

## پیش‌بینی تراوایی سنگ مخزن کربناته با استفاده از شبکه عصبی مصنوعی و ماشین بردار پشتیبان در یکی از مخازن نفتی ایران

یاسر عزیز<sup>۱</sup> و نوید شادمنام<sup>۲\*</sup>

۱. دانشجوی کارشناسی ارشد، مهندسی اکتشاف نفت، دانشگاه صنعتی سهند، تبریز، ایران

۲. استادیار، دانشکده مهندسی معدن، دانشگاه صنعتی سهند، تبریز، ایران

(دریافت: ۹۵/۳/۲۳، پذیرش نهایی: ۹۶/۳/۲)

### چکیده

تراوایی از مؤلفه‌های اساسی در ارزیابی مخازن هیدروکربنی است که عمدتاً از طریق اندازه‌گیری‌های آزمایشگاهی از مغزه یا داده‌های چاه‌آزمایی به دست می‌آید. با این حال، به دلیل هزینه زیاد و فراوانی کم این نوع از داده‌ها، پیش‌بینی تراوایی با استفاده از داده‌های چاه‌نگاری از جایگاه ویژه‌ای برخوردار است. در این مطالعه، برای تخمین تراوایی، ابتدا داده‌های چاه‌نگارها با توجه به مطالعات زمین‌شناسی صورت گرفته بر روی میدان مورد مطالعه به چهار گروه رخساره‌های الکتریکی دسته‌بندی می‌شوند: پکستون-وکستون-مادستون، پکستون-وکستون، گرینستون-پکستون و گرینستون-پکستون-وکستون.

در این مطالعه، از شبکه‌های عصبی مصنوعی و ماشین بردار پشتیبان برای تخمین تراوایی در یکی از مخازن ناهمگون کربناته با استفاده از داده‌های چاه در میدان مذکور استفاده شده است. جهت تخمین تراوایی، ابتدا داده‌های نگاره‌های چاه با استفاده از روش‌های «تجزیه و تحلیل مؤلفه‌های اصلی» و «تجزیه و تحلیل خوشه‌مبتنی بر مدل» به رخساره‌های الکتریکی تقسیم‌بندی شده‌اند. سپس هر رخساره الکتریکی به عنوان ورودی شبکه عصبی مصنوعی و ماشین بردار پشتیبان جهت تخمین تراوایی در نظر گرفته شده‌اند.

شبکه عصبی مصنوعی با استفاده از «توابع پس‌انتشار لوببرگ»، «گرادیان نزولی با تکانه وزنی» و «تابع یادگیری بیاس» با ده لایه مخفی آموزش داده شده است. از ماشین بردار پشتیبان با رگرسیون‌های اِپسیلون و نو با توابع کرنلی مختلف استفاده شده است. در این مطالعه، تابع کرنل شعاعی ماشین بردار پشتیبان دارای خطای کمتری در مقایسه با شبکه عصبی است. خطای حاصل از ماشین بردار پشتیبان برای رخساره‌های الکتریکی گروه اول تا چهارم به ترتیب برابر است با: ۰،۰۲۴۲، ۰،۰۰۶۵، ۰،۰۱۹۵ و ۳،۶۵۸۷.

واژه‌های کلیدی: تراوایی، رخساره الکتریکی، رگرسیون، شبکه عصبی مصنوعی، ماشین بردار پشتیبان، نمودارهای پتروفیزیکی.

### ۱. مقدمه

یکی از موضوعات کلیدی در ارزیابی مخازن، استفاده از داده‌های چاه‌نگارها برای پیش‌بینی خواص پتروفیزیکی، مانند تراوایی و تخلخل سنگ مخزن است. هرچند اطلاعات مغزه که از تجزیه و تحلیل‌های آزمایشگاهی به دست می‌آیند از دقت بالایی برخوردار هستند، اما این تحلیل‌ها پرهزینه و زمان‌بر هستند و داده‌های آن‌ها برای اکثر چاه‌ها در دسترس نیستند. در صنعت نفت و گاز به منظور مدل‌سازی، شبیه‌سازی و طراحی روش‌های ازدیاد برداشت از مشخصات مخزن، همانند تراوایی و تخلخل استفاده می‌کنند و از این‌رو از بزرگ‌ترین چالش‌های مهندسان مخزن تعیین این مؤلفه‌ها در سنگ مخزن است (محقق و همکاران، ۱۹۹۶).

معمولاً تراوایی را از نمودارهای چاه، با استفاده از روابط تجربی یا از رگرسیون‌های آماری (مؤلفه‌ای و غیرمؤلفه‌ای) تخمین می‌زنند. با این حال، مدل‌های تجربی در مناطقی که دارای محیط‌های مختلف رسوبی هستند، بدون اعمال تصحیحات مقادیر ثابت و توان‌ها قابل استفاده نیستند (لی و گوپتا، ۱۹۹۹). در سال‌های اخیر روش‌های رگرسیون غیرمؤلفه‌ای، همانند شبکه عصبی مصنوعی و ماشین بردار پشتیبان برای غلبه بر محدودیت‌های رایج در رگرسیون چندگانه معرفی شده‌اند.

کاربرد این روش‌ها در مخازن کربناته ناهمگون، با وجود

نمودارهای چاه هستند که مشخص کننده یک لایه و عامل تشخیص آن از لایه‌های دیگر است (نشاوی و ملالا، ۲۰۰۹). خوشه‌بندی رخساره‌های الکتریکی در این پژوهش شامل دو بخش است: ۱. تحلیل مؤلفه‌های اصلی، ۲. تحلیل خوشه‌ای مبتنی بر مدل.

## ۱-۲. تحلیل مؤلفه‌های اصلی (Principal Component Analysis (PCA))

تحلیل مؤلفه‌های اصلی ابزار قدرتمندی برای تحلیل داده‌های چندبعدی است که می‌تواند برای تشخیص الگوها به واسطه افکندگی‌های جدید از داده‌ها استفاده شود و کارایی بهتری را با تغییرپذیری ذاتی داده‌های مورد مطالعه به دست می‌دهد. هدف اصلی تحلیل مؤلفه‌های اصلی، خلاصه کردن داده‌ها به صورت مؤثر، به منظور کاهش ابعاد داده‌ها بدون از دست دادن مقدار قابل توجهی از داده‌ها است؛ با این کار فهم بهتری از ساختار داده‌ها به دست می‌آید. در روش تحلیل مؤلفه‌های اصلی، متغیرهای اصلی و وابسته بر اساس میزان اهمیت آن‌ها مشخص می‌شوند و داده‌ها به صورت تابعی از متغیرهای جدید که به صورت ترکیب خطی پاسخ‌های چاه‌نگارهای اولیه است، نشان داده می‌شوند. مؤلفه‌های اصلی به دست آمده بر یکدیگر عمود هستند که این ویژگی باعث از بین بردن بخش‌های زائد داده‌ها می‌شود (دیویس، ۲۰۰۲).

برای به دست آوردن مؤلفه‌های اصلی، ابتدا، تأثیرات مقیاس و واحدهای متغیرهای نمودارگیری به حداقل رسانده می‌شود. داده‌های به دست آمده از نمودارگیری با کم کردن میانگین از هر مقدار و تقسیم آن بر انحراف معیار استاندارد می‌شوند (بوچب و اوانس، ۱۹۹۴). فرض کنید اطلاعات مجموعه‌ای از داده‌ها،  $X$ ، موجود باشد که هر مؤلفه آن،  $x_{ij}$ ، مربوط به داده  $i$ ام و عمق  $j$ ام است.  $(i=1, \dots, n, \text{ and } j=1, \dots, p)$  کواریانس ماتریس  $X$  را می‌توان به صورت زیر تعریف کرد:

$$\begin{aligned} \text{Cov}(X) &= \frac{1}{(n-1)} (X - n^{-1}11^T X)^T (X - n^{-1}11^T X) \\ &= (X^T X - n\bar{x}^T \bar{x}) \end{aligned} \quad (1)$$

ناهمگنی در خواص سنگ مخزن نتایج قابل قبولی ارائه داده است. با این حال، مشکلات قابل توجهی در شناسایی تغییرات شدید در خواص مخزن ناشی از تغییرات ناگهانی محیط رسوبی وجود دارد. یکی از ویژگی‌های متمایز مخازن کربناته، عدم همبستگی تخلخل و تراوایی در این نوع مخازن است. برای نمونه ممکن است در مناطقی که تراوایی کم است، تخلخل زیاد باشد یا برعکس. همه این ویژگی‌ها از نظر پیش‌بینی جریان سیال، به خصوص در گلوگاه‌های با تراوایی کم به رگه‌های با تراوایی زیاد بسیار مهم است (لی و گوپتا، ۱۹۹۹).

