

بررسی پدیده خستگی لوله‌های مغزی سیار در چاه‌های نفت

میادین جنوب غرب ایران

احمد رضا عمرانی^{۱*}، خلیل شهبازی^۲، صالح زرگریان^۳، علیرضا شهبازی^۴

دانشگاه صنعت نفت، دانشکده نفت اهواز

ahmadrzaomrani478@gmail.com

چکیده:

واحدهای لوله مغزی سیار با سرعت عملیاتی بالاتری نسبت به دکل‌های حفاری متداول کار می‌کنند، در حالی که هزینه‌های عملیاتی کمتری دارند و از تجهیزات کوچک‌تری استفاده می‌کنند. علاوه بر این، زمان لازم برای برپایی دکل در آن‌ها کمتر بوده و بازدهی کلی بالاتری ارائه می‌دهند. در نتیجه، فناوری لوله مغزی سیار کاربرد گسترده‌ای در صنعت نفت و گاز یافته است. با این حال، لوله‌های مغزی سیار در معرض خرابی ناشی از خستگی قرار دارند که این امر به دلیل تنش‌های خمشی چرخه‌ای است که در قرقره و قوس راهنما، به‌ویژه در شرایط کاری با فشار بالا، تجربه می‌شود. عمر خستگی لوله مغزی سیار را می‌توان از طریق سه روش اصلی ارزیابی کرد: روش فوت رانش، روش آزمایشگاهی و روش نظری. به دلیل محدودیت‌های موجود در دو روش نخست، روش نظری که مبتنی بر به‌کارگیری و توسعه مدل‌های پیش‌بینی عمر خستگی است، اهمیت فراوانی دارد. پژوهش حاضر با هدف برآورد عمر خستگی لوله مغزی سیار با استفاده از روش‌های مدل‌سازی مبتنی بر هوش مصنوعی، انجام شده است. به این منظور، ۲۴۹ مجموعه داده از مطالعات و مقالات منتشرشده، گردآوری شد. سه الگوریتم یادگیری ماشین متمایز (رگرسیون بردار پشتیبان، جنگل تصادفی و CatBoost) برای توسعه مدل‌های پیش‌بینی عمر خستگی لوله مغزی سیار برحسب تعداد گردش‌ها (N) مورد استفاده قرار گرفتند. هدف اصلی، شناسایی مؤثرترین الگوریتم در پیش‌بینی دقیق عمر خستگی بود. نتایج حاصل از ارزیابی سه مدل یادگیری ماشین نشان داد که عملکرد آن‌ها در مجموعه داده‌های آزمون بسیار نزدیک به یکدیگر است. این امر بیانگر همگرایی مدل‌ها در یادگیری الگوی داده‌ها و سازگاری مناسب متغیرهای ورودی با خروجی هدف است. در میان آن‌ها، مدل رگرسیون بردار پشتیبان با داشتن بالاترین مقدار R^2 و کمترین مقادیر میانگین درصد خطای مطلق و ریشه میانگین مربعات خطا، بهترین عملکرد را نشان داد. دو مدل دیگر نیز دقت قابل قبولی از خود نشان دادند.

کلمات کلیدی: لوله مغزی سیار، پیش‌بینی عمر خستگی، مدل‌سازی، یادگیری ماشین، میادین جنوب غرب ایران

آدرس الکترونیکی: ahmadrzaomrani478@gmail.com

^۲ دانشیار دانشکده نفت اهواز

^۳ کارشناس ارشد مهندسی نفت، مخازن هیدروکربوری، دانشگاه صنعت نفت، دانشکده نفت اهواز

^۴ مدیر خدمات فنی شرکت ملی حفاری ایران

Investigating The Coiled Tubing Fatigue Phenomenon in Wells of Iranian Southwestern Oilfields

Abstract:

Coiled tubing (CT) units operate at higher speeds compared to conventional drilling rigs, while offering lower operational costs and more compact equipment. Additionally, they require less time for rig-up and provide greater overall efficiency. Consequently, CT technology has found extensive application in the oil and gas industry. Nevertheless, CT is susceptible to fatigue failure due to cyclic bending stresses experienced on the reel and guide arch, particularly under high-pressure operating conditions. The fatigue life of CT can be evaluated through three main approaches: the running foot method, the laboratory (trip) method, and the theoretical method. However, due to the inherent limitations of the running foot and laboratory methods, the development and application of predictive fatigue life models have become increasingly important. The present study aims to estimate the fatigue life of CT using artificial intelligence (AI)-based modeling techniques. For this purpose, 249 datasets were compiled from previously published studies and research articles. Three distinct machine learning algorithms (Support Vector Regression (SVR), Random Forest, and CatBoost) were employed to develop predictive models for CT fatigue life as a function of the number of trips. The primary objective was to identify the most effective algorithm for accurate fatigue life prediction. The results obtained from evaluating the three machine learning models indicated that their performance on the test dataset was very close to each other. This finding demonstrates the convergence of the models in learning the data patterns and the proper consistency between the input variables and the target output. Among these, the SVR model achieved the highest R^2 and the lowest AAPE and RMSE values, demonstrating superior performance. The other two models also exhibited satisfactory accuracy.

Keywords: Coiled tubing, fatigue life prediction, modeling, machine learning, southwestern Iranian fields

مقدمه:

واحدهای لوله‌های مغزی سیار^۵ با سرعت عملیاتی بالاتری نسبت به دکل‌های حفاری متداول کار می‌کنند، در حالی که هزینه‌های عملیاتی کمتری دارند و از تجهیزات کوچک‌تری استفاده می‌کنند. علاوه بر این، زمان لازم برای برپایی دکل در آن‌ها کمتر بوده و بازدهی کلی بالاتری ارائه می‌دهند. بنابراین، لوله‌های مغزی سیار در عملیات‌های مختلف از جمله تکمیل چاه، نمودارگیری، تعمیراتی، تمیز کردن چاه، سیمان‌کاری، اسیدکاری، تولید و حفاری چاه‌های نفتی کاربرد گسترده‌ای دارند [۴-۱]. استفاده از عمر مفید لوله‌های مغزی سیار تحت تأثیر عوامل مختلفی است، از جمله این عوامل می‌توان به خستگی^۶، افزایش قطر و تغییر شکل لوله‌های مغزی سیار از دایره به بیضی (بیضی شدن)^۷، آسیب‌های مکانیکی (عیب، پیچ‌خوردگی، ناهنجاری سطح)، خوردگی و جوش‌ها اشاره کرد. یکی از عواملی که عمر مفید لوله‌های مغزی سیار را بیشتر از همه محدود می‌کند، عمر خستگی است. عمر خستگی لوله‌های مغزی سیار به دلیل اجتناب‌ناپذیر بودن، عدم اندازه‌گیری با تست‌های غیرمخرب و تأثیر عمده بر عمر مفید لوله‌های مغزی سیار یکی از عوامل حیاتی در طول عمر لوله‌های مغزی سیار است. با وجود هزینه‌های زیاد مرتبط با شکست عمر خستگی، پیش‌بینی عمر خستگی باقی‌مانده یک رشته لوله مغزی سیار برحسب چرخه‌های خمشی یا گردش^۸، قبل از هر عملیات بسیار مهم است. با این حال، در حال حاضر هیچ روش غیر مخربی برای اندازه‌گیری مستقیم عمر خستگی وجود ندارد [۵-۷]. در عوض، مدل‌های خستگی لوله مغزی سیار برای پیش‌بینی عمر خستگی لوله مغزی سیار استفاده می‌شود

