

# تعیین و پیش‌بینی رخساره‌های منفذی براساس تلفیقی از داده‌های تزریق جیوه، پتروفیزیکی و پتروگرافی با استفاده از ترکیب شبکه‌های عصبی خودسازمان‌ده و ماشین بردار پشتیبان

ابراهیم سفیداری<sup>۱\*</sup>، عبدالحسین امینی<sup>۱</sup> و علی دشتی<sup>۱</sup>

۱- دانشکده زمین‌شناسی، پردیس علوم، دانشگاه تهران، تهران، ایران

۲- گروه زمین‌شناسی نفت، پژوهشکده علوم کاربردی جهاد دانشگاهی، واحد دانشگاه شهید بهشتی، تهران، ایران

تاریخ دریافت: ۹۴/۱/۲۴ تاریخ پذیرش: ۹۴/۶/۱۷

## چکیده

شبکه منفذی کنترل‌کننده رفتار سیالات در سنگ مخزن است. در مخازن کربناته به دلیل عدم تبعیت خصوصیات جریان سیال از بافت رسوبی اولیه، ویژگی‌های شبکه منفذی باید مستقیماً در فرآیند تعیین رخساره استفاده شوند تا بتوان شرایط واقعی مخزن را تحلیل کرد. در این مطالعه با استفاده از ترکیب مطالعات پتروگرافی، پتروفیزیکی و مهندسی مخزن، رخساره‌های منفذی و سنگی در سازندهای کنگان و دالان در میدان گازی پارس جنوبی مطالعه شده‌اند. بر این اساس پنج رخساره منفذی با استفاده از روش شبکه‌های عصبی خودسازمان‌ده خصوصیات پتروفیزیکی، زمین‌شناسی و مخزنی منحصربه‌فردی دارند. براساس خصوصیات این رخساره‌های منفذی یک روند مشخص کاهش کیفیت مخزنی از رخساره یک به سمت رخساره پنج مشاهده شد. در نهایت برای ارتباط دادن رخساره‌های معرفی شده و نمودارهای پتروفیزیکی از روش ماشین بردار پشتیبان استفاده شد که با استفاده از روش میانگین مربعات خطا از نمودارهای چانه‌گاری، رخساره‌های معرفی شده را با دقت ۷۸٪ پیش‌بینی کرد.

**کلمات کلیدی:** رخساره منفذی، شبکه عصبی خودسازمان‌ده، ماشین بردار پشتیبان، میدان گازی پارس جنوبی، سازندهای دالان و کنگان.

## مقدمه

به گروه‌هایی با کیفیت مخزنی متفاوت تعیین می‌شود. روش‌های متفاوت تعیین رخساره در سنگ مخزن دیدگاهی متفاوت به سنگ مخزن دارند. رخساره‌های سنگی<sup>۱</sup> براساس بافت رسوبی، ویژگی‌های ذرات تشکیل‌دهنده سنگ، اندازه آنها و ساختارهای رسوبی تعیین می‌شوند [۱ و ۲].


مدل‌سازی مخزن مشتمل بر دو بخش زمین‌شناسی و مخزنی است که در هر دوی آنها تعیین رخساره‌های مخزنی و جریانی اهمیت ویژه دارد. رخساره در مطالعات مخزنی با هدف طبقه‌بندی سنگ مخزن

و دالان با سن پرمو- تریاس و لیتولوژی غالب کربناته در میدان گازی پارس جنوبی استفاده شده است (شکل ۱). داده‌های جمع‌آوری شده شامل ۳۲۰۰ داده تخلخل و تراوایی مغزه از سه چاه SP-A، SP-B و SP-C، اطلاعات کامل نگارهای چاه‌پیمایی سه چاه و ۱۰۹ داده تزریق جیوه هستند. در مرحله اول مجموعه‌ای از مشخصه‌های خاص، که در ادامه درباره آنها بحث خواهد شد، از داده‌های تزریق جیوه و مجموعه‌ای از مشخصه‌های پتروفیزیکی دیگر نیز با استفاده از داده‌های تخلخل و تراوایی مغزه استخراج شدند. مشخصه‌های استخراج شده از داده‌های تزریق جیوه به همراه پارامترهای استخراج شده از داده‌های تخلخل و تراوایی مغزه، برای خوشه‌بندی و مشخص کردن رخساره‌های منفذی، به‌عنوان ورودی شبکه عصبی خودسازمان‌ده<sup>۱</sup> استفاده شدند. در مرحله آخر برای ارتباط دادن رخساره‌های معرفی شده و نمودارهای پتروفیزیکی از روش ماشین بردار پشتیبان<sup>۲</sup> استفاده شد که در ادامه هر یک از این مراحل به تفصیل بررسی خواهد شد.

رخساره‌های الکتریکی براساس نگارهای چاه‌پیمایی که به ویژگی‌های فیزیکی سنگ حساس هستند انتخاب می‌شوند [۳-۶]. همچنین رخساره‌های منفذی براساس مشخصه‌های استخراج شده از داده‌های تزریق جیوه مانند شبکه گلوگاه‌ها، هندسه منفذی و به‌طور کلی خصوصیات شبکه تخلخل و تراوایی در سنگ مخزن تعیین شده‌اند [۷-۹]. در سال‌های اخیر کارهای زیادی نیز برای ارتباط دادن رخساره‌های سنگی و رخساره‌های الکتریکی و درک هر چه بهتر مخزن انجام شده است [۱۰-۱۳]. این مطالعه برای تعیین رخساره‌های منفذی در نمونه‌های حاصل از سه چاه از دو سازند کربناته دالان و کنگان به سن پرمو- تریاس در میدان گازی پارس جنوبی انجام گردیده است.

روش کار

در این مطالعه برای تعیین رخساره‌های منفذی از اطلاعات حاصل از سه چاه از سازندهای کنگان



شکل ۱ موقعیت میدان گازی پارس جنوبی و چینه‌شناسی سازندهای بررسی شده در این مطالعه [۴].

1. Self-Organizing Map(SOM)  
2. Support Vector Machine(SVM)

برای محاسبه این مشخصه گسترش یافته‌اند که در این مطالعه، از معادله‌ای استفاده شده که میانگین مقدار فشار را در اشباع‌شدگی‌های ۱۶، ۵۰ و ۸۴٪ به کار می‌گیرد. این مشخصه تغییرات دامنه اندازه گلوگاه‌ها را بررسی می‌کند و افزایش آن به معنی افزایش کیفیت شبکه گلوگاه‌ها و برعکس است.