به طور کلی، نمودارهای چاه، اطلاعات ارزشمند اما غیرمستقیم درباره کانی‌شناسی، بافت، ساختار رسوبی، محتوای سیال و خواص هیدرولیکی مخزن ارائه می‌کنند. پاسخ‌های مشخص نمودارها از سازند می‌توانند نشان‌دهنده رخساره‌های الکتریکی باشند که اغلب با رخساره‌های سنگی همبستگی دارند. شناسایی رخساره‌های سنگی عمدتاً از طریق اطلاعات مغزه‌ها و بر اساس ویژگی‌های رسوب‌گذاری و دیاژنتیکی صورت می‌گیرد. اهمیت توصیف رخساره‌های الکتریکی در توصیف و مدیریت مخزن به طور گسترده‌ای شناخته شده است (هون لی و همکاران، ۲۰۰۲). در این پژوهش، پس از خوشه‌بندی داده‌های چاه‌نگاری و شناسایی رخساره‌های الکتریکی، از شبکه‌های عصبی مصنوعی و ماشین‌های بردار پشتیبان برای تخمین تراوایی در هر خوشه استفاده شده است و در نهایت، مقدار تراوایی به دست آمده از دو روش مذکور با مقدار تراوایی حاصل از داده‌های مغزه مقایسه می‌شود.

## ۲. خوشه‌بندی داده‌های چاه‌نگاری و شناسایی رخساره‌های الکتریکی

گام اول در برآورد تراوایی، خوشه‌بندی داده‌های چاه‌نگاری و شناسایی رخساره‌های الکتریکی است. رخساره‌های الکتریکی مجموعه‌ای از پاسخ‌های

۱۹۹۳؛ فرالی، ۱۹۹۸). این رویکرد می‌تواند عملکرد بسیار بهتری در مقایسه با روش‌های معمولی، از قبیل لینک منفرد و  $K$ -میانگین خوشه‌ای داشته باشد (ریپلای، ۱۹۹۴). روش‌های معمولی اغلب در شناسایی گروه‌هایی که با هم تداخل دارند یا اشکال و اندازه‌های مختلفی دارند، با شکست مواجه می‌شوند. از مزایای دیگر رویکرد مبتنی بر مدل این است که از معیارهای بیزین مرتبط برای ارزیابی مدل استفاده می‌کند. این ویژگی نه تنها مدل را مؤلفه‌بندی می‌کند، بلکه تعداد خوشه‌ها را بدون قضاوت ذهنی در مقایسه با سایر روش‌های تحلیل خوشه‌ای معمولی فراهم می‌کند (لی و گوپتا، ۱۹۹۹؛ لیم و همکاران، ۱۹۹۷؛ متیسن و همکاران، ۲۰۰۱).

بنفیلد و رفتی (۱۹۹۳)، چارچوب مبتنی بر مدل برای خوشه‌بندی را با مؤلفه‌بندی ماتریس کواریانس در تجزیه مقادیر ویژه آن توسعه دادند. این مدل موفقیت‌های قابل توجهی در کاربردهای مختلف، از جمله شناسایی کاراکتر، تقسیم‌بندی بافت، میدان مین و تشخیص گسل لرزه‌ای داشته است. خوشه‌های شناسایی شده را می‌توان به‌عنوان گروه‌های مجزای رخساره‌های الکتریکی در نظر گرفت که منعکس‌کننده ویژگی‌های هیدرولیکی، رخساره سنگی و دیاژنتیکی هستند. اگر اطلاعات اضافی، از قبیل داده‌های مغزه یا اطلاعات زمین‌شناسی موجود باشند، می‌توان برای اطمینان، شناسایی گروه‌های رخساره‌های الکتریکی را با تفسیر زمین‌شناسی کالیبره کرد (متیسن و همکاران، ۲۰۰۱).

### ۳. شبکه عصبی مصنوعی

پس از خوشه‌بندی داده‌ها و شناسایی رخساره‌های الکتریکی، گام بعدی، اجرای رگرسیون با استفاده از روش‌های هوشمند به منظور برآورد تراوایی در هر یک از گروه‌های رخساره‌های الکتریکی شناسایی شده است. استفاده از روش شبکه‌های عصبی مصنوعی یکی از گزینه‌های متداول در این کار است. در این مطالعه، از شبکه عصبی نوع تغذیه رو به جلو با تابع آموزشی

که در آن،  $\bar{x} = 1^T X/n$  بردار سطری میانگین متغیرهای داده‌چاه است. 1 بردار ستونی است که همه مؤلفه‌های آن یک است. از آنجا که  $Cov(X)$  ماتریس متقارن غیرمنفی است، ماتریس کواریانس با استفاده از روش تجزیه مقدار تکین می‌تواند به صورت ترکیبی از ماتریس‌های قطری و متعامد تبدیل شود.

$$\Sigma = Q^T \Lambda Q \quad (2)$$

که در آن  $Cov(X)$  ماتریس متقارن غیرمنفی و  $\Lambda$ ، ماتریس قطری مقادیر ویژه  $\Sigma$  با مؤلفه‌های قطری  $\lambda_1, \dots, \lambda_n$ ،  $\lambda_1$  است.  $Q$ ، ماتریس متعامد بردارهای ستونی است که شامل بردارهای ویژه است که به ترتیب با مقادیر ویژه  $\lambda_1, \dots, \lambda_n$  مرتبط هستند. بردار سطری  $X$  را می‌توان به‌عنوان یک نقطه در فضای  $P$  بعدی نشان داد؛ بنابراین فضای داده‌های  $X$ ، به شکل یک ابر در فضا است.

از لحاظ تئوری، بردارهای ویژه، برای مختصات مؤلفه اصلی ابر صفحه و  $Q$  برای تبدیل داده‌های اصلی به مؤلفه‌های اصلی استفاده می‌شود. مؤلفه‌های اصلی شکل دیگری از نمایش داده‌ها را نشان می‌دهند که در نتیجه، امکان استفاده بهتر از ساختار داده‌ها، بدون تغییر اطلاعات را فراهم می‌سازد. علاوه بر این، به دلیل اینکه واریانس کل در مجموعه داده‌ها می‌تواند به صورت مجموع واریانس‌های هر یک از مؤلفه‌های اصلی تعریف شود، اولین مؤلفه‌های اصلی بسیاری از تغییرات متغیرهای اصلی را در خود دارند. این مؤلفه‌ها، اغلب برای آشکار ساختن ساختار داده‌ها استفاده می‌شوند و می‌توانند ابعاد مسئله و پیچیدگی خوشه‌بندی و تحلیل تفکیک‌کننده را کاهش دهند (لی و گوپتا، ۱۹۹۹؛ ولف و کومبسور، ۱۹۸۲؛ لیم و همکاران، ۱۹۹۷).

### ۲-۲. تحلیل خوشه‌ای مبتنی بر مدل

هدف از تحلیل خوشه‌ای، طبقه‌بندی مجموعه داده‌ها بر اساس مقدار تشابه یا عدم تشابه بین گروه داده‌ها است؛ به طوری که اعضای گروه در داخل هر گروه، همگن و در خارج از آن مجزا هستند. در این مطالعه، مدل مبتنی بر خوشه که یک روش خوشه‌بندی سلسله‌مراتبی تجمعی است، استفاده شده است (بنفیلد و رفتی،

جدول ۱، چهار تبدیل استاندارد توابع کرنل را که اغلب در مدل‌سازی و رگرسیون به کار می‌روند، نشان می‌دهد. انتخاب مناسب تابع کرنل امکان استفاده از یک تابع غیرخطی در فضای ورودی‌ها را برای تبدیل به تابع خطی در فضای ویژگی‌ها فراهم می‌کند.

