریب همبستگی (الگوهای آموزش)	MSE (الگوهای آزمون)	ضریب همبستگی (الگوهای آزمون)	تعداد کل پارامترهای شبکه	تعداد مؤثر پارامترهای شبکه
۱	۴-۲-۱۶-۱	۱/۱۳۹	۰/۹۹۲	۲/۳۹۴	۰/۹۸۵	۷۵	۲۵
۲	۴-۲-۱۴-۱	۱/۲۲۸	۰/۹۹۱	۲/۴۰۵	۰/۹۸۷	۶۷	۲۳
۳	۴-۳-۷-۱	۱/۱۹۸	۰/۹۹۲	۲/۴۱۴	۰/۹۸۶	۵۱	۲۰
۴	۴-۳-۶-۱	۱/۱۹۸	۰/۹۹۲	۲/۴۱۸	۰/۹۸۶	۴۶	۲۰
۵	۴-۳-۸-۱	۱/۱۹۸	۰/۹۹۲	۲/۴۱۹	۰/۹۸۶	۵۶	۲۱
۶	۴-۳-۱۳-۱	۱/۱۹۷	۰/۹۹۲	۲/۴۱۹	۰/۹۸۶	۸۱	۲۱
۷	۴-۳-۱۴-۱	۱/۱۹۶	۰/۹۹۲	۲/۴۱۹	۰/۹۸۶	۸۶	۲۱

جدول ۲- نتایج ترکیب آنسامبلی خطی شبکه های ۱ و ۳ جدول ۱.

نتایج	روش ترکیب خطی	میانگین گیری ساده	Hashem - OLC	GA - OLC
ترکیب آنسامبلی	۳ و ۱	۳ و ۱	۳ و ۱	۳ و ۱
MSE (الگوهای آموزش)	۱/۰۹۳	۱/۰۹۰	۱/۰۹۶	۱/۰۹۶
کاهش در MSE (الگوهای آموزش)	٪ ۴	٪ ۴/۳	٪ ۳/۸	٪ ۳/۸
MSE (الگوهای آزمون)	۲/۳۱۳	۲/۳۰۳	۲/۲۱	۲/۲۱
کاهش در MSE (الگوهای آزمون)	٪ ۳/۴	٪ ۳/۸	٪ ۷/۷	٪ ۷/۷

جدول ۳- نتایج ترکیب آنسامبلی خطی شبکه های ۱، ۳ و ۴ جدول ۱.

نتایج	روش ترکیب خطی	میانگین گیری ساده	Hashem - OLC	GA - OLC
ترکیب آنسامبلی	۴ و ۳، ۱	۴ و ۳، ۱	۴ و ۳، ۱	۴ و ۳، ۱
MSE (الگوهای آموزش)	۱/۱۱۱	۱/۰۹۰	۱/۰۹۹	۱/۰۹۹
کاهش در MSE (الگوهای آموزش)	٪ ۲/۵	٪ ۴/۳	٪ ۳/۵	٪ ۳/۵
MSE (الگوهای آزمون)	۲/۳۲۷	۲/۲۹۹	۲/۱۹۷	۲/۱۹۷
کاهش در MSE (الگوهای آزمون)	٪ ۲/۸	٪ ۴	٪ ۸/۲	٪ ۸/۲

جدول ۴- نتایج ترکیب آنسامبلی خطی شبکه های ۱، ۲، ۳ و ۴ جدول ۱.

نتایج	روش ترکیب خطی	میانگین گیری ساده	Hashem - OLC	GA - OLC
ترکیب آنسامبلی	۴ و ۳، ۲، ۱	۴ و ۳، ۲، ۱	۴ و ۳، ۲، ۱	۴ و ۳، ۲، ۱
MSE (الگوهای آموزش)	۱/۰۹۵	۱/۰۷۸	۱/۰۹۸	۱/۰۹۸
کاهش در MSE (الگوهای آموزش)	٪ ۳/۹	٪ ۵/۴	٪ ۳/۶	٪ ۳/۶
MSE (الگوهای آزمون)	۲/۳۳۴	۲/۲۹۸	۲/۱۲۷	۲/۱۲۷
کاهش در MSE (الگوهای آزمون)	٪ ۲/۵	٪ ۴	٪ ۱۱/۲	٪ ۱۱/۲

جدول ۵- نتایج ترکیب آنسامبلی خطی شبکه های ۱، ۲، ۴، ۵ و ۶ جدول ۱.

