



پیش‌بینی پنجره ایمن وزن گل حفاری با استفاده از مدل‌های ترکیبی یادگیری ماشین مبتنی بر پرسپترون چندلایه و الگوریتم‌های بهینه‌سازی

میثم رجبی^{۱*}، حمزه قربانی^۲، سید وحید علوی نژاد خلیل‌آباد^۳

۱- استادیار گروه مهندسی معدن، دانشگاه صنعتی بیرجند، بیرجند، ایران.

۲- دانش‌آموخته مهندسی نفت، باشگاه پژوهشگران جوان و نخبگان، دانشگاه آزاد اسلامی، اهواز، ایران.

۳- استادیار گروه مهندسی عمران، دانشگاه صنعتی بیرجند، بیرجند، ایران.

دریافت: ۱۴۰۵/۰۳/۰۷؛ پذیرش: ۱۴۰۵/۰۳/۳۱

(*) نویسنده مسئول: m.rajabi@birjandut.ac.ir

چکیده

تعیین دقیق پنجره ایمن وزن گل حفاری یکی از مسائل کلیدی در مهندسی حفاری است که نقش مهمی در جلوگیری از ناپایداری چاه، هرزروی گل و افزایش هزینه‌های عملیاتی دارد. در این پژوهش، جهت پیش‌بینی حداقل وزن گل زیر فشار شکست و حداکثر وزن گل بالاتر از فشار شکست، از مدل‌های ترکیبی یادگیری ماشین استفاده شده است. در این راستا، شبکه عصبی پرسپترون چندلایه با چهار الگوریتم بهینه‌سازی شامل الگوریتم کرم شبتاب، جستجوی گرانشی، کلونی زنبور عسل و الگوریتم رقابت استعماری ترکیب شد. داده‌های مورد استفاده شامل اطلاعات سه چاه از یک میدان گازی در جنوب ایران بوده که به سه بخش آموزش (۷۰٪)، اعتبارسنجی (۱۵٪) و آزمون (۱۵٪) تقسیم شدند. نتایج آماری نشان داد که، «الگوریتم پرسپترون چندلایه- الگوریتم جستجوی گرانشی» از دیگر مدل‌ها، دقیق‌تر است. چنان‌که زیرمجموعه آزمایشی الگوریتم مذکور، برای حداقل وزن گل زیر فشار شکست با مقدار ریشه میانگین مربعات خطای ۱۲/۲۸۳ پوند بر اینچ مربع و ضریب تعیین ۰/۹۰ و حداکثر وزن گل بالای فشار شکست با ریشه میانگین مربعات خطا ۱۲/۵۳۶ پوند بر اینچ مربع و ضریب تعیین ۰/۹۴۱۷ کمترین خطا را نشان داده‌اند. بر این اساس، استفاده از مدل‌های ترکیبی یادگیری ماشین می‌تواند دقت پیش‌بینی پنجره ایمن وزن گل را به‌طور قابل توجهی افزایش دهد و به‌عنوان ابزاری کارآمد در تصمیم‌گیری‌های عملیاتی حفاری مورد استفاده قرار گیرد.

پنجره ایمن وزن گل، ژئومکانیک، یادگیری ماشین، پرسپترون چندلایه، بهینه‌سازی

واژگان کلیدی

۱- مقدمه

در پیش‌بینی پایداری چاه و کاهش ریسک‌های عملیاتی ایفا می‌کند. اطلاعات دقیق و جامع ژئومکانیکی به‌عنوان یکی از عوامل موثر در بهبود فرآیندهای حفاری، تکمیل و تحریک مخازن نفتی به شمار می‌آید. پیچیدگی و خطرات موجود در این فرآیندها، داشتن اطلاعات دقیق و قابل‌اعتماد در زمینه ژئومکانیک را ناگزیر می‌نماید [۲]. در حوزه ژئومکانیک، مطالعه سازندهای زیرزمینی به‌وسیله ساخت مدل‌های

در سال‌های اخیر، افزایش پیچیدگی شرایط زمین‌شناسی و توسعه حفاری در مخازن عمیق، توجه به تحلیل‌های ژئومکانیکی را افزایش داده است. ژئومکانیک^۱ یکی از حوزه‌های بنیادی و اساسی در زمینه‌های مرتبط با بهینه‌سازی فرآیندهای حفاری و توسعه مخازن نفتی به شمار می‌رود [۱]. ژئومکانیک با بررسی رفتار تنش-کرنش سنگ‌ها، نقش مهمی

¹ Geomechanics

در سال‌های اخیر، الگوریتم‌های یادگیری ماشین به‌طور قابل توجهی توانایی خود را در حل مسائل پیچیده با دقت و سرعت بالاتر و همچنین هزینه کمتر نشان داده‌اند [۱۱]. این قابلیت سبب شده تا از این تکنیک‌ها در حوزه‌های مختلفی مانند حفاری^{۱۴}، مخزن^{۱۵}، ژئومکانیک و غیره استفاده شود. به‌عنوان مثال، یکی از کاربردهای مهم قابل ذکر، استفاده از مدل‌های مختلف یادگیری ماشینی برای پیش‌بینی فشار منفذی با استفاده از اطلاعات مربوط به داده‌های چاه‌نگاری می‌باشد [۱۲].

۲- ادبیات پیشین

برای پیش‌بینی فشار منفذی در میادین نفتی و گازی، در سال ۲۰۱۴ توسط ابیدین^{۱۶} مدلی بر اساس شبکه عصبی مصنوعی^{۱۷} توسعه داده شد. این مدل به‌صورت سه لایه، طراحی و نتایج قابل توجهی از خود نشان داد. به‌طور خاص، دقت بسیار بالا با خطای پیش‌بینی ۵ درصد برای این مدل ثبت شده است [۱۳].

کیس و همکاران^{۱۸} در سال ۲۰۱۸، با بهره‌گیری از دانش و تجربیات پیشین در حوزه یادگیری ماشین و به‌منظور توسعه روش‌های پیش‌بینی دقیق‌تر و کارآمدتر برای مسائل مرتبط با حفاری چاه‌ها، یک مدل شبکه عصبی مصنوعی را برای پیش‌بینی فشار منفذی توسعه دادند. مدل مذکور از دو پارامتر راندمان حفاری^{۱۹} و انرژی ویژه مکانیکی^{۲۰} مرتبط با حفاری استفاده کرد. نتایج نشان داد که مدل‌های شبکه عصبی مصنوعی قادر به ارائه پیش‌بینی‌های قابل اعتماد برای فشار منفذی با دقتی در حدود ۹۰ درصد هستند [۱۴]. لذا دقت بالا در پیش‌بینی فشار منفذی، نشان‌دهنده توانایی مدل‌های هوش مصنوعی در ارتقای پیش‌بینی‌های مرتبط با حفاری و مخازن نفتی می‌باشد. چنان‌که این نتایج به‌عنوان یک گام موفقیت‌آمیز در جهت بهبود فرآیندهای حفاری و بهینه‌سازی

شبیه‌سازی که از ویژگی‌های مکانیکی مخصوص به خود برخوردارند، انجام می‌شود [۳]. این مدل‌ها امکان ارائه دقیق‌ترین تجزیه و تحلیل فرآیندهای مختلف را فراهم ساخته و بر اساس نتایج این تحلیل‌ها، امکان بهینه‌سازی و کاهش هزینه‌های عملیاتی، در دسترس قرار می‌گیرد [۴]. این مدل‌ها با استفاده از داده‌های چاه‌نگاری^۱ مانند اطلاعات چگالی سازند^۲، تخلخل^۳ و نگاره‌های آکوستیکی^۴، همچنین با بهره‌گیری از داده‌های آزمایشگاهی و میدانی^۵ تهیه و تولید می‌شوند.

یکی از ویژگی‌های مهم در حفاری و توسعه مخازن نفتی، پایداری چاه^۶ است [۵]. عدم پایداری چاه، هرز روی گل حفاری^۷ و مچاله شونده‌گی لوله جداری^۸ را به همراه دارد [۶]. این مشکلات می‌تواند سبب بروز مشکلات حفاری، اختلال در جریان سیالات^۹، اتلاف زمان^{۱۰} و منابع مالی شود [۷]. از این‌رو، تعیین پنجره ایمن گل^{۱۱} به‌منظور کنترل و مدیریت پایداری چاه، از اهمیت ویژه‌ای برخوردار است. پنجره ایمن معمولاً با توجه به شرایط تنشی در اطراف چاه تعیین می‌شود [۸]. برای ارزیابی تنش‌ها در محیط اطراف چاه، داشتن اطلاعات دقیق و جامع از فشار منفذی^{۱۲}، فشار شکست^{۱۳} و داده‌های چاه‌نگاری در اعماق مختلف ضروری است. این داده‌ها به‌عنوان ورودی‌های مهم مدل‌های ژئومکانیکی مطرح می‌باشد. با بهره‌گیری از داده‌های مذکور و استفاده از مدل‌های ژئومکانیکی، پنجره ایمن گل تعیین شده و راه‌حل‌های مناسبی برای مواجهه با مشکلات ناپایداری اتخاذ می‌گردد [۹].

با این‌وجود، تجزیه و تحلیل‌های دقیق و کامل به‌عنوان رویکردی هزینه‌بر و زمان‌بر مطرح بوده که محدودیت‌های زیادی را ایجاد می‌نماید [۱۰]. از این‌رو، تلاش‌هایی برای تبدیل آن به روش‌هایی سریع‌تر، کارآمدتر و اقتصادی‌تر جهت استفاده در تمامی پروژه‌های حفاری و توسعه مخازن نفتی در حال انجام است.

