



Research Article



DOI: 10.22034/farayandno.2025.2069800.2012



This journal is an open access journal licensed under an Attribution-Non Commercial 4.0 International Licenses (CC BY-NC 4.0).

## Application of Artificial Intelligence Algorithms in Predicting and Optimizing Rate of Penetration in the Shadegan Oilfield Formations Based on Hydraulic and Formation Pressure Data

Mahdi Nazari Saram<sup>1\*</sup>, Rahim Dabiri<sup>2</sup>

<sup>1</sup> Department of Petroleum, Mining and Materials, CT.C, Islamic Azad University, Tehran, Iran

<sup>2</sup> Department of Geology, Ma.C., Islamic Azad University, Mashhad, Iran

Received: 31 May 2025

Accepted: 3 Aug 2025

### Abstract

Accurate prediction of the Rate of Penetration (ROP) remains a major challenge in drilling optimization due to its highly nonlinear and multivariate nature. In this study, real field data from the Shadegan oil field including hydraulic parameters (e.g., pump pressure, flow rate), formation pressure, and operational variables were used to develop and compare two deep learning models: Recurrent Neural Network (RNN) and Long Short-Term Memory (LSTM). After preprocessing and time-series segmentation, models were evaluated using RMSE, MAE, and  $R^2$  metrics. The LSTM model demonstrated superior performance with  $R^2=0.95$ , MAE=0.0236, and RMSE=0.0346, significantly outperforming the RNN ( $R^2=0.85$ ). Furthermore, the trained LSTM model was employed as a surrogate for ROP optimization, yielding an optimal ROP of 8.63 m/h more than 3.3 times the observed field average (2.6 m/h) under safe operational constraints. This data-driven approach offers a practical framework for real-time drilling advisory systems.

**Keyword:** Rate of Penetration (ROP), Shadegan oil Field, Artificial Intelligence (AI), LSTM Network, Hydraulic Data, Drilling Optimization, Deep Learning

\* mahdinazarisaram@iau.ac.ir

### Please Cite This Article Using:

Nazari Saram, M., Dabiri, R., "Application of Artificial Intelligence Algorithms in Predicting and Optimizing Rate of Penetration in the Shadegan Oilfield Formations Based on Hydraulic and Formation Pressure Data", Journal of Farayandno – Vol. 20 – No. 90, pp. 73-90, In Persian, (2025).



DOI: 10.22034/farayandno.2025.2069800.2012



This journal is an open access journal licensed under an Attribution-Non Commercial 4.0 International Licenses (CC BY-NC 4.0).

## کاربرد الگوریتم‌های هوش مصنوعی در پیش‌بینی و بهینه‌سازی نرخ نفوذ مته در سازندهای میدان نفتی شادگان با تکیه بر داده‌های هیدرولیکی و فشار سازندی

مهدی نظری صارم<sup>1\*</sup>، رحیم دبیری<sup>2</sup>

<sup>1</sup> گروه مهندسی نفت، معدن و مواد، واحد تهران مرکزی، دانشگاه آزاد اسلامی، تهران، ایران

<sup>2</sup> گروه زمین‌شناسی، واحد مشهد، دانشگاه آزاد اسلامی، مشهد، ایران

دریافت: 1404/03/10 پذیرش: 1404/05/12

### چکیده

پیش‌بینی دقیق نرخ نفوذ مته به دلیل رفتار غیرخطی و چندمتغیره آن، یکی از چالش‌های کلیدی در بهینه‌سازی عملیات حفاری است. در این مطالعه، با استفاده از داده‌های واقعی میدان نفتی شادگان شامل پارامترهای هیدرولیکی، فشار سازندی و مشخصات مکانیکی، دو مدل یادگیری عمیق RNN و LSTM توسعه یافتند. پس از پیش‌پردازش داده‌ها و تقسیم‌بندی زمانی، مدل‌ها بر اساس معیارهای RMSE، MAE و  $R^2$  ارزیابی شدند. نتایج نشان داد مدل LSTM با ضریب تعیین 0/95، MAE برابر 0/0236 و RMSE معادل 0/0346، عملکردی برتر نسبت به RNN ( $R^2 = 0/85$ ) دارد. همچنین، با بهینه‌سازی پارامترهای عملیاتی، نرخ نفوذ مته به 8/63 متر بر ساعت افزایش یافت که بیش از 3/3 برابر میانگین مشاهده شده است. این رویکرد می‌تواند در سیستم‌های پشتیبان تصمیم‌گیری حفاری به کار رود.

**کلمات کلیدی:** نرخ نفوذ مته، میدان نفتی شادگان هوش مصنوعی، شبکه عصبی LSTM، داده‌های هیدرولیکی، بهینه‌سازی عملیات حفاری

\* mahdinazarisaram@iau.ac.ir

## 1- مقدمه

عملیات حفاری یکی از پرهزینه‌ترین و استراتژیک‌ترین مراحل در چرخه اکتشاف و تولید منابع هیدروکربنی به‌شمار می‌رود که مستقیماً بر زمان‌بندی پروژه، کارایی اقتصادی و ایمنی کلی فرآیند توسعه میدان‌های نفتی تأثیر می‌گذارد [1]. در این میان، نرخ نفوذ مت‌آبه‌عنوان شاخصی کلیدی در ارزیابی عملکرد حفاری، نقش مهمی در کاهش زمان عملیات و در نتیجه، صرفه‌جویی در هزینه‌های مستقیم و غیرمستقیم حفاری ایفا می‌کند [2]. نرخ نفوذ مت‌ نشان‌دهنده میزان پیشروی مت‌ در سازند طی واحد زمان است و افزایش آن در چارچوب محدودیت‌های عملیاتی و ایمنی، همواره از اهداف اصلی مهندسان حفاری محسوب می‌شود. با این حال، پیش‌بینی دقیق نرخ نفوذ مت‌ همواره با چالش‌هایی همراه است؛ چراکه این پارامتر تحت تأثیر ترکیبی از عوامل زمین‌شناسی و عملیاتی نظیر خواص ژئومکانیکی سازند (شامل سختی، مقاومت فشاری و تخلخل)، مشخصه‌های هیدرودینامیکی سیال حفاری (نظیر دبی و فشار پمپ) و نیز فشار سازندی قرار دارد [3]. ماهیت چندمتغیره، پویا و غیرخطی این عوامل، موجب شده است که روش‌های سنتی و تجربی مبتنی بر مدل‌های خطی یا تحلیل‌های آماری ساده، دقت و کارایی لازم را در پیش‌بینی نرخ نفوذ نداشته باشند [4].

در دهه‌های اخیر، پیشرفت‌های قابل توجه در حوزه هوش مصنوعی و به‌ویژه الگوریتم‌های یادگیری ماشین و یادگیری عمیق، زمینه را برای توسعه مدل‌های پیشرفته و دقیق‌تر در تحلیل داده‌های پیچیده حفاری فراهم کرده است. شبکه‌های عصبی مصنوعی<sup>2</sup> به دلیل توانایی در تقریب توابع غیرخطی و استخراج الگوهای پنهان میان متغیرها، به‌عنوان ابزاری توانمند برای پیش‌بینی نرخ نفوذ مت‌ معرفی شده‌اند [5]. در ادامه این روند، شبکه‌های عصبی بازگشتی<sup>3</sup> با قابلیت مدل‌سازی وابستگی‌های زمانی، و به‌ویژه معماری حافظه بلندمدت-کوتاه‌مدت<sup>4</sup> که محدودیت‌های ساختارهای معمول RNN را برطرف می‌کند، عملکرد به‌مراتب بهتری در تحلیل داده‌های سری زمانی حفاری از خود نشان داده‌اند [6].

