



پیش بینی نرخ نفوذ مته به کمک شبکه‌های عصبی و بررسی تأثیر وزن دهی پارامترهای ورودی به کمک فرآیند تحلیل سلسله مراتبی فازی برای یکی از میادین غرب ایران

پرهام پهلوانی^{۱*}؛ علی محمد پاکدامن^۲؛ مهدی مهران پور^۳

۱. استادیار؛ دانشکده مهندسی نقشه برداری و اطلاعات مکانی، پردیس دانشکده‌های فنی، دانشگاه تهران

۲. دانشجوی دکتری مکانیک سنگ؛ دانشکده مهندسی معدن، پردیس دانشکده‌های فنی، دانشگاه تهران

۳. دانشجوی دکتری مکانیک سنگ؛ دانشکده مهندسی معدن، پردیس دانشکده‌های فنی، دانشگاه تهران

دریافت دست‌نوشته: ۱۳۹۷/۱۰/۰۱ پذیرش دست‌نوشته: ۱۳۹۸/۰۳/۲۷

DOI: 10.22107/jpg.2019.163496.1079

چکیده	واژگان کلیدی
<p>تعیین نرخ نفوذ مته یکی از موارد پر اهمیت در صنعت حفاری است. عموماً، دو روش برای مدل‌سازی نرخ نفوذ مته وجود دارد که عبارت‌اند از مدل‌های فیزیکی و مدل‌های مبتنی بر شبکه‌های عصبی. کارایی مدل‌های فیزیکی با توجه به نقاط ضعفی مانند استفاده از ضرایب تجربی، نیاز به داده‌های جانبی زیاد، مورد تردید است. از سوی دیگر، شبکه‌های عصبی می‌توانند با توجه به محدودیت داده‌های در دسترس، ابزاری مناسب جهت پیش‌بینی نرخ نفوذ مته باشند. در این مقاله نرخ نفوذ مته به کمک حدود ۱۹۷۴ داده‌ی حفاری، با استفاده از شبکه‌های عصبی پرسپترون چند لایه و المان مدلسازی شد. در هر دو شبکه‌ی مذکور تعداد ۷ نرون به عنوان نرون پهنه در تنها لایه‌ی پنهان تعیین شد که نتایج نشانگر میزان همبستگی ۰/۷۷/۱، ۰/۷۶/۷ و میانگین مربعات خطای ۰/۱۳۱، ۰/۱۳۳ به ترتیب در شبکه‌ی پرسپترون چند لایه و شبکه‌ی المان بود. سپس، به منظور ارتقاء نتایج هر دو شبکه‌ی عصبی، پارامترهای ورودی به کمک نظرات کارشناسان و با استفاده از رویه‌ی تحلیل سلسله مراتبی وزن دهی شد و مجدداً مدلسازی نرخ نفوذ صورت گرفت که باعث بهبود نتایج هر دو شبکه‌ی عصبی شد. نتایج حاصل از این پژوهش نشانگر برتری شبکه‌ی پرسپترون چند لایه جهت تخمین نرخ حفاری است که بیانگر این واقعیت است که شبکه‌های عصبی با دقت مناسبی قابلیت پیش‌بینی نرخ نفوذ مته را بر اساس داده‌های در دسترس دارند.</p>	<p>پیش‌بینی نرخ نفوذ مته، شبکه عصبی پرسپترون چند لایه، شبکه‌ی عصبی المان، فرآیند تحلیل سلسله مراتبی فازی</p>

برای یک نوع خاص از مته توسعه یافته‌اند و شامل تعدادی از ضرایب تجربی که بعضی از آن‌ها وابسته به مشخصات زمین‌شناسی می‌باشند و می‌توانند یک ارتباط بین پارامترهای حفاری و نرخ نفوذ مته برقرار نمایند. اولین مدل از این دست مدل بینگهام می‌باشد. در این رابطه ارتباط بین نرخ نفوذ مته با پارامترهای وزن روی مته، سرعت چرخش مته و قطر مته توسط ثابت‌هایی که از خصوصیات سنگ مخزن تعیین می‌شوند، تخمین زده می‌شود (Bingham, 1964, 1965; Bingham, 1964(a,b)).

۱. پیش‌گفتار

تعیین نرخ نفوذ مته یکی از موارد پر اهمیت در صنعت حفاری و یکی از عوامل کلیدی نشان‌دهنده‌ی راندمان عملیات حفاری می‌باشد. نرخ نفوذ مته بالاتر به معنی انجام عملیات حفاری سریع‌تر، راندمان بهتر دکل حفاری و کاهش هزینه‌های حفاری واحد طول چاه است. عموماً مدل‌های پیش‌بینی نرخ نفوذ مته را می‌توان به دو گروه تقسیم نمود: دسته‌ی اول عبارت است از مدل‌های سنتی (بر مبنای تست‌های فیزیکی) و دسته‌ی دوم نیز مدل‌های بر مبنای شبکه‌های عصبی می‌باشند. مدل‌های فیزیکی بسیاری به منظور تخمین نرخ نفوذ مته بر مبنای آزمون‌های آزمایشگاهی توسعه یافته است. این مدل‌ها عمدتاً

مدل هارلند و رامپرساد^۱ برای مته‌های حفاری تیغه‌ای^۲ ارائه شد. در این مدل پارامترهای بیشتری از خصوصیات مته، نوع مته و سنگ درگیر با مته وارد معادلات شد. همچنین این مدل قابلیت محاسبه نرخ نفوذ مته‌های الماسه^۳ را نیز داراست (Hareland & Rampersad, 1994) در مدل بورگوینه و یانگ^۴، نرخ نفوذ مته برای مته‌های مخروطی برمبنای هشت پارامتر مختلف که عموماً در حین حفاری ثبت می‌شوند با استفاده از رگرسیون چند متغیره حاصل می‌شود. کارایی و دقت این روش وابسته به نحوه محاسبه این ضرایب است. این پارامترها تأثیر عواملی مانند مقاومت سازند، نوع مته، نوع گل و درصد جامد موجود در گل، افزایش تراکم سنگ با افزایش عمق، اختلاف وزن گل و فشار سازند مورد حفاری، وزن روی مته، سرعت چرخش مته، خوردگی مته و تأثیر پارامتر هیدرولیک مته بر روی سرعت حفاری را مشخص می‌نماید (Bourgoyne & Young, 1974) مطهری و همکاران مدلی را برای پیش‌بینی نرخ نفوذ مته‌های الماسه ارائه دادند که تفاوت عمده این مدل با سایر مدل‌ها استفاده از مقاومت فشاری محصور شده^۵ (CCS) در آن است (Motahhari et al., 2010).

اگرچه روش‌های سنتی پیش‌بینی نرخ نفوذ مته با موفقیت‌هایی همراه بوده است، اما سوارس^۶ و همکاران، نشان دادند که این روش‌ها دارای نقاط ضعفی مانند استفاده از ضرایب تجربی، نیاز به داده‌های جانبی زیاد (مانند خصوصیات مته، خصوصیات گل حفاری، مشخصات طراحی مته و...)، دقت پایین در پیش‌بینی نرخ نفوذ مته و وابستگی شدید به زمین-شناسی منطقه مورد حفاری می‌باشند. فرم کلی این مدل‌ها غیرقابل تغییر بوده و فقط ضرایب تجربی به صورت پیوسته بر مبنای کالیبراسیون انجام شده بر روی داده‌ها تغییر می‌نمایند. با توجه به این موارد کارایی این مدل‌ها با توجه به پارامترهای ورودی و شرایط کنترل شده‌ی آزمایشگاهی، همواره مورد

تردید بوده است و همچنین نشان داده شده است که این مدل‌ها در برابر اطلاعات واقعی میدان نتایج قابل قبولی ارائه نمی‌دهند. همچنین، این مدل‌ها وابسته به تعدادی پارامترهای حفاری بوده که اندازه‌گیری و مدل‌سازی آن‌ها بسیار دشوار است (Soares et al., 2016). از این رو روش‌های جدید و قدرتمندی بر مبنای داده‌های آماری برای مدل‌سازی دقیق‌تر و با انعطاف بیشتر نرخ نفوذ مته ارائه شده است. با توسعه‌ی تکنولوژی‌های جدید حفاری، مدل‌های تجربی پیش‌بینی نرخ نفوذ مته برای انواع مته‌ها و بر مبنای داده‌های استخراج شده از عملیات حفاری، توسعه یافت که از آن جمله می‌توان به مدل‌های مطهری و همکاران و هگده^۷ و همکاران اشاره کرد (Motahhari et al., 2010; Hegde et al., 2017). همچنین نشان داده شده است این مدل‌ها می‌توانند با دقت قابل قبولی نرخ نفوذ مته را پیش‌بینی نمایند. بیلگسو^۸ و همکاران یک مدل شبکه عصبی برای تعیین ارتباط بین پارامترهای مختلف حفاری نظیر وزن روی مته، نوع مته، عمق و سرعت چرخش مته ارائه دادند و نشان دادند که استفاده از شبکه‌های عصبی می‌تواند به خوبی برای پیش‌بینی نرخ نفوذ مته استفاده شود (Bilgesu et al., 1997). موران^۹ و همکاران نیز یک شبکه عصبی با ۶ ورودی شامل مقاومت سنگ، نوع سنگ، سایش مته، وزن روی مته، سرعت چرخش و وزن گل حفاری را ارائه دادند؛ که این شبکه دارای ۱۰ لایه مخفی و ۲ لایه خروجی نرخ نفوذ مته و فرسایش مته بوده است (Moran et al., 2010). در تحقیقی دیگر، الاهی‌فر^{۱۰} و همکاران با ترکیب داده‌های به دست آمده از آزمون‌های آزمایشگاهی، نرخ نفوذ مته را بر اساس داده‌های حفاری آزمایشگاهی وزن مته و سرعت چرخش مته، خصوصیات مکانیکی نمونه سنگی و در نهایت میزان لرزش ساقه حفاری، به کمک یک شبکه عصبی چند لایه‌ی بازگشتی، مدل‌سازی و پیش‌بینی نمودند (Elahifar et al., 2012). گوندلمن^{۱۰} و

¹ Hareland & Rampersad

² Drag Bit

³ PDC Bit

⁴ Bourgoyne & Young

⁵ Confined Compressive Strength (CCS)

⁶ Soares

⁷ Hegde

⁸ Bilgesu

⁹ Moran

¹⁰ Gandelman

پیش‌بینی نرخ نفوذ مته به کمک شبکه‌های عصبی و بررسی تأثیر وزن دهی پارامترهای ورودی به کمک فرآیند ...