¹¹ Safe mud window

¹² Pore pressure

¹³ Fracture pressure

¹⁴ Drilling

¹⁵ Reservoir

¹⁶ Abidin

¹⁷ Artificial neural network

¹⁸ Kiss et al.

¹⁹ Drilling efficiency

²⁰ Mechanical specific energy

¹ Log data

² Density

³ Porosity

⁴ Acoustic log

⁵ Experimental and field data

⁶ Wellbore stability

⁷ Mud loss

⁸ Casing collapse

⁹ Loss circulation

¹⁰ Time

تصمیم‌گیری‌ها در صنعت نفت و گاز به شمار می‌آید.

احمد و همکاران^۱ در سال ۲۰۲۰، در زمینه پیش‌بینی فشار منفذی با استفاده از روش‌های یادگیری ماشینی به نتایج مهمی دست‌یافته‌اند. آن‌ها با هدف بهبود دقت و کارایی پیش‌بینی‌ها، روش‌های مختلفی از جمله شبکه عصبی عمکردی^۲، تابع پایه شعاعی^۳، شبکه عصبی مصنوعی و ماشین بردار پشتیبان^۴ را برای پیش‌بینی فشار منفذی مورد بررسی و تجزیه و تحلیل قرار دادند. در این مطالعه، مدل ماشین بردار پشتیبان با عملکرد برتر در پیش‌بینی فشار پوزولانی شناخته شد. این مدل به طور موفقیت‌آمیزی توانست پیش‌بینی‌های دقیقی را ارائه دهد و همچنین زمان محاسباتی کمتری نسبت به سایر مدل‌های مورد آزمایش داشته باشد. ضریب تعیین^۵ برابر با ۰/۹۹۵۰ و میانگین خطای نسبی^۶ برابر با ۰/۱۴٪ از دیگر نتایج چشم‌گیر این مطالعه بود [۱۵].

در همان سال، ظاهری و آبدیده^۷ با استفاده از هوش مصنوعی و الگوریتم‌های یادگیری ماشینی به پیش‌بینی پنجره وزن گل ایمن پرداختند. آن‌ها ابتدا یک مدل مکانیکی با استفاده از داده‌های چاه، مدول الاستیک سنگ و معیارهای شکست ساختند. سپس، از الگوریتم‌های یادگیری ماشینی برای ایجاد رابطه بین داده‌های چاه و پنجره وزن گل ایمن استفاده کرده و تعداد پارامترهای مورد نیاز برای محاسبه را کاهش دادند. نویسندگان که از مجموعه داده‌های سه چاه برای آموزش و آزمایش بهره بردند، به ضریب تعیین ۰/۹۳ هنگام استفاده از الگوریتم رگرسیون بردار پشتیبان با هسته تابع پایه شعاعی برای پیش‌بینی فشار پنجره وزن گل ایمن عملیات شکست هیدرولیکی دست یافتند. این مطالعه، پتانسیل استفاده از الگوریتم‌های یادگیری ماشینی را برای پیش‌بینی پنجره وزن گل ایمن و رسیدگی به مشکلات پرهزینه در صنعت نفت برجسته می‌کند [۱۶].

در سال ۲۰۲۲، مطالعه‌ای توسط متین کیا و همکاران^۸ انجام شد که به بررسی و مقایسه انواع مختلف الگوریتم‌های

پیش‌بینی برای مدل‌سازی فشار منفذی با استفاده از داده‌های چاه‌نگاری پرداخت. آن‌ها سه الگوریتم پیش‌بینی، یعنی ماشین بردار پشتیبان حداقل مربعات^۹، شبکه عصبی کانولوشن^{۱۰} و ماشین یادگیری افراطی چندلایه^{۱۱} را با سه الگوریتم بهینه‌ساز، یعنی الگوریتم ژنتیک^{۱۲}، الگوریتم بهینه‌سازی ترکیبی^{۱۳} و بهینه‌سازی ازدحام ذرات^{۱۴} مقایسه کردند. به طوری که هشت مدل یادگیری ماشینی و همچنین مدل‌های هیبریدی از این مدل‌ها برای پیش‌بینی فشار منفذی در دو حلقه چاه در مناطق نفتی جنوب غربی ایران توسعه و آزمایش شدند. نتایج این تحقیق نشان داد که مدل شبکه عصبی کانولوشن به عنوان یک مدل عصبی عمیق، عملکرد بسیار بهتری در مقایسه با مدل‌های دیگر داشته و پیش‌بینی‌های دقیق و معتبرتری از فشار منفذی ارائه می‌کند. چنان‌که، این مدل با دقت بسیار بالایی که ریشه میانگین مربعات خطا^{۱۵} آن برابر با ۰/۱۰۶۶ و ضریب تعیین آن برابر با ۰/۹۸۰۶ بود، مورد تأیید قرار گرفت [۱۷].

پن و همکاران^{۱۶} نیز در سال ۲۰۲۲، یک راه‌حل هوش مصنوعی برای پیش‌بینی پنجره‌های وزن گل ایمن وابسته به زمان و نمودارهای قطبی در چاه‌های مایل معرفی کردند. ریشه میانگین مربعات خطا ۰/۱۰۷ و ضریب تعیین ۰/۹۹۵ برای وزن‌های گل به دست آمد. در این مطالعه، راه‌حل هوش مصنوعی از نظر سرعت محاسباتی از راه‌حل تحلیلی بهتر عمل کرد. البته که مطالعات موردی، قابلیت‌ها و مزایای راه‌حل هوش مصنوعی برای پیش‌بینی پنجره‌های گل ایمن را تأیید کرده‌اند [۱۸].

پژوهش دیگری در سال ۲۰۲۲، توسط بهشتیان و همکاران^{۱۷} انجام شد که در آن به منظور پیش‌بینی پنجره ایمن وزن گل، از ترکیب ماشین یادگیری چندلایه^{۱۸} و الگوریتم بهینه‌ساز ازدحام ذرات بهره بردند. نتایج نشان داد که این مدل، با دقت بالا، عملکرد بسیار مطلوبی دارد [۱۹].

در سال ۲۰۲۵، مدل‌های ترکیبی که از ادغام شبکه‌های

¹⁰ Convolutional neural network

¹¹ Multiple hidden layers extreme learning machine

¹² Genetic algorithm

¹³ Coyote optimization algorithm

¹⁴ Particle swarm optimization

¹⁵ Root-mean-square error

¹⁶ Phan et al.

¹⁷ Beheshtian et al.

¹⁸ Multiple layer extreme learning machine

¹ Ahmed et al.

² Functional network

³ Radial basis function

⁴ Support vector machine

⁵ Coefficient of determination

⁶ Average relative error

⁷ Zaheri and Abdideh

⁸ Matinkia et al.

⁹ Least squares support vector machine

مطالعه [۱۹] از الگوریتم بهینه‌سازی ازدحام ذرات استفاده کرده‌اند؛ (ب) استفاده از داده‌های واقعی چاه‌نگاری عملیاتی (بدون نیاز به ساخت مدل ژئومکانیکی مستقل) برای پیش‌بینی مستقیم پنجره ایمن گل؛ (ج) ارزیابی همزمان هر دو مرز بالایی و پایینی پنجره ایمن گل در یک مدل یکپارچه.

۳- روش انجام کار

۳-۱- روش کار

شکل ۱، نمودار گردش کار به‌منظور پیش‌بینی پنجره گل ایمن با استفاده از یادگیری ماشین ترکیبی را نشان می‌دهد. همان‌طور که مشاهده می‌شود، پژوهش، با جمع‌آوری ۱۹۸۷ داده از سه چاه در یک مخزن گازی واقع در جنوب غربی ایران آغاز می‌گردد. در مرحله بعد مقادیر حداکثر و حداقل هر متغیر مشخص شده و سپس داده‌ها بر اساس رابطه ۱ بین ۱- و ۱+ نرمال می‌شود.

$$Q_i^l = \left(\frac{Q_i^l - Q_{min}^l}{Q_{max}^l - Q_{min}^l} \right) \times 2 - 1 \quad (1)$$

جایی که Q_i^l مقدار نرمال شده و Q_{max}^l و Q_{min}^l حداقل و حداکثر مقدار هر متغیر می‌باشد. البته حذف داده‌های پرت پیش از مرحله نرمال‌سازی و بر اساس روش فاصله بین چارکی^۱ بر روی مجموعه داده خام انجام شده بود. جهت بهبود کارایی چهار الگوریتم ترکیبی و دقت در پیش‌بینی، داده‌ها به سه دسته‌ی آموزشی (۷۰٪)، آزمایشی (۱۵٪) و اعتبارسنجی (۱۵٪)، تقسیم‌بندی شده‌اند. بنابراین ترتیب پیش‌پردازش داده‌ها، شامل شناسایی و حذف داده‌های پرت، تقسیم داده‌ها به سه زیرمجموعه آموزشی، آزمایش و اعتبارسنجی و سپس نرمال‌سازی مستقل هر زیرمجموعه می‌باشد. در مرحله بعد، نتایج حاصل از عملکرد الگوریتم‌ها با استفاده از پارامترهای آماری، مقایسه شده‌اند. تحلیل مقایسه‌ای، درک دقیق‌تر از عملکرد هر الگوریتم را ارائه می‌دهد.

