

## استفاده از رگرسیون بردار پشتیبان بر پایه کرنل گاوسی برای مدل‌سازی تخلخل مخزن در یکی از میادین نفتی ایران

مهدی رفیعی<sup>۱</sup>، مجید باقری<sup>۲\*</sup> و مجید نبی‌بدهندی<sup>۳</sup>

۱. دانشجوی کارشناسی ارشد، گروه فیزیک زمین، مؤسسه ژئوفیزیک، دانشگاه تهران، تهران، ایران

۲. استادیار، گروه فیزیک زمین، مؤسسه ژئوفیزیک، دانشگاه تهران، تهران، ایران

۳. استاد، گروه فیزیک زمین، مؤسسه ژئوفیزیک، دانشگاه تهران، تهران، ایران

(دریافت: ۹۹/۱۰/۵، پذیرش نهایی: ۱۴۰۰/۶/۲۹)

### چکیده

تراوایی، تخلخل و رخساره‌های رسوبی فاکتورهای اساسی مشخصه‌های مخزنی هستند. تخلخل نمایانگر توانایی سنگ در ذخیره سیالات است. رویکردهای زیادی برای رگرسیون‌های خطی/غیرخطی از جمله شبکه‌های عصبی در سال‌های اخیر بسیار مورد توجه بوده‌اند، شبکه عصبی پرسپترون چندلایه (MLP) یکی از این شبکه‌ها می‌باشد که توانایی خود را به اثبات رسانده است ولی هر کدام از این روش‌ها معایبی دارند. در این تحقیق روش ماشین بردار پشتیبان (SVM) به‌عنوان روش اصلی برای رگرسیون و تخمین تخلخل مخزن در یکی از مخازن هیدروکربنی به کار گرفته شده است. این روش با روش پرسپترون چندلایه مقایسه شده است و نتایج هر کدام مورد بررسی قرار گرفته‌اند. برای این کار ابتدا هر کدام از ماشین‌های مورد نظر برای تخمین تخلخل در محل چاه به کار گرفته شده‌اند و نتایج اولیه باهم مقایسه شدند. نتایج اولیه رگرسیون بردار پشتیبان توانایی بالاتری نسبت به پرسپترون چندلایه نشان داد. برای این کار بردار پشتیبان بر پایه کرنل‌های مختلف مورد استفاده قرار گرفت که تابع کرنل گاوسی نتایج بهتری حاصل کرد و نهایتاً برای مدل‌سازی سه‌بعدی تخلخل به کار گرفته شد. برای تهیه یک نقشه سه‌بعدی به داده‌های لرزه‌ای و نشانگرهای استخراج شده مناسب از روی آن نیاز می‌باشد. بررسی و مقایسه نتایج نشان داد که هر دو ماشین‌های پرسپترون چندلایه و بردار پشتیبان از توانایی بالایی برخوردار هستند ولی رگرسیون بردار پشتیبان با توجه به قدرت تخمین بالا نتایج بهتری حاصل کرد.

واژه‌های کلیدی: تخلخل، رگرسیون، شبکه عصبی پرسپترون چندلایه، ماشین بردار پشتیبان، نشانگرهای لرزه‌ای، نگارهای چاه.

### ۱. مقدمه

بهترین روش برای به دست آوردن مقادیر دقیق از این سه فاکتور اندازه‌گیری مستقیم آنها در آزمایشگاه است. به‌رحال این روش معایبی دارد: هزینه زیاد، زمان‌بر بودن، عدم دسترسی به کل عمق چاه. به‌همین دلیل زمین‌شناسان تنها از تعدادی از چاه‌ها و از بازه‌ای خاص مغزه‌گیری می‌کنند (موری و لیت، ۲۰۱۸). زمین‌شناسان عموماً از یک رویکرد آماری شامل رگرسیون چندگانه خطی یا غیرخطی برای مرتبط کردن مشخصه‌های مخزن به همدیگر استفاده می‌کنند (بالان و همکاران، ۱۹۹۵). در این زمینه‌ها یک رابطه خطی یا غیرخطی بین تخلخل با سایر مشخصه‌های مخزن فرض می‌شود (ژی و همکاران، ۲۰۱۵). به‌رحال این تکنیک‌ها برای مسائل مشخصی همچون مخازن ناهمگن ناکافی هستند (البازا و همکاران،

مشخصه‌های مخزنی می‌توانند به سه گروه تقسیم شوند: مشخصه‌های زمین‌شناسی (ساختار، سنگ‌پوش، سنگ‌شناسی، دیاژنز)، داده‌های مهندسی (فاصله‌بندی چاه، یکپارچگی حفر چاه و غیره)، ویژگی‌های مربوط به سنگ و سیالات درون آن (تخلخل، تراوایی، مقاومت و غیره) (سیپل، ۲۰۰۳). تخلخل، تراوایی و رخساره‌های رسوبی فاکتورهای کلیدی برای مدل‌سازی مخزن هستند (حسینی و همکاران، ۲۰۱۹). تخلخل به‌عنوان نسبت حجم منافذ به حجم سنگ تعریف شده است و معمولاً به‌صورت درصد بیان می‌شود. تراوایی توانایی سنگ متخلخل در انتقال سیال است که بیشتر به ارتباط بین منافذ سنگ به یکدیگر بستگی دارد (لینکی و همکاران، ۲۰۱۸) تا اندازه منافذ و به تخلخل مؤثر وابسته‌تر از تخلخل کل است.