⁵ Coiled Tubing (CT) Units

⁶ Fatigue


⁷ Ovality

⁸ Trip

[۵]. در این تحقیق، برای پیش‌بینی تعداد گردش تا شکست (N) از الگوریتم‌های یادگیری ماشین که مبتنی بر مدل‌های پیش‌بینی خستگی است، استفاده شد که این الگوریتم‌ها شامل رگرسیون بردار پشتیبان^۹، جنگل تصادفی^{۱۰} و catboost در این مقاله، بعد از معرفی پدیده خستگی لوله‌های مغزی سیار، الگوریتم‌های رگرسیون بردار پشتیبان، جنگل تصادفی و catboost به همراه آموزش آن‌ها ارائه خواهد شد. جمع‌آوری داده‌ها و انتخاب پارامترها، پیش پردازش داده‌ها در بخش داده‌ها و روش‌ها توضیح داده خواهد شد. در بخش نتایج، خروجی مدل‌های انتخاب شده یادگیری ماشین به همراه مقایسه بین مدل‌ها برای ارزیابی و نتیجه‌گیری، ارائه می‌شود.

توصیف پدیده خستگی لوله‌های مغزی سیار

لوله مغزی سیار با هر بار خم شدن روی قرقره و قوس راهنما و همچنین هنگامی که صاف می‌شود، دچار تغییر شکل پلاستیکی می‌شود. این تغییر شکل پلاستیکی مکرر منجر به تخریب پیشرونده مواد می‌شود، فرآیندی که به عنوان خستگی شناخته می‌شود [۵]. همانطور که در شکل (۱) نشان داده شده است، در طول هر رفت و برگشت به داخل و خارج از چاه، لوله مغزی سیار شش چرخه خمشی را تجربه می‌کند. این چرخه‌ها شامل باز شدن و صاف شدن از قرقره، خم شدن روی قوس راهنما، صاف شدن در انژکتور، خم شدن مجدد روی قوس راهنما، صاف شدن هنگام عبور از قوس راهنما و در نهایت پیچیدن به روی قرقره است [۶].



شکل ۱- محل تغییر شکل‌های پلاستیک لوله‌های مغزی سیار [۶].

در طول عملیات پیمایش در داخل و خارج از چاه، لوله مغزی سیار در حین حرکت بر روی قرقره و قوس راهنما، دچار خمش مکرر می‌شود. این خمش تناوبی باعث ایجاد تنش‌های کششی و فشاری متناوب می‌شود که از مقاومت تسلیم لوله مغزی سیار فراتر می‌رود و منجر به تغییر شکل پلاستیکی و شکست خستگی می‌شود. علاوه بر این، فشار داخلی لوله مغزی سیار باعث ایجاد تنش حلقه‌ای می‌شود و تغییر شکل پلاستیکی را تسریع می‌کند [۸]. ترکیبی از تغییر شکل شدید تناوبی، فشار داخلی بالا و نیروی محوری، خستگی فلز را به عامل اصلی محدود کننده طول عمر عملیاتی لوله مغزی سیار در میدان تبدیل می‌کند.

⁹ Support Vector Regression (SVR)

¹⁰ Random Forest (RF)

[۹، ۱۰]. با هر چرخه خم شدن و صاف شدن، آسیب خستگی در لوله مغزی سیار جمع می‌شود. هنگامی که یک بخش، خستگی بیش از حد را تجربه می‌کند، ترک‌های میکروسکوپی در سطح داخلی لوله ایجاد می‌شود. با گذشت زمان، این ترک‌ها از طریق دیواره لوله مغزی سیار گسترش می‌یابند و در نهایت منجر به شکست ساختاری می‌شوند [۱۱].

توصیف مدل رگرسیون بردار پشتیبان

رگرسیون بردار پشتیبان یک تکنیک رگرسیونی است که مفاهیم ماشین بردار پشتیبان^{۱۱} را برای وظایف رگرسیونی به کار می‌برد. به ویژه زمانی موثر است که رابطه بین ویژگی‌های ورودی و متغیر هدف، غیرخطی باشد. روش رگرسیون بردار پشتیبان با یافتن یک ابر صفحه در فضایی با ابعاد بالاتر کار می‌کند که به بهترین وجه ارتباط بین ویژگی‌های ورودی و مقادیر هدف را نشان می‌دهد. این ابر صفحه برای به حداکثر رساندن حاشیه بین ابر صفحه و نقاط داده طراحی شده است، در حالی که اطمینان می‌دهد که نقاط داده در یک حاشیه خطای از پیش تعریف شده (اپسیلون) باقی می‌مانند. رابطه بین ویژگی‌های ورودی (X) و متغیر هدف ($f(x)$) با استفاده از معادله (۱) مدل شده است.


$$f(x) = W \cdot \phi(x) + b \quad (1)$$

که در آن W و $\phi(x)$ بردارهایی هستند که ریسک منظم شده را به حداقل می‌رساند و b عبارت بایاس است [۱۲].

توصیف مدل جنگل تصادفی

جنگل تصادفی یک تکنیک یادگیری گروهی است که بر اساس مفهوم درخت‌های تصمیم با ترکیب خروجی‌های چندین درخت برای افزایش دقت پیش‌بینی، ایجاد می‌شود. هنگامی که یک ورودی جدید ارائه می‌شود، هر درخت تصمیم در جنگل تصادفی یک مقدار پیش‌بینی شده تولید می‌کند. سپس پیش‌بینی نهایی با میانگین‌گیری (یا میانگین یا میانه) پیش‌بینی‌های انجام شده توسط همه درختان تصمیم، تعیین می‌شود (شکل ۲).

¹¹ Support Vector Machine (SVM)




شکل ۲- ساختار جنگل تصادفی تعمیم یافته [۱۳].

