

## تخمین سرعت حفاری با سیال کف با استفاده از شبکه عصبی مصنوعی

### رگرسیون عمومی

بهروز باغبانی<sup>۱</sup>، علی مرادزاده<sup>۲</sup>، علی نخعی<sup>۳</sup>، رضا روکی<sup>۴</sup>

۱- شاهرود، دانشگاه صنعتی شاهرود

پست الکترونیک [en.baghbani@gmail.com](mailto:en.baghbani@gmail.com)

### چکیده

سرعت حفاری یا به بیان دیگر نرخ نفوذ مته از مهمترین پارامترها در عملیات حفاری می‌باشد. از آنجا که عملیات حفاری سهم قابل توجهی از هزینه‌های اکتشاف و بهره‌برداری مواد هیدروکربوری را به خود اختصاص می‌دهد، تخمین سرعت حفاری از اهمیت ویژه‌ای برخوردار است. بدست آوردن ارتباط صحیح بین پارامترهای حفاری جهت تخمین سرعت حفاری اهمیت بالایی دارد، که شبکه‌های عصبی قادر به بدست آوردن ارتباط صحیح بین پارامترهای حفاری و نرخ نفوذ مته می‌باشند. در این مقاله به تخمین سرعت حفاری با سیال کف با روش شبکه عصبی مصنوعی رگرسیون عمومی برای چاه شماره ۶ میدان شانول، پرداخته می‌شود. میدان شانول واقع در جنوب ایران، منطقه فارس ساحلی می‌باشد. این میدان جزء میداین گازی کشور بوده که چاه شماره ۶ این میدان حدود ۲۸۰۰ متر با کف حفاری شده است. نتایج حاصل نشان دهنده قابلیت بالای شبکه عصبی در تخمین سرعت حفاری با توجه پارامترهای دخیل در حفاری می‌باشد.

واژه‌های کلیدی: شبکه عصبی رگرسیون عمومی، سیال کف، سرعت حفاری

---

۱- دانشجوی کارشناسی ارشد حفاری و بهره‌برداری نفت

۲- استاد دانشگاه صنعتی شاهرود

۳- استادیار انیستیتو نفت، دانشگاه تهران

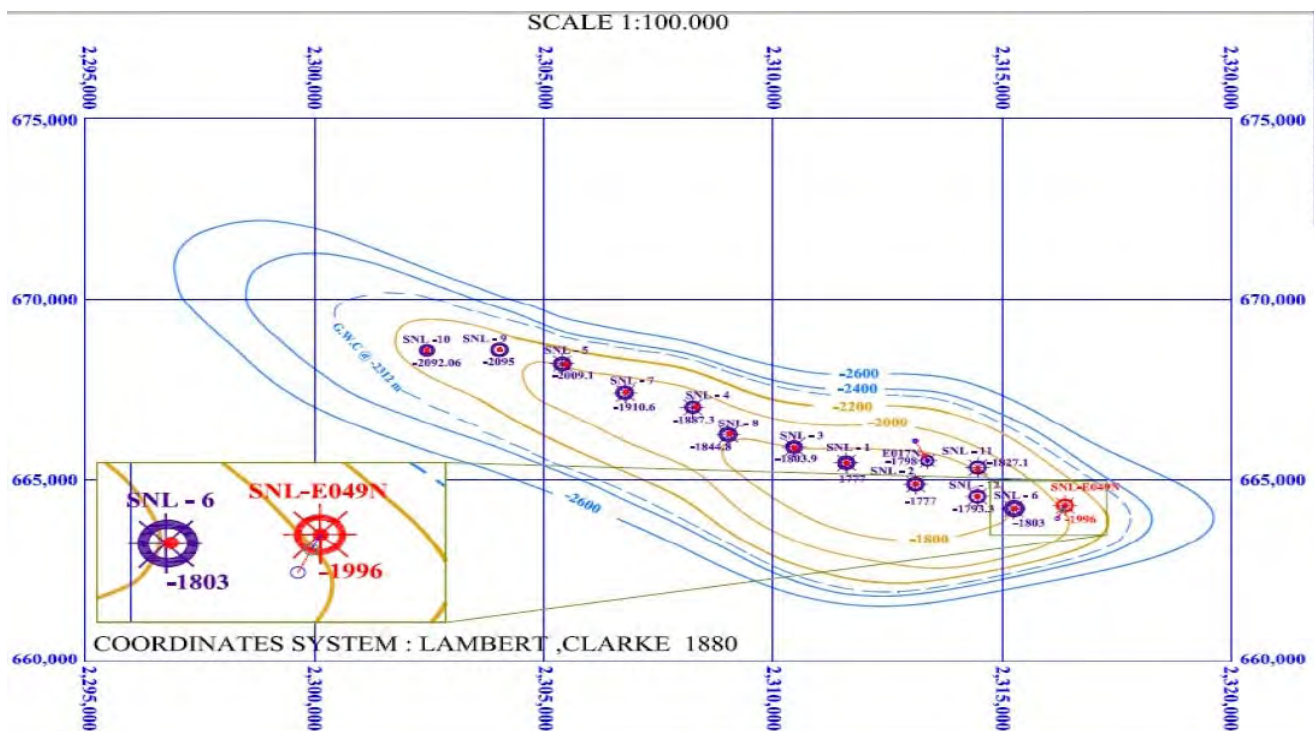
۴- دانشجوی دکتری اکتشاف معدن، دانشگاه صنعتی شاهرود