(۲۰۰۷). اخیراً دانشمندان علوم زمین از روش‌های هوش مصنوعی (AI) به‌خصوص شبکه‌های عصبی (NNs) برای پیش‌بینی مشخصات مخزن بهره برده‌اند. شبکه‌های عصبی به‌طور گسترده‌ای در زمینه‌های مختلف علوم و مهندسی مورد استفاده قرار گرفته‌اند. در صنعت نفت شبکه‌های عصبی برای پیش‌بینی شدت گسل‌خوردگی (علی، ۱۹۹۴)، برای توسعه میدین نفتی (دوین، ۱۹۹۸)، برای تجزیه و تحلیل رخساره‌های رسوبی (تامباسو، ۲۰۰۴)، برای پیش‌بینی اشباع آب دست‌نیافتنی (بین و جوتن، ۲۰۰۰)، پیش‌بینی هیدرولیک حفرچاه (لیفارت و هارت، ۲۰۰۱)، و برای بقیه اهداف مثل بهینه‌سازی طراحی تزریق هیدرولیک، توصیف کردن مخازن نفت و گاز، بهینه‌سازی عملیات حفر چاه، تفسیرنگار چاه‌پیمایی، تولیدنگارهای رزونانس مغناطیسی مجازی و انتخاب چاه‌های واجد شرایط برای شبیه‌سازی مخزن همواره مورد توجه بوده‌اند. شبکه‌های عصبی مصنوعی ابزارهای قدرتمندی برای مدل‌سازی سیستم‌های پیچیده و غیرخطی هستند. آنها سیستم‌های توزیع‌پذیر و موازی هستند که در مسائل تشخیص الگو بسیار مفیدند (غلامی و انصاری، ۲۰۱۷؛ کومار و همکاران ۲۰۱۶). آنها قادر به پیش‌بینی روابط پیچیده بین چندین متغیر (به‌عنوان مثال بین‌نگارهای چاه و نشانگرهای لرزه‌ای، تراوایی، تخلخل و نوع سنگ) هستند (هومل و همکاران ۲۰۱۸). به‌رحال شبکه‌های عصبی همانند جعبه سیاه هستند که از توابع فعال‌سازی از پیش تعریف شده استفاده می‌کنند (اما با پارامترهایی که در طول آموزش شبکه قابل تغییرند) و از یک معماری از پیش تعریف شده (تعداد لایه‌های پنهان، تعداد نورون‌ها در هر لایه) برخوردارند که بدون در نظر گرفتن مشخصات خاص پدیده‌ای که مدل‌سازی شده است عمل می‌کنند.

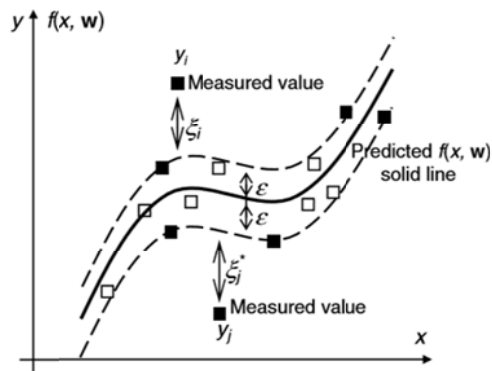
البازا و همکاران (۲۰۰۷) یک مدل شبکه عصبی برای تخمین تراوایی از داده‌های چاه‌پیمایی طراحی کردند. سقاف و همکاران (۲۰۰۳) برای شناسایی نوع رخساره‌های سنگی در یک چاه نفت از یک شبکه عصبی توزیع شده استفاده کردند. سوتو و همکاران (۲۰۰۰) یک سیستم

ترکیبی را ارائه دادند که شامل سه شبکه عصبی تطبیقی و یک سیستم پیشرفته قاعده‌مند برای شناسایی رخساره‌ها از داده‌های چاه بود. بولاندی و همکاران (۲۰۱۷) با استفاده از شبکه‌های عصبی اطلاعات سنگ‌شناسی را از داده‌های چاه به‌دست آوردند. پرین و همکاران (۲۰۰۷) از شبکه‌های عصبی برای پیش‌بینی تراوایی در یک میدان گازی دریایی در ساحل کانادا استفاده کرده است. هومل و همکاران (۲۰۱۸) از شبکه عصبی برای پیش‌بینی تخلخل و تراوایی در یک مخزن گازی با تراوایی کم، بر اساس داده‌های چاه‌نگاری استفاده کرده است. امین‌زاده و براور (۲۰۰۶) از یک شبکه عصبی پس انتشار خطا برای پیش‌بینی تراوایی از تخلخل و اندازه متوسط خلل و فرج و اطلاعات کانی‌شناسی استفاده کرده است. شوتز و همکاران (۱۹۹۴) برای به‌دست آوردن مشخصات مخزن به کلیات تکنولوژی محاسبات کامپیوتری که شامل شبکه عصبی و منطق فازی و الگوریتم‌های تکاملی بود پرداخته است. حسینی و همکاران (۲۰۱۹) مفهومی از آنالیز آماری چند متغیره مجتمع، شبکه عصبی و منطق فازی برای پیش‌بینی مشخصات مخزن از چاه‌های مغزه‌گیری نشده توسعه داده‌اند. سوتو و همکاران (۲۰۰۱) از ماشین بردار پشتیبان و منطق فازی برای پیش‌بینی تخلخل و تراوایی از داده‌های چاه بهره برده‌اند. بولاندی و همکاران (۲۰۱۷) با بهره‌گیری از ماشین بردار پشتیبان و به‌کارگیری داده‌های چاه‌نگاری و مغزه به تحلیل رخساره‌های رسوبی در مخزن پرداخته‌اند. اشافی و غریب (۲۰۰۷) برای شناسایی پتانسیل هیدروکربنی یک مخزن شیلی و سنگ ماسه‌ای از ماشین بردار پشتیبان استفاده کردند.

## ۲. روش پژوهش

ماشین بردار پشتیبان اولین بار توسط کورتس و وپنیک (۱۹۹۵) برای کلاس‌بندی داده‌ها بر اساس بیشترین حاشیه معرفی شد. با توجه به توانایی بالای این الگوریتم بعدها برای رگرسیون و تخمین توابع پیش‌بینی مورد استفاده قرار گرفت. ماشین‌های برداری پشتیبان ماشین‌های یادگیری

بود.



شکل ۱. نمایشی از برازش غیرخطی و تیوب وپنیک به شعاع  $\epsilon$ . بردارهای پشتیبان می‌توانند روی تیوب یا خارج از آن قرار بگیرند (ونگ، ۲۰۰۵).