عصبی با الگوریتم‌های بهینه‌سازی فراابتکاری بهره می‌برند، مورد توجه ویژه قرار گرفته‌اند. این مدل‌ها با تنظیم بهینه پارامترهای شبکه، قادر به بهبود دقت پیش‌بینی هستند. به‌عنوان مثال، در یک مطالعه جدید، استفاده از مدل‌های ترکیبی یادگیری ماشین برای پیش‌بینی پنجره ایمن وزن گل بر اساس داده‌های ژئوشیمیایی منجر به دستیابی به دقت بسیار بالا (ضریب تعیین بیش از ۰.۹۹) شد [۲۰].

همچنین، ترکیب روش‌های داده‌محور با مدل‌های مبتنی بر فیزیک به‌عنوان یک رویکرد نوین مطرح شده است. به طوری که در سال ۲۰۲۵، پژوهشی نشان داد که ادغام دانش فیزیکی با الگوریتم‌های یادگیری ماشین می‌تواند خطای پیش‌بینی را به‌طور قابل توجهی کاهش داده و پایداری مدل را افزایش دهد [۲۱].


با وجود پیشرفت‌های قابل توجه، بررسی ادبیات نشان می‌دهد که هنوز خلأهای مهمی در این حوزه وجود دارد. بسیاری از مطالعات بر پیش‌بینی پارامترهای منفرد تمرکز داشته و تعداد محدودی از آن‌ها به پیش‌بینی مستقیم پنجره ایمن وزن گل پرداخته‌اند. همچنین، مقایسه جامع عملکرد الگوریتم‌های بهینه‌سازی مختلف در قالب یک چهارچوب یکپارچه کمتر مورد توجه قرار گرفته است.

در تحقیق پیش رو، یک رویکرد نوآورانه جهت تعیین مستقیم محدوده ایمن برای وزن‌های گل حفاری، بر اساس تجزیه و تحلیل داده‌های ژئومکانیکی معرفی شده است. چنان‌که با استفاده از یک رویکرد ترکیبی مبتنی بر شبکه عصبی پرسپترون چندلایه و چهار الگوریتم بهینه‌سازی، دقت پیش‌بینی پنجره ایمن وزن گل افزایش می‌یابد. این روش، می‌تواند یک راه‌حل موثر و دقیق را برای تعیین وزن‌های گل حفاری در هر زمانی که داده‌های ورودی (همان داده‌های چاه‌نگاری) در دسترس قرار دارند، ارائه دهد.

نوآوری این مطالعه در مقایسه با مطالعات پیشین [۱۶]، [۱۸] و [۱۹] در موارد زیر خلاصه می‌شود: (الف) مقایسه جامع چهار الگوریتم بهینه‌سازی فراابتکاری کرم شبتاب، جستجوی گرانشی، کلونی زنبورهای عسل و الگوریتم رقابت استعماری در یک چهارچوب یکپارچه با شرایط یکسان برای پیش‌بینی پنجره ایمن گل، در حالی که مطالعه [۱۶] تنها از الگوریتم الگوریتم رگرسیون بردار پشتیبان با هسته تابع پایه شعاعی و

¹ Interquartile Range

که به روشی تحت نظارت الگوریتم انتشار برگشتی آموزش داده شده‌است، به‌طور گسترده در حل طیف وسیعی از مسائل استفاده می‌شود [۲۷]. شکل ۲، شماتیک الگوریتم پرسپترون چندلایه را نشان می‌دهد.



شکل ۲. شماتیک الگوریتم پرسپترون چندلایه.

۳-۳- الگوریتم کرم شب‌تاب^۲

کرم شب‌تاب از حشراتی است که نور زرد از خود ساطع می‌کند و مشخصه حرکت آن‌ها به سمت نوری است که بیشترین درخشندگی را دارد [۲۸]. با توجه به این قابلیت، الگوریتم فوق به‌عنوان یک الگوریتم بهینه‌سازی مناسب برای پیش‌بینی‌ها استفاده می‌شود [۲۹]. به بیانی دیگر، الگوریتم کرم شب‌تاب یک روش بهینه‌سازی است که با شبیه‌سازی رفتار کرم شب‌تاب سعی در یافتن پاسخ بهینه برای مسئله دارد [۳۰]. شکل ۳، الگوریتم کرم شب‌تاب را نشان می‌دهد.

پیش‌بینی پنجره گل ایمن با استفاده از یادگیری ماشین ترکیبی		
گام ۱: جمع‌آوری داده‌های گزارش چاه از ۳ حلقه چاه یک مخزن گاز	گام ۲: مرتب‌سازی و تعیین حداکثر و حداقل برای هر مقدار متغیر	گام ۳: نرمال‌سازی هر مقدار متغیر ورودی و متغیر خروجی بین -۱ و ۱+
گام ۴: مجموعه داده چاه به زیر مجموعه آموزش (۷۰٪)، تست (۱۵٪) و اعتبارسنجی (۱۵٪) تقسیم بندی می‌گردد	گام ۵: بدست آوردن خطاهای آماری برای هر الگوریتم	مرحله ۶: یافتن بهترین الگوریتم بر اساس مقایسه خطای آماری هر الگوریتم


شکل ۱. گردش کار به‌منظور پیش‌بینی پنجره گل ایمن

۲-۳- الگوریتم پرسپترون چندلایه^۱


شبکه عصبی مصنوعی، ابزار هوشمندی است که برای ایجاد روابط پیچیده غیرخطی بین مجموعه‌ای از متغیرها استفاده می‌شود. در نتیجه، شبکه عصبی مصنوعی می‌تواند متغیر(های) وابسته (خروجی) موردعلاقه را با دقت بالا پیش‌بینی کند. برای توسعه یک مدل پرسپترون چندلایه با کارایی بالا، چندین عامل کلیدی باید در نظر گرفته شود: الف) معماری شبکه (تعداد گره‌ها و لایه‌ها)، ب) توابع انتقال اعمال شده بین لایه‌ها، ج) انتخاب الگوریتم آموزشی مورد استفاده برای بهینه‌سازی عملکرد پیش‌بینی و د) انتخاب ویژگی‌های مناسب (یعنی نوع متغیرهای مستقل). لازم به ذکر است که عوامل فوق در تعیین میزان دقت پیش‌بینی مدل‌های پرسپترون چندلایه نقش حیاتی ایفا می‌کنند [۲۲]. کار شبکه عصبی ایجاد یک الگوی خروجی بر اساس الگوی ورودی ارائه‌شده به شبکه است. داده‌های ورودی می‌تواند داده‌های خام یا خروجی نوروهای دیگر باشد. خروجی نیز می‌تواند محصول نهایی یا ورودی برای سایر نوروها باشد. از این‌رو، شبکه عصبی مصنوعی شبکه‌ای از نوروهای مصنوعی است که درواقع عناصر پردازش کننده می‌باشند [۲۳ و ۲۴]. هر نورو تعدادی ورودی داشته که به هر ورودی وزن تعلق می‌گیرد. سپس خروجی میانه هر نورو از مجموع تمام ورودی‌ها ضرب در وزن‌ها به دست می‌آید [۲۵]. پرسپترون چندلایه، یک معماری شبکه عصبی مصنوعی است که در آن نوروهای شبکه به چندین لایه تقسیم می‌شوند [۲۶]. پرسپترون چندلایه از یک لایه ورودی و یک خروجی و همچنین یک یا چندلایه بین لایه‌های ورودی و خروجی به نام "لایه(های) مخفی" تشکیل شده‌است. پرسپترون چندلایه

² Firefly Algorithm (FA)

¹ Multi-Layer Perceptron's Algorithm



شکل ۴. فلوچارت الگوریتم کلونی زنبور عسل.



شکل ۳. الگوریتم کرم شب تاب.

۳-۶- الگوریتم رقابت استعماری^۳

الگوریتم رقابت استعماری یک الگوریتم بهینه سازی است که با مدل سازی ریاضی فرآیند تکامل اجتماعی - سیاسی، روشی برای حل مسائل بهینه سازی ارائه می دهد. این الگوریتم در حالت اولیه از چندین جمعیت شروع شده و جمعیت ها در واقع پاسخ های ممکن برای این مشکل هستند. ایده ی اصلی این الگوریتم الهام گرفته از فرآیند واقعی شکل گیری، توسعه و رقابت امپراطوری ها برای تسلط بر جهان است. در این الگوریتم، راه حل ها به عنوان «کشورها» مدل می شوند. برخی از این کشورها قوی تر (امپراطور) و برخی ضعیف تر (مستعمره) هستند. امپراطوری ها با تصاحب مستعمرات، رقابت می کنند و در نهایت تنها یک امپراطوری باقی می ماند. رقابت امپریالیستی در کنار سیاست جذب، هسته اصلی این الگوریتم بوده و باعث می شود که جمعیت به سمت حداقل مطلق تبعیت حرکت کند. با تکامل الگوریتم، جمعیت به دلیل جاذبه به سمت یک الگوریتم جابه جا می شود که راه حل تابع هدف آن از میانگین مربعات خطا بهره می برد [۳۸ - ۴۴].

