

تخمین میزان تراوایی مخازن نفتی به کمک شبکه‌ی خودسازمانده نرو-فازی FCMAC با آموزش الگوریتم ژنتیک

سید جواد صفوی دانشکده علوم پایه، دانشگاه آزاد اسلامی واحد علوم و تحقیقات jsafavi@gmail.com	مهران زیادلو دانشکده کامپیوتر، دانشگاه علم و صنعت ایران mehranziadloo@gmail.com	کریم فائز استاد دانشکده مهندسی برق، دانشگاه صنعتی امیرکبیر kfaez@aut.ac.ir	سید عبدالوحید کاظمی دانشکده کامپیوتر، دانشگاه آزاد اسلامی واحد قزوین vahidkazemi@hotmail.com
---	--	---	---

سانتی‌متر مربعی، تحت فشار یک اتمسفر بر سانتی‌متر، می‌دهد. دقیق‌ترین روش برای تعیین میزان تراوایی یک سازند^۳ (سنگ تشکیل دهنده‌ی زمین)، تحلیل بخشی از آن (با عنوان مغزه^۴) در آزمایشگاه می‌باشد.

مغزه به بخشی از سازند اطلاق می‌شود که در حین حفاری، به شکل استوانه‌ای، از زمین استخراج شده و برای تحلیل به آزمایشگاه ارسال می‌شود. با انجام آزمایش‌های گوناگون بر روی مغزه می‌توان اطلاعات زیادی از خصوصیات چاه را بدست آورد. از مهم‌ترین دستاوردهای تحلیل مغزه، محاسبه‌ی میزان تراوایی سازند تشکیل دهنده‌ی چاه می‌باشد. با افزایش میزان تراوایی یک سازند، سیالات (برای مثال نفت) با صرف انرژی کمتری از آن استخراج می‌شوند. از این رو بدست آوردن عمقی از چاه که بیشترین میزان تراوایی را داشته باشد، از اهمیت زیادی برخوردار است. یکی از اصلی‌ترین دلایلی که موجب می‌شود تا نتوانیم میزان تراوایی را در تمام عمق چاه با استفاده از تحلیل مغزه‌ها در آزمایشگاه بدست آوریم، هزینه بالای آن است.

معمولاً در زمان حفاری یک چاه، به کمک ابزارهای مخصوص، اطلاعاتی از سازند تشکیل دهنده‌ی چاه ثبت و نگهداری می‌شود. این اطلاعات با عنوان داده‌های چاه^۵ شناخته می‌شوند. از جمله داده‌های چاه می‌توان به نحوه‌ی عبور الکتریسته از سازند و یا میزان رادیواکتیویته‌ی آن اشاره کرد. هر چند هیچکدام از داده‌های چاه نمی‌توانند به صورت مستقیم میزان تراوایی را مشخص کنند، ولی استفاده از داده‌های چاه در کنار نتایج مغزه‌ها به منظور بدست آوردن یک رابطه بین آنها، یکی از روش‌های مطرح می‌باشد. تلاش‌های زیادی به منظور ارائه روابطی بین داده‌های چاه و میزان تراوایی شده است، ولی تمام آنها تجربی بوده و نوعاً موردی می‌باشند (فقط در یک میدان معتبرند) و در نتیجه قابل اثبات نیستند. به همین دلیل موارد نقض بسیاری برای آنها وجود دارد.

در این مقاله، سعی شده تا با استفاده از داده‌های چاه در کنار میزان تراوایی مغزه‌ها، به عنوان داده‌های آموزشی یک شبکه‌ی نرو-فازی،

چکیده: تراوایی مخازن هیدروکربنی یکی از پارامترهای مهم در تحلیل میزان بهره برداری از چاه‌های نفتی هست. روش متداول برای بدست آوردن میزان تراوایی، انجام آزمایش‌های پرهزینه بر روی مغزه‌هایی از سازند، در آزمایشگاه می‌باشد. با توجه به هزینه‌ی این آزمایش‌ها، استخراج مغزه فقط برای نقاط معدودی از چاه امکان‌پذیر است، از این رو تحقیقات زیادی به منظور تخمین میزان تراوایی مخزن، به کمک داده‌های چاه صورت پذیرفته است ([1]، [2] و [3]). با محقق شدن این تحقیقات، می‌توان میزان تراوایی را برای سرتاسر عمق یک مخزن تخمین زد. در این مقاله سعی شده است تا به کمک شبکه‌ی نرو-فازی FCMAC [4]، [5]، [6] و [7]، میزان تراوایی چاه‌های نفتی را با استفاده از داده‌های چاه، تخمین زد. شبکه‌ی FCMAC نیازمند الگوریتم خوشه‌بندی DIC [8] به منظور تولید ترم‌های فازی ورودی خود می‌باشد، این الگوریتم دارای پارامترهایی به منظور کنترل تعداد و اندازه‌ی خوشه‌های فازی است که به منظور پیدا نمودن بهترین تلفیق این پارامترها از الگوریتم ژنتیک استفاده شده. با تحقق این هدف، می‌توان دید دقیق‌تری نسبت به خصوصیت‌های یک چاه به دست آورد که خود می‌تواند از صرف هزینه‌های اضافی در حفر چاه جلوگیری نماید. به منظور آزمایش روش پیشنهادی از داده‌های چاه نگاری مخزن بنگستان میدان رگ سفید استفاده شده است. نتایج بدست آمده نشان می‌دهد که این روش با توجه به دقت و سرعت عملکرد خود، یک راه‌حل عملی برای این مسئله می‌باشد.

کلمات کلیدی: تراوایی مخازن نفتی، داده‌های چاه نگاری، نرو-فازی، FCMAC، DIC.

