



فصلنامه علوم محیطی، دوره بیست و یکم، شماره ۱، بهار ۱۴۰۲

۱۶۳-۱۸۰

مقاله پژوهشی

ارزیابی آلودگی فلزات سنگین و مواد آلی کنده‌ها و گل حفاری با استفاده از تکنیک الگوریتم رگرسیون یادگیری حدی هوش مصنوعی در یکی از میادین نفتی جنوب ایران

سعید احدی^۱، اندیشه علی مرادی^۱، حمید سرخیل^{۲*}، مهیار کلهر محمدی^۳ و مهدی فتحی^۱

^۱ گروه مهندسی معدن، دانشگاه بین المللی امام خمینی (ره)، قزوین، ایران
^۲ گروه زمین شناسی کاربردی، دانشکده علوم زمین، دانشگاه خوارزمی، تهران، ایران
^۳ واحد مدیریت پسماند حفاری، شرکت حفاری سیالات پارس، ایران

تاریخ دریافت: ۱۳۹۹/۱۱/۱۱ تاریخ پذیرش: ۱۴۰۰/۴/۲۵

احدی، س.، ا. علی مرادی، ح. سرخیل، م. کلهر محمدی و م. فتحی. ۱۴۰۲. ارزیابی آلودگی فلزات سنگین و مواد آلی کنده‌ها و گل حفاری با استفاده از تکنیک الگوریتم رگرسیون یادگیری حدی هوش مصنوعی در یکی از میادین نفتی جنوب ایران. فصلنامه علوم محیطی. ۲۱(۱): ۱۶۳-۱۸۰.

سابقه و هدف: فرآیند استخراج و بهره برداری از منابع نفت و گاز به چرخه تولید، ارسال و بازیافت گل حفاری یا سیال حفاری نیاز دارد، بنابراین رسیدن به ترکیب مناسب گل حفاری و بازیافت مجدد آن، به عنوان یک امر مهم و اساسی در صنعت نفت و محیط زیست به شمار می‌رود. به طوری که مشخص نمودن میزان آلودگی فلزات سنگین و مواد آلی موجود در گل حفاری و کنده‌های حفاری به صورت غیر مستقیم می‌تواند حائز اهمیت باشد.

مواد و روش‌ها: در این تحقیق سعی شده است که میزان آلودگی کنده‌های حفاری، با وجود پارامترهای سازندی در ۱۰ چاه نفتی حفاری شده در اعماق مختلف (۶۶ دسته داده)، به کمک رگرسیون یادگیری حدی شبکه عصبی مصنوعی، تخمین زده شود.

نتایج و بحث: تعداد ۶۰ دسته داده از داده‌های تهیه شده به منظور تخمین میزان تغییر در غلظت فلزات سنگین، هیدروکربن‌های آروماتیک چند حلقه‌ای در فرآیند یادگیری و آزمون دخالت داده شده‌اند و ۶ دسته داده دیگر مربوط به یک چاه که به طور تصادفی انتخاب شده و در فرآیند اعتبارسنجی شبکه عصبی مصنوعی استفاده شده‌اند. الگوریتم رگرسیون یادگیری حدی برای ۱۰ عنصر سنگین و ۱۰ ترکیب آروماتیک آلوده کننده‌ی کنده و گل حفاری بر روی دو سری داده‌ی مختلف در یک منطقه‌ی حفاری در یکی از میادین نفتی جنوب ایران مورد ارزیابی قرار گرفت.

* Corresponding Author: *Email Address.* sarkheil@khu.ac.ir

<http://dx.doi.org/10.48308/envs.2021.1010>

<http://dorl.net/dor/20.1001.1.17351324.1402.21.1.1.7>

نتیجه گیری: تخمین میزان آلودگی کنده‌های حفاری و گل حفاری با استفاده از الگوریتم مورد استفاده در تحقیق مناسب بوده و در پروسه‌های بعدی صیانت از محیط زیست از قبیل فرآیند تثبیت آلودگی‌ها و بازیافت گل حفاری نقش کارآمدی خواهد داشت.

واژه‌های کلیدی: فلزات سنگین، هیدروکربن‌های آروماتیک چند حلقه‌ای، کاتینگ حفاری، رگرسیون یادگیری حدی.

مقدمه

2018). آلودگی کنده حفاری، به تغییر در ترکیب شیمیایی مواد جامد جدا شده توسط صافی از گل حفاری پس از اتمام حفاری، می‌گویند (Annis and Smith, 1996; ASME, 2003; Rabiha, 1985).

در مطالعه مشابهی چارچوب جدید برای مدیریت محیط-زیستی تغییرات چاه‌های نفتی با استفاده از تکنیک هوش مصنوعی در ترکیب با آمارگیری نمونه‌های کنده و گل حفاری معرفی شده است. در سال ۲۰۲۱ میلادی، در مقاله‌ی اثرات زیست‌محیطی کنده‌های حفاری سعی شده است که یک روش جایگزین به جای روش مرسوم و متداول جامد سازی به عنوان فرآیند مدیریت پسماند حفاری انتخاب شود که از لحاظ محیط‌زیستی و اقتصادی مقرون به صرفه باشد (Sarkheil et al., 2021b; Rayegani et al., 2019). یکی از مسائل مهم در مهندسی محیط زیست در علوم نفت، بررسی ساز و کار جابه‌جایی و تاثیرات کنده‌های حفاری در چاه‌های نفتی است که در چند دهه‌ی اخیر روش‌های مختلفی براساس مدل‌ها و دستگاه‌های آزمایشگاهی برای بررسی این تاثیرات توسعه یافته‌اند (Ball et al., 2011). در اکثر مقاله‌های مقایسه‌ی روش‌های آزمایشگاهی و تحلیل عددی از جمله هوش محاسباتی، نتایج حاصل از آن‌ها نشان داده‌اند که مدل‌های عددی و روش‌های تحلیلی بر پایه هوش محاسباتی از جمله هوش مصنوعی، تطابق بیشتر و هزینه بسیار کمتری نسبت به نتایج آزمایشگاهی دارند (Gholamzadeh Nabati and Thoben, 2016).

در این تحقیق بر روی نتایج آنالیز آزمایشگاهی نمونه‌های گرفته شده از کنده‌های حفاری، الگوریتم رگرسیون یادگیری حدی برای ۱۰ عنصر سنگین و ۱۰ ترکیب

فرآیند استخراج و بهره برداری از منابع نفتی کشور به چرخه‌ی تولید، ارسال و بازیافت گل حفاری و همراه همیشگی آن یعنی کنده حفاری نیاز دارد (Griesbaum et al., 2000; Xue et al., 2018). به طوری که این چرخه می‌تواند آلودگی‌هایی محیط زیستی به همراه داشته باشد. بنابراین بررسی این تغییرات در ترکیب یا آلودگی‌ها، بسیار حائز اهمیت است. از الگوریتم‌های هوش مصنوعی متعددی می‌توان برای تخمین و اعمال رگرسیون و سپس پیش بینی آلودگی‌های ناشی از کنده‌های حفاری استفاده نمود. یکی از این الگوریتم‌های هوشمند، شبکه عصبی مصنوعی بر پایه یادگیری ماشینی رگرسیون یادگیری حدی است (Huang et al., 2012; Dend et al., 2009). صنعت حفاری یکی از بخش‌های اصلی صنعت نفت و یکی از تخصصی‌ترین فعالیت‌های این صنعت در سطح جهان می‌باشد. به طوری که در این صنعت، مراحل عملیاتی همچون، اکتشاف و شناسایی وضعیت مخازن هیدروکربنی (نفت و گاز)

(Sarkheil et al., 2013; Sarkheil et al., 2021a). استخراج نفت از طریق چاه‌های نفت، حفاری چاه‌های توسعه‌ای میدان و انتقال نفت برای فعالیت‌های نفت و پالایشگاهی وجود دارد (Hassani et al., 2011). این صنعت مانند هر فعالیت صنعتی دیگر در پایان عملیات، پسماندها و ضایعاتی را به محیط برمی‌گرداند که عمده‌ترین پسماندهای تولیدی از عملیات حفاری چاه‌های نفت و گاز، گل‌های حفاری برگشتی، کنده‌های حفاری که با سیال حفاری پوشیده شده‌اند، آب همراه تولیدی و مواد شیمیایی می‌باشند (Sarkheil et al., 2018; Sarkheil et al., 2021b; Morillon et al., 2002; Chen et al.,

معمولی و سدیم سیلیکات مایع به عنوان مواد چسباننده برای تهیه نمونه‌های تثبیت شده، و برای تهیه نمونه‌های شسته شده از آب منطقه هورالعظیم که در منطقه حفاری قابل دسترس بود استفاده شد. کننده و سیالات حفاری مورد آزمایش نیز از سیال حفاری برگشتی به سطح در زمان حفاری چاه شماره B در منطقه آزادگان جنوبی استفاده شده است. همچنین در این مطالعه تعداد ۹ عمق به عنوان اعماق نمونه‌گیری در چاه مورد مطالعه انتخاب شده است (جدول ۱). لازم به ذکر است که این اعماق، بر اساس ورود به یک سازند جدید یا ضخامت زیاد سازند، تغییر در ترکیبات سیال حفاری، زمین شناسی لایه‌های مختلف زمین تعیین شده است.