توصیف مدل CatBoost

تقویت گرادیان^{۱۲} یک روش یادگیری گروهی قوی است که برای کارهای رگرسیون و طبقه‌بندی استفاده می‌شود. هدف آن ایجاد یک مدل پیش‌بینی قوی با ترکیب پیش‌بینی‌های یادگیرنده‌های ضعیف چندگانه، معمولاً درخت‌های تصمیم است. این تکنیک با ساخت مکرر یک سری درخت کار می‌کند، جایی که هر درخت جدید خطاها یا باقیمانده‌های درختان قبلی را تصحیح می‌کند. پیش‌بینی نهایی با تجميع پیش‌بینی‌های همه درختان، اغلب از طریق میانگین‌های موزون یا مجموع به دست می‌آید. یک پیاده‌سازی محبوب تقویت گرادیان، ماشین تقویت گرادیان^{۱۳} است، با متغیرهایی مانند XGBoost، LightGBM و CatBoost که به طور گسترده به دلیل کارایی و عملکرد آنها استفاده می‌شود [۱۴]. مدل CatBoost که برای مدیریت موثر ویژگی‌های طبقه‌بندی بدون پیش‌پردازش گسترده طراحی شده است، از تقویت سفارشی استفاده می‌کند و داده‌های دسته‌بندی را به‌طور قوی مدیریت می‌کند (شکل ۳).

¹² Gradient boosting

¹³ Gradient Boosting Machine (GBM)



شکل ۳- ساختار درخت تصمیم تقویت گرادیان تعمیم یافته [۱۳].

روش کار

جمع‌آوری داده‌ها

داده‌های آزمایشگاهی در مطالعات خستگی لوله‌های مغزی سیار بسیار مهم است زیرا تعداد چرخه‌هایی را ارائه می‌کند که لوله مغزی سیار در طول عمر خستگی خود طی می‌کند. این اطلاعات برای مدل‌سازی دقیق خستگی لوله‌های مغزی سیار ضروری است. هدف از این مطالعه محاسبه و پیش‌بینی عمر خستگی لوله‌های مغزی سیار با استفاده از تکنیک‌های یادگیری ماشین است. برای دستیابی به این هدف، داده‌ها از مقالات و منابع پژوهشی مرتبط جمع‌آوری شده است. در این مطالعه از نوع لوله مغزی سیار، نوع سیال، قطر خارجی لوله مغزی سیار، ضخامت لوله مغزی سیار، طول لوله مغزی سیار، شعاع قرقه، شعاع قوس راهنما، فشار داخلی لوله مغزی سیار، ضریب خوردگی عملیاتی، ضریب مقاومت تسلیم، مدول الاستیسیته، نوع جوش، ضریب تمرکز تنش و تعداد گردش تا شکست به عنوان پارامترهای مورد استفاده در نظر گرفته شدند. جدول (۱)، مجموعه داده خستگی لوله‌های مغزی سیار را نشان می‌دهد. در جدول (۱) منظور از تعداد، تعداد خانه حاوی مقدار برای هر پارامتر ورودی است. عدد صفر در ستون نوع جوش، نشان دهنده‌ی این است که در نمونه لوله مغزی سیار استفاده شده در تست خستگی، هیچ جوشی وجود نداشته است [۱، ۱۵-۲۶].

جدول ۱- آمار مجموعه داده خستگی لوله‌های مغزی سیار قبل از پیش پردازش [۱، ۱۵-۲۶].

N [گردش]	K_s [-]	نوع جوش [-]	$E \times 10^{-7}$ [پاسکال]	K_{us} [-]	K_c [-]	$P_i \times 10^{-4}$ [پاسکال]	R_g [متر]	R_r [متر]	L-CT [متر]	t_{CT} [متر]	OD_CT [متر]	نوع سیال [-]	نوع CT [-]	
۲۴۹	۲۴۹	۲۴۹	۰/۰۰۰۰۱۹۵	۹۸	۱۴۹	۰۰۰۲۴۹	۲۴۹	۲۴۹	۱۵۹	۲۴۹	۲۴۹	۲۴۹	۲۴۹	تعداد
۷۲/۲۷	۱	۰	۱۶۵۴۷/۴	۱/۱۵۵	۰/۹۲۵	۲۱۵۱/۹	۱/۶۵۴	۱/۵۷	۲۵/۷۱	۰/۰۰۳۲	۰/۰۴۵	۱/۰۲	۳/۳۷	متوسط

انحراف استاندارد	۲/۵۹	۲/۵۸	۰/۰۱۲	۰/۰۰۰۸	۸۴/۳۷	۰/۶۲	۰/۵۸۷	۱۴۹۳/۴	۰/۱۵۵	۰/۱۹۰	۷۹۹/۸	۰	۱	۵۱/۸۹
حداقل	۰	۰	۰/۰۳۱	۰/۰۰۲۲	۰/۰۶	۰/۹۱	۰/۹۱۴	۱۳۷/۹	۰/۵	۱	۱۵۵۱۳/۲	۰	۱	۱
%۲۵	۱	۱	۰/۰۳۸	۰/۰۰۲۷	۰/۵	۱/۲۱	۱/۲۱۹	۱۰۵۵/۶	۱	۱	۱۵۷۸۹	۰	۱	۳۳
%۵۰	۳	۱	۰/۰۳۸	۰/۰۰۳۴	۱/۵۲	۱/۲۱	۱/۲۷	۱۹۸۰/۹	۱	۱	۱۶۰۶۴/۸	۰	۱	۶۱
%۷۵	۵	۱	۰/۰۶	۰/۰۰۳۴	۳۸/۱	۱/۸۲	۱/۸۲۸	۳۴۴۷/۴	۱	۱/۲۵۰	۱۷۲۳۶/۹	۰	۱	۱۰۶
حداکثر	۱۱	۳	۰/۰۸۸	۰/۰۰۵۶	۶۰/۹۶	۳/۰۴	۳/۰۴۸	۷۵۸۴/۲	۱	۱/۴۷۰	۱۷۵۸۱/۶	۰	۱	۲۷۹

پیش پردازش^{۱۴}

در مطالعه خستگی لوله های مغزی سیار، مجموعه داده های اولیه معمولاً از داده های میدانی یا اندازه گیری های آزمایشگاهی جمع آوری می شوند. با این حال، این مجموعه داده های خام اغلب حاوی مسائلی مانند مقادیر از دست رفته، ناسازگاری ها و نادرستی هستند. بنابراین، پاکسازی داده ها و پیش پردازش، گام های اساسی برای اطمینان از قابلیت اطمینان داده ها هستند. پاکسازی داده ها شامل شناسایی و تصحیح خطاها، آدرس دادن به مقادیر از دست رفته، عادی سازی داده ها، مدیریت نقاط پرت و حل اختلافات ناشی از خطاهای اندازه گیری یا تغییرات در منابع داده است. پیش پردازش، مجموعه داده را بیشتر اصلاح می کند و اطمینان حاصل می کند که برای تجزیه و تحلیل دقیق و توسعه مدل، به درستی قالب بندی و ساختار یافته است. مدیریت مقادیر از دست رفته یک مرحله مهم در پیش پردازش داده است، زیرا بسیاری از الگوریتم های یادگیری ماشینی نمی توانند مجموعه داده های ناقص را به طور موثر پردازش کنند. تکنیک های مختلفی را می توان برای رسیدگی به داده های از دست رفته استفاده کرد، و اطمینان حاصل کرد که مجموعه داده برای تحلیل و مدل سازی مناسب باقی می ماند. یک تکنیک پرکاربرد برای مدیریت داده های از دست رفته، تعیین مقادیر تخمینی برای حفظ یکپارچگی مجموعه داده است.