با توجه به اهمیت بهینه‌سازی عملکرد حفاری در میدان‌های نفتی شادگان و پیچیدگی‌های ناشی از شرایط زمین‌شناسی و عملیاتی آن، این مطالعه به طراحی و ارزیابی مدل‌های مبتنی بر RNN و LSTM برای پیش‌بینی نرخ نفوذ مت‌ بر اساس داده‌های واقعی میدانی شامل دبی سیال حفاری، فشار پمپ و فشار سازندی می‌پردازد. هدف نهایی این پژوهش، توسعه مدلی داده‌محور و دقیق برای پیش‌بینی نرخ نفوذ مت‌ است که بتواند در راستای افزایش بهره‌وری، کاهش هزینه‌ها و ارتقاء ایمنی عملیات حفاری مورد استفاده مهندسان قرار گیرد. اکثر مطالعات موجود یا از داده‌های شبیه‌سازی شده استفاده کرده‌اند یا تنها بر پارامترهای مکانیکی از جمله وزن روی مت‌ و سرعت دوران مت‌ تمرکز داشته‌اند. در این پژوهش، برای اولین بار در میدان شادگان، داده‌های واقعی شامل فشار سازندی و پارامترهای هیدرولیکی در یک چارچوب LSTM مورد استفاده قرار گرفته است. این ترکیب، امکان مدل‌سازی دقیق‌تری از تعامل پیچیده بین شرایط زمین‌شناسی و عملیاتی را فراهم می‌کند و نوآوری اصلی این مطالعه محسوب می‌شود و از سوی دیگر مدل‌های کلاسیک سری زمانی مانند آریمای پروپت برای داده‌های تک‌متغیره و خطی طراحی شده‌اند و

<sup>1</sup> Rate of Penetration - ROP

<sup>2</sup> Artificial Neural Networks - ANN

<sup>3</sup> Recurrent Neural Networks - RNN

<sup>4</sup> Long Short-Term Memory - LSTM

نمی‌توانند روابط غیرخطی بین چندین پارامتر حفاری را مدل‌سازی کنند. از این رو، در این مطالعه از معماری‌های یادگیری عمیق استفاده شد.

## 2 - مواد و روش‌ها

### 2-1- مجموعه داده‌ها

داده‌های پژوهش حاضر از عملیات حفاری میدانی در یکی از میادین نفتی واقع در جنوب غرب ایران استخراج شده‌اند. این داده‌ها به صورت سری‌های زمانی پیوسته و با نرخ نمونه‌برداری بالا ثبت شده و شامل پارامترهای کلیدی مرتبط با فرآیند حفاری هستند. متغیرهای ورودی شامل پارامترهای عملیاتی (نظیر نرخ تزریق سیال حفاری، فشار پمپ، گشتاور، وزن روی مته، سرعت چرخش مته)، ویژگی‌های زمین‌شناسی-ژئومکانیکی (مقاومت فشاری تک‌محوره سنگ، مدول یانگ، ضریب پواسون) و فشار سازند می‌باشد. همچنین، نرخ نفوذ مته به عنوان متغیر هدف مدل‌سازی در نظر گرفته شده است. پس از حذف داده‌های ناقص، مقادیر پرت و نمونه‌های دارای عدم اعتبار، مجموعه داده نهایی متشکل از بیش از 30000 رکورد معتبر جهت تحلیل‌های آماری و مدل‌سازی مورد استفاده قرار گرفت. داده‌های مورد استفاده از سه چاه عملیاتی در میدان نفتی شادگان استخراج شده‌اند که در محدوده عمقی 1200 تا 3200 متر حفاری شده‌اند. این داده‌ها عمدتاً مربوط به سازندهای آسماری (کربناته) و گچساران (ناهمگن با لایه‌های گچی و نمکی) هستند. برای اطمینان از نمایندگی کافی از شرایط زمین‌شناسی متنوع، داده‌ها به صورت تصادفی تقسیم‌بندی شدند. در این پژوهش داده‌ها مربوط به چاه‌هایی است که با مته‌های الماس مصنوعی<sup>5</sup> با قطر 8/5 اینچ حفاری شده‌اند.

### 2-2- پیش‌پردازش داده‌ها

پیش‌پردازش داده‌های سری زمانی از اهمیت بالایی در بهبود عملکرد مدل‌های یادگیری عمیق برخوردار است. فرآیند آماده‌سازی داده‌ها شامل مراحل زیر بود:

- پاک‌سازی داده‌ها: حذف نقاط پرت بر اساس تحلیل آماری دقیق (شامل معیار انحراف معیار و روش جعبه‌ای) به منظور افزایش دقت مدل‌ها انجام شد. داده‌های گمشده نیز با روش میانگین متحرک تعویض گردید تا از ایجاد ابهام در روند یادگیری جلوگیری شود [7].
- نرمال‌سازی: برای جلوگیری از ناپایداری عددی و تسریع همگرایی الگوریتم‌های آموزش، کلیه ویژگی‌ها با استفاده از تکنیک Min-Max Scaling در بازه [0, 1] مقیاس‌بندی شدند [8].
- تولید توالی‌های زمانی: با توجه به ماهیت توالی‌محور داده‌ها، از روش Sliding Window برای ساخت داده‌های ورودی به شبکه‌های عصبی استفاده شد. طول پنجره‌های زمانی برای مدل RNN برابر با 10 و برای مدل LSTM برابر با 12 نمونه تعیین گردید تا مدل بتواند وابستگی‌های کوتاه و بلندمدت داده‌ها را به شکل مؤثر شناسایی و یادگیری نماید.

### 2-2-1- توسعه مدل‌های شبکه عصبی بازگشتی (RNN) و حافظه بلندمدت - کوتاهمدت (LSTM)


<sup>5</sup> Polycrystalline Diamond Compact

با توجه به خصوصیت سری زمانی و پیچیدگی‌های غیرخطی داده‌های حفاری، از مدل‌های یادگیری عمیق RNN و LSTM به منظور پیش‌بینی دقیق نرخ نفوذ مته استفاده شد. ساختار این مدل‌ها به گونه‌ای طراحی گردید که قابلیت یادگیری روابط پیچیده زمانی و مکانی میان ورودی‌ها و خروجی را داشته باشند [9 و 10].

### 2-2-2- ساختار مدل RNN

مدل RNN شامل یک لایه بازگشتی با 50 نورون و تابع فعال‌سازی  $\tanh$  می‌باشد که توانایی یادگیری وابستگی‌های زمانی کوتاه‌مدت را دارد. به منظور جلوگیری از بیش‌برازش (overfitting)، تکنیک Early Stopping با patience معادل 10 دوره آموزشی به کار گرفته شد. مشخصات فنی مدل به شرح زیر است:

- تابع هزینه MSE
- بهینه‌ساز Adam با نرخ یادگیری 0,001
- تعداد اپک‌ها: 100
- اندازه هر دسته (batch size): 64



شکل 1- ساختار مدل RNN

در شکل شماره 1 تابع A تعدادی شبکه‌ی عصبی است که  $x_t$  را به‌عنوان ورودی می‌گیرد و با توجه به آن خروجی  $h_t$  را به ما می‌دهد. حلقه‌ای هم در شکل می‌بینیم که اطلاعات را از گامی به گام بعدی منتقل می‌کند. به‌طور کلی، شبکه‌ی عصبی بازگشتی (RNN) خیلی فرق چندانی با شبکه‌ی عصبی معمولی ندارد. این شبکه زنجیره‌ای از شبکه‌ای مشابه است که هر یک اطلاعات را به بعدی منتقل می‌کند. رای بهینه‌سازی هایپر پارامترها، از روش جستجوی شبکه‌ای (Grid Search) استفاده شد. مقادیر مختلفی برای طول پنجره (8، 10، 12، 15)، نرخ یادگیری (0/0008، 0/001، 0/0005) و تعداد نورون‌ها (32، 50، 64) آزمایش گردید. بهترین نتایج با طول پنجره 12، نرخ یادگیری 0/0008 و 50 نورون حاصل شد.