۳-۷- الگوریتم های ترکیبی

شبکه عصبی، به عنوان یکی از ابزارهای حل مسئله، در این مطالعه نیز مورد استفاده قرار گرفته است. برای مقایسه بهتر و جامع نتایج، از ترکیب الگوریتم پرسپترون چندلایه با روش های بهینه سازی استفاده شده است. شکل ۵، چگونگی

۳-۴- الگوریتم جستجوی گرانشی^۱

این الگوریتم یکی از الگوریتم های جمعیت بر اساس قوانین گرانش است که در آن اطلاعات بین اجسام از طریق نیروی گرانش بین آن ها رد و بدل می شود، به عبارت دیگر اجسام به دلیل جرمشان به یکدیگر فشار می آورند [۳۱ و ۳۲]. جرم هر عامل با توجه به تابع هدف تعیین می شود [۳۳]. هر عضو رفتار ساده ای دارد که منجر به رفتار هوشمندانه اعضا می شود [۳۲]. تبادل اطلاعات بین هر عضو، از چهار روش، موقعیت، جرم اینرسی، جزء فعال جرم گرانشی و جزء غیرفعال جرم گرانشی انجام می گردد [۳۴].

۳-۵- الگوریتم کلونی زنبور عسل^۲

الگوریتم زنبور عسل رفتار گروه های زنبور عسل را در جستجوی غذا شبیه سازی می کند [۳۵]. در این مدل ریاضی، کلونی زنبور عسل مصنوعی دارای سه نوع زنبور است. زنبورهای کارگر روی گردآوری غذا و آوردن آن به کندو از یک منبع غذایی خاص کار می کنند. زنبورهای ناظر در میان کارگرها گشت می زنند تا تشخیص دهند یک منبع غذایی همچنان ارزش استفاده دارد یا خیر و در نهایت زنبورهای دیده بان که به دنبال کشف منابع غذایی جدید هستند [۳۶ و ۳۷]. شکل ۴، مراحل الگوریتم زنبور عسل را نشان می دهد.

³ Imperialist Competitive Algorithm (ICA)

¹ Gravitational Search Algorithm (GSA)

² Artificial Bee Colony Algorithm (ABC)

می‌دهد.


۸-۳- انتخاب معماری شبکه و پارامترهای کنترلی

به منظور انتخاب معماری بهینه شبکه عصبی پرسپترون چندلایه (MLP)، پیش از اعمال الگوریتم‌های فراابتکاری، یک فرآیند جستجوی شبکه‌ای^۱ بر روی تعداد لایه‌های پنهان (۱ تا ۳ لایه) و تعداد نورون‌ها (۵ تا ۲۰ نورون) انجام شد. نتایج این جستجو نشان داد که معماری با یک لایه پنهان و ۱۰ نورون، کمترین خطای اعتبارسنجی را بر روی داده‌های آموزشی تولید می‌کند. بر این اساس، این معماری به عنوان ساختار یکسان و ثابت برای تمامی چهار مدل ترکیبی انتخاب شد تا مقایسه عملکرد الگوریتم‌های بهینه‌ساز در شرایط کاملاً یکسان صورت پذیرد. تعداد ۵۰ عامل (جمعیت) و ۱۰۰ تکرار نیز بر اساس آزمون‌های اولیه و مشاهده همگرایی منحنی خطا در این محدوده انتخاب شدند. به‌طوری‌که افزایش بیشتر این پارامترها بهبود محسوسی در دقت پیش‌بینی ایجاد نکرد، اما هزینه محاسباتی را افزایش داد.

۹-۳- اعتبارسنجی متقاطع K-تایی

به منظور ارزیابی قابلیت تعمیم‌پذیری مدل‌ها و کاهش احتمال بیش‌برازش^۲، از روش اعتبارسنجی متقاطع K-تایی^۳ با K برابر با ۸ استفاده شد. در این روش، مجموعه داده‌ها به ۸ زیرمجموعه^۴ مساوی تقسیم شدند. در هر مرحله، ۷ زیرمجموعه برای آموزش و یک زیرمجموعه برای آزمایش استفاده شد. این فرآیند ۸ بار تکرار گردید تا هر زیرمجموعه یک بار نقش داده آزمایشی را ایفا کند. میانگین و انحراف معیار معیارهای عملکرد در ۸ تکرار به عنوان شاخص نهایی عملکرد مدل گزارش شد. استفاده از ۸ زیر مجموعه به جای مقادیر کمتر، تعادل بهتری بین واریانس تخمین و هزینه محاسباتی فراهم می‌آورد.

ترکیب الگوریتم پرسپترون چندلایه با الگوریتم‌های بهینه‌ساز کرم شبتاب، جستجوی گرانشی، کلونی زنبورهای عسل و الگوریتم رقابت استعماری را نشان می‌دهد.



شکل ۵. شماتیک الگوریتم‌های ترکیبی.

در روش ترکیبی فوق، وزن‌ها و بایاس‌های پرسپترون‌ها در هر لایه با الگوریتم‌های بهینه‌ساز کرم شبتاب، جستجوی گرانشی، کلونی زنبورعسل و الگوریتم رقابت استعماری به دست می‌آید. همان‌طور که در فلوچارت نشان داده شده‌است، شبکه الگوریتم پرسپترون چندلایه به‌عنوان تابع هزینه برای الگوریتم بهینه‌سازی مطرح بوده و درواقع پس از به دست آوردن هر وزن، شبکه را با وزن‌های جدید بازتعریف نموده و داده‌های آموزشی بر اساس آن تست می‌گردد.

تعامل بین شبکه الگوریتم پرسپترون چندلایه و الگوریتم‌های بهینه‌ساز کرم شبتاب، جستجوی گرانشی، کلونی زنبورهای مصنوعی و الگوریتم رقابت استعماری به‌گونه‌ای است که تمام وزن لایه‌ها و همچنین بایاس‌ها را به‌عنوان یک آرایه یا بردار در نظر می‌گیرد. جداول ۱ تا ۴، به ترتیب پارامترهای کنترلی برای ترکیب الگوریتم شبکه ترکیبی پرسپترون چندلایه با الگوریتم‌های بهینه‌ساز کرم شبتاب، جستجوی گرانشی، کلونی زنبورعسل و رقابت استعماری را به‌منظور پیش‌بینی پنجره ایمن وزن گل نشان

³ K-Fold Cross- Validation

⁴ Fold

¹ Grid search

² Overfitting

جدول ۱. پارامترهای کنترلی برای الگوریتم ترکیبی پرسپترون چندلایه - الگوریتم کرم شب تاب به منظور پیش بینی پنجره ایمن گل.

پرسپترون چندلایه		الگوریتم کرم شب تاب	
پارامتر کنترلی	مقدار	پارامتر کنترلی	مقدار
عملکرد فعال سازی (پنهان در خروجی)	purelin	تعداد کل کرم شب تاب	۵۰
تعداد نورون ها در لایه های پنهان	۱۰	مقدار پایه ضریب جذب (بتا)	۲
تابع فعال سازی (ورودی به مخفی)	tansig	ضریب جذب نور (گاما)	۱
تعداد لایه های پنهان	۱	تعداد متغیرهای وابسته	۱
		عامل جهش یکنواخت (دلتا)	۰/۰۵
		تعداد متغیرهای ورودی (m)	۶
		حداکثر تعداد تکرار	۱۰۰
		تعداد کل کرم شب تاب	۵۰
		نسبت میرایی ضریب جهش	۰/۹۸
		ضریب جهش (آلفا)	۰/۰۲

جدول ۲. پارامترهای کنترلی برای الگوریتم ترکیبی پرسپترون چندلایه - الگوریتم جستجوی گرانشی به منظور پیش بینی پنجره ایمن گل.

پرسپترون چندلایه		الگوریتم جستجوی گرانشی	
پارامتر کنترلی	مقدار	پارامتر کنترلی	مقدار
عملکرد فعال سازی (پنهان در خروجی)	purelin	ضریب تنظیم فاصله اقلیدسی	۰/۰۱
تعداد نورون ها در لایه های پنهان	۱۰	توان آلفای گرانشی	۲
تابع فعال سازی (ورودی به مخفی)	tansig	حداکثر تعداد تکرار	۱۰۰
تعداد لایه های پنهان	۱	تعداد k-best عامل اولیه استفاده شده	۳
		میزان جمعیت	۵۰
		ثابت گرانشی اولیه	۱۰

جدول ۳. پارامترهای کنترلی برای الگوریتم ترکیبی پرسپترون چندلایه - الگوریتم کلونی زنبورعسل به منظور پیش‌بینی پنجره ایمن گل.

الگوریتم کلونی زنبورعسل		پرسپترون چندلایه	
مقدار	پارامتر کنترلی	مقدار	پارامتر کنترلی
۱۰۰	تعداد کل زنبورها	purelin	عملکرد فعال‌سازی (پنهان در خروجی)
۵۰	تعداد کل زنبورهای پیشاهنگ	۱۰	تعداد نورون‌ها در لایه‌های پنهان
۶۰	حد بالایی آزمایشی	tansig	تابع فعال‌سازی (ورودی به مخفی)
۱	تعداد متغیرهای وابسته	۱	تعداد لایه‌های پنهان
۱۰۰	حداکثر تعداد تکرار		
۵۰	تعداد کل زنبورها		
۶	تعداد متغیرهای ورودی (m)		

جدول ۴. پارامترهای کنترلی برای الگوریتم ترکیبی پرسپترون چندلایه - الگوریتم رقابت استعماری به منظور پیش‌بینی پنجره ایمن گل.

