



## به کارگیری مدل رگرسیون ماشین بردار پشتیبان به منظور تخمین میزان اشباع‌شدگی آب سازند یکی از میدان‌های نفتی بزرگ جنوب غرب ایران

رضا احمدی<sup>۱\*</sup> و محمد صادق امیری بختیار<sup>۲</sup>

۱- استادیار، دانشکده مهندسی معدن، دانشگاه صنعتی اراک

۲- دانشجوی کارشناسی ارشد، دانشگاه صنعت نفت آبادان

دریافت مقاله: ۱۳۹۶/۰۱/۱۲؛ پذیرش مقاله: ۱۳۹۶/۰۷/۲۵

\* نویسنده مسئول مکاتبات: rezahmadi@gmail.com

### چکیده

### واژگان کلیدی

اشباع‌شدگی آب ( $S_w$ ) سنگ مخزن یکی از پارامترهای پتروفیزیکی مهم است؛ که تأثیر زیادی بر دقت تخمین میزان نفت اولیه مخزن دارد. به دلیل اهمیت زیاد این پارامتر در محاسبات اقتصادی توسعه مخزن، تعیین دقیق آن اجتناب‌ناپذیر است. در پژوهش حاضر برای تخمین این پارامتر، مدل رگرسیون ماشین بردار پشتیبان شامل ۵ متغیر ورودی یعنی داده‌های چاه‌نگاری پرتو گامای طبیعی، تخلخل نوترونی، چگالی کیه‌ای سازند، زمان گذر امواج صوتی و مقاومت ویژه الکتریکی حقیقی و پارامتر  $S_w$  به عنوان تک خروجی برای سه حلقه چاه در یکی از میدان‌های نفتی بزرگ سازند آسماری واقع در جنوب غرب کشور ایران مورد استفاده قرار گرفته است. به منظور مقایسه نتایج تخمین با واقعیت به طور بصری، ستون چینه‌شناسی و اشباع‌شدگی آب و هیدروکربور سازند نیز توسط نرم‌افزار Geolog برای چاه‌های مورد مطالعه ترسیم شده است. از تعداد کل ۱۲۱۱ داده نقطه‌ای موجود برای سه حلقه چاه، حدود ۸۰ درصد به عنوان داده‌های آموزشی و حدود ۲۰ درصد به عنوان داده‌های آزمون انتخاب شدند. عملکرد الگوریتم از طریق اعتبارسنجی متقابل بر اساس معیارهای مختلف همانند ترسیم نمودار پراکندگی مقادیر اندازه‌گیری‌های آزمایشگاهی  $S_w$  توسط مغزه‌ها در مقابل مقادیر تخمینی با استفاده از داده‌های چاه‌نگاری سه حلقه چاه توسط مدل SVR و محاسبه پارامترهای آماری معرف خطا، نیز اعتبارسنجی شده است. نتایج تحقیق نشان می‌دهد که مدل مذکور از قابلیت بالایی برای تخمین میزان  $S_w$  سنگ مخزن با استفاده از داده‌های چاه‌نگاری برخوردار است. به گونه‌ای که داده‌های آموزشی را با ضریب تعیین همبستگی عالی بیش از ۸۷ درصد و داده‌های آزمون را با ضریب تعیین همبستگی مطلوب بیش از ۷۶ درصد تخمین زده است.

اشباع‌شدگی آب ( $S_w$ )  
رگرسیون ماشین بردار پشتیبان (SVR)  
سازند آسماری  
داده‌های چاه‌نگاری

سازندهای مختلف، با بررسی‌های پتروفیزیکی و تجزیه و تحلیل مغزه در آن سازند به دست می‌آید. به همین دلیل پژوهشگران به روش‌های مختلف سعی کرده‌اند تا با در نظر گرفتن مجموعه‌ای از فرضیات و لحاظ کردن بعضی عوامل تأثیرگذار، روابطی را برای محاسبه اشباع آب در سازندهای رس‌دار ارائه کنند. تاکنون مدل‌های تجربی زیادی برای اندازه‌گیری  $S_w$  سنگ مخزن از داده‌های چاه‌نگاری ارائه شده است؛ که از بزرگ‌ترین معایب این مدل‌ها وابستگی شدید آن‌ها به سازند خاص مورد مطالعه و عدم جامعیت کاربرد آن‌ها برای انواع مختلف سازندهای دیگر است.

از طرفی پیش‌بینی میزان  $S_w$  در مخازن کربناته به دلیل ناهمگنی پارامترهای پتروفیزیکی، تغییرات گسترده اندازه حفره‌های موجود و پیچیده و مبهم بودن ارتباط ضرایب آرچی با کانی‌شناسی و حفره‌های موجود در مخزن، امری دشوار و پیچیده بوده و همین مسئله باعث می‌شود تا مقادیر  $S_w$  در سنگ‌های کربناته در گستره وسیعی از توان اشباع دچار نوسان شود.

علاوه بر روش‌های تجربی، از روش‌های رگرسیون خطی متعددی نیز برای تخمین میزان  $S_w$  سنگ مخزن، از داده‌های چاه‌نگاری استفاده شده است که به دلیل پیچیدگی ویژگی‌های این پارامتر، روابط این مدل‌ها نیز قادر به پیش‌بینی صحیح آن نمی‌باشند. در مقاله حاضر از روش هوشمند مبتنی بر آمار رگرسیون ماشین بردار پشتیبان (SVR: Support Vector Regression) برای تخمین  $S_w$  سنگ مخزن یکی از میدان‌های نفتی بزرگ واقع در جنوب غربی کشور از طریق داده‌های چاه‌نگاری مناسب استفاده شده است.

## ۲- مرور پیشینه تحقیق

اخیراً روش‌های هوشمند توسط بسیاری از محققین در زمینه‌های مختلف صنعت نفت به‌ویژه جهت تخمین پارامترهای مختلف پتروفیزیکی مخزن استفاده شده است. به‌عنوان نمونه علی‌مرادی (۱۳۹۰) از داده‌های لرزه‌نگاری سه‌بعدی به‌منظور بهبود روش‌های تخمین پارامتر اشباع‌شدگی از هیدروکربور در مخازن تیپ کربناته استفاده نمود. برای این منظور ابتدا با استفاده از روش بهینه‌سازی الگوریتم ژنتیکی، معادله سرعت گسمن بهبود یافت. سپس از دو نشانگر فاز و فرکانس پوش وزنی برای مدل‌سازی معکوس دو پارامتر تخلخل و ابعاد حفرات با دو روش هوشمند شبکه‌های عصبی مصنوعی و ماشین بردار پشتیبان استفاده نمود؛ که نتایج بیانگر عملکرد بهتر روش ماشین بردار پشتیبان در تخمین مقادیر این پارامترها بود. در نهایت از سه پارامتر تخلخل، بعد حفرات و سرعت موج به‌منظور پیش‌بینی مقادیر اشباع‌شدگی از آب سازند استفاده کرد.