با توجه به اینکه داده‌ها پیش از نرمال‌سازی از نقاط پرت پاک‌سازی شده بودند، استفاده از Min-Max Scaling منجر به عملکرد پایداری گردید. روش‌های جایگزین مانند Robust Scaling نیز آزمایش شدند، اما بهبود معناداری در نتایج ایجاد نکردند [2].

### 2-3- ساختار مدل LSTM

برای ارتقاء قابلیت مدل در یادگیری وابستگی‌های بلندمدت سری‌های زمانی، از معماری LSTM استفاده شد. این مدل شامل یک لایه LSTM با 50 واحد حافظه است که گیت‌های ورودی، خروجی و فراموشی بهینه‌شده آن امکان تنظیم جریان اطلاعات ورودی و داخلی را فراهم می‌آورند. مشخصات فنی این مدل عبارت است از:

- توابع فعال‌سازی: سیگموئید در گیت‌ها و ReLU در لایه‌های خروجی

- تابع هزینه MSE:
- بهینه‌ساز: Adam با نرخ یادگیری 0/0008
- تعداد اپک‌ها: 100
- اندازه دسته: 64
- اعمال Early Stopping بر اساس کاهش معیار MSE



شکل 2- ساختار مدل LSTM

همان‌طور که در شکل 2 ملاحظه می‌کنید، شبکه عصبی LSTM از سه درگاه اصلی تشکیل شده است که هر یک از آن‌ها پردازشی را بر روی داده ورودی انجام می‌دهند و در نهایت خروجی حاصل شده به مرحله زمانی بعدی ارسال می‌شود [2].

با توجه به ماهیت سری زمانی داده‌ها، از روش تقسیم‌بندی زمانی (بدون نشت اطلاعات) استفاده شد. استفاده از Cross-Validation تصادفی برای این نوع داده‌ها توصیه نمی‌شود، چرا که ممکن است باعث نشت اطلاعات آینده به گذشته شود. پس بر این اساس برای بهینه‌سازی هایپرپارامترها، از روش جستجوی شبکه‌ای استفاده شد. مقادیر مختلفی برای طول پنجره (8، 10، 12، 15)، نرخ یادگیری (0/001، 0/0008، 0/0005) و تعداد نورون‌ها (32، 50، 64) آزمایش گردید. بهترین نتایج با طول پنجره 12، نرخ یادگیری 0/0008 و 50 نورون حاصل شد.

### 3- معیارهای سنجش عملکرد مدل

برای ارزیابی کمی عملکرد پیش‌بینی مدل‌ها، از معیارهای استاندارد زیر استفاده شد که به عنوان متداول‌ترین شاخص‌ها در تحلیل داده‌های سری زمانی به شمار می‌روند:

◀ ریشه میانگین مربعات خطا (RMSE): که حساسیت بالایی نسبت به بزرگنمایی خطاهای بزرگ دارد و به صورت زیر تعریف می‌شود.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (1)$$

◀ میانگین قدر مطلق خطا (MAE): که میانگین خطاهای مطلق را نشان می‌دهد و به صورت زیر تعریف می‌شود:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (2)$$

ضریب تعیین (R-squared): که درصد واریانس داده‌های واقعی توضیح داده شده توسط مدل را نشان می‌دهد و از رابطه زیر محاسبه می‌شود:

$$R^2 = 1 - \frac{\sum_i^n (y_i - \hat{y}_i)^2}{\sum_i^n (y_i - \bar{y})^2} \quad (3)$$

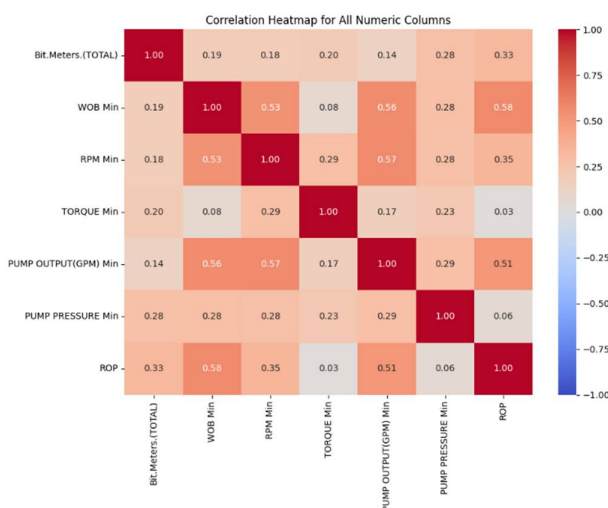
این معیارها به طور کلی نمایانگر توانایی تعمیم‌پذیری مدل‌ها و دقت پیش‌بینی آن‌ها در حوزه داده‌های واقعی می‌باشند [11].

#### 4- تجزیه تجلیل داده‌ها

در این پژوهش، با استفاده از داده‌های حفاری و زمین‌شناسی میدان نفتی شادگان، شبکه عصبی و حافظه طولانی-کوتاه مدت برای پیش‌بینی و بهینه‌سازی نرخ نفوذ مته توسعه و ارزیابی شدند. آنالیزهای مختلف شامل همبستگی متغیرها، آمار توصیفی، تقسیم‌بندی داده‌ها، روش‌های پیش‌بینی و مقایسه عملکرد مدل‌ها انجام شد.

#### 4-1- همبستگی متغیرها

بررسی همبستگی بین متغیرهای ورودی و نرخ نفوذ مته با استفاده از نمودار هیتمپ<sup>6</sup> نشان داده شده است.



شکل 3- همبستگی هیتمپ متغیرهای ورودی و نرخ نفوذ مته

- وزن روی مته با ضریب همبستگی +0/58 و دبی خروجی پمپ<sup>7</sup> با ضریب همبستگی +0/51 دارای همبستگی مثبت قوی با نرخ نفوذ مته هستند.
- سرعت چرخش مته نیز دارای تأثیر قابل توجهی بر نرخ نفوذ مته است که این موضوع با ضریب همبستگی +0/53 نشان داده می‌شود.

<sup>6</sup> Hatmap

<sup>7</sup> PUMP OUTPUT(GPM) Min

- در مقابل، گشتاور<sup>8</sup> با ضریب همبستگی تنها  $+0/03$  و فشار خروجی پمپ<sup>9</sup> با ضریب همبستگی  $+0/06$ ، دارای تأثیر بسیار ضعیف‌تری بر نرخ نفوذ مته می‌باشند.

#### 4-2- آمار توصیفی

داده‌های موجود در این جدول نشان می‌دهند که نرخ نفوذ مته دارای میانگین  $2/60$  متر بر ساعت و انحراف استاندارد  $2/66$  متر بر ساعت است. این موضوع نشان‌دهنده پراکندگی بالای مقادیر نرخ نفوذ مته حول مقدار متوسط است، که می‌تواند ناشی از تغییرات زمین‌شناسی، شرایط عملیاتی یا تغییرات فشار و دما در طول چاه باشد. همچنین، میانگین نرخ نفوذ مته بالاتر از میانه آن است که نشان‌دهنده چولگی مثبت (Right-Skewness) در توزیع داده‌هاست. این نوع توزیع بیانگر وجود مقادیر بسیار بالای نرخ نفوذ مته در برخی از نقاط است که می‌تواند ناشی از شرایط مساعد زمین‌شناسی در لایه‌های نرم‌تر باشد. تحلیل همبستگی نیز نشان داد که نرخ نفوذ مته با دو پارامتر مهم WOB و GPM همبستگی مثبت قابل‌توجهی دارد که در جدول شماره یک قید گردیده است.