الگوریتم رقابت استعماری		پرسپترون چندلایه	
مقدار	پارامتر کنترلی	مقدار	پارامتر کنترلی
۱	فشار انتخاب	purelin	عملکرد فعال‌سازی (پنهان در خروجی)
۰/۲	ضریب هزینه	۱۰	تعداد نورون‌ها در لایه‌های پنهان
۱۰	تعداد امپراطوری‌ها	tansig	تابع فعال‌سازی (ورودی به مخفی)
۱۰۰	حداکثر تعداد تکرار	۱	تعداد لایه‌های پنهان
۰/۵	احتمال انقلاب		
۱/۵	ضریب جذب		
۵۰	میزان جمعیت		

۴- بحث و نتایج

فشار شکست هیدرولیکی^۳ سازند قرار می‌گیرد؛ تجاوز از این حد موجب هرزروی گل حفاری می‌گردد. پنجره ایمن گل (SMW) بازه‌ای است که وزن گل باید در آن قرار گیرد ($SMW_{min} \leq \rho(mud) \leq SMW_{max}$).
 زمان حفاری^۴، کالیبر^۵، وزن روی مته^۶، جریان ورودی گل^۷، فشار تخلیه پمپ^۸ و چرخش در دقیقه^۹، متغیرهایی هستند که به منظور پیش‌بینی دو پارامتر حداقل فشار وزن گل زیر فشار شکست^{۱۰} و حداکثر فشار وزن گل بالاتر از شکست^{۱۱} مورد استفاده قرار گرفته‌اند. توصیفات آماری توزیع متغیرها در جدول ۵ ارائه شده است

در این مطالعه، به منظور پیش‌بینی پنجره ایمن گل از ۱۹۸۷ داده مربوط به سه چاه واقع در یکی از میادین گازی جنوب ایران استفاده شده است. در این مطالعه، حداقل وزن گل زیر فشار شکست به عنوان کمینه وزن گل حفاری تعریف می‌شود که از آستانه شکست برشی^۱ سازند جلوگیری می‌کند؛ در صورت کاهش وزن گل از این حد، ناپایداری جداره چاه رخ می‌دهد. حداکثر وزن گل بالاتر از فشار شکست نیز بالاترین وزن مجاز گل است که پایین‌تر از فشار شکست کششی^۲ یا

⁷ Flow rate

⁸ Pump discharge pressure

⁹ Rotations Per Minute

¹⁰ Minimum mud weight below the shear failure

¹¹ Maximum mud weight above the tensil failure

¹ Shear failure

² Tensil failure

³ Fracture Pressure

⁴ Drilling time

⁵ Calliper

⁶ Weight on Bit

جدول ۵. توصیف آماری متغیرهای مورد استفاده برای پیش‌بینی پنجره ایمن برای سه چاه از یکی از میدان نفتی در جنوب ایران.

متغیر	زمان	کالیبر	وزن روی	جریان	فشار تخلیه	چرخش	حداقل فشار	حداکثر فشار
	حفاری (ساعت)	(اینچ)	مته (کیلو پوند)	ورودی گل (گالن بر دقیقه)	پمپ (پوند بر اینچ مربع)	در دقیقه	وزن گل زیر فشار شکست (پوند بر اینچ مربع)	وزن گل بالاتر از شکست (پوند بر اینچ مربع)
میانگین	۲۶/۲۱	۶/۳۷	۲۱/۶۲	۷۰۹/۵۰	۱۷۹۶/۰۳	۱۹۲/۰۲	۳۲۵۸/۵۶	۶۰۰۲/۰۶
انحراف معیار	۶/۴۶	۰/۰۷	۱۰/۴۱	۳۰۰/۲۱	۵۹۰/۹۹	۴۵/۶۸	۱۰۳۳/۶۷	۲۰۰۶/۴۵
واریانس	۷۰/۳۴	۰/۰۳	۱۵۵/۳۰	۱۱۱۶۳۴/۱۰	۴۳۰۹۸۷/۲۱	۱۶۸۸/۸۷	۱۲۰۳۲۱۴/۷۹	۷۶۵۴۲۲۰/۶۷
مینیمم	۶/۰۸	۶/۴۳	۵/۹۵	۳۰۰/۱۳	۲۷۰/۶۳	۷۸/۸۵	۱۵۷۸/۰۳	۲۵۰۰/۷۹
ماکزیمم	۴۲/۷۳	۹/۰۹	۶۹/۷۵	۱۲۳۰/۴۱	۲۷۶۶/۲۷	۲۰۰/۸۹	۵۰۰۴/۱۵	۹۶۸۴/۳۳
چولگی	-۰/۶۰	۰/۷۰	۰/۸۸	۰/۳۹	-۰/۸۰	-۰/۴۹	۰/۱۹	۰/۲۴
کشیدگی	-۱/۸۶	-۱/۳۳	۰/۳۴	-۱/۱۷	-۰/۲۰	۱/۵۲	-۱/۰۳	-۱/۲۳

همان‌طور که قبلاً اشاره شد، در این مقاله، از ترکیب الگوریتم ترکیبی پرسپترون چندلایه با بهینه‌سازهای کرم شب‌تاب، الگوریتم جستجوی گرانشی، الگوریتم کلونی زنبور عسل و الگوریتم رقابت استعماری برای پیش‌بینی پنجره ایمن گل استفاده می‌شود. برای ارزیابی و مقایسه عملکرد روش‌های مذکور، از تکنیک‌های آماری، به شرح معادلات ۲ تا ۹ استفاده می‌گردد. یکی از دلایل کلیدی برای ترکیب حد بالایی و پایینی فشار گل به‌عنوان دو پارامتر این است که مقدار پنجره ایمن گل بین این دو آستانه قرار دارد. جهت بهبود کارایی چهار الگوریتم ترکیبی و دقت در پیش‌بینی، داده‌ها به سه دسته‌ی آموزشی (۷۰٪)، آزمایشی (۱۵٪) و اعتبارسنجی (۱۵٪)، تقسیم‌بندی شده‌اند. در مرحله بعد، نتایج حاصل از عملکرد الگوریتم‌ها با استفاده از پارامترهای آماری، مقایسه شده‌اند. جداول ۶ تا ۸ به ترتیب، نتایج ارائه‌شده برای زیرمجموعه‌های آموزش، آزمایش و اعتبارسنجی را نشان می‌دهد. شایان ذکر این‌که معادلات ۲ تا ۹ مراحل محاسباتی منتهی به چهار شاخص نهایی ارزیابی عملکرد (AARE،

STD، RMSE و R^2) را شامل شده و این چهار شاخص، معیارهای نهایی گزارش‌شده در جداول ۶ تا ۸ هستند.

$$RE_i = \frac{SMW_{(Measured)} - SMW_{(Predicted)}}{SMW_{(Measured)}} \times 100 \quad (2)$$

$$ARE = \frac{\sum_{i=1}^n RE_i}{n} \quad (3)$$

$$AARE = \frac{\sum_{i=1}^n |RE_i|}{n} \quad (4)$$

$$R^2 = 1 - \frac{\sum_{i=1}^N (SMW_{Predicted_i} - SMW_{Measured_i})^2}{\sum_{i=1}^N \left(SMW_{Predicted_i} - \frac{\sum_{i=1}^N SMW_{Measured_i}}{n} \right)^2} \quad (5)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (SMW_{Measured_i} - SMW_{Predicted_i})^2 \quad (6)$$

$$RMSE = \sqrt{MSE} \quad (7)$$

$$STD = \sqrt{\frac{\sum_{i=1}^n (D_i - Dimean)^2}{n-1}} \quad (8)$$

$$Dimean = \frac{1}{n} \sum_{i=1}^n (SMW_{Measured_i} - SMW_{Predicted_i}) \quad (9)$$

جدول ۶. ارائه نتایج آماری برای پیش‌بینی پارامترهای حداقل وزن گل زیر فشار شکست و حداکثر وزن گل بالای فشار شکست برای تعیین پنجره ایمن گل بر اساس داده‌های آموزش.

پارامتر پیش‌بینی شده	الگوریتم‌های به کار برده	AARE (%)	STD (psi)	RMSE (psi)	R ²
حداقل وزن گل زیر فشار شکست	پرسپترون چندلایه- الگوریتم کرم شب‌تاب	۹/۳۶۱	۸۹/۱۲۶	۹۲/۶۵۹	۰/۸۸۲۹
	پرسپترون چندلایه-الگوریتم جستجوی گرانشی	۹/۳۸۹	۱۰/۹۹۵	۱۲/۳۶۴	۰/۹۲۳۵
	پرسپترون چندلایه-الگوریتم کلونی زنبور عسل	۹/۴۹۳	۱۱۲/۵۵۲	۱۱۱/۳۴۷	۰/۷۶۳۵
	پرسپترون چندلایه-الگوریتم رقابت استعماری	۹/۳۷۴	۱۰۸/۵۷۴	۱۰۷/۱۶۴	۰/۷۹۳۶
حداکثر وزن گل بالتر از شکست	پرسپترون چندلایه- الگوریتم کرم شب‌تاب	۷/۹۳۲	۹۹/۹۷۰	۱۰۰/۵۶۷	۰/۸۸۴۷
	پرسپترون چندلایه-الگوریتم جستجوی گرانشی	۶/۲۷۱	۹/۳۰۳	۱۰/۲۵۸	۰/۹۳۷۱
	پرسپترون چندلایه-الگوریتم کلونی زنبور عسل	۷/۷۴۶	۱۳۲/۹۲۹	۱۳۴/۵۸۷	۰/۷۵۱۳
	پرسپترون چندلایه-الگوریتم رقابت استعماری	۷/۵۸۵	۱۲۳/۰۱۶	۱۲۲/۱۳۴	۰/۷۸۶۴

جدول ۷. ارائه نتایج آماری برای پیش‌بینی پارامترهای حداقل وزن گل زیر فشار شکست و حداکثر وزن گل بالای فشار شکست برای تعیین پنجره ایمن گل بر اساس داده‌های آزمایش.