۱- مقدمه

میزان تراوایی^۱ میادین نفتی یکی از پارامترهای اصلی در تحلیل مخازن هیدروکربنی می‌باشد. تعریف تراوایی عبارت است از توانایی عبور سیال از یک محیط متخلخل. واحد تراوایی داری^۲ بوده و یک داری تراوایی سنگی می‌باشد که اجازه جریان یک سانتی‌متر مکعب از سیال با ویسکوزیته یک سانتی‌پواز را در یک ثانیه، از سطح مقطع یک

به منظور مقایسه‌ی مدل نرو-فازی FCMAC با نوع غیر فازی آن، نحوه‌ی عملکرد آن نسبت به شبکه عصبی مصنوعی اصلی شفاف‌تر شده، آموزش آن بسیار سریع‌تر گشته است.

۲-۲ ساختار شبکه

هر سیستم فازی از دو بخش اصلی تشکیل می‌شود: پایگاه دانش و موتور استنتاج، شبکه نرو-فازی FCMAC نیز از این قاعده مستثنا نیست. در مورد شبکه‌ی FCMAC پایگاه دانش توسط ساختار خود شبکه، در قالب قوانین فازی فراهم شده و به منظور تولید خروجی می‌توان از انواع روش‌های استنتاج فازی نیز استفاده نمود. در این مقاله از روش یاگر، با تلفیق روش ممدانی، برای استنتاج استفاده شده است. در روش یاگر، ورودی‌ها و خروجی‌ها در ابتدای امر فازی شده و سپس به کار گرفته می‌شوند. به منظور سادگی شبکه، قوانین فازی به کار گرفته شده از ساختار چند ورودی و تک خروجی (MISO) پیروی می‌کنند، چرا که تولید یک سیستم چند ورودی و چند خروجی (MIMO) از روی ساختار قبلی به سادگی امکان‌پذیر است.

در یک شبکه FCMAC-Yager [1] فضای ورودی در ابتدای امر می‌بایست به خوشه‌هایی (ترم‌های فازی) تقسیم شود که این امر توسط الگوریتم DIC [8] محقق می‌شود. این امر موجب می‌شود تا فضای ورودی به صورت فازی کوانتیزه شده و از هدر رفتن حافظه که در روش کوانتیزه کلاسیک (با فواصل یکنواخت) اتفاق می‌افتد، جلوگیری گردد. در شکل (۱) می‌توانید ساختار یک شبکه FCMAC نمونه را مشاهده نمایید. در این شکل ورودی دو بعدی بوده و به ترتیب به ۴ و ۵ ترم فازی تقسیم شده‌اند. همچنین این شبکه دارای یک خروجی با ۴ ترم فازی می‌باشد. در این تحقیق از ترم‌های فازی با تابع عضویت شبه گوسی^{۱۰} استفاده شده است.

در ادامه نحوه‌ی عملکرد این شبکه تشریح می‌شود. این شبکه در شش قدم خروجی خود را تولید می‌کند.

قدم اول (فازی کردن^{۱۱} ورودی‌ها): از آنجایی که ورودی‌های مسئله همیشه اعداد به صورت غیر فازی^{۱۲} می‌باشند، برای آنکه توسط استنتاج یاگر مورد استفاده قرار بگیرند، می‌بایست فازی شوند. نمونه‌ی ورودی X $[x_1, x_2, \dots, x_n]^T$ را در نظر بگیرید. در اینجا بعد ورودی، I فرض شده است. هر بعد از متغیر ورودی به صورت مجزا به شکل Singleton به یک مجموعه‌ی فازی \bar{X}_i تبدیل می‌شود.

$$\mu_{\bar{X}_i}(x_i) = \begin{cases} 1, & \text{if } \bar{x}_i = x_i \\ 0, & \text{otherwise} \end{cases} \quad (1)$$

که در آن x_i بعد نام از ورودی غیر فازی X می‌باشد.

قدم دوم (انتخاب قوانین): در این شبکه، آموزش شبکه و تولید خروجی به صورت محلی صورت می‌پذیرد بدین صورت که با قرار گرفتن یک ورودی در شبکه، فقط تعداد معدودی از قوانین فازی فعال می‌شوند. این

سیستمی طراحی شود که به کمک آن بتوان روشی برای تخمین میزان تراوایی یک سازند ارائه نمود.

در این تحقیق از یک شبکه‌ی نرو-فازی جدید، با نام FCMAC (Fuzzy Cerebellar Model Articulation Controller) استفاده شده است. شبکه FCMAC نیازمند آن است که در کنار داده‌های ورودی آموزشی، ترم‌های فازی تفکیک کننده فضای ورودی را نیز دریافت کند، که برای این منظور از الگوریتم خوشه‌بندی^{۱۳} فازی DIC (Discrete Incremental Clustering) استفاده شده است. الگوریتم DIC دارای یک سری پارامتر به منظور کنترل تعداد و اندازه‌ی ترم‌های فازی تولیدی می‌باشد. به منظور تنظیم این پارامترها، از الگوریتم ژنتیک^{۱۴} کمک گرفته شده. دو الگوریتم DIC و ژنتیک فقط در فاز آموزش استفاده خواهند شد و پس از تکمیل آموزش سیستم، شبکه‌ی FCMAC به تنهایی عمل خواهد نمود. در ادامه، هر یک از الگوریتم‌های نام برده معرفی و نحوه‌ی استفاده از آنها تشریح می‌شود.


۲-۲ شبکه FCMAC

۲-۲ معرفی شبکه

شبکه FCMAC مدل فازی شده‌ی شبکه عصبی مصنوعی CMAC می‌باشد. این شبکه نرو-فازی، یک مدل از حافظه‌ی انجمنی خودکار از نوع بازخورد به جلو می‌باشد. شبکه FCMAC همانند یک جدول جستجو ست که قدرت تعمیم دهی محلی^{۱۵} را با استفاده از خصوصیت هم‌پوشانی^{۱۶} بردارهای ورودی بدست می‌آورد. در این تکنیک، فضای ورودی به بخش‌هایی تقسیم شده و هر بخش به یک ترم فازی کوانتیزه می‌شود.