شاخص کیفیت مخزنی<sup>۵</sup> و شاخص زون جریان<sup>۶</sup>؛ مبنای اصلی واحدهای جریانی هیدرولیکی براساس رابطه تخلخل و تراوایی مغزه است. این روش بر این فرض استوار است که رابطه حفرات را می‌توان با مجموعه‌ای از لوله‌های مویین نشان داد [۱۸ و ۱۹]. رابطه ۳ با استفاده از ترکیب قوانین داریسی<sup>۷</sup> و پویزویله<sup>۸</sup> برای لوله‌های استوانه‌ای مستقیم استنتاج شده و گویای نحوه ارتباط تراوایی با مشخصات هندسی حفرات خالی است:

$$K = \frac{\phi_e r^2}{8\tau^2} = \left[ \left( \frac{\phi_e}{2\tau^2} \right) \times \left( \frac{r}{2} \right)^2 \right] = \frac{\phi_e r m h^2}{2\tau^2} \quad (3)$$

K، تراوایی برحسب میکرومتر مربع؛  $\phi_e$ ، تخلخل موثر؛  $\tau$ ، فاکتور پیچاپیچی؛  $\tau_{mh}$ ، شعاع هیدرولیکی میانگین؛  $\tau$ ، شعاع هیدرولیکی و عدد ۸ مربوط به لوله‌های استوانه‌ای است. حال می‌توان شعاع هیدرولیکی میانگین را مرتبط با هر واحد حجم ذره<sup>۹</sup> و تخلخل مفید دانست و رابطه زیر را ارائه داد:

$$Sgv = \frac{2}{r} \times \frac{\phi_e}{1-\phi_e} = \frac{1}{r_{mh}^2} \times \frac{\phi_e}{1-\phi_e} \quad (4)$$

با ترکیب روابط ۳ و ۴ رابطه معروف به معادله کوزنی-کارمن به دست می‌آید:

$$K = \frac{\phi_e^3}{(1-\phi_e)^2} \times \left[ \frac{1}{F_s \tau^2 Sgv^2} \right] \quad (5)$$

$F_s$ ، فاکتور شکل است.  $F_s \tau^2$  به عنوان ثابت کوزنی شناخته و معمولاً ۵ تا ۱۰۰ (برای توده سنگی استحکام‌نیافته حدود ۵) در نظر گرفته می‌شود [۲۰].

## مشخصه‌های استخراج‌شده از منحنی‌های تزریق جیوه و داده‌های تخلخل و تراوایی

شعاع گلوگاه<sup>۱</sup>: با استفاده از رابطه زیر شعاع گلوگاه‌ها در لوله‌های مویینه به عنوان شعاع گلوگاه‌های مرتبط‌کننده منافذ معرفی شد [۱۴]:

$$r_c = \frac{2\sigma \cdot \cos \theta}{P_c} \quad (1)$$

$\sigma$ ، کشش سطحی جیوه براساس dyn/cm؛  $\theta$ ، زاویه تشکیل‌شده بین دیواره منافذ و جیوه و  $P_c$ ، فشار مویینه برحسب dyn/cm<sup>2</sup> است. شعاع گلوگاه‌ها در ۱۵، ۳۵، ۵۰ و ۸۴٪ اشباع جیوه محاسبه و از ۳۵، ۵۰ و ۸۴٪ اشباع جیوه برای طبقه‌بندی رخساره‌ها استفاده شده که دلیل انتخاب آنها رابطه بهتر با تراوایی بوده است.

ارتفاع از سطح آب آزاد<sup>۲</sup>: ستون هیدروکربن در مخازن با رابطه زیر محاسبه می‌شود:

$$H = \frac{0.102 P_c}{(\Delta\rho)} \quad (2)$$

H، برحسب m؛  $\Delta\rho$ ، اختلاف چگالی آب و هیدروکربن (g/cm<sup>3</sup>) موردنظر در شرایط آزمایشگاه و  $P_c$ ، نیز فشار مویینه معادل در سیستم هیدروکربن-آب است. براساس این معادله ارتفاع از سطح آب آزاد با فشار مویینه ارتباط مستقیم دارد.

پارامتر سوانسون<sup>۳</sup>: سوانسون با انجام آزمایش‌هایی نقطه‌ای را در منحنی تزریق جیوه، به عنوان نماینده اشباع در بخشی از شبکه گلوگاه‌ها که به شکلی موثر به هم پیوسته‌اند و جریان سیالات در سنگ بیش‌تر برعهده آنهاست، معرفی کرد [۱۵] که براساس تقسیم بیش‌ترین مقدار اشباع‌شدگی بر فشار تزریق معادل محاسبه شده است [۱۶]. این نقطه در نمودار محل تبدیل شبکه گلوگاه‌های به هم پیوسته و بزرگ‌تر را به گلوگاه‌های کوچک‌تر نشان می‌دهد که عامل به دام افتادن سیالات هستند.

مشخصه جورشدگی گلوگاه‌ها<sup>۴</sup>: این مشخصه برای اندازه‌گیری هندسه گلوگاه‌ها و جورشدگی آنها در نمونه‌های سنگ معرفی شد [۱۷] که از جذر فشار در ربع سوم منحنی تزریق جیوه به فشار در ربع اول آن محاسبه می‌شود. معادله‌های دیگری نیز

1. Pore Throat Radius( $r_c$ )

2. Height Above Free Water Level(HAFWL)

3. Swanson's Parameter (Sp)

4. Pore Throat Sorting (PTS)

5. Reservoir Quality Index

6. Flow Zone Indicator


7. Darcy's Law

8. Poiseuille's Law

9. Special Grain Volume(Sgv)

گروه‌های یک شبکه یک‌بعدی، دوبعدی یا بیش‌تر قرار گرفته‌اند. واحدها در یک فرآیند یادگیری رقابتی نسبت به الگوهای ورودی منظم شده‌اند و محل واحدها در شبکه به گونه‌ای نظم یافته که برای ویژگی‌های ورودی، یک دستگاه مختصات معنی‌دار روی شبکه ایجاد شود. بر این اساس یک نقشه خودسازمان‌ده یک نقشه توپوگرافیک از الگوهای ورودی را تشکیل می‌دهد که در آن محل قرار گرفتن واحدها متناظر با ویژگی‌های ذاتی الگوهای ورودی است [۲۶]. یادگیری رقابتی که در این گونه شبکه‌ها به کار می‌رود به گونه‌ای است که در هر قدم یادگیری، واحدها برای فعال شدن با یکدیگر به رقابت می‌پردازند و در پایان یک مرحله رقابت تنها یک واحد برنده می‌شود که وزن‌های آن نسبت به وزن‌های دیگر واحدها به‌شکلی متفاوت تغییر داده می‌شود. این نوع یادگیری را یادگیری بی‌نظارت می‌نامند [۲۷]. این شبکه‌ها خود شامل نورون‌های سازمان‌یافته در یک شبکه منظم هستند. هر نورون با نورون‌های مجاور با رابطه همسایگی، که توپولوژی یا نقشه‌های ساختمانی کوهنن<sup>۱</sup> نامیده می‌شود، در ارتباط است (شکل ۲).

ماشین بردار پشتیبان: ماشین بردار پشتیبان یکی از انواع روش‌های یادگیری ماشین است. ایده اصلی در این طبقه‌بندی یافتن صفحه‌ای است که داده‌های ورودی متعلق به کلاس‌های متفاوت را در فضای n بعدی از هم مجزا کند.



شکل ۲ الگوی شبکه عصبی خودسازمان‌ده متشکل از لایه‌های ورودی و رقابتی [۲۸].