پارامتر پیش‌بینی شده	الگوریتم‌های به کار برده	AARE (%)	STD (psi)	RMSE (psi)	R ²
حداقل وزن گل زیر فشار شکست	پرسپترون چندلایه- الگوریتم کرم شب‌تاب	۱۱/۲۴۵	۹۲/۵۹۱	۹۳/۰۱۵	۰/۸۷۲۲
	پرسپترون چندلایه-الگوریتم جستجوی گرانشی	۱۰/۲۶۲	۱۱/۸۷۰	۱۲/۲۸۳	۰/۹۰۱۴
	پرسپترون چندلایه-الگوریتم کلونی زنبور عسل	۱۱/۵۲۱	۱۰۷/۵۷۷	۱۰۸/۳۶۹	۰/۷۳۱۲
	پرسپترون چندلایه-الگوریتم رقابت استعماری	۱۱/۲۷۲	۱۰۳/۳۷۶	۱۰۲/۹۹۸	۰/۷۶۷۵
حداکثر وزن گل بالتر از شکست	پرسپترون چندلایه- الگوریتم کرم شب‌تاب	۸/۹۵۶	۱۰۷/۷۸۷	۱۰۶/۹۸۴	۰/۸۶۵۵
	پرسپترون چندلایه-الگوریتم جستجوی گرانشی	۷/۲۸۳	۱۱/۷۱۹	۱۲/۵۳۶	۰/۹۴۱۷
	پرسپترون چندلایه-الگوریتم کلونی زنبور عسل	۸/۵۴۷	۱۲۷/۹۴۸	۱۲۶/۸۸۷	۰/۷۴۵۸
	پرسپترون چندلایه-الگوریتم رقابت استعماری	۸/۸۱۸	۱۲۳/۹۰۸	۱۲۲/۳۲۵	۰/۷۷۹۸

جدول ۸. ارائه نتایج آماری برای پیش‌بینی پارامترهای حداقل وزن گل زیر فشار شکست و حداکثر وزن گل بالای فشار شکست برای تعیین پنجره ایمن گل بر اساس داده‌های اعتبارسنجی.


پارامتر پیش‌بینی شده	الگوریتم‌های به کار برده	AARE (%)	STD (psi)	RMSE (psi)	R ²
حداقل وزن گل زیر فشار شکست	پرسپترون چندلایه- الگوریتم کرم شب‌تاب	۱۰/۶۴۷	۸۵/۹۲۵	۸۴/۹۷۴	۰/۸۶۹۹
	پرسپترون چندلایه-الگوریتم جستجوی گرانشی	۹/۶۴۷	۱۱/۴۳۱	۱۱/۶۸۷	۰/۹۲۱۸
	پرسپترون چندلایه-الگوریتم کلونی زنبور عسل	۱۰/۶۱۳	۱۱۵/۲۰۷	۱۱۶/۶۳۷	۰/۷۲۸۷
	پرسپترون چندلایه-الگوریتم رقابت استعماری	۱۰/۴۸۰	۱۰۶/۲۰۰	۱۰۷/۶۴۷	۰/۷۳۶۵
حداکثر وزن گل بالتر از شکست	پرسپترون چندلایه- الگوریتم کرم شب‌تاب	۹/۹۸۰	۹۵/۲۷۲	۹۴/۱۶۳	۰/۸۴۷۲
	پرسپترون چندلایه-الگوریتم جستجوی گرانشی	۸/۲۹۰	۱۰/۴۲۱	۱۱/۷۲۱	۰/۹۳۶۴
	پرسپترون چندلایه-الگوریتم کلونی زنبور عسل	۹/۵۹۵	۱۲۸/۵۹۳	۱۲۹/۴۳۰	۰/۷۴۹۳
	پرسپترون چندلایه-الگوریتم رقابت استعماری	۹/۰۰۲	۱۱۹/۹۲۳	۱۱۸/۲۲۲	۰/۷۷۲۵

گرانشی در مقایسه با الگوریتم پرسپترون چندلایه- الگوریتم کرم شب تاب، الگوریتم پرسپترون چندلایه- الگوریتم کلونی زنبور عسل و الگوریتم پرسپترون چندلایه- الگوریتم رقابت استعماری، دقت بالاتری از خود نشان می دهد.

شکل های ۶ و ۷، برای هر مدل مقادیر حداقل و حداکثر وزن گل پیش بینی شده را در مقابل مقادیر اندازه گیری شده نشان می دهد. از جداول ۶ تا ۸ و شکل های ۶ و ۷ مشخص است که الگوریتم پرسپترون چندلایه- الگوریتم جستجوی




شکل ۶. نمودار متقاطع به منظور پیش بینی حداقل وزن گل زیر فشار شکست با استفاده از (الف) الگوریتم پرسپترون چندلایه- الگوریتم کرم شب تاب؛ (ب) الگوریتم پرسپترون چندلایه- الگوریتم جستجوی گرانشی؛ (ج) الگوریتم پرسپترون چندلایه- الگوریتم کلونی زنبور عسل؛ (د) الگوریتم پرسپترون چندلایه- الگوریتم رقابت استعماری.




شکل ۷. نمودار متقاطع به منظور پیش بینی حداکثر وزن گل بالای فشار شکست با استفاده از (الف) الگوریتم پرسپترون چندلایه- الگوریتم کرم شب تاب؛ (ب) الگوریتم پرسپترون چندلایه- الگوریتم جستجوی گرانشی؛ (ج) الگوریتم پرسپترون چندلایه- الگوریتم کلونی زنبور عسل؛ (د) الگوریتم پرسپترون چندلایه- الگوریتم رقابت استعماری.

پرسپترون چندلایه- الگوریتم جستجوی گرانشی، توزیع خطا از توزیع نرمال پیروی می‌کند. با این حال، توزیع خطاهای آماری سایر الگوریتم‌ها، الگوهای غیرعادی را نمایش می‌دهند.

شکل‌های ۸ و ۹، هیستوگرام خطاهای پیش‌بینی حداکثر وزن گل بالای فشار شکست و حداقل وزن گل زیر فشار شکست را نشان می‌دهند که از چهار مدل ترکیبی قوی، به‌دست آمده‌اند. همان‌طور که مشاهده می‌شود، برای الگوریتم



شکل ۸. هیستوگرام خطا به‌منظور پیش‌بینی حداقل وزن گل زیر فشار شکست با استفاده از (الف) الگوریتم پرسپترون چندلایه- الگوریتم کرم شب‌تاب؛ (ب) الگوریتم پرسپترون چندلایه- الگوریتم جستجوی گرانشی؛ (ج) الگوریتم پرسپترون چندلایه- الگوریتم کلونی زنبور عسل؛ (د) الگوریتم پرسپترون چندلایه- الگوریتم رقابت استعماری.




شکل ۹. هیستوگرام خطا به‌منظور پیش‌بینی حداکثر وزن گل بالای فشار شکست با استفاده از (الف) الگوریتم پرسپترون چندلایه- الگوریتم کرم شب‌تاب؛ (ب) الگوریتم پرسپترون چندلایه- الگوریتم جستجوی گرانشی؛ (ج) الگوریتم پرسپترون چندلایه- الگوریتم کلونی زنبور عسل؛ (د) الگوریتم پرسپترون چندلایه- الگوریتم رقابت استعماری.

متغیرهای ورودی، تحلیل حساسیت بر اساس ضریب همبستگی پیرسون^۱ انجام شد. این تحلیل رابطه خطی بین هر یک از متغیرهای ورودی (زمان حفاری، کالیبر، وزن روی مته، جریان ورودی گل، فشار تخلیه پمپ و چرخش در دقیقه) با پارامترهای خروجی (حداقل وزن گل زیر فشار شکست و حداکثر وزن گل بالاتر از فشار شکست) را کمی می‌کند. نتایج تحلیل حساسیت در شکل‌های ۱۲ و ۱۳ ارائه شده است. این تحلیل امکان درک بهتر رفتار فیزیکی فرآیند حفاری و تأیید سازگاری نتایج مدل با اصول ژئومکانیک را فراهم می‌آورد که بر اساس آن مشخص می‌گردد که جریان ورودی و فشار تخلیه ی پمپ تأثیر بسیاری بر حداقل وزن گل زیر فشار شکست و حداکثر وزن گل بالاتر از فشار شکست دارد.

شکل‌های ۱۰ و ۱۱، مقادیر خطا به ازای تکرار جهت پیش‌بینی حداقل وزن گل زیر فشار شکست و حداکثر وزن گل بالای فشار شکست با استفاده از روش‌های ترکیبی الگوریتم پرسپترون چندلایه-الگوریتم کرم شب‌تاب، الگوریتم پرسپترون چندلایه-الگوریتم جستجوی گرانشی، الگوریتم پرسپترون چندلایه-الگوریتم کلونی زنبور عسل، الگوریتم پرسپترون چندلایه-الگوریتم رقابت استعماری را نشان می‌دهد. با بررسی نتایج حاصله و در ۱۰۰ تکرار، می‌توان بیان داشت که به هنگام هیبرید کردن الگوریتم شبکه پرسپترون چندلایه و الگوریتم بهینه‌ساز جستجوی گرانشی، نتایج دارای دقت بالاتر نسبت به سایر الگوریتم‌ها می‌باشد.