## مقدمه

کشور ایران یکی از کشورهای مستعد از لحاظ منابع نفت و گاز است در نتیجه توسعه میدانهای نفتی و گازی با استفاده از روش‌های مانند حفاری فرو تعادلی در کشور از اهمیت خاصی برخوردار است. در همین راستا بدست آوردن رابطه‌ای بین پارامترهای حفاری جهت تخمین سرعت حفاری به عنوان کاهش هزینه حفاری بسیار قابل اهمیت می‌باشد. نرخ نفوذ حاصل از مته حفاری به همراه نرخ فرسودگی مته، تأثیری قطعی و مستقیم روی هزینه‌های حفاری به ازای هر فوت دارند. اندازه‌گیری سرعت حفاری از اهمیت زیادی برای زمین‌شناس بر خوردار است. زیرا شاخص بلاواسطه‌ای را برای او فراهم می‌کند که نسبت به تغییرات لیتولوژی حساس بوده و می‌تواند در کنار نتایج حاصل از چاه پیمایی مورد بررسی قرارگیرد [۱]. در مطالعات عوامل موثر بر سرعت حفاری ما با متغیرهایی سروکار داریم که به نوعی با چند متغیر دیگر در ارتباط هستند. در نتیجه برای بهتر و صحیح‌تر جواب گرفتن جهت تخمین سرعت حفاری، می‌بایست از روش رگرسیون خطی چند متغیره و یا شبکه‌های عصبی مصنوعی برای برقراری نوعی ارتباط بین این متغیرها استفاده نمود. شبکه‌های عصبی مصنوعی اخیراً کاربردهای زیادی در علوم مختلف داشته‌اند که قابلیت بالای آنها را در کارهای مختلف به خصوص در مهندسی نفت می‌توان مشاهده نمود [۲ و ۳]. شبکه عصبی رگرسیون عمومی در واقع نوعی شبکه شعاعی با ساختار موازی است. این شبکه با توجه به سرعت زیاد برآورد و همچنین پارامترهای کمتر قابل تنظیم نسبت به شبکه پس انتشار خطا، در بسیاری از موارد ارجحیت دارد. در این زمینه استفاده از این شبکه می‌توان به مدل سازی و تشخیص الگوی زمین‌شناسی با شبکه عصبی رگرسیون عمومی (هوانگ و ویلیامسون، ۱۹۹۴) [۴]، تعیین خواص مخزن با استفاده از معکوس‌سازی هوشمند داده‌های لرزه‌ای (آرتن و همکاران، ۲۰۰۵) [۵]، و توسعه نگارهای مصنوعی هوشمند (رولان، ۲۰۰۴) [۶]، اشاره کرد. در این مطالعه در نظر است با اجرای یک رشته کدنویسی در محیط نرم افزار متلب (MatLab) توانمندی‌های این روش برای برآورد سرعت حفاری در چاه شماره ۶ میدان شانول به کمک داده‌های پارامترهای حفاری این چاه مورد بررسی قرار گیرد.