در مدل رگرسیونی SVM لازم است، وابستگی تابع  $y$  به مجموعه‌ای از متغیرهای مستقل  $X$  تخمین زده شود. دو نمونه متداول از مدل‌های SVM عبارت‌اند از: مدل‌های رگرسیونی SVM نوع اول، مدل Nu-SVM و مدل‌های رگرسیونی Epsilon-SVM (نوری و همکاران، ۲۰۱۱).

جدول ۱. انواع توابع کرنل استفاده‌شده (کریستیانینی و تیلور، ۲۰۰۰).

| شکل تابع   | نوع کرنل   |
|--|------------|
| $f(x_i, x) = \langle x_i, x \rangle$               | خطی        |
| $f(x_i, x) = (1 + x_i x)^k$                        | چندجمله‌ای |
| $f(x_i, x) = e^{-\frac{\ x_i - x\ ^2}{2\sigma^2}}$ | رادیال     |
| $f(x_i, x) = \tanh [f(x_i, x) + \theta]$           | سیگموئید   |

#### ۵. روش کار

مراحل تخمین تراوایی به‌طور خلاصه به صورت زیر است:

مرحله اول: انتخاب مجموعه نگارهای مناسب و آماده‌سازی داده‌ها.

مرحله دوم: خوشه‌بندی داده‌ها که شامل تحلیل مؤلفه‌های اصلی (PCA) و کاهش مقدار داده‌ها، بدون کاهش قابل توجه در تنوع آن‌ها و در نهایت، مشخص کردن رخساره‌های الکتریکی با تحلیل خوشه‌ای (MCA) است.

مرحله سوم: پیش‌بینی تراوایی با استفاده از روش‌های شبکه عصبی و SVM و مقایسه آن‌ها با داده‌های مغزه.

#### ۵-۱. مرحله اول

در این مطالعه از اطلاعات چاه‌نگاری و داده‌های مغزه مربوط به چهار حلقه چاه استفاده شده است. نگارهای چاه مورد استفاده عبارت‌اند از: نگارهای گاما (GR)، نوترون (NPHI)، چگالی (RHOB)، صوتی (DT)، مقاومت ویژه لثرولاگ عمیق (LLD)، مقاومت ویژه

پس‌انتشار لونبرگ-مارکوارت و تابع یادگیری GDM با ۱۰ لایه مخفی استفاده شده است. همچنین، تابع انتقال آن، تابع سیگموئید تانژانت هیپربولیک است. در این مطالعه، از ۱۵ درصد داده‌ها برای آزمایش، ۱۵ درصد داده‌ها برای تصحیح و ۷۰ درصد داده‌ها برای آموزش شبکه استفاده شده است. برای تعیین عملکرد شبکه از دو خطای میانگین مربع و خطای میانگین مربع نرمال شده استفاده شده است. این خطاها به ترتیب در معادلات ۳ و ۴ آورده شده است.

$$MSE = \frac{1}{n} \sum (y - y')^2 \quad (3)$$

$$NMSE = \frac{n \sum (y - y')^2}{\sum y \sum y'} \quad (4)$$

#### ۴. ماشین بردار پشتیبان (SVM)

ماشین‌های بردار پشتیبان که نخستین بار توسط واپنیک در سال ۱۹۹۵ معرفی گردید، مجموعه‌ای از روش‌های یادگیری با نظارت هستند که برای دسته‌بندی و رگرسیون داده‌ها استفاده می‌شوند. این روش بر پایه نظریه یادگیری محاسباتی توسعه یافته است. در این روش، داده‌ها به صورت خطی توسط معادله ۵ نمایش داده می‌شوند:

$$y = \text{sign} \left( \sum_{i=1}^n y_i \alpha_i (X \bullet X_i) + b \right) \quad (5)$$

که در آن،  $y$  خروجی معادله،  $y_i$  ارزش طبقه نمونه آموزشی  $X_i$  و علامت «•» نشان‌دهنده ضرب داخلی است. بردار  $X = (x_1, x_2, \dots, x_n)$  نشان‌دهنده یک داده ورودی و بردارهای  $X_i, i=1, \dots, N$  بردارهای پشتیبان هستند. در رابطه ۵، مؤلفه‌های  $b, \alpha_i$  تعیین‌کننده ابر صفحه هستند. اگر داده‌ها به صورت خطی تفکیک‌پذیر نباشند، رابطه ۵ به رابطه ۶ تغییر پیدا می‌کند:

$$y = \text{sign} \left( \sum_{i=1}^n y_i \alpha_i K(X \bullet X_i) + b \right) \quad (6)$$

که در آن،  $K(X \bullet X_i)$  تابع کرنلی است که برای ایجاد ماشین‌هایی با انواع مختلفی از سطوح تصمیم‌گیری غیرخطی در فضای داده‌ها استفاده می‌شود.

تحلیل مؤلفه‌های اصلی، PCA، اغلب روش مناسبی برای شناسایی مؤلفه‌های اصلی است. شکل ۱ نتایج حاصل از کاربرد تحلیل مؤلفه‌های اصلی بر روی داده‌های چاه‌های مدنظر را نشان می‌دهد. همان‌طور که در شکل ۱ نشان داده شده است، ۴ مؤلفه اصلی، ۹۴/۲ درصد از تنوع کل داده‌ها را توصیف می‌کنند. با توجه به مطالعات پتروفیزیکی انجام گرفته بر روی میدان مورد مطالعه، از نظر نوع دانه‌بندی، بخش‌های مختلف سیستم رسوبی سازند مخزنی مورد نظر نیز به ۴ گروه تقسیم‌بندی شده‌اند (جدول ۲). از این‌رو، تعداد خوشه‌های انتخاب‌شده (۴ خوشه) با اطلاعات زمین‌شناسی و پتروفیزیکی سازند مخزنی مطابقت دارند و به همین دلیل، رخساره‌های الکتریکی سازند مخزنی، به ۴ گروه تقسیم‌بندی شده‌اند (جدول ۲).

جدول ۲. تقسیم‌بندی بخش‌های مختلف سیستم رسوبی سازند مورد مطالعه از نظر نوع دانه‌بندی و رخساره‌های مختلف آن.

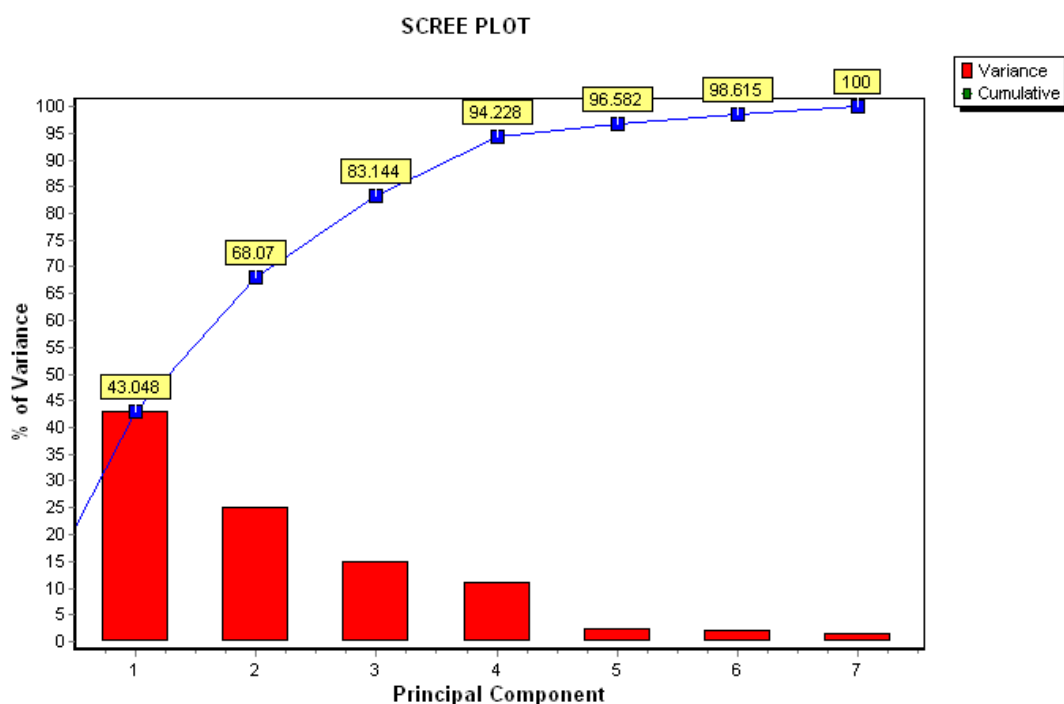
|                            |               |
|----------------------------|---------------|
| پکستون - وکستون - مادستون  | جزر و مد صاف  |
| پکستون - وکستون            | پلت فرم داخلی |
| گرینستون - پکستون          | تپه رودیست    |
| گرینستون - پکستون - وکستون | پلت فرم باز   |