حذف^{۱۵}

یک رویکرد رایج برای رسیدگی به داده های از دست رفته شامل حذف ردیف ها یا ستون هایی است که حاوی مقادیر ناموجود (خانه های خالی) هستند. در این مطالعه، از روش حذف برای پرداختن به مقادیر از دست رفته استفاده شد، زیرا تأثیر آن بر یکپارچگی داده ها کم بود. مقادیر تعدادی از پارامترهای ورودی (نوع جوش، ضریب تمرکز تنش) در سرتاسر مجموعه داده یکسان بوده است، بنابراین مدل های یادگیری ماشین نمی توانند تأثیر این پارامترها را روی عمر خستگی لوله های مغزی سیار محاسبه کنند، در نتیجه این پارامترها (نوع جوش، ضریب تمرکز تنش) جزو داده های حذف شده بودند. همچنین پارامترهای نوع لوله مغزی سیار و نوع سیال که به ترتیب برای محاسبه K_{us} و K_c استفاده شدند، از مجموعه داده حذف شدند. دلیل حذف این پارامترها (نوع لوله مغزی سیار و نوع سیال) این بود که ضرایب K_{us} و K_c به ترتیب، تأثیر نوع لوله مغزی سیار و نوع سیال

¹⁴ Preprocessing

¹⁵ Deletion

را روی عمر خستگی لوله‌های مغزی سیار نشان می‌دهند و در محاسبات عمر خستگی، تاثیر این دو پارامتر توسط ضرایب K_{us} و K_c در نظر گرفته می‌شود. دلیل دیگر حذف این دو پارامتر، به منظور افزایش دقت مدل‌ها بود.

موارد پرت^{۱۶}

داده‌های پرت می‌توانند خطا ایجاد کنند و بر دقت نتایج تأثیر بگذارند. برای رفع این مشکل، الگوریتم‌های مبتنی بر داده‌ها برای شناسایی و حذف موارد پرت استفاده می‌شوند. در این مطالعه از روش‌های Z -score، فاصله Mahalanobis و winsorization برای بخش‌های مربوطه استفاده شد. اثربخشی این تکنیک‌ها با استفاده از نمودار ستونی و نمودار احتمال در هر مرحله از تجزیه و تحلیل ارزیابی شد.

عادی‌سازی^{۱۷}

عادی‌سازی در یادگیری ماشین به تنظیم یا تبدیل ویژگی‌ها (متغیرها) یک مجموعه داده اشاره دارد، به طوری که آنها در محدوده یا توزیع استاندارد قرار گیرند. این فرآیند می‌تواند با اطمینان از اینکه همه ویژگی‌ها در مقیاس مشابهی هستند، عملکرد مدل را افزایش داده و سرعت همگرایی را افزایش دهد، بنابراین از غلبه بر ویژگی‌های خاص جلوگیری می‌کند. در این تحقیق از روش مقیاس بندی حداقل-حداکثر استفاده شده است که ویژگی‌ها را در محدوده ۰ تا ۱ مقیاس بندی می‌کند (معادله ۲).

$$\frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (2)$$

که X بیانگر مقادیر مجموعه داده، $X_{\min}$ بیانگر حداقل مقادیر مجموعه داده برای هر متغیر و $X_{\max}$ بیانگر حداکثر مقادیر مجموعه داده برای هر متغیر است [۲۷]. پس از تکمیل تمام مراحل ذکر شده قبلی، مجموعه داده مورد مطالعه همانطور که در جدول (۲) نشان داده شده است، سازماندهی شد.

جدول ۲- آمار مجموعه داده خستگی لوله‌های مغزی سیار پس از پیش پردازش.

N	$E \times 10^{-7}$	K_{us}	K_c	$P_{in} \times 10^{-7}$	R_g	R_r	L-CT	t_CT	OD_CT	
[گردش]	[پاسکال]	[-]	[-]	[پاسکال]	[متر]	[متر]	[متر]	[متر]	[متر]	
۲۳۰	۰/۰۰۰۰۲۳۰	۲۳۰	۲۳۰	۰/۰۲۳۰	۲۳۰	۲۳۰	۲۳۰	۲۳۰	۲۳۰	تعداد
۶۹/۴۵	۱۶۶۸۵/۳	۱/۰۶	۰/۹۳	۱۹۷۲/۵	۱/۶	۱/۵۴	۱۳/۵۰۶	۰/۰۰۳	۰/۰۴۴	متوسط
۴۲/۹۷	۷۷۹/۱	۰/۱۲	۰/۱۲	۱۱۱۳/۸	۰/۵۱	۰/۶	۲۲/۰۰۵	۰/۰۰۰۷	۰/۰۱۱	انحراف استاندارد
۱۰	۱۵۵۱۳/۲	۱	۰/۶۶	۳۶۶/۸	۱/۲۱	۱/۰۶	۰/۰۶	۰/۰۰۲۲	۰/۰۳۱	حداقل
۳۴	۱۵۷۸۹	۱	۱	۱۰۵۵/۵	۱/۲۱	۱/۲۱	۰/۵	۰/۰۰۲۷	۰/۰۳۸	%۲۵
۶۴/۵	۱۷۲۳۶/۹	۱	۱	۱۹۸۰/۵	۱/۲۱	۱/۲۱	۱/۹۹	۰/۰۰۳۴	۰/۰۳۸	%۵۰
۱۰۶	۱۷۲۳۶/۹	۱	۱	۳۴۴۷/۳	۱/۸۲	۱/۸۲	۳۰/۴۹	۰/۰۰۳۴	۰/۰۶	%۷۵

¹⁶ Outlier

¹⁷ Normalization

حداکثر	۰/۰۶	۰/۰۰۴۳	۶۰/۹۶	۳/۰۴	۲/۷۹	۳۴۹۹/۷	۱	۱/۳۷	۱۷۵۸۱/۶	۱۴۰
--------	------	--------	-------	------	------	--------	---	------	---------	-----