استفاده شده است (Mantha & Samuel, 2016). امر^{۱۸} و همکاران با استفاده از شبکه عصبی، نرخ نفوذ مته در دلتای رودخانه نیل را پیش‌بینی نمودند. از تفاوت‌های عمده موجود در این مدل استفاده از کدهای مته^{۱۹} و درصد مواد تشکیل دهنده سنگ مورد حفاری نظیر ماس، شیل، رس، انیدریت و آهک است (Amer et al., 2017). الکتنتی^{۲۰} و همکاران با استفاده از تعداد ۳۳۳۳ داده نقطه‌ای و اطلاعاتی نظیر سرعت چرخش مته، وزن روی مته، نرخ تزریق گل، فشار لوله حفاری^{۲۱}، گشتاور حفاری و خصوصیات گل حفاری نظیر چگالی گل حفاری و ویسکوزیته پلاستیک^{۲۲}؛ توسط شبکه عصبی به پیش‌بینی نرخ نفوذ مته پرداختند (Elkatatny et al., 2017). انه‌منگلی و همکاران در سال ۲۰۱۷ از الگوریتم بهینه‌سازی سوکو^{۲۳} برای به دست آوردن ثابت‌های مدل بورگیونه و یانگ برای دو چاه از یکی از میداین جنوب غرب ایران استفاده کردند و نشان دادند این روش نسبت به روش‌های ریاضی موجود مانند رگرسیون چند متغیره^{۲۴}، روش تصادفی تصاعدی^{۲۵} و روش‌هایی مانند الگوریتم ژنتیک^{۲۶} و روش بهینه‌سازی ازدحام ذرات^{۲۷}؛ نرخ همگرایی سریع‌تر و خطای کمتری دارا است (Anemangely et al., 2017). عبدالجبار^{۲۸} و همکاران با استفاده از شبکه عصبی و به‌کارگیری به‌کارگیری ۴۵۰۰ دسته داده نرخ نفوذ مته را پیش‌بینی نموده‌اند. داده‌های ورودی شامل نرخ پمپاژ، وزن روی مته، سرعت چرخش مته، گشتاور مته، فشار گل در گرداننده فوقانی و مقاومت فشاری تک‌محوره بوده است که در نهایت توانست

همکاران با استفاده از شبکه‌های عصبی توانستند نرخ نفوذ مته را در لایه‌های نمکی فراساحل برزیل نسبت به روش‌های سنتی افزایش قابل توجهی دهند (Gandelman, 2012). خوخی^{۱۱} و همکاران ابتدا پارامترهای مدل بورگیونه و یانگ را محاسبه کرده و این پارامترها را به عنوان ورودی وارد شبکه عصبی «المان»^{۱۲} نموده و نرخ نفوذ مته را پیش‌بینی نمودند (Khoukhi et al., 2012). بتایی^{۱۳} و همکاران با استفاده از یک شبکه عصبی با لایه‌های مخفی مختلف به این نتیجه رسیدند که تعداد لایه مخفی بهینه یک لایه بوده و با استفاده از ورودی‌هایی مانند قطر مته، عمق، وزن روی مته، سرعت چرخش مته و وزن گل؛ اقدام به پیش‌بینی نرخ نفوذ مته نمودند (Bataee et al., 2010). عرب جمالویی و شادی‌زاده با تعریف هفت پارامتر شامل عمق، پارامتر معرف وزن مته، سرعت چرخش مته، پارامتر معرف هیدرولیک مته، پارامتر معرف ساعت کارکرد مته، فشار معادل چرخش سیال و ارتفاع هیدرواستاتیک، نرخ نفوذ مته را به کمک شبکه عصبی برای یکی از میداین جنوب ایران پیش‌بینی نمودند و با مقایسه با رگرسیون خطی چند متغیره و روش بورگیونه و یانگ نشان دادند که مقادیر پیش‌بینی شده به کمک شبکه عصبی خطای کم‌تری دارند (Arabjamaloei et al., 2014). مانتا و سامونل^{۱۴} با تلفیق روش‌های آماری سنتی و شبکه عصبی و اعتبارسنجی ضربدری به مدل‌سازی نرخ نفوذ مته پرداختند. در این مطالعه از روش‌های شبکه عصبی، طبقه‌بندی بردار ماشین پشتیبان^{۱۵} و طبقه‌بندی درخت‌های رگرسیونی^{۱۶} استفاده و برای بهبود آن از روش جنگل‌های تصادفی^{۱۷}

¹¹ Khoukhi

¹² Elman Neural Network

¹³ Bataee

¹⁴ Mantha & Samuel

¹⁵ Support Vector Regression

¹⁶ Classification Regression Trees

¹⁷ Random Forest

¹⁸ Amer

¹⁹ IADC Codes

²⁰ Elkatatny

²¹ Stand Pipe Pressure

²² Plastic Viscosity

²³ Cuckoo Optimization Algorithm

²⁴ Multiple Regression

²⁵ Progressive Stochastic

²⁶ Genetic Algorithm

²⁷ Particle Swarm Optimization

²⁸ Al-Abduljabbar

عصبی پرسپترون چند لایه با روش بهینه‌سازی ازدحام ذرات و روش ترکیبی بهینه‌سازی ازدحام ذرات با توابع پایه شعاعی دارای بالاترین راندمان در مقایسه با سایر روش‌ها است (Ashrafi et al., 2019).

در این تحقیق با توجه به مزایای شبکه‌های عصبی در مدل‌سازی نرخ حفاری، اقدام به مدل‌سازی نرخ حفاری توسط مجموعه‌ای از پارامترهای ورودی که به نحو مناسبی از یکدیگر استقلال خطی دارند؛ با استفاده از دو شبکه‌ی عصبی «پرسپترون چندلایه^{۲۹}» و المان صورت می‌گیرد. هدف از استفاده از شبکه‌های عصبی در این پژوهش مطابق مطالعات صورت گرفته، امکان تخمین نرخ نفوذ مت‌بر مبنای داده‌های در دسترس با ضریب همبستگی مناسب است. سپس، به منظور ارتقا شبکه‌ی عصبی در این پژوهش در مقایسه با مطالعات پیشین، درجه‌ی اهمیت پارامترهای ورودی در تعیین نرخ نفوذ مت‌بر مبنای نظرات کارشناسان خبره‌ی صنعت نفت به گونه‌ای که برای سایر میادین نیز راهگشا باشد، بر مبنای روش «سلسله مراتبی فازی^{۳۰}» تعیین خواهد شد. استفاده از رویه‌ی سلسله مراتبی فازی نه تنها منجر به کمی کردن مقایسات کارشناسان شده و مقادیر وزن پارامترهای ورودی را تعیین می‌کند بلکه عدم قطعیت حاصل از نظرات کارشناسان را نیز در نظر خواهد گرفت. در پایان نیز کارایی این دو شبکه در تخمین نرخ حفاری با یکدیگر مقایسه می‌شود.

۲. محدوده مورد مطالعه و جمع‌آوری داده‌ها

۲.۱ محدوده مورد مطالعه

در این مطالعه از داده‌های حفاری و مقاومتی یکی از میادین غرب ایران استفاده شد. مخازن مورد بهره‌برداری در این میدان مخازن آسماری و بنگستان است. مخزن آسماری شامل سنگ‌های کربناته و ماسه‌سنگ است. چاه‌ها همگی قائم بوده و دارای محدوده عمقی بین ۱۶۰۰ تا ۴۳۰۰ متر است. داده‌های این مطالعه از بیست و دو چاه در مرز استان ایلام و خوزستان حاصل شده‌اند. با توجه به کمبود داده‌های ژئومکانیکی و هزینه بالای جمع‌آوری آن‌ها، معمولاً در میادین

در میدان، ۲۲٪ نرخ نفوذ مت‌ه را بهبود ببخشند (Al-Abduljabbar et al., 2018). در تحقیقی دیگر هگده و همکاران با ترکیب مدل‌های قطعی فیزیکی و الگوریتم‌های آموزش ماشین، توانستند با دقت بالاتری نسبت به روش‌های قطعی فیزیکی نرخ نفوذ مت‌ه را در چاه‌های افقی شیل باکن^{۳۱} پیش‌بینی نمایند (Hegde et al., 2018). همچنین عباس^{۳۲} و همکاران به کمک شبکه عصبی مصنوعی و با وارد نمودن داده‌هایی نظیر شیب و آزیموت چاه‌ها به علاوه داده‌های حفاری و مدل ژئومکانیکی یک‌بعدی چاه، یک مدل برای پیش‌بینی نرخ نفوذ مت‌ه در چاه‌های انحرافی میدان ذوبیر^{۳۳} در جنوب عراق توسعه دادند و توانستند به خوبی نرخ نفوذ مت‌ه در میدان را برای چاه‌های مجاور پیش‌بینی نمایند (Abbas et al., 2018). ال‌کاتاتی در سال ۲۰۱۸ با ترکیب پارامترهای حفاری مانند نرخ جریان، سرعت چرخش مت‌ه، گشتاور وزن روی مت‌ه، فشار در لوله‌ی قائم و خصوصیات سیال نظیر چگالی گل و ویسکوزیته پلاستیک و همچنین مقاومت سازند؛ به کمک شبکه عصبی نرخ نفوذ مت‌ه را پیش‌بینی کرد و اهمیت ترکیب خصوصیات سیال حفاری و پارامترهای حفاری را به منظور افزایش دقت پیش‌بینی، نشان داد (Elkatatny, 2018). انه‌منگلی و همکاران در سال ۲۰۱۸ با ترکیب شبکه عصبی پرسپترون چند لایه با بهینه‌سازی ازدحام ذرات و الگوریتم بهینه‌سازی سوکو؛ و با استفاده از پنج پارامتر ورودی سرعت چرخش، وزن روی مت‌ه، نرخ سیال، سرعت موج فشاری و برشی، نشان دادند مدل ترکیبی پرسپترون چند لایه با الگوریتم بهینه‌سازی سوکو دارای همگرایی سریع‌تر و دقت بالاتری است (Anemangely et al., 2018). ژائو و همکاران در سال ۲۰۱۹ با استفاده از داده‌های یک چاه‌گازی در جنوب ایران و الگوریتم کلونی زنبورها به خوبی توانستند نرخ نفوذ مت‌ه را در عملیات حفاری پیش‌بینی نمایند (Zhao et al., 2019). اشرفی و همکاران در سال ۲۰۱۹ با ترکیب هشت پارامتر وزن روی مت‌ه، سرعت گردش مت‌ه، نرخ جریان فشار پمپ، فشار منفذی، امواج گاما و لاگ چگالی و سرعت موج برشی؛ نشان دادند که نتایج حاصل از مدل‌های ترکیبی شبکه