۴-۱- تحلیل حساسیت متغیرهای ورودی

به منظور تفسیرپذیری مدل‌ها و تعیین اهمیت نسبی




شکل ۱۰: مقدار خطا به ازای تکرار جهت پیش‌بینی حداقل وزن گل زیر فشار شکست با استفاده از الگوریتم پرسپترون چندلایه-الگوریتم کرم شب‌تاب، الگوریتم پرسپترون چندلایه-الگوریتم جستجوی گرانشی، الگوریتم پرسپترون چندلایه-الگوریتم کلونی زنبور عسل و الگوریتم پرسپترون چندلایه-الگوریتم رقابت استعماری.


¹ Pearson Correlation Coefficient



شکل ۱۱. مقدار خطا به ازای تکرار جهت پیش‌بینی حداکثر وزن گل بالای فشار شکست با استفاده از الگوریتم پرسپترون چند لایه - الگوریتم کرم شب تاب، الگوریتم پرسپترون چند لایه - الگوریتم جستجوی گرانشی، الگوریتم پرسپترون چند لایه - الگوریتم کلونی زنبور عسل و الگوریتم پرسپترون چند لایه - الگوریتم رقابت استعماری.



شکل ۱۲. تحلیل حساسیت پیرسون برای حداقل وزن گل زیر فشار شکست.



شکل ۱۳. تحلیل حساسیت پیرسون برای حداکثر وزن گل زیر فشار شکست.

۲-۴- محدودیت‌های پژوهش

این پژوهش با محدودیت‌هایی مواجه است که می‌بایست در تفسیر نتایج، مد نظر قرار گیرند. نخست، مجموعه داده‌های مورد استفاده تنها شامل ۱۹۸۷ رکورد از سه چاه در یک میدان گازی در جنوب ایران است، بنابراین تعمیم مستقیم مدل‌ها به میداین دیگر با زمین‌شناسی متفاوت مستلزم اعتبارسنجی مجدد با داده‌های جدید است. دوم، متغیرهای ورودی محدود به داده‌های عملیاتی حفاری هستند و برخی پارامترهای ژئومکانیکی مستقیم (مانند مدول الاستیسیته و نسبت پواسون) به عنوان ورودی در مدل‌ها لحاظ نشده‌اند. سوم، مقایسه در این مطالعه محدود به چهار الگوریتم فراابتکاری است و مقایسه با روش‌های دیگر مانند جنگل تصادفی^۱ یا XGBoost موضوع تحقیقات آینده خواهد بود.

۵- نتیجه‌گیری

نتایجی که می‌توان برای این مقاله در نظر گرفت به قرار ذیل است:

۱- در این مطالعه، به‌منظور پیش‌بینی پنجره ایمن گل از ۱۹۸۷ داده مربوط به سه چاه واقع در یکی از میداین گازی جنوب ایران استفاده شده است. زمان حفاری، کالیبر، وزن روی مته، جریان ورودی گل، فشار تخلیه پمپ و چرخش در دقیقه، متغیرهایی هستند که به‌منظور پیش‌بینی دو پارامتر حداقل

وزن گل زیر فشار شکست و حداکثر وزن گل بالاتر از شکست مورد استفاده قرار گرفته‌اند.

۲- بدین منظور از چهار الگوریتم ترکیبی یادگیری ماشینی شامل الگوریتم پرسپترون چندلایه- الگوریتم کرم شب‌تاب، الگوریتم پرسپترون چندلایه- الگوریتم جستجوی گرانشی، الگوریتم پرسپترون چندلایه- الگوریتم کلونی زنبور عسل و الگوریتم پرسپترون چندلایه- الگوریتم رقابت استعماری بهره برده شده است.

۳- جهت بهبود کارایی چهار الگوریتم ترکیبی و دقت در پیش‌بینی، داده‌ها به سه دسته‌ی آموزشی (۷۰٪)، آزمایشی (۱۵٪) و اعتبارسنجی (۱۵٪)، تقسیم‌بندی شده‌اند. در مرحله بعد، نتایج حاصل از عملکرد الگوریتم‌ها با استفاده از پارامترهای آماری، مقایسه شده‌اند.

۴- نتایج نشان داد که، «الگوریتم پرسپترون چندلایه- الگوریتم جستجوی گرانشی» از دیگر مدل‌ها، دقیق‌تر است. چنان‌که زیرمجموعه آزمایشی الگوریتم مذکور، کمترین خطا را برای حداقل وزن گل زیر فشار شکست (psi) فشار شکست ($RMSE = 12/283$ ؛ $R^2 = 0/9014$) و حداکثر وزن گل بالای فشار شکست ($RMSE = 12/536$ ؛ psi ؛ $R^2 = 0/9417$) نشان می‌دهد.

۵- بر اساس نتایج زیرمجموعه آزمایشی، مدل MLP-GSA برای پارامتر حداقل وزن گل زیر فشار شکست، ضریب تعیین

¹ Random Forest

بوده که محدودیت‌های زیادی را ایجاد می‌نماید. در مقابل، مدل توسعه‌یافته در این مطالعه تخمین مناسبی را با الگوریتم‌های هیبریدی ارائه می‌دهد.

۷- یافته‌های این مطالعه می‌تواند درک بهتری از کاربرد مدل ترکیبی برای پیش‌بینی قابل‌اعتماد پنجره ایمن گل در سه چاه مورد مطالعه در میدان گازی جنوب ایران ارائه دهد. لازم به ذکر است که قابلیت تعمیم این مدل به سایر میداين مستلزم اعتبارسنجی با داده‌های بیشتر از چاه‌های مختلف است.

برابر با ۰/۹۰۱۴ را ثبت کرده است که نسبت به مدل MLP-FA (با ضریب تعیین ۰/۸۷۲۲) بهبودی معادل تقریباً سه درصد واحد و نسبت به مدل MLP-ABC (با ضریب تعیین ۰/۷۳۱۲) بهبودی معادل تقریباً هفده درصد واحد نشان می‌دهد. به همین ترتیب، برای پارامتر حداکثر وزن گل بالاتر از فشار شکست، مدل MLP-GSA با ضریب تعیین ۰/۹۴۱۷ نسبت به مدل MLP-FA (۰/۸۶۵۵) بهبودی معادل تقریباً هشت درصد واحد و نسبت به مدل MLP-ABC (۰/۷۴۵۸) بهبودی معادل تقریباً بیست درصد واحد دارد.

۶- تجزیه و تحلیل‌های دقیق و کامل مبتنی بر تخمین‌های مدل ژئومکانیکی به‌عنوان رویکردی هزینه‌بر و زمان‌بر مطرح

۶- منابع

- [1] Chen, C. Ji, G. Wang, H. Huang, H. Baud, P. Wu, Q. (2022). Geology-engineering integration to improve drilling speed and safety in ultra-deep clastic reservoirs of the Qiulitage structural belt. *Advances in Geo-Energy Research*, (6), 347-356.
- [2] Asadi, A. (2017). Application of artificial neural networks in prediction of uniaxial compressive strength of rocks using well logs and drilling data. *Procedia Engineering*, (191), 279-286.
- [3] Perchikolaee, RS. Shadizadeh, SR. Shahryar, K. Kazemzadeh, E. (2010). Building a Precise Mechanical Earth Model and its Application in Drilling Operation Optimization: A Case Study of Asmari Formation in Mansuri Oil Field. *SPE*, 132204.
- [4] Zevgolisi, IE. Deliveris, AV. Koukoulzas, NC. (2018). Probabilistic design optimization and simplified geotechnical risk analysis for large open pit excavations. *Computers and Geotechnics*, (103), 153-164.
- [5] Jiang, G. Tengfei, D. Kaixiao, CUI. Yinbo, HE. Xiaohu, Q. Lili, Y. (2022). Research status and development directions of intelligent drilling fluid technologies. *Petroleum Exploration and Development*, (49), 660-670.
- [6] Khakzad, N. Khan, F. Amyotte, P. (2013). Quantitative risk analysis of offshore drilling operations: A Bayesian approach. *Safety science*, (57), 108-117.
- [7] Al-Nutai, AM. (2014). Wellbore Instability Analysis in a Highly Fractured Carbonate Gas Reservoirs. International Petroleum Technology Conference, Kuala Lumpur, Malaysia, 1-10.
- [8] Maleki, S. Gholami, R. Rasouli, V. Moradzadeh, A. Riabi, RG. Sadaghzadeh, F. (2014). Comparison of different failure criteria in prediction of safe mud weight window in drilling practice. *Earth-Science Reviews*, (136), 36-58.
- [9] Akbarpour, M. Abdideh, M. (2020). Wellbore stability analysis based on geomechanical modeling using finite element method. *Modeling Earth Systems and Environment*, (6), 617-626.
- [10] Epelle, EI. Gerogiorgis, DI. (2020). A review of technological advances and open challenges for oil and gas drilling systems engineering. *AIChE Journal*, (66), 16842.
- [11] Jung, H. Jeon, J. Choi, D. Park, J-Y. (2021). Application of machine learning techniques in injection molding quality prediction: Implications on sustainable manufacturing industry. *Sustainability*, (13), 4120.
- [12] Zhang, W. Li, H. Li, Y. Liu, H. Chen, Y. Ding, X. (2021). Application of deep learning algorithms in geotechnical engineering: a short critical review. *Artificial Intelligence Review*, (54), 1-41.

