



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

مهدی یحیی، بابک نوادی، حمیدرضا عباسی، شرکت نفت مناطق مرکزی ایران

پرویز باغبانی، علی برادزاده، دانشکاه صنعتی شاهرود

چکیده

سرعت حفاری یا به بیان دیگر، نرخ نفوذ مته، از مهمترین پارامترها در عملیات حفاری است. 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. به دست آوردن ارتباط صحیح بین پارامترهای حفاری جهت تخمین سرعت حفاری، اهمیت بالایی دارد. شبکه‌های عصبی قادر به تعیین ارتباط صحیح بین پارامترهای حفاری و نرخ نفوذ مته هستند. در این مقاله تخمین سرعت حفاری با سیال کف به روش شبکه عصبی مصنوعی رگرسیون عمومی برای چاه شماره X میدان مورد مطالعه، بررسی می‌شود. میدان مورد مطالعه واقع در جنوب ایران، منطقه فارس ساحلی است. این میدان جزو میادین گازی کشور بوده که چاه شماره X این میدان حدود ۲۸۰۰ متر با کف، حفاری شده است. نتایج حاصله، نشان‌دهنده قابلیت بالای شبکه عصبی در تخمین سرعت حفاری با توجه به پارامترهای دخیل در حفاری می‌باشد.

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

### مقدمه

و همچنین پارامترهای کمتر-قابل-تنظیم، نسبت به شبکه پس انتشار خطا، در بسیاری از موارد ارجحیت دارد. در خصوص زمینه‌های استفاده از این شبکه، می‌توان به مدل‌سازی 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 نرم‌افزار متلب (MatLab)، توانمندی‌های این روش برای برآورد سرعت حفاری در چاه شماره X میدان مورد مطالعه، به کمک داده‌های پارامترهای حفاری این چاه، مورد بررسی قرار گیرد.

### ۱- زمین‌شناسی منطقه

میدان گازی مورد مطالعه، در منطقه فارس ساحلی، حدود ۲۰۰ کیلومتری جنوب شیراز قرار دارد. چاه شماره X این میدان به صورت عمودی تا عمق ۳۵۸۴ متر حفر شده که البته از عمق ۷۶ متری تا ۲۹۲۹ متری با سیال کف، حفاری شده است. سازندهای موجود در این میدان به ترتیب شامل سازند میشان، گچساران، آسماری و جهرم، پابده، گورپی، ایلام، لافان، سروک، کژدمی، داریان، گدوان، فهلیان، هیث، سرمه، نیریز، دشتک، کنگان و دالان می‌باشد. در این چاه از بالای سازند گچساران تا بالای سازند کنگان، حفاری با سیال کف انجام شده است. جهت

کشور ایران یکی از کشورهای مستعد از لحاظ منابع نفت و گاز است. در نتیجه، توسعه میدان‌های نفتی و گازی با استفاده از روش‌هایی مانند حفاری فروتعدالی در کشور از اهمیت خاصی برخوردار است. در همین راستا، به دست آوردن رابطه‌ای بین پارامترهای حفاری، جهت تخمین سرعت حفاری و کاهش هزینه حفاری، بسیار حائز اهمیت است. نرخ نفوذ حاصل از مته حفاری به‌همراه نرخ فرسودگی مته، تأثیری قطعی و مستقیم بر روی هزینه‌های حفاری به‌ازای هر فوت دارد. اندازه‌گیری سرعت حفاری از اهمیت زیادی برای زمین‌شناس برخوردار است. زیرا شاخص بلاواسطه‌ای را برای او فراهم می‌کند که نسبت به تغییرات لیتولوژی حساس بوده و می‌تواند در کنار نتایج حاصل از چاه‌پیمایی، مورد بررسی قرار گیرد [۱]. در مطالعات عوامل موثر بر سرعت حفاری، با متغیرهایی سروکار داریم که به‌نوعی، با چند متغیر دیگر در ارتباط هستند. در نتیجه، برای بهتر و صحیح‌تر جواب گرفتن جهت تخمین سرعت حفاری، باید از روش رگرسیون خطی چندمتغیره و یا شبکه‌های عصبی مصنوعی برای برقراری نوعی ارتباط بین این متغیرها استفاده کرد. شبکه‌های عصبی مصنوعی اخیراً کاربردهای زیادی در علوم مختلف داشته‌اند که قابلیت بالای آن‌ها را در کارهای مختلف به‌خصوص 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

شکل ۱ نشان داده شده است، ساختار این شبکه شبیه به ساختار کلی شبکه شعاعی با اندکی تفاوت در لایه دوم است [۸].