آروماتیک آلوده کننده‌ی کنده و گل حفاری بر روی دو سری داده‌ی مختلف به کار گرفته شد. به طوری که بتوان به صورت غیر مستقیم میزان آلودگی گل حفاری و کنده-های حفاری را به صورت موثر ارزیابی نمود. نتایج حاصل برای اعتبار سنجی آن‌ها به صورت دو پارامتر، مجذور میانگین مربعات خطای یادگیری (RMSE) و متوسط خطای مطلق (MAE) در نظر گرفته شده است.

مواد و روش‌ها

روش تحقیق

نمونه‌گیری و آماده سازی نمونه

در این تحقیق از مواد اولیه همچون سیمان پروتلند

جدول ۱- اعماق نمونه‌گیری و ساختارهای زمین شناسی
Table 1. Depth of sampling and geological structures

زمین شناسی Geology	سازند Formation	عمق (متر) Depth (m)
مارن- ماسه- سنگ رس Marl - Sand - Clay Stone	آغاجاری Aghajari	75
مارن- ماسه- سنگ رس Marl - Sand - Clay Stone	آغاجاری Aghajari	500
مارن- ماسه- سنگ رس Marl - Sand - Clay Stone	آغاجاری Aghajari	1080
سنگ آهک دولومیتی Dolomite Lime Stone	آسماری Asmari	1800
سنگ آهک رسی Clay Lime Stone	پابده Pabdeh	2100
سنگ آهک رسی- مارن Marl Lime Stone	گورپی Gorpi	2400
سنگ آهک- سنگ رس Clay- Lime Stone	ایلام Ilam	2600
سنگ آهک گچی- آهک دولومیتی- سنگ آهک رسی Clay-Dolomite-Chalky limestone	سروک Sarvak	2700
سنگ آهک گچی- آهک دولومیتی- سنگ آهک رسی Clay-Dolomite-Chalky limestone	سروک Sarvak	2780

کنده‌ی حفاری بخش شکسته شده از قسمت جامد یک گمانه حفر شده توسط حفار و روش‌های حفر است که توسط گل حفاری به سطح آورده می‌شود (شکل ۱)، کنده حفاری به طور رایج به عنوان یک وسیله اندازه‌گیری (یک لاگ نمونه- برداری)، از مواد زیر سطح زمین برای شناسایی اعماق مختلف به کار می‌رود که در صنایع حفاری نفت و گاز (هیدروکربن) به آن لاگ گل نیز گفته می‌شود (Darley and Gray, 1988; Cheraghian *et al.*, 2018; Onwuka *et al.*, 2018).

نوع و میزان غلظت هیدروکربن‌ها به طور معمول به نوع و میزان روغن‌های استفاده شده در سیال حفاری بستگی دارد.


آماده سازی نمونه خاک بکر: این نمونه از عمق یک متری و به دور از فرآیندهای حفاری (حدوداً هزار متر) برداشت شده است تا به عنوان نمونه مرجع برای مقایسه نتایج آزمایشات (به خصوص آزمایش شوری) مورد استفاده قرار گیرد. لازم به ذکر است که هیچ فرآیندی مثل تثبیت و یا شستشو روی نمونه خاک بکر صورت نگرفته است.

آماده سازی نمونه کنده به همراه گل حفاری: برای آماده سازی نمونه‌های این بخش باید سیال حفاری دفع شده از روی خروجی الک‌های لرزان جمع‌آوری شود، سپس بدون هیچ نوع افزودنی و یا فرآیندی، به عنوان نمونه‌های "کنده به همراه سیال حفاری" معرفی شوند.

مختلف و همچنین افزودن و با حذف فلز یا فلزهای در ترکیب های اولیه سیالات حفاری در عمق های مختلف می باشد. به طوری که غلظت هیچکدام از این فلزها در نمونه های مختلف، از حدود مجاز تعیین شده در استاندارد خاک ایران برای فلزهای سنگین، عبور نکرده است. بنابراین در این چاه فلزهای سنگین به عنوان آلاینده شناخته نمی شود که در نتیجه برای کنترل و یا کاهش غلظت فلزهای سنگین به هیچ فرآیند خاصی در مدیریت پسماند، نیازی نمی باشد.

به طور کلی در نمونه های گرفته شده از عمق ۱۸۰۰ متر و پایین تر، ۶ مورد از ۱۶ مورد هیدروکربن مورد بررسی، بیش از حد استاندارد بوده اند که عبارتند از: Benz [a] anthracene, Chrysene, Naphthalene, Pyrene Fluorene, Phenanthrene.

غلظت فلزهای سنگین در انواع نمونه های گرفته شده در تمام طول، دارای نوسان بوده و از الگوی مشخصی پیروی نکرده است. دلیل این امر وجود فلزهای در چینه ها در سازندهای



شکل ۱- تصویر اجزاء یک نمونه کنده حفاری زیر یک میکروسکوپ

Fig. 1- Image of the components of a drilling sample under a microscope

یادگیری با تغییراتی در اتصالات سیناپسی که بین اعصاب قرار دارد، همراه است. از این روش در شبکه های عصبی مصنوعی نیز استفاده شده است و عمل فهم و شناخت سیستم مورد مطالعه از طریق آموزش و تنظیم پارامترهایی به نام وزن و بایس شبکه صورت می گیرد (Sarkheil et al., 2009a; Sarkheil et al., 2009b).

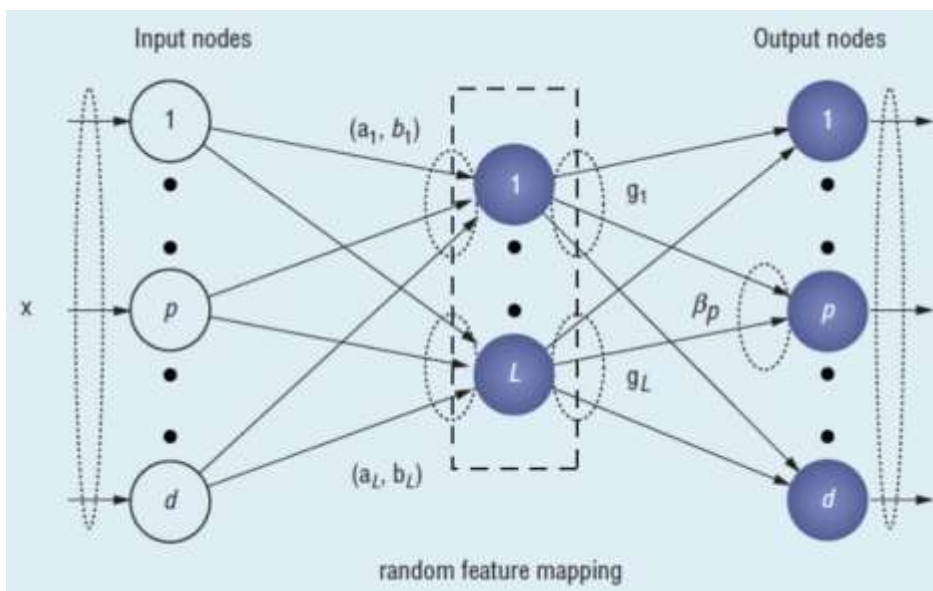
رگرسیون یادگیری حدی تک لایه

رگرسیون یادگیری حدی، یک شبکه عصبی رو به جلو است که برای طبقه بندی، تحلیل رگرسیون، مشتق زایی و لاپلاس گیری تقریبی، مقایسه و آموزش ویژگی های یک پدیده، دارای یک یا چند لایه در نورون های پنهان می باشد به گونه ای که نیازی به پارامترهای نورون های پنهان نباشد. این نورون های پنهان می توانند به صورت تصادفی اختصاص داده شده باشد و هرگز بهبود وزن ها برایش

