


بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ



دانشگاه صنعتی شاهرود

دانشکده مهندسی معدن، نفت و ژئوفیزیک

گروه مهندسی نفت، حفاری و بهره برداری

پایان نامه کارشناسی ارشد

تعیین درجه فرسایش مته با استفاده از دو مدل سیستم استنتاج تطبیقی نرو - فازی و

ژنتیک الگوریتم

سیاوش اصغری رودسری

اساتید راهنما:

دکتر مهرداد سلیمانی منفرد

دکتر بهنام میرشکاری

آذر ۱۳۹۴

شماره: ۴۴۴۱۶۳۴-۲
تاریخ: ۲۵/۱۲/۹۴
ویرایش:

باسمه تعالی



مدیریت تحصیلات تکمیلی

فرم شماره ۶: صورتجلسه دفاع از پایان نامه تحصیلی دوره کارشناسی ارشد

با تأییدات خداوند متعال و با استعانت از حضرت ولی عصر (عج) ارزیابی جلسه دفاع از پایان نامه کارشناسی ارشد آقای سیاوش اصغری رودسری به شماره دانشجویی ۹۲۰۲۲۲۴، رشته مهندسی نفت گرایش حفاری و بهره برداری چاه‌های نفت و گاز تحت عنوان «درجه فرسایش مته با استفاده از دو مدل سیستم تطبیقی نروفازی و ژنتیک الگوریتم» که در تاریخ ۱۳۹۴/۱۰/۲۷ با حضور هیأت محترم داوران در دانشگاه صنعتی شاهرود برگزار گردید به شرح ذیل اعلام می‌گردد:

قبول (با درجه: بسیار خوب) امتیاز: ۱۵ ☒ / ☐ دفاع مجدد ☐ / ☐ مردود

- ۱- عالی (۲۰ - ۱۹) ۲- بسیار خوب (۱۸/۹۹ - ۱۸) ۳- خوب (۱۶ - ۱۷/۹۹) ۴- قابل قبول (۱۵/۹۹ - ۱۴) ۵- نمره کمتر از ۱۴ غیر قابل قبول

عضو هیأت داوران	نام و نام خانوادگی	مرتبه علمی	امضاء
۱- استاد راهنمای اول	دکتر مهرداد سلیمانی منفرد	استادیار	
۲- استاد راهنمای دوم	دکتر بهنام میرشکاری	استادیار	
۳- استاد مشاور			
۴- نماینده شورای تحصیلات تکمیلی	دکتر سوسن ابراهیمی	استادیار	
۵- استاد ممتحن اول	دکتر بهزاد تخم‌چی	دانشیار	
۶- استاد ممتحن دوم	دکتر احمد رمضان زاده	استادیار	

رئیس دانشکده:
وزارت علوم، تحقیقات و فناوری
دانشگاه صنعتی شاهرود

تقدیم به سه وجود مقدس:

آنان که ناتوان شدند تا ما به توانایی برسیم ...

موهایشان سپید شد تا ما روسفید شویم ...

و عاشقانه سوختند تا گرمابخش وجود ما و روشنگر راهمان باشند ...

پدرانمان

مادرانمان

استادانمان

تشکر و قدردانی:

بر خود لازم می دانم از زحمات استاد گرانقدر جناب آقای دکتر سلیمانی که در تمامی مراحل این پایان-

نامه مرا صمیمانه یاری کردند، تشکر نمایم.

همچنین از جناب دکتر میرشکاری که با وجود تمام مشغله‌های کاری به عنوان ریاست حفاری شرکت

پترو گوهر فرا ساحل کیش که اینجانب را راهنمایی نمودند کمال تشکر و قدردانی را دارم.

امیدوارم خداوند منان توانی عطا فرماید تا بتوانم کمی از محبت عزیزان را جبران کنم.

تعهد نامه

اینجانب سیاوش اصغری رودسری دانشجوی دوره کارشناسی ارشد رشته مهندسی نفت دانشکده معدن، نفت، ژئوفیزیک دانشگاه شاهرود نویسنده پایان نامه تعیین درجه فرسایش مته با استفاده دو مدل سیستم استنتاج تطبیقی نروفازی و ژنتیک الگوریتم تحت راهنمایی دکتر سلیمانی منفرد و دکتر میرشکاری متعهد می شوم.