²⁹ Bakken

³⁰ Abbas

³¹ Zubair Oil Field

³² Multi-Layer Perceptron (MLP)

³³ Fuzzy AHP

پیش‌بینی نرخ نفوذ متنه به کمک شبکه‌های عصبی و بررسی تأثیر وزن دهی پارامترهای ورودی به کمک فرآیند

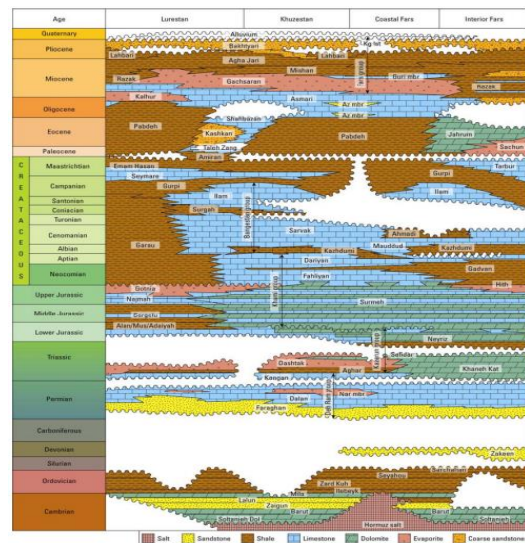
۲.۲ جمع‌آوری و تنظیم داده‌های حفاری و مکانیک

سنگی

برای تهیه‌ی ورودی‌های شبکه عصبی، اقدام به جمع‌آوری و تنظیم داده‌های حفاری شد. برای این منظور از داده‌های حفاری که از گزارش‌های روزانه حفاری^{۳۴} در یکی از میدانی غرب ایران استخراج شده است، استفاده شد. گزارش‌های روزانه شامل موارد متعددی از پارامترهای حفاری است، با توجه به مطالعات بخش قبل و داده‌های در دسترس پارامترهای عمق^{۳۵}، وزن روی متنه^{۳۶}، وزن گل^{۳۷}، فشار پمپ^{۳۸}، سایز متنه^{۳۹}، سرعت چرخش متنه (*RPM*)، میزان گردش گل^{۴۰} و نرخ نفوذ متنه (*ROP*) از این گزارش‌ها استخراج شد. در استخراج این اطلاعات از گزارش‌های حفاری باید به این نکته توجه داشت که زمان مفید حفاری استخراج شود و زمان‌هایی که مربوط به تأخیرات، تعویض لوله‌ها، هدر رفت گل، خرابی تجهیزات و سایر موارد که در آن‌ها حفاری صورت نمی‌پذیرد، از گزارش‌ها خارج و فقط زمان مفید حفاری محاسبه شود. در نهایت، پس از انجام این موارد تعداد ۱۹۷۴ داده‌ی حفاری حاصل شد.

داده‌های مربوط به خصوصیات مقاومت سنگ نیز با استفاده از مدل یک‌بعدی مکانیکی ساخته شده برای یکی از چاه‌های میدان استخراج شد. از آنجایی که در طول یک روز حفاری، متنه از سنگ با خصوصیات مختلف مکانیکی عبور می‌کند، با توجه به عمق و میزان حفاری در یک روز، میانگین خصوصیات مکانیکی سنگ‌های حفاری شده در نظر گرفته شد. پارامترهای مربوط به خصوصیات مقاومتی سنگ استخراج شده شامل مقاومت فشاری تک محوره^{۴۱}، زاویه اصطکاک داخلی^{۴۲}، مدول الاستیک^{۴۳} و مدول برشی^{۴۴} می‌باشد.

نفت و گاز در ایران در یک یا نهایتاً دو چاه این اطلاعات جمع‌آوری می‌شود. از این رو در این پروژه، مدل زمین‌شناسی سه‌بعدی مخزن کاملاً ساخته شده و اطلاعات مربوط به حفاری و تغییرات لیتولوژی در هر چاه در دسترس بوده است. با توجه به عمق و تغییرات لیتولوژی هر چاه، برای تعیین پارامترهای ژئومکانیکی از اطلاعات ژئومکانیکی یک چاه در سایر چاه‌ها استفاده شده است. نقشه لایه‌های مختلف زمین‌شناسی در منطقه زاگرس در شکل ۱ نمایش داده شده است (Rezaei & Nogol-Sadat., 2004). در این پژوهش، از داده‌های حین حفاری و لاگ‌های بعد از حفاری که به صورت پیوسته و دیجیتالی در سیستم ذخیره می‌گردد، استفاده شده است. تنها به دلیل آنکه بازه اندازه‌گیری داده‌های حفاری دارای بازه بزرگ‌تری نسبت به داده‌های لاگ داشته است؛ میانگین داده‌های لاگ برای آن بازه حفاری در نظر گرفته شده است.



شکل ۱. نقشه لایه‌های مختلف زمین‌شناسی در منطقه

زاگرس (Rezaei & Nogol-Sadat., 2004)

³⁴ Daily Drilling Report

³⁵ Depth

³⁶ Weight on Bit (WOB)

³⁷ Mud Weight (MW)

³⁸ Pump Pressure

³⁹ Bit Size

⁴⁰ Gallon per Minute (GPM)

⁴¹ Uniaxial Compressive Strength (UCS)

⁴² Friction Angle (ϕ)

⁴³ Young Modulus (E)

⁴⁴ Shear Modulus (G)

۳.۲ پیش‌پردازش داده‌های ورودی جهت به‌کارگیری در شبکه‌ی عصبی

جهت تعیین جواب قابل اعتماد در یک شبکه‌ی عصبی ابتدا باید پیش‌پردازش مناسب داده‌های ورودی صورت گیرد که در حکم فاز کنترل کیفیت داده‌های ورودی است. فاز کنترل کیفیت داده‌های ورودی شامل دو مرحله است که این دو مرحله عبارتند از حذف داده‌های خارج از ردیف و حذف ورودی‌های با همبستگی شدید خطی است.

۱.۳.۲ حذف داده‌های خارج از ردیف

به منظور حذف داده‌های خارج از ردیف، میانگین و انحراف معیار داده‌ها مطابق جدول ۱ محاسبه شد. سپس کلیه‌ی داده‌های خارج از بازه‌ی (سه برابر انحراف معیار \pm میانگین) (Aladjev & Vasanov, 2014)، از داده‌های ورودی حذف شدند. این فرآیند سبب از بین بردن تأثیر داده‌های خارج از ردیف بر نتایج شبکه‌ی عصبی می‌شود. چنانچه بیش از ۳ برابر انحراف معیار در این پروسه در نظر گرفته شود، تعداد داده‌های کم‌تری حذف خواهند شد که منجر به ایفای نقش داده‌های خارج از ردیف در تعیین وزن‌ها می‌شود. همچنین کمتر بودن ضریب مذکور از ۳، منجر به حذف بیش‌تر داده‌ها و افزایش احتمال از بین رفتن داده‌های ارزشمند می‌شود.

جدول ۱. میانگین و انحراف معیار پارامترهای مربوط به

حفاری و مکانیک سنگی			
پارامترهای ورودی	واحد	میانگین	انحراف معیار
WOB	کیلو پوند	۱۵/۱۳	۹/۵۵
RPM	دور بر دقیقه	۱۴۸/۸۲	۴۶/۹۹۹
Pump Pressure	پوند بر گال	۲۳۸۰	۵۵۸/۸
MW	پوند بر گال	۱۰۵/۲۸	۳۳/۶
E	مگا پی اس آی	۱/۶۲	۰/۹۲۷
G	مگا پی اس آی	۰/۶۲۶	۰/۳۵۳
PHI	درجه	۳۵/۵۱	۶/۸۷
UCS	پی اس آی	۶۸۹۰	۳۹۳۰
ROP	متر بر ساعت	۲/۲۹	۳/۰۳

۲.۳.۲ حذف ورودی‌های با همبستگی شدید خطی

برای جلوگیری از تأثیر مجدد یک پارامتر ورودی بر شبکه‌ی عصبی، باید داده‌های ورودی که همبستگی شدید خطی (ضریب همبستگی بیش از ۷۰ درصد) دارند، حذف شوند که برای این منظور، ماتریس ارتباط همبستگی ۲ به ۲ برای کلیه داده‌های موجود مطابق جدول ۲ تشکیل شد، در نتیجه مشخص شد که ورودی‌های عمق، سایز مته و میزان تزریق گل دارای همبستگی شدید با یکدیگر می‌باشند، که سرانجام ورودی سایز مته به عنوان نماینده‌ی این ۳ دسته انتخاب شد. همچنین داده‌های مقاومت فشاری تک محوره، مدول الاستیسیته و مدول برشی نیز دارای همبستگی بسیار شدید با یکدیگر بوده که مقاومت فشاری تک محوره به عنوان نماینده‌ی این داده‌ها انتخاب گردید.