نتایج	روش ترکیب خطی	میانگین گیری ساده	Hashem - OLC	GA - OLC
ترکیب آنسامبلی	۶ و ۵، ۴، ۲، ۱	۶ و ۵، ۴، ۲، ۱	۶ و ۵، ۴، ۲، ۱	۶ و ۵، ۴، ۲، ۱
MSE (الگوهای آموزش)	۱/۱۰۷	۱/۰۷۱	۱/۰۸۹	۱/۰۸۹
کاهش در MSE (الگوهای آموزش)	٪ ۲/۸	٪ ۶	٪ ۴/۴	٪ ۴/۴
MSE (الگوهای آزمون)	۲/۳۴۶	۲/۳۲۱	۲/۱۹۴	۲/۱۹۴
کاهش در MSE (الگوهای آزمون)	٪ ۲	٪ ۳	٪ ۸/۴	٪ ۸/۴

جدول ۶- نتایج ترکیب آنسامبلی خطی شبکه‌های ۱، ۲، ۴، ۵، ۶ و ۷ جدول ۱

GA - OLC	Hashem - OLC	میانگین گیری ساده	نتایج روش ترکیب خطی
۷ و ۶، ۵، ۴، ۲، ۱	۷ و ۶، ۵، ۴، ۲، ۱	۷ و ۶، ۵، ۴، ۲، ۱	ترکیب آنسامبلی
۱/۰۸۹	۱/۰۶۵	۱/۱۱۷	MSE (الگوهای آموزش)
% ۴/۴	% ۶/۵	% ۱/۹	کاهش در MSE (الگوهای آموزش)
۲/۱۶۹	۲/۳۲۷	۲/۳۵۵	MSE (الگوهای آزمون)
% ۹/۴	% ۲/۸	% ۱/۶	کاهش در MSE (الگوهای آزمون)

جدول ۷- نتایج ترکیب آنسامبلی خطی ۷ شبکه جدول ۱

GA - OLC	Hashem - OLC	میانگین گیری ساده	نتایج روش ترکیب خطی
۷ و ۶، ۵، ۴، ۳، ۲، ۱	۷ و ۶، ۵، ۴، ۳، ۲، ۱	۷ و ۶، ۵، ۴، ۳، ۲، ۱	ترکیب آنسامبلی
۱/۰۸۷	۱/۰۶۳	۱/۱۲۵	MSE (الگوهای آموزش)
% ۴/۶	% ۶/۷	% ۱/۲	کاهش در MSE (الگوهای آموزش)
۲/۲۰۱	۲/۳۳۷	۲/۳۶۱	MSE (الگوهای آزمون)
% ۸/۱	% ۲/۴	% ۱/۴	کاهش در MSE (الگوهای آزمون)

کتابنگاری

- افشارحرب، ع.، ۱۳۸۱- زمین شناسی نفت، انتشارات دانشگاه پیام نور.
- حسینی پاک، ع.ا. و شرف‌الدین، م.، ۱۳۸۰- تحلیل داده‌های اکتشافی، انتشارات دانشگاه تهران.
- خسروتهرانی، خ.، ۱۳۸۳- زمین شناسی ایران، انتشارات دانشگاه پیام نور، چاپ پنجم.
- رحیمی، م.، ۱۳۸۱- تعبیر و تفسیر لرزه‌ای ناحیه پارس جنوبی در افق‌های آسماری، جهرم، سروک، داریان، فهلیان، سورمه، کنگان، نار و فراقون، مدیریت اکتشاف شرکت ملی نفت ایران.
- زارعی، س.، موحد، ب.، باقری، ع.م. و مردانی، ع.، ۱۳۸۶- ارزیابی تراوایی سازند کنگان با استفاده از داده‌های نگار CMR و مغزه در میدان پارس جنوبی، بیست و ششمین گردهمایی علوم زمین شناسی.

References

- Bhatt, A. & Helle, H. B., 2002- Committee neural networks for porosity and permeability prediction from well logs, Geophysical Prospecting, 50: 645-660.
- Bhatt, A., 2002- Reservoir properties from well logs using neural networks, PhD thesis, Department of Petroleum Engineering and Applied Geophysics, Norwegian University of Science and Technology.
- Chen, C. H. & Lin, Z. S., 2006- A committee machine with empirical formulas for permeability prediction, Computer & Geosciences, 32: 485-496.
- Demuth, H. & Beale, M., 2002- Neural network toolbox user's guide of MATLAB, Version 4, Online on <http://www.mathworks.com/>.
- Hashem, S., 1993- Optimal linear combination of neural networks, PhD thesis, School of Industrial Engineering, Purdue University.
- Hashem, S., 1997- Optimal linear combination of neural networks, Neural Networks, 10: 599-614.
- Hashem, S., Shmeiser, B. & Yih, Y., 1994- Optimal linear combination of neural networks: An overview, School of Industrial Engineering, Purdue University.
- MathWorks™, 2007- Genetic algorithm and direct search toolbox 2 user's guide of MATLAB, Online on <http://www.mathworks.com/>.
- Sharkey, A., Sharkey, N., Gerecke, U. & Chandroth, G. O., 2000- The "test and select" approach to ensemble combination. In: Kittler J. & Roli F. (eds.) Multiple classifier systems. Springer-Verlag, Inc. PP30-44.

Investigation of Guno Storm and Their Effects on Coastlines Geomorphology of Makran Sea use of Remot Sensing

A. R. Salehipour Milani¹, K. Nejad Afzali^{1*} & F. Bayatani²

¹Geological Survey of Iran, Marine Geology Management, Tehran, Iran

² Faculty of Geography, Tehran University, Tehran, Iran.

Received: 2010 January 05

Accepted: 2010 June 22

Abstract

The Guno storm, due to its severe intensity, caused substantial damages to the coasts of Sistan and Baluchestan and Hormozgan provinces. Tropical storms develop in the form of enormous hurricanes which suck the surrounding air towards them. We feel such rapid movement of air as strong winds; In satellite images, it is seen as the movement of clouds (water vapor) towards the core or the eye of the storm. With a velocity of 150 km/h and rain reaching 160 mm, the storm had made considerable geomorphologic changes in the coast of Oman Gulf as well as damages. Such geomorphologic changes were studied using ETM, TM and LISS III satellite data and were compared before and after the Guno storm. Also the early results taken from satellite images were coordinated with field study after the storm. These inquiries show that acute changes have been made in the opening of important estuaries such as Shur, Sargan, Kahir, Bir and Bandini. Also change stream course, due to migration channel on river meander and area of flooded area on coastal plain was determined. Cooperation of satellite data shows, discharge of sediment to the bays such as Pozm, Chabahar that it can be a serious problem for navigation and coastal structures in this area.

Keywords: Gonu, Geomorphologic Evolution, Remote sensing, Barrier, Jask, Chabahar, Pozm

For Persian Version see pages 23 to 32

*Corresponding author: K. Nejad Afzali; E-mail: K_afzali2007@yahoo.com

Porosity Assessment of Kangan Gas Formation in South Pars Hydrocarbon Field by Application of Committee Machine Composed of Single Artificial Neural Networks Trained using Regularization Method

A. Kamkar Rouhani¹ & M. Zakeri^{1*}

¹ Faculty of Mining, Petroleum and Geophysics, Shahrood University of Technology, Shahrood, Iran

Received: 2009 May 12

Accepted: 2010 July 31

Abstract

In order to obtain more accurate results from application of the method of artificial neural networks, instead of selection of the best network determined by trial and error process, we suitably combine the results of several networks that is called committee machine, to reduce the error, and thus, increasing the accuracy of the output results. In this research, ensemble combination of single artificial neural networks has been used in order to estimate the effective porosity of Kangan gas reservoir rock in South Pars hydrocarbon field. To achieve this goal, well logging data of 4 wells in the area at the depth interval corresponding to Kangan formation were used. Acoustic, density, gamma ray and neutron porosity well log data were assigned as the input of the networks while the effective porosity data were considered as the output of the networks. Back-propagation single neural networks having different structures were trained using regularization method and their results were assessed. Then, the networks with the best results, i.e. contained minimum mean of squares of errors in the test step, were selected for making ensemble combinations. To determine the weighting coefficients of the networks in the linear ensemble combinations, we applied three methods of simple averaging, Hashem's optimal linear combination and non-analytical optimal linear combination employing genetic algorithm, and their results were compared. The best ensemble combination, in which we had the maximum reduction in mean of squares of errors of the test step compared to the best single neural network, was an optimal linear four-network combination obtained by using genetic algorithm optimization method. This best ensemble combination, compared to the best single neural network, reduced the mean of squares of errors in the training and test steps 3.6% and 11.2%, respectively.

Keywords: Kangan Formation, Porosity, Well Logs, Artificial Neural Network, Regularization Training Method, Committee Machine, Ensemble Combination, Genetic Algorithm

For Persian Version see pages 33 to 40

*Corresponding author: M. Zakeri; E-mail:mahmood_zakery2006@yahoo.com

The Huge Jiroft Landslide: Introduction, Indications and Characteristics

A. Abbasnejad^{1*}

¹Department of Geology, Shahid Bahonar University of Kerman, Kerman, Iran

Received: 2009 December 09

Accepted: 2010 August 29

Abstract

The huge and historical landslide of Jiroft, being about 53 Km² in area, is located in 35 Km NW of Jiroft town just adjacent to Jiroft Dam and in coordinates of 28° 45' to 28° 53' N and 57° 20' to 57° 30' E. This slide which has taken place as a result of massive movement of upper reefal part of Qom formation dipping only 6°, 8 cubic kilometers in volume and about 300 meters thickness over the underlying marls, is recognizable based on shattered rocks, anomaly along the course of Halil Roud and the presence of well-rounded igneous boulders in some parts among the shattered rocks. As a result of this slide, the course of Halil was completely blocked and an ephemeral lake was created. Afterwards, the lake overflowed in another place (the present place of the Dam) which was the lowest point in its periphery. Due to this river detour, the Halil Roud incised its fan, created a gorge from the overflowing point to its confluence point, as well as incision of several small fans along its course. The presence of several active faults and low slope of the sliding mass imply the probable influence of earthquake and heavy precipitation as triggering mechanisms. The main characteristics of this slide include very low slope (6°), its size (53km² in area and maximum run-out distance of about 7 km), comprising four parts, specific mechanism (like other sturztorms) and its time of occurrence (probably 60000 to 100000 years ago). Depending on the classification of landslides, it may be considered as extremely rapid rock slide, sturztorm, rock avalanche as well as debris avalanche. The desert varnish of boulders engaged in the slide mass and the solution runnels generated after the slide suggest that the age of the slide is about tens of thousands to several thousands years ago.

Keywords: Landslide, Jiroft, Halil Roud, Jiroft Dam, Channel anomaly, Natural lake, Alluvial fan.

For Persian Version see pages 41 to 48

*Corresponding author: A. Abbasnejad; E-mail: aabbas@uk.ac.ir

Using Index Overlay, Fuzzy Logic Method and Analytical Hierarchy Process in order to Determine Au and Cu Potential Targets in North Part of Dali Porphyry Deposit

S. Youseffar^{1*}, A. Khakzad¹, H. Asadi Harooni², M. R. Jafari³, M. Vosoughi Abedini¹

¹ Department of Geology, Science and Research Branch, Islamic Azad University, Tehran, Iran

² Mining Department, Faculty of Mining Engineering, Isfahan University of Technology, Isfahan, Iran

³ Department of Geology, North Tehran Branch, Islamic Azad University, Tehran, Iran

Received: 2010 April 04

Accepted: 2010 September 19

Abstract

Dali porphyry copper-gold deposit is situated geologically incontact of the Urmieh-Dokhtar magmatic belt and the Sanandaj-Sirjan zone in central of Iran and for the first time this deposit was investigated with using the satellite image processing (TM). In this research, the Northern part of the Dali deposit has been investigated in order to recognize the potential copper and gold-bearing target areas. The survey layers include