## زمین‌شناسی منطقه


میدان گازی شانول در منطقه فارس ساحلی، حدود ۲۰۰ کیلومتری جنوب شیراز قرار دارد. چاه شماره ۶ این میدان به صورت عمودی تا عمق ۳۵۸۴ متر حفر شده است، که از عمق ۷۶ متری تا ۲۹۲۹ متری این چاه با سیال کف حفاری شده است. شکل ۱ نقشه توپوگرافی شانول را نشان می‌دهد و همچنین موقعیت چاه شماره ۶ شانول را در این میدان، نسبت به دیگر چاه‌ها نشان می‌دهد. سازندهای موجود در این میدان به ترتیب شامل سازند میشان، سازند گچساران، سازند آسماری و جهرم، سازند پابده، سازند گورپی، سازند ایلام، سازند لافان، سازند سروک، سازند کژدمی، سازند داریان، سازند گدوان، سازند فهلیان، سازند هیث، سازند سرمه، سازند نیریز، سازند دشتک، سازند کنگان و سازند دالان می‌باشد. در این چاه از بالای سازند گچساران تا بالای سازند کنگان حفاری با سیال کف شده است. به علت زیادی توضیح لیتولوژی فقط نام لیتولوژی این سازندها گفته می‌شود، و باید توجه داشت که این لیتولوژی‌ها در سازندهای مختلف نام برده شده با رنگ و مقاومت مختلفی می‌باشند. لیتولوژی سازندهای نام برده شده شامل سنگ آهک، سنگ سیلیت، دولومیت، سنگ رس، انیدریت و شیل می‌باشد.



شکل ۱- نقشه توپوگرافی میدان شانول و موقعیت چاه شماره ۶

### شبکه عصبی مصنوعی رگرسیون عمومی<sup>۵</sup>

GRNN را می‌توان به عنوان یک شبکه شعاعی نرمالیزه شده در نظر گرفت که برای هر الگوی آموزشی یک نرون در لایه پنهان دارد. این شبکه یک الگوریتم یادگیری تک گذر با ساختار موازی است که در سال ۱۹۹۰ توسط اسپچت<sup>۶</sup> اختراع شد. این شبکه بر اساس تابع چگالی احتمال (Probability density function) پایه گذاری شده و از خصیصه‌های آن زمان آموزش سریع و مدل سازی توابع غیر خطی است. صورت الگوریتمی این شبکه برای هر مسئله رگرسیونی در جایی که هیچگونه فرضیاتی برای قضاوت خطی بودن نباشد، می‌توان استفاده کرد. این شبکه پارامترهای شبکه پس انتشار خطا را ندارد ولی در عوض فاکتور تعدیلی (Smooth factor) دارد که مقدار بهینه آن در طی آموزش با سعی و خطا با توجه به میانگین مربعات خطا بدست می‌آید [۷]. همانطور که در شکل ۲ نشان داده شده است، ساختار این شبکه شبیه به ساختار کلی شبکه شعاعی است؛ فقط تفاوت جزئی در لایه دوم دارد [۸].



<sup>5</sup> - General regression neural network (GRNN)

<sup>6</sup> - Specht

شکل ۲- ساختار شبکه عصبی رگرسیون عمومی

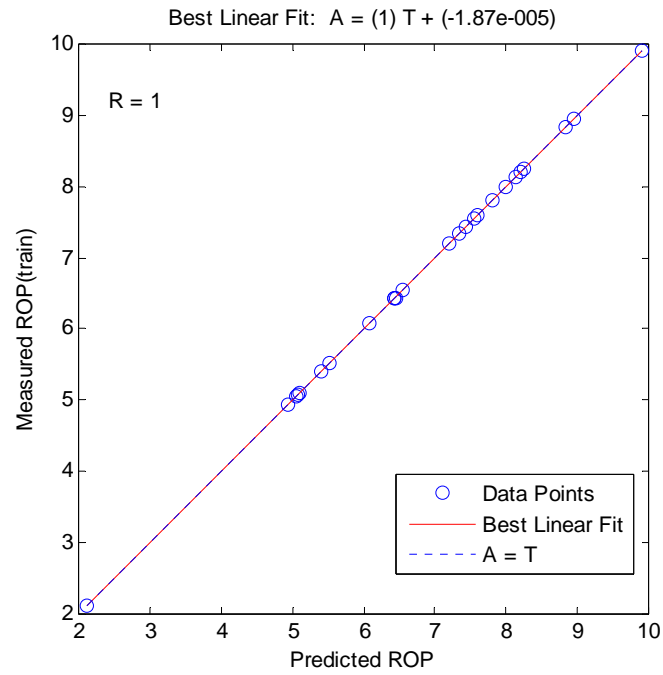
تخمین سرعت حفاری

جدول ۱ فاکتورهای استفاده شده به عنوان ورودی به شبکه عصبی را نشان می‌دهد. این داده‌ها برای آموزش و تست شبکه که در بازه ۱- و ۱، نرمال شده بودند، استفاده گردیدند. ورودی های شبکه شامل عمق، وزن روی مته، چرخش لوله حفاری، فشار پمپ، گشتاور، تزریق سیال، حجم هوا، فرسودگی دندان مته و لیتولوژی سازند می باشد.