در نهایت بعد از حذف داده‌های مذکور، هفت داده‌ی وزن روی مته، وزن گل، فشار پمپ، سایز مته، سرعت گردش مته، مقاومت فشاری تک محوره، زاویه اصطکاک داخلی؛ به عنوان ورودی شبکه عصبی و نرخ نفوذ مته به عنوان خروجی انتخاب شدند. در پایان پروسه‌ی پیش‌پردازش، پس از حذف ۱۱۱ داده‌ی خارج از ردیف از تعداد کل داده‌ها که برابر ۱۹۷۴ داده بود؛ ۱۸۶۳ داده برای ورود به شبکه‌ی عصبی در نظر گرفته شد.

۳. متدولوژی تحقیق

هدف از این تحقیق استفاده از شبکه‌های عصبی، برای پیش‌بینی نرخ حفاری است. از این رو، دو شبکه‌ی پس انتشار^{۴۵} (که «پرسپترون چندلایه» و شبکه‌ی «بازگشتی^{۴۶} آلمان») به دلیل کاربردهای متعدد آن‌ها در تقریب توابع^{۴۷} (همان‌طور که در بخش مقدمه نیز اشاره شده) استفاده می‌شود که در ادامه تشریح می‌شوند. سپس، با استفاده از رویه «سلسله مراتبی فازی^{۴۸}» ورودی‌های شبکه‌های عصبی به منظور تطبیق بهتر بر نتایج با توجه به نظرات کارشناسان وزندهی می‌شوند؛ که رویه‌ی سلسله مراتبی نیز در وزندهی پارامترهای ورودی اشاره خواهد شد.

⁴⁵ Feedforward

⁴⁶ Recurrent

⁴⁷ Function Approximation

⁴⁸ Fuzzy AHP

پیش‌بینی نرخ نفوذ متنه به کمک شبکه‌های عصبی و بررسی تأثیر وزن دهی پارامترهای ورودی به کمک فرآیند


جهت اتصالات لایه‌ها در این شبکه‌ها یک‌طرفه بوده و هیچ لایه‌ی بازگشتی در آن‌ها وجود ندارد. لایه‌ی ابتدایی به عنوان لایه‌ی ورودی و لایه‌ی انتهایی تحت عنوان لایه‌ی خروجی شناخته می‌شود. باقی لایه‌ها، به عنوان لایه‌های مخفی نام-گذاری می‌شوند. شبکه‌های چندلایه بسیار قدرتمند هستند؛ به گونه‌ای که انتخاب یک تابع غیر خطی^{۵۲} برای لایه‌ی میانی و تابع خطی برای لایه‌ی آخر؛ می‌توان هر تابع دلخواه با تعداد محدود نقاط ناپیوستگی را تخمین زد (Demuth & Beale, 2000).

۱.۳ شبکه‌های عصبی پرسپترون چندلایه^{۴۹}

یک شبکه‌ی عصبی شامل اجزای سازنده لایه‌ها و وزن‌ها می‌باشد. در شبکه‌های عصبی دو یا چند نرون می‌توانند با هم در قالب یک لایه ترکیب شوند. یک شبکه نیز می‌تواند از چند لایه تشکیل شود. هر لایه دارای ماتریس وزن‌ها^{۵۰}، بایاس‌ها^{۵۱} و خروجی‌های مختص به خود می‌باشد. در شبکه‌های عصبی پرسپترون چندلایه، که نوعی از شبکه‌های پس انتشار می‌باشند، خروجی هر یک از لایه‌های میانی به عنوان ورودی لایه‌ی بعدی مورد استفاده قرار می‌گیرد (مطابق شکل ۲).

جدول ۲. اندازه‌گیری همبستگی پارامترهای مختلف حفاری و مکانیک سنگی

	DEPTH	BIT SIZE	WOB	RPM	GPM	PP	MW	E	G	PHI	UCS	ROP
DEPTH	۱	-۰/۱۸۸	-۰/۴۶	۰/۰۷۳	-۰/۷۹	۰/۱۲	-۰/۲۰	۰/۵۵	۰/۵۵	۰/۲۷	-۰/۵۵	-۰/۵۵
BIT SIZE	-۰/۱۸۸	۱	۰/۴۴	۰/۰۱	۰/۱۸۵	۰/۰۶	-۰/۱۳	-۰/۴۶	-۰/۴۶	-۰/۲۷	-۰/۴۶	۰/۴۰
WOB	-۰/۴۶	۰/۴۴	۱	۰/۰۷	۰/۴۶	۰/۳۳	-۰/۱۹	-۰/۲۴	-۰/۲۴	-۰/۲۳	-۰/۲۴	۰/۳۲
RPM	۰/۰۷۳	۰/۰۱	۰/۰۷	۱	۰/۰۱	۰/۲۹	۰/۱۸	۰/۰۲	۰/۰۲	۰/۰۹	۰/۰۲	-۰/۰۴
GPM	-۰/۷۹	۰/۱۸۵	۰/۴۶	۰/۰۱	۱	۰/۰۰	-۰/۳۷	-۰/۴۳	-۰/۴۳	-۰/۴۵	-۰/۴۳	۰/۵۱
PP	۰/۱۲	۰/۰۶	۰/۳۳	۰/۲۹	۰/۰۰	۱	۰/۵۳	۰/۱۳	۰/۱۳	۰/۳۰	۰/۱۳	-۰/۲۴
MW	۰/۲۰	-۰/۱۳	-۰/۱۹	۰/۱۸	-۰/۳۷	۰/۵۳	۱	۰/۱۱	۰/۱۱	۰/۶۱	۰/۱۱	-۰/۴۴
E	۰/۵۵	-۰/۴۶	-۰/۲۴	۰/۰۲	-۰/۴۳	۰/۱۳	۰/۱۱	۱	۱	۰/۲۳	۱	-۰/۳۲
G	۰/۵۵	-۰/۴۶	-۰/۲۴	۰/۰۲	-۰/۴۳	۰/۱۳	۰/۱۱	۱	۱	۰/۲۳	۱	-۰/۳۲
PHI	۰/۲۷	-۰/۲۷	-۰/۲۳	۰/۰۹	-۰/۴۵	۰/۳۰	۰/۶۱	۰/۲۳	۰/۲۳	۱	۰/۲۳	-۰/۳۱
UCS	۰/۵۵	-۰/۴۶	-۰/۲۴	۰/۰۲	-۰/۴۳	۰/۱۳	۰/۱۱	۱	۱	۰/۲۳	۱	-۰/۳۲
ROP	-۰/۵۵	۰/۴۰	۰/۳۲	-۰/۰۴	۰/۵۱	-۰/۲۴	-۰/۴۴	-۰/۳۲	-۰/۳۲	-۰/۳۱	-۰/۳۲	۱



شکل ۲. نمای شماتیک شبکه عصبی پرسپترون ساخته شده برای تعیین نرخ حفاری

⁴⁹ Feedforward Neural Networks

⁵⁰ Weights

⁵¹ Biases

⁵² Sigmoid

۲.۳ شبکه‌های عصبی بازگشتی

شبکه‌های عصبی بازگشتی ساده، دارای اتصالات بازگشتی می‌باشند که قابلیت یادگیری خواص موقتی مجموعه داده‌های ورودی را دارند. شبکه‌های بازگشتی متنوعی تعمیم یافته‌اند که از این میان شبکه‌ی عصبی المان (مطابق شکل ۴) شبکه‌ای است که از شبکه‌های عصبی پس انتشار تعمیم یافته است. در این شبکه، یک کپی از لایه‌ی میانی که لایه‌ی کانتکت^{۵۷} نام دارد، ساخته می‌شود که وضعیت قبلی لایه‌ی پنهان (وضعیت لایه‌ی پنهان در زمان ارائه‌ی الگوی قبلی) را ذخیره می‌سازد. این لایه‌ی کانتکت به عنوان تعمیمی برای لایه‌ی ورودی شبکه‌ی عصبی به کار می‌رود. لایه‌ی کانتکت به صورت کامل با کلیه‌ی لایه‌های پنهان در تماس است (مطابق شکل ۴). اتصال از هر واحد پنهان به واحد مربوطه در لایه‌ی کانتکت با وزن واحد صورت می‌گیرد تا لایه‌ی پنهان به سادگی به لایه‌ی ورودی اضافه شود (Engelbrecht, 2002). این نوع شبکه‌ها عموماً در حل مسائل با تأخیر زمانی کاربرد دارند. شبکه‌ی المان نیز همچون شبکه‌های پس انتشار با استفاده از تابع انتقال غیر خطی در لایه‌ی پنهان و تابع انتقال خطی در لایه‌ی خروجی قادر به شبیه‌سازی انواع مسائل است (Demuth & Beale, 2000). در پروسه‌ی آموزش و تست این شبکه‌ها نیز باید از رویه‌ی تقسیم داده‌های آموزشی، اعتبارسنجی و تست در کنار اعتبارسنجی ضربدری K فولد که در بخش ۳ به آن اشاره شد استفاده کرد.

۳.۳ فرآیند تحلیل سلسله مراتبی فازی

روش‌های تحلیل چند معیاره، روش‌هایی هستند که به کمک آن‌ها می‌توان با مدنظر قرار دادن معیارهای کمی و کیفی متعدد، بهترین گزینه را از میان چندین گزینه انتخاب نمود. اگرچه فرآیند تحلیل سلسله مراتبی از توانایی بالایی در ارزیابی چند معیار گزینه‌های مختلف برخوردار است، اما قادر به اعمال عدم قطعیت‌های موجود در مقایسه‌های زوجی و تأثیر آن در فرآیند انتخاب نیست. به همین منظور در سال‌های اخیر استفاده از روش‌های تصمیم‌گیری چند معیاره‌ی فازی بیش

عموماً شبکه‌های عصبی ابتدا بر اساس بخش عمده‌ای از داده‌ها (عموماً ۶۰ درصد داده‌ها) آموزش^{۵۳} داده می‌شوند تا وزن‌ها و بایاس‌ها برای تعیین پارامتر(های) خروجی موردنظر حاصل شوند. همچنین، یک پروسه‌ی اعتبارسنجی^{۵۴} جهت جلوگیری از وقوع بیش‌برازش^{۵۵} در هر شبکه‌ی عصبی باید در نظر گرفته شود (عموماً ۲۰ درصد داده‌ها) و نهایتاً بخش تست (عموماً ۲۰ درصد) که برای تعیین جواب‌هایی که شبکه در حین آموزش و اعتبارسنجی با آن‌ها مواجه نشده، جهت تعیین همبستگی و میزان خطای نهایی باید در نظر گرفته شود (Demuth & Beale, 2000).