لترولاگ کم عمق (LLS) و مقاومت ویژه کروی میکرو (MSFL).

قبل از ورود داده‌ها به شبکه‌های عصبی و ماشین بردار پشتیبان، یکسری تصحیحات و عملیات مقدماتی بر روی داده‌ها جهت حصول جواب قابل اطمینان انجام گرفته است. این عملیات شامل حذف داده‌های نامناسب، هماهنگ‌سازی بین نتایج اندازه‌گیری‌ها در مغزه و نگارها و همچنین، تطابق عمق بین نگارهای چاه و مغزه است. با توجه به مطالعات پتروفیزیکی انجام گرفته بر روی میدان مورد مطالعه از نظر نوع دانه‌بندی، بخش‌های مختلف سیستم رسوبی سازند مورد نظر در این مطالعه را می‌توان به ۴ گروه تقسیم‌بندی کرد (جدول ۲). از این‌رو، رخساره‌های الکتریکی نیز به ۴ گروه تقسیم‌بندی شده‌اند. برای تعیین و تشخیص رخساره‌های الکتریکی معمولاً استفاده از نگار PEF نتایج قابل قبولی را به همراه دارد. ولی از آنجایی که در این مطالعه این نگار در دسترس نبوده است، سعی شده است تا از ترکیب نگارهای مختلف جهت جبران این کمبود استفاده شود.

## ۲-۵. مرحله دوم

### ۱-۲-۵. تحلیل مؤلفه‌های اصلی (PCA)

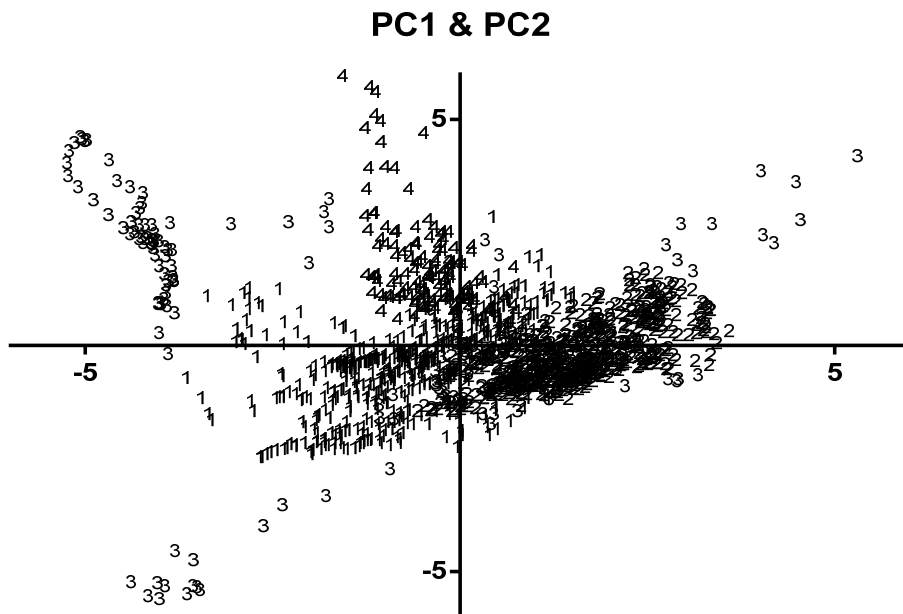


شکل ۱. نمودار میله‌ای واریانس‌های واریانس‌های مؤلفه‌های اصلی داده‌های چاه‌های مورد مطالعه.

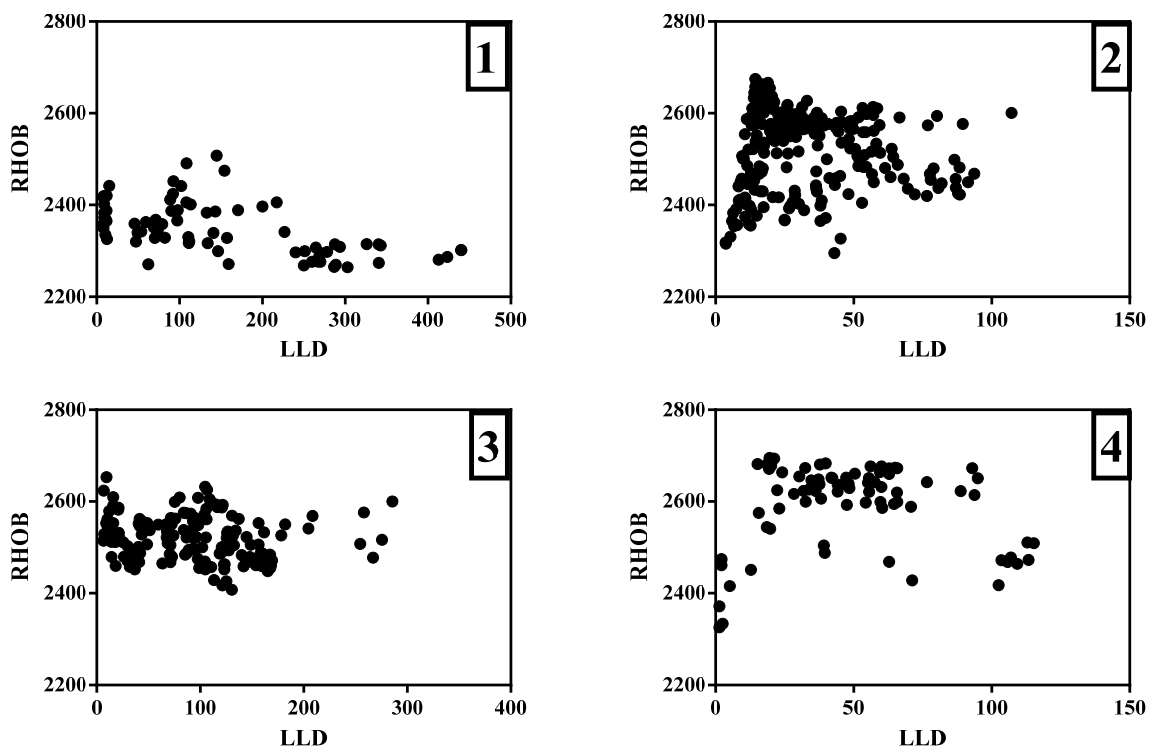
۲-۲-۵. تحلیل خوشه‌ای مبتنی بر مدل (MCA)

تحلیل خوشه‌ای مبتنی بر مدل برای تعریف چهار گروه مجزا بر اساس ویژگی‌های منحصربه‌فرد از داده‌های اندازه‌گیری شده در نگاره‌های چاه استفاده می‌شود. شکل ۲، هر خوشه را به صورت یک رخساره

الکتریکی که نشان‌دهنده ویژگی‌های هیدرولوژیکی، رخساره سنگی و دیاژنتیکی است، نشان می‌دهد. همچنین، در شکل ۳، کراس پلات دو نگاره اصلی ROHB و LLD برای خوشه‌های ۱ تا ۴ آورده شده است.