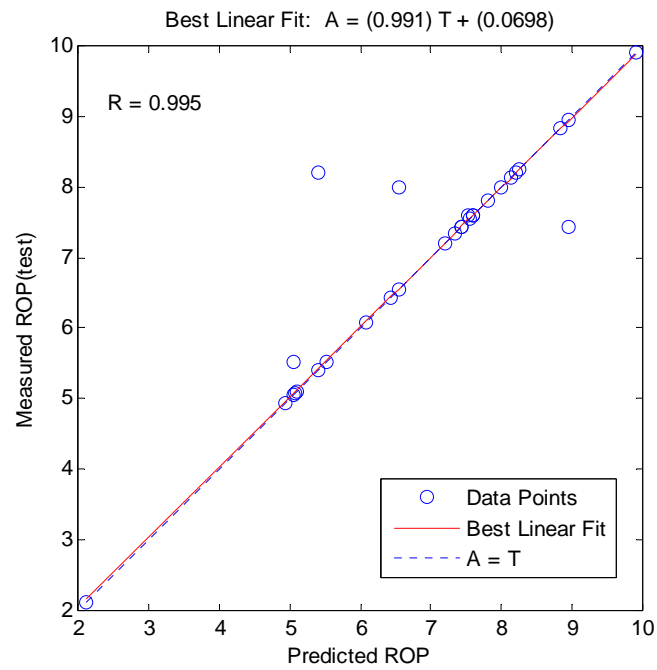
جدول ۱- فاکتورها و نمونه داده‌های شانول ۶ جهت ورودی به شبکه عصبی

سرعت حفاری (متر بر ساعت)	عمق (متر)	وزن روی مته (کیلو پوند)	چرخش لوله حفاری (rpm)	فشار پمپ (psi)	گشتاور (klb.ft)	تزریق (گالن بر دقیقه)	حجم هوا (استاندارد فوت مکعب)	فرسودگی دندان مته	لیتولوژی سازند (%)
۲,۱۱	۷۶	۷	۶۸	۳۶۰	۱	۱۳۰	۴۰۰۰	۰,۳۶۷۸	آهکی ۱۰۰٪
۲,۱۱	۷۷	۷	۶۸	۳۶۰	۱,۹	۱۳۰	۴۰۰۰	۰,۳۶۸۱	آهکی ۱۰۰٪
۲,۱۱	۷۸	۷	۶۸	۳۶۰	۱,۹	۱۳۰	۴۰۰۰	۰,۳۶۸۳	آهکی ۱۰۰٪
۲,۱۱	۷۹	۷	۶۸	۳۶۰	۲,۳	۱۳۰	۴۰۰۰	۰,۳۶۸۶	آهکی ۱۰۰٪
۷,۸۱	۲۰۱	۱۹	۱۰۵	۳۲۰	۳	۱۰۰	۴۰۰۰	۰,۴۰۱۲	دولومیتی ۹۰٪
۷,۸۱	۲۰۲	۱۹	۱۰۵	۳۲۰	۲,۴	۱۰۰	۴۰۰۰	۰,۴۰۱۵	دولومیتی ۹۰٪
۷,۸۱	۲۰۳	۱۹	۱۰۵	۳۲۰	۲,۴	۱۰۰	۴۰۰۰	۰,۴۰۱۸	دولومیتی ۹۰٪
۷,۸۱	۲۰۴	۱۹	۱۰۵	۳۲۰	۲,۵	۱۰۰	۴۰۰۰	۰,۴۰۲۱	دولومیتی ۹۰٪
۸,۲۵	۱۵۰۱	۱۳	۹۵	۷۶۰	۵,۲	۱۱۵	۴۱۰۰	۰,۳۹۸۵	شیلی ۸۰٪
۸,۲۵	۱۵۰۲	۱۳	۹۵	۷۶۰	۵,۲	۱۱۵	۴۱۰۰	۰,۳۹۸۸	شیلی ۸۰٪
۸,۲۵	۱۵۰۳	۱۳	۹۵	۷۶۰	۴,۷	۱۱۵	۴۱۰۰	۰,۳۹۹۱	شیلی ۸۰٪