برای اندازه‌گیری برازش، باید عبارت خطای  $R_{emp}$  به کمک تابع خطای وپنیک  $\epsilon-insensitivity$  مینیمم شود:

$$R_{emp}^{\epsilon}(w, b) = \frac{1}{l} \sum_{i=1}^l |y_i - w^T x_i - b|_{\epsilon} \quad (3)$$

بعد از حل معادلات و بازنویسی روابط،  $w_0$  به صورت زیر به دست می‌آید:

$$w_0 = \sum_{i=1}^l (\alpha_i - \alpha_i^*) x_i \quad (4)$$

که در آن  $\alpha_i$  و  $\alpha_i^*$  ضرایب لاگرانژ می‌باشند. نهایتاً تابع تصمیم به صورت زیر به دست می‌آید:

$$f(x, w) = w_0^T x + b = \sum_{i=1}^l (\alpha_i - \alpha_i^*) x_i^T x + b \quad (5)$$

### ۳. اعمال روش و نتایج

در این مطالعه از مجموعه داده‌های آموزشی با دسترسی آزاد نرم‌افزار Petrel استفاده شده است. این داده‌ها شامل نگار چاه، تخلخل و تراوایی به دست آمده از مغزه و داده‌های یک عملیات لرزه‌ای سه‌بعدی است. منطقه مورد مطالعه دارای ۷ چاه است که ۳ چاه آن مغزه‌گیری شده. در این تحقیق از دو چاه با نام‌های چاه شماره ۱ و چاه شماره ۲ با مجموع ۱۴۵ داده نمونه برداری شده، استفاده شده است. این داده‌ها مورد بررسی قرار گرفته‌اند و تحلیل آماری بر روی آنها انجام شده است تا الگوهای ناپیدا و

هستند که اصل القایی کمینه‌سازی ریسک ساختاری (SRM) را برای به دست آوردن تعمیم خوبی از روی تعداد محدودی الگوی یادگیری اجرا می‌کنند. برای داده پراکنده با ابعاد بالا ماشین‌های برداری پشتیبان تعمیم‌دهی بهتری نسبت به تخمین زنده‌های غیرخطی قدیمی دارند که اصل القایی ریسک تجربی را استفاده می‌کنند.

ماشین بردار پشتیبان به طور موفقیت‌آمیزی در تشخیص الگو، رگرسیون گیری، پردازش سیگنال و شناسایی سیستم به کار گرفته شد و در اکثر مواقع نتایجی به‌خوبی و یا حتی بهتر از شبکه‌های عصبی تولید می‌کنند، در حالی که عموماً از نظر محاسباتی آسان‌ترند و یک تابع ریاضی حقیقی تولید می‌کند.

### ۱-۲. رگرسیون بردار پشتیبان

اگر یک مجموعه داده در فضای دوبعدی به صورت  $(x_1, y_1), (x_2, y_2), \dots, (x_l, y_l)$  در نظر گرفته شود، صفحه خطی برازش به صورت زیر تعریف می‌شود:

$$f(x, w) = w^T x + b \quad (1)$$

برخلاف کلاسه‌بندی که ماکزیم‌شدن حاشیه اندازه گرفته می‌شود در برازش، خطای تقریب اندازه گرفته می‌شود. برخلاف روش‌های قدیمی برازش، در روش‌های جدید از یک تابع خطا استفاده می‌شود. در اینجا از تابع خطای خطی وپنیک (Vapnik) با زون  $\epsilon-insensitivity$  استفاده می‌شود به صورت زیر:

$$E(x, y, f) = |y - f(x, w)|_{\epsilon} = \begin{cases} 0 & \text{if } |y - f(x, w)| \leq \epsilon \\ |y - f(x, w)| - \epsilon & \text{otherwise} \end{cases} \quad (2)$$

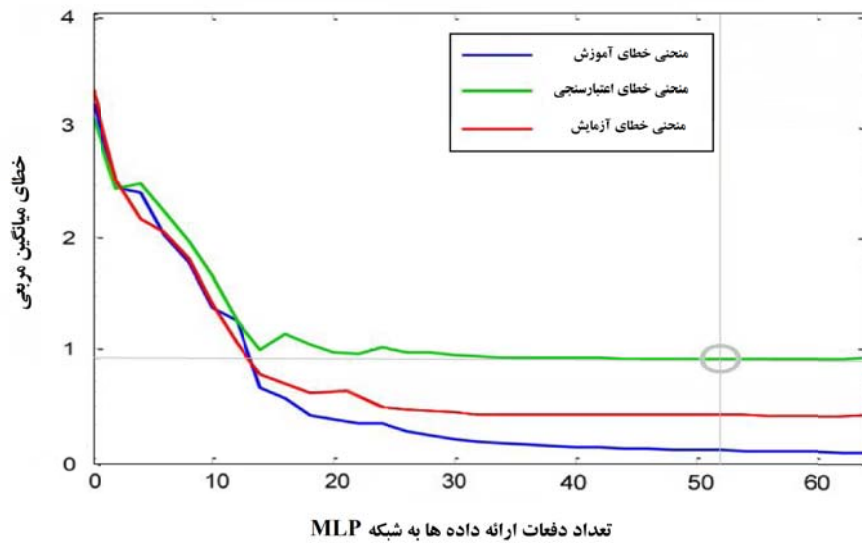
بنابراین تابع خطای وپنیک یک تیوب به شعاع  $\epsilon$  تعریف می‌کند. اگر مقدار تخمین زده شده داخل تیوب باشد، مقدار تابع خطا صفر خواهد بود و اگر مقدار تخمین زده شده، خارج از تیوب باشد، مقدار خطا برابر بزرگی اختلاف بین مقدار تخمین زده شده و شعاع تیوب خواهد

روابط بامعنا بین خروجی‌های حقیقی و مشخصه‌های ورودی مشخص ارزیابی شوند. این امر سبب به‌دست آوردن اطلاعات بیشتر از داده‌ها می‌شود. داده‌های مرتبط با دو چاه با یکدیگر ترکیب شده و سپس به‌صورت تصادفی به دو مجموعه تقسیم شدند. مجموعه اول داده‌های آموزشی با نسبت ۷۰ درصد و مجموعه دوم داده‌های آزمایشی با نسبت ۳۰ درصد از داده‌ها نام‌گذاری شدند. مجموعه داده‌های آموزشی برای ساختن مدل استفاده شد و داده‌های آزمایشی برای ارزیابی قدرت پیش‌بینی مدل مورد استفاده قرار گرفت. به جهت بررسی تخمین تخلخل، پنج نوع نگار چاه شامل: نگار صوتی (DT)، نگار نوترون (NPHI)، نگار چگالی (RHOB)، نگار پرتو گاما (GR)، نگار مقاومت‌ویژه عمیق (LLD) به‌عنوان ورودی برای هر دو شبکه و ماشین مورد استفاده قرار گرفت. برای بررسی عملکرد و دقت مدل‌ها، محاسبه مؤلفه‌های کیفی آماری مثل ضریب همبستگی (CC) و ریشه میانگین مربعات خطا (RMSE) انجام شده است. یک مدل‌سازی خوب بایستی ضریب همبستگی بالا و ریشه میانگین مربعات خطای کوچک داشته باشد.