Cheng et al. (1993) از روش شبکه عصبی مصنوعی برای

تخمین تخلخل در یکی از میدان‌های نفتی کانادا بر اساس داده‌های

اشباع‌شدگی آب سازند به کسری از فضاها خالی سنگ گفته می‌شود؛ که توسط آب اشغال شده باشد. این پارامتر یکی از کاربردی‌ترین پارامترهای پتروفیزیکی مخازن نفتی است؛ که درجه موفقیت بسیاری از فعالیت‌های حفاری، تکمیل و تولید چاه‌های نفت و گاز، به دقت روش‌های استفاده شده در اندازه‌گیری آن وابسته است. بنابراین تخمین دقیق آن در اکتشاف، توسعه و بهره‌برداری از مخازن نفت و گاز ضروری است. در صنعت نفت پارامترهای مخزن توسط دو روش متداول و کاربردی تحلیل مغزه به عنوان روش مستقیم و ارزیابی داده‌های چاه‌نگاری به عنوان روش غیرمستقیم تعیین می‌شوند. روش تحلیل مغزه که در آزمایشگاه و با روش آزمایش بر روی مغزه صورت می‌گیرد، اطلاعات مفیدی درباره میزان  $S_w$  سنگ مخزن ارائه می‌کند. به‌عنوان نمونه مرادزاده و همکاران (۱۳۹۲) را در یکی از مخازن هیدروکربوری کربناته با استفاده از داده‌های آزمایشگاهی حاصل از آزمایش‌های مغزه محاسبه کردند. محاسبات آن‌ها از طریق تلفیق داده‌های آزمایشگاهی فشار مؤینگی، به روش تریق جیوه و طبقه‌بندی سنگ‌های کربناته با استفاده از مفهوم واحدهای جریان هیدرولیکی، استفاده از تابع لورت و ارتباط آن با اشباع آب نرمال شده، انجام شد.

استفاده از روش آزمایشگاهی برای اندازه‌گیری این پارامتر، گران قیمت و زمان‌بر است. بنابراین استفاده از این روش تنها در تعداد معدودی از چاه‌های یک میدان، امکان‌پذیر است. از این‌رو ارائه روشی توانا به‌منظور تخمین این پارامتر در میدان‌های نفتی، با استفاده از داده‌های چاه‌نگاری به‌ویژه در چاه‌های فاقد مغزه، ضروری است.

Archie (1942) با بررسی تغییرات مقاومت ویژه واقعی سازند

( $R_t$ : True resistivity) و آب سازندی ( $R_w$ : Water resistivity) رابطه اساسی زیر را برای محاسبه  $S_w$  در مخازن هیدروکربوری ارائه کرد:

$$S_w = \sqrt[n]{\frac{a}{\phi^m} \times \frac{R_w}{R_t}} \quad (1)$$

که در این رابطه  $n$  توان اشباعی،  $a$  یک عدد ثابت و تابع جنس سنگ (لیتولوژی)،  $\phi$  تخلخل و  $m$  ضریب سیمان‌شدگی سازند است. معمولاً در مخازن هیدروکربوری،  $S_w$  با استفاده از داده‌های چاه‌نگاری و به‌کارگیری این رابطه، تخمین زده می‌شود؛ اما رابطه (۱) فقط در مورد سازندهای ماسه‌سنگی تمیز (فاقد رس) برقرار است.

بررسی‌های انجام شده نشان می‌دهد که با حضور درصد کمی از کانی‌های رسی در سازند، به دلیل کاهش مقاومت ویژه سازند، درصد اشباع آب به کمک فرمول آرچی، بیش از مقدار واقعی به دست می‌آید. بنابراین به‌کارگیری رابطه (۱) در این‌گونه موارد با خطای زیادی همراه خواهد بود (Luthi, 1941). پارامترهای  $n$ ،  $a$  و  $m$  ثابت‌های مجهول و ناشناخته‌ای هستند، که مقادیر آن‌ها برای

رشته کوه زاگرس واقع شده؛ که در ناحیه فروافتادگی دزفول دارای بیشترین گسترش است (مطیعی، ۱۳۸۲). این میدان به صورت طاقدیسی ملایم با روند شمال غربی - جنوب شرقی و در امتداد روند عمومی چین خوردگی‌های زاگرس قرار دارد. میدان مورد مطالعه فاقد عوارض و شواهد سطحی چین خورده است؛ که این مسئله با استفاده از داده‌های لرزه‌نگاری نیز به اثبات رسیده است. طول این میدان بر روی آخرین منحنی تراز بسته حدود ۶۳ کیلومتر و عرض آن حدود ۵ کیلومتر است.

مخزن آسماری در محدوده میدان‌های نفتی مناطق نفت‌خیز جنوب همچون اهواز، منصوری و مارون، از جمله مخازن کربناته ترشیری ایران محسوب می‌شود. سازند آسماری در میدان نفتی مورد مطالعه شامل سازند آسماری بالایی از جنس دولومیت، آهک دولومیتی به همراه تکه‌هایی از انیدرید که در زیر بخش یک سازند گچساران (پوش سنگ) قرار دارد، آسماری میانی شامل تناوبی از ماسه‌سنگ، آهک، آهک ماسه‌ای، دولومیت و ماسه شیلی و آسماری زیرین از جنس آهک، آهک دولومیتی و ماسه‌سنگ است. ماسه‌سنگ‌های این زیرلایه به صورت غیرسیمانی و یا سیمان شده هستند؛ که سیمان آن‌ها از جنس آهک، دولومیت و گاهی نیز انیدرید است. ضخامت این سازند در میدان مطالعه شده بین ۲۹۰ تا ۳۵۰ متر است. متراژ حفاری سه حلقه چاه A، B و C در سازند آسماری میدان نفتی مورد مطالعه به ترتیب، ۳۵۰، ۳۸۵ و ۴۷۵ متر است؛ که به‌طور کلی از توالی سنگ‌های کربناته (سنگ آهک و دولومیت)، ماسه‌سنگ و شیل تشکیل شده است. در این میدان نفتی فرآیند دولومیتی شدن در کل مخزن رخ داده و بیشترین درصد دولومیت در بخش بالایی مخزن مشاهده می‌شود (مطیعی، ۱۳۸۲؛ محمدی، ۱۳۸۳).

تخلخل متوسط مناطق نفتی دولومیتی و ماسه‌سنگی به ترتیب ۱۳ و ۱۶ درصد و نفوذپذیری این مناطق به ترتیب ۱۰ و ۶۰۰ میلی‌داری است (اداره مطالعات زمین‌شناسی شرکت ملی مناطق نفت‌خیز جنوب، ۱۳۸۷).