عبارت  $F_s \tau^2 S_{gv}^2$  هم تابعی از ویژگی‌های زمین‌شناسی فضای متخلخل است و با تغییر هندسه حفرات تغییر می‌کند. آموفیل و همکارانش طرفین معادله ۵ را بر تخلخل موثر تقسیم کردند و از طرفین جذر گرفتند تا رابطه زیر به دست آید [۱۸]:

$$0.0314 \sqrt{\frac{K}{\phi_e}} = \frac{\phi_e}{1 - \phi_e} \times \frac{1}{\sqrt{F_s \tau S_{gv}}} \quad (6)$$

در این رابطه ضریب  $0.0314$  برای تبدیل تراوایی از میکرومتر مربع به میلی‌داری استفاده شده است. حال اندیس کیفیت مخزنی از رابطه ۷ محاسبه می‌شود:

$$RQI = 0.0314 \sqrt{\frac{K}{\phi_e}} \quad (7)$$

شاخص منطقه‌ای جریان، که گویای هر واحد جریان هیدرولیکی است، با تقسیم اندیس کیفیت مخزنی بر مقادیر تخلخل نرمال‌شده (۴) PHIZ (رابطه زیر) محاسبه می‌شود [۲۱ و ۲۲]:

$$FZI = \frac{RQI}{\epsilon} \quad (8)$$

#### خوشه‌سازی و کلاس‌بندی

خوشه‌سازی روشی برای ارزیابی شباهت و عدم‌شباهت داده‌هاست. خوشه‌سازی داده‌های عددی پایه بسیاری از روش‌های طبقه‌بندی و الگوریتم‌های مدل‌سازی است، زیرا با شناسایی گروه‌های طبیعی موجود در یک مجموعه عظیم داده‌ها الگویی دقیق از رفتار سیستم در حال مطالعه ارائه می‌دهد. از طرف دیگر کلاس‌بندی، پیش‌بینی کلاس‌های از قبل مشخص‌شده در داده‌ها با استفاده از روش‌های مختلف است؛ بنابراین اختلاف خوشه‌سازی با کلاس‌بندی در مشخص بودن اولیه کلاس‌ها در روش کلاس‌بندی است.

شبکه عصبی خودسازمان‌ده: شبکه‌های عصبی خودسازمان‌ده از مهم‌ترین مدل‌های شبکه عصبی هستند که اخیراً در زمینه‌های زیادی مانند آنالیز تصاویر [۲۳]، تعیین جهت حرکت بادها [۲۴] و تفسیر امواج لرزه‌ای [۲۵] استفاده شده‌اند. در شبکه خودسازمان‌ده، از روش یادگیری رقابتی برای آموزش استفاده شده است و واحدهای پردازشگر در

در واقع در حال حاضر دو روی‌کرد برای مسئله ماشین بردار پشتیبان چندکلاسی وجود دارند: ۱- براساس ساختن و ترکیب طبقه‌بندهای دو دوتایی و ۲- با ملاحظه مستقیم تمام داده‌ها در یک فرمول بهینه‌سازی [۳۱].

### نتایج و بحث

#### استخراج مشخصه‌های حاصل از تزریق جیوه


داده‌های تزریق جیوه و تخلخل - تراوایی برای ۱۰۹ نمونه از سه چاه SP-A، SP-B و SP-C در شکل ۳ نشان داده شده‌اند. مشخصه‌های توضیح داده‌شده در بالا، مانند شعاع گلوگاه‌ها در اشباع‌شدگی‌های مختلف، مشخصه سوانسون، مشخصه جورشدگی گلوگاه‌ها، ارتفاع بالای سطح آب آزاد، اندیس کیفیت مخزنی و شاخص منطقه‌ای جریان، برای ۱۰۹ نمونه داده تزریق جیوه استخراج شدند. انطباق مشخصه‌های استخراج‌شده با تراوایی نمونه‌ها در شکل‌های ۴ و ۵ نشان داده شده است. همان‌طور که در این دو شکل دیده می‌شود، اندیس کیفیت مخزنی بیش‌ترین انطباق را با تراوایی نشان می‌دهد و مشخصه شعاع گلوگاه‌های تخلخل در ۳۵ و ۵۰ درصد اشباع جیوه، مقدار جورشدگی گلوگاه‌ها و ارتفاع بالای آب آزاد در ۵۰٪ اشباع نیز انطباقی تقریباً مناسب (بیش از ۵۰٪) را با مقدار تراوایی نشان می‌دهند. از طرف دیگر تراوایی و تخلخل نمونه‌ها ارتباطی مشخص ندارند که نشان‌دهنده تاثیر فرآیندهای دیاژنزی ثانویه و پیچیده شدن ارتباط تخلخل با تراوایی است. در مرحله بعد از این مشخصه‌های استخراج‌شده به‌عنوان ورودی برای خوشه‌سازی رخساره‌های منفذی استفاده می‌شود.

#### تعیین رخساره‌های منفذی

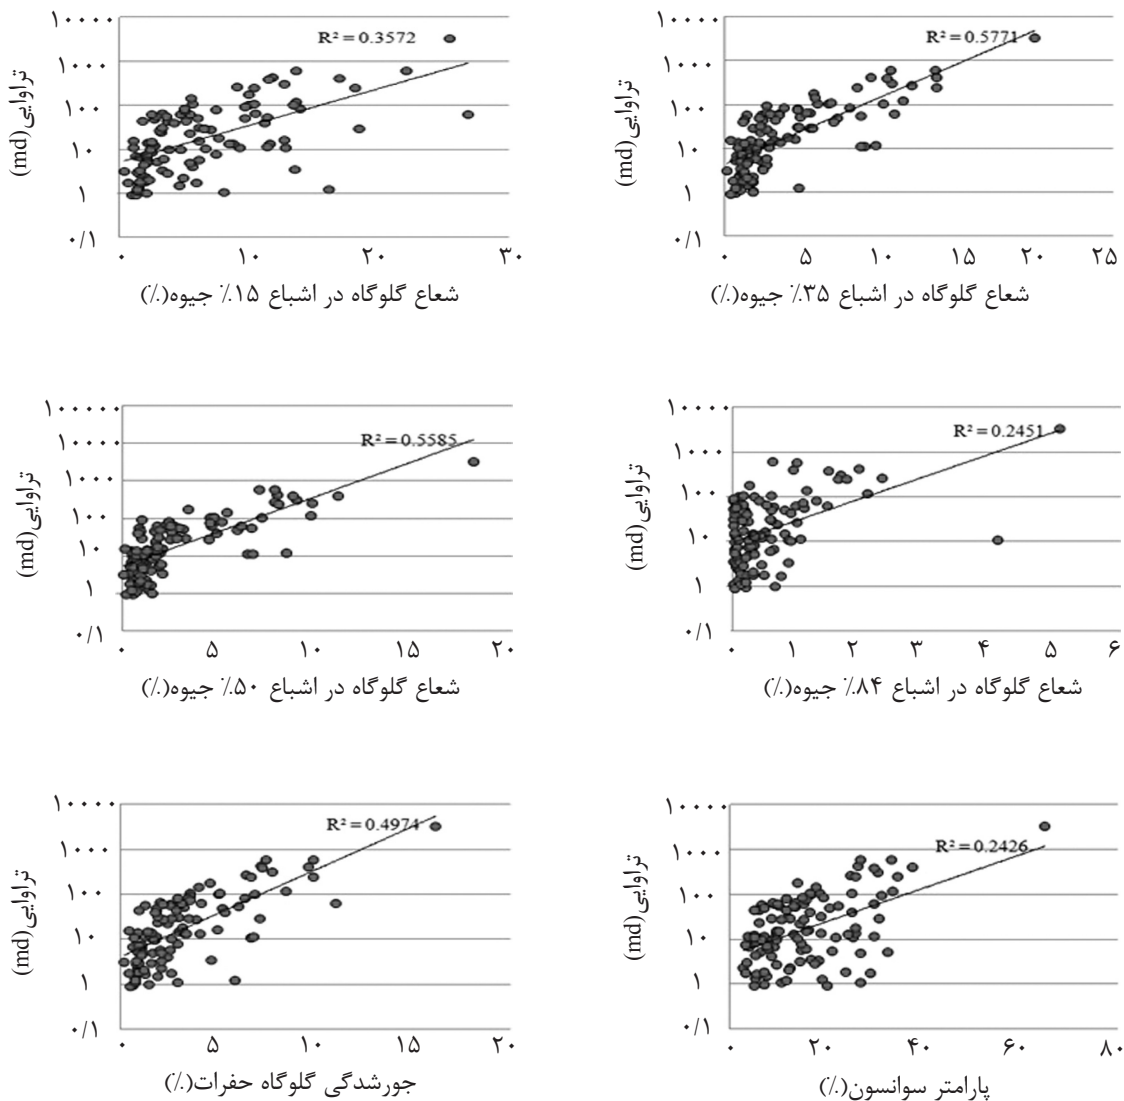
در یک ارزیابی خوشه‌ای اولین مرحله انتخاب متغیرهای است که قرار است با سنجش فاصله آنها در ابعاد مختلف (ابعاد داده‌ها برابر با تعداد متغیرها) خوشه‌سازی شود.