جدول 2- تحلیل همبستگی

پارامتر	واحد	میانگین
Bit.Meters (Total)	متر	269/03
PUMP PRESSURE Min	psi	2335/88
WOB Min	klbf	14/89
RPM Min	rpm	108/41
TORQUE Min	lb·ft	2156/44
PUMP OUTPUT (GPM) Min	gpm	517/77
ROP (m/h)	m/h	2/6
Bit.Meters (Total)	متر	269/03

این نتایج برجسته می‌کند که افزایش وزن روی مته و دبی خروجی پمپ می‌تواند منجر به افزایش سرعت نفوذ مته شود. بنابراین، این دو متغیر باید در فرآیند بهینه‌سازی در اولویت اول قرار گیرند. با توجه به تغییرات عمقی، مشاهده می‌شود که با افزایش عمق چاه، مقدار نرخ نفوذ مته به‌طور کلی کاهش می‌یابد. این کاهش می‌تواند ناشی از افزایش فشار سازندی، دما، سختی لایه‌های زیرسطحی و افزایش مقاومت سنگ باشد. بنابراین، این روند نشان‌دهنده وابستگی غیرخطی بین نرخ نفوذ مته و عمق چاه است که در مدل‌سازی باید به‌خوبی در نظر گرفته شود. این جدول پایه‌ی آماری لازم برای انتخاب متغیرهای مؤثر، تشخیص روندها و تعیین نرخ‌های بهینه را فراهم می‌کند. همچنین، وجود داده‌های پرت و توزیع ناهمگن در برخی از متغیرها نیاز به پیش‌پردازش دقیق داده‌ها و استفاده از مدل‌های هوش مصنوعی قوی را در پیش‌بینی دقیق نرخ نفوذ مته برجسته می‌کند. آمار توصیفی مقادیر ورودی و خروجی نشان داد که:

<sup>8</sup> TORQUE Min

<sup>9</sup> PUMP PRESSURE Min

- نرخ نفوذ مته دارای توزیع کجی مثبت و پراکندگی بالا است، که نشان‌دهنده تنوع شرایط زمین‌شناسی و عملیاتی در فرآیند حفاری است.
  - جدول آماری نشان می‌دهد که سرعت دوران مته دارای انحراف استاندارد بالا ( $\sigma=2/66$  m/h) و حداکثر مقدار قابل توجهه ( $18/89$  m/h) است، که نشان‌دهنده تنوع زیاد در عملیات حفاری است.
- همان‌طور که در شکل 3 مشاهده می‌شود، نرخ نفوذ مته با افزایش عمق به‌طور کلی کاهش می‌یابد که ناشی از افزایش سختی سازند، فشار سازندی و دما در عمق‌های بیشتر است. این روند غیرخطی، لزوم مدل‌سازی پیچیده‌تری نسبت به روابط خطی سنتی را تأکید می‌کند.

**جدول 2- خصوصیات آماری پارامترهای ورودی و خروجی برای میدان نفتی شادگان**

پارامتر	میانگین	میانه	انحراف استاندارد	حداقل	حداکثر	Q <sub>1</sub> (25%)	Q <sub>2</sub> (50%)	Q <sub>3</sub> (75%)
Bit.Meters(Total)	269/03	212	247/32	1	1208	212	52	423
PUMP PRESSURE Min	2335/88	2500	586/76	50	3200	2500	2100	2700
WOB Min	14/89	15	9/36	1	50	15	10	20
RPM Min (RPM)	108/41	120	56/97	20	430	120	50	160
TORQUE Min	2156/44	2000	2241/15	1	8000	2000	200	4000
PUMP OUTPUT (GPM) Min	517/77	460	207/21	7	1000	460	400	550
ROP(m/h)	2/6	1/94	2/66	0/17	18/89	1/38	1/94	2/51

#### 3-4- تقسیم‌بندی داده‌ها

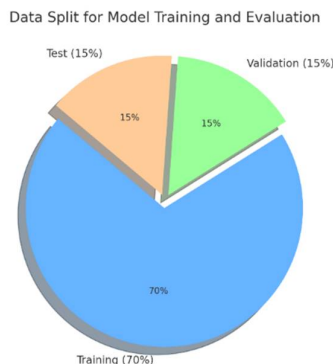
در این پژوهش، از یک مجموعه داده شامل 619 نمونه استخراج‌شده از داده‌های حفاری و زمین‌شناسی چاه میدان نفتی شادگان استفاده شد. برای توسعه و اعتبارسنجی مدل‌های یادگیری عمیق (RNN و LSTM) داده‌ها به سه بخش تقسیم شدند:

- داده‌های آموزش 70<sup>0</sup> درصد جهت یادگیری الگوها و روابط موجود در داده‌ها
  - داده‌های اعتبارسنجی 15<sup>1</sup> درصد برای پایش عملکرد مدل در طول آموزش و جلوگیری از بیش‌برازش (Overfitting)
  - داده‌های آزمون 15<sup>2</sup> درصد برای ارزیابی نهایی دقت و تعمیم‌پذیری مدل
- این تقسیم‌بندی به‌صورت تصادفی انجام شد تا اطمینان حاصل شود که همه زیرمجموعه‌ها نماینده مناسبی از کل داده‌ها هستند و مدل قادر به عملکرد صحیح در شرایط واقعی خواهد بود.
- داده‌ها بر اساس ترتیب زمانی (نه تصادفی) تقسیم شدند تا از نشت اطلاعات جلوگیری شود: 70% داده‌های ابتدایی برای آموزش، 15% بعدی برای اعتبارسنجی و 15% نهایی برای آزمون استفاده گردید.

#### 4-4- نرمال‌سازی داده‌ها

<sup>1</sup> Training 0  
<sup>1</sup> Validation 1  
<sup>1</sup> Test 2

به منظور بهبود همگرایی و کاهش تأثیر مقیاس‌های مختلف متغیرها، تمامی داده‌های ورودی و خروجی تحت فرآیند نرمال‌سازی خطی قرار گرفتند تا مقادیر در بازه  $[-1,+1]$  تبدیل شوند. این مرحله نقش مهمی در افزایش سرعت یادگیری و کاهش خطای شبکه عصبی دارد.



شکل 3- تقسیم‌بندی داده‌ها

#### 4-5- آموزش مدل‌ها و تحلیل عملکرد

مدل‌های RNN و LSTM پس از مرحله پیش‌پردازش داده‌ها، با ساختاری مشابه شامل یک لایه بازگشتی (با 50 نورون)، تابع هزینه میانگین مربعات خطا<sup>13</sup> و الگوریتم بهینه‌سازی Adam با نرخ یادگیری اولیه ثابت آموزش داده شدند. هدف از آموزش، یادگیری الگوهای پنهان و وابستگی‌های زمانی در داده‌های حفاری برای پیش‌بینی نرخ نفوذ مته در گام‌های زمانی آینده بود.

هر دو مدل برای 100 دوره (epoch) آموزش داده شدند و از تکنیک Early Stopping با مقدار patience برابر با 10 استفاده شد تا از بروز پدیده بیش‌برازش<sup>14</sup> جلوگیری شود. در طول فرآیند آموزش، داده‌های مجموعه اعتبارسنجی<sup>15</sup> به‌طور جداگانه برای نظارت بر عملکرد مدل و توقف به‌موقع آموزش به‌کار رفتند.