### ۳-۱. نتایج شبکه عصبی پرسپترون چند لایه و ماشین بردار پشتیبان

یک مدل MLP برای تخمین تخلخل در راستای عمودی چاه با استفاده از داده‌های چاه توسعه پیدا کرد. مدل‌های زیادی توسعه داده و از بین آنها بهینه‌ترین مدل انتخاب شد. مدل منتخب شامل یک لایه ورودی با شش نورون، دو لایه پنهان با بیست نورون (ده نورون برای هر کدام) و یک لایه خروجی می‌شود. منحصراً توابع خطی و سیگموئیدی به‌عنوان تابع فعال‌سازی و از الگوریتم لوبنبرگ-مارکوات (levenberg-marquardt) در شبکه برای این مدل استفاده شد. محاسبات مربوطه در محیط نرم‌افزار Matlab انجام شده است. یکی از اهداف اصلی

در آموزش شبکه عصبی اطمینان از این است که شبکه برای داده‌هایی که قبلاً با آنها آموزش ندیده است به‌درستی کار کند که به آن تعمیم (generalization) می‌گویند. روش استاندارد برای اطمینان از توانایی تعمیم خوب شبکه تقسیم داده‌های آموزشی به چند مجموعه داده است. عمومی‌ترین مجموعه داده‌ها عبارت‌اند از مجموعه داده‌های آموزشی، اعتبارسنجی و آزمایشی. از مجموعه داده‌های آموزشی برای به‌دست آوردن رابطه تبدیل استفاده می‌شود در صورتی که از مجموعه داده‌های اعتبارسنجی برای ارزیابی خطای برآورد در حین آموزش استفاده می‌شود. آموزش زیادی با مجموعه داده‌های آموزشی اغلب باعث تطبیق ضعیف‌تر با مجموعه داده‌های اعتبارسنجی می‌شود. هنگام آموزش شبکه با استفاده از داده‌های آموزشی، کارایی شبکه به‌طور متناوب با استفاده از مجموعه داده‌های اعتبارسنجی بررسی می‌شود. در حین این بررسی وزن‌ها آموزش داده نمی‌شوند ولی کارایی شبکه روی مجموعه اعتبارسنجی به‌دست می‌آید و با مقدار قبلی آن مقایسه می‌شود. اگر شبکه شروع به یادگیری روند کلی تغییرات در داده‌ها، شبکه مثال‌های آموزشی را حفظ کند، کارایی آن بر روی داده‌های اعتبارسنجی رو به کاهش می‌گذارد. بدین ترتیب از مجموعه داده‌های اعتبارسنجی برای به‌دست آوردن زمانی که شبکه بدون آموزش زیادی تا حد ممکن آموزش دیده است (بیشترین تعمیم) می‌توان استفاده کرد. گاهی وقت‌ها اتفاق می‌افتد که شبکه مسئله را به درستی یاد نگیرد. در این موارد منحنی‌های خطا به صفر نزدیک نمی‌شوند. در نرم‌افزار متلب از روش توقف اولیه (Early stopping) که سبب توقف آموزش در دوره‌ای که شبکه کمترین خطای اعتبارسنجی را دارد استفاده شده است. نمودار خطای شبکه MLP برای داده‌های آموزشی و آزمایشی در شکل ۲ آمده است.




شکل ۲. نمودار عملکرد منحنی های خطای آموزش و آزمایش شبکه MLP.

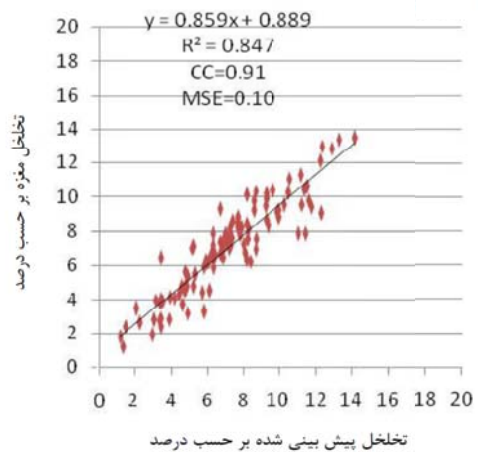
مدل همان نگارهای چاه استفاده شده برای پرسپترون چند لایه است. مقدار انتخابی کرنل  $\text{kernel-option}=0.30$  و پارامتر تنظیم  $\lambda=500$  و بیشینه خطا  $\epsilon=1 \times 10^{-6}$  پس از انجام اعتبارسنجی متقابل و انتخاب تعداد نمونه های بهینه برای آموزش ماشین و جست و جوی شبکه ای مشخص شد. نتایج به دست آمده از ماشین بردار پشتیبان برای داده ها برابر  $CC=0.96$  و  $MSE=0.07$  به دست آمد. در شکل های ۴-الف و ۴-ب عملکرد مدل نمایش داده شده است.

مدل MLP قادر به پیش بینی تخلخل با ضریب همبستگی  $CC=0.91$  و میانگین مربعات خطا  $MSE=0.1$  برای مجموعه داده ها به دست آمد. نتایج تخمین در شکل های ۳-الف و ۳-ب آمده است که نشان دهنده عملکرد بهینه مدل است.

مدل ماشین بردار پشتیبان (رگرسیون) استفاده شده برای تخمین تخلخل دارای پامترهای زیر است: از تابع کرنل گاوسی (Gaussian kernel) استفاده شده است. ورودی




(ب)




(الف)

شکل ۳. مقایسه تخلخل به دست آمده از مغزه و تخلخل پیش بینی شده از روش MLP.



(ب)



(الف)

شکل ۴. مقایسه تخلخل به دست آمده از مغزه و تخلخل پیش بینی شده از روش ماشین بردار پشتیبان.