شکل ۲. چگونگی توزیع رخساره‌های الکتریکی برحسب PC1 و PC2 (اعداد، گروه‌های رخساره‌های الکتریکی را نشان می‌دهند).



شکل ۳. کراس پلات نگاره‌های اصلی ROHB و LLD برای خوشه‌های ۱ تا ۴.

تصحیح میزان خطای واقعی بایستی از خطای میانگین مربع نرمال‌شده استفاده شود. به دلیل مشخص نبودن داده‌های آموزشی، اعتبارسنجی و آزمایشی (این داده‌ها به طور تصادفی توسط شبکه انتخاب می‌شوند)، در این نوع شبکه امکان محاسبه خطای نرمال‌شده فراهم نبوده است.

شکل ۴، پروفایل تراوایی برحسب عمق را برای داده‌های واقعی و برآوردشده از شبکه عصبی نشان می‌دهد. همان‌طور که مشاهده می‌شود، روند کلی تغییرات تراوایی توسط روش شبکه عصبی به خوبی پیش‌بینی شده است، ولی به نظر می‌رسد، یک مقدار ثابت تقریباً به اندازه ۳۰ میلی‌داریسی، به مقادیر تراوایی کمتر از ۱۰۰ میلی‌داریسی اضافه شده است.

۳-۵. مرحله سوم



۳-۵-۱. تخمین تراوایی برای رخساره‌های الکتریکی گروه ۱

۳-۵-۱-۱. تخمین تراوایی با استفاده از شبکه عصبی مصنوعی

روش شبکه عصبی پس‌انتشار با ده لایه مخفی برای داده‌های رخساره‌های الکتریکی گروه ۱ به کار گرفته شده است. خطای میانگین مربع و ضریب همبستگی مدل ایجادشده در شبکه عصبی برای داده‌های آموزشی، اعتبارسنجی و آزمایشی در جدول ۳ آمده است. همان‌طور که مشاهده می‌شود، خطای موجود بسیار بیشتر از حد معمول است که این امر به دلیل نرمال‌نبودن داده‌های ورودی و خروجی است. از این‌رو، برای

جدول ۳. خطاهای میانگین مربع و ضریب همبستگی مدل ایجادشده در شبکه عصبی برای رخساره‌های الکتریکی گروه ۱.

|          | MSE     | NMSE    | R <sup>2</sup> |
|----------|---------|---------|----------------|
| Train    | 1225.48 | -       | 95.8           |
| Validate | 5962.66 | -       | 79.5           |
| Test     | 619.98  | -       | 71.5           |
| Total    | -       | 13.7861 | 91.18          |




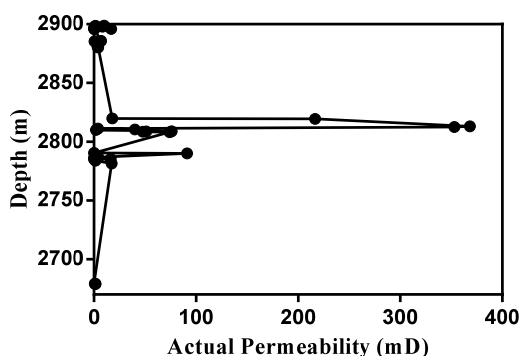
شکل ۴. پروفایل تراوایی برحسب عمق برای داده‌های واقعی (چپ) و تخمینی (راست) رخساره‌های الکتریکی گروه ۱ با روش شبکه عصبی.

روش SVM برای رخصاره‌های الکتریکی گروه ۱ با استفاده از مدل‌های رگرسیونی Nu-SVR و Epsilon-SVR را نشان می‌دهد. توابع کرنل به کاررفته در اینجا، شامل کرنل‌های خطی، شعاعی، چندجمله‌ای درجه سه و سیگنوییدی هستند. همان‌طور که در جدول ۴ مشاهده می‌شود، رگرسیون به دست آمده از تابع کرنل شعاعی (RBF) برای کل داده‌ها (۹۰/۴۲۴) دارای کمترین خطای میانگین مربع نرمال شده (۰/۰۰۶۵) است. در شکل ۵، پروفایل تراوایی برحسب عمق برای داده‌های واقعی و تخمین زده‌شده توسط ماشین بردار پشتیبان آورده شده است. همان‌طور که ملاحظه می‌شود بیشتر نقاط به خوبی پیش‌بینی شده‌اند.

۵-۳-۱-۲. تخمین تراوایی با استفاده از ماشین بردار پشتیبان  
در این مطالعه، برای کاربرد روش SVM، از ۲۵ درصد داده‌ها برای آزمایش شبکه و ۷۵ درصد داده‌ها برای آموزش شبکه استفاده شده است. با توجه به کاربرد روزافزون روش ماشین بردار پشتیبان در تخمین پارامترهای صنعت نفت، استفاده از ۷۵ درصد داده‌ها جهت آموزش شبکه توسط محققان دیگر (مهیاری و صنیعی، ۱۳۹۳ و فتاحی و بیات‌زاده، ۱۳۹۵) توصیه شده است. همچنین، در این پژوهش بهترین نتایج زمانی حاصل شد که ۷۵ درصد داده‌ها برای آموزش شبکه استفاده شد. جدول ۴، مقدار خطا و ضریب همبستگی

جدول ۴. مقدار خطا و ضریب همبستگی در روش SVM برای رخصاره‌های الکتریکی گروه ۱.

|                             | Nu-SVR |             |        |        | Epsilon-SVR |             |        |        |
|-----------------------------|--------|-------------|--------|--------|-------------|-------------|--------|--------|
|                             | Model% | Validation% | Total  | NMSE   | Model%      | Validation% | Total  | NMSE   |
| Linear                      | 76.298 | 72.498      | 74.937 | 3.5851 | 76.110      | 64.316      | 71.705 | 0.2471 |
| Radial Basis Function (RBF) | 95.598 | 70.973      | 86.236 | 0.1373 | 98.901      | 76.629      | 90.424 | 0.0065 |
| Polynomial, degree = 3      | 95.551 | 72.664      | 86.852 | 0.2613 | 98.900      | 83.423      | 93.010 | 0.1501 |
| Sigmoid                     | 74.580 | 71.690      | 73.571 | 7.1719 | 76.573      | 71.913      | 74.883 | 0.0428 |



شکل ۵. پروفایل تراوایی برحسب عمق برای داده‌های واقعی (چپ) و تخمین زده‌شده (راست) از داده‌های رخصاره‌های الکتریکی گروه ۱ توسط روش SVM.



علی‌رغم اینکه شبکه عصبی برای این گروه رخساره‌های الکتریکی رگرسیون قابل قبولی را ارائه می‌دهد، ولی خطای MSE و NMSE در این روش بسیار زیاد است و قابل قبول نیست.

در شکل ۶، پروفایل تراوایی برحسب عمق برای داده‌های واقعی و تخمین زده شده توسط شبکه عصبی آمده است. همان‌طور که مشاهده می‌شود، در برخی عمق‌ها شبکه قادر به پیش‌بینی درست برخی از نقاط نبوده است؛ این امر می‌تواند به دلیل مقادیر زیاد خطاهای MSE و NMSE باشد.

۳-۱-۳-۵. مقایسه روش‌های استفاده شده در تخمین تراوایی برای رخساره‌های الکتریکی گروه ۱ در جدول ۵، نتایج به دست آمده از روش‌های ANN و SVM برای رخساره‌های الکتریکی شماره ۱ با یکدیگر مقایسه شده‌اند. نتایج بیانگر آن است که روش SVM در پیش‌بینی تراوایی در مقایسه با روش ANN خطای کمتری دارد.