#### ۴- معرفی روش استفاده شده (SVR)

همان‌گونه که از رابطه (۱) ملاحظه می‌شود، نگارهای مقاومت ویژه و تخلخل از مهم‌ترین نگارهای مورد استفاده در تعیین اشباع‌شدگی آب در رابطه اساسی تجربی آرچی هستند. تخلخل سازند را می‌توان با دقت قابل قبولی از روی داده‌های چاه‌نگاری صوتی، چگالی و نوترون به دست آورد؛ اما نگارهای مقاومت ویژه به شدت به حضور شیل و ناخالصی‌های رسی سازندها حساس هستند؛ که با استفاده از نمودار GR می‌توان تأثیر میزان رس سازند را نیز اعمال نمود. بنابراین به‌کارگیری یک روش هوشمند با استفاده از داده‌های چاه‌نگاری مناسب، برای تخمین  $S_w$  سازند سودمند خواهد بود. در پژوهش حاضر برای این منظور روش هوشمند SVR مورد استفاده قرار گرفته

نگارهای صوتی، چگالی نوترون و پرتو گاما استفاده کردند. در این پژوهش نتایج تخمین توسط شبکه‌های عصبی، با تخمین مبتنی بر روش رگرسیون خطی، مقایسه شد و بر اساس نتایج حاصل به وسیله شبکه عصبی تخمین بهتری از تخلخل صورت گرفت. Cuddy (2000) با استفاده از منطق فازی و بر اساس قوانین تجربی، ستون چینه‌شناسی سنگ مخزن میدان گازی وایکینگ (Viking) واقع در قسمت جنوبی دریای شمال را ترسیم نمود. با مشخص بودن ستون چینه‌شناسی، مقادیر نفوذپذیری سنگ مخزن را نیز بر اساس قوانین تجربی تخمین زد. Singh (2005) در پژوهشی که در میدان یوتا (Utah) در خلیج یوینتا (Uintah) انجام داد، شبکه‌های عصبی مصنوعی را برای تخمین نفوذپذیری با استفاده از داده‌های نگارهای پرتو گاما، نوترون و چگالی بکار گرفت. (Lim et al. (2006) در یکی از میدان‌های نفتی کره از تلفیق دو روش شبکه عصبی و الگوریتم ژنتیک برای تخمین نفوذپذیری سنگ مخزن در یکی از چاه‌های این میدان نفتی بر اساس نگارهای چاه و با هدف تخمین تخلخل بر اساس توابع چندجمله‌ای استفاده کردند. در این پژوهش هدف، بهینه‌سازی ضرایب چندجمله‌ای تخمین بود؛ که بر اساس روش تلفیقی مذکور، نتایج بهتری نسبت به زمانی که از شبکه‌های عصبی مصنوعی به‌تنهایی استفاده می‌شد، به دست آمد. Aminzadeh and Brouwer (2006) از شبکه‌های عصبی - فازی برای بهبود پیش‌بینی خصوصیات پتروفیزیکی مخزن در یکی از میدان‌های نفتی آمریکا استفاده کردند. (Adeniran et al. (2009) پارامتر پتروفیزیکی تخلخل را با استفاده از داده‌های شش نمودار و پارامتر  $S_w$  سازند را با داده‌های پنج نمودار چاه‌نگاری با استفاده از روش شبکه‌های تابعی (حالت تعمیم یافته‌ای از شبکه‌های عصبی با تغذیه پیشرو) تخمین زدند. Jafari Kenari and Mashohor (2013) از ترکیب روش‌های مختلف یادگیری ماشین (Machine learning) برای تخمین  $S_w$  مخزن از روی داده‌های چاه‌نگاری استفاده کردند. (Bagheripour and Asoodeh (2014) از روش منطق فازی بهبودیافته (ترکیب ژنتیک الگوریتم با جستجوی الگو جهت تنظیم قواعد فازی و استخراج پارامترهای بهینه دخیل در ساختار محاسباتی مدل فازی) برای تخمین  $S_w$  سازند بر اساس داده‌های چاه‌نگاری استفاده نمودند.

هر چند تحقیقات مبتنی بر روش‌های هوشمند قبلی در خصوص تخمین پارامترهای مخزن، موفقیت‌آمیز بوده‌اند؛ برای تخمین پارامتر مهمی چون  $S_w$  مخزن، همچنان ارائه مدل‌های توانا تر به‌ویژه روش‌های هوشمند مبتنی بر آمار پیشرفته با استفاده از داده‌های چاه‌نگاری، مورد نیاز است.

#### ۳- زمین‌شناسی و خصوصیات مخزنی منطقه مورد مطالعه

میدان نفتی مورد مطالعه درون سازند آسماری در جنوب غربی

حال بیشینه شدن اندازه حاشیه جدایش است. تابع  $L_\varepsilon$  تابع وینیک است؛ که به صورت زیر تعریف می‌شود:

$$|y - f(x, w)|_\varepsilon = \begin{cases} 0 & \text{if } |y - f(x, w)| \leq \varepsilon \\ |y - f(x, w)| - \varepsilon & \text{Otherwise} \end{cases} \quad (4)$$

مسئله بالا به صورت بیشینه شدن معادله زیر بازنویسی می‌شود:

$$L_p(\alpha_i, \alpha_i^*) = -\frac{1}{2} \sum_{i,j=1}^l (\alpha_j - \alpha_j^*) (\alpha_j - \alpha_j^*) x_j^T x_j - \varepsilon \sum_{i=1}^l (\alpha_i + \alpha_i^*) + \sum_{i=1}^l (\alpha_i - \alpha_i^*) y_i \quad (5)$$

که شرایط آن به صورت زیر است:

$$\begin{cases} \sum_{i=1}^l (\alpha_i - \alpha_i^*) = 0 \\ 0 \leq \alpha_i \leq C, \quad i = 1, \dots, l \\ 0 \leq \alpha_i^* \leq C, \quad i = 1, \dots, l \end{cases} \quad (6)$$

با حل معادله بالا می‌توان تابع SVR یعنی  $f$  را با استفاده از تابع کرنل به صورت زیر محاسبه نمود:

$$f(x, w) = w_0^T x + b = \sum_{i=1}^l (\alpha_i - \alpha_i^*) x_i^T x + b \quad (7)$$

#### ۴-۲- جمع‌آوری، آماده‌سازی و پردازش داده‌های مورد نیاز

در این پژوهش از داده‌های چاه‌نگاری مناسب شامل GR، تخلخل نوترونی، چگالی کپه‌ای سازند، زمان گذر امواج صوتی و مقاومت ویژه الکتریکی حقیقی به دست آمده از سوند القایی عمیق برداشت شده درون سه حلقه چاه، در محدوده مورد مطالعه استفاده شده است. مقادیر  $S_w$  اندازه‌گیری شده در آزمایشگاه از طریق مغزه نیز برای تمام طول این سه حلقه چاه، در دسترس می‌باشند.