- [13] Abidin, MH. (2014). Pore pressure estimation using artificial neural network. A project dissertation submitted to the bachelor of Petroleum Engineering, PETRONAS University of Technology.
- [14] Kiss, A. Fruhwirth, RK. Pongratz, R. Maier, R. Hofstätter, H. (2018). Formation breakdown pressure prediction with artificial neural networks. SPE, D023S09R02.
- [15] Ahmed, A. Elkatatny, S. Ali, A. Abughaban, M. Abdulraheem, A. (2020). Application of artificial intelligence techniques in predicting the lost circulation zones using drilling sensors. *Journal of Sensors*, (2020), 1-18.
- [16] Zahiri, J. Abdideh, M. Ghaleh Golab, E. (2019). Determination of safe mud weight window based on well logging data using artificial intelligence. *Geosystem Engineering*, (22), 193-205.
- [17] Matinkia, M. Amraeiniya, A. Behboud, MM. Mehrad, M. Bajolvand, M. Gandomgoun, MH. (2022). A novel approach to pore pressure modeling based on conventional well logs using convolutional neural network. *Journal of Petroleum Science and Engineering*, (211), 110-156.
- [18] Phan, DT. Liu, C. Altammar, MJ. Han, Y. Abousleiman, YN. (2022). Application of artificial intelligence to predict time-dependent mud-weight windows in real time. *SPE Journal*, (27), 39-59.
- [19] Beheshtian, S., Rajabi, M., Davoodi, S., Wood, D.A., Ghorbani, H., Mohamadian, N., Ahmadi Alvar, M., Band, S. (2022). Robust computational approach to determine the safe mud weight window using well-log data from a large gas reservoir, *Marine and Petroleum Geology* (142), 105772.
- [20] Zhang, W., Li, H., Liu, Y., & Chen, X. (2025). Machine learning approach for prediction of safe mud weight window based on geochemical drilling log data. *Frontiers in Earth Science*, 13, 1529320. <https://doi.org/10.3389/feart.2025.1529320>
- [21] Chen, C., Wang, G., Huang, H., Wu, Q., & Baud, P. (2025). Prediction of mud weight window based on geological sequence matching and a physics-driven machine learning model. *Processes*, 13(7), 2255. <https://doi.org/10.3390/pr13072255>
- [22] Gao, G. Hazbeh, O. Davoodi, S. Tabasi, M. Rajabi, M. Ghorbani, H. et al. (2023). Prediction of fracture density in a gas reservoir using robust computational approaches. *Frontiers in Earth Science*, (10), 1023578.
- [23] Sánchez-Gutiérrez, ME. González-Pérez, PP. (2022). Multi-Class Classification of Medical Data Based on Neural Network Pruning and Information-Entropy Measures. *Entropy*, (24), 196.
- [24] Ross, A. Leroux, N. De Riz, A. Marković, D. Sanz-Hernández, D. Trastoy, J. et al. (2023). Multilayer spintronic neural networks with radiofrequency connections. *Nature Nanotechnology*, (1), 1-8.
- [25] Guo, H. Guo, C. Xu, B. Xia, Y. Sun, F. (2021). MLP neural network-based regional logistics demand prediction. *Neural Computing and Applications*, (33), 3939-3952.
- [26] Desai, M. Shah, M. (2021). An anatomization on breast cancer detection and diagnosis employing multi-layer perceptron neural network (MLP) and Convolutional neural network (CNN). *Clinical eHealth*, (4), 1-11.
- [27] Da Silva, IN. Hernane Spatti, D. Andrade Flauzino, R. Liboni, LHB. dos Reis Alves, SF. et al. (2017). Artificial neural network architectures and training processes. Switzerland: Springer, 62 .
- [28] Gautam, GD. Mishra, DR. (2019). Firefly algorithm based optimization of kerf quality characteristics in pulsed Nd: YAG laser cutting of basalt fiber reinforced composite. *Composites*, (176), 107340.
- [29] Ghorbani, H. Moghadasi, J. Wood, DA. (2017). Prediction of gas flow rates from gas condensate reservoirs through wellhead chokes using a firefly optimization algorithm. *Journal of Natural Gas Science and Engineering*, (45), 256-271.

- [30] Çelik, Y. Kutucu H. (2018). Solving the Tension/Compression Spring Design Problem by an Improved Firefly Algorithm, *IDDM*, (1), 1-7.
- [31] Naserbegi, A. Aghaie, M. Minuchehr, A. Alahyarizadeh, G. (2018). A novel exergy optimization of Bushehr nuclear power plant by gravitational search algorithm (GSA). *Energy*, (148), 373-385.
- [32] Rashedi, E. Rashedi, E. Nezamabadi-Pour, H. (2018). A comprehensive survey on gravitational search algorithm. *Swarm and evolutionary computation*, (41), 141-158.
- [33] Duman, S. Sönmez, Y. Güvenç, U. Yörükeren, N. (2012). Optimal reactive power dispatch using a gravitational search algorithm. *IET generation, transmission & distribution*, (6), 563-576.
- [34] Hashemi, A. Dowlatshahi, MB. Nezamabadi-Pour, H. (2021). Gravitational Search Algorithm: Theory, Literature Review, and Applications. *Handbook of AI-based Metaheuristics*, Boca Raton: CRC Press, 119-150.
- [35] Sharma, A. Choudhary, S. Pachauri, RK. Shrivastava, A. Kumar, D. (2020). A review on artificial bee colony and its engineering applications. *Journal of Critical Reviews*, (7), 4097-4107.
- [36] Aslan, S. Karaboga, D. (2022). A genetic Artificial Bee Colony algorithm for signal reconstruction based big data optimization. *Applied Soft Computing*, (88), 106053.
- [37] Rahnama, N. Gharehchopogh, FS. (2020). An improved artificial bee colony algorithm based on whale optimization algorithm for data clustering. *Multimedia Tools and Applications*, (79), 32169-32194.
- [38] Talatahari, S. Azar, BF. Sheikholeslami, R. Gandomi, AH. (2012). Imperialist competitive algorithm combined with chaos for global optimization. *Communications in Nonlinear Science and Numerical Simulation*, (17), 1312-1319.
- [39] Mesleh, AM. (2017). Lung Cancer Detection Using Multi-Layer Neural Networks with Independent Component Analysis: A Comparative Study of Training Algorithms. *Jordan Journal of Biological Sciences*, (10), 239-249.
- [40] Shawli, A. (2011). Scoring the SF-36 health survey in scleroderma using independent component analysis and principle component analysis. Master of Science thesis. McGill University, Department of Mathematics and Statistics.
- [41] Rutledge, DN. Bouveresse, DJ-R. (2013). Independent components analysis with the JADE algorithm. *TrAC Trends in Analytical Chemistry*, (50), 22-32.
- [42] Ghasemi, M. Ghavidel, S. Ghanbarian, MM. Massrur, HR. Gharibzadeh, M. (2014). Application of imperialist competitive algorithm with its modified techniques for multi-objective optimal power flow problem: a comparative study. *Information Sciences*, (281), 225-247.
- [43] Li, B. Tang, ZB. (2022). Double-assimilation of prosperity and destruction oriented improved imperialist competitive algorithm with computational thinking. *IEEE*, (1), 1-8.
- [44] Bizon, K. Continillo, G. Lombardi, S. Sementa, P. Vaglieco, BM. (2016). Independent component analysis of cycle resolved combustion images from a spark ignition optical engine. *Combustion and Flame*, (163), 258-269.



Prediction of Safe Mud Weight Window Using Hybrid Machine Learning Models Based on Multilayer Perceptron and Metaheuristic Optimization Algorithms

Meysam Rajabi^{*1}, Hamzeh Ghorbani², Seyed Vahid Alavi Nezhad Khalil Abad³

1. Assistant Professor, Department of Mining Engineering, Birjand University of Technology, Birjand, Iran

2- Graduated in Petroleum Engineering, Young Researchers and Elite Club, Islamic Azad University, Ahvaz, Iran

3- Assistant Professor, Department of Civil Engineering, Birjand University of Technology, Birjand, Iran

Received: 28 May 2026 Accepted: 21 June 2026

(*Corresponding author: m.rajabi@birjandut.ac.ir)

Keywords

**Safe Mud Weight Window,
Petroleum Geomechanics,
Machine Learning,
Multilayer Perceptron,
Metaheuristic Optimization**

Abstract

Accurate determination of the safe mud weight window is a critical challenge in drilling engineering, with direct implications for wellbore stability, lost circulation prevention, and reduction of non-productive time (NPT) and associated operational costs. In this study, hybrid machine learning (ML) models were developed to predict the lower bound of the mud weight window — defined by the collapse pressure — and the upper bound — constrained by the fracture pressure gradient. To this end, a multilayer perceptron (MLP) neural network was integrated with four distinct optimization algorithms: the Firefly Algorithm (FA), Gravitational Search Algorithm (GSA), Artificial Bee Colony (ABC) and Imperialist Competitive Algorithm (ICA). The dataset comprised well-log and geomechanical data acquired from three wells in an gas field located in southern Iran. Following data normalization, the dataset was partitioned into training (70%), validation (15%), and test (15%) subsets. When assessing the safe mud weight window within the test subset of the Multi-Layer Perceptron-Gravitational Search algorithm, minimal errors are evident for both the minimum drilling mud weight pressure (RMSE = 12.283 psi; $R^2 = 0.9014$) and the maximum mud weight pressure during drilling (RMSE = 12.536 psi; $R^2 = 0.9417$). These findings indicate that hybrid machine learning frameworks can substantially enhance the predictive accuracy of the safe mud weight window and offer a robust, data-driven decision-support tool for real-time drilling operations.