این شبکه به منظور ذخیره اطلاعات و یادگیری به صورت محلی عمل می‌کند، بدین معنی که به منظور یادگیری یک ورودی فقط تعداد کمی از وزن‌های شبکه می‌بایست تغییر یابند. این خود باعث می‌شود که تعداد محاسبات لازم در هر قدم کاهش یافته و زمان مورد نیاز برای آموزش آن به شکل قابل توجهی پایین بیاید. همچنین در زمان استفاده از شبکه، هر ورودی موجب فعال شدن بخش کوچکی از شبکه شده و از تاثیر دیگر بخش‌های شبکه بر روی خروجی جلوگیری می‌شود. رفتار محلی در این شبکه موجب می‌شود تا بتواند با تعداد داده‌های آموزشی کم نیز کارایی قابل قبولی داشته باشد.

از ضعف‌های این شبکه می‌بایست به مصرف بالای حافظه‌ی آن اشاره کرد. حافظه مورد نیاز این شبکه به صورت مضربی از تعداد ترم‌های فازی ورودی‌ها، افزایش می‌یابد. همچنین افت عملکرد این شبکه با وجود ورودی‌های مشابه و یا با هم‌پوشانی زیاد، قابل ذکر است. کمبود این شبکه نیز در عدم امکان بخش‌بندی اولیه‌ی فضای ورودی می‌باشد، که می‌بایست این کمبود را توسط دیگر روش‌ها جبران نمود. در این تحقیق از الگوریتم DIC برای این منظور استفاده شده است.



شکل (۱): ساختار یک شبکه‌ی FCMAC با ترم‌های فازی شبه گوسی

به عنوان مثالی از روش انتخاب قوانین، دو مجموعه‌ی S زیر را در نظر بگیرید:

$$S_1 = \{1,2\}, \quad S_2 = \{4,6\}$$

با توجه به معادله (۳) و مجموعه‌های داده شده در بالا، تعداد قوانینی که انتخاب خواهند شد، ۴ عدد خواهد بود که عبارتند از:

$$Z_{[1]}^{[4]}, \quad Z_{[2]}^{[4]}, \quad Z_{[1]}^{[6]}, \quad Z_{[2]}^{[6]}$$

قدم سوم) تطابق مقدم‌ها: پس از فازی کردن ورودی‌ها در قدم اول و انتخاب قوانین در قدم دوم، وقت آن است که تک تک بُعدهای فازی شده از ورودی را به مقدم مربوطه از قانون انتخاب شده، تطابق دهیم و میزان برآورده شدن هر قانون را محاسبه کنیم. برای این عمل از روش یاگر استفاده شده است. در این روش، در ابتدای امر میزان عدم تطابق بین هر بعد ورودی و مقدم مربوطه از یک قانون محاسبه می‌شود. این محاسبه توسط تابع عدم تشابه محقق می‌شود (۴):

$$DM_{i,s_i} = (\overline{X_i} \cap (\neg A_{i,s_i})) \quad \forall i \in \{1, \dots, I\}, \forall s_i \in S_i \quad (4)$$

که در آن S_i مجموعه‌ای از اندیس‌های ترم‌های همسایه از بعد i ام می‌باشد که در قدم دوم انتخاب گشته‌اند. $A_{i,j}$ نیز ترم فازی i ام از بعد i ام ورودی است. با توجه به Singleton بودن ورودی $\overline{X_i}$ و مفروض شدن عملگر مینیمم به عنوان t -norm، عبارت فوق به صورت معادله‌ی (۵) ساده می‌شود:

$$DM_{i,s_i} = 1 - \mu_{A_{i,s_i}}(x_i) \quad (5)$$

روش در مقابل سیستم‌هایی است که به ازای هر ورودی می‌بایست به منظور تولید خروجی، تمام قوانین پایگاه دانش را فعال نمود.

با فرض در اختیار داشتن ورودی $\overline{X_i}$ ، به ازای هر بعد از ورودی، مجموعه‌ای از اندیس‌های ترم‌های فازی به شکل زیر تهیه می‌شود:

$$S_i = \begin{cases} \{1\}, & \text{if } c(A_{i,1}) > c(\overline{X_i}) \\ \{J_i\}, & \text{if } c(A_{i,J_i}) < c(\overline{X_i}) \\ \{j, j+1\}, & \text{if } \exists j: c(A_{i,j}) \leq c(\overline{X_i}) \leq c(A_{i,j+1}) \end{cases} \quad (2)$$

$$\forall i \in \{1, 2, \dots, I\}$$

منظور از $c(A)$ مرکز مجموعه‌ی فازی A بوده و مجموعه‌ی S_i شامل اندیس ترم‌های فازی بعد i امی می‌باشد که در مجاورت بعد i ام از ورودی قرار دارند. بدین صورت به تعداد I مجموعه‌ی S_i به وجود می‌آید که به کمک آنها لیست قوانین مربوط به ورودی $\overline{X_i}$ مشخص می‌گردد. تعداد قوانین فازی که توسط این مجموعه‌ها انتخاب خواهند شد برابر است با:

$$N = \prod_{i=1}^I |S_i| \quad (3)$$

در معادله‌ی (۳) $|S_i|$ نشان دهنده‌ی تعداد اعضای مجموعه می‌باشد. به عنوان مثال در شکل (۱) قانون $Z_{[3,3]}^{[3]}$ زمانی فعال می‌شود که به ازای ورودی‌ای، ترم‌های $A_{2,3}$ و $A_{1,3}$ به ترتیب از بعد یک و دو انتخاب شوند. در این صورت ترم خروجی O_2 ، خروجی شبکه خواهد بود.

۳-۲ آموزش شبکه

آموزش شبکه FCMAC در دو مرحله صورت می‌پذیرد. در مرحله اول، آموزش ساختاری، ترم‌های فازی ورودی و خروجی شکل می‌گیرند. این مرحله توسط الگوریتم DIC پیاده‌سازی شده است که در بخش ۳ به صورت کامل تشریح می‌شود.