معیارهای عملکرد^{۱۸}

معیارهای عملکرد برای ارزیابی کیفیت و اثربخشی مدل‌ها و الگوریتم‌های پیش‌بینی استفاده می‌شوند. در این مطالعه از معیارهای مختلفی مانند مربعات خطا^{۱۹}، ریشه میانگین مربعات خطا^{۲۰} و میانگین درصد خطای مطلق^{۲۱} استفاده شد. مربعات خطا، نسبت واریانس در متغیر هدف را که توسط مدل توضیح داده شده است، اندازه‌گیری می‌کند. مقدار مربعات خطا از صفر تا یک متغیر است، جایی که مقدار صفر به این معنی است که مدل هیچ یک از واریانس‌های متغیر وابسته را توضیح نمی‌دهد. مقادیر مربعات خطا بالاتر، برازش مدل بهتری را نشان می‌دهد، که نشان می‌دهد نسبت بیشتری از تغییرپذیری در متغیر وابسته توسط متغیر(های) مستقل توضیح داده می‌شود. مقدار یک نشان می‌دهد که مدل تمام واریانس‌ها را توضیح می‌دهد. مربعات خطا با استفاده از معادله (۳) محاسبه می‌شود.

$$R^2 = 1 - \frac{\sum_{i=1}^n (x_i - y_i)^2}{\sum_{i=1}^n (Y - y_i)^2} \quad (3)$$

که در آن x_i مقدار پیش‌بینی شده y_i مقدار واقعی i و Y میانگین مقادیر واقعی است [۲۸].

ریشه میانگین مربعات خطا، یک متریک پرکاربرد برای ارزیابی میانگین بزرگی خطاها بین مقادیر پیش‌بینی شده و واقعی در یک مجموعه داده است. ریشه میانگین مربعات خطا با استفاده از معادله (۴) محاسبه می‌شود.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - y_i)^2} \quad (4)$$

که در آن x_i مقدار پیش‌بینی شده y_i مقدار واقعی i و n جمع مقادیر است [۲۸].

میانگین درصد خطای مطلق، درصد اختلاف بین مقادیر پیش‌بینی شده و واقعی را ارزیابی می‌کند و آن را به ویژه برای درک بزرگی نسبی خطاهای پیش‌بینی، مفید می‌کند. میانگین درصد خطای مطلق با استفاده از معادله (۵) محاسبه می‌شود.

$$AAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{x_i - y_i}{y_i} \right| \quad (5)$$

که در آن x_i مقدار پیش‌بینی شده y_i مقدار واقعی i و n جمع مقادیر است [۲۸].

نتایج و بحث

در این بخش، نتایج اعمال سه مدل مختلف یادگیری ماشین برای پیش‌بینی عمر خستگی لوله‌های مغزی سیار (N) مورد بحث قرار خواهد گرفت. نتایج این مدل‌ها بینش‌هایی را در مورد دقت و عملکرد هر مدل در پیش‌بینی مقادیر N ارائه می‌دهد. این بخش همچنین نحوه عملکرد هر یک از سه مدل را از نظر معیارهایی مانند مربعات خطا، ریشه میانگین مربعات خطا و میانگین درصد خطای مطلق برای ارزیابی اثربخشی آنها در پیش‌بینی این ویژگی‌ها شرح می‌دهد. این کار پس از اعمال پیش‌پردازش،

¹⁸ Performance Metric

¹⁹ R-square (R^2)


²⁰ Root Mean Square Error (RMSE)

²¹ Average Absolute Percentage Error (AAPE)

مجموعه داده را به ۸۰ درصد برای آموزش^{۲۲} و ۲۰ درصد برای آزمایش^{۲۳} برای ارزیابی الگوریتم‌های ذکر شده یادگیری ماشین، تقسیم می‌کند.

نتایج مدل‌های یادگیری ماشین برای N

شکل (۴) نتایج مدل رگرسیون بردار پشتیبان برای N را نشان می‌دهد که به ترتیب برای داده‌های آموزش و آزمون هستند. برای داده‌های آموزش، مدل رگرسیون بردار پشتیبان با میانگین درصد خطای مطلق برابر با ۰/۱۶ و ریشه میانگین مربعات خطا برابر با ۱۵/۹۹۹ برای پیش‌بینی N، خوب عمل می‌کند. مقدار مربعات خطا برابر با ۰/۸۵۷ است که نشان می‌دهد مدل ۸۵/۷ درصد از واریانس داده‌های N را به دست می‌آورد که انطباق خوبی را نشان می‌دهد. برای داده‌های آزمون، مقدار میانگین درصد خطای مطلق برابر با ۰/۳۰۹، ریشه میانگین مربعات خطا برابر با ۱۷/۱۸۸ و مربعات خطا برابر با ۰/۸۵۵ است.




شکل ۴- سمت راست) مقادیر واقعی N بر حسب مقادیر پیش‌بینی شده برای داده‌های آموزش در مدل رگرسیون بردار پشتیبان. سمت چپ) مقادیر واقعی N بر حسب مقادیر پیش‌بینی شده برای داده‌های آزمون در مدل رگرسیون بردار پشتیبان.

شکل (۵) نتایج مدل جنگل تصادفی برای N را نشان می‌دهد که به ترتیب برای داده‌های آموزش و آزمون هستند. در مجموعه داده آموزش، مدل جنگل تصادفی نیز با مقدار میانگین درصد خطای مطلق برابر با ۰/۱۹۴ و ریشه میانگین مربعات خطا برابر با ۱۳/۸۶۱ عملکرد خوبی دارد. مربعات خطا با مقدار ۰/۸۹۳ نشان‌دهنده انطباق بالا با نتایج واقعی است. در مجموعه داده آزمون، مدل جنگل تصادفی برای پیش‌بینی N، مقدار میانگین درصد خطای مطلق برابر با ۰/۳۷ را دارد. ریشه میانگین مربعات خطا برابر با ۱۷/۳۹۶ است که مقدار آن پایین است و نشان‌دهنده دقت بالای پیش‌بینی است. مقدار مربعات خطا برابر با ۰/۸۳۳ است که نشان‌دهنده واریانس ۸۳/۳ درصدی از داده‌های N است. این مقدار مربعات خطا، نشان‌دهنده انطباق خوبی است و عملکرد مناسبی برای مدل جنگل تصادفی است.


²² Training

²³ Test



شکل ۵- سمت راست) مقادیر واقعی N بر حسب مقادیر پیش‌بینی شده برای داده‌های آموزش در مدل جنگل تصادفی. سمت چپ) مقادیر واقعی N بر حسب مقادیر پیش‌بینی شده برای داده‌های آزمون در مدل جنگل تصادفی.