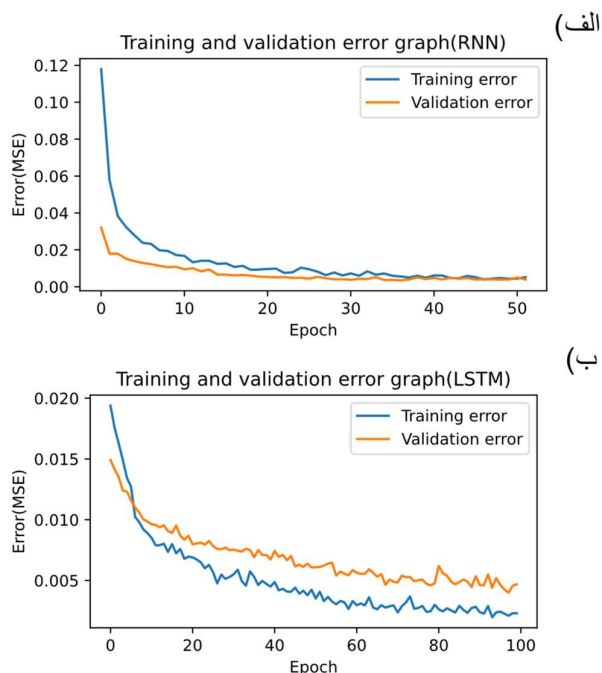
شکل 3 روند کاهش خطای آموزش و اعتبارسنجی<sup>16</sup> را در دو مدل نشان می‌دهد. در مراحل ابتدایی، هر دو مدل کاهش نسبتاً سریع در خطای آموزش از خود نشان دادند. با این حال، مدل LSTM نه‌تنها به سرعت به ناحیه همگرایی رسید، بلکه توانست تا پایان فرآیند آموزش، اختلاف خطای بین مجموعه آموزش و اعتبارسنجی را در سطح بسیار پایینی حفظ کند.

<sup>13</sup> Mean Squared Error; MSE

<sup>14</sup> Overfitting

<sup>15</sup> validation set

<sup>16</sup> Training & Validation Loss



شکل 3- مقایسه میان نتایج روند تغییر خطای آموزش و اعتبارسنجی مدل های RNN و LSTM

در پایان آموزش، مدل LSTM موفق شد مقدار خطای MSE را در مجموعه اعتبارسنجی تا 0/0012 کاهش دهد. این مقدار در مدل RNN برابر با 0/0040 بود که حدوداً سه برابر بیشتر از مقدار خطای LSTM است. این اختلاف به وضوح نشان دهنده توانایی بیشتر مدل LSTM در یادگیری وابستگی های زمانی بلندمدت در داده های سری زمانی حفاری است.

یکی دیگر از شاخص های مهم برای ارزیابی دقت پیش بینی، میانگین قدر مطلق خطا (MAE) بود. مقدار MAE برای مدل LSTM برابر 0/0236 و برای مدل RNN برابر با 0/0438 به دست آمد که باز هم تأییدکننده عملکرد دقیق تر مدل LSTM در بازسازی الگوهای واقعی نرخ نفوذ است. همچنین، ضریب تعیین ( $R^2$ ) که میزان تطابق پیش بینی ها با مقادیر واقعی را نشان می دهد، برای مدل LSTM برابر 0/95 و برای مدل RNN معادل 0/85 بود. این مقادیر نشان می دهد که مدل LSTM توانسته حدود 95% از تغییرات واقعی نرخ نفوذ را به درستی مدل سازی کند، در حالی که مدل RNN تنها حدود 85% از واریانس داده ها را توضیح داده است. مقدار  $patience=10$  بر اساس روند همگرایی منحنی خطا (شکل 3) انتخاب شد، چرا که پس از 10 دور بدون بهبود، مدل به حالت پایدار می رسد. این تفاوت عملکرد به ساختار داخلی دو مدل بازمی گردد. RNN ها به دلیل مشکل ناپایداری گرادیان (Vanishing Gradient) در یادگیری وابستگی های زمانی طولانی دچار ضعف هستند. در مقابل، معماری LSTM با برخورداری از حافظه سلولی و دروازه های ورودی، خروجی و فراموشی<sup>17</sup> قابلیت حفظ اطلاعات کلیدی در بازه های زمانی بلندمدت را دارد. این ساختار به مدل LSTM امکان می دهد تا تغییرات پیچیده و غیرخطی موجود در داده های حفاری مانند نرخ نفوذ، که متأثر از فاکتورهای زمین شناسی، هیدرولیکی و فنی است، با دقت بالاتری بازسازی کند.

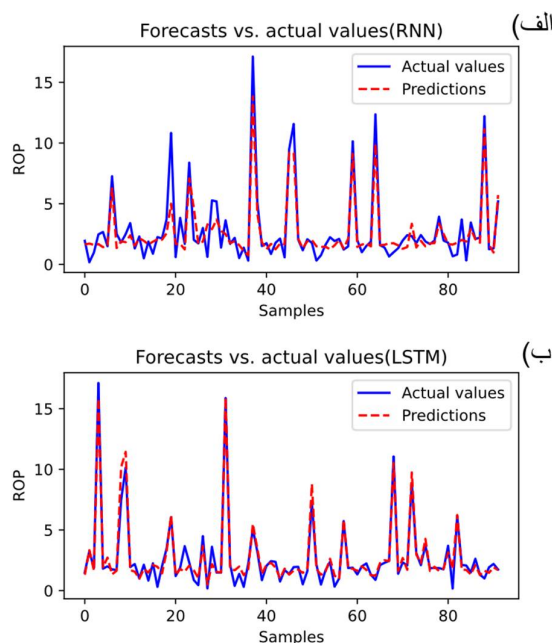
<sup>17</sup> Input, Output & Forget Gates

به طور خلاصه، تحلیل عملکرد کمی و گرافیکی مدل‌ها نشان می‌دهد که LSTM در هر سه معیار ارزیابی MAE، MSE و  $R^2$  عملکرد برتری از خود نشان داده و مدل مناسب‌تری برای تحلیل سری‌های زمانی در عملیات حفاری محسوب می‌شود.

#### 4-6- مقایسه پیش‌بینی با داده‌های واقعی

به منظور ارزیابی کیفی دقت مدل‌های RNN و LSTM در پیش‌بینی نرخ نفوذ مته (ROP)، مقادیر خروجی هر مدل با داده‌های واقعی آزمون مورد مقایسه قرار گرفت. نتایج این مقایسه در شکل 4 نمایش داده شده است. نمودار مذکور شامل دو سری داده (مقادیر واقعی و مقادیر پیش‌بینی شده) در بازه زمانی مشابه است که روند زمانی نرخ نفوذ را برای هر دو مدل به تصویر می‌کشد.

مدل LSTM توانسته است با دقت بالاتری نوسانات نرخ نفوذ را، به ویژه در نقاط دارای تغییرات شدید (پیک‌ها و افت‌ها)، بازسازی کند. در مقابل، مدل RNN در تطابق با این نوسانات عملکرد ضعیف‌تری داشته و در برخی نواحی با خطای بالا نسبت به مقدار واقعی، دچار انحراف شده است. این موضوع بیانگر آن است که ساختار ساده‌تر RNN در یادگیری وابستگی‌های زمانی پیچیده محدودیت داشته و توانایی مدل‌سازی حافظه بلندمدت را در داده‌های غیرخطی ندارد.