از تعداد کل ۱۲۱۱ داده نقطه‌ای (شامل داده‌های ۵ سوند چاه‌نگاری و مقدار  $S_w$  اندازه‌گیری شده از طریق مغزه)، موجود برای سه حلقه چاه، حدود ۸۰ درصد (۹۸۸ عدد) به‌عنوان داده‌های آموزشی و حدود ۲۰ درصد (۲۲۳ عدد) به‌عنوان داده‌های آزمون (Test) انتخاب شدند.

از آنجایی‌که لیتولوژی تأثیر بسزایی بر روی پارامترهای پتروفیزیکی مخازن دارد. بنابراین در پژوهش حاضر به‌منظور ارائه تصویری از وضعیت واقعی ساختار مخزن، امکان تجسم و درک ملموس‌تری از آن و مقایسه نتایج تخمین مدل‌سازی با واقعیت به‌طور بصری، با استفاده از نرم‌افزار Geolog مطالعه لیتولوژی سازند محدوده مخزن نفتی مورد نظر بر اساس مطالعه مغزه‌ها و تفسیر همزمان پنج نگار چاه، برداشت شده در سه حلقه چاه میدان نفتی مورد مطالعه نیز صورت گرفت و ستون چینه‌شناسی هر سه حلقه چاه ترسیم گردید. به‌عنوان نمونه در شکل ۲ ستون چینه‌شناسی همراه با جزئیات پتروفیزیکی سازند آسماری در حلقه چاه A (با شماره ۰۶۸) ترسیم شده است. در این شکل از چپ به راست به

#### ۴-۱- مبانی نظری روش SVR

الگوریتم SVR یکی از الگوریتم‌های یادگیری ماشین است؛ که بر اساس تئوری آموزش آماری استوار است. این روش که جزو روش‌های آموزش نظارت‌شده (Supervised) است؛ بین داده‌های ورودی و مقدار پارامتر وابسته، بر اساس کمینه‌سازی ریسک ساختاری ارتباط برقرار می‌کند. کمینه‌سازی ریسک ساختاری، نسبت به روش متداول کمینه‌سازی ریسک تجربی مورد استفاده در الگوریتم‌هایی مانند شبکه‌های عصبی و روش‌های کلاسیک آماری، دارای برتری است و برخلاف روش‌هایی همانند شبکه‌های عصبی، به جواب‌های موضعی همگرا نمی‌شود. SVR روشی برای تخمین یک تابع است که بر اساس داده‌های آموزشی از یک شیء ورودی به یک عدد واقعی نگاشت می‌شود. در مسائل رگرسیون، بردارهای ورودی به یک فضای چندبعدی، نگاشت می‌شوند؛ سپس یک ابرصفحه ساخته می‌شود که بردارهای ورودی را با بیشترین فاصله ممکن، از یکدیگر جدا می‌کند. برای رفع مشکل انجام عملیات در فضای با ابعاد زیاد، از یک تابع کرنل استفاده می‌شود. در این صورت عملیات می‌تواند با همان سرعت فضای داده‌های ورودی انجام شود. در واقع با استفاده از تابع کرنل، مشکل چندبعدی و غیرخطی بودن نگاشت، مرتفع می‌شود. فرآیند بهینه‌سازی باید با یک تابع اصلاح شده همراه شود؛ تا سنجش فاصله را دربر گیرد. در حقیقت هدف SVR، تخمین پارامترهای وزن‌ها و ارباب تابعی است که بهترین انطباق را بر داده‌ها داشته باشد (Yu and Kim, 2012). تابع SVR می‌تواند خطی (شکل ۱-الف) یا غیرخطی باشد (شکل ۱-ب) و در حالت غیرخطی، محاسبه تابع رگرسیون در یک فضای ویژگی با ابعاد بالا صورت می‌گیرد؛ که داده‌های ورودی از طریق یک تابع غیرخطی، نگاشت می‌شوند.

با فرض آنکه  $l$  داده آموزشی وجود داشته باشد، اگر هر ورودی  $X$  دارای تعداد  $D$  ویژگی بوده (به عبارت دیگر متعلق به فضایی با بعد  $D$  باشد) و هر نقطه دارای مقدار  $Y$  نظیر ویژه‌ای باشد -مانند تمام روش‌های رگرسیون- هدف پیدا کردن تابعی است که بین ورودی و خروجی رابطه برقرار کند.

$$f(x, w) = w^T x + b \quad (2)$$

برای به دست آوردن تابع  $f$  محاسبه مقادیر  $w$  و  $b$  ضروری است. برای محاسبه مقادیر  $w$  و  $b$  رابطه آتی باید کمینه شود (Vapnik, 1995).


$$R(C) = \frac{1}{2} \|w\|^2 + C \frac{1}{l} \sum_{i=1}^l L_\varepsilon(y_i, f_i(x, w)) \quad (3)$$

که در آن  $C$  پارامتری ثابت بوده و مقدار آن باید به وسیله کاربر مشخص شود. در واقع وظیفه پارامتر ثابت  $C$  ایجاد تعادل و تغییر وزن‌های میزان جریمه ناشی از اغماض (متغیر  $\varepsilon$ ) و در عین

راست و حجم اشغال شده تخلخل مفید با آب (VUWA) با رنگ طوسی روشن (و افزایش از چپ به راست) نمایش داده شده است. بدیهی است بقیه حجم اشغال شده تخلخل مؤثر (رنگ سبز) به هیدروکربور اختصاص می‌یابد.

مقایسه و انطباق نتایج تخمین میزان اشباع‌شدگی سازند در مرحله بعدی، با اشکال نمایشی ستون چینه‌شناسی و ستون اشباع‌شدگی از آب و هیدروکربور سازند ترسیم شده برای سه حلقه چاه، هم از طریق مشاهده چشمی و هم از نظر دقت عددی، به ارزیابی سریع عملکرد الگوریتم مورد استفاده کمک می‌کند.

ترتیب ستون اول، نمودار پرتو گاما (GR)، ستون دوم نمودار قطرسنجی چاه (Caliper)، ستون سوم شامل سه نمودار زمان گذر امواج صوتی (DT)، تخلخل نوترونی (NPHI) و چگالی کپه‌ای سازند (RHOB) و ستون چهارم نمودار مقاومت ویژه حقیقی سوند القایی عمیق (ILD) است. در ستون پنجم نیز لیتولوژی سازند شامل انیدرید (VANH)، دولومیت (VDOL)، کلسیت (VLST)، کوارتز (VSST) و شیل (VSH) به صورت درصد حجمی با رنگ و الگوهای نمایشی مربوطه، نشان داده شده است. در ستون ششم درجه اشباع‌شدگی سازند از آب با نمودار آبی و با افزایش از راست به چپ، میزان تخلخل مؤثر (PHIE) با نمودار مشکی و افزایش از چپ به



شکل ۱: الف - نمایش یک تابع SVR خطی (Ivanciuc, 2007)، ب - نمایش تابع SVR غیرخطی که یک تیوب به شعاع  $\epsilon$  را بر داده‌ها برازش می‌دهد (Smola and Schölkopf, 2003).