۳-۲-۵. تخمین تراوایی برای رخساره‌های الکتریکی گروه ۲ همان‌طور که در جدول ۶ نشان داده شده است،

جدول ۵. مقایسه نتایج به دست آمده از دو روش ANN و SVM برای رخساره‌های الکتریکی شماره ۱.

|                |       | ANN   | SVM    |
|----------------|-------|-------|--------|
| R <sup>2</sup> | Train | 95.8  | 98.9   |
|                | Test  | 79.5  | 76.6   |
| NMSE           | Total | 13.79 | 0.0065 |

جدول ۶. خطای میانگین مربعی و ضریب همبستگی مدل ایجاد شده در شبکه عصبی برای رخساره‌های الکتریکی گروه ۲.

|          | MSE    | NMSE    | R <sup>2</sup> |
|----------|--------|---------|----------------|
| Train    | 62.09  | -       | 93.8           |
| Validate | 191.24 | -       | 90.8           |
| Test     | 619.98 | -       | 88.05          |
| Total    | -      | 11.8629 | 85.34          |



شکل ۶. پروفایل تراوایی برحسب عمق برای داده‌های واقعی (چپ) و تخمینی (راست) رخساره‌های الکتریکی گروه ۲ با روش شبکه عصبی.

تخمین تراوایی با استفاده از ماشین بردار پشتیبان برای گروه رخساره‌های الکتریکی ۲ در جدول ۷ ارائه شده است. رگرسیون به دست آمده از تابع کرنل شعاعی (RBF) برای کل داده‌ها (۹۲/۲) دارای کمترین خطای میانگین مربع نرمال شده (۰/۰۲۴۲) است. توابع کرنل خطی و سیگموئید برای این گروه رخساره‌های الکتریکی قادر به پیش‌بینی تراوایی نبوده‌اند.


در شکل ۷، پروفایل تراوایی برحسب عمق برای داده‌های واقعی و تخمین زده شده توسط ماشین بردار پشتیبان آورده شده است.

در جدول ۸ نتایج به دست آمده از ۲ روش ANN و SVM برای رخساره‌های الکتریکی شماره ۲ با یکدیگر مقایسه شده‌اند. نتایج نشان می‌دهند که روش SVM در پیش‌بینی تراوایی در مقایسه با شبکه عصبی مقدار خطای

کمتری (۰/۰۲۴۲) دارد. با توجه به ناهمگونی و ناهمسانی خصوصیات و ویژگی‌های پارامتر هدف (تراوایی) ممکن است که روش‌های مورد استفاده جهت تخمین ناکارآمد باشند. به نظر می‌رسد که روش‌های مورد استفاده در این پژوهش برای این رخساره الکتریکی نتایج قابل قبولی نداشته‌اند. علت اصلی این ناکارآمدی در خصوصیات و ویژگی‌های این رخساره الکتریکی است که حدود ۹۰ درصد از داده‌هایی که در این رخساره قرار گرفته‌اند، در محدوده تراوایی ۰/۰۰۲ تا ۱۹ میلی داریسی است و ۱۰ درصد داده‌ها بین ۱۹ تا ۳۶۱ میلی داریسی است. به نظر می‌رسد که پخش شدن ناهمگون پراکندگی تراوایی در این رخساره الکتریکی سبب ایجاد خطا در تخمین شده است.

جدول ۷. مقدار خطا و ضریب همبستگی برای رخساره‌های الکتریکی گروه ۲ توسط روش SVM.

|                             | Nu-SVR  |              |            |        | Epsilon-SVR |              |            |        |
|-----------------------------|---------|--------------|------------|--------|-------------|--------------|------------|--------|
|                             | Model % | Validation % | Total      | NMS E  | Model %     | Validation % | Total      | NMS E  |
| linear                      | 0.000   | 20.979       | -          | -      | 21.971      | 15.345       | -          | .      |
| Radial Basis Function (RBF) | 97.914  | 87.632       | 92.2       | 0.0242 | 89.559      | 79.188       | 83.84<br>2 | 1.8271 |
| Polynomial , degree = 3     | 83.605  | 86.783       | 85.46<br>6 | 3.5289 | 86.52       | 74.53        | 79.91<br>9 | 5.0144 |
| Sigmoid                     | 0.000   | 11.276       | -          | -      | 0.000       | 4.026        | -          | -      |



شکل ۷. پروفایل تراوایی برحسب عمق برای داده‌های واقعی (چپ) و تخمینی (راست) رخساره‌های الکتریکی گروه ۲ توسط روش SVM.

جدول ۸. مقایسه نتایج به دست آمده از دو روش ANN و SVM برای رخساره‌های الکتریکی شماره ۲.

|                |       | ANN     | SVM    |
|----------------|-------|---------|--------|
| R <sup>2</sup> | Train | 93.8    | 97.914 |
|                | Test  | 88.05   | 87.632 |
| NMSE           | Total | 11.8629 | 0.0242 |

۳-۳-۵. تخمین تراوایی برای رخساره‌های الکتریکی گروه ۳


در جدول ۹، تخمین تراوایی با استفاده از شبکه عصبی مصنوعی برای گروه رخساره‌های الکتریکی ۳ گزارش شده است. همان‌طور که نشان داده شده است، شبکه عصبی برای داده‌های آموزشی این گروه رخساره‌های الکتریکی، رگرسیون بسیار قابل قبولی (۹۹/۵) ارائه داده است، ولی همان‌طور که ملاحظه می‌شود، مقدار خطای MSE و NMSE در این روش قابل قبول نیست. در شکل ۸، پروفایل تراوایی برحسب عمق برای داده‌های واقعی و تخمین زده‌شده توسط شبکه عصبی

آورده شده است. بسیاری از نقاط به خوبی پیش‌بینی شده‌اند که این امر می‌تواند به دلیل آموزش مناسب شبکه باشد.

تخمین تراوایی با استفاده از ماشین بردار پشتیبان برای گروه رخساره‌های الکتریکی ۳ در جدول (۱۰) ارائه شده است. رگرسیون به دست آمده از تابع کرنل شعاعی (RBF) برای کل داده‌ها (۹۳/۱۱۹) و دارای خطای میانگین مربع نرمال شده (۳/۶۵۸۷) است. همچنین توابع کرنل خطی، چندجمله‌ای و سیگموئید برای این گروه رخساره‌های الکتریکی قادر به پیش‌بینی مناسب نبوده‌اند (جدول ۱۰).

جدول ۹. خطای میانگین مربعی و ضریب همبستگی مدل ایجادشده در شبکه عصبی برای رخساره‌های الکتریکی گروه ۳.

|          | MSE   | NMSE   | R <sup>2</sup> |
|----------|-------|--------|----------------|
| Train    | 2.22  | -      | 99.5           |
| Validate | 9     | -      | 73.6           |
| Test     | 149.6 | -      | 85.7           |
| Total    | -     | 5.8090 | 95.17          |



شکل ۸. پروفایل تراوایی برحسب عمق برای داده‌های واقعی (چپ) و تخمینی (راست) رخساره‌های الکتریکی گروه ۳ با روش شبکه عصبی.


جدول ۱۰. مقدار خطا و ضریب همبستگی در روش SVM برای رخساره‌های الکتریکی گروه ۳.

|                             | Nu-SVR  |             |        |        | Epsilon-SVR |             |        |        |
|-----------------------------|---------|-------------|--------|--------|-------------|-------------|--------|--------|
|                             | Model%  | Validation% | Total  | NMSE   | Model%      | Validation% | Total  | NMSE   |
| Linear                      | 14.989  | 0.00        | -      | -      | 45.583      | 16.668      | -      | .      |
| Radial Basis Function (RBF) | 100.000 | 80.943      | 93.119 | 3.6587 | 100.000     | 57.240      | 84.560 | 4.7953 |
| Polynomial, degree = 3      | 100.000 | 0.000       | -      | -      | 100.000     | 0.000       | -      | -      |
| Sigmoid                     | 14.773  | 0.00        | -      | -      | 42.084      | 31.641      | -      | -      |

۴-۳-۵. تخمین تراوایی برای رخساره‌های الکتریکی گروه ۴


گزارش عملکرد شبکه عصبی مصنوعی برای تخمین تراوایی در گروه رخساره‌های الکتریکی ۴ در جدول ۱۲ نشان داده شده است. شبکه عصبی مصنوعی برای داده‌های این گروه رخساره‌های الکتریکی، رگرسیون (۹۴/۳۳) را ارائه داده است، خطای MSE بسیار زیاد و NMSE در این روش (۰/۶۲۸۷) قابل قبول است.