ماشین بردار پشتیبان، با معرفی یک فضای ویژگی منتج از به‌کارگیری توابع کرنل، داده‌های ورودی را به فضای با ابعاد بالاتر می‌برد و قابلیت جداپذیری داده‌هایی را که در حالت عادی به‌صورت خطی جدایی‌پذیر نیستند افزایش می‌دهد. نوعاً این کار، یعنی بردن بردارهای ورودی به فضایی دارای ابعاد بالاتر، با افزایش پیچیدگی محاسباتی و بروز مشکل هم‌پوشانی همراه است؛ اما زیرکی خاص ماشین بردار پشتیبان این است که مستقیماً با فضای جدید دارای ابعاد بالاتر سروکار ندارد (در این فضا فقط به فرمول‌های مربوط به ضرب نقطه‌ای بردارها نیاز است).

تئوری ماشین بردار پشتیبان: ایده پایه به کار بردن ماشین بردار پشتیبان برای طبقه‌بندی را می‌توان به‌صورت زیر خلاصه کرد: ابتدا، بردارهای ورودی به یک فضای ویژگی (که ممکن است بعدی بالاتر داشته باشد) نگاشته می‌شوند. در فضای ویژگی با توجه به انتخاب تابع کرنل، بردارهای ورودی یا به‌طور خطی و یا غیرخطی از یک‌دیگر جدا می‌شوند. سپس در فضای ویژگی از مرحله نخست، یک طبقه خطی‌بند بهینه‌شده جستجو می‌شود. به‌عبارت دیگر، یک ابرصفحه ساخته می‌شود که دو کلاس را از یک‌دیگر جدا می‌کند (این مطلب می‌تواند برای چندین کلاس نیز گسترش یابد). ماشین‌های بردار پشتیبان همیشه به‌دنبال یک حل بهینه‌شده سراسری می‌گردند و از بیش‌پوشش داده‌ها اجتناب می‌کنند؛ بنابراین می‌توانند با تعداد بزرگی از ویژگی‌ها رفتار کنند. یک توصیف کامل از ماشین‌های بردار پشتیبان در شناسایی الگو را می‌توان در مراجع ۲۹ و ۳۰ دید. همان‌طور که در بالا گفته شد، ماشین بردار پشتیبانی یک طبقه‌بند دو دوتایی است در حالی که بسیاری از مسائل طبقه‌بندی شامل چند کلاس هستند و بنابراین باید به‌نحوی آن را توسعه داد. چندین روش برای این منظور پیشنهاد شده‌اند که عموماً در آنها طبقه‌بندی چندکلاسی با ترکیب چندین طبقه‌کننده دودویی ساخته می‌شود.

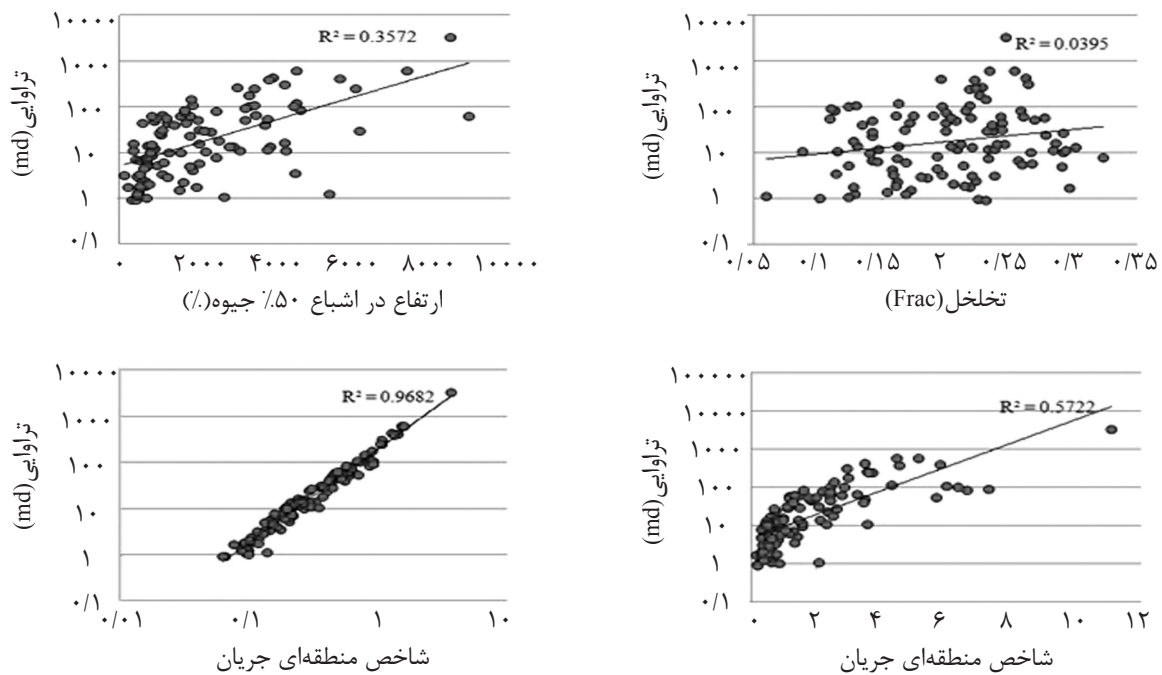


شکل ۳ الف) نمودار فشار تزریق جیوه در مقابل اشباع‌شدگی نمونه‌ها و ب) نمودار تخلخل در مقابل تراوایی نمونه‌ها.