با مشخص شدن ترم‌های فازی، مرحله‌ی دوم آموزش، آموزش پارامتری، آغاز می‌شود. در این مرحله می‌بایست مشخص شود که محتویات هر خانه‌ی حافظه‌ی FCMAC توسط کدام مقدار خروجی اشغال خواهد شد. و یا به عبارتی دیگر، تالی هر یک از قوانین فازی، کدام ترم خروجی است. این فرآیند با یکبار ارائه داده‌های آموزشی به شبکه محقق می‌شود. این حقیقت که آموزش شبکه FCMAC نیازی به تکرار ندارد، هزینه آموزش آن را بسیار کاهش می‌دهد.

به منظور تعیین خروجی هر قانون فازی، یک ضریب برای آن قانون به ازای هر ترم خروجی در نظر می‌گیریم. مقدار اولیه‌ی آن را صفر در نظر گرفته و به کمک معادله (۱۱)، با ارائه هر داده‌ی آموزشی، مقدار آن را به روز می‌کنیم:

$$w_{(n,k)}^{t+1} = w_{(n,k)}^t + (RF_n \times ACT(O_k)) \quad (11)$$

در معادله‌ی (۱۱)، $w_{(n,k)}^t$ ضریب ترم فازی خروجی k ام به ازای قانون n ام، در زمان مشاهده‌ی داده‌ی آموزشی t ام می‌باشد. همچنین ACT یک تابع فعال ساز بوده، که هدف آن انتخاب ترم فازی خروجی فعال شده در هنگام مشاهده‌ی داده‌ی آموزشی است. تعریف دقیق این تابع در معادله (۱۲) ارائه شده است:

$$ACT(O_k) = \begin{cases} \mu_{O_k}(y), & \text{if } \{k=1 \wedge c(O_k) > y\} \text{ OR} \\ & \{k=K \wedge c(O_k) < y\} \text{ OR} \\ & \{c(O_k) \leq y \leq c(O_{k+1})\} \\ 0, & \text{otherwise} \end{cases} \quad (12)$$

$c(O_k)$ معرف مرکز ترم فازی خروجی و y نشان دهنده‌ی خروجی هدف در داده‌ی آموزشی است. همچنین $\mu_{O_k}(y)$ میزان عضویت خروجی مورد نظر، در ترم فازی خروجی را نشان می‌دهد.

پس از محاسبه‌ی تمام $w_{(n,k)}$ ها به ازای داده‌های آموزشی در دست، می‌بایست خروجی هر قانون فازی را تعیین نمود. این امر با توجه به ضرایب محاسبه شده بدین صورت انجام می‌گیرد که از بین ترم‌های فازی خروجی، آن ترمی تالی یک قانون فازی است که ضریب بزرگتری نسبت به دیگر ترم‌ها داشته باشد. ضریب بزرگتر در یک ترم فازی خروجی به معنی مشاهده‌ی بیشترین تعداد خروجی از داده‌های آموزشی در حوزه‌ی آن ترم می‌باشد که معرف ارتباط بیشتر قانون مربوطه با ترم فازی خروجی است. بدین شکل تالی هر قانون فازی تعیین می‌گردد.

این قدم با بدست آوردن میزان عدم تشابه بین ورودی و مقدم قوانین انتخابی به پایان می‌رسد.

قدم چهارم برآورده شدن قوانین: در این قدم به ازای تمام قوانین انتخاب شده از قدم دوم، میزان عدم شباهت بعدهای ورودی و مقدم‌های قوانین، در دست است. روش محاسبه میزان برآورده شدن قوانین فازی، با توجه به روش یاگر، بدین صورت است (۶):

$$RF_n = \min_{i \in \{1, \dots, I\}} \{SM_{1,s_1}, SM_{2,s_2}, \dots, SM_{I,s_I}\} \quad (6)$$

در معادله‌ی (۶)، SM معرف تابع شباهت دو مجموعه‌ی فازی می‌باشد که برعکس تابع عدم میزان شباهت تعریف می‌شود. از این رو می‌توان معادله (۶) را به صورت (۷) ساده کرد.

$$RF_n = 1 - \max_{i \in \{1, \dots, I\}} \{1 - SM_{1,s_1}, 1 - SM_{2,s_2}, \dots, 1 - SM_{I,s_I}\} \\ = 1 - \min_{i \in \{1, \dots, I\}} \{\mu_{A_i, s_i}(x_i), \mu_{A_i, s_i}(x_i), \dots, \mu_{A_i, s_i}(x_i)\} \quad (7)$$

قدم پنجم) استنتاج نتیجه: در این شبکه، همانند تمام سیستم‌های فازی، هر قانون به یک ترم فازی از خروجی اشاره می‌رود. با فرض R_n به عنوان یک قانون فازی، O_n را به عنوان ترم فازی تالی قانون و μ_{O_n} را به عنوان تابع عضویت آن در نظر بگیرید. چنانچه قانون R_n به میزان RF_n برآورده شود، موجب تولید ترم فازی μ_{O_n} شده که تابع عضویت آن به شکل زیر تعریف می‌شود:

$$\mu_{O_n} = 1 - T(RF_n, 1 - \mu_{O_n}) \quad (8)$$

با در نظر گرفتن عملگر مینیمم به عنوان t -norm، معادله فوق به صورت (۹) ساده می‌شود:

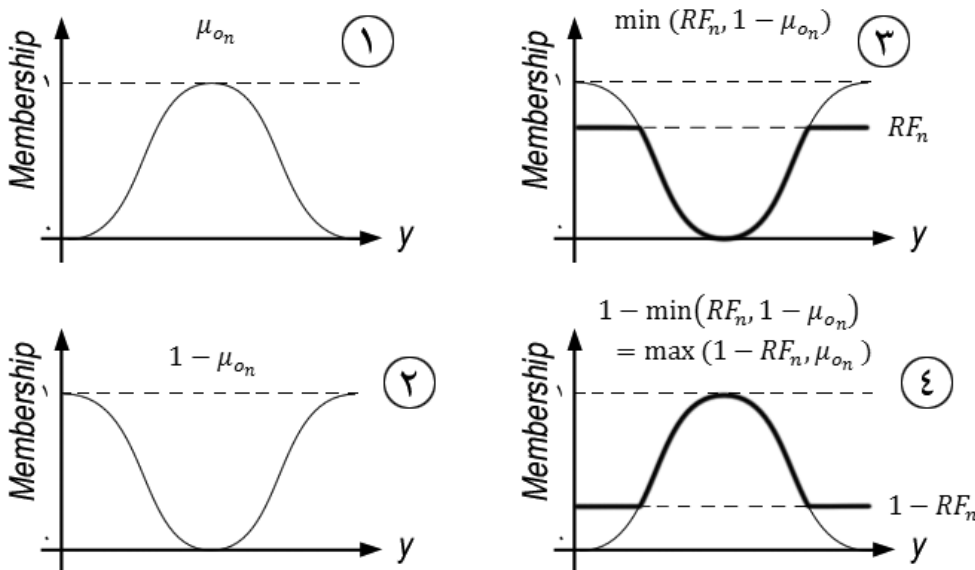
$$\mu_{O_n} = 1 - \min(RF_n, 1 - \mu_{O_n}) \quad (9)$$

تصاویر شکل (۲) مراحل فوق را به صورت ساده‌ای نقش می‌کنند.

قدم ششم) غیر فازی کردن^{۱۲} خروجی‌ها: تا اینجا موفق به تولید خروجی به صورت یک سری ترم فازی شده‌ایم. حال می‌بایست به کمک آنها، یک خروجی غیر فازی محاسبه نماییم. برای این منظور از یک روش "مرکز میانگین"^{۱۳} تغییر یافته استفاده می‌کنیم.

$$O = \frac{\sum_{n=1}^N RF_n \times \frac{c(\mu_{O_n})}{A(\mu_{O_n})}}{\sum_{n=1}^N RF_n \times \frac{1}{A(\mu_{O_n})}} \quad (10)$$

در معادله‌ی (۱۰) $c(\mu_{O_n})$ و $A(\mu_{O_n})$ به ترتیب معرف مرکز ترم فازی و مساحت زیر منحنی آن می‌باشند. دقت نمایید که با توجه به مثال ارائه شده در شکل (۱)، در بسیاری از موارد ترم‌های فازی خروجی تولید شده دارای مساحت زیر منحنی به سمت بی‌نهایت می‌باشند. برای حل این مشکل می‌بایست متغییر خروجی را محدود فرض نمود تا بتوان برای ترم‌های خروجی مساحت زیر منحنی محاسبه نمود.



شکل (۲): مراحل استنتاج نتیجه از ترم فازی خروجی انتخاب شده توسط روش یاگر

۱-۲-۳ ایجاد یک خوشه (ترم فازی)

زمانی یک ترم فازی جدید ایجاد می‌گردد که میزان عضویت نمونه‌ی ورودی جاری در بهترین ترم فازی موجود، از حد آستانه عضویت کمتر باشد. منظور از بهترین ترم فازی، ترمی است که داده ورودی بیشترین درجه‌ی عضویت را نسبت به دیگر ترم‌های فازی، در آن داشته باشد. در این زمان یک ترم فازی با مرکزیت داده ورودی و عرض اولیه (σ) ایجاد گشته و به لیست ترم‌های موجود اضافه می‌گردد.

۲-۲-۳ گسترش خوشه‌ها

چنانچه درجه عضویت داده ورودی در بهترین ترم فازی بزرگتر از آستانه‌ی هسته (KT) باشد، عضو آن ترم شمرده شده و هیچ تغییری در مجموعه‌ی ترم‌های موجود ایجاد نمی‌گردد. ولی چنانچه درجه عضویت داده ورودی بین آستانه عضویت (MT) و آستانه هسته باشد، موجب گسترش بهترین ترم شده و میزان گسترش آن از فرمول زیر محاسبه می‌شود:

$$\sigma_p^{t+1} = \sigma_p^t + \beta \cos(\theta_p^t) \times \sigma_p^t \quad (14)$$

در معادله فوق، σ_p^t عرض ترم فازی p م (بهترین ترم فازی) در زمان t بوده و β میزان رشد یک ترم را کنترل می‌کند. مقدار β در کل این تحقیق به صورت ثابت ۰.۵ در نظر گرفته شده است. همانطور که ملاحظه می‌فرمایید، پارامتر θ نیز میزان رشد یک ترم فازی را کنترل می‌کند. این پارامتر به صورتی طراحی شده که با گذشت زمان، میزان رشد یک ترم را کاسته و در نهایت موجب توقف رشد آن شود. نحوه‌ی تغییر این پارامتر به شکل زیر است:

$$\theta_p^{t+1} = \theta_p^t + STEP \quad (15)$$

۳- الگوریتم خوشه‌بندی DIC

۱-۳ معرفی الگوریتم

الگوریتم DIC یک الگوریتم خوشه‌بندی می‌باشد که خروجی آن ترم‌های فازی است. در حقیقت این الگوریتم یک فضا را توسط ترم‌های فازی کوانتیزه می‌کند. نکته اصلی در مورد این الگوریتم آن است که فقط بر روی داده‌های تک بعدی عمل می‌کند. بدین صورت می‌بایست برای مسائلی که دارای ورودی چند بعدی می‌باشند، به ازای هر بعد از ورودی، یک بار الگوریتم را به صورت مجزا، اجرا نمود.