### ۳- 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 گردید. ورودی‌های شبکه شامل عمق، وزن روی مته، چرخش لوله حفاری، فشار پمپ، گشتاور، تزریق سیال، حجم هوا، فرسودگی دندان‌ه مته و لیتولوژی سازند می‌باشد.

برای به دست آوردن سرعت حفاری، از تعداد ۲۸۵۴ داده، ۷۰ درصد این مقدار به طور تصادفی برای آموزش و ۳۰ درصد برای آزمون شبکه انتخاب شد. برای بالا بردن قابلیت تشخیص شبکه، ورودی‌های شبکه در بازه ۱- و ۱ نرمال شدند. شبکه‌های مختلف با فاکتور تعدیل‌های مختلف جهت به دست آوردن شبکه بهینه اجرا گردید و در نهایت فاکتور تعدیل ۰/۰۲ به عنوان بهینه انتخاب و سرعت حفاری در دو سری داده آموزش و تست توسط شبکه تخمین زده شد. ضریب همبستگی بین نرخ نفوذ پیش‌بینی شده و اندازه‌گیری شده در دو سری داده آموزش و تست به ترتیب در شکل‌های ۲- و ۳ نشان داده شده است. هر چه مقدار ضریب همبستگی و شیب خط به عدد ۱ نزدیک‌تر 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 می‌باشد. همچنین مقدار خطای نسبی حاصل از شبکه برای دو سری داده آموزش و تست به ترتیب برابر با ۰/۰۰۱۲۲ درصد و ۰/۱۲ درصد است.

### نتیجه‌گیری

در این مطالعه از روش شبکه عصبی رگرسیون عمومی برای

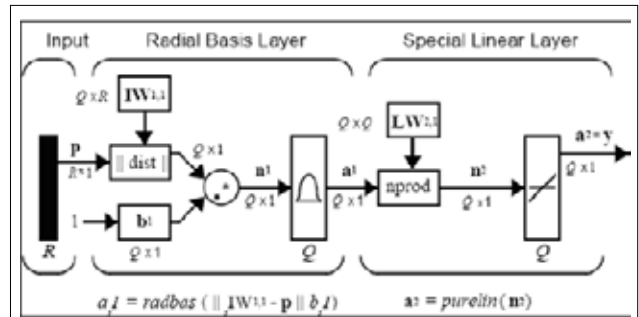


شکل ۳ | سرعت حفاری اندازه‌گیری شده در مقابل سرعت حفاری پیش‌بینی شده توسط شبکه عصبی در داده‌های تست

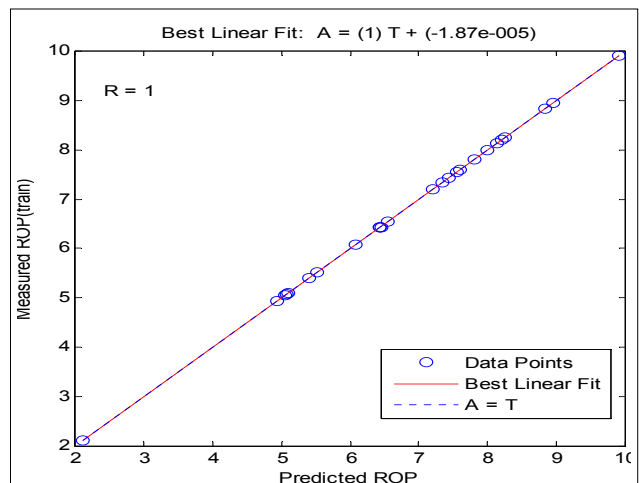
اختصار در اینجا فقط نام لیتولوژی این سازندها گفته می‌شود و باید توجه داشت که این لیتولوژی‌ها در سازندهای مختلف پیش گفته، با رنگ و مقاومت مختلفی وجود دارند. این لیتولوژی‌ها عبارتند از: سنگ آهک، سنگ سیلیت، دولومیت، سنگ رس، انیدریت و شیل.