شبکه عصبی مصنوعی

یک شبکه عصبی مصنوعی، روشی کاربردی برای پردازش اطلاعات اکتشافی است که از سیستم عصبی انسانی الهام گرفته و مانند یک مغز با سلول های زیاد، اطلاعات را پردازش می کند. عنصر کلیدی این روش، ساختار جدید سیستم پردازش اطلاعات آن می باشد. این سیستم از شمار زیادی عناصر پردازشی سریع و فوق العاده به هم پیوسته به نام نورون ها تشکیل شده است که برای حل یک موضوع با هم هماهنگ کار می کنند. شبکه های عصبی مصنوعی نیز مانند انسان ها با مثال های زیاد می آموزند و یک شبکه عصبی مصنوعی برای انجام وظیفه های مشخص خود مانند شناسایی الگوها و دسته بندی اطلاعات، در طول یک فرآیند یادگیری، پیش فرض های خود را تنظیم می کند. در سیستم های عصبی زیستی،

دارا می‌باشد. مدل‌های مختلف رگرسیون بردار پشتیبان نسبت به رگرسیون یادگیری حدی، پیچیدگی محاسباتی بیشتری دارند و به‌طور کلی به جواب زیر بهینه نزدیک می‌شوند. از لحاظ تئوری، مدل رگرسیون یادگیری حدی می‌تواند هر تابع هدف کلی و پیوسته‌ای را به‌طور صحیح تخمین بزند و هر ناحیه‌ی متمایزی را به‌طور کامل دسته‌بندی و مشخص کند. نتایج عملی این مدل‌های رگرسیونی نشان می‌دهد که مقیاس پذیری بهتر و مناسب تری را به همراه دارند و همچنین رگرسیون یادگیری حدی، سرعت بسیار بیشتری در مقایسه با روش‌های متداول رگرسیون بردار پشتیبان دارد (Huang and Chen, 2008).



شکل ۲- مدل رگرسیون یادگیری حدی تک لایه (Huang and Chen, 2008)

Fig. 2- Single-layer partial learning regression model (Huang and Chen, 2008)

مطالعات آماری داده‌ها

مطالعات آماری انجام شده در این تحقیق، شامل محاسبه و تحلیل مقادیر پارامترهای اولیه آماری نظیر میانگین، مد، میانه و تعدادی دیگر از شاخص‌های مرکزی آمار برای تمام مجموعه داده‌های مورد استفاده است. در این پژوهش از نرم افزار SPSS برای مطالعات آماری استفاده شده است. در جداول ۲ و ۳ مقادیر پارامترهای آماری را برای داده‌های موجود ارائه شده است.

انجام نگیرد. در اغلب موارد، وزن خروجی نوروهای پنهان معمولاً در یک مرحله گنجانده می‌شود که اساساً به یادگیری یک مدل به صورت خطی و با مشتق ثابت می‌پردازد (Huang et al., 2012; Deng et al., 2009; Golamzadeh Nabata and Thoben, 2016).

مدل رگرسیون یادگیری حدی می‌تواند در یک قالب کلی یکپارچه با انواع انتقال را برای ویژگی‌های وسیعی که می‌تواند در لایه مخفی استفاده کرد، فراهم کند که می‌تواند به‌طور مستقیم در دسته‌بندی چندرسته‌ای و رگرسیونی مورد استفاده قرار گیرند (شکل ۲).

از منظر بهینه‌سازی، رگرسیون یادگیری حدی محدودیت‌های کمتری نسبت به رگرسیون بردار پشتیبان

داده‌های مورد استفاده در این تحقیق را به دو دسته ی داده‌های اصلی و داده‌های اعتبارسنجی تقسیم می‌کنیم. داده‌های اصلی که برای یادگیری شبکه استفاده می‌شوند، از یک حلقه چاه در یک منطقه نفتی متفاوت با منطقه نفتی داده‌های اعتبارسنجی نمونه برداری شده‌اند. داده‌های اصلی شامل ۶۰ دسته داده برای هر ترکیب آروماتیک و فلز سنگین و داده‌های اعتبارسنجی شامل ۶ دسته داده برای هر ترکیب آروماتیک و فلز سنگین می‌باشد.

جدول ۲- مقادیر پارامترهای آماری اندازه‌گیری شده بر روی بخش فلزات سنگین داده‌ها

Table 2. Values of statistical parameters measured on the heavy metals section of the data

نوع فلز Type of Metal	مد Mode	میانگین Median	میانه Middle	واریانس Variance	انحراف معیار Standard Deviation	دامنه تغییرات Variation Range	چولگی Skewness	کشیدگی Elongation
نقره Ag	0.009	1.3727	0.92	1.794	1.6717	12.276	4.706	29.865
باریم Ba	11.64	529.19	540.56	34877	186.72	923.786	-0.658	0.7
کادمیم Cd	0.068	0.034	0.11	1.06	1.03	6.65	5.16	27.73
کبالت Co	0.3	1	0.74	1.61	1.27	9.29	5.47	35.17
کروم Cr	26.64	16.74	12.78	129.5	11.38	56.83	1.86	4.695
مس Cu	0.65	25.11	19.91	442.32	21.031	69.06	0.53	-0.966
نیکل Ni	6.81	15.9	12.19	88.87	9.42	29.478	0.778	-0.895
سرب Pb	12.76	11.29	11.78	64.98	8.061	46.26	1.691	6.72
وانادیم Va	2.2	10.07	7.43	162.36	12.74	73.92	3.29	12.84
روی Zn	0.35	1.36	0.95	2.67	1.63	9.54	3.27	12.61

جدول ۳- مقادیر پارامترهای آماری اندازه‌گیری شده بر روی بخش ترکیبات آروماتیک داده‌ها

Table 3. The values of statistical parameters measured on the section of the aromatic compound of the data

ترکیب Type	مد Mode	میانگین Median	میانه Middle	واریانس Variance	انحراف معیار Standard Deviation	دامنه تغییرات Variation Range	چولگی Skewness	کشیدگی Elongation
آنتراسن Anthracene	0.5	14.13	2.35	414.24	20.35	64.95	1.44	0.647
اسنافتیلن Astaphetiline	19	16.38	19	194.95	13.96	73.6	1.09	2.96
اسنافتن Asnaphene	4.4	4.86	4.4	6.72	2.592	12.8	0.926	1.028
بنزن / آنتراسن Banzen/Anthrasene	0.1	6.2	2.35	49.67	7.05	19.99	0.889	-0.735
پیرن Pyrene	0.95	4.36	1.92	29.31	5.41	26.53	2.2	5.47
فنانترن Phenanthrene	0.78	55.41	23.45	7507.63	86.46	476.09	2.604	8.735
نفتالین Naphtaline	15.2	68.39	29.25	7217.77	84.95	29.48	392.9	3.33
فلوئورن Flourene	6.6	25.85	11.29	1056.5	32.5	106.885	1.59	1.05
فلوئورانتین Flouorantine	0.11	4.475	1.8	71.14	8.434	61.844	5.44	35.84
کریزین Chrysin	0.13	5.5	2.88	32.77	5.725	15.98	0.703	-1.05

صورت پذیرد (Huang and Chen, 2008).

$$Xn = (Xt - Xm) * \left(\frac{1}{Xs}\right) \quad (1)$$

که در رابطه بالا $Xn =$ مقدار نرمال شده ی هر کمیت، $Xt =$ مقدار کمیت پیش از نرمال شدن، $Xm =$ مقدار میانگین کمیت و $Xs =$ مقدار واریانس کمیت است. یادگیری توسط شبکه عصبی: در شکل شماره ۳ عملکرد شبکه عصبی را به صورت خلاصه ارائه شده است.