شکل ۴ رابطه مشخصه‌های استخراج‌شده از منحنی‌های تزریق جیوه با تراوایی. به ترتیب بالا، راست: تراوایی در مقابل شعاع گلوگاه‌ها در اشباع ۳۵٪؛ بالا، چپ: تراوایی در مقابل شعاع گلوگاه‌ها در اشباع ۱۵٪؛ وسط، راست: تراوایی در مقابل شعاع گلوگاه‌ها در اشباع ۸۴٪؛ وسط، چپ: تراوایی در مقابل شعاع گلوگاه‌ها در اشباع ۵۰٪؛ پایین، راست: تراوایی در مقابل مشخصه سوانسون (SP) و پایین، چپ: رابطه چورشدگی گلوگاه‌ها با تراوایی.

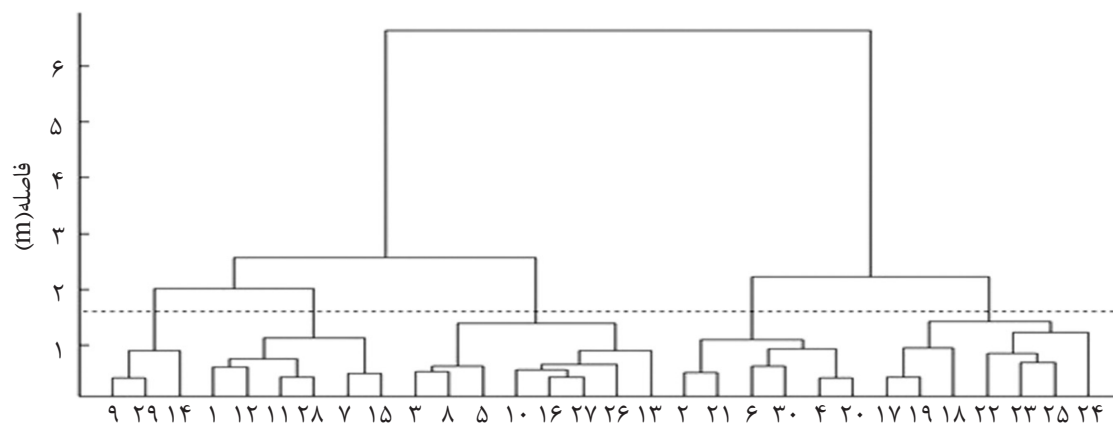




شکل ۵ رابطه مشخصه‌های استخراج‌شده از منحنی‌های تزریق جیوه و پتروفیزیکی با تراوایی. به ترتیب: بالا، چپ: تراوایی در مقابل ارتفاع بالای آب آزاد در اشباع ۵۰٪؛ بالا، راست: تراوایی در مقابل تخلخل؛ پایین، راست: تراوایی در مقابل اندیس منطقه‌ای جریان و پایین، چپ: تراوایی در مقابل اندیس کیفیت مخزنی.


را انتخاب کرد [۲۶]. در این مقاله از درخت خوشه‌ای برای تعیین تعداد خوشه‌های بهینه استفاده شد. شکل ۶ درخت خوشه‌ای را برای داده‌های ورودی در این مطالعه نشان می‌دهد و همان‌طور که در این شکل دیده می‌شود، انتخاب ۵ خوشه به‌عنوان خوشه بهینه بهترین دقت را دارد. شکل ۷ مدل یو-ماتریکس<sup>۱</sup> استخراج‌شده با استفاده از شبکه عصبی SOM اولیه را نشان می‌دهد. همان‌طور که دیده می‌شود، انتخاب ۵ خوشه به‌عنوان خوشه بهینه دارای بهترین دقت است. در مرحله بعد یک شبکه عصبی خودسازمان‌ده در محیط نرم‌افزار MATLAB، نسخه b ۲۰۱۱ طراحی و ابعاد شبکه با استفاده از تعداد داده‌های ورودی و همچنین تعداد متغیرها مشخص شد [۳۲]. در نهایت داده‌های ورودی انتخاب‌شده به شبکه معرفی شدند و خوشه‌بندی براساس الگوریتم توضیح داده شده در بالا برای شبکه‌های عصبی خودسازمان‌ده انجام شد. جدول ۱ میانگین مشخصه‌های ورودی برای هر یک از کلاس‌های معرفی‌شده را نشان می‌دهد.

در این مطالعه مقدار انطباق مشخصه‌های استخراج‌شده با تراوایی عاملی برای انتخاب متغیرهای ورودی برای فرآیند خوشه‌سازی است. برای این منظور متغیرهایی که با مقدار تراوایی انطباق بالاتر از ۲۰٪ را نشان می‌دادند به‌عنوان ورودی‌های خوشه‌سازی استفاده شدند؛ بنابراین از تمام مشخصه‌های استخراج‌شده، به غیر از تخلخل، به‌عنوان ورودی استفاده شد. مرحله بعد از انتخاب ورودی‌ها، انتخاب تعداد خوشه‌سازی بهینه است که عاملی مهم در فرآیند خوشه‌سازی است. اگر تعداد ورودی‌ها یا متغیرها محدود باشند، می‌توان با کراس‌پلات‌های دوبعدی و سه‌بعدی با هم‌دیگر توزیع فضایی داده‌ها را مشخص و تعداد خوشه بهینه را انتخاب کرد؛ ولی اگر تعداد متغیرهای ورودی بیش از سه مشخصه باشد، دیگر نمی‌توان از پلات‌های دو و سه‌بعدی برای مشخص کردن توزیع فضایی داده‌ها استفاده کرد. در این حالت روش‌هایی مختلف وجود دارند که به کمک آنها و با محاسبه فاصله داده‌ها در ابعاد مختلف و با الگوریتم‌های متفاوت می‌توان تعداد خوشه بهینه




مشاهده

شکل ۶ درخت خوشه‌ای که در آن آستانه برش برای انتخاب بهترین شماره خوشه نشان داده شده است. انتخاب ۵ خوشه دارای بهترین دقت است.



توزیع نمونه در نقشه روش خودسازمان‌ده



فاصله وزنی خوشه‌های مجاور

شکل ۷ انتخاب خوشه بهینه برای مجموعه داده‌های مطالعه‌شده، نحوه قرارگیری داده‌ها در شبکه SOM (چپ)، و انتخاب ۵ کلاس به‌عنوان کلاس بهینه براساس شکل یو-ماتریکس (راست).

جدول ۱ خصوصیات آماری مشخصه‌های ورودی در رخساره‌های منفذی مختلف معرفی شده.