- تحقیقات در این پایان نامه توسط اینجانب انجام شده است و از صحت و اصالت برخوردار است.
- در استفاده از نتایج پژوهش‌های محققان دیگر به مرجع مورد استفاده استناد شده است.
- مطالب مندرج در پایان نامه تاکنون توسط خود یا فرد دیگری برای دریافت هیچ نوع مدرک یا امتیازی در هیچ جا ارائه نشده است.
- کلیه حقوق معنوی این اثر متعلق به دانشگاه شاهرود می باشد و مقالات مستخرج با نام « دانشگاه شاهرود » و یا « Shahrood University » به چاپ خواهد رسید.
- حقوق معنوی تمام افرادی که در به دست آمدن نتایج اصلی پایان نامه تأثیرگذار بوده‌اند در مقالات مستخرج از پایان نامه رعایت می گردد.
- در کلیه مراحل انجام این پایان نامه ، در مواردی که از موجود زنده (یا بافت‌های آنها) استفاده شده است ضوابط و اصول اخلاقی رعایت شده است.
- در کلیه مراحل انجام این پایان نامه، در مواردی که به حوزه اطلاعات شخصی افراد دسترسی یافته یا استفاده شده است اصل رازداری ، ضوابط و اصول اخلاق انسانی رعایت شده است.

تاریخ

امضای دانشجو

مالکیت نتایج و حق نشر

- کلیه حقوق معنوی این اثر و محصولات آن (مقالات مستخرج، کتاب، برنامه های رایانه ای، نرم افزار ها و تجهیزات ساخته شده است) متعلق به دانشگاه شاهرود می باشد. این مطلب باید به نحو مقتضی در تولیدات علمی مربوطه ذکر شود.
- استفاده از اطلاعات و نتایج موجود در پایان نامه بدون ذکر مرجع مجاز نمی باشد.

چکیده :

عملیات حفاری یکی از پر هزینه‌ترین فعالیت‌ها در صنعت بالادستی نفت است. همواره کاهش هزینه‌های عملیات حفاری مورد توجه صنعت بوده است. زمان، به عنوان یکی از موثرترین فاکتورها در افزایش هزینه‌های حفاری شناخته می‌شود. اکثر هزینه‌های مرتبط با حفاری از جمله هزینه‌های پرسنلی، اجاره دکل حفاری، حمل و نقل و تغذیه به طور مستقیم با افزایش زمان در حفر یک چاه افزایش می‌یابد. عواملی از قبیل: از دست دادن مته درون چاه، کاهش نرخ نفوذ، مانده‌یابی، تغییر مسیر چاه به دلیل از دست رفتن مسیر اصلی، گیر لوله‌های حفاری به دلیل اختلاف فشار نیز از جمله عوامل تاثیر گذار در تاخیر عملیات حفاری مد نظر قرار می‌گیرند. روش سنتی کنترل شرایط فرسایش مته نیازمند متوقف کردن عملیات حفاری و بیرون راندن مته می‌باشد. توقف عملیات حفر چاه و بیرون کشیدن مته مستلزم صرف زمان و هزینه است. از طرفی ادامه حفاری توسط مته‌هایی با قدرت برندگی کم، موجب بیشتر شدن زمان حفر مترژ مشخصی از چاه و در نهایت نرخ نفوذ حفاری خواهد شد. ارائه مدلی مبتنی بر تجربیات مته‌های استفاده شده در چاه‌های مجاور، برای آگاهی از شرایط مته در حین حفاری کمک شایانی به مهندسين حفار خواهد کرد. در این پایان‌نامه مدل‌های جدیدی براساس سیستم استنتاج تطبیقی فازی - عصبی و مدل شبکه عصبی طبقه بندی با به کارگیری الگوریتم ژنتیک به عنوان الگوریتم بهینه‌ساز در پیش بینی درجه فرسایش مته ارائه می‌شود. مدل‌های مدنظر سعی دارد، علاوه بر طرف کردن محدودیات مدل‌های گذشته، مقایسه‌ای بین منطق فازی و شبکه عصبی مصنوعی داشته باشد. داده‌های عملیات حفاری به دست آمده از سی چاه حفر شده در یک میدان جمع آوری شده است. پارامترهای ثبت مته از جمله: نوع مته، عمق ورودی مته، عمق خروجی مته، زمان حفاری مته، نرخ نفوذ حفاری، وزن روی مته، سرعت چرخش مته و دبی گل، به عنوان ورودی‌های مدل و درجه فرسایش مته به عنوان خروجی معرفی می‌شود. دستیابی به ضریب همبستگی داده‌های آزمون ۰/۹۶۴۴۴ برای مدل شبکه عصبی - الگوریتم

ژنتیک در طبقه بندی خروجی‌های شبکه، و ضریب همبستگی ۰/۹۷۸۴۱ برای مدل استنتاج تطبیقی

فازی – عصبی، کارآمدی این دو مدل را در تعیین درجه فرسایش مته نشان می‌دهد.