نرمال سازی داده‌ها: مطالعات آماری روی داده‌های آلودگی کنده‌های حفاری بیان می‌کند که با وجود تعداد داده‌های کم برای شبکه داده‌ها دارای تغییرات زیادی در میزان آلودگی هر فلز یا هر هیدروکربن هستند و هیچ کدام شروط اولیه توزیع نرمال (میانگین ۱ و انحراف معیار صفر) را ندارند و برای ادامه کار در رگرسیون یادگیری حدی باید با استفاده از رابطه ۱، نرمال سازی داده‌ها



شکل ۳-مراحل عملکرد شبکه عصبی برای تخمین آلودگی کننده‌ها و گل حفاری

Fig. 3-Neural network operation steps to estimate drilling cutting and mud contamination

نتایج و بحث

بخش قبل وارد رگرسیون ماشین یادگیری حدی می-شوند. در این بخش جهت اجرای پروسه الگوریتم رگرسیون یادگیری حدی، از نرم افزار MATLAB 2019a بهره گرفته شده است. جهت انجام روند تخمین توسط شبکه عصبی ELR، تابع تبدیل رگرسیون Hard limit و تعداد نورون‌های میانی ۶۲ عدد در نظر گرفته شده است. در جدول‌های شماره ۴ و ۵ ضریب همبستگی رگرسیون و مجذور میانگین خطای یادگیری شبکه و مجذور میانگین خطای مطلق برای هر فلز و هر ترکیب آروماتیک آورده شده است.

در این تحقیق بر اساس الگوی ارائه شده در بخش روش تحقیق، تعداد ۶۰ دسته داده از داده‌های تهیه شده به منظور تخمین میزان تغییر در غلظت فلزات سنگین، هیدروکربن‌های آروماتیک چند حلقه‌ای در فرآیند یادگیری و آزمون دخالت داده شده‌اند و ۶ دسته داده دیگر مربوط به یک چاه که به طور تصادفی انتخاب شده و در فرآیند اعتبارسنجی شبکه عصبی مصنوعی استفاده شده‌اند.

جهت تخمین آلودگی، داده‌های اصلی نرمال شده در

جدول ۴-نتایج مربوط به یادگیری شبکه عصبی با داده‌های اصلی برای فلزات سنگین

Table 4. Results of neural network learning with basic data for heavy metals


	R-Train	R-Test	RMSE-Train	RMSE-Test	RMAE-Train	RMAE-Test
فلز نقره Ag	0.981	0.975	0.018	0.012	0.125	0.127
فلز باریوم Ba	0.991	0.887	0.009	0.025	0.091	0.247
فلز کادمیم Cd	0.992	0.917	0.017	0.017	0.271	0.143
فلز کوبالت Co	0.998	0.973	0.015	0.009	0.097	0.098
فلز کروم Cr	0.995	0.923	0.009	0.015	0.134	0.158
فلز مس Cu	0.963	0.842	0.015	0.034	0.037	0.092
فلز نیکل Ni	0.954	0.952	0.014	0.021	0.075	0.099
فلز سرب Pb	0.934	0.923	0.016	0.031	0.12	0.175
فلز وانادیم Vn	0.999	0.825	0.008	0.045	0.068	0.195
فلز روی Zn	0.973	0.812	0.012	0.057	0.143	0.27

جدول ۵- نتایج مربوط به یادگیری شبکه عصبی با داده های اصلی برای هیدروکربن های آروماتیک
Table 5. Neural network learning outcomes with primary data for aromatic hydrocarbons


	R-Train	R-Test	RMSE-Train	RMSE-Test	RMAE-Train	RMAE-Test
اسنافتن Asnaphene	0.911	0.905	0.019	0.021	0.111	0.117
اسنافتیلین Astaphetilene	0.923	0.899	0.015	0.025	0.091	0.147
آنتراسن Anthracene	0.987	0.928	0.009	0.027	0.121	0.145
بنزن انتراسن Banzen/Anthrasene	0.992	0.978	0.008	0.021	0.097	0.215
کریزین Chrysin	0.951	0.927	0.011	0.014	0.144	0.178
فلوئورانتین Flouorantine	0.923	0.872	0.017	0.034	0.167	0.247
فلوئورن Flourene	0.912	0.898	0.028	0.027	0.177	0.278
نفتالین Naphtaline	0.999	0.947	0.005	0.011	0.094	0.099
فنانتترین Phenanthrene	0.982	0.967	0.01	0.013	0.92	0.097
پیرین Pyrene	0.957	0.937	0.013	0.017	0.144	0.189

برداشت شده اصلی متفاوت است استفاده می شود که نتایج حاصل از اعتبارسنجی در شکل های ۴ تا ۱۷ قابل مشاهده است.


اعتبارسنجی توسط شبکه عصبی: برای اعتبارسنجی شبکه عصبی، از داده های اعتبارسنجی که از نظر مکانی با داده های



شکل ۴- نمودار تفاوت مقادیر واقعی و تخمین زده شده اعتبارسنجی فلز نقره و باریم
Fig. 4- Graph of the difference between the real and estimated values of silver and barium metal validation

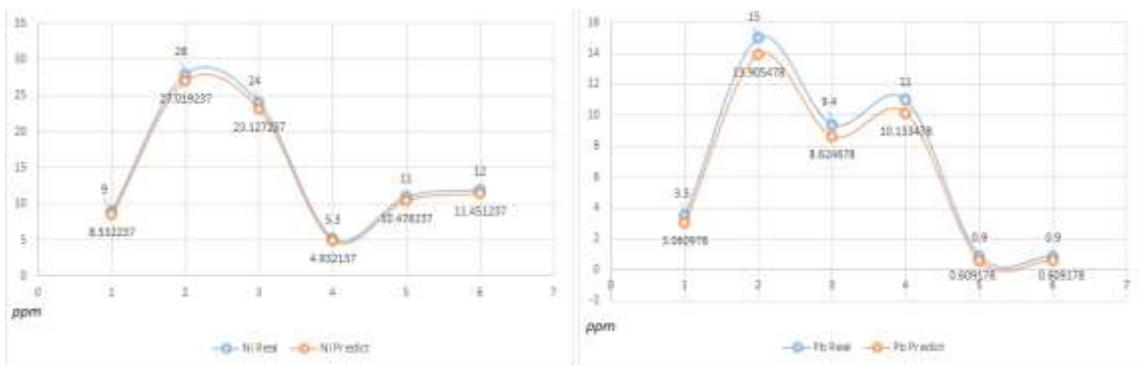


شکل ۵- نمودار تفاوت مقادیر واقعی و تخمین زده شده اعتبارسنجی فلز کادمیم و کبالت
Fig. 5 - Graph of the difference between the real and estimated values of cadmium and cobalt metal validation




شکل ۶- نمودار تفاوت مقادیر واقعی و تخمین زده شده اعتبارسنجی فلز کروم و مس

Fig. 6- Diagram of the difference between the real and estimated values of chromium and copper metal validation




شکل ۷- نمودار تفاوت مقادیر واقعی و تخمین زده شده اعتبارسنجی فلز نیکل و سرب

Fig. 7- Diagram of the difference between real and estimated values of nickel and lead metal validation



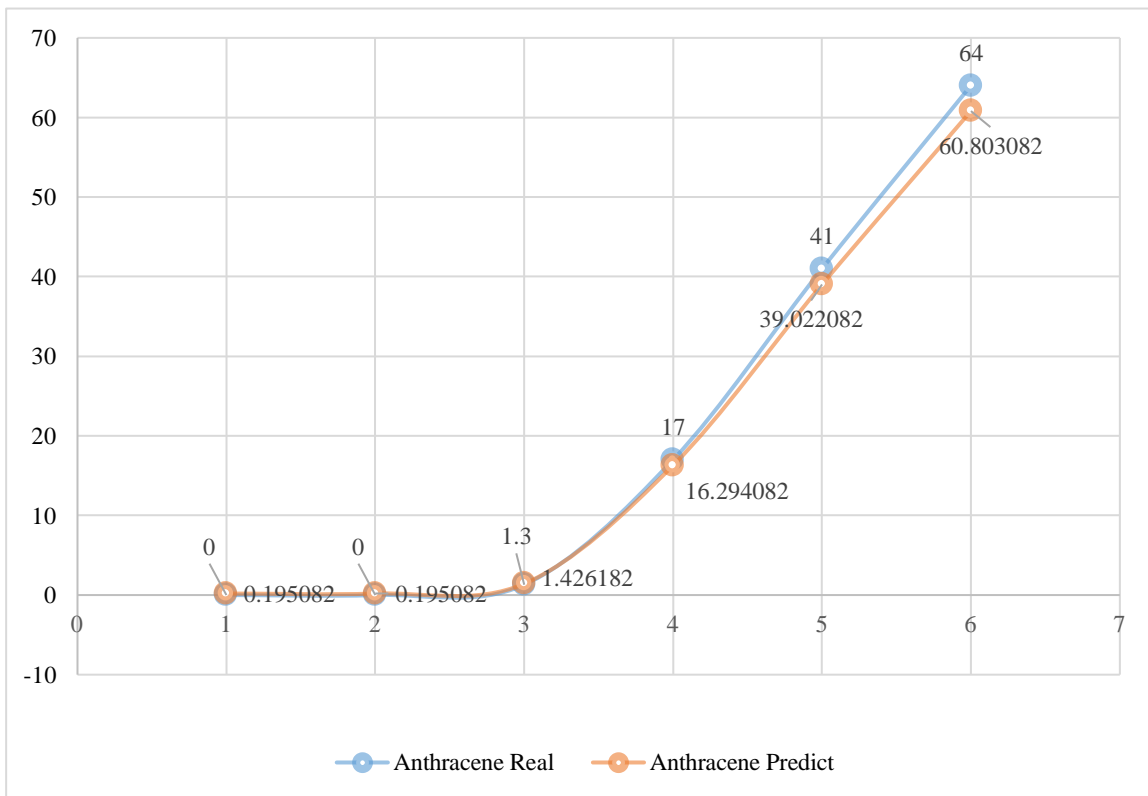
شکل ۸- نمودار تفاوت مقادیر واقعی و تخمین زده شده اعتبارسنجی فلز وانادیم و روی