ورودی‌نگارهای چاه محاسبه شد. با توجه به اینکه داده‌های لرزه‌ای بر حسب زمان هستند، قبل از هر کاری ابتدا می‌بایست رابطه‌ای برای تبدیل محور عمق به زمان در نگاره‌های تخلخل موجود در تمام چاه‌ها به دست آورد که این رابطه با استفاده از نگاره صوتی و تبدیل آن به چک شات به دست آمد. سپس محور قائم‌نگاره‌ها با استفاده از این رابطه به زمان تبدیل شد. در مرحله بعد این داده‌ها با فیلتر پایین‌گذر به بسامد قطع نایکوئیست داده‌های لرزه‌ای فیلتر شدند و در نهایت با فاصله نمونه‌برداری زمانی ۲ میلی‌ثانیه از آنها نمونه‌برداری شد. به منظور عملی شدن این کار از نرم‌افزار EasyTrace استفاده شد. مراحل به انجام رسیدن این کار عبارت‌اند از: ۱) تهیه رابطه زمان-عمق در چاه‌ها با استفاده از نگار صوتی و چک شات. ۲) تبدیل نگاره‌های عمقی به نگاره‌های زمانی. ۳) نمونه‌برداری منظم از نگاره‌های زمانی با فاصله نمونه‌برداری کم. ۴) اعمال فیلتر پایین‌گذر بر نگاره‌ها به منظور حذف بسامدهای بالاتر از بسامد نایکوئیست. ۵) نمونه‌برداری مجدد از نگاره‌ها با فاصله نمونه‌برداری زمانی مشابه داده‌های لرزه‌ای (۲ میلی‌ثانیه).

۲-۳. نتایج تخمین تخلخل با استفاده از نشانگرهای لرزه‌ای


در این مطالعه پنج نشانگر لرزه‌ای برای تخمین تخلخل انتخاب شدند: فرکانس لحظه‌ای، فاز لحظه‌ای، طول کمان، نیمه-زمان انرژی و ریشه میانگین مربعی دامنه. شکل ۵، داده لرزه‌ای سه‌بعدی برداشت شده را در میدان مورد مطالعه را نشان می‌دهند که در آن مکان چاه‌های حفاری شده نشان داده شده است.

### ۱-۲-۳. تخمین تخلخل در محل چاه

از ماشین بردار پشتیبان (SVR) برای تخمین تخلخل در راستای عمودی در محل چاه استفاده شد. برای ساخت مدل SVR و انجام عمل پیش‌بینی از نرم‌افزار LIBSVM استفاده شده است. به کارگیری این نرم‌افزار شامل دو مرحله است: مرحله اول شامل آموزش مدل توسط داده‌های آموزشی و مرحله دوم به کارگیری مدل برای پیش‌بینی داده‌های آزمایشی می‌شود. (چانگ و لین، ۲۰۱۱). در ابتدای کار تخلخل برای ۵ چاه فاقد مغزه با استفاده از ماشین ساخته شده در مرحله قبل با



شکل ۵. داده لرزه‌ای سه‌بعدی برداشت شده در منطقه مورد مطالعه.

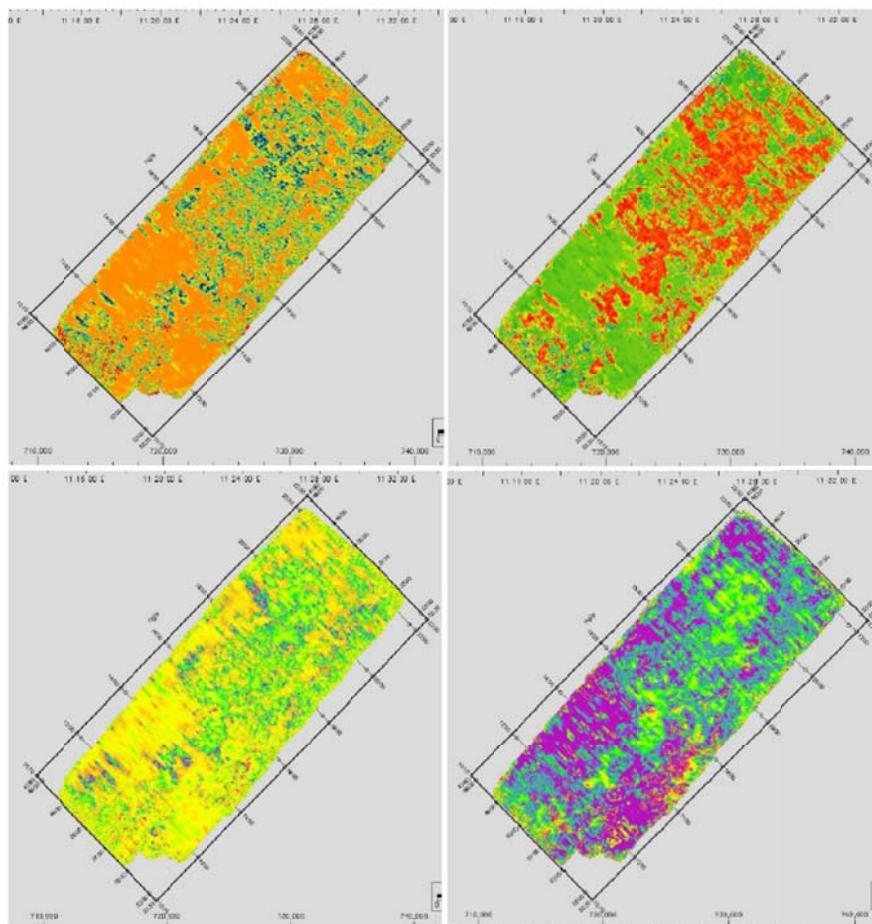


شکل ۶. نشانگرهای استخراج شده. اولین پنل از سمت چپ نمایش ردلرزه در محل چاه شماره یک، و به ترتیب ریشه میانگین مربعی دامنه، فاز لحظه‌ای، فرکانس لحظه‌ای و طول کمان را نشان می‌دهد. ناحیه مربوط به مخزن در بین خطوط آبی نشان داده شده است.

می‌گیرند برای آموزش استفاده شد. شکل ۶، نشان‌دهنده ردلرزه در کنار نشانگرهای لرزه‌ای در محل چاه شماره یک است.