یک گام بسیار مهم در ساخت شبکه‌های عصبی، استفاده از روش اعتبارسنجی ضربدری K فولد^{۵۶} است (Engelbrecht, 2002). داده‌های ورودی به جهت آموزش بهتر شبکه به ۵ دسته تقسیم می‌شوند و در هر بار ۴ دسته به عنوان داده‌های آموزشی و اعتبارسنجی شبکه‌ی عصبی و یک دسته به عنوان تست نتیجه‌ی شبکه‌ی عصبی مورد استفاده قرار می‌گیرد. این فرآیند اعتبارسنجی، گامی بسیار مهم و مؤثر جهت دستیابی به خروجی قابل اطمینان شبکه‌ی عصبی است. لازم به ذکر است که از بین هر چهار لایه‌ای که به عنوان داده‌های آموزشی و اعتبارسنجی مورد استفاده قرار می‌گیرند، ۲۵ درصد آخر به عنوان داده‌ی اعتبارسنجی مورد استفاده قرار می‌گیرد تا نهایتاً ۶۰ درصد داده‌های ورودی به عنوان داده‌ی آموزشی، ۲۰ درصد به عنوان داده‌ی اعتبارسنجی و ۲۰ درصد به عنوان داده‌ی تست مورد استفاده قرار گرفته باشد. به عبارت دیگر، مجموعاً ۲۰ درصد کل داده‌ها برای اعتبارسنجی مورد استفاده قرار گرفته است (که شامل ۲۵ درصد داده‌های آخر هر لایه‌ی آموزشی مطابق شکل ۳ می‌باشد).

فلوچارت شکل ۳، رویه‌ی اعتبارسنجی داده‌های ورودی را در این مقاله نشان می‌دهد. رویه‌ی اعتبارسنجی اشاره شده سبب می‌شود تا نه تنها از کلیه‌ی ورودی‌های شبکه جهت آموزش و تست شبکه استفاده شود بلکه پراکندگی نتیجه‌ی حاصل شده‌ی نهایی به حداقل برسد.

⁵³ Train

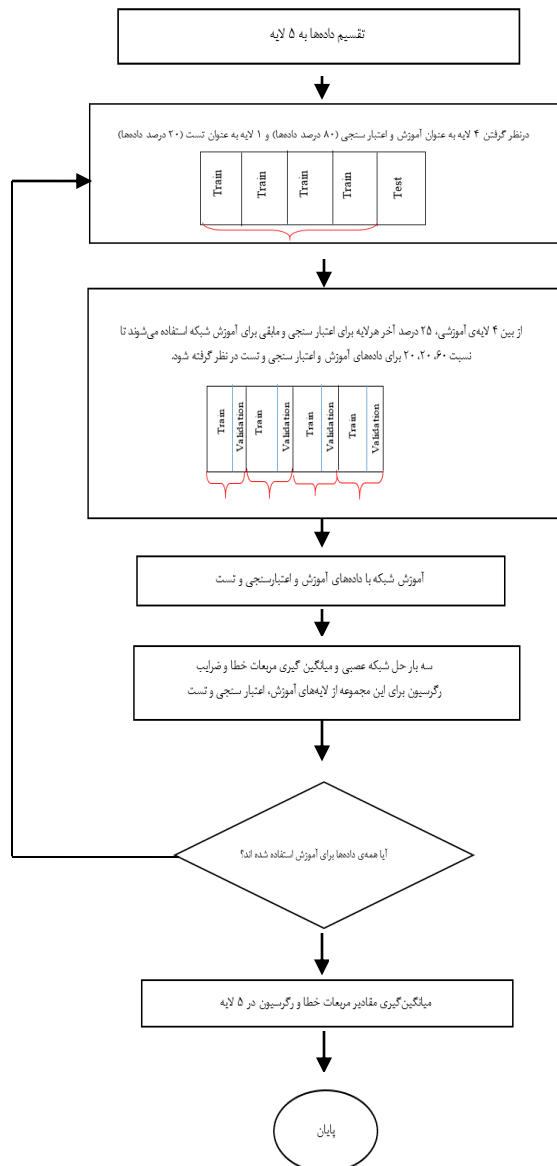
⁵⁴ Validation

⁵⁵ Overfitting

⁵⁶ K-fold cross validation

⁵⁷ Context Layer

پیش‌بینی نرخ نفوذ متنه به کمک شبکه‌های عصبی و بررسی تأثیر وزن دهی پارامترهای ورودی به کمک فرآیند



شکل ۳. فلوجارت پروسه‌ی اعتبارسنجی لایه‌های ورودی

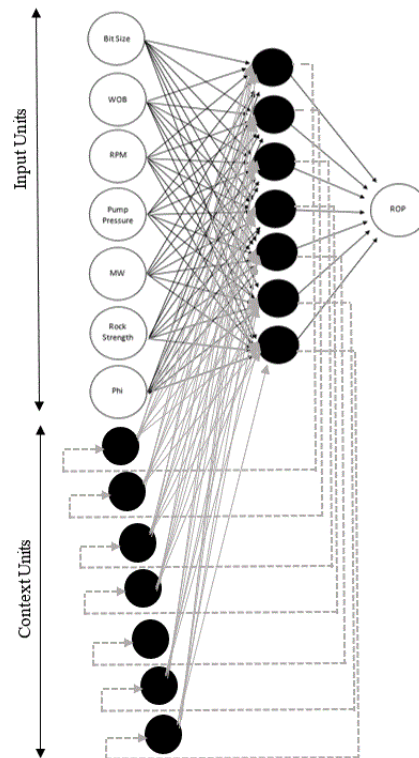
از پیش‌گسترش یافته است. روش‌های تصمیم‌گیری چند معیاره‌ی فازی، تلفیقی از منطق فازی و فرایندهای تصمیم‌گیری چند شاخه است. در این روش‌ها عدم قطعیت‌های موجود در قضاوت‌ها با استفاده از یک عدد فازی در فرآیند تصمیم‌گیری، دخالت داده می‌شود.

فرآیند تحلیل سلسله‌مراتبی فازی برای اولین بار در مطالعات ون لارهوون و پدریز (Van Laarhoven et al., 1983) مورد توجه قرار گرفت. پس از آن برخی دیگر از محققین روش‌های تحلیل سلسله‌مراتبی فازی متعددی را در زمینه‌های مختلف، ارائه نمودند. تحلیل توسعه‌ای یکی از متداول‌ترین روش‌های تحلیل چند معیاره‌ی فازی است که مبتنی بر استفاده از اعداد فازی مثلثی و مقایسه‌های زوجی می‌باشد و توسط چانگ توسعه یافته است (Chang, 1996). در این روش پس از تشکیل سلسله‌مراتب تصمیم‌گیری، با توجه به میزان اهمیت هر معیار یا گزینه، یک عدد فازی مثلثی به آن اختصاص می‌یابد و ماتریس‌های مقایسه‌ی زوجی برای هر سطح از سلسله‌مراتب ایجاد می‌شود (مطابق جدول ۳)، در نهایت بر اساس ماتریس‌های مقایسه‌ی زوجی که بر اساس اعداد فازی مثلثی بنا نهاده شده است؛ وزن مربوط به هر پارامتر ورودی حاصل می‌شود. در این پژوهش، پارامترهایی که اعداد فازی مثلثی به آن‌ها اختصاص داده می‌شود، همان پارامترهای ورودی شبکه‌ی عصبی هستند که بر اساس اهمیت‌شان مطابق جدول ۳، با توجه به نظر کارشناسان اهمیت‌سنجی شده و در نهایت با فرآیند فازی سلسله‌مراتبی به هر پارامتر ورودی، وزنی اختصاص داده می‌شود.

جدول ۳. مقیاس‌های اساسی برای مقایسه‌ی زوجی

پارامترهای ورودی			تعریف
ضریب (l) فاز	ضریب (m) فاز	ضریب (u) فاز	
۱	۱	۱	اهمیت برابر
۰/۵	۱	۱/۵	نسبتاً مهم
۱	۱/۵	۲	مهم‌تر
۱/۵	۲	۲/۵	خیلی مهم‌تر
۲	۲/۵	۳	خیلی مهم‌تر
۲/۵	۳	۳/۵	بی‌نهایت مهم‌تر

پس از پیش پردازش داده‌های ورودی، اقدام به ساخت شبکه‌ی عصبی صورت می‌گیرد؛ برای این منظور دو شبکه‌ی عصبی پرسپترون دو لایه با یک لایه‌ی مخفی و همچنین شبکه‌ی عصبی المان با همین ویژگی‌ها با روند آموزش «لونبرگ مارکوارد»^{۵۸} تحت آموزش قرار می‌گیرد. سپس باید تعداد نرون بهینه که در آن حداقل خطا^{۵۹} (میانگین مربع خطا) یا حداکثر همبستگی مشاهده می‌شود، تعیین شود. برای تعیین تعداد نرون بهینه، تعداد نرون در لایه‌ی مخفی در هر دو شبکه‌ی عصبی از ۷ تا ۲۴ مطابق جدول ۴، تغییر داده شده و ضریب همبستگی و میزان خطا در آن اشاره شده است. شیوه‌ی محاسبه‌ی مقادیر خطا و ضرایب رگرسیون برای هر شبکه با تعداد نرون‌های لایه‌ی مخفی مشخص (به عنوان مثال هفت عدد) به این ترتیب می‌باشد که ابتدا در فولد (که همان‌طور که اشاره شد در آن ۴ دسته از داده‌ها برای آموزش و اعتبارسنجی تخصیص داده شده‌اند و یک دسته برای تست در نظر گرفته شده است) میانگین مقادیر ضریب همبستگی و مربعات خطا حاصل از سه بار حل میانگین‌گیری می‌شود. سپس میانگین ضرایب رگرسیون و مربعات خطا حاصل از هر ۵ لایه میانگین‌گیری می‌شود (مطابق فلوجارت شکل ۳). رویه‌ی مذکور به صورت هم‌زمان برای داده‌های آموزشی و تست دنبال می‌شود. استفاده از این رویه‌ی دقیق سبب می‌شود تا از تمامی داده‌ها برای آموزش و تست شبکه استفاده شود. همچنین با در نظر گرفتن بخش مشخصی از داده‌ها برای