نتایج مدل CatBoost در پیش‌بینی N ، برای داده‌های آموزش و آزمون به ترتیب در شکل‌های (۶) آمده است. مدل CatBoost در مجموعه داده آموزش، عملکرد خیلی خوبی را نشان می‌دهد. مدل CatBoost، پایین‌ترین مقادیر میانگین درصد خطای مطلق و ریشه میانگین مربعات خطا را در بین همه‌ی مدل‌ها دارد که به ترتیب برابر با 0.124 و 11.439 هستند. مربعات خطا با مقدار 0.927 ، نشان‌دهنده‌ی انطباق برجسته با مقادیر واقعی است. مدل CatBoost، در مجموعه داده آزمون با میانگین درصد خطای مطلق 0.313 عملکرد مناسبی را نشان می‌دهد. مقدار ریشه میانگین مربعات خطا برابر با 17.723 است که مقدار پایینی است و نشان‌دهنده‌ی پیش‌بینی خوبی است. مقدار مربعات خطا با 0.845 نشان از واریانس 84.5 درصدی با مقادیر واقعی N است و انطباق خوبی را نشان می‌دهد.



شکل ۶- سمت راست) مقادیر واقعی N بر حسب مقادیر پیش‌بینی شده برای داده‌های آموزش در مدل رگرسیون بردار پشتیبان. سمت چپ) مقادیر واقعی N بر حسب مقادیر پیش‌بینی شده برای داده‌های آزمون در مدل رگرسیون بردار پشتیبان.

آنالیز کلی نتایج پیش‌بینی N

جدول (۳) معیارهای عملکرد را برای مدل‌های مختلف یادگیری ماشین آموزش دیده و آزمایش شده برای داده‌های N ارائه می‌دهد. این معیارها شامل مربعات خطا، ریشه میانگین مربعات خطا و میانگین درصد خطای مطلق است. در میان مدل‌ها،


CatBoost به عنوان بهترین عملکرد در هر سه معیار برای داده‌های آموزش ظاهر می‌شود. برای میانگین درصد خطای مطلق، مدل CatBoost کمترین خطا را با مقدار ۰/۱۲۴ نشان می‌دهد. از نظر ریشه میانگین مربعات خطا نیز، مدل CatBoost برتر است با مقدار ۱۱/۴۳۹ که کوچکترین مقدار خطا را نشان می‌دهد. با توجه به مربعات خطا، مدل CatBoost بالاترین سطح واریانس را برای مقدار مربعات خطا با ۰/۹۲۷ نشان می‌دهد. این نتایج در مجموع نشان می‌دهد که مدل CatBoost موثرترین مدل از نظر دقت بر روی داده‌های آموزش N است. بهترین مدل در داده‌های آزمون برای پیش‌بینی N از نظر میانگین درصد خطای مطلق، ریشه میانگین مربعات خطا و مربعات خطا، مدل رگرسیون بردار پشتیبان است که با میانگین درصد خطای مطلق برابر با ۰/۳۰۹، ریشه میانگین مربعات خطا برابر با ۱۷/۱۸۸ و مربعات خطا برابر با ۰/۸۵۵ برجسته شده است. به طور کلی، هر سه مدل عملکردی بسیار نزدیک دارند. اختلاف بین معیارها (مربعات خطا، ریشه میانگین مربعات خطا و میانگین درصد خطای مطلق) تقریباً ناچیز است که نشان‌دهنده‌ی همگرایی مدل‌ها در یادگیری الگوی داده‌ها است. این مسئله می‌تواند به یکنواخت بودن داده‌ها یا هم‌پوشانی زیاد میان ویژگی‌ها اشاره کند. با این حال، مدل رگرسیون بردار پشتیبان از نظر پایداری و تعمیم‌پذیری بهترین مدل محسوب می‌شود و اختلاف بسیار کمی بین خطای آموزش و آزمون دارد. Catboost آموزش دقیق‌تر است، ولی اندکی بیش‌برازش^{۲۴} دارد. مدل جنگل تصادفی تعادلی بین این دو ایجاد می‌کند و عملکرد میانگین دارد. در نتیجه، از دیدگاه علمی می‌توان گفت که هم‌گرایی نتایج سه مدل نشان‌دهنده‌ی سازگاری داده‌ها و اعتبار روش مدل‌سازی است.

جدول 3- معیارهای عملکرد برای مدل‌های مختلف آموزش دیده و آزمایش شده بر روی متغیر هدف (N).


مدل‌ها	آموزش N			آزمون N		
	میانگین درصد خطای مطلق	ریشه میانگین مربعات خطا	مربعات خطا	میانگین درصد خطای مطلق	ریشه میانگین مربعات خطا	مربعات خطا
SVR	۰/۱۶	۱۵/۹۹۹	۰/۸۵۷	۰/۳۰۹	۱۷/۱۸۸	۰/۸۵۵
Random forest	۰/۱۹۴	۱۳/۸۶۱	۰/۸۹۳	۰/۳۷	۱۷/۳۹۶	۰/۸۳۳
CatBoost	۰/۱۲۴	۱۱/۴۳۹	۰/۹۲۷	۰/۳۱۳	۱۷/۷۲۳	۰/۸۴۵

شکل‌های (۷)، (۸) و (۹)، نمودارهای ستونی میانگین درصد خطای مطلق، ریشه میانگین مربعات خطا و مربعات خطای مدل‌های مختلف را برای مجموعه داده‌ی آموزش نشان می‌دهند.


²⁴ Overfitting



شکل ۷- نتایج نمودار ستونی میانگین درصد خطای مطلق مدل‌ها در پیش‌بینی N برای داده‌های آزمایش




شکل ۸- نتایج نمودار ریشه میانگین مربعات خطای مدل‌ها در پیش‌بینی N برای داده‌های آزمایش




شکل ۹- نتایج نمودار ستونی مربعات خطای مدل‌ها در پیش‌بینی N برای داده‌های آزمایش


شکل‌های (۱۰)، (۱۱) و (۱۲)، نمودارهای ستونی میانگین درصد خطای مطلق، ریشه میانگین مربعات خطا و مربعات خطای مدل‌های مختلف را برای مجموعه داده‌ی آزمون نشان می‌دهند.