Fig. 8- Diagram of the difference between real and estimated values of vanadium and zinc validation



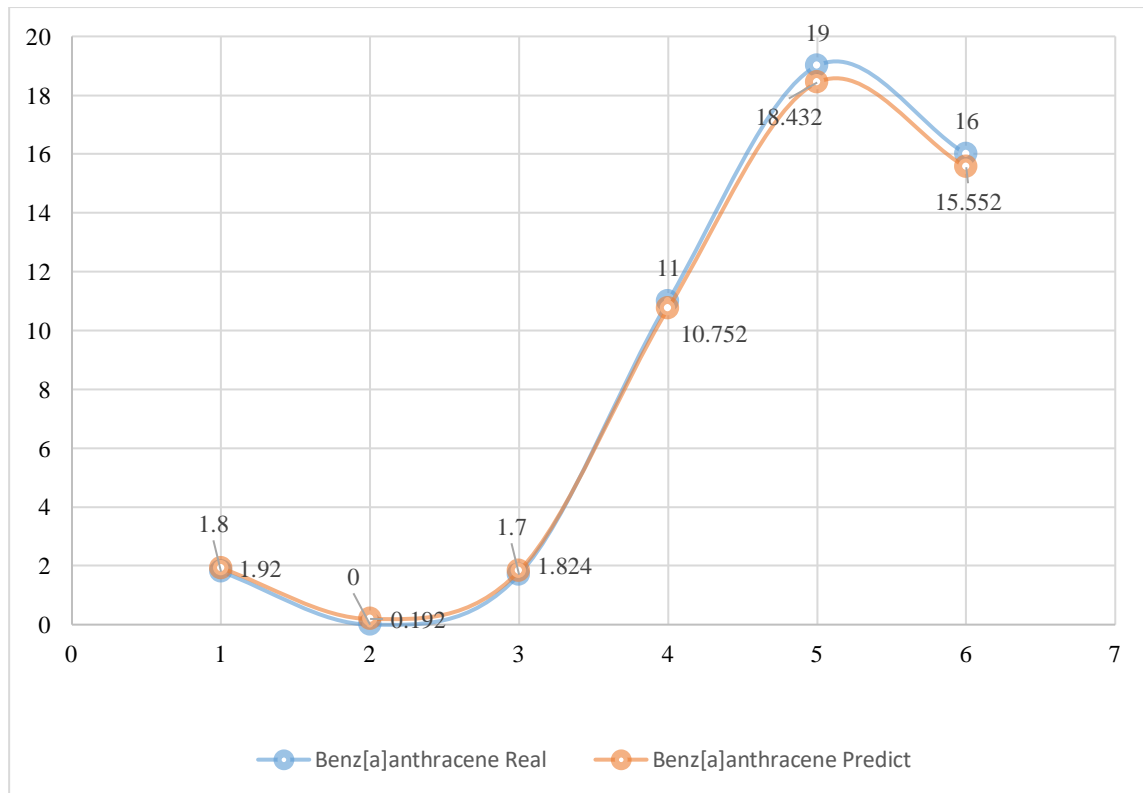
شکل ۹- نمودار تفاوت مقادیر واقعی و تخمین زده شده اعتبارسنجی اسنافتن و اسنافتیلن

Fig. 9 - Diagram of the difference between the real and estimated values of the validation of snafthen and snaftylene



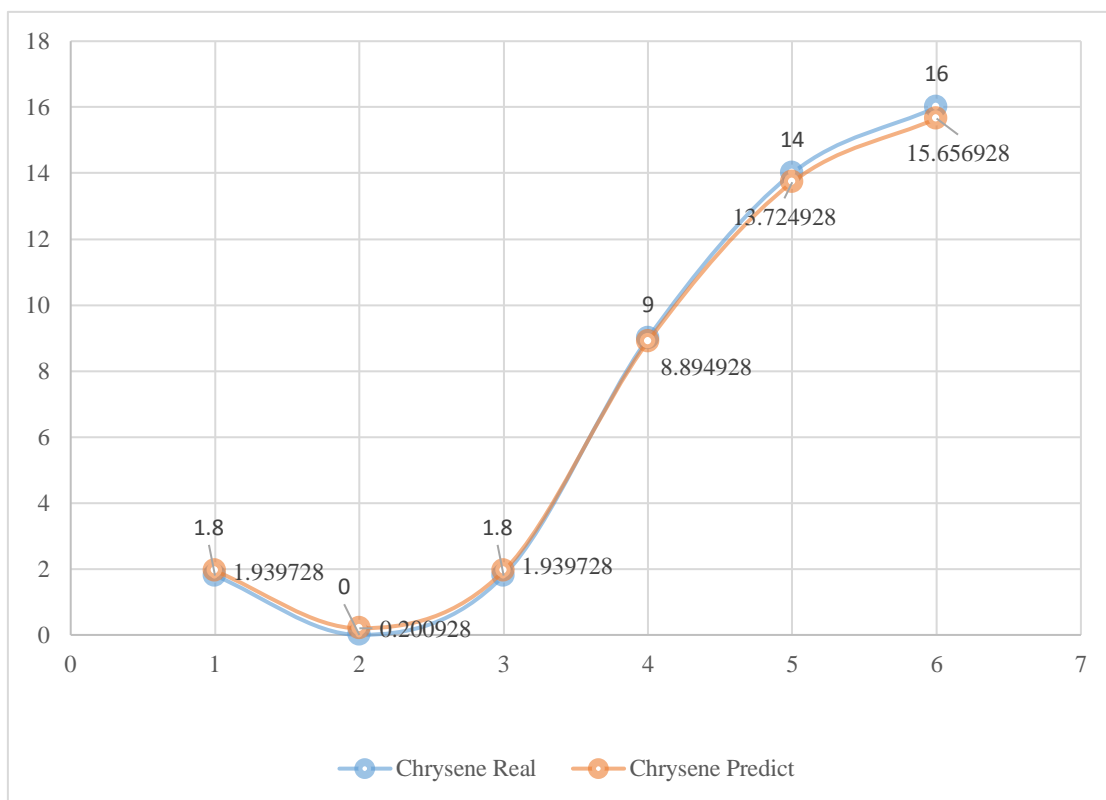
شکل ۱۰- نمودار تفاوت مقادیر واقعی و تخمین زده شده اعتبارسنجی انتراسن

Fig. 10- Diagram of the difference between real and estimated values of Anthracene validation




شکل ۱۱- نمودار تفاوت مقادیر واقعی و تخمین زده شده اعتبارسنجی بنز انتراسن

Fig. 11- Diagram of the difference between the real and estimated values of Benz Anthracene validation