شکل ۴. نمای شماتیک شبکه عصبی المان ساخته شده برای تعیین نرخ حفاری

۴. پیاده‌سازی

به منظور ساخت شبکه‌ی عصبی (در هر دو روش با استفاده از شبکه‌ی پس انتشار و المان) ابتدا باید ورودی‌ها به صورت تصادفی مرتب شوند. چینش کلیه داده‌ها به صورت تصادفی سبب جلوگیری از تأثیر روندهای موجود در داده‌های دنبال هم می‌شود. سپس رویه‌ی اعتبارسنجی ضربدری K فولد صورت می‌پذیرد؛ و در نهایت نیز نگاشت داده‌های ورودی و خروجی به فضای بین صفر و یک انجام می‌شود تا از تأثیر داده‌های با جنس متفاوت که مقادیر متفاوتی دارند بر تعیین وزن‌ها و بایاس‌های شبکه‌ی عصبی ممانعت شود.

⁵⁸ Levenberg–Marquard

⁵⁹ Mean Square Error (MSE)

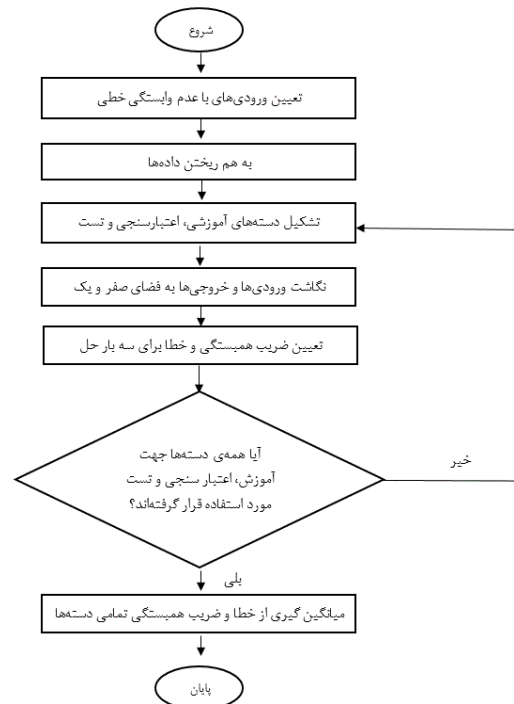
پیش‌بینی نرخ نفوذ متنه به کمک شبکه‌های عصبی و بررسی تأثیر وزن دهی پارامترهای ورودی به کمک فرآیند

خطای نسبتاً بالاتری در اختیار قرار می‌دهد؛ اگرچه به دلیل شباهت ساختاری این دو شبکه (از آنجا که شبکه‌ی المان نوع بازگشتی شبکه‌ی پرسپترون چندلایه می‌باشد) و همچنین شباهت در تعداد لایه‌های مخفی و فرآیند آموزش، تفاوت مقادیر ضریب رگرسیون و میانگین مربعات خطا چندان زیاد نیست. در شکل ۷، نمونه‌ای از نمودار ضریب همبستگی خروجی شبکه عصبی ترسیم شده است که در آن در محور قائم، مقادیر خروجی نرخ حفاری حاصل از شبکه و محور افقی مقادیر واقعی نرخ حفاری قابل مشاهده است. همان‌طور که در این شکل قابل مشاهده است، ضریب همبستگی حاصل از پروسه‌ی آموزشی، نزدیکی بسیار زیادی به نتایج تست دارد که مؤید صحت پروسه‌ی ساخت شبکه‌های عصبی و پیش‌بینی مؤثر آن است.

برای تعیین اولویت‌بندی ورودی‌ها و اعمال وزن بیشتر برای داده‌های مهم‌تر جهت دستیابی به خطای کم‌تر یا ضریب همبستگی بیشتر در شبکه‌های عصبی، با استفاده از فرآیند تحلیل سلسله مراتبی فازی (مطابق بخش ۳.۳)، پرسشنامه‌ای تهیه و برای ۱۰ نفر از کارشناسان خبره صنعت حفاری با میانگین سابقه کاری ۹/۵ سال شد تا ضرایب مربوط به وزن هر یک از پارامترهای ورودی محاسبه شود. به منظور بهره‌گیری از دو هدف از نظرات کارشناسان در این پژوهش استفاده شد. اول، تجربیات عملی چندین ساله‌ی آن‌ها در سایر میادین و دیگر اشراف ایشان به داده‌های مورد استفاده در این پژوهش است. با بهره‌گیری از این دو مزیت، وزن‌های برازش شده از نظر کارشناسان را می‌توان مناسب برای سایر میادین نیز توصیف کرد.

پس از انجام نظرسنجی کیفی توسط کارشناسان برای مقایسات زوجی پارامترهای ورودی (مطابق جدول ۵)، با استفاده از برنامه‌ی نوشته شده برای کمی کردن وزن کارشناسان بر اساس پروسه‌ی سلسله مراتبی فازی، وزن‌ها به صورت کمی حاصل می‌شوند. اساس الگوریتم نوشته شده استفاده از جدول ۳ و تشکیل سه ماتریس l و m و u است؛ در گام بعد جمع سطری هریک از این ماتریس‌ها محاسبه شده و این سه ماتریس تبدیل به سه ستون می‌شوند. در ادامه پس از نرمالیزه کردن ستون‌ها، یک ماتریس (به عنوان مثال با نام M) با سه ستون نرمالیزه شده‌ی l و m و u وجود خواهد داشت که هر سطر این ماتریس d_i نامیده می‌شود که مشخصاً نشانگر

اعتبارسنجی (۲۰ درصد)، عملاً امکان بیش برازش داده‌ها به حداقل ممکن می‌رسد. شکل ۵، فلوچارت رویه‌ی ساخت شبکه‌های عصبی را نمایش می‌دهد.



شکل ۵. پروسه‌ی تعیین ضریب همبستگی و میزان خطا برای هر نرون در هر دو شبکه‌ی عصبی

با توجه به این که معیار انتخاب نرون بهینه ضریب همبستگی و خطای حاصل از تست می‌باشد؛ مطابق جدول ۴ در هر دو شبکه‌ی عصبی، تعداد نرون هفت به عنوان تعداد نرون بهینه در نظر گرفته شد که برای شبکه‌ی عصبی پرسپترون چندلایه منجر به میزان همبستگی ۰/۷۷/۱٪ و خطای ۱/۳۱ و برای شبکه‌ی عصبی المان سبب همبستگی ۰/۷۶/۷٪ و خطای ۱/۳۳ شد. شکل ۶ نشانگر نمودار تغییرات ضرایب همبستگی و میزان خطا با توجه به تغییر تعداد نرون لایه‌ی مخفی در دو شبکه‌ی عصبی پرسپترون چند لایه و المان است.

باید توجه داشت که به طور کلی استفاده از شبکه‌ی عصبی پرسپترون چند لایه منجر به دستیابی به ضریب همبستگی بالاتر و میانگین مربعات خطای پایین‌تری در مقایسه با شبکه‌ی عصبی المان می‌شود. به نظر می‌رسد به دلیل تعداد بیش از حد بیش‌تر پارامترهای ورودی شبکه‌ی عصبی المان، این شبکه رگرسیون پایین‌تر و میانگین مربعات

$$d_i = (l_i \cdot m_i \cdot u_i) ; d_j = (l_j \cdot m_j \cdot u_j) \quad (1)$$

$$W(d_i, d_j) = \begin{cases} 1 & \text{for } d_i > d_j \\ \frac{u_i - l_j}{(u_i - m_i) + (m_j - l_j)} & \text{for } l_j < u_i \\ 0 & \text{Otherwise} \end{cases}$$

هر یک از مقادیر وزن حاصل از جدول ۶، در مقادیر مربوطه به آن پارامتر پس از نگاشت به فضای صفر و یک و پیش از آغاز آموزش شبکه‌ی عصبی بهینه (تعداد نرون هفت) اعمال شد. به عنوان مثال، عدد مربوط به وزن کمی شده توسط نظر کارشناسان برای وزن گل که ۰/۱۱ است در کلیه‌ی داده‌های وزن گل که به فضای صفر و یک نگاشت شده بودند، ضرب شد (کل ۱۸۶۳ داده‌ی وزن گل). به همین ترتیب سایر پارامترهای ورودی نیز وزن دهی شد و پروسه‌ی آموزش، اعتبارسنجی و تست شبکه با این ورودی‌های وزن دهی شده صورت گرفت که در نتیجه شبکه‌ی عصبی پرسپترون چند لایه به ضریب همبستگی ۷۷/۴ درصد و میانگین مربعات خطای ۱/۲۸۷ دست یافت؛ همچنین برای شبکه‌ی عصبی المان نیز ضریب همبستگی ۷۷/۱ درصد و میانگین مربعات خطای ۱/۲۹۳ که این امر باعث ارتقاء جزئی شبکه (حدوداً ۰/۴ درصد) در هر دو روش شد.