### ۲- شبکه عصبی مصنوعی رگرسیون عمومی

شبکه عصبی مصنوعی رگرسیون عمومی (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 اسپجت<sup>۲</sup> اختراع شد. این شبکه، بر اساس تابع چگالی احتمال<sup>۳</sup> پایه گذاری شده و از خصیصه‌های آن، آموزش سریع و مدل سازی توابع غیر خطی است. برای هر مسأله رگرسیونی، در جایی که هیچ گونه فرضیاتی برای قضاوت خطی بودن موجود نباشد، می‌توان از شکل الگوریتمی این شبکه استفاده کرد. این شبکه پارامترهای شبکه پس انتشار خطا را ندارد، ولی در عوض از فاکتور تعدیلی<sup>۴</sup> برخوردار است که مقدار بهینه آن، در طی آموزش با سعی و خطا، با توجه به میانگین مربعات خطا، به دست می‌آید [۷]. همانطور که در



شکل ۱ | ساختار شبکه عصبی رگرسیون عمومی



شکل ۲ | سرعت حفاری اندازه‌گیری شده در مقابل سرعت حفاری پیش‌بینی شده توسط شبکه عصبی در داده‌های آموزش



تعدیل، مقدار سرعت حفاری در دو سری داده آموزش و تست محاسبه گردید. ضریب همبستگی بین مقدار پیش‌بینی و اندازه‌گیری شده در دو سری داده آموزش و تست برابر با ۱ و ۰/۹۹ می‌باشد که نشان از قابلیت بالای شبکه برای پیش‌بینی سرعت حفاری از روی پارامترهای موثر بر آن دارد. ■

برآورد سرعت حفاری در چاه شماره X میدان مورد مطالعه 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 به دست آمد که با استفاده از این فاکتور

۱ | فاکتورها و نمونه داده‌های مورد مطالعه X جهت ورودی به شبکه عصبی

سرعت حفاری (متر بر ساعت)	عمق (متر)	وزن روی مته (کیلوپوند)	چرخش لوله حفاری	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	۴۰۰	۰.۳۶۷۸	آهکی-۱۰۰٪
۲.۱۱	۷۷	۷	۶۸	۳۶۰	۱.۹	۱۳۰	۴۰۰	۰.۳۶۸۱	آهکی-۱۰۰٪
۲.۱۱	۷۸	۷	۶۸	۳۶۰	۱.۹	۱۳۰	۴۰۰	۰.۳۶۸۳	آهکی-۱۰۰٪
۲.۱۱	۷۹	۷	۶۸	۳۶۰	۲.۳	۱۳۰	۴۰۰	۰.۳۶۸۶	آهکی-۱۰۰٪
۷.۸۱	۲۰.۱	۱۹	۱۰۵	۳۲۰	۳	۱۰۰	۴۰۰	۰.۴۰۱۲	دولومیتی-۹۰٪
۷.۸۱	۲۰.۲	۱۹	۱۰۵	۳۲۰	۲.۴	۱۰۰	۴۰۰	۰.۴۰۱۵	دولومیتی-۹۰٪
۷.۸۱	۲۰.۳	۱۹	۱۰۵	۳۲۰	۲.۴	۱۰۰	۴۰۰	۰.۴۰۱۸	دولومیتی-۹۰٪
۷.۸۱	۲۰.۴	۱۹	۱۰۵	۳۲۰	۲.۵	۱۰۰	۴۰۰	۰.۴۰۲۱	دولومیتی-۹۰٪
۸.۲۵	۱۵۰.۱	۱۳	۹۵	۷۶۰	۵.۲	۱۱۵	۴۱۰۰	۰.۳۹۸۵	شیلی-۸۰٪
۸.۲۵	۱۵۰.۲	۱۳	۹۵	۷۶۰	۵.۲	۱۱۵	۴۱۰۰	۰.۳۹۸۸	شیلی-۸۰٪
۸.۲۵	۱۵۰.۳	۱۳	۹۵	۷۶۰	۴.۷	۱۱۵	۴۱۰۰	۰.۳۹۹۱	شیلی-۸۰٪

## پانویس‌ها

<sup>1</sup> General Regression Neural Network

<sup>3</sup> Probability density function

<sup>2</sup> Specht

<sup>4</sup> Smooth factor

## 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.