۲-۳ نحوه‌ی عملکرد

هدف از این الگوریتم، همانگونه که به آن اشاره شد، مشخص کردن ترم‌های فازی متناسب با توزیع داده‌ها می‌باشد. این عمل توسط پنج پارامتر کنترل می‌شود: عرض اولیه‌ی ترم‌های فازی σ ، آستانه‌ی عضویت MT^{۱۵}، آستانه‌ی هسته KT^{۱۶}، β به عنوان پارامتر انعطاف‌پذیری^{۱۷} و TD^{۱۸} به عنوان پارامتر تمایل به گسترش. در این تحقیق از تابع شبه گوسی برای تعریف ترم‌های فازی استفاده شده است. با این حال می‌توان از انواع دیگر ترم‌های فازی همانند مثلثی و یا دوزنقه‌ای نیز استفاده نمود. یک ترم فازی شبه گوسی توسط یک مرکز (c) و یک عرض (σ) به صورت زیر تعریف می‌شود:

$$\mu(x_i) = e^{-\frac{1}{2} \left(\frac{x_i - c}{\sigma} \right)^2} \quad (13)$$

در ادامه نحوه‌ی ایجاد و گسترش ترم‌های فازی توسط الگوریتم DIC تشریح می‌شود.

فراهم است. کروموزم الگوریتم ژنتیک به صورت یک رشته‌ی بیتی، یک بایت به ازای هر پارامتر (۲ بیت برای عرض اولیه) پیاده‌سازی شده. همچنین برای هر بعد ورودی و خروجی یک کروموزم مجزا تعبیه گردید تا متناسب با نیاز هر بعد، تنظیمات متفاوتی ارائه شود.

۴- مطالعه موردی

در این تحقیق هدف، تخمین زدن میزان تراوایی یک چاه نفتی با استفاده از داده‌های چاه می‌باشد. برای این منظور، از داده‌های مخزن بنگستان میدان رگ سفید استفاده شده است. به علت کمبود تعداد رکوردهای مغزه در مخزن، فقط امکان استفاده از داده‌های یک چاه مهیا بود. این چاه دارای ۲۹۲ رکورد مغزه بوده که ۸۰٪ آن (معادل ۲۳۴ رکورد) به منظور آموزش سیستم و مابقی ۲۰٪ (معادل ۵۸ رکورد) برای آزمایش کارایی شبکه به کار گرفته شده است. این چاه دارای ۳ داده‌ی چاه به نام‌های DT (مدت زمان لازم برای عبور یک پالس صوتی از یک متر سازند)، SGR (Sum Gamma Ray - مجموع اشعه‌های گامای بدست آمده از رادیواکتیویته عناصر U و Th و K) و CNL (سنجش میزان نوترون سازند) می‌باشد. در مقابل این سه داده‌ی چاه، میزان تراوایی سازند وجود دارد که به عنوان خروجی مورد نظر از شبکه، مورد استفاده قرار گرفت.

با توجه به سه مرحله‌ی بودن آموزش (GA، DIC و FCMAC)، برای بدست آوردن بهترین ترکیب ممکن پارامترهای DIC توسط GA نیازمند بودیم که تعدادی از داده‌های آموزشی را به عنوان داده‌ی آزمایشی ترکیب آموزش داده شده به کار ببریم. ۱۸۷ عدد از داده‌های آموزشی را برای آموزش FCMAC و ۴۷ عدد از آنها را برای محاسبه‌ی بازده شبکه به خدمت گرفتیم. در نهایت با استفاده از ۵۸ رکورد اختصاص یافته برای آزمایش، سیستم نهایی را آزمودیم. بدین شکل، ۵۸ نمونه‌ی آزمایشی نهایی، زمانی به کار گرفته می‌شوند که آموزش به کمک الگوریتم ژنتیک خاتمه یافته و می‌خواهیم کارایی سیستم نهایی را محاسبه کنیم.

به منظور بالا بردن کارایی شبکه‌های مورد آزمایش، یک عمل پیش پردازشی، توسط فرمول (۱۷)، بر روی خروجی‌های واقعی اعمال شده است:

$$y_i = (y_i^R - \mu) / \sigma + 1 \quad (17)$$

در معادله‌ی (۱۷)، y_i^R نمونه‌ای نام از خروجی واقعی (بر حسب داری) بوده و y_i نمونه‌ی نرمالیزه شده خروجی واقعی (بدون بعد) می‌باشد. μ و σ به ترتیب میانگین و انحراف معیار خروجی‌های واقعی می‌باشند. با روش فوق خروجی، بعد خود را از دست داده و همچنین میانگین آن بر روی یک قرار می‌گیرد چرا که مقادیر نزدیک صفر می‌توانند محاسبه‌ی کارایی شبکه را با مشکل مواجه کنند.

مقدار اولیه θ_p^t صفر می‌باشد و به ازای هر دفعه گسترش ترم، به اندازه $STEP$ به آن افزوده شده تا به $(\frac{\pi}{2}) ۱.۵۷$ برسد. در این زمان با صفر کردن β ، از رشد ترم جلوگیری می‌کند. اندازه متغیر $STEP$ از پارامترهای الگوریتم DIC بوده و می‌تواند در بازه‌ی (۰، ۱.۵۷) باشد.

میزان گسترش یک ترم فازی توسط یک متغیر دیگر نیز کنترل می‌شود. متغیر TD در محاسبه عرض ترم فازی تاثیر مستقیم ندارد، بلکه فقط زمان توقف گسترش آن را کنترل می‌کند. مقدار اولیه این متغیر ۰.۵ بوده و در حین گسترش عرض یک ترم، کاهش می‌یابد، تا زمانی که صفر شود. در این زمان از افزایش عرض ترم جلوگیری خواهد شد. میزان کاهش متغیر TD از روش زیر محاسبه می‌شود:

$$TD_p^{t+1} = TD_p^t + (-0.5 - TD_p^t) \times (1 - \mu_p(x_i))^2 \quad (16)$$

همان گونه که ملاحظه می‌فرمایید، میزان کاهش TD یک ترم، متناسب با میزان عضویت داده ورودی در آن ترم می‌باشد.

۳-۲-۳ نحوه‌ی استفاده از الگوریتم

به منظور استفاده از این الگوریتم، هر بعد از داده‌های آموزشی در دست، به صورت جداگانه به الگوریتم DIC داده می‌شود. این داده‌ها به صورت تکراری مورد استفاده قرار می‌گیرد، تا زمانی که دیگر ترم فازی جدیدی ایجاد نگردد و همچنین هیچکدام از ترم‌های موجود تغییری نکنند. در این زمان الگوریتم خاتمه می‌یابد.