برای بدست آوردن سرعت حفاری، از تعداد ۲۸۵۴ داده، ۷۰ درصد این مقدار را به طور تصادفی برای آموزش و ۳۰ درصد را برای آزمون شبکه انتخاب شد. برای بالا بردن قابلیت تشخیص شبکه، ورودی‌های شبکه در بازه ۱- و ۱ نرمال شدند. شبکه‌های مختلف با فاکتور تعدیل های مختلف جهت بدست آوردن شبکه بهینه اجرا گردید و در نهایت فاکتور تعدیل ۰/۰۲ به عنوان بهینه انتخاب گردید و سرعت حفاری در دو سری داده آموزش و تست توسط شبکه تخمین زده شد. ضریب همبستگی بین نرخ نفوذ پیش‌بینی شده و اندازه گیری شده در دو سری داده آموزش و تست به ترتیب در شکل‌های ۳ و ۴ نشان داده شده است. هرچه مقدار ضریب همبستگی و شیب خط به عدد ۱ نزدیک تر باشد، پراکندگی داده‌ها حول خط برازش کمتر و نشان از پیش‌بینی خوب می‌باشد. مقدار ضریب همبستگی در دو سری داده آموزش و تست به ترتیب برابر با ۱ و ۰/۹۹ می باشد. همچنین مقدار خطای نسبی حاصل از شبکه برای دو سری داده آموزش و تست به ترتیب برابر با ۰/۰۰۰۱۲ و ۰/۱۲ می‌باشد.



شکل ۳. سرعت حفاری اندازه گیری شده در مقابل سرعت حفاری پیش بینی شده توسط شبکه عصبی در داده های آموزش



شکل ۴. سرعت حفاری اندازه گیری شده در مقابل سرعت حفاری پیش بینی شده توسط شبکه عصبی در داده های تست

## نتیجه گیری

در این مطالعه از روش شبکه عصبی رگرسیون عمومی برای برآورد سرعت حفاری در چاه شماره ۶ میدان شانول با استفاده از پارامترهای دخیل در سرعت حفاری از جمله عمق، وزن روی مته، چرخش لوله حفاری، فشار پمپ، گشتاور، تزریق سیال، حجم هوا، فرسودگی دندان مته و لیتولوژی سازند استفاده گردید. فاکتور تعدیل بهینه برای شبکه مقدار ۰/۰۲ بدست آورده شد و با استفاده از این فاکتور تعدیل مقدار سرعت حفاری در دو سری داده آموزش و تست بدست آورده شد. ضریب همبستگی بین مقدار پیش بینی و اندازه گیری شده در دو سری داده آموزش و تست برابر با ۱ و ۰/۹۹ می باشد که نشان از قابلیت بالای شبکه برای پیش بینی سرعت حفاری از روی پارامترهای موثر بر آن است.

## تشکر و قدردانی

از مهندس حمیدرضا عباسی، کارشناس ارشد برنامه ریزی اداره حفاری شرکت نفت مرکزی ایران برای زحمات فراوان ایشان جهت قرار دادن اطلاعات در اختیار اینجانب، کمال تشکر را دارم.

## منابع

- [1] Bourgoyne, A.T., Millheim, K.K., Chenevert, M.E. and Young, F.S., Applied Drilling Engineering, SPE Textbook Series, Vol. 2, Richardson, TX, 1986.
- [2] Mohaghegh, S., Ameri, S., 1995., Artificial Neural Network As A Valuable Tool For Petroleum Engineers, SPE29220, Proceedings, SPE, West Virginia.
- [3] Mohaghegh, S., 2000., Virtual- Intelligence Applications in Petroleum Engineering : Part I – Artificial neural networks, Journal of Petroleum Science and Engineering.
- [4] Huang, Z. and Williamson, M. A., 1994., Geological pattern recognition and modeling with a general regression neural network, Canadian Journal of Exploration Geophysics, 30(1), 60–68.
- [5] Artun, E., Mohaghegh, S. and Toro, J., 2005., Reservoir Characterization Using Intelligent Seismic Inversion, SPE98012, West Virginia University.
- [6] Rolon, L., 2004., Developing Intelligent Synthetic Logs: Application to Upper Devonian Units in PA, M.Sc. thesis, West Virginia University, Morgantown, West Virginia.
- [7] Bhatt, A., 2002., Reservoir properties from well logs using neural networks, A dissertation for the partial fulfillment of requirements for the degree of PhD at the Department of Petroleum Engineering and Applied Geophysics, Norwegian University of Science and Technology.
- [8] Demuth, H. and Beale, M., 2002., Neural Network Toolbox For Use with MATLAB, User's Guide Version 4.