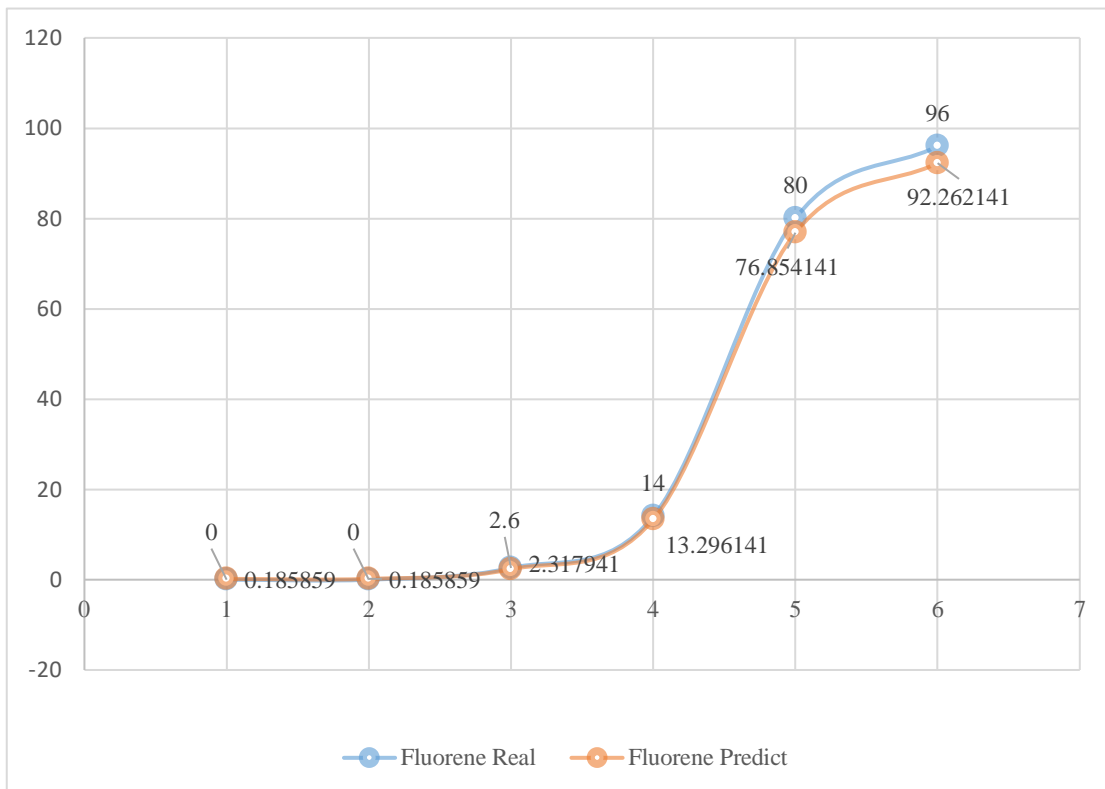
شکل ۱۲- نمودار تفاوت مقادیر واقعی و تخمین زده شده اعتبارسنجی کریزین

Fig. 12- Graph of the difference between real and estimated values of Chrysine validation



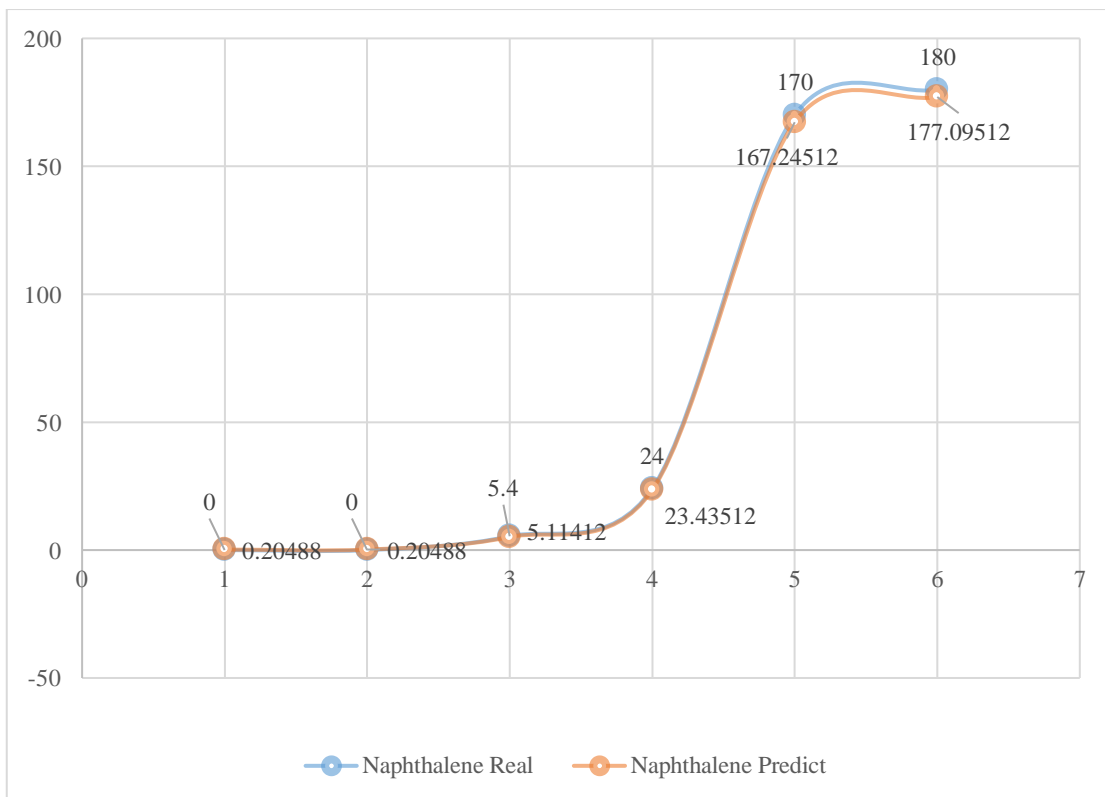
شکل ۱۳- نمودار تفاوت مقادیر واقعی و تخمین زده شده اعتبارسنجی فلورانتین

Fig. 13- Diagram of the difference between real and estimated values of Florentine validation



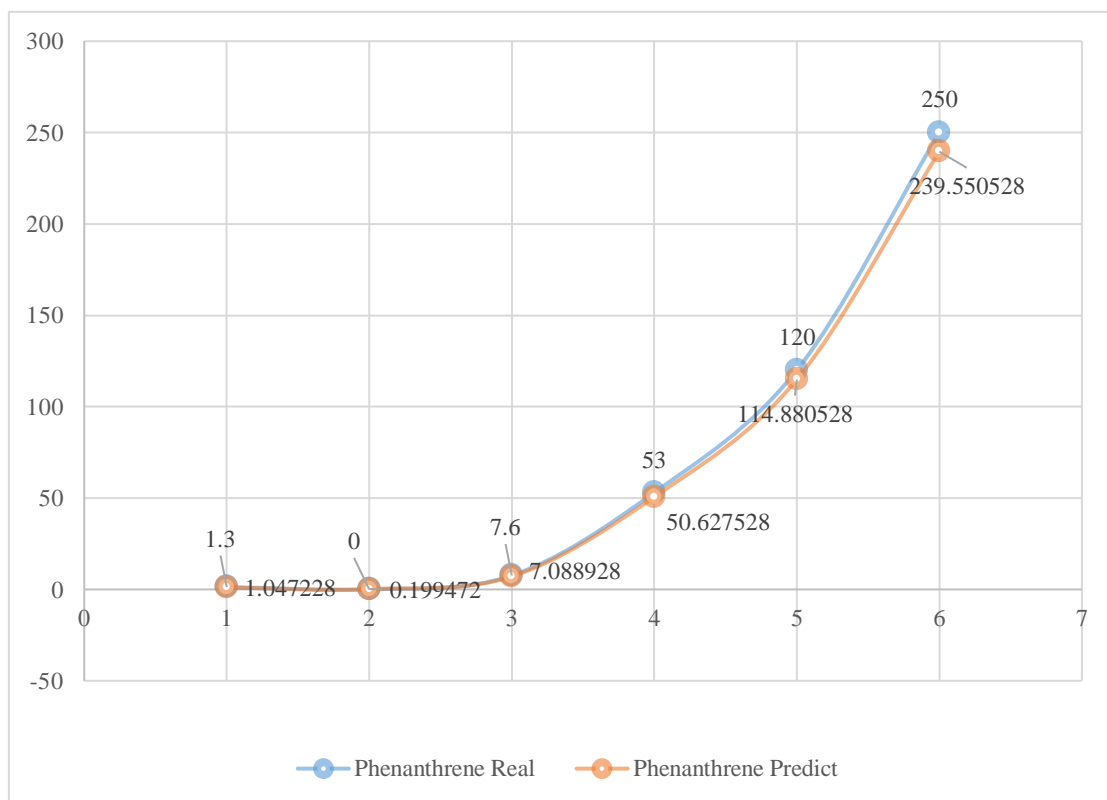
شکل ۱۴- نمودار تفاوت مقادیر واقعی و تخمین زده شده اعتبارسنجی فلئورن