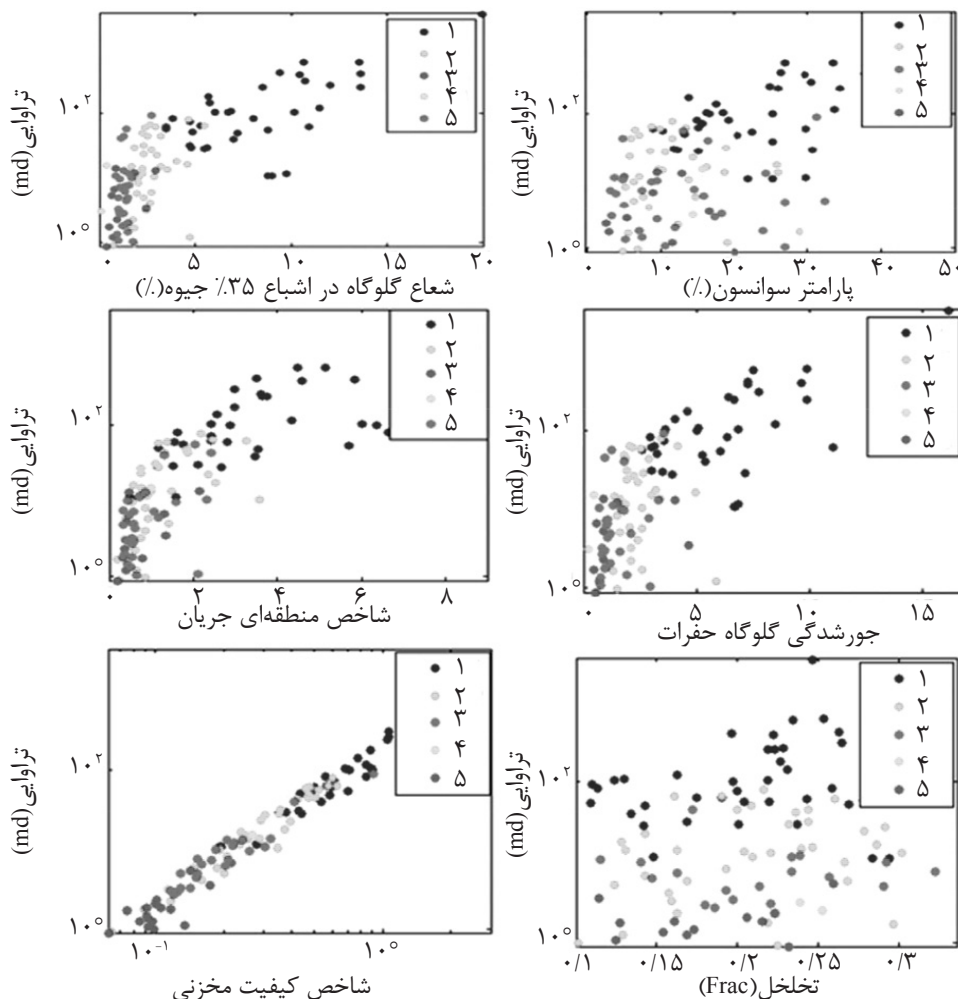
تراوایی (md)	تخلخل (%)	شاخص منطقی جریان	شاخص کیفیت مخزنی	ارتفاع در تزریق ۵۰٪ جیوه (m)	جورشدگی گلوگاه حفرات	پارامتر سوانسون	شعاع گلوگاه در ۸۴٪ اشباع جیوه (cm)	شعاع گلوگاه در ۵۰٪ اشباع جیوه (cm)	شعاع گلوگاه در ۳۵٪ اشباع جیوه (cm)	شعاع گلوگاه در ۱۵٪ اشباع جیوه (cm)	
۲۴/۱/۲۵	۰/۲۰۴	۳/۴	۰/۸۳	۵۰۴/۹۲	۶/۱۷	۲۳/۲۴	۱/۰۰	۶/۲۳	۸/۳۱	۱۱/۲۸	رخساره منفذی ۱
۲۲/۳۹	۰/۲۰۵	۱/۲۲	۰/۲۸	۱۵۴۸/۶۲	۲/۴	۱۱/۹۸	۰/۴۹	۱/۷۱	۲/۶۸	۴/۹۹	رخساره منفذی ۲
۱۲/۸۳	۰/۱۹۳	۱/۱۱	۰/۲۱	۶۱۵۳/۵۳	۱/۴۷	۱۳/۲۰	۰/۱۹	۰/۸۶	۱/۳۲	۳/۳۷	رخساره منفذی ۳
۶/۴۶	۰/۱۹	۰/۸۶	۰/۱۷	۲۳۳۲۱/۲۹	۱/۵۸	۱۲/۱۷	۰/۱۲	۰/۵۲	۱/۲۳	۳/۸۸	رخساره منفذی ۴
۹/۲۸	۰/۲۲	۰/۶۷	۰/۱۹	۳۱۰۸/۷۸	۰/۳۲	۱۵	۰/۰۴	۰/۱۲	۰/۲۴	۰/۸	رخساره منفذی ۵



**کیفیت مخزنی رخساره‌های منفذی**

به سمت رخساره ۵ کاهش می‌یابد که نشان‌دهنده کاهش جورشدگی شبکه گلوگاه‌هاست. مقدار اندیس کیفیت مخزنی و اندیس زون جریانی از رخساره ۱ تا رخساره ۵ کاهش دارد. از طرف دیگر، مقدار تراوایی از رخساره ۱ به سمت رخساره ۵ کاهش می‌یابد که همه اینها کاهش کیفیت مخزنی از رخساره ۱ به سمت رخساره ۵ را نشان می‌دهند. در این جا نکته مهم این است که مقدار تخلخل در رخساره‌های مختلف از الگویی خاص پیروی نمی‌کند که نشان می‌دهد در یک سنگ مخزن کربناته افزایش تخلخل به معنای افزایش کیفیت مخزنی نیست و عامل اصلی کنترل‌کننده کیفیت مخزنی ارتباط حفره‌های تخلخل با هم‌دیگر یا همان قطر گلوگاه‌های تخلخل و جورشدگی آنهاست.

بعد از خوشه‌سازی داده‌های ورودی، کیفیت مخزنی به هر یک از خوشه‌های معرفی شده تخصیص می‌یابد. جدول ۱ و شکل ۸ کیفیت مخزنی رخساره‌های منفذی معرفی شده را نشان می‌دهند. در شکل ۸ دیده می‌شود که رخساره یک بهترین کیفیت مخزنی را دارد. کیفیت مخزنی رخساره‌ها به ترتیب از ۱ تا ۵ کاهش می‌یابد. میانگین شعاع گلوگاه‌های تخلخلی که در ۱۵، ۳۵، ۵۰ و ۸۵ درصد تزریق جیوه اشباع شده‌اند از رخساره ۱ به سمت رخساره ۵ کاهش می‌یابد که نشان از کاهش کیفیت مخزنی از رخساره یک به رخساره ۵ دارد. همچنین مشخصه سوانسون در رخساره ۱ بیش‌ترین مقدار و در رخساره ۴ کم‌ترین مقدار را دارد. مقدار جورشدگی گلوگاه رخساره‌ها از رخساره ۱




شکل ۸ ارتباط تراوایی و دیگر مشخصه‌های استخراج شده در رخساره‌های منفذی مختلف.