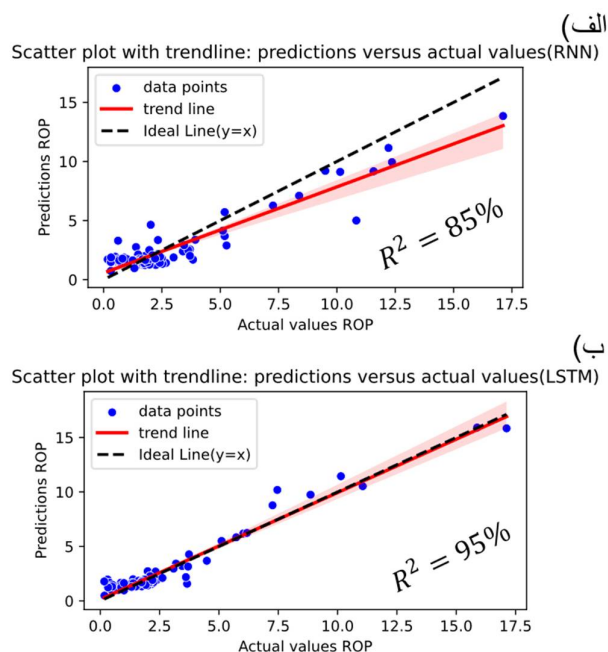


شکل 4- مقایسه روند زمانی نرخ نفوذ واقعی و پیش‌بینی شده توسط مدل‌های RNN و LSTM

در ادامه، به منظور تحلیل دقت پیش‌بینی به صورت عددی، از نمودار پراکندگی<sup>18</sup> میان مقادیر واقعی و مقادیر پیش‌بینی شده توسط هر مدل استفاده شده که در شکل 5 ارائه گردیده است. در این نمودار، خط ایده‌آل ( $x = y$ ) به عنوان مبنای پیش‌بینی کاملاً دقیق در نظر گرفته شده و موقعیت نقاط نسبت به این خط نشان‌دهنده میزان انطباق مدل با داده‌های واقعی است. عدم تقارن کامل در توزیع باقی‌مانده‌ها ناشی از تغییرات ناگهانی در خواص سازند (مانند

<sup>18</sup> Scatter Plot

عبور از لایه‌های گچی یا آهکی) است که رفتار غیرخطی شدیدی ایجاد می‌کند. با این حال، تمرکز بالای خطاها در محدوده  $\pm 1$  نشان‌دهنده دقت قابل قبول مدل است.



شکل 5- نمودار پراکندگی مقادیر واقعی و پیش‌بینی شده نرخ نفوذ مت (ROP) با استفاده از دو مدل LSTM و RNN

در مدل RNN، پراکندگی داده‌ها نسبت به خط ایده‌آل قابل توجه است و به‌ویژه در نواحی با مقادیر بالاتر نرخ نفوذ مت، انحراف‌ها بیشتر می‌گردد. این مسأله نشان‌دهنده کاهش دقت مدل در شرایط خاص زمین‌شناسی یا عملیاتی است.

در مقابل، مدل LSTM توزیع یکنواخت‌تر و متمرکزتری پیرامون خط ایده‌آل دارد. خط رگرسیون (Trend Line) داده‌های پیش‌بینی شده توسط LSTM نیز با شیب نزدیک به واحد و عرض از مبدأ تقریباً صفر، تطابق بالایی مدل با رفتار واقعی را تأیید می‌کند. حاشیه خطا در اطراف خط ایده‌آل نیز به‌وضوح کمتر بوده و بیانگر پایداری و دقت بالایی مدل LSTM در بازسازی ساختار داده‌های آزمون است.

به‌طور کلی، مقایسه کیفی و کمی دو مدل در شکل‌های 4 و 5 نشان می‌دهد که LSTM در پیش‌بینی نرخ نفوذ نه‌تنها از لحاظ معیارهای عددی دقیق‌تر عمل کرده، بلکه از نظر بازسازی روند و انطباق با داده‌های واقعی نیز برتری محسوسی نسبت به RNN دارد. این مسئله به دلیل معماری حافظه‌محور LSTM است که وابستگی‌های زمانی بلندمدت را با اثربخشی بیشتر مدل‌سازی می‌کند و در نتیجه توان پیش‌بینی بالاتری را ارائه می‌دهد.


#### 4-7- مقایسه تحلیل خطا و بررسی باقی‌مانده‌ها

برای ارزیابی عملکرد مدل‌ها در بازسازی دقیق مقادیر نرخ نفوذ مت، تحلیل باقی‌مانده‌ها<sup>19</sup> به‌عنوان یکی از ابزارهای کلیدی در ارزیابی مدل‌های یادگیری عمیق به کار گرفته شد. باقی‌مانده در اینجا به‌صورت تفاضل بین مقدار واقعی


<sup>19</sup> Residual Analysis

نرخ نفوذ متهم واقعی و مقدار پیش‌بینی شده توسط مدل تعریف می‌شود. تحلیل دقیق باقی‌مانده‌ها می‌تواند نشانه‌های احتمالی از وجود خطای سیستماتیک، عدم تعادل در مدل‌سازی یا ضعف در تعمیم‌پذیری مدل را آشکار سازد. شکل 6 توزیع آماری باقی‌مانده‌ها را برای هر دو مدل RNN و LSTM به صورت هیستوگرام چگالی نشان می‌دهد. در مدل RNN، توزیع باقی‌مانده‌ها نسبت به مقدار صفر متقارن نبوده و دارای دم‌های کشیده‌تر در دو سمت است که به وجود خطاهای پرت<sup>20</sup> با مقادیر بزرگ دلالت دارد. این موضوع بیانگر آن است که مدل RNN در برخی نقاط از آزمون، قادر به بازسازی صحیح رفتار واقعی ROP نبوده و دچار خطای پیش‌بینی قابل توجه شده است.

(الف)



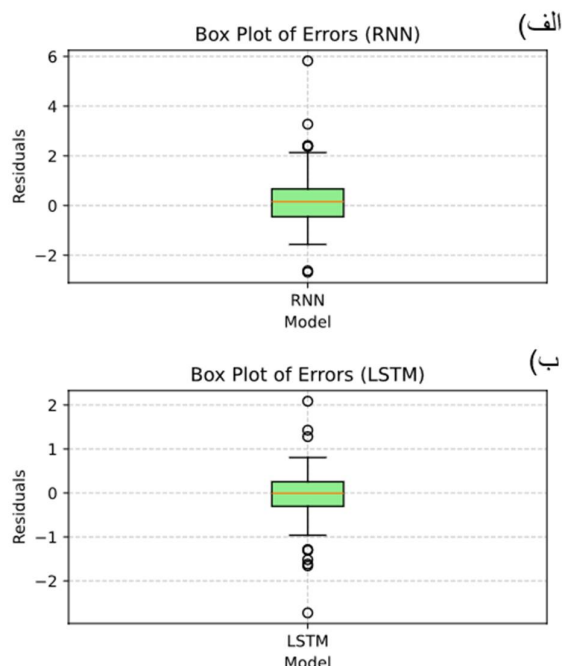
(ب)



شکل 6- (الف): نمودار توزیع باقی‌مانده‌ها (Residuals) در مدل RNN. پراکندگی قابل توجهی در خطاها مشاهده می‌شود و وجود داده‌های پرت در دو سوی توزیع، گویای دقت پایین‌تر مدل نسبت به LSTM است. (ب): نمودار توزیع باقی‌مانده‌ها (Residuals) در مدل LSTM. تمرکز بالا در حوالی صفر و نبود خطاهای شدید، نشان‌دهنده دقت و پایداری بیشتر این مدل در پیش‌بینی نرخ نفوذ متهم است

در مقابل، مدل LSTM توزیع باقی‌مانده‌هایی با چگالی بالا در حوالی صفر و شکل نزدیک به توزیع نرمال از خود نشان داده است. بیش از 80 درصد از باقی‌مانده‌ها در بازه  $\pm 1$  قرار دارند و گستره تغییرات آن نیز محدودتر از مدل RNN است. این ویژگی نشان‌دهنده دقت بالاتر و پایداری پیش‌بینی‌های مدل LSTM در شرایط متغیر عملیاتی و زمین‌شناسی است. جهت تکمیل تحلیل، از نمودار جعبه‌ای برای مقایسه توزیع خطاهای پیش‌بینی بین دو مدل استفاده شد که در شکل 7 نمایش داده شده است. در مدل RNN، باکس پلات نشان‌دهنده پراکندگی وسیع‌تر داده‌ها، فاصله بین چارکی (IQR) بزرگ‌تر، و تعداد بیشتری نقاط پرت در بالا و پایین محدوده نرمال است. این موضوع به ناپایداری عملکرد مدل در پاسخ به داده‌های متنوع اشاره دارد.