کلمات کلیدی: سیستم استنتاج تطبیقی فازی – عصبی، الگوریتم ژنتیک، شبکه عصبی، فرسایش مته

مقاله مستخرج از پایان نامه:

• مقاله کنفرانسی

اصغری، س.، سلیمانی، م.، (۱۳۹۳). کاربرد سیستم استنتاج تطبیقی فازی- عصبی در تعیین درجه فرسایش مته حفاری. سومین همایش ملی نفت و گاز و صنایع وابسته، دانشگاه باهنر کرمان.

فهرست مطالب

۱	فصل اول (کلیات).....	۱
۱-۱	مقدمه:.....	۲
۲-۱	پیشینه تحقیق:.....	۳
۳-۱	ضرورت انجام تحقیق :	۴
۴-۱	اهداف :	۵
۵-۱	ساختار پایان نامه:	۶
۲	فصل دوم (پارامترهای حفاری).....	۷
۱-۲	مقدمه:.....	۸
۲-۲	پارامترهای حفاری :	۸
۱-۲-۲	نرخ نفوذ حفاری:.....	۹
۲-۲-۲	اثر پایین نگه داشتن خرده‌های حفاری:.....	۹
۳-۲-۲	نوع مته :	۱۰
۴-۲-۲	هیدرولیک مته :	۱۱
۵-۲-۲	وزن روی مته :	۱۴
۶-۲-۲	سرعت چرخش مته :.....	۱۷
۷-۲-۲	دبی جریان گل:.....	۱۸
۸-۲-۲	فرسایش مته :	۱۸
۳-۲	درجه بندی فرسایش مته مخروطی:	۱۹
۴-۲	جمع بندی:.....	۲۰
۳	فصل سوم (پیشینه تحقیق)	۲۱
۱-۳	مقدمه	۲۲
۲-۳	عیب‌یابی مته‌های حفاری با استفاده از شبکه عصبی:.....	۲۲
۳-۳	بهینه‌سازی پارامترهای حفاری جهت انتخاب بهترین مته:	۲۳

۴-۳	مدل تشخیص عمر دندان و شکست یاتاقان مته	۲۶
۵-۳	مدل فرسایش یاتاقان برای مته های مخروطی	۲۹
۶-۳	مدل ارزیابی شرایط فرسایش زود رس مته	۳۰
۷-۳	تشخیص فرسایش مته بر اساس مدل بیلگسو در ایران	۳۳
۸-۳	جمع بندی:	۳۴
۴	فصل چهارم (داده ها و روش کار پایانه نامه)	۳۷
۱-۴	مقدمه:	۳۸
۲-۴	روش جمع آوری اطلاعات:	۳۸
۳-۴	معرفی میدان:	۴۰
۴-۴	ناسازگاری ها و داده های پرت:	۴۳
۱-۴-۴	تعریف داده پرت:	۴۴
۲-۴-۴	داده های پرت سراسری:	۴۴
۳-۴-۴	داده های پرت حوض های:	۴۴
۴-۴-۴	داده پرت گروهی:	۴۵
۵-۴	تشخیص داده های پرت:	۴۶
۱-۵-۴	روش نظارت شده:	۴۶
۲-۵-۴	روش غیر نظارت شده:	۴۶
۳-۵-۴	روش نیمه نظارت شده:	۴۷
۶-۴	روش شناسی تشخیص داده پرت در پایان نامه:	۴۷
۷-۴	روش کار طراحی سیستم های هوشمند در پایان نامه:	۴۹
۱-۷-۴	مدل اول: توسعه مدل الگوریتم ژنتیک و شبکه عصبی تشخیص الگو:	۴۹
۱-۱-۷-۴	بارگذاری داده ها:	۵۰
۲-۱-۷-۴	تقسیم داده ها:	۵۰
۳-۱-۷-۴	نرمال سازی داده:	۵۰

۴-۱-۷-۴	ساختار شبکه:	۵۱
۴-۱-۷-۵	آموزش شبکه عصبی با استفاده از الگوریتم ژنتیک:	۵۱
۴-۷-۲	مدل دوم: سیستم استنتاج تطبیقی نرو - فازی:	۵۴
۴-۷-۳	سیستم استنتاج تطبیقی فازی - عصبی:	۵۴
۴-۷-۳-۱	ساختار انفیس:	۵۵
۴-۷-۳-