مورد استفاده قرار می‌گیرند که تابع کرنل خطی ساده‌ترین نوع آن‌ها است. امروزه تابع پایه شعاعی نسبت به توابع دیگر، اهمیت بیشتری پیدا کرده و مطابق رابطه (۸) اغلب به صورت گوسی بکار می‌رود. هر چند که این تابع به صورت نمایی هم کاربرد دارد. علت استفاده از تابع پایه شعاعی در این پژوهش آن است که این نوع تابع کرنل در موارد زیادی در عمل مورد استفاده قرار گرفته و در موارد استفاده شده به نتایج مطلوبی رسیده است. هر چند توابع کرنل دیگر نیز به صورت سعی و خطا آزمایش شدند؛ ولی بهترین نتیجه مطابق پیش‌بینی، با استفاده از تابع پایه شعاعی به دست آمد. این تابع در حالتی که داده‌ها در بازه  $-1$  و  $1$  باشند، بهترین عملکرد را از خود نشان می‌دهد. بنابراین ابتدا داده‌ها با استفاده از رابطه (۹) بین این دو مقدار نرمالیزه شدند.

$$y_i = 2 \times \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} - 1 \quad (9)$$

در واقع با این تبدیل، کمترین مقدار داده‌ها به عدد  $-1$  و بیشترین مقدار، به عدد  $1$  نگاشت می‌شود. مقادیر بهینه پارامترهای به دست آمده نیز در جدول ۱ آمده است. در این جدول ثابت مثبت C (پارامتر تنظیم برازش) یا پارامتر توازی (Trade off) بین اندازه

### ۳-۴ - تخمین اشباع‌شدگی آب سازند با مدل SVR

به منظور به‌کارگیری روش SVR برای تخمین مقادیر  $S_w$  لازم است که مدل با استفاده از داده‌های ورودی و خروجی مناسب در محیط MATLAB آموزش داده شود. در این پژوهش ورودی‌ها شامل ۵ متغیر (داده‌های چاه‌نگاری) و خروجی نیز تک پارامتر  $S_w$  است. برای ساخت بهترین مدل SVR باید پارامترهای تأثیرگذار آن بهینه شود. به منظور بهینه‌سازی پارامترهای مدل می‌توان از روش جستجو در فضای استفاده نمود که در این پژوهش از روش جستجو در فضای شبکه‌بندی شده پارامترهای بردار پشتیبان با تابع کرنل پایه شعاعی (RBF: Radial Basis Function) گوسی استفاده شد. این تابع کرنل برای دو متغیر  $a$  و  $b$  مطابق رابطه (۸) تعریف می‌شود (Yu and Kim, 2012):

$$K(a, b) = \exp(-\gamma \|a - b\|^2) = \exp\left(-\frac{\|a - b\|^2}{2\sigma^2}\right) \quad (8)$$


که در این رابطه پارامتر  $\gamma$  با عکس مجذور عرض (پهنای) کرنل گوسی ( $\sigma$ ) متناسب است.

به طور کلی در مسائل SVM چهار نوع تابع کرنل خطی، تابع چندجمله‌ای از درجه  $n$ ، تابع پایه شعاعی و تابع تانژانت سیگموئید،

احمدی و امیری بختیار، به کارگیری مدل رگرسیون ماشین بردار پشتیبان به منظور تخمین میزان اشباع‌شدگی آب سازند یکی از میدان‌های نفتی ...، صفحات ۲۱۰-۱۹۹.

راستای عمود برهم مشابه سه ضلع، یک مکعب سه‌بعدی ایجاد کرده و این مکعب، شبکه‌بندی می‌شود. سپس با استفاده از سه حلقه For در محیط نرم‌افزار MATLAB مقدار یک تابع هدف (خطا) کمینه می‌شود. تابع هدف نیز میانگین قدر مطلق اختلاف مقادیر واقعی پارامتر اندازه‌گیری ( $S_w$ ) با مقادیر تخمینی مدل SVR بر اساس مقادیر C،  $\epsilon$  و  $\gamma$  در هر گره از این شبکه، تعریف شد. مقدار اولیه پارامتر  $\epsilon$  معمولاً در ابتدا ۰/۱ انتخاب می‌شود (Ivanciuc, 2007).

حاشیه (Margin) و میزان خطاها و پارامتر  $\epsilon$  معرف دقت تخمین یعنی اختلاف بین مقادیر واقعی و مقادیر تخمینی است (Yu and Kim, 2012). هرچه مقدار C بزرگ‌تر انتخاب شود، اندازه حاشیه کوچک‌تر خواهد بود و برعکس (Hastie et al., 2001; Parrella, 2007). مقادیر بهینه پارامترهای C،  $\epsilon$  و  $\gamma$  با استفاده از روش جستجو در یک فضای شبکه‌بندی شده به دست آمدند. در این روش از طریق تعریف حدود مقادیر بالا و پایین برای این سه پارامتر، در سه



شکل ۲: نمایش ستون چینه‌شناسی همراه با جزئیات پتروفیزیکی سازند آسماری در حلقه چاه A (با شماره ۰۶۸).

جدول ۱: مقادیر بهینه پارامترهای مدل SVR استفاده شده برای تخمین مقادیر  $S_w$ .

پارامتر مدل	ضریب تنظیم برازش (c)	دقت تخمین (ε)	گاما (γ)
مقدار بهینه	۱/۲۰۸	۰/۱۲۳	۲۰/۰۹۴

برای داده‌های آموزش و آزمون در جدول ۲ خلاصه شده است. پارامترهای آماری  $R^2$ ، MSE، MRE و AMRE برای متغیری مانند X به ترتیب مطابق روابط (۱۰) تا (۱۳) تعریف می‌شوند.

$$R^2 = 1 - \frac{\sum_{i=1}^n (X_i - \hat{X}_i)^2}{\sum_{i=1}^n (\bar{X} - \hat{X}_i)^2} \quad (10)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (X_i - \hat{X}_i)^2 \quad (11)$$

$$MRE = \frac{1}{n} \sum_{i=1}^n \left( \frac{X_i - \hat{X}_i}{X_i} \right) \quad (12)$$


$$AMRE = \frac{1}{n} \sum_{i=1}^n \left| \left( \frac{X_i - \hat{X}_i}{X_i} \right) \right| \quad (13)$$

که در این روابط X متغیر مشاهده‌ای یا اندازه‌گیری شده،  $\bar{X}$  میانگین متغیر X و  $\hat{X}$  مقدار تخمینی آن متغیر است. با توجه به این روابط ملاحظه می‌شود که پارامتر MSE معرف میزان خطای مطلق است؛ ولی دو پارامتر دیگر (MRE و AMRE) بیانگر میزان خطای نسبی می‌باشند.