<sup>20</sup> Outliers



شکل 7- (الف): نمودار باکس پلات خطاهای مدل RNN میانه خطا نزدیک به صفر است، اما پراکندگی نسبتاً زیاد و وجود چند نقطه پرت شدید در آن قابل مشاهده است، (ب): نمودار باکس پلات خطاهای مدل LSTM پراکندگی خطاها کمتر و توزیع باقی مانده‌ها منسجم‌تر از مدل RNN است که نشان‌دهنده عملکرد پایدارتر مدل می‌باشد

در مقابل، مدل LSTM دارای جعبه‌ای فشرده‌تر با دامنه بین چارکی کوچک‌تر، میانه نزدیک به صفر، و تعداد نقاط پرت بسیار کمتر است. این شاخص‌ها نشان می‌دهند که خطاهای مدل LSTM نه تنها کوچک‌تر بلکه از نظر آماری منسجم‌تر هستند. تفاوت در رفتار باقی مانده‌ها بین دو مدل، نشان‌دهنده نقش معماری مدل در کنترل خطا و تعمیم‌پذیری است. معماری حافظه‌ای LSTM با مکانیزم دروازه‌ای خود، قادر به فیلتر کردن نوسانات غیرمفید و حفظ وابستگی‌های بلندمدت در داده‌های حفاری است. در نتیجه، این مدل عملکرد پایدارتری نسبت به RNN دارد که از ساختار ساده‌تری برخوردار بوده و در مواجهه با داده‌های نویزی یا پیچیده، دچار افت دقت و افزایش خطای پیش‌بینی می‌شود.

#### 8-4- اعتبار سنجی مدل

برای ارزیابی اعتبار مدل پیشنهادی، نتایج آن با یکی از رایج‌ترین مدل‌های تجربی پیش‌بینی نرخ نفوذ مته، یعنی مدل وارن، مقایسه شد. این مدل بر اساس رابطه زیر است.

$$ROP = K \cdot \left(\frac{WOB}{A_b}\right)^a \cdot (RPM)^b \quad (4)$$

که در آن  $a$ ،  $b$ ،  $K$  ضرایب تجربی و  $A_b$  سطح تماس مته است.

با استفاده از داده‌های آزمون، مدل وارن دارای  $R^2 = 0.62$  و  $MAE = 0.081$  بود، در حالی که مدل LSTM مقادیر  $R^2 = 0.95$  و  $MAE = 0.0236$  را نشان داد. این مقایسه تأیید می‌کند که مدل پیشنهادی نه تنها از دقت بالاتری برخوردار است، بلکه قادر به مدل‌سازی روابط غیرخطی پیچیده‌تری است که مدل‌های تجربی ساده نمی‌توانند آن را پوشش

دهند. از نظر قابلیت اجرا، مدل LSTM می‌تواند به راحتی در سکوها‌های نرم‌افزاری مانند متلب، پایتون یا سیستم‌های بلادرنگ حفاری مانند دریل پلان پیاده‌سازی شود. با دریافت داده‌های زنده از سنسورهای سطحی، این مدل می‌تواند به صورت آنی نرخ نفوذ بهینه را پیشنهاد دهد و در تصمیم‌گیری مهندس حفاری مؤثر باشد.

### 5- بهینه‌سازی نرخ نفوذ مته

پس از توسعه و ارزیابی مدل‌های یادگیری عمیق، به‌ویژه مدل حافظه بلندمدت-کوتاه‌مدت، این مدل به‌عنوان ابزار تصمیم‌یار جهت بهینه‌سازی نرخ نفوذ مته مورد استفاده قرار گرفت. هدف از این مرحله، تعیین مقادیر بهینه پارامترهای عملیاتی مؤثر بر نرخ نفوذ، شامل وزن روی مته، سرعت چرخش مته و دبی سیال حفاری، به‌گونه‌ای است که نرخ نفوذ مته در محدوده عملیاتی مجاز به حداکثر مقدار ممکن برسد.

برای این منظور، از مدل آموزش‌دیده LSTM به‌عنوان یک تابع تقریب‌زننده غیرخطی<sup>1</sup> استفاده شد. این مدل قادر است با دقت بالا، نرخ نفوذ متناظر با هر ترکیب از پارامترهای ورودی را پیش‌بینی کند. سپس، یک تحلیل سیستماتیک از فضای ورودی‌ها صورت گرفت تا ترکیبی از پارامترها به‌دست آید که بیشینه نرخ نفوذ را تحت محدودیت‌های عملیاتی حفاری فراهم آورد.

جدول 3 مقادیر بهینه‌ی استخراج‌شده برای پارامترهای وزن روی مته، سرعت چرخش مته و دبی سیال حفاری را ارائه می‌دهد که توسط مدل LSTM بیش‌ترین مقدار نرخ نفوذ مته را در داده‌های مربوط به میدان نفتی شادگان پیش‌بینی می‌کنند. نتایج حاصل از این بهینه‌سازی نشان می‌دهد که افزایش وزن روی مته و نرخ تزریق سیال حفاری، تا حدی که موجب افزایش فشار معکوس یا آسیب به دیواره چاه نشود، اثر مثبتی بر افزایش نرخ نفوذ خواهد داشت. همچنین، افزایش کنترل‌شده سرعت چرخش مته (تا حدود بهینه مشخص‌شده) نیز نقش مهمی در تسهیل فرایند برش سنگ و کاهش زمان حفاری دارد.

با این حال، باید توجه داشت که وابستگی نرخ نفوذ به متغیرهای ورودی، تابعی از نوع سازند، سختی سنگ، فشار سازندی و ویژگی‌های مکانیکی محیط است. به‌عبارت دیگر، افزایش هم‌زمان تمام متغیرها به‌طور خطی منجر به بهبود نرخ نفوذ مته نمی‌شود، بلکه وجود وابستگی‌های غیرخطی و تعامل متقابل پارامترها، لزوم استفاده از مدل‌های پیش‌بینی دقیق مانند LSTM را در تصمیم‌سازی‌های عملیاتی اثبات می‌کند.

از منظر عملیاتی، پیشنهاد می‌شود از مقادیر بهینه به‌دست‌آمده برای تعریف نواحی ایمن عملیاتی<sup>2</sup> برنامه‌ریزی حفاری استفاده شود. مدل ارائه‌شده می‌تواند به‌عنوان یک ماژول در سیستم‌های پشتیبان تصمیم‌گیری حفاری<sup>3</sup> پیاده‌سازی شده و با استفاده از داده‌های زنده چاه، به صورت بلادرنگ نرخ نفوذ بهینه را پیشنهاد دهد.