در شکل ۷، نشانگرهای ریشه میانگین مربعی دامنه، فاز لحظه‌ای، فرکانس لحظه‌ای و طول کمان بر روی برش زمانی ۱۲ میلی‌ثانیه نشان داده شده است.

به منظور استخراج نشانگرهای لرزه‌ای از نرم‌افزار Hampson-Russell استفاده شده است. بدین منظور ردلرزه‌های لرزه‌ای که در محل چاه استخراج شده بودند، با نرم‌افزار قرائت شدند و با استفاده از آنها نشانگرهای لرزه‌ای مرتبط با تخریخ تولید شد. از قسمتی از نشانگرهای تولید شده که در محدوده زمانی مخزن قرار



شکل ۷. نشانگرهای ریشه میانگین مربعی دامنه، فاز لحظه‌ای، فرکانس لحظه‌ای و طول کمان بر روی برش زمانی ۱۲ میلی‌ثانیه.

به‌دست آمده از نشانگرها و نگار تخلخل در هر ۲ میلی‌ثانیه است برای تمام چاه‌ها است. قبل از آموزش شبکه با انجام اعتبارسنجی تقاطعی و با استفاده از جست‌وجوی شبکه‌ای پارامترهای SVR مشخص شدند. با استفاده از مدل SVR به‌دست آمده از آموزش و آزمایش داده‌ها، نتایج حاصل از کرنل‌های گوناگون محاسبه شد (جدول ۱). ضریب همبستگی برای کرنل گاوسی  $0/66$  محاسبه شده است که بیشتر از کرنل‌های استفاده شده دیگر است.

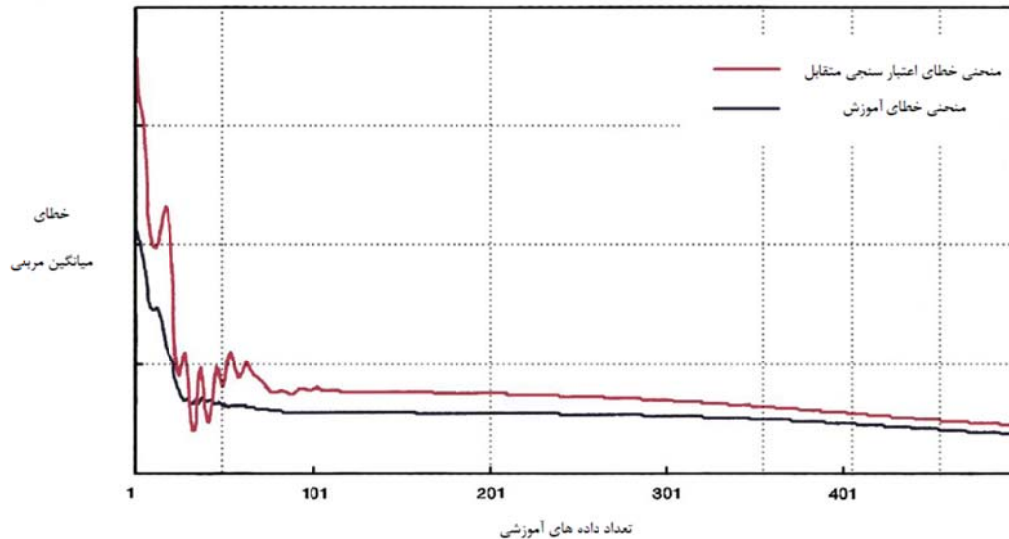
افزایش نشانگرهای دیگر به این مجموعه نه فقط باعث بهبود برآورد نمی‌شود؛ بلکه باعث ناپایداری در جواب‌ها و همچنین افزایش زمان محاسبه‌ها می‌شود. شکل ۸، منحنی‌های خطای میانگین مربعی نمونه‌های آموزشی و اعتبارسنجی متقابل را برای ماشین نشان می‌دهد. شکل‌های ۹-الف و ۹-ب نتایج مدل‌سازی را نشان می‌دهند. نتایج با  $MSE=0/15$  و  $CC=0/76$  قابل قبول می‌باشند.

با توجه به تعداد زیاد نشانگرهای تولید شده، به‌منظور حذف مؤلفه‌های غیرضروری، بهترین نشانگرها برای آموزش ماشین با استفاده از روش برازش گام‌به‌گام صورت گرفت (دراپر و اسمیت، ۱۹۶۶). در این روش ابتدا بهترین نشانگر برای برآورد کردن تخلخل را با بررسی همه نشانگرها پیدا می‌کنیم، به‌نحوی که این نشانگر دارای کمترین خطای برآورد باشد. در مرحله بعد بهترین جفت نشانگری را پیدا می‌کنیم که شامل نشانگر قبلی باشد. سپس نشانگر سوم و چهارم و ... را نیز به‌همین ترتیب به‌دست می‌آوریم. با عملی ساختن روش برازش گام‌به‌گام پنج نشانگر فرکانس لحظه‌ای، فاز لحظه‌ای، طول کمان، نیمه-زمان انرژی و ریشه میانگین مربعی دامنه به‌عنوان بهترین نشانگرها انتخاب شدند. این پنج نشانگر به‌همراه مقادیر عددی نگار تخلخل، ماتریسی با شش ستون را تشکیل داد که تعداد سطرهای آن برابر تعداد مقادیر




جدول ۱. کرنل های مختلف به کار گرفته شده برای SVR.

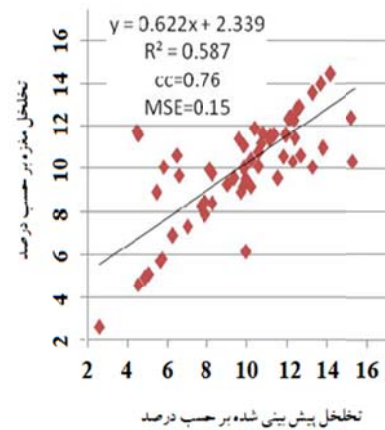
	گاوسی	سیگموئید	چند جمله ای	خطی
ضریب همبستگی	۰/۶۶	۰/۶۱	۰/۴۶	۰/۵۲
میانگین مربعات خطا	۰/۶۶	۰/۷۵	۰/۷۹	۰/۹۸



شکل ۸. منحنی خطای آموزشی (سیاه) و خطای اعتبارسنجی متقابل (قرمز) در مرحله آموزش ماشین SVR.