Fig. 14- Diagram of the difference between real and estimated values of Fluorene validation



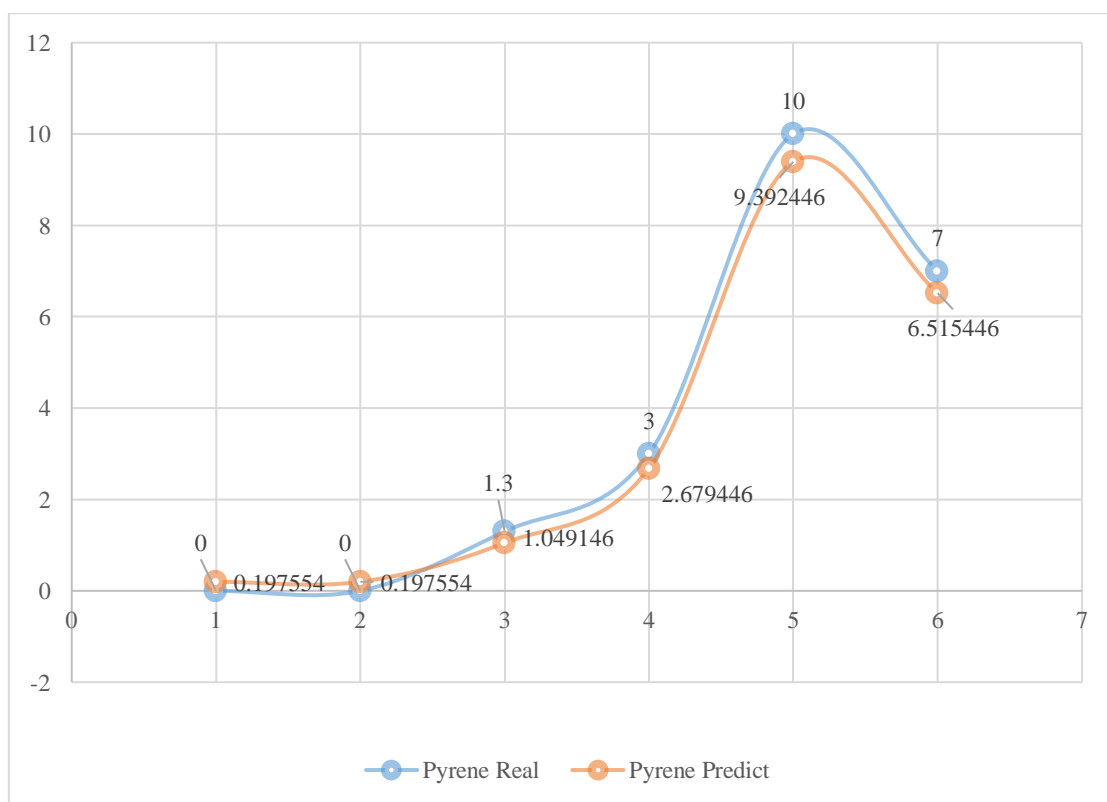
شکل ۱۵- نمودار تفاوت مقادیر واقعی و تخمین زده شده اعتبارسنجی نفتالین

Fig. 15- Diagram of the difference between real and estimated values of Naphthalene validation



شکل ۱۶- نمودار تفاوت مقادیر واقعی و تخمین زده شده اعتبارسنجی فنانتترین

Fig. 16 - Diagram of the difference between the real and estimated values of the Phenanthrene validation



شکل ۱۷- نمودار تفاوت مقادیر واقعی و تخمین زده شده اعتبارسنجی پیرین

Fig. 17- Diagram of the difference between the real values and the estimated effect of Pirin validation

در این تحقیق مطابق خروجی‌های ارائه شده، الگوریتم رگرسیون یادگیری حدی برای ۱۰ عنصر سنگین و ۱۰ ترکیب آروماتیک آلوده کننده و گل حفاری بر روی دو سری داده‌ی مختلف مورد بررسی قرار گرفت به طوری که نتایج حاصل برای اعتبار سنجی آن‌ها به صورت دو پارامتر، مجذور میانگین مربعات خطای یادگیری، برابر با ۲۰ درصد و متوسط خطای مطلق آن ۲۵ درصد بوده است که حسب متغیرهای موجود، در تخمین میزان آلودگی کنده‌های حفاری مناسب بوده و در پروسه‌های بعدی صیانت از محیط زیست از قبیل فرآیند تثبیت آلودگی‌ها و بازیافت گل حفاری نقش کارآمدی خواهد داشت.

بررسی میزان آلودگی کنده‌های حفاری و تطابق آن با ساختار گل حفاری و ساختار زمین شناسی به علت کمبود داده در این زمینه به صورت نسبی به تحقق دست یافت. خطا در اعتبارسنجی برای فلزات و هیدروکربن‌های آروماتیک می‌تواند به دو علت عدم وجود داده‌ها در مورد سازنده‌های مختلف برای بهبود یادگیری شبکه و عدم ورود اطلاعات زمین شناسی منطقه به خاطر محرمانه بودن حفاری‌های نفتی در آن منطقه باشد. در بیشتر ترکیبات آروماتیک و فلزات سنگین، پارامترهای موجود برای داده‌ها، توانایی لازم برای تخمین آلودگی را دارد ولی در مورد فلز کادمیم، کبالت و وانادیم به پارامترهای دیگری از جمله پارامترهای زمین شناسی و سازندی لازم است.

نتیجه‌گیری

بازیافت گل حفاری به عنوان یک فعالیت مهم و اساسی در صنعت نفت و همچنین برای حفاظت از محیط زیست حائز اهمیت می‌باشد. برای این امر مشخص نمودن میزان آلودگی فلزات سنگین و مواد آلی موجود در گل حفاری و کنده‌های حفاری یک عامل کلیدی می‌باشد، امروزه استفاده از روش‌های هوشمند تخمین میزان این آلودگی‌ها به صورت غیر مستقیم، پر کاربرد است. استفاده از هوش

مصنوعی که توانایی ارزیابی مقادیر آلاینده‌ی را با استفاده از داده‌های ورودی با تعداد، تنوع و پیچیدگی بسیار بالا دارا می‌باشد، می‌تواند نتایج مناسبی را به همراه داشته باشد. الگوریتم شبکه عصبی مورد استفاده در این تحقیق که الگوریتم رگرسیون یادگیری حدی بوده است برای ۱۰ عنصر سنگین و ۱۰ ترکیب آروماتیک آلوده کننده‌ی کنده و گل حفاری بر روی دو سری داده‌ی مختلف در یک منطقه‌ی حفاری در یکی از میادین نفتی جنوب ایران مورد ارزیابی قرار گرفت توانست در زمینه یادگیری و آموزش به خوبی عمل کند به طوری که برای این میزان داده (۶۶ داده) در بیشتر ترکیبات آروماتیک و فلزات سنگین پارامترهای موجود برای داده‌ها توانایی لازم برای تخمین آلودگی را داشته اند ولی در مورد فلز کادمیم، کبالت و وانادیم به پارامترهای تکمیلی دیگری از جمله پارامترهای زمین شناسی و سازندی به طور کامل نیاز می‌باشد. بنابراین می‌توان با استفاده از الگوریتم مزبور به صورت غیر مستقیم میزان آلودگی گل حفاری و کنده‌های حفاری را به صورت موثر تخمین زد و در پروسه‌های بعدی صیانت از محیط زیست از قبیل فرآیند تثبیت آلودگی‌ها و بازیافت گل حفاری نقش کارآمدی داشت.

پیشنهاد می‌شود ساختار گل و کنده حفاری خارج شده از چاه به صورت سیستماتیک و با دقت بالا بررسی و آنالیز شود و نتایج آن با اطلاعات زمین شناسی زیر سطحی و سازنده‌های دارای هیدروکربن، تلفیق گردد زیرا این موضوع در بهبود عملکرد شبکه عصبی نقش موثری خواهد داشت. به طوری که پیش‌بینی‌های دقیق‌تری از آلاینده‌ی ارائه خواهد نمود.

در بحث الگوریتم شبکه عصبی، استفاده از الگوریتم‌های ماشین حدی دو یا چند لایه همانند الگوریتم ماشین یادگیری بولتزمن محدود شده می‌تواند در افزایش کارایی شبکه عصبی و کاهش قابل توجه تعداد نورون‌های لایه میانی شبکه عصبی و تخمین همزمان چند پارامتر به طور موثر مورد استفاده قرار گیرد.