پیش‌بینی به مجموعه داده آموزشی نیاز دارند. در این مطالعه کلاس‌های مشخص شده با شبکه عصبی خودسازمان‌ده در مراحل قبل، کلاس‌های آموزشی و لاگ‌های پتروفیزیکی، ورودی در نظر گرفته شدند. یکی از مزیت‌های ماشین‌های بردار پشتیبان این است که پیاده‌سازی‌های بسیاری از آن به شکل آزاد و رایگان در اینترنت در دسترس است که مشهورترین آنها SVM-light و Lib-SVM هستند. SVM-light یک پیاده‌سازی از ماشین بردار پشتیبان به زبان C است که دانشگاه کرنل آمریکا آن را نوشته است. هم‌چنین نرم‌افزار قدرتمند یادگیری ماشین WEKA نیز پیاده‌سازی موثری برای SVM دارد. نرم‌افزار MATLAB، نسخه ۷/۶/۳۲ (R 2008a) که در ۱۰ فوریه سال ۲۰۰۸ منتشر شد، و نسخه‌های جدیدتر آن استفاده از طبقه‌کننده ماشین بردار پشتیبان را ممکن کرده است. پیش‌تر تعداد بسیاری جعبه‌ابزار پیاده‌سازی SVM نیز برای MATLAB نوشته شده‌اند که از این میان می‌توان به جعبه‌ابزار معرفی شده در مرجع ۳۳ اشاره کرد.

عموما نمی‌توان انتظار داشت که رخساره‌های منفذی شرایط دیاژنزی و رسوبی مشابهی را نشان دهند، بنابراین نمی‌توان از این شرایط برای تقسیم‌بندی رخساره‌ها استفاده کرد. نکته ضروری در بررسی شرایط دیاژنزی و رسوبی این است که با فهم این شرایط در هر رخساره منفذی می‌توان به سیستم منافذ مشخصه‌های موثر در کیفیت مخزنی پی برد. در شکل ۹ تصاویری از مقاطع نازک میکروسکوپی هر رخساره منفذی نشان داده شده‌اند. از این شکل می‌توان نتیجه گرفت که ارتباط فضای خالی از رخساره منفذی یک به سمت پنج کاهش می‌یابد. فضاهای خالی موجود در رخساره منفذی یک عمدتاً از نوع بین‌دانه‌ای<sup>۱</sup> است که فراوانی آن به سمت رخساره پنج کاهش یافته است. در رخساره منفذی شماره پنج عمده فضاهای منفذی از نوع قالبی و درون‌دانه‌ای منفصل است که موجب افزایش مشخصه تخلخل شده، ولی نتوانسته به جریان یافتن سیال در مخزن کمک کند.


**پیش‌بینی رخساره‌های منفذی معرفی شده در محدوده چاه ماشین‌های یادگیری برای یافتن الگو و حل مسائل**



شکل ۹ الف) رخساره منفذی گرینستونی دارای حفرات بین‌دانه‌ای؛ ب) رخساره منفذی گرینستونی دارای حفرات قالبی و بین‌دانه‌ای؛ ج) رخساره منفذی دولومادستونی دارای حفرات بین‌بلوری و قالبی؛ د) رخساره منفذی پکستونی دارای حفرات قالبی و e) رخساره منفذی دولوگرینستونی دارای حفرات قالبی.

۷۵ داده ورودی و خروجی و آزمون حاوی ۳۴ نمونه از ۱۰۹ داده موجود تقسیم شدند. داده‌های آموزشی برای آموزش و بهینه کردن ماشین بردار پشتیبان به کار رفتند. بعد از آموزش و بهینه کردن مدل از داده‌های کنار گذاشته شده آزمون به‌عنوان آزمایش شبکه استفاده شد. شکل ۱۰ نتایج حاصل از ماشین بردار پشتیبان را برای داده‌های آموزشی و آزمون نشان می‌دهد و دیده می‌شود که مدل در پیش‌بینی داده‌ها موفق عمل کرده است.

در این مطالعه برای پیاده‌سازی ماشین بردار پشتیبان، از میان انبوه پیاده‌سازی‌ها و بسته‌های نرم‌افزاری، از Lib-SVM استفاده شد که تحت نرم‌افزار MATLAB نیز ارائه شده است. در این مطالعه نمودارهای چاه‌پیمایی اشعه گاما، سرعت انتقال صوت، چگالی، نوترون و نگار انحراف سرعت به‌عنوان ورودی و ۵ کلاس معرفی شده در مراحل قبل به‌عنوان خروجی ماشین بردار پشتیبان انتخاب شدند. ابتدا داده‌ها به دو دسته آموزشی متشکل از



شکل ۱۰ نتایج حاصل از ماشین بردار پشتیبان در برآورد رخساره‌های منفذی در میدان پارس جنوبی.

شد. برای پیش‌بینی رخساره‌های منفذی در چاه‌های بدون مغزه از روش ماشین بردار پشتیبان و برای انجام این کار از نمودارهای چاه‌پیمایی به‌عنوان ورودی و خوشه‌های استخراج شده در مرحله قبل به‌عنوان خروجی استفاده شد. دقت روش ماشین بردار پشتیبان، با استفاده از روش میانگین مربعات خطا، ۷۸٪ است که دقت شبکه در ارائه نتایج خروجی را نشان می‌دهد؛ بنابراین می‌توان نتیجه گرفت که می‌توان با به‌کارگیری نمودارهای چاه‌پیمایی از روش یادگیری ماشین، به‌خصوص ماشین بردار پشتیبان، برای پیش‌بینی رخساره‌های منفذی در چاه‌های فاقد اطلاعات آنالیزهای مخصوص مغزه استفاده کرد.

## نتیجه‌گیری

داده‌های تزریق جیوه برای تعیین رخساره‌های منفذی در میدان گازی پارس جنوبی استفاده شدند. برای انجام این کار از معادلاتی مشخص برای استخراج مجموعه‌ای از مشخصه‌های خاص از داده‌های تزریق جیوه استفاده شد. ارتباط مشخصه‌های استخراج شده با کیفیت مخزنی در چارچوب هم‌بستگی این مشخصه‌ها با مقدار تراوایی به کار رفت. مشخصه‌هایی که هم‌بستگی منطقی با مقدار تراوایی داشتند، ورودی آنالیز خوشه‌سازی و تعیین رخساره‌های منفذی، با استفاده از روش شبکه عصبی خودسازمان‌ده، شدند. با استفاده از مشخصه‌های استخراج شده، کیفیت مخزنی هر یک از خوشه‌های معرفی شده تعیین