شکل ۱۰- نتایج نمودار ستونی میانگین درصد خطای مطلق مدل‌ها در پیش‌بینی N برای داده‌های آزمون



شکل ۱۱- نتایج نمودار ستونی ریشه میانگین مربعات خطای مدل‌ها در پیش‌بینی N برای داده‌های آزمون



شکل ۱۲- نتایج نمودار ستونی مربعیات خطای مدل‌ها در پیش‌بینی N برای داده‌های آزمون

نتیجه‌گیری

پیش‌بینی عمر خستگی لوله مغزی سیار به دلیل کاربرد گسترده آن در صنعت نفت و گاز و همچنین به دلیل اینکه خرابی بر اثر خستگی لوله مغزی سیار اجتناب ناپذیر است و ناگهانی رخ می‌دهد، از اهمیت بالایی برخوردار است. این پژوهش با بهره‌گیری از ۲۴۹ مجموعه داده گردآوری شده از مطالعات و مقالات منتشر شده، بر پیش‌بینی شکست خستگی لوله‌های مغزی سیار از طریق برآورد تعداد گردش‌ها (N) تمرکز دارد. هدف از این پژوهش، توسعه و ارزیابی مدل‌های یادگیری ماشین به‌منظور پیش‌بینی دقیق‌تر عمر خستگی لوله مغزی سیار و بهبود قابلیت اطمینان عملیات حفاری و خدمات چاه بود. داده‌های ورودی به مدل پس از مراحل پیش‌پردازش، شامل قطر خارجی لوله مغزی سیار، ضخامت لوله مغزی سیار، طول لوله مغزی سیار، شعاع قرقره، شعاع قوس راهنما، فشار داخلی لوله مغزی سیار، ضریب خوردگی عملیاتی، ضریب مقاومت تسلیم، مدول الاستیسیته و تعداد گردش تا شکست بودند. به این منظور، سه الگوریتم یادگیری ماشین مختلف برای توسعه مدل‌های پیش‌بینی به کار گرفته شده‌اند. هدف مدل‌ها شناسایی موثرترین رویکرد از طریق تحلیل تطبیقی بود. به این منظور، معیارهای عملکرد مورد تجزیه و تحلیل قرار گرفت تا بهترین مدل پیش‌بینی شناسایی شود. نتایج به دست آمده از این تحقیق عبارتند از:

- ۱- در طول مرحله آموزش، مدل CatBoost بهترین عملکرد را نسبت به مدل‌های دیگر برای پیش‌بینی N نشان می‌دهد که به پایین‌ترین میانگین درصد خطای مطلق و ریشه میانگین مربعات خطا، همراه با بالاترین مقدار مربعات خطا دست می‌یابد.
- ۲- در داده‌های تست، مدل رگرسیون بردار پشتیبان برای پیش‌بینی N برتری دارد و به پایین‌ترین میانگین درصد خطای مطلق، ریشه میانگین مربعات خطا و مربعات خطای خوب می‌رسد.
- ۳- به طور کلی، با در نظر گرفتن داده‌های آموزشی و آزمایشی، مدل رگرسیون بردار پشتیبان بهترین مدل برای پیش‌بینی N است. مدل‌های CatBoost و جنگل تصادفی نیز عملکرد معقولی را هم در مجموعه داده‌های آموزش و هم در مجموعه داده آزمون ارائه می‌دهند.
- ۴- نتایج حاصل از ارزیابی سه مدل یادگیری ماشین شامل رگرسیون بردار پشتیبان، جنگل تصادفی و CatBoost نشان داد که عملکرد آن‌ها در مجموعه داده‌های آزمون بسیار نزدیک به یکدیگر است؛ به‌طوری‌که مقادیر معیارهای عملکرد (میانگین درصد خطای مطلق، ریشه میانگین مربعات خطا و مربعات خطا) تنها اختلافی جزئی در حدود چند صدم دارند. این امر بیانگر همگرایی مدل‌ها در یادگیری الگوی داده‌ها و سازگاری مناسب متغیرهای ورودی با خروجی هدف است.
- ۵- مدل‌سازی دقیق، قابلیت‌های پیش‌بینی را افزایش می‌دهد و امکان تشخیص زودهنگام خرابی‌های احتمالی لوله مغزی سیار و بهینه‌سازی عملکرد آن، برای خدمات ایمن و کارآمد را فراهم می‌کند.

فهرست واژه‌ها

علائم انگلیسی			
AAPE	Average Absolute Percentage Error, میانگین درصد خطای مطلق	b	عبارت بایاس، Bias Term
CT	Coiled Tubing, لوله مغزی سیار	E	پاسکال، مدول ینگ، Young's Module

GBM	ماشین گرادیان تقویت, Gradient Boosting Machine	K_c	ضریب خوردگی عملیاتی, Operation Corrosion Factor,
K_s	ضریب تمرکز تنش, Stress Concentration Factor	K_{us}	ضریب مقاومت تسلیم, Ultimate Compensation Factor,
L-CT	متر, طول لوله مغزی سیار, Length of Coiled Tubing	MSE	میانگین مربعات خطا, Mean Square Error,
N	تعداد گردش تا شکست لوله مغزی سیار, Trip	n	جمع مقادیر, Sum values,
OD-CT	قطر خارجی لوله مغزی سیار, Outer Diameter of Coiled Tubing	P_{in}	پاسکال, فشار داخلی, Inside Pressure,
R_r	متر, شعاع قرقره, Reel Radius	R_g	متر, شعاع قوس راهنما, Goosneck Radius,
RF	جنگل تصادفی, Random Forest	R^2	مربعات خطا, R-square,
RMSE	ریشه میانگین مربعات خطا, Root Mean Square Error	SVR	رگرسیون بردار پشتیبان, Support Vector Regression,
SVM	ماشین بردار پشتیبان, Support Vector Machine	t-CT	ضخامت لوله مغزی سیار, متر, Thickness of Coiled Tubing,
X_{max}	حداکثر مقادیر مجموعه داده, maximum values of dataset	X_{min}	حداقل مقادیر مجموعه داده, Minimum Values of Dataset,
X	مقادیر مجموعه داده, Values of Dataset	x_i	مقدار پیش‌بینی شده i, Predicted ith value,
Y	متوسط مقادیر پیش‌بینی شده, Mean of Actual Values	y_i	مقدار واقعی i, Actual ith value,