تشکر و قدردانی

به خاطر حمایت‌های مالی و معنوی پژوهش حاضر تشکر می‌نمایند.

نویسندگان مقاله از شرکت سیالات حفاری پارس (PDF)

منابع

- Annis, M.R. and Smith, M.V., 1996. *Drilling Fluids Technology*, Revised Edition, Exxon Company, USA.
- ASME, 2003. *Handbook of Drilling Fluids Processing*. By ASME Shale Shaker Committee, 666.
- Ball, A.S., Steward, R.J. and Schlipf, K., 2011. A review of the current options for the treatment and safe disposal of drill cuttings. *Waste Management and Research Journal*. 30(5), 457-473.
- Chen, Z., Zhou, J., Chen, Z., Chen, H. and Yuanjian, X., 2018. A laboratory evaluation of superheated steam extraction process for decontamination of oil based drill cuttings. *Journal of Environmental Chemical Engineering*. 6, 6691-6699. <https://doi.org/10.1016/j.jece.2018.10.040>
- Cheraghian, G., Wu, Q., Mostofi, M., Li, M.C., Afrand, M. and Sangwai, J.S., 2018. Effect of a novel clay/silica nanocomposite on water-based drilling fluids: Improvements in rheological and filtration properties. *Colloids and Surfaces: A Physicochemical and Engineering Aspects*. 555, 339-350.
- Darley, H.C.H. and Gray, G.R., 1988. *Composition and Properties of Drilling and Completion Fluids*, (fifth Edition). Woburn, MA: Butterworth-Heinemann.
- Deng, W., Zheng, Q. and Chen, L., 2009. Regularized Extreme Learning Machine, *Proc. IEEE Symposium. CIDM*, 389-395.
- Gholamzadeh Nabatia, E. and Thoben, K.D., 2016.
- Data-driven decision making in planning the maintenance activities of Off-shore wind energy, In *Proceedings 5th International Conference on Through-life Engineering Services*. pp.160-165.
- Griesbaum, K., Behr, A., Biedenkapp, D., Voges, H.W., Garbe, D., Paetz, C., Collin, G., Mayer, D., and Höke, H., 2002. Hydrocarbons, in *Ullmann's Encyclopedia of Industrial Chemistry*, Wiley-VCH, Weinheim.
- Hassani, H., Sarkheil, H., Foroud, T. and Karimpoori, S., 2011. A Proxy Modeling Approach to Optimization Horizontal Well Placement; OnePetro: San Francisco, CA, USA.
- Huang, G.B., Zhou, H., Ding, X. and Zhang, R., 2012. ELM for Regression and Multiclass Classification, *IEEE Transactions on Systems, Man, and Cybernetics*. 42(2), 513-529.
- Morillon, A., Vidalie, J.F., Hamzah, U.S., Suripno, S. and Hadinoto, E.K., 2002. *Drilling and Waste Management*, SPE 73931, presented at the SPE International Conference on Health, Safety, and the Environment in Oil and Gas Exploration and Production, 20th-22th March.
- Onwuka, O.S., Ogbonnaya, I.G.W.E., Ifediegwu, S.I. and Uwom, C.S., 2018. An assessment of the effectiveness of drilling waste treatment process in X-gas field, Niger Delta, Nigeria. *Geology, Ecology, and Landscapes Journal* 2 (7).
- Rabia, H. 1985, *Oilwell drilling engineering: principles and practice*; Gaithersburg, MD, USA.
- Rayegani, B., Barati, S., Goshtasb, H., Sarkheil, H. and Ramezani, J. 2019. An effective approach to

selecting the appropriate pan-sharpening method in digital change detection of natural ecosystems. *Ecological Informatics* 53, 100984.

Sarkheil, H., Hassani, H. and Alinia, F., 2021a. Fractures Reservoir Distribution Characterization using Folding Mechanism Analysis and Patterns Recognition in the Tabnak Hydrocarbon Reservoir Anticline, *Journal of Petroleum Exploration and Production Technology*. 11:2425–2433. <https://doi.org/10.1007/s13202-021-01225-y>

Sarkheil, H., Kalhor, M., Azimi, Y., Talaeian Araghi, M. and Fathi Noran, M., 2021b. Investigating the Effectiveness of Drilling Mud-Cutting on Heavy Metals and Polycyclic Aromatic Hydrocarbons Contamination by Case Study in Well B of Azadegan South Oil Field; *Environmental Sciences*. 19 (2), 111-126. (In Persian with English abstract)

Sarkheil, H., Hassani, H. and Alinia, F., 2009a. The fracture network modeling in naturally fractured reservoirs using artificial neural network based on image logs and core measurements. *Australian Journal of Basic and Applied Sciences*. 3 (4), 3297-3306.

Sarkheil, H., Azimi, Y. and Rahbari, S., 2018.



Fuzzy Wastewater Quality Index Determination for Environmental Quality Assessment under Uncertain and Vagueness Conditions. *International Journal of Engineering*, 31 (8), 1196-1204

Sarkheil, H., Hassani, H. and Alinia, F., 2013. Fractures distribution modeling using fractal and multi-fractal–neural network analysis in Tabnak hydrocarbon field, Fars, Iran. *Arabian Journal of Geosciences*. 6, 945-956.

Sarkheil, H., Hassani, H., Alinya, F., Enayati, A.A. and Motamedi, H., 2009b. A Forecasting System of Reservoir Fractures Based on Artificial Neural Network And Borehole Images Information- Exemplified by reservoir Fractures in Tabnak Feild, Iran, *International Multidisciplinary Scientific GeoConference: SGEM: 1:563, Surveying Geology & Mining Ecology Management (SGEM)*.

Xua, T., Wang, L., Wang, X., Li, T. and Zhan, X., 2018. Heavy metal pollution of oil-based drill cuttings at a shale gas drilling field in Chongqing, China: A human health risk assessment for the workers, *Ecotoxicology, and Environmental Safety*. 165, 2018, 160-163.



Environmental Sciences Vol.21 / No.1 / Spring 2023

163-180

Original Article

Assessment of cutting and drilling mud heavy metals and organic matter contamination using limit learning regression algorithm technique of artificial intelligence in one of the oil fields of Southern Iran

Saeid Ahadi,¹ Andisheh Alimoradi,¹ Hamid Sarkheil,^{2*} Mahyar Kalhor Mohammadi³ and Mahdi Fathi¹

¹ Department of Mining Engineering, Imam Khomeini International University, Qazvin, Iran

² Department of Applied Geology, Faculty of Earth Sciences, Kharazmi University, Tehran, Iran

³ Drilling Waste Management Unit, Pars Drilling Fluids (PDF) Company, Tehran, Iran

Received: 2021.01.30 Accepted: 2021.07.16

Ahadi, S., Alimoradi, A., Sarkheil, H., Kalhor Mohammadi, M. and Fathi, M., 2023. Assessment of cutting and drilling mud heavy metals and organic matter contamination using limit learning regression algorithm technique of artificial intelligence in one of the oil fields of Southern Iran. *Environmental Sciences*. 21(1): 163-180.

Introduction: The process of extraction and exploitation of oil and gas resources requires the cycle of production, sending, and recycling of drilling mud or drilling fluid, so achieving the right combination of drilling mud and its recycling is an essential and fundamental matter in the industrial oil and gas and also the environment.

Material and methods: Determining the level of contamination of heavy metals and organic matter in the drilling mud and drilling cuttings can be necessary so that intelligent methods to estimate these contaminants can be indirectly effective. This study tried to estimate the contamination rate of drilling cuttings, despite the formation parameters of 10 oil wells drilled at different depths (66 data sets), using the regression learning limit of an artificial neural network.

Results and discussion: A total of 60 data sets were prepared to estimate the rate of change in the concentration of heavy metals, polycyclic aromatic hydrocarbons in the learning and testing process, and another six sets of data related to a well that was randomly selected and used in the artificial neural network validation process. Limit learning regression algorithm for ten heavy elements and ten aromatic compounds contaminating cutting

* Corresponding Author: *Email Address*. sarkheil_h@yahoo.co.uk

and drilling mud on two different data sets in a drilling area in one of the oil fields in southern Iran was evaluated.

Conclusion: The results are suitable for estimating the contamination of drilling cuttings and subsequent environmental protection processes. Such processes of contamination and recycling of drilling mud will play an efficient role.

Keywords: Heavy metals, Polycyclic aromatic hydrocarbons, Drilling cutting, Limit learning regression.