با توجه به داده‌های جدول ۲ ملاحظه می‌شود که میزان ضریب تعیین مدل SVR هم برای داده‌های آموزشی و هم برای داده‌های آزمون دارای مقدار بیشتر از ۰/۷ است که مطلوب ارزیابی می‌شود. همچنین مقادیر پارامترهای خطا هم برای داده‌های آموزشی و هم برای داده‌های آزمون، اندک است. بنابراین رویکرد پیشنهادی پارامتر  $S_w$  مخزن را با دقت مطلوبی پیش‌بینی نموده است.

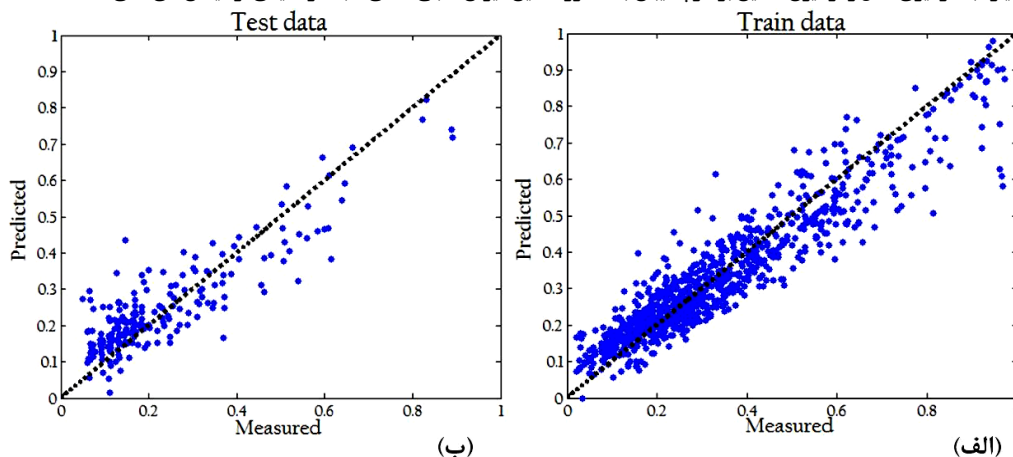
در شکل ۳ شمای کلی از ساختار (معماری) مدل SVR استفاده شده در این مقاله نشان داده شده است. عملکرد الگوریتم از طریق اعتبارسنجی متقابل بر اساس معیارهای مختلف همانند ترسیم نمودار پراکندگی مقادیر اندازه‌گیری‌های آزمایشگاهی  $S_w$  از روی مغزه‌ها در مقابل مقادیر تخمینی، با استفاده از داده‌های چاه‌نگاری سه حلقه چاه، توسط مدل SVR و محاسبه پارامترهای آماری معرف خطا، اعتبارسنجی شده است. شکل ۴ نمودار پراکندگی مقادیر اندازه‌گیری شده  $S_w$  در مقابل مقادیر تخمینی توسط مدل SVR را برای داده‌های آموزشی (شکل الف) و آزمون (شکل ب) نشان می‌دهد. با توجه به این شکل مشاهده می‌شود که پراکندگی داده‌ها عمدتاً حول خط نیمساز ربع اول است. در شکل‌های ۵ و ۶ نیز مقادیر اندازه‌گیری شده  $S_w$  در مقابل مقادیر تخمینی توسط مدل SVR به ترتیب برای داده‌های آموزشی و آزمون، مقایسه شده است. با دقت در این دو شکل و مشاهده چشمی نیز می‌توان میزان انطباق داده‌های مشاهده‌ای با مقادیر تخمینی را مطلوب ارزیابی نمود. بنابراین در مجموع با توجه به این شکل‌ها می‌توان نتیجه‌گیری نمود که مدل SVR از توانایی لازم برای مدل‌سازی  $S_w$  سنگ مخزن با استفاده از داده‌های مناسب چاه‌نگاری برخوردار است.

ارزیابی عملکرد رویکرد پیشنهادی (مدل SVR) بر اساس پارامترهای آماری مختلف شامل ضریب تعیین (Coefficient of determination) داده‌های مشاهده‌ای و تخمینی ( $R^2$ )، میانگین مربعات خطای تخمین (MSE: Mean Squared Error)، میانگین خطای نسبی (MRE: Mean Relative Error) و قدر مطلق میانگین خطای نسبی (AMRE: Absolute of Mean Relative Error) که همگی معرف میزان دقت (خطای) تخمین می‌باشند،

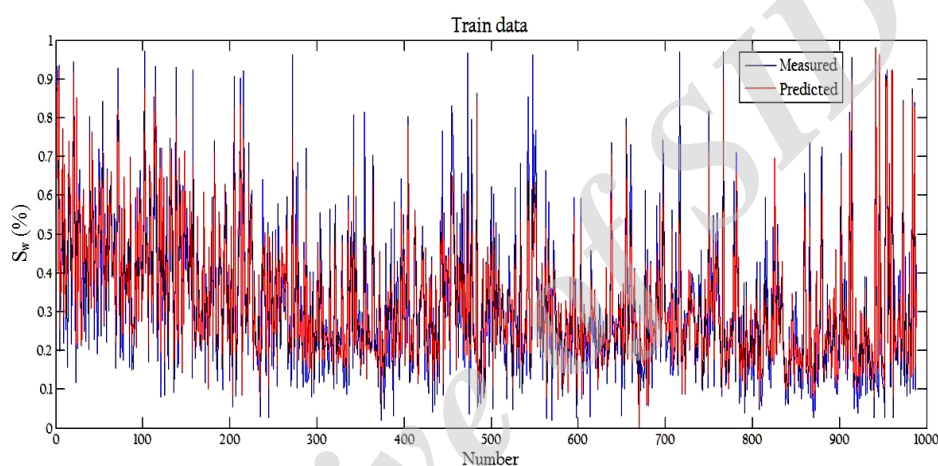


شکل ۳: شمایی از ساختار SVR استفاده شده در پژوهش حاضر با ۵ ورودی.

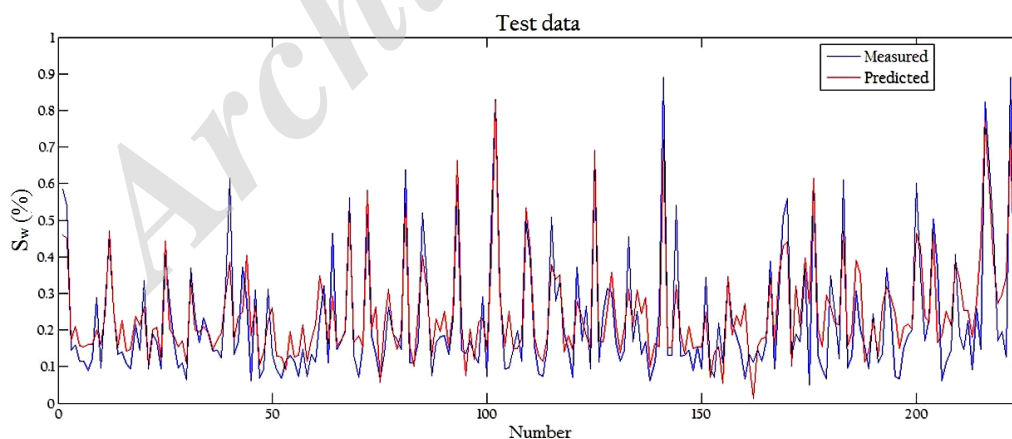
احمدی و امیری بختیار، به کارگیری مدل رگرسیون ماشین بردار پشتیبان به منظور تخمین میزان اشباع‌شدگی آب سازند یکی از میدان‌های نفتی ...، صفحات ۲۱۰-۱۹۹.