مراجع

- [۱] K. Newman and D. Newburn, "Coiled-tubing-life modeling," in SPE Annual Technical Conference and Exhibition?, 1991: SPE, pp. SPE-22820-MS. <https://doi.org/10.2118/22820-MS>
- [۲] Y. Li, X.-L. Gao, L. Ni, Q. Hu, and Y. Xin, "Fatigue of coiled tubing and its influencing factors: a comparative study," in ASME International Mechanical Engineering Congress and Exposition, 2016, vol. 50633: American Society of Mechanical Engineers, p. V009T12A081. <https://doi.org/10.1115/IMECE2016-65972>
- [۳] Y. F. Ji, H. Zhang, Q. Q. Duan, and Y. B. Cao, "Research on the analysis of coiled tubing fatigue life," Applied Mechanics and Materials, vol. 66, pp. 1173-1178, 2011. <https://doi.org/10.4028/www.scientific.net/AMM.66-68.1173>
- [۴] H. He, "Development of coiled tubing technique and equipment," China Petroleum Machinery, vol. 34, no. 1, pp. 1-6, 2006.
- [۵] R. API, "5C7 (Recommended Practice for Coiled Tubing Operations in Oil and Gas Well Services)," ed: Dec, 1996.
- [۶] L. CTES, "Coiled tubing manual," Conroe, Texas, 2005.
- [۷] K. Shahbazi, Underbalanced Drilling. Ahwaz Faculty of Petroleum Engineering, 2020.
- [۸] J. Wu, "Coiled tubing working life prediction," in SPE Oklahoma City Oil and Gas Symposium/Production and Operations Symposium, 1995: SPE, pp. SPE-29461-MS. <https://doi.org/10.2118/29461-MS>
- [۹] S. M. Tipton, "Coiled-tubing deformation mechanics: Diametral growth and elongation," SPE production & facilities, vol. 13, no. 03, pp. ۱۹۹۸, ۱۹۹-۱۹۴. <https://doi.org/10.2118/50966-PA>
- [۱۰] R. Rolovic, Plasticity Modeling of Multiaxial Cyclic Ratcheting in Coiled Tubing. The University of Tulsa, 1997.

- [١١] S. M. Tipton and I. Document, "The Achilles Fatigue Model," CTES LP User Technical Note, 1999.
- [١٢] I. Cohen, Y. Huang, J. Chen, J. Benesty, J. Benesty, J. Chen, Y. Huang, and I. Cohen, "Pearson correlation coefficient," Noise reduction in speech processing, pp. 1-4, 2009. https://doi.org/10.1007/978-3-642-00296-0_5
- [١٣] H. Tao, S. Salih, A. Y. Oudah, S. Abba, A. M. S. Ameen, S. M. Awadh, O. A. Alawi, R. R. Mostafa, U. P. Surendran, and Z. M. Yaseen, "Development of new computational machine learning models for longitudinal dispersion coefficient determination: case study of natural streams, United States," Environmental Science and Pollution Research, vol. 29 ,no. 24, pp. 35841-35861, 2022. <https://doi.org/10.1007/s11356-022-18554-y>
- [١٤] T. Chen and C. Guestrin, "Xgboost: A scalable tree boosting system," in Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining, 2016, pp. 785-794. <https://doi.org/10.1145/2939672.2939785>
- [١٥] F. Behenna, D. Myrick, R. Stanley, S. Tipton, and W. Hammond, "Field validation of a coiled tubing fatigue model," in SPE/ICoTA Well Intervention Conference and Exhibition, 2003: SPE, pp. SPE-81726-MS. <https://doi.org/10.2118/81726-MS>
- [١٦] V. Avakov, J. Foster, and E. Smith, "Coiled tubing life prediction," in Offshore technology conference, 1993: OTC, pp. OTC-7325-MS. <https://doi.org/10.4043/7325-MS>
- [١٧] W. Sisak and D. Crawford, "The fatigue life of coiled tubing," in SPE/IADC Drilling Conference and Exhibition, 1994: SPE, pp. SPE-27437-MS. <https://doi.org/10.2118/27437-MS>
- [١٨] K. Newman and P. Brown, "Development of a standard coiled-tubing fatigue test," in SPE Annual Technical Conference and Exhibition?, 1993: SPE, pp. SPE-26539-MS. <https://doi.org/10.2118/26539-MS>
- [١٩] V. A. Avakov and J. Martin, "Large Coiled Tubing Fatigue Life," in SPE/ICoTA Well Intervention Conference and Exhibition : ١٩٩٧, SPE, pp. SPE-38407-MS. <https://doi.org/10.2118/38407-MS>
- [٢٠] T. Urayama, T. Yonezawa, M. Hamada, M. Sugino, H. Takabe, and A. Ikeda, "Research and development of advanced coiled-tubing construction and performance," SPE Drilling & Completion, vol. 16, no. 02, pp. 83-90, 2001. <https://doi.org/10.2118/72062-PA>
- [٢١] N. Perozo, C. Paz, C. Teodoriu, J. Holzmann, O. Grijalva, and J. Oppelt, "A Novel Testing Facility for Coiled Tubing Fatigue Evaluation Under Deep Drilling Conditions," in SPE Western Regional Meeting, 2016: SPE, pp. SPE-180483-MS. <https://doi.org/10.2118/180483-MS>
- [٢٢] G. Luebke and S. M. Tipton, "The Fatigue Behavior of Concentric Coiled Tubing," in SPE/ICoTA Well Intervention Conference and Exhibition, 2018: SPE, p. D021S007R004. <https://doi.org/10.2118/189917-MS>
- [٢٣] L. Shaohu, Z. Hao, Z. Hong, L. Yang, and W. Zhen, "Experimental and numerical simulation study on fatigue life of coiled tubing with typical defects," Journal of Petroleum Science and Engineering, vol. 198, p. 108212, 2021. <https://doi.org/10.1016/j.petrol.2020.108212>
- [٢٤] P. Bian, L. Liu, F. Luo, Y. Luo, and J. Zhao, "Fatigue Life Calculation of Tubing for In Situ Drilling Rig," Highlights in Science, Engineering and Technology, vol. 25, pp. 210-216, 2022.
- [٢٥] M. Valdez, C. Morales, R. Rolovic, and B. Reichert, "The development of high-strength coiled tubing with improved fatigue performance and H2S resistance," in SPE/ICoTA Well Intervention Conference and Exhibition, 2015: SPE, p. D011S004R004. <https://doi.org/10.2118/173639-MS>
- [٢٦] J. Liu, Q. Wang, W. Zhang, Z. Zhou, W. Hu, and Y. Wang, "Fatigue Life Analysis of Coiled Tubing in Deep Well Jet Plugging Removal," World Journal of Engineering and Technology, vol. 11, no. 1 ,pp. 48-54, 2022. <https://doi.org/10.4236/wjet.2023.111005>

- [۲۷] T. Ore and D. Gao, "Prediction of reservoir brittleness from geophysical logs using machine learning algorithms," *Computers & Geosciences*, vol. 171, p. 105266, 2023. <https://doi.org/10.1016/j.cageo.2022.105266>
- [۲۸] D. Chicco, M. J. Warrens, and G. Jurman, "The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation," *Peerj computer science*, vol. 7, p. e623, 2021. <https://doi.org/10.7717/peerj-cs.623>

Accepted paper