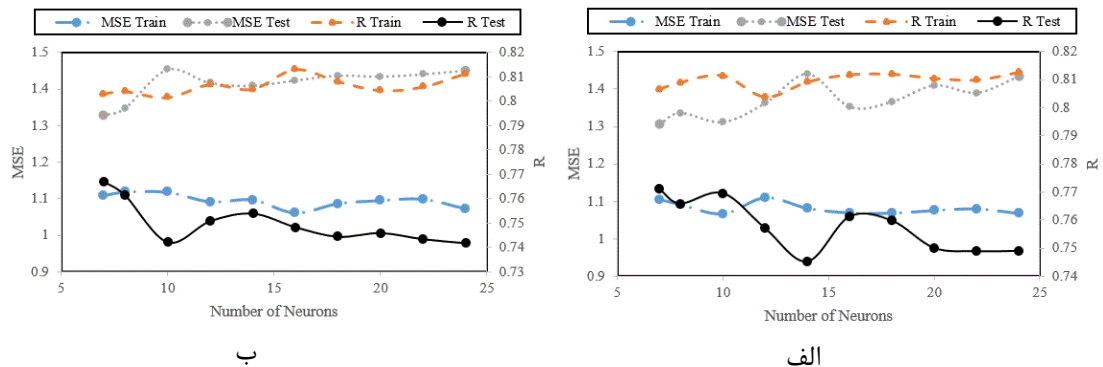
یکی از معیارها است (به عنوان مثال d_i نشانگر سطر اول بوده که نشانگر معیار سایز مته می‌باشد). در گام بعد برای تعیین وزن معیارها (به عنوان مثال معیار اول که همان سایز مته می‌باشد) جفت سطرهای d_i و d_j تشکیل شده و تخصیص وزن مطابق رابطه‌ی ۱ صورت می‌گیرد. در نهایت حداقل مقدار وزن مربوط به هر معیار (که با سایر معیارها مقایسه شده) به عنوان وزن آن معیار توسط آن کارشناس در نظر گرفته می‌شود (برای جزئیات بیشتر می‌توان به (Chang, 1996) مراجعه کرد. نظر دو نفر از کارشناسان شرط سازگاری در تحلیل سلسله مراتبی را ارضا نکرد و از وزن‌های ۸ نفر باقی‌مانده میانگین هندسی گرفته شد و سپس وزن‌های میانگین‌گیری شده نرمال شدند و جهت تلفیق نظر کارشناسان، پس از کمی-سازی نظر ایشان از میانگین هندسی مقادیر کمی شده برای هر معیار استفاده شده است که در جدول ۶ قابل مشاهده می‌باشد.

با توجه به جداول ۲ و ۶، در اکثر موارد انطباق مناسبی بین وزن به دست آمده از نظر کارشناسان (جدول ۶) و ضریب همبستگی داده‌های ورودی و نرخ حفاری (با توجه به جدول ۲) وجود دارد. البته در برخی موارد (مثل فشار پمپ و سرعت چرخش مته) اختلافاتی نیز مشاهده می‌شود که به دلیل ملاحظات اجرایی (و نه صرفاً ضریب همبستگی که به صورت ریاضیاتی است) و تجربیات چندین ساله‌ی کارشناسان از سایر میدان‌ها است.

جدول ۴. ضریب همبستگی و خطای محاسبه شده با توجه به تعداد نرون لایه‌ی مخفی

شبکه‌ی عصبی	تعداد نرون‌ها	آموزش			تست		
		میانگین مربعات خطا	همبستگی	میانگین مربعات خطا	همبستگی	میانگین مربعات خطا	همبستگی
شبکه‌ی پرسپترون چندلایه	۷	۱/۱۰	۰/۸۰۶۵	۱/۳۰۶	۰/۷۷۱۱	۱/۳۰۶	۰/۷۶۷۱
	۸	۱/۰۹	۰/۸۰۸۹	۱/۳۳۵	۰/۷۶۵۸	۱/۳۳۵	۰/۷۶۱۴
	۱۰	۱/۰۷	۰/۸۱۱۳۶	۱/۳۱۱	۰/۷۶۹۵	۱/۳۱۱	۰/۷۴۲۲
	۱۲	۱/۱۰۹	۰/۸۰۹۱	۱/۳۶	۰/۷۵۷۲	۱/۳۶	۰/۷۵۰۹
	۱۴	۱/۰۸۱	۰/۸۰۱۶	۱/۴۴	۰/۷۴۵۴	۱/۴۴	۰/۷۵۴۰
	۱۶	۱/۰۶۹	۰/۸۱۱۸	۱/۳۵	۰/۷۶۱۲	۱/۳۵	۰/۷۴۴
	۱۸	۱/۰۶۹	۰/۸۱۰۴	۱/۳۶	۰/۷۵۹۸	۱/۳۶	۰/۷۴۴۵
	۲۰	۱/۰۷۶	۰/۸۱۰۹	۱/۴۱	۰/۷۵۰۲	۱/۴۱	۰/۷۴۶۰
	۲۲	۱/۰۸۰	۰/۸۰۹۷	۱/۳۹	۰/۷۴۹۰	۱/۳۹	۰/۷۴۳۵
	۲۴	۱/۰۶۸	۰/۸۱۲۵	۱/۴۳	۰/۷۴۹۱	۱/۴۳	۰/۷۴۱۸

پیش‌بینی نرخ نفوذ متنه به کمک شبکه‌های عصبی و بررسی تأثیر وزن دهی پارامترهای ورودی به کمک فرآیند



شکل ۶. تغییرات میانگین مربعات خطا و همبستگی با توجه به تغییر تعداد نرون لایه‌ی پنهان
الف: شبکه‌ی پرسپترون چندلایه ب: شبکه‌ی المان

هر دو شبکه‌ی عصبی پرسپترون چندلایه و المان پس از اعمال نظرات کارشناسان نسبت به حالتی که همه‌ی پارامترهای ورودی وزنی برابر داشته‌اند، بهبود یافته است که دلیل این امر، وزن دار کردن پارامترهای ورودی بر مبنای نظرات ایشان و دخول تجربیات عملی در محاسبات ریاضیاتی می‌باشد. به عبارت دیگر، در نظر گرفتن اهمیت پارامترهای ورودی نسبت به یکدیگر مطابق جدول ۶، سبب افزایش دقت پیش‌بینی شبکه‌های عصبی شده است.

علت ارتقاء نسبتاً کم شبکه آن است که وزن‌های به دست آمده با توجه به نظر کارشناسان تفاوت وزنی قابل ملاحظه‌ای با وزن‌های اولیه (که همگی برابر با یک بودند) نداشت. اگرچه ضرایب به دست آمده برای ورودی‌های مختلف متفاوت است اما چون همه‌ی ورودی‌ها همچنان در ساخت شبکه‌ی عصبی حضور دارند و یک ورودی چیرگی قابل ملاحظه‌ای بر دیگر ورودی‌ها ندارد؛ ارتقاء بارزی در خروجی‌های شبکه‌ی عصبی مشاهده نمی‌شود. اگرچه، همان‌طور که در جدول ۷ نیز قابل مشاهده است، ضریب همبستگی و میانگین مربعات خطا در


جدول ۵. نمونه‌ای از مقایسه‌های کیفی صورت گرفته توسط کارشناسان

	Bit Size	WOB	RPM	GPM	Pump Pressure	MW	Rock Strength	Angel of Internal Friction
Bit Size	اهمیت برابر	اهمیت برابر	اهمیت برابر	اهمیت برابر	مهم‌تر	مهم‌تر	مهم‌تر	مهم‌تر
WOB		اهمیت برابر	اهمیت برابر	خیلی مهم‌تر	نسبتاً مهم	نسبتاً مهم	نسبتاً مهم	نسبتاً مهم
RPM			اهمیت برابر	نسبتاً مهم	خیلی مهم‌تر	خیلی مهم‌تر	خیلی مهم‌تر	خیلی مهم‌تر
GPM				اهمیت برابر	اهمیت برابر	اهمیت برابر	اهمیت برابر	اهمیت برابر
Pump Pressure					اهمیت برابر	اهمیت برابر	اهمیت برابر	اهمیت برابر
MW						اهمیت برابر	نسبتاً مهم	نسبتاً مهم
Rock strength							اهمیت برابر	نسبتاً مهم
Angel of Internal Friction								اهمیت برابر

۵. نتیجه‌گیری

هدف از ارائه‌ی این تحقیق تعیین نرخ حفاری بر مبنای پارامترهای حفاری و خصوصیات سنگ با استفاده از شبکه‌ی عصبی بود که برای این منظور هفت پارامتر وزن روی مته، وزن گل، فشار پمپ، سایز مته، سرعت گردش مته، مقاومت فشاری تک محوره و زاویه اصطکاک داخلی، به عنوان ورودی شبکه عصبی انتخاب شد و پس از کنترل کیفیت داده‌های ورودی و تشکیل اعتبارسنجی ضربدری K فولد داده‌های ورودی، اقدام به ساخت شبکه‌های عصبی پرسپترون چندلایه و المان شد، که نتایج نشانگر ضریب همبستگی $0.77/1$ درصد و میانگین مربعات خطای $1/31$ برای شبکه‌ی پرسپترون چندلایه و ضریب همبستگی $0.76/7$ و میانگین مربعات خطای $1/33$ برای شبکه‌ی المان با تعداد ۷ نرون به عنوان تعداد نرون بهینه در لایه‌ی پنهان در هر دو شبکه شد که نشانگر کارایی بهتر شبکه‌ی پرسپترون چندلایه در تخمین نرخ حفاری به دلیل در نظر گرفتن تعداد پارامترهای ورودی مناسب‌تر (کم‌تر) بود.

سپس با استفاده از نظرات مورد قبول هشت کارشناس خبره، داده‌های ورودی شبکه‌ی عصبی وزن‌دهی شد که در این حالت ارتقاء نسبتاً کمی در خروجی‌های هر دو شبکه‌ی عصبی به دلیل وجود همه‌ی ورودی‌ها در وزن‌های میانگین‌گیری شده و تفاوت نه چندان قابل‌ملاحظه‌ی وزن‌های ورودی حاصل شد به گونه‌ای که در هر دو شبکه‌ی عصبی ضریب همبستگی به مقدار تقریبی 0.4 درصد بهبود یافته است. پس از این ارتقاء نیز همچنان شبکه‌ی عصبی پرسپترون چندلایه رگرسیون بالاتر و میانگین مربعات خطای کم‌تری را نشان داد که باز هم نشان از برتری این شبکه‌ی عصبی در تخمین توابع چند متغیره دارد.