شکل ۴: مقادیر اندازه‌گیری شده  $S_w$  در مقابل مقادیر تخمینی مدل SVR برای الف- داده‌های آموزشی و ب- داده‌های آزمون.



شکل ۵: مقایسه مقادیر اندازه‌گیری شده  $S_w$  با مقادیر تخمینی مدل SVR برای داده‌های آموزشی.



شکل ۶: مقایسه مقادیر اندازه‌گیری شده  $S_w$  با مقادیر تخمینی مدل SVR برای داده‌های آزمون.

جدول ۲: پارامترهای آماری مدل SVR استفاده شده برای تخمین مقادیر  $S_w$ .

روش	نوع داده	$R^2$	MSE	MRE	AMRE
SVR	آموزشی	۰/۸۷۳۷	۰/۰۰۵۲	-۰/۱۴۹۲	۰/۲۸۱۱
	آزمون	۰/۷۶۴۱	۰/۰۰۶۵	-۰/۳۰۱۷	۰/۴۳۰۱



- Adeniran, A., Elshafei, M. and Hamada, G., 2009, Functional network soft sensor for formation porosity and water saturation in oil wells, Instrumentation and Measurement Technology Conference, I2MTC '09. IEEE, Singapore, 113-1143.
- Aminzadeh, F. and Brouwer, F., 2006, Integrating neural networks and fuzzy logic for improved reservoir property prediction and prospect ranking, 2006, SEG Annual Meeting, 1-6 October, New Orleans, Louisiana, Society of Exploration Geophysicists.
- Archie, G.E., 1942, The electrical resistivity log as an aid in determining some reservoir characteristics, Petroleum Transactions of AIME, 146, 54-62.
- Bagheripour, P. and Asoodeh, M., 2014, Genetic implanted fuzzy model for water saturation determination, Journal of Applied Geophysics, 103, 232-236.
- Basak, D., Srimanta Pal, S. and Patranabis, D.C., 2007, Support vector regression, neural information processing.
- Cheng, D.Z., Xi Ling, W. and Ju-An, C., 1993, Determining reservoir properties in reservoir studies using a fuzzy neural network, SPE Annual Technical Conference and Exhibition, 3-6 October, Houston, Texas, Society of Petroleum Engineers, 141-150.
- Cuddy, S.J., 2000, Litho-facies and permeability prediction from electrical logs using fuzzy logic, SPE Reservoir Evaluation & Engineering, Society of Petroleum Engineers, 3(4), 319-324.
- Gunn, S.R., 1998, Support vector machines for classification and regression, Technical Report, Faculty of engineering, science and mathematics, University of Southampton.
- Hastie, T., Tibshirani, R. and Friedman, J., 2001, The elements of statistical learning: data mining, Inference, and Prediction, Springer, New York.
- Ivanciuc, O., 2007, Applications of support vector machines in chemistry, Reviews in Computational Chemistry, 23, 291.
- Jafari Kenari, S.A. and Mashohor, S., 2013, Robust committee machine for water saturation prediction, Journal of Petroleum Science and Engineering, 104, 1-10.
- Joachims, T., 2003, Support Vector and Kernel Methods, Cornell University Computer Science Department, <http://www.Joachims.org>
- Li, H.D., Liang, Y. and Xu, Q., 2009, Support vector machines and its applications in chemistry, Chemometrics and Intelligent Laboratory Systems,


در پژوهش حاضر از روش هوشمند مبتنی بر آمار رگرسیون ماشین بردار پشتیبان با استفاده از داده‌های مناسب چاه‌نگاری پرتو گاما، تخلخل نوترونی، چگالی کپه‌ای سازند، زمان گذر امواج صوتی و مقاومت ویژه حقیقی سازند برای تخمین  $S_w$  سنگ مخزن یکی از میدان‌های بزرگ نفتی جنوب غربی کشور استفاده شد. نتایج پژوهش بر اساس ترسیم نمودار پراکندگی مقادیر اندازه‌گیری شده  $S_w$  در مقابل مقادیر تخمینی توسط مدل SVR و محاسبه پارامترهای آماری مختلف معرف دقت، نشان می‌دهند که مدل SVR پیشنهادی می‌تواند این پارامتر پتروفیزیکی مهم را به روش غیرمستقیم و با دقت بالایی تخمین زند، به‌گونه‌ای که میزان ضریب تعیین همبستگی بین داده‌های اندازه‌گیری شده در آزمایشگاه از طریق مغزه، با داده‌های تخمینی در مرحله آموزشی، بیش از ۸۷ درصد و برای مرحله آزمون، بیش از ۷۶ درصد است. این میزان همبستگی برای داده‌ها به‌ویژه در مرحله آزمون، مطلوب ارزیابی می‌گردد. مقایسه و مطابقت نتایج حاصل از تخمین، با اشکال نمایشی ستون لیتولوژی و ستون اشباع‌شدگی آب و هیدروکربور سازند، همراه با جزئیات پتروفیزیکی سازند آسماری در سه حلقه چاه محدوده مورد مطالعه، ترسیم شده با استفاده از نرم‌افزار Geolog، هم به روش مشاهده چشمی و هم از نظر دقت عددی، اعتبار عملکرد الگوریتم مورد استفاده را تأیید می‌نماید. بنابراین روش پیشنهادی (SVR) یک روش دقیق، سریع و ارزان برای ارزیابی پارامتر پتروفیزیکی مهم  $S_w$  سنگ مخزن است.

## ۶- منابع

- اداره مطالعات زمین‌شناسی شرکت ملی مناطق نفت‌خیز جنوب، ۱۳۸۷، گزارش زمین‌شناسی گسترشی (از مجموعه گزارش‌های داخلی مناطق نفت‌خیز جنوب).
- علی‌مرادی، ا.، ۱۳۹۰، ارائه روشی برای تخمین اشباع هیدروکربور مخازن کربناته به کمک نشانگرهای لرزه‌ای و داده‌های چاه، رساله دکتری، دانشکده مهندسی معدن، نفت و ژئوفیزیک، دانشگاه صنعتی شاهرود.
- محمدی، ا.، ۱۳۸۳، تعیین گروه‌های سنگی مخزنی سازند آسماری بر مبنای لاگ‌های پتروفیزیکی با استفاده از روش منطق فازی، پایان‌نامه کارشناسی ارشد، دانشکده زمین‌شناسی، دانشگاه تهران.
- مراذزاده، ع.، سلیمی دلشاد، ی. و کاظم‌زاده، ع. ا.، ۱۳۹۲، بهبود محاسبه اشباع آب در مخازن هیدروکربوری کربناته به کمک داده‌های چاه‌نگاری و آزمایشگاهی، مجله فیزیک زمین و فضا، ۳۹ (۱)، ۱۰۷-۱۲۱.
- مطیعی، ه.، ۱۳۸۲، زمین‌شناسی ایران، چینه‌شناسی زاگرس، سازمان

احمدی و امیری بختیار، به کارگیری مدل رگرسیون ماشین بردار پشتیبان به منظور تخمین میزان اشباع‌شدگی آب سازند یکی از میدان‌های نفتی ...، صفحات ۲۱۰-۱۹۹. RBF SVM parameters, <http://scikit-learn.org>.