در شکل ۱۰ پروفایل تراوایی برحسب عمق برای داده‌های واقعی و تخمین زده شده توسط شبکه عصبی آمده است. همان‌طور که ملاحظه می‌شود بسیاری از نقاط به خوبی پیش‌بینی شده‌اند.



در شکل ۹، پروفایل تراوایی برحسب عمق برای داده‌های واقعی و تخمین زده شده توسط ماشین بردار پشتیبان برای رخساره‌های الکتریکی ۳ آورده شده است که با توجه به رگرسیون ۱۹۳/۱۱۹ اکثر نقاط به خوبی پیش‌بینی شده‌اند، ولی با توجه به خطای NMSE (۳/۶۵۸۷) برخی نقاط در اعماق کمتر از ۲۷۰۰ متر به خوبی پیش‌بینی نشده‌اند.

در جدول ۱۱، نتایج به دست آمده از دو روش ANN و SVM برای رخساره‌های الکتریکی شماره ۳ با یکدیگر مقایسه شده‌اند. همچنان که مشاهده می‌شود، باز هم نتایج به دست آمده از روش SVM در پیش‌بینی تراوایی دارای مقادیر خطای کمتری در مقایسه با سایر روش‌هاست.





شکل ۹. پروفایل تراوایی برحسب عمق برای داده‌های واقعی (چپ) و تخمینی (راست) رخساره‌های الکتریکی گروه ۳ توسط روش SVM.

جدول ۱۱. مقایسه نتایج به دست آمده از دو روش ANN و SVM برای رخساره‌های الکتریکی شماره ۳.

|                |       | ANN    | SVM    |
|----------------|-------|--------|--------|
| R <sup>2</sup> | Train | 99.5   | 100.00 |
|                | Test  | 85.7   | 80.943 |
| NMSE           | Total | 5.8090 | 3.6587 |

جدول ۱۲. خطای میانگین مربعی و ضریب همبستگی مدل ایجاد شده در شبکه عصبی برای رخساره‌های الکتریکی گروه ۴.

|          | MSE   | NMSE   | R <sup>2</sup> |
|----------|-------|--------|----------------|
| Train    | 0.7   | -      | 99.8           |
| Validate | 12.27 | -      | 70.26          |
| Test     | 89.06 | -      | 88.45          |
| Total    | -     | 0.6287 | 94.33          |



شکل ۱۰. پروفایل تراوایی برحسب عمق برای داده‌های واقعی (چپ) و تخمینی (راست) رخساره‌های الکتریکی گروه ۴ با روش شبکه عصبی.

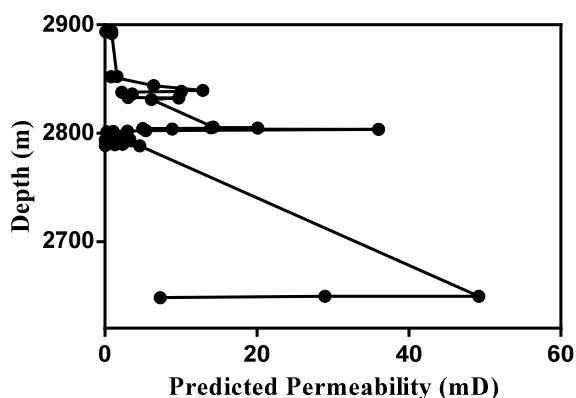

داده‌های واقعی و تخمین زده‌شده توسط ماشین بردار پشتیبان آمده است که با توجه به رگرسیون (۸۷/۳۱۷) و مقدار NMSE (۰/۰۱۹۵) اکثر نقاط به‌خوبی پیش‌بینی شده‌اند.

در جدول ۱۴، نتایج به دست آمده از دو روش ANN و SVM برای رخساره‌های الکتریکی شماره ۴ با یکدیگر مقایسه شده‌اند. همچنان که مشاهده می‌شود، باز هم نتایج به دست آمده از روش SVM در پیش‌بینی تراوایی دارای مقادیر خطای کمتری در مقایسه با ANN است.

عملکرد روش ماشین بردار پشتیبان در تخمین تراوایی گروه رخساره‌های الکتریکی ۴ در جدول ۱۳ آورده شده است. رگرسیون به دست آمده از تابع کرنل شعاعی (RBF) برای کل داده‌ها برابر ۸۷/۳۱۷ و خطای میانگین مربع نرمال شده برابر ۰/۱۹۵ است. همچنین، توابع کرنل چندجمله‌ای برای کل داده‌ها و کرنل سیگموئید در روش Epsilon-SVR برای این گروه الکتر و فاسیس قادر به پیش‌بینی مناسب نبوده‌اند. در شکل ۱۱، پروفایل تراوایی برحسب عمق برای

جدول ۱۳. میزان خطا و ضریب همبستگی در روش SVM برای رخساره‌های الکتریکی گروه ۴.

|                             | Nu-SVR  |             |        |        | Epsilon-SVR |             |        |        |
|-----------------------------|---------|-------------|--------|--------|-------------|-------------|--------|--------|
|                             | Model%  | Validation% | Total  | NMSE   | Model%      | Validation% | Total  | NMSE   |
| Linear                      | 89.175  | 73.678      | 82.998 | 0.0231 | 91.005      | 64.883      | 80.530 | 0.5932 |
| Radial Basis Function (RBF) | 100.000 | 68.556      | 87.317 | 0.0195 | 100.000     | 0.00        | 59.586 | -      |
| Polynomial, degree = 3      | 100.000 | 0.000       | -      | -      | 100.000     | 0.000       | -      | -      |
| Sigmoid                     | 87.520  | 62.834      | 77.648 | 0.5587 | 0.000       | 0.000       | -      | -      |



شکل ۱۱. پروفایل تراوایی برحسب عمق برای داده‌های واقعی (چپ) و تخمینی (راست) رخساره‌های الکتریکی گروه ۴ توسط روش SVM.

جدول ۱۴. مقایسه نتایج به دست آمده از دو روش ANN و SVM برای رخساره‌های الکتریکی شماره ۴.

|                |       | ANN    | SVM    |
|----------------|-------|--------|--------|
| R <sup>2</sup> | Train | 99.8   | 100.00 |
|                | Test  | 88.45  | 68.556 |
| NMSE           | Total | 0.6287 | 0.0195 |

## ۶. نتیجه گیری

هستند.

به طور کلی، در تمامی گروه‌های رخساره‌های الکتریکی، روش SVM دارای خطای کمتری در مقایسه با سایر روش‌هاست. در این روش، تابع کرنل شعاعی در مقایسه با سایر توابع کرنل همبستگی بیشتر و خطای کمتری دارد. در روش SVM از دو مدل Nu-SVR و Epsilon-SVR استفاده شده است که هر کدام برای مدل‌سازی از چهار تابع کرنل خطی، شعاعی، چندجمله‌ای و سیگموئید بهره برده‌اند.

## مراجع

مهیاری، ش.، صنیعی، م.، ۱۳۹۳، آنالیز غربالگری روش‌های مختلف ازدیاد برداشت نفت با استفاده از شبکه‌های عصبی مصنوعی برای تعدادی از مخازن جنوب غرب ایران، ماهنامه علمی-ترویجی اکتشاف و تولید نفت و گاز، ۱۱۵، ۶۲-۶۵.

فتاحی، ه.، بیات زاده، ز.، ۱۳۹۵، پیش‌بینی گشتاور چرخشی مورد نیاز برای انجام عملیات حفاری انحرافی در لایه‌های سنگی با استفاده از ترکیب شبکه عصبی مصنوعی و الگوریتم بهینه‌سازی مبتنی بر جغرافیای زیستی، نشریه روش‌های تحلیلی و عددی در مهندسی معدن، ۱۱.