(ب)




(الف)

شکل ۹. مقایسه تخلخل به دست آمده از مغزه و تخلخل پیش بینی شده با استفاده از ماشین بردار پشتیبان.

تفسیر شده استفاده شد. مدل مورد نظر از قسمت های فوقانی و انتهایی مخزن ساخته شد. شکل ۱۰، نشان دهنده افق های لرزه ای تفسیر شده در محدوده مخزن را نشان می دهد.

۲-۲-۳. تخمین تخلخل به صورت سه بعدی


در قسمت آخر از این تحقیق به ساخت مدل سه بعدی از تخلخل مخزن مورد بررسی پرداخته شده است. از نرم افزار Petrel برای ساخت شبکه بندی سه بعدی از سطوح لرزه ای




شکل ۱۰. تصویر مقاطع تفسیرشده لرزه‌ای در محدوده مخزن.

شکل ۱۲، نتیجه نهایی و توزیع سه‌بعدی از تخلخل در محدوده مخزن در میدان نفتی مورد مطالعه را نشان می‌دهد. مناطق صورتی رنگ تخلخل کم و مناطق قرمز تخلخل بالا را نشان می‌دهد.

در شکل ۱۱، نمودار هیستوگرام از توزیع تخلخل در محدوده مخزن در میدان مورد مطالعه آورده شده است. چنانچه از این شکل مشخص است، حدود ۲۰ درصد از نمونه‌ها کیفیت بالای مخزنی را نشان می‌دهد.



شکل ۱۱. هیستوگرام توزیع تخلخل در محدوده مخزن در منطقه مورد مطالعه.



شکل ۱۲. نتیجه نهایی و توزیع سه‌بعدی از تخلخل در محدوده مخزن در میدان نفتی مورد مطالعه.

## ۴. نتیجه‌گیری

به کار بردن نشانگرهای لرزه‌ای به همراه داده‌های چاه‌پیمایی توانایی تخمین تخلخل در فضای ما بین چاه‌های حفاری را ممکن کرد. نتایج اولیه رگرسیون بردار پشتیبان توانایی بالاتری نسبت به پرسپترون چندلایه نشان داد. برای این کار بردار پشتیبان بر پایه کرنل‌های مختلف مورد استفاده قرار گرفت که تابع کرنل گاوسی نتایج بهتری حاصل کرد و نهایتاً برای مدل‌سازی سه‌بعدی تخلخل به کار گرفته شد. برای تهیه یک نقشه سه‌بعدی به داده‌های لرزه‌ای و نشانگرهای استخراج شده مناسب از روی آن نیاز می‌باشد. بررسی و مقایسه نتایج نشان داد که هر دوی ماشین‌های پرسپترون چندلایه و بردار پشتیبان از توانایی بالایی برخوردار هستند ولی رگرسیون بردار پشتیبان با توجه به قدرت تخمین بالا نتایج بهتری حاصل کرد.

## مراجع

- AL-Bazzaz, W. H, Al-Mehanna, Y. W. and Gupta, A., 2007, Permeability Modeling Using Neural-Networks Approach for Complex Mauddud-Burgan Carbonate Reservoir SPE 105337.
- Ali, K, 1994, Neural Networks: A New Tool for the Petroleum Industry, SPE.
- Aminzadeh, F. and Brouwer, F. 2006, Integrating Neural Networks and Fuzzy Logic for Improved Reservoir Property Prediction and Prospect Ranking. SEG New Orleans 2006 Annual Meeting.
- Balan, B., Mohaghegh, S. and Ameri, S., 1995, State-of-the-Art in Permeability Determination from Well Log Data: Part I. Comparative study, model development. SPE Eastern Regional Conference and Exhibition, West Virginia, 17-21.
- Bean M. and Jutten C., 2000, Neural Networks in Geophysical Applications, Geophysics, 65, 1032-1047.
- Bolandi, V., Kadkhodaie, A. and Farzi, R., 2017, Analyzing organic richness of source rocks from well log data by using svm and ann classifiers: A case study from the kazhdumi formation, the persian gulf basin, offshore iran.
- Cortes, C. and Vapnik, V., 1995, Support-Vector Networks. Machine Learning, 20, 273-297.
- Leiphart, D. J. and Hart, B. S., 2001, Case History Comparison of Linear Regression and Probabilistic Neural Network to Predict Porosity from 3-D seismic Attributes in Lower Brushy Canyon Channel Sandstones, Southeast New Mexico, Geophysics, 66(5), 1349-1358.
- Doyen, P. M., 1998, Porosity from seismic data - A geostatistical approach: Geophysics, 3, 1263-1275.
- Eshafei, M. and Gharib, M., 2007, Neural Network Identification of Hydrocarbon Potential of Shaly Sand Reservoirs, Technical Symposium SPE.
- Gholami, A. and Ansari, H. R., 2017, Estimation of porosity from seismic attributes using a committee model with bat-inspired optimization algorithm. J Pet Sci Eng 152:238-249.
- Hommel, J., Coltman, E. and Holger, C., 2018, Porosity – permeability relations for evolving pore space: a review with a focus on (bio-)geochemically altered porous media. Transp Porous Med. 124(2):589-629.
- Hosseini, E., Gholami, R. and Hajivand, F., 2019., Geostatistical modeling and spatial distribution analysis of porosity and permeability in the Shurijeh-B reservoir of Khangiran gas field in Iran. J Pet Explor Prod Technol, 9, 1051-1073.
- Kumar, R., Das, B., Chatterjee, R. and Sain, K., 2016, A methodology of porosity estimation from inversion of post stack seismic data.

در این تحقیق روش ماشین بردار پشتیبان (SVM) به‌عنوان روش اصلی در رگرسیون و تخمین تخلخل مخزن در یکی از مخازن هیدروکربنی به کار گرفته شده است. این روش با روش پرسپترون چندلایه مقایسه شده است و نتایج هر کدام مورد بررسی قرار گرفته‌اند. برای این کار ابتدا هر کدام از ماشین‌های موردنظر برای تخمین تخلخل در محل چاه به کار گرفته شده‌اند و نتایج اولیه با هم مقایسه شدند. نزدیکی بین مقادیر دقیق استخراج شده مغزه‌ها و مقادیر تخمینی به‌دست آمده از شبکه عصبی نشان‌دهنده اعتبار و توانایی شبکه‌های عصبی در برقراری ارتباطات پیچیده غیرخطی بین داده‌های چاه‌پیمایی، نشانگرهای لرزه‌ای و تخلخل بود. با توجه به مؤلفه‌های آماری و نتایج به‌دست آمده از این تحقیق و داده‌های این پژوهش روش SVM نسبت به شبکه عصبی پرسپترون چند لایه (MLP) مزیت دارد.