- Singh, S., 2005, Permeability prediction using artificial neural network (ANN): A case study of Uinta basin, SPE Annual Technical Conference and Exhibition, 9-12 October, Dallas, Texas, Society of Petroleum Engineers.
- Smola, A.J. and Schölkopf, B., 2003, A tutorial on support vector regression, *Statistics and Computing*, 14 (3), 199-222.
- Vapnik, V., 1995, *The nature of statistical learning theory*, Springer, New York.
- Yu, H. and Kim, S., 2012, SVM tutorial: classification, regression, and ranking, *Handbook of Natural Computing*, Springer Berlin Heidelberg, 479-506.
- Zisserman, A., 2015, Lecture 3: SVM dual, kernels and regression, C19 Machine Learning, Hilary, <http://www.robots.ox.ac.uk/~az/lectures/ml/>.
- Lim, J.S., Park, H.J. and Kim, J., 2006, A new neural network approach to reservoir permeability estimation from well logs, SPE Asia Pacific Oil & Gas Conference and Exhibition, 11-13 September, Adelaide, Australia, Society of Petroleum Engineers.
- Luthi, E.M., 2001, *Geological well logs, their use in reservoir modeling*, Springer-Verlag Berlin Heidelberg, Germany.
- Parrella, F., 2007, *Online support vector regression*, A thesis presented for the degree of information science, Department of Information Science, University of Genoa, Italy.
- Parviainen, M., 2012, *Radial Basis Function (RBF) and Support Vector Machines (SVM) networks*, Tampere University of Technology, [www.cs.tut.fi](http://www.cs.tut.fi).
- Scikit-learn developers (BSD License), 2010-2014,



## Application of support vector regression to estimate the formation water saturation in one of the largest oil fields located in the southwest of Iran

Reza Ahmadi<sup>1\*</sup> and Mohammad-Sadegh Amiri Bakhtiar<sup>2</sup>

1- Assistant professor, Mining Engineering Department, Arak University of Technology, Arak, Iran

2- M.Sc. Student, Abadan Petroleum University of Technology, Abadan, Iran

Received: 1 April 2017; Accepted: 17 October 2017

\* Corresponding author: rezahmadi@gmail.com

### Keywords

Water Saturation ( $S_w$ )  
Support Vector Regression (SVR)  
Asmari Formation  
Well Logs Data

### Extended Abstract

#### Summary

Water saturation ( $S_w$ ) of a hydrocarbon reservoir is an important petrophysical parameter having a great impact on the accuracy of primitive estimation of the reservoir. Due to highly importance of this parameter dealing with the economic calculations of the reservoir, it must be estimated precisely.

Although experimental analysis of core samples taken from a reservoir leads to very useful information about  $S_w$  of the reservoir, this experimental method is highly expensive and time consuming; and therefore, this method is applicable only for a small number of wells in a field. To overcome this problem, an intelligent pattern recognition method, known as support vector regression (SVR), has been employed in the current research to estimate  $S_w$  from well logs data of 3 wells in one of the largest oil fields of Iran. The performance of the algorithm has also been validated through different criteria. The results of this research indicate that the SVR model can estimate  $S_w$  from well logs data accurately, in which the determination coefficients of 87 and 76 percent have been obtained from the training and test steps, respectively.

### Introduction

Generally in most commonly hydrocarbon reservoirs,  $S_w$  is estimated using well logs data through applying Archie's fundamental empirical relation. However, this relation is just satisfied for clean sandstone formations (without clay minerals). So far several empirical models have been proposed to measure  $S_w$  using well logs data. The main disadvantage of these models is their formation dependency, which makes the models specific and not comprehensive to be applied in a variety of other formations. In addition to empirical methods, several linear regression techniques have also been applied to estimate this parameter using well logs data. These techniques cannot estimate  $S_w$  appropriately due to the complexity of the parameter features. Resistivity and porosity logs are the most important well logs used to estimate  $S_w$  by Archie's relation. The porosity of a formation can be very accurately determined through sonic, density and neutron logs. However, resistivity logs are very sensitive to the presence of shale and other clayey impurities in formations. Their effects can be adjusted by means of gamma ray (GR) log. Therefore, to estimate  $S_w$ , employing an intelligent method using appropriate well logs data will be useful. The oil reservoir, studied in this research, is located in Asmari formation in southwest of Zagros Mountain. Overall this formation in the investigated region has been formed from a sequence comprising of carbonate rocks (limestone and dolomite), sandstone and shale.

### Methodology and Approaches

In the current research, to estimate  $S_w$ , SVR method has been applied to well logs data from 3 wells in one of the largest oil fields of Iran. In this study, appropriate well logs data comprising of GR, neutron porosity, formation bulk density, sonic transit time and true resistivity from deep induction log (ILD) have been used. Moreover,  $S_w$  values measured from cores in the laboratory are available for whole depth of the wells. In order to employ SVR to estimate  $S_w$ , the model needs to be trained using appropriate input and output data in MATLAB environment. In the current research, the input consists of 5 variables (well logs data) while the output is only the  $S_w$  parameter. From 1211 data points (containing 5 variables of well logs data and  $S_w$  parameter measured by core) available from the 3 wells, about 80 percent (i.e. 988 samples) were selected for training and the remaining 20 percent (i.e. 223 samples) were chosen for test. To compare the estimated values with the measured ones for the reservoir in the study region, visually, chart of lithology, water and hydrocarbon saturations of the formation were also depicted for the 3 wells by means of Geolog software.

**Results and Conclusions**

The performance of the algorithm has been validated through different criteria such as scatter plot of  $S_w$  values from cores versus the estimated  $S_w$  values from well logs data of 3 study wells by means of SVR model as well as computing statistical parameters indicating the accuracy of the results. Furthermore, the results of the research revealed that the SVR model can estimate  $S_w$  using well logs data accurately so that it has estimated the training and test data with the determination coefficients of 87 and 76 percent, respectively. As a result, the proposed method, i.e. SVR, is an accurate, fast and cost-effective method to evaluate the petrophysical parameter  $S_w$ .

---

Archive of SID