جدول 3- مقادیر بهینه پارامترهای عملیاتی و نرخ نفوذ پیش‌بینی شده

پارامتر	مقدار بهینه
وزن روی مته	21/5 کیلو پوند فورث
سرعت چرخش مته	138 دور بر دقیقه
دبی سیال حفاری	111 گالن بر دقیقه

<sup>2</sup> Nonlinear Surrogate Model

1

<sup>2</sup> Safe Operating Zones

2

<sup>2</sup> Drilling Advisory Systems

3



مقدار نرخ نفوذ مته پیش‌بینی شده	8/63 متر بر ساعت
انرژی مخصوص مکانیکی	18/2 کلیو ژول بر متر مربع
وضعیت فرسایش مته	قابل قبول

تحلیل این نتایج نشان می‌دهد که تأثیر افزایش پارامترهای عملیاتی بر نرخ نفوذ دارای ماهیت غیرخطی و وابسته به سازند است. به‌ویژه، افزایش بیش‌ازحد وزن روی مته ممکن است منجر به پدیده‌های نامطلوبی نظیر stick-slip یا آسیب به ابزار حفاری گردد، در حالی که دبی بالای سیال، اگر با طراحی مناسب سیستم هیدرولیکی همراه نباشد، می‌تواند منجر به فرسایش چاه یا افت فشار ناگهانی شود. در نتیجه، مدل LSTM نه‌تنها امکان پیش‌بینی دقیق نرخ نفوذ مته را فراهم کرده، بلکه می‌تواند به‌عنوان ابزار پشتیبان در طراحی محدوده بهینه و ایمن عملیاتی<sup>24</sup> به کار رود و نقش مهمی در کاهش زمان حفاری و هزینه‌های عملیاتی ایفا کند.

## 6- نتیجه‌گیری

این پژوهش با هدف پیش‌بینی و بهینه‌سازی نرخ نفوذ مته در سازندهای میدان نفتی شادگان، دو مدل هوش مصنوعی مبتنی بر یادگیری عمیق شبکه عصبی بازگشتی و شبکه حافظه بلندمدت-کوتاه‌مدت را بر اساس داده‌های واقعی میدانی توسعه داد. مهم‌ترین یافته‌های کمی این مطالعه به شرح زیر است.

- مدل LSTM با ضریب تعیین 0/95، میانگین قدر مطلق خطا 0/0236 و ریشه میانگین مربعات خطا 0/0346، عملکردی به‌مراتب بهتر از مدل RNN (ضریب تعیین 0/85 و خطا 0/0438) از خود نشان داد. این نتایج نشان می‌دهد که LSTM توانسته است بیش از 95 درصد از رفتار واقعی نرخ نفوذ را به‌درستی مدل‌سازی کند.
- تحلیل خطاها نشان داد که بیش از 80 درصد از خطاهای پیش‌بینی مدل LSTM در محدوده‌ای کمتر از 0/1 متر بر ساعت قرار دارند و توزیع خطاها نسبت به مدل RNN منسجم‌تر و پایدارتر است.
- با استفاده از مدل LSTM به‌عنوان یک ابزار تصمیم‌یار، مقادیر بهینه پارامترهای عملیاتی شناسایی شدند:
  - وزن روی مته برابر با 21/5 کیلوپوند
  - سرعت چرخش مته برابر با 138 دور در دقیقه
  - دبی سیال حفاری برابر با 111 گالن در دقیقه

این ترکیب منجر به نرخ نفوذ پیش‌بینی شده 8/63 متر بر ساعت می‌شود که بیش از سه برابر میانگین نرخ نفوذ مشاهده‌شده در داده‌های اولیه (2/6 متر بر ساعت) است. همچنین، بررسی‌های تکمیلی نشان داد که این مقادیر بهینه در محدوده ایمن عملیاتی قرار دارند؛ یعنی نه تنها نرخ نفوذ را افزایش می‌دهند، بلکه خطر آسیب به مته یا ناپایداری چاه را نیز به حداقل می‌رسانند. در مجموع، این مطالعه ثابت کرد که ترکیب داده‌های واقعی میدانی (شامل پارامترهای هیدرولیکی و فشار سازندی) با مدل‌های پیشرفته هوش مصنوعی، می‌تواند چارچوبی دقیق و کاربردی برای پیش‌بینی و بهینه‌سازی نرخ نفوذ فراهم کند. این رویکرد می‌تواند در سیستم‌های پشتیبان تصمیم‌گیری حفاری به کار رود و به کاهش چشمگیر زمان و هزینه عملیات منجر شود.

<sup>2</sup> Safe Operating Envelope

این مطالعه دارای محدودیت‌هایی است که از آن جمله می‌توان به استفاده تنها از داده‌های میدان شادگان، عدم استفاده از معماری‌های پیچیده‌تر همچون LSTM و اثر دما و سایر پارامترهای زیرسطحی در مدل اشاره نمود.

## 7- منابع

- [1] A. Ahmed k, S. Rushdi, M. Alsaba and M. F. Dushaishi, "Drilling Rate of Penetration Prediction of High-Angled Wells Using Artificial Neural Networks," *Journal of Energy Resources Technology*, pp. 11, 2019.
- [2] Z.-J. Pei, . X.-Z. Song, H.-T. Wang, Y.-Q. Shi, S.-C. Tian and G.-S. Li, "Interpretation and characterization of rate of penetration intelligent prediction model," *Petroleum Science*, pp. 582-596, 2024.
- [3] E. Brenjkar, E. Biniiaz Delijani and K. Karroubi, "Prediction of penetration rate in drilling operations: a comparative study of three neural network forecast methods," *Journal of Petroleum Exploration and Production Technology*, pp. 805-818, 2021.
- [4] A. Al-AbdulJabbar, S. Elkatatny, A. A. Mahmoud, . T. Moussa, D. Al-Shehri, M. Abughaban and A. Al-Yami, "Prediction of the Rate of Penetration while Drilling Horizontal Carbonate Reservoirs Using the Self-Adaptive Artificial Neural Networks Technique," *MDPI Sustainability*, pp. 19, 2020.
- [5] A. K. Abbas, S. Rushdi, M. Alsaba and M. F. Al Dushaishi, "Drilling Rate of Penetration Prediction of High-Angled Wells Using Artificial Neural Networks," *Journal of Energy Resources Technology*, pp. 11, 2019.
- [6] C. Hegde, H. Daigle, . H. Millwater and K. Gray, "Analysis of rate of penetration (ROP) prediction in drilling using physics-based and data-driven models," *Journal of Petroleum Science and Engineering*, pp. 295-306, 2017.
- [7] O. A. Olafadehan and I. D. Ahaotu, "Comparative Analysis of Machine Learning Algorithms in Predicting Rate of Penetration during Drilling," *Journal of Petroleum & Chemical Engineering*, pp. 16, 2023.
- [8] M. Bataee, S. Irawan and M. Kamyab, "Artificial Neural Network Model For Prediction Of Drilling Rate of Penetration and Optimization of Parameters," *Journal of the Japan Petroleum Institute*, pp. 65-70, 2014.
- [9] O. Hazbeh, . S. Khezerloo-ye Aghdam , H. Ghorbani, N. Mohamadian, M. Ahmadi Alvar and J. Moghadasi, "Comparison of accuracy and computational performance between the machine learning algorithms for rate of penetration in directional drilling well," *Petroleum Research*, pp. 271-282, 2021.
- [10] D. Etesami, M. G. Shirangi and W. Zhang, "A Semiempirical Model for Rate of Penetration with Application to an Offshore Gas Field," *SPE Drilling Completion*, pp. 18, 2020.
- [11] آ. ابراهیم آبادی، "ارائه مدلی برای پیش‌بینی نرخ نفوذ حفاری در میدان نفتی شادگان با استفاده از شبکه عصبی مصنوعی"، نشریه علمی ژئومکانیک نفت، دوره 5، شماره 2، صفحات 1-16، 1401.