## مراجع

- [1]. Qi L. S. and Carr T. R., "Neural network prediction of carbonate lithofacies from well logs, big bow & sand arroyo creek fields, southwest kansas," *Comput. Geo.*, Vol. 32, pp. 947-964, 2006.
- [2]. Koehrer B. S., Heymann C., Prousa F. and Aigner T., "Multiple-scale facies and reservoir quality variations within a dolomite body-outcrop analog study from the middle triassic," *SW German Basin. Mar. Pet. Geol.*, Vol. 27, pp. 386-411, 2010.
- [3]. Ma Z. Y., Wang H., Sitchler J., Gurpinar O., Gomez E. and Wang Y., "Mixture decompositions and lithofacies clustering from wire line logs," *J. Appl. Geophys.*, 102,10-20, 2014.
- [4]. Sfidari E., Kadkhodaie-Ilkhchi A., Rahimpour-bonab H. and Soltani B., "A hybrid approach for litho-facies characterization in the framework of sequence stratigraphy: a case study from the south pars gas field, the Persian Gulf Basin," *J. Pet. Sci. Eng.*, Vol 121, pp. 87-102, 2014.
- [5]. Kadkhodaie-Ilkhchi R., Rezaee R., Moussavi-Harami R. and Kadkhodaie-Ilkhchi A., "Analysis of the reservoir electrofacies in the framework of hydraulic flow units in the wicher range field, perth basin, western Australia," *J. Pet. Sci. Eng.*, Vol 111, pp. 106-120, 2013.
- [6]. Ye S. J. and Rabiller P., "A new way for electro-facies analysis: multi-resolution graph-based clustering," *SP-WLA 41<sup>st</sup> Annu. Logging Symp.*, June 4-7, 2000.
- [7]. Chehrazi A., Rezaee R. and Rahimpour-Bonab H., "Pore facies as a tool for incorporation of small-scale dynamic information in integrated reservoir studies," *J. Geophys. Eng.*, Vol. 8, pp. 202-24, 2011.
- [8]. Aliakbardoust E. and Rahimpour-Bonab H., "Integration of rock typing methods for carbonate reservoir characterization," *J. Geophys. Eng.*, 10, p. 11, 2013.
- [9]. Rahimpour-Bonab H. and Aliakbardoust E., "Pore facies analysis: incorporation of rock properties into pore geometry based classes in a permo-triassic carbonate reservoir in the Persian Gulf," *J. Geophys. Eng.*, Vol. 11, No. 3, 035008, 2014.
- [10]. Saggaf M. M. and Nebrija E. L., "A fuzzy logic approach for the estimation of facies from wire-line logs," *AAPG Bull.*, Vol. 87, No. 7, pp. 1233-1240, 2003.
- [11]. Al-Anazi A. and Gates. I. D., "A support vector machine algorithm to classify lithofacies and model permeability in heterogeneous reservoirs," *Eng. Geo.*, Vol. 114, No. 3-4, pp 267-277, 2010.
- [12]. Qi L., Carr T. R. and Goldstein R. H., "Geostatistical three-dimensional modeling of oolite shoal, St. Louis limestone, Southwest Kansas," *AAPG Bull.*, Vol. 91, No. 1, pp. 69-96, 2007.
- [13]. Sfidari E., Amini A., Kadkhodaie A. and Ahmadi B., "Electrofacies clustering and a hybrid intelligent based method for porosity and permeability prediction in the south Pars Gas field, Persian Gulf," *J. Geopersia*, Vol. 2, No. 2, pp. 11-23, 2012.
- [14]. Vavra C. L., Kaldi J. G. and Sneider R. M., "Geological applications of capillary pressure: a review," *AAPG Bull.*, Vol. 86, pp. 840-50, 1992.
- [15]. Swanson B. F., "Visualizing pores and non-wetting phase in porous rocks: Society of petroleum engineers," *Annual Fall Technical Conference, SPE Paper 6857*, p. 10, 1977.

- [16]. Swanson B. F. and Simple A., "Correlation between Permeabilities and mercury capillary pressures," J. Pet. Tech., Vol. 33, No 2, pp. 488-504, 1981.
- [17]. Jennings J. B. "Capillary pressure techniques: application to exploration and development geology," AAPG Bull., Vol. 71, pp. 1196-1209, 1987.
- [18]. Amaefule J. O., Altunbay M., Tiab D., Kersey D. G. and Keelan D. K., "Enhanced reservoir description: using core and log data to identify hydraulic (flow) units and predict permeability in uncored intervals/wells," SPE 26436, Presented at 68th Annual Technical Conf. and Exhibition, 1993.
- [19]. Porras J. C., Barbato R. and Khazen L., "Reservoir flow units: a comparison between three different models in the santa barbara and piritul fields, North monagas area," Eastern Venezuela Basin, SPE 53671, 1999.
- [20]. Kozeny J., "Uber kapillare leitung des wassers im boden, stizurgsberichte, royal academy of science," Vienna, Proc. Vol. 136, pp. 271-306, 1927.
- [21]. Abbaszadeh M., Fujii H. and Fujimoto F., "Permeability prediction by hydrolic flow units theory and applications," SPE Format. Evaluate, Vol. 11, pp. 263-271, 1996.
- [22]. Svirsky D., Ryazanov A., Pankov M., Yukos E. P. and Corbett P. W. M., "Hydraulic flow units resolve reservoir description challenges in a Siberian oil field," SPE Paper 87056, 12pp, 2004.
- [23]. Vilmann T., Merenyi E. and Hammer B., "Neural maps in remote sensing image analysis," Neural Networks, Vol. 16, pp. 389-403, 2003.
- [24]. Cassano E. N., Lynch A. H., Cassano J. J. and Koslow M. R., "Classification of synoptic patterns in the western arctic associated with extreme events at barrow, Alaska, USA," Clim. Res., Vol. 30, pp. 83-97, 2006.
- [25]. Coléou T., M. Poupon and Azbe K., "Unsupervised seismic facies classification: a review and comparison of techniques and implementation," The Leading Edge, Vol. 22, pp. 942-953, 2003.
- [26]. Kohonen T., "Self-organizing maps, springer series in information sciences," New York, Springer-Verlag, Vol. 30, 2001.
- [27]. Mukherjee A. "Self-organizing neural network for identification of natural modes," The Journal of Computing in Civil Engineering, Vol. 11 (1), pp. 74-77, 1997.
- [28]. Sfidari E., Kadkhodaie-Ilkhchi A. and Najjari S., "Comparison of intelligent and statistical clustering approaches to predicting total organic carbon using intelligent systems," J. Pet. Sci. Eng., Vol. 86-87, pp. 190-205, 2012.
- [29]. Burges C. J. C., "A tutorial on support vector machines for pattern recognition," Data Mining and Knowledge Discovery, Vol. 2, pp. 121-167, 1998.
- [30]. Chin K. "Support vector machines applied to speech pattern classification," Mphil. In Computer Speech and Language Processing, Cambridge University Engineering Department, 1999.
- [31]. Kumar M., Verma R. and Gajendra P. S. Raghava, "Prediction of mitochondrial proteins using support vector machine and hidden markov model," J. Biol. Chem., Vol. 281, pp. 5357-5363, 2006.
- [32]. Vesanto J., Himberg J., Alhoniemi E. and Parhankangas J., "Self-organizing map in matlab: the SOM toolbox," In: Proceedings of The Matlab DSP Conference, Espoo, Finland: Comsol Oy, pp. 35-40. 1999.
- [33]. Pollastri G., Martin A. J., Mooney C. and Vullo A., "Accurate prediction of protein secondary structure and solvent accessibility by consensus combiners of sequence and structure information," BMC Bioinformatics, Vol. 8(1), 201, 2007.