نتایج حال از مدل‌سازی‌های صورت گرفته با دو روش شبکه عصبی و ماشین بردار پشتیبان برای داده‌های مخزن کربناته نشان می‌دهند که چهار مؤلفه اصلی انتخاب شده برای مدل‌سازی، در حدود ۹۴/۲ درصد از تنوع کل داده‌ها را توصیف می‌کنند که نشانگر استفاده منطقی از تعداد مؤلفه‌ها در جهت مدل‌سازی تراوایی بوده است. در این پژوهش مؤلفه‌های اصلی تحت عنوان رخساره‌های الکتریکی به کار رفتند. در واقع گروه‌هایی از داده‌ها که به‌عنوان یک خوشه تفکیک شده‌اند، به صورت یک رخساره الکتریکی در نظر گرفته شده است. در روش SVM، تابع کرنل شعاعی (RBF) بهترین پیش‌بینی را برای تمام گروه‌های رخساره‌های الکتریکی ارائه کرده است. روش SVM، در رخساره‌های الکتریکی گروه یک و دو دارای بیشترین همبستگی و کمترین درصد خطا در مدل‌سازی است. در رخساره‌های الکتریکی گروه ۳ و ۴، شبکه عصبی دارای همبستگی بهتری در مقایسه با روش SVM است، اما روش SVM خطای کمتری دارد. با این حال، در این داده‌ها به دلیل ناهمگونی مؤلفه هدف، روش‌های مورد نظر با مقدار خطای بیشتری در مقایسه با سایر رخساره‌های الکتریکی قادر به پیش‌بینی مؤلفه هدف

Banfield, J. D. and Raftery, A. E., 1993, Model-based Gaussian and Non-Gaussian Clustering, *Biometrics* 49, No. 3, 803.

Bucheb, J. A. and Evans, H. B., 1994, Some Applications of Method Used in Electrofacies Identification, *The Log Analyst* 35, 14.

Cristianini, N. and Shaw-Taylor, J., 2000, *An Introduction to Support Vector Machines and Other Kernel-Based Learning Methods* (New York: Cambridge University Press) p 189.

Davis, J.C., 2002, *statistics and data analysis in geology* third edition, John Wiley & son, New York City.

Fraley, C. and Raftery, A. E., 1998, *Mclust: Software for Model-Based Cluster and Discriminant Analysis*, Technical Report No. 342, Dept. of Statistics, U. of Washington, Seattle, Washington.

Lee, S. H. and Dutta-Gupta, A., 1999, *Electrofacies Characterization and Permeability Predictions in Carbonate*

*Reservoirs: Role of Multivariate Analysis and Nonparametric Regression*, SPE56658, October.

Lim, Jong-Se, Kang, J. M. and Kim, J., 1997, *Multivariate Statistical Analysis for Automatic Electrofacies Determination from Well Log Measurements*, paper SPE 38028 presented at the SPE Asia Pacific Oil and Gas Conference, Kuala Lumpur, 14-16 April.

Mathisen, Sang Heon Lee and Akhil Datta-Gupta, 2001, *Texas A&M U. Improved Permeability Estimates in Carbonate Reservoirs Using Electrofacies Characterization: A Case Study of the North Robertson Unit, West Texas*.

Mohaghegh, S., Arefi, R. and Ameri, S., 1996, *Virtual measurement of heterogeneous formation permeability using geophysical well log responses*, *The Log Analyst* (Society of Professional Well Log Analysts) pp 32-9.

Nashawi, I. S. and Malallah, A., 2009,

- Improved electrofacies characterization and permeability predictions in sandstone reservoirs using a data mining and expert system approach. *Petrophysics*, 50(03).
- Noori, R., Karbassi, A. R., Moghaddammia, A., Han, D., Zokaei-Ashtiani, M. H., Farokhnia, A. and Ghafari Gousheh, M., 2011, Assessment of input variables determination on the SVM model performance using PCA, Gamma test and forward selection techniques for monthly stream flow prediction. *Journal of Hydrology*, 401, 177-189.
- Ripley, B. D., 1994, *Modern Applied Statistics with S-Plus*, Springer-Verlag, New York City 301.
- Sang Heon Lee, SPE, Arun Kharghoria, SPE, and Akhil Datta-Gupta, 2002, *Electrofacies Characterization and Permeability Predictions in Complex Reservoirs*, June.
- Vapnik, V., 1995, *The Nature of Statistical Learning Theory*, Springer, New York.
- Wolff, M. and Pelissier-Combescure, J. 1982, "FACIOLOG—Automatic Electrofacies Determination," paper presented at the SPWLA Annual Logging Symposium, Corpus Christi, Texas, 6–9 July.

## Permeability Prediction in one of the Iranian Carbonate Oil Reservoir using Artificial Neural Network and Support Vector Machine

Azizi, Y.<sup>1</sup> and Shad Manaman, N.<sup>2\*</sup>

*1. M.Sc. Student, Faculty of Mining Engineering, Sahand University of Technology, Tabriz, Iran*

*2. Assistant Professor of Seismology, Faculty of Mining Engineering, Sahand University of Technology, Tabriz, Iran*

*(Received: 12 Jun 2016, Accepted: 23 May 2017)*

### Summary

Permeability is one of the main parameters in the oil reservoir evaluation that is usually estimated by using well test data and laboratory measurements from the reservoir core samples. However, these methods are very expensive and time consuming, and usually a few number of wells have such information to obtain permeability and other reservoir parameters. Therefore, the prediction and assessment of the reservoir rock permeability using other non-expensive and indirect methods can effectively reduce the exploration and production costs and give us useful information about the permeability of the hydrocarbon reservoirs. Nevertheless, we have to consider that this kind of information may suffer in resolution and the results may have some unacceptable errors in estimation of the permeability. Thus, using proper prediction methods and comparing the obtained results with the permeability from the well test data and laboratory measurements leads to better and reasonable predictions of the permeability in oil and gas reservoirs. Moreover, the type of the reservoir rocks can also severely affect the estimated permeability. Usually the permeability estimation in the sand stone reservoirs is much easier than in carbonate reservoirs, especially in the heterogeneous carbonate reservoirs. This is mostly because of the porosity type and the conditions of depositional environments.

In this regard, using well log data also has important role in the permeability prediction. This is mostly because the well logging tools run in many wells and well log data are more available. Including more data in the prediction process will result in better constrained permeability estimation. Common methods of permeability prediction use empirical equations based on not always sufficient core data. These equations are usually used for a special type of reservoir and may not applicable to various types of reservoirs.

In this study, Artificial Neural Networks (ANN) and Support Vector Machine (SVM) methods are used to estimate permeability parameter in one the Iranian heterogeneous carbonate oil reservoir using well log data from the 4 wells, located in the given oilfield. These wells have 7 common logs that are incorporated in the permeability prediction process. The well log data firstly are classified into 4 electrofacies based on geological studies carried out on the field. The classified electrofacies are as follow: packstone-wackestone, mudstone-packstone, wackestone-grainstone-packstone, grainstone-packstone-wackestone. The classification is done by using Principle Component Analysis (PCA) and Model Based Cluster Analysis (MCA) methods. Then, each group of electrofacies is used as input data for Artificial Neural Networks and Support Vector Machine methods to predict permeability.

Artificial Neural Network (ANN) is trained by using Levenberg-Marquardt back propagation algorithm and Gradient Descent method with Momentum Weight and Bias Learning Function with 10 hidden layers. The Support Vector Machine (SVM) method is implemented using Nu and Epsilon algorithms and different types of kernel functions, such as linear, radial based functions, polynomial and sigmoid functions. Usually, the radial based kernel function gives the best regression with minimum error values. Our results show that, for all of the electrofacies, Support Vector Machine (SVM) method has less error than Artificial Neural Network (ANN) in the regression process. The Support Vector Machine (SVM) errors for the above mentioned Electrofacies are as following: 0.0065, 0.0242, 3.6587 and 0.0195 respectively.

**Keywords:** Permeability, Electrofacies, Support Vector Machine, Artificial Neural Network, Regression, Well Logs.