- Journal of Natural Gas Science and Engineering, 28, 356–364.
- Linqi, Z., Zhang, C. and Guo, C., 2018, Calculating the total porosity of shale reservoirs by combining conventional logging and elemental logging to eliminate the effects of gas saturation. *Petrophysics*, 59(2), 162–84.
- Mori, T. and Leite, E. P., 2018, Porosity Prediction of a Carbonate Reservoir in Campos Basin Based on the Integration of Seismic Attributes and Well Log Data. (2018).
- Perrin, C., Rafik, M., Akbar, M. and Jain, S., 2007, Integration of Borehole Image to Enhance Conventional Electrofacies Analysis in Dual Porosity Carbonate Reservoirs, SPE, 11622, International Petroleum Technology Conference, Dubai, UAE 6-4 December.
- Saggaf, M. M., Toksöz, M. N. and Marhoon, M. I., 2003, Seismic Facies Classification and Identification by Competitive Neural Networks, *Geophysics*, 68(6), 1984-1999.
- Schutz, P. S., Hattori, M. and Corbett, C., 1994, Seismic guided estimation of log properties, parts 1,2, and 3: The Leading Edge, 13,305-310,674-678, and 770-776.
- Sippel, M., 2003, Reservoir Characterization from Seismic and Well Control with Intelligent Computing Software, AAPG Annual Convention, Salt Lake City, Utah, May 11-14.
- Soto, R.B., Bernal, M.C. and Silva, B., 2000, How to Improve Reservoir Characterization using Intelligent Systems. SPE 62938.
- Soto, R., Torres, B.F., Arango, S. and Cobaleda, G., 2001, Improved Reservoir Permeability Models from Flow Units and Soft Computing Techniques. A Case Study, Suria and Reforma-Libertad, SPE 69625.
- Wang, L., 2005, Support Vector Machines: Theory and Applications, *STUDFUZZ*, volume 177.
- Xie, M., Mayer, KU., Claret, F., Alt-Epping, P., Jacques, D., Steefel, C., Chiaberge, C. and Simunek, J., 2015, Implementation and evaluation of permeability-porosity and tortuosity-porosity relationships linked to mineral dissolution-precipitation. *Comput Geo Sci.*, 19(3), 655–71.

## Reservoir porosity modelling using support vector regression based on Gaussian kernel in an oil field of Iran

Rafei, M.<sup>1</sup>, Bagheri, M.<sup>2\*</sup> and Nabi-Bidhendi, M.<sup>3</sup>

1. M.Sc. Student, Department of Earth Physics, Institute of Geophysics, University of Tehran, Tehran, Iran  
2. Assistant Professor, Department of Earth Physics, Institute of Geophysics, University of Tehran, Tehran, Iran  
3. Professor, Department of Earth Physics, Institute of Geophysics, University of Tehran, Tehran, Iran

(Received: 25 Dec 2020, Accepted: 20 Sep 2021)

### Summary

Permeability, porosity and sedimentary facies are the main factors of reservoir characteristics. Porosity indicates the ability of a rock to store fluids. So far, many approaches including linear / nonlinear regressions have been developed to predict porosity. Neural networks have received a lot of attention in recent years, and various types of learning machines based on neural networks have been introduced. Multilayer perceptron neural network (MLP) is one of these networks that proven its ability, but each of these methods has disadvantages. In this research, the support vector machine (SVM) method has been used as the main method for regression and estimation of the reservoir porosity in one of the hydrocarbon reservoirs. This method has been compared with the multilayer perceptron method and the results of each have been investigated.

The best way to get accurate values of physical properties of reservoir is to measure them directly in the laboratory. However, this method has disadvantages: high cost, time consuming, lack of access to the entire depth of the well. For these reasons, geologists extract core from a number of wells and from a specific range. Geologists generally use a statistical approach involving multiple linear or nonlinear regressions to relate reservoir characteristics to each other (eg, porosity and permeability). In these contexts, a linear or non-linear relationship is assumed between porosity and other reservoir characteristics. However, these techniques are insufficient for certain issues, such as heterogeneous reservoirs. Recently, geoscientists have used artificial intelligence (AI) methods, especially neural networks (NNs), to predict reservoir parameters. Neural networks have been widely used in various fields of science and engineering.

To build a three-dimensional model of a reservoir, a thorough knowledge of permeability, porosity and sedimentary facies is required. Well logs and core information are local measurements that do not reflect the behavior of the reservoir as a whole. In addition, well information does not cover the entire field area, while 3D seismic information covers a larger area. Changes in lithology and fluids cause changes in amplitude, wavelet shape, coherence coefficient, and other seismic attributes. These attributes can provide information for building a repository model.

The main purpose of this research is to analyze training machines developed by computer scientists to predict reservoir characteristics such as porosity in vertical and lateral directions with the help of well logs and seismic attributes. The aim is to achieve the following steps to estimate a reliable porosity model of the reservoir:

- Development of a multilayer perceptron (MLP) to estimate the porosity using well logs.
- Development of a support vector machine (SVM) to estimate the porosity using well logs.
- Comparing the proposed methods and choosing the best.
- Estimation of porosity based on seismic attributes using the selected algorithm.
- Making a three-dimensional model of the reservoir porosity based on the training machine.

As it was expected, these computational intelligence approaches overcome the weakness of the standard regression techniques. Generally, the results show that the performances of Support Vector Machine outperform that Multilayer Perceptron neural networks. In addition, Support Vector Regression (SVR) is more robust, easier and quicker to train. Therefore, it could be concluded that the use of SVM technique will be valuable and powerful for geoscientists to model the reservoir properties.

**Keywords:** Porosity, Regression, Multilayer Perception Neural Network, Support Vector Machine, Seismic attributes, well logs.

\* Corresponding author:

majidbagheri@ut.ac.ir