شکل ۷. نمونه‌ای از نمودار ضریب همبستگی خروجی برای یک بار حل در تعداد مشخص از نرون‌های لایه‌ی فرعی در یک فولد

جدول ۶. تلفیق وزن‌های به‌دست آمده از نظر کارشناسان با استفاده از تحلیل سلسله مراتبی فازی

پارامترها	مقادیر وزن تخصیص داده شده
Bit Size	۰/۱۸۸
WOB	۰/۱۷۱
RPM	۰/۲۱۱
Pump Pressure	۰/۰۹۶
MW	۰/۱۱
Rock Strength	۰/۱۰۷
Phi	۰/۱۱۷
مجموع	۱

جدول ۷. تغییرات ضریب همبستگی و میانگین مربعات خطا بعد از اعمال ضرایب به دست آمده از تحلیل سلسله مراتبی فازی

تعداد شبکه‌ی عصبی	میانگین مربعات خطا	همبستگی
نرون	خطا	همبستگی
بهینه	آموزش	
شبکه‌ی پرسپترون	۱/۱۲۰	۰/۷۹۹۳
چندلایه	۷	تست
	۱/۲۸۷	۰/۷۷۴۲
	آموزش	
شبکه‌ی المان	۱/۱۰۷	۰/۸۰۳۸
۷	تست	
	۱/۳۹۳	۰/۷۷۱۲

پیش‌بینی نرخ نفوذ متنه به کمک شبکه‌های عصبی و بررسی تأثیر وزن دهی پارامترهای ورودی به کمک فرآیند ...

می‌باشند که شبکه‌های عصبی ابزاری قابل اعتماد و بسیار مناسب برای پیش‌بینی نرخ حفاری با توجه به پارامترهای ورودی در دسترس می‌باشند به شرطی که تعداد داده‌های مناسبی (حتی حاصل از چندین چاه) برای آموزش این شبکه‌ها استفاده شود.

ذکر این نکته ضروری است که استفاده از اوزان کارشناسان برای میادین غرب ایران و نزدیک به محدوده‌ی مورد مطالعه دارای کارایی مناسب‌تری است. مقادیر ضرایب همبستگی و میانگین مربعات خطای اشاره شده در هر دو شبکه‌ی المان و پرسپترون چندلایه به خوبی نشانگر این است که شبکه‌های عصبی، قابلیت پیش‌بینی نرخ حفاری بر مبنای داده‌های ورودی را در صورت وجود تعداد کافی داده‌های ورودی دارا

مراجع

- Abbas A.K., Rushdi S., Alsaba M. (2018). Modeling rate of penetration for deviated wells using artificial neural networks. *Abu Dhabi International Petroleum Exhibition & Conference*, Abu Dhabi, UAE.
- Aladjev, V., Aladjev, V., (2014) General Statistics, International Academy of Noospher, the baltic branch, Tallin.
- Al-Abduljabbar A., Elkatatny S., Abdulazeez Abdulraheem M.M. (2018). Predicting rate of penetration using artificial intelligence techniques. *SPE Kingdom of Saudi Arabia Annual Technical Symposium and Exhibition*. Dammam, Saudi Arabia: Society of Petroleum Engineers.
- Amer M., Sattar D., Hashem A. (2017). An ROP predictive model in Nile delta area using artificial neural networks. *SPE Kingdom of Saudi Arabia Annual Technical Symposium and Exhibition*. Dammam, Saudi Arabia: Society of Petroleum Engineers.
- Anemangely M., Ramezanzadeh A., Tokhmechi B., (2017). Determination of constant coefficients of Bourgoyne and Young drilling rate model using a novel evolutionary algorithm, *Journal of Mining and Environment*, 8(4), 693-702.
- Anemangely M., Ramezanzadeh A., Tokhmechi B., Molaghab A., Mohammadian A., (2018) Drilling rate prediction from petrophysical logs and mud logging data using an optimized multilayer perceptron neural network, *Journal of Geophysics and Engineering*, 15(4), 1146-1159.
- Arabjamaloei, A., Shadizadeh, S. (2014). Modeling and optimizing rate of penetration using intelligent systems in an Iranian southern oil field (Ahwaz Oil Field). *Petroleum Science and Technology*, 29(16), 1637-1648.
- Ashrafi B., Anemangely M., Sabah M., Ameri M. J., (2019) Application of hybrid artificial neural networks for predicting rate of penetration (ROP): A case study from Marun oil field *Journal of Petroleum Science and Engineering*, 175, 604-623.
- Bataee, M., Kamyab, M., and Ashena, R. (2010). Investigation of various ROP models and optimization of drilling parameters for PDC and roller-cone bits in shadegan oil field. *CPS/SPE International Oil & Gas Conference and Exhibition* (p. SPE130932). Beijing, China: Society of Petroleum Engineers.
- Bilgesu, H. I., Tetrick, L. T., Mohaghegh, S., Ameri, S. (1997). A new Approach for the Prediction of Rate of Penetration Values. *SPE Eastern Regional Meeting* (pp. 175-179). Lexington: Society of Petroleum Engineers.

- Bingham , M. (1964). How to interpret drilling in the performance region. *The Oil and Gas journal*, 173-179.
- Bingham , M. (1964-1965). A new approach to interpreting rock drillability . *The Oil and Gas Journal*.
- Bingham, M. (1964). How rock properties are related to drilling. *The Oil and Gas Journal*, 94-101.
- Bourgoyne, A., & Young , F. (1974). A multiple regression approach to optimal drilling and abnormal pressure detection. *Society of Petroleum Engineers Journal*, 371-384.
- Chang, Y. D. (1996). Application of the extent analysis method on fuzzy AHP. *European Journal of Operational Research*, 95, 649-655.
- Demuth, H. Beale, M. (2000). *Neural network toolbox*. The MathWorks.
- Elahifar, B. T., Thonhauser, G., Fruhwirth, R. K., Esmaili, A. (2012). ROP modeling using neural networks and drill string vibration data, . *SPE Kuwait International Petroleum Conference and Exhibition* (pp. 1-8). Kuwait : Society of Petroleum Engineers.
- Elkatatny, S.M., (2017). New approach to optimize the rate of penetration using artificial neural network. *Arabian Journal for Science and Engineering*, 43(11), 6297-6304.
- Elkatatny, S.M., Tariq, Z. and Mahmoud, M.A. Al-AbdulJabbar, A. (2017). Optimization of rate of penetration using artificial intelligent techniques. . *51st US Rock Mechanics Geomechanics Symposium held in San Francisco*. California, USA.: American Rock Mechanics Association.
- Engelbrecht, A. P. (2002). *Computational Intelligence*. John Wiley.
- Gandelman, R. A. (2012). *ROP prediction and real-time optimization of operational parameters on drilling offshore oil Wells*. Brazil: Universidade Federal do Rio de Janeiro.
- Gharechelou, S., Amini, A., Kadkhodaie-Ilkhchi, A, Moradi, M. (2015). An integrated approach for determination of pore-type distribution in carbonate-siliciclastic Asmari Reservoir, Cheshmeh-Khosh Oilfield, SW Iran. *Journal of Geophysics and Engineering*, 12, 793-809.
- Hareland, G., & Rampersad , P. (1994). Drag-bit model including wear. *The Third Latin American/Caribbean Petroleum Engineering Conference*, (pp. 27-29). Buenos Aires.
- Hegde, C., Diagle, H., Milwater, H., Gray, K. (2017). Analysis of rate of penetration (ROP) prediction in drilling using physics-based and data-driven models. *Journal of Petroleum Science and Engineering*, 159, 295-306.
- Hegde, C., Soares, S., Gray, K. (2018). Rate of penetration modeling using hybrid models: Deterministic and machine learning, *Unconventional Resources Technology Conference, Huston, Texas*.
- Khoukhi, A., Alarfaj I. (2012). Rate of penetration prediction and optimization using advances in artificial neural networks, a comparative study. . *4th International Joint Conference on Computational Intelligence*, (pp. 647-652). K.S.A. .
- Mantha, B., Samuel, R. (2016). ROP optimization using artificial intelligence techniques with statistical regression coupling. *SPE Annual Technical Conference and Exhibition*. Dubai, UAE: Society of Petroleum Engineers.

پیش‌بینی نرخ نفوذ منته به کمک شبکه‌های عصبی و بررسی تأثیر وزن دهی پارامترهای ورودی به کمک فرآیند ...

- Moran, D., Ibrahim, H., Purwanto, A. (2010). Sophisticated ROP prediction technologies based on neural network delivers accurate drill time results. *Asia Pacific Drilling Technology Conference and Exhibition* (pp. 1-8). Ho Chi Minh : Society of Petroleum Engineers.
- Motahhari, H. R., Hareland, G., and James, J. A. (2010). Improved drilling efficiency technique using integrated PDM and PDC bit parameters. *Journal of Canadian Petroleum Technology*, 49(10), 45-52.
- Rezaie, A., & Nogole-Sadat, M. (2004). Fracture modeling in Asmari reservoir of Rag-e Sefid. *Iranian International Journal Of Science*, 5, 107-121.
- Soares, C., Daigle, H., Gray, K (2016). Evaluation of PDC bit ROP models and the effect of rock strength on model coefficients. *Journal of Natural Gas Science and Engineering*, 34, 1225-1236.
- Van Laarhoven, P. J., Pedrycz, W. (1983). A fuzzy extension of Saaty's priority theory. *Fuzzy Sets and Systems*, 11, 229-241.
- Zhao Y., Noorbakhsh A., Tokhmechi B., Koopialipour M., Aydin A., Tahir M. M., (2019) A new methodology for optimization and prediction of rate of penetration during drilling operations, *Engineering with Computers*, 1-9.