الگوریتم DIC دارای پارامترهایی است که عملکرد آن را کنترل می‌کند. از این پارامترها، پنج مورد مهم‌تر آنها برای کنترل این الگوریتم در این تحقیق به کار گرفته شده‌اند. در جدول زیر این پنج مورد و بازه‌ای که برای هر کدام در نظر گرفته شده است را ملاحظه می‌فرمایید:

جدول (۱): پارامترهای در نظر گرفته شده برای DIC و بازه‌ی آنها

نام پارامتر	بازه	
	از	تا
KT	۰.۵	۰.۹۹۸۰
MT	۰.۰۰۱۹۵	۰.۴۹۹۹
عرض اولیه	۰.۰۰۱	۱۰۰
β	۰.۴	۰.۶
STEP	۰.۱	۰.۵۹۸۰

در جدول (۱)، مقدار عرض اولیه‌ی ترم‌های فازی متناسب با مضرری از "بازه‌ی متغیر، تقسیم بر تعداد نمونه" تعریف شده است. بدین شکل تعداد و بازه نمونه‌های یک بعد، تاثیر مستقیمی در عرض اولیه‌ی ترم‌های فازی خواهند داشت.

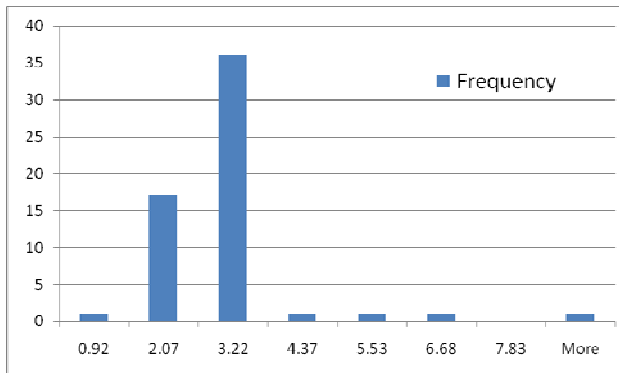
به منظور پیدا کردن بهترین ترکیب ممکن از پارامترهای الگوریتم DIC از الگوریتم ژنتیک استفاده شده است. از آنجایی که زمان مورد نیاز برای آموزش و آزمایش شبکه FCMAC و همچنین DIC بسیار کم می‌باشد، امکان اجرای چندین باره‌ی آنها در یک زمان قابل قبول

در جدول (۲) می‌توانید نحوه‌ی تنظیم پارامترهای DIC را توسط الگوریتم ژنتیک ملاحظه نمایید:

جدول (۲): پارامترهای الگوریتم DIC بدست آمده توسط GA

نام پارامتر	DT	SGR	CNL	تراوایی
KT	۰.۰۶۷۱۸	۰.۰۵۴۱	۰.۰۵۱۹۵	۰.۰۵۵۴۶
MT	۰.۰۰۴۲۹	۰.۰۰۲۱۴	۰.۰۰۹۱۷	۰.۰۰۸
عرض اولیه	۱.۰۳۶۵۵	۱.۰۰۵۵۳	۷.۰۹۸۸۷	۰.۰۶۲۰۴
β	۰.۰۴۱۲۵	۰.۰۴۱۰۹	۰.۰۴۲۱۹	۰.۰۴۱۳۳
STEP	۰.۰۱۲۷۳	۰.۰۱۵۴۶	۰.۰۱۷۸۱	۰.۰۱۲۳۴

در شکل (۳) نمودار نحوه‌ی توزیع پراکنندگی خطا ارائه شده است. همانطور که ملاحظه می‌فرمایید، اکثر خطاها در حدود ۳ داریسی بوده، این در حالی است که بازه‌ی داریسی در این تحقیق از صفر تا ۱۵۰ می‌باشد.



شکل (۳): نحوه‌ی توزیع خطای شبکه‌ی FCMAC

برای محاسبه‌ی توزیع پراکنندگی خطا، معکوس تابع نرمالیزه را بر خروجی شبکه اعمال کرده تا به داریسی تبدیل شود. سپس قدر مطلق اختلاف مقدار داریسی واقعی و خروجی شبکه را محاسبه نموده که هیستوگرام آن در شکل (۳) رسم شده است.

۶- نتیجه‌گیری

در این مقاله سعی شده است تا از تکنیک‌های به روز هوش مصنوعی، شبکه‌ی نرو-فازی FCMAC، در راستای حل مسئله‌ی تخمین میزان تراوایی در مخازن هیدروکربنی، استفاده شود. نتایج بدست آمده نشان می‌دهد که این روش نسبت به روش‌های دیگر از قابلیت بالاتری برای تخمین میزان تراوایی برخوردار است. این در حالی است که به دلیل کم هزینه بودن این روش در مقابل روش پرهزینه تحلیل مغزه‌ها در آزمایشگاه، می‌تواند راه‌حل مناسبی برای پیش‌بینی تراوایی مخازن هیدروکربنی باشد.

از دیگر کاربردهای این روش تخمین میزان تراوایی مخازن هیدروکربنی‌ای است، که برای آنها هیچ نمونه‌ی مغزه‌ای در دست نمی‌باشد. در این شرایط، در صورت مهیا بودن اطلاعات یک چاه مشابه،

۵- خروجی شبکه

شبکه‌ی FCMAC با مشخصات فوق، آموزش داده شد و به منظور مقایسه، سه شبکه دیگر از نوع ^۱MLP، ^۲RBF و ^۳ANFIS نیز با داده‌های آموزشی و آزمایشی یکسان مورد تحلیل قرار گرفتند. به منظور مقایسه این سه روش از تابع خطای ارائه شده در معادله (۱۸) استفاده شده است. بازه‌ی (کارایی) هر کدام از روش‌های فوق به شکل زیر محاسبه شده است:

- MLP: ۸۲,۴٪
- RBF: ۴۵,۲۷۳٪
- ANFIS: ۴۲,۸۲۵٪
- FCMAC: ۹۸,۹۱٪

$$error = \frac{\sum_{i=1}^N (y_i - o_i)^2}{\sum_{i=1}^N (y_i)^2} \quad (18)$$

در معادله‌ی فوق y_i خروجی مورد نظر، o_i خروجی تولیدی شبکه و N تعداد نمونه‌های آزمایشی می‌باشد. دلیل تعریف تابع خطا به صورت فوق، حقیقی بودن خروجی است. با تعریف تابع خطا به شکل معادله (۱۸)، امکان آن وجود دارد که میزان خطا بیش از ۱۰۰٪ بشود که در این صورت کارایی سیستم منفی خواهد بود. در مورد دو شبکه RBF و ANFIS نیز همین حالت پیش آمده است. هر دو شبکه‌ی مذکور دارای کارایی منفی می‌باشند.

در مورد دو شبکه‌ی RBF و ANFIS می‌بایست ذکر کرد که کارایی این دو شبکه بر روی داده‌های آموزشی در حدود ۱۰۰٪ می‌باشد، ولی کارایی آنها بر روی داده‌های آزمایشی بسیار پایین بوده که نشان دهنده‌ی ضعف قدرت تعمیم‌دهی آنهاست. در دفاع از دو شبکه‌ی مذکور می‌بایست اذعان کرد که امکان آن وجود دارد با تنظیم دقیق پارامترهای این دو شبکه، کارایی آنها نیز تا حد قابل قبولی افزایش یابد. ولی به دلیل زمانگیر بودن آموزش این دو شبکه، به خصوص شبکه‌ی نرو-فازی ANFIS، امکان آزمایش آنها با انواع مختلف پارامتر، در یک زمان معقول، وجود ندارد.

در نهایت، پس از تکمیل فاز آموزش FCMAC، تعداد ترم‌های فازی مورد استفاده برای هر بعد ورودی و خروجی از قرار زیر است:

- DT: ۷ ترم فازی
- SGR: ۳ ترم فازی
- CNL: ۶ ترم فازی
- تراوایی: ۴ ترم فازی

Fuzzification	۱۱
Crisp	۱۲
Defuzzification	۱۲
Center Of Average	۱۴
Membership Threshold	۱۵
Kernel Threshold	۱۶
Plasticity	۱۷
Tendency	۱۸
Multi Layer Perceptron	۱۹
Radial Basis Function	۲۰
Adaptive-Network-Based Fuzzy Inference System	۲۱
Generalization	۲۲
Generic Self-Organizing Fuzzy Neural Network	۲۳
Genetic Programming	۲۴

می توان با آموزش یک شبکه به کمک داده های آن، میزان تراوایی چاه بدون مغزه را نیز تخمین زد.

در این روش، در صورت کافی بودن داده های آموزشی می توان تخمینی پیوسته از میزان تراوایی برای کل عمق چاه بدست آورد.

به منظور گسترش این تحقیق می توان از دیگر روش های نرو-فازی مانند شبکه های $^{**}GenSoFNN$ [9] و همچنین تکنیک $^{**}GP$ استفاده نمود. با در دست داشتن اطلاعات غنی از چندین چاه نفت، می توان بر روی انواع داده های چاه و ارتباط آنها با میزان تراوایی سازند، به کمک تکنیک GP تحقیقاتی انجام داد. با این عمل میزان و نحوه ی ارتباط هر کدام از داده های چاه با میزان تراوایی مشخص خواهد شد.

مراجع

- [1] Wong, Patrick M., Jang, M., Cho, S., Gedeon, Tom D., *Multiple Permeability Prediction Using an Observational Learning Algorithm*, Computers & Geosciences 26, pp. 907-913, 2000.
- [2] Wong, K.W., Wong, P.M., Gedeon, T.D., Fung, C.C., *A State-of-The-Art Review of Fuzzy Logic for Reservoir Evaluation*, APPEA Journal, pp. 587-593, 2003.
- [3] Cuddy, S.J., *Litho-facies and Permeability Prediction from Electrical Logs Using Fuzzy Logic*, SPE Reservoir Evaluation and Engineering, 3(4), pp. 31-24, 2000.
- [4] J. Sim, W. L. Tung, C. Quek, *FCMAC-Yager: A Novel Yager-Inference-Scheme-Based Fuzzy CMAC*, IEEE Transactions on Neural Networks, VOL. 17, NO. 6, pp. 1394-1410, 2006.
- [5] M. N. Nguyen, D. Shi, C. Quek, *Self-Organizing Gaussian Fuzzy CMAC with Truth Value Restriction*, IEEE ICITA, Sydney, Australia, pp. 185-190, 2005.
- [6] M. N. Nguyen, D. Shi, C. Quek, *FCMAC-BYY: Fuzzy CMAC Using Bayesian Ying-Yang Learning*, IEEE Trans. Systems, Man, Cybernetics B 36 (5), pp. 1180-1190, 2006.
- [7] Z. Y. Guo, C. Quek, D. L. Maskell, *FCMAC-AARS: A Novel FNN Architecture for Stock Market Prediction and Trading*, IEEE Congress On Evolutionary Computation, pp. 2375-2381, 2006.
- [8] W. L. Tung, C. Quek, *DIC: A Novel Discrete Incremental Clustering Technique for the Derivation of Fuzzy Membership Functions*, 7th Pacific Rim Int. Conf. Artif. Intell., Tokyo, Japan, pp. 178-187, 2002.
- [9] Tung, W.L., Quek, C., *GenSoFNN: A Genetic Self-Organizing Fuzzy Neural Network*, IEEE Transactions on Neural Networks, 13(5), pp. 1075-1086, 2002.

زیر نویس ها

Permeability	۱
Darcy	۲
Formation	۳
Core	۴
Well Log	۵
Clustering	۶
Genetic Algorithm	۷
Localized Generalization	۸
Overlapping	۹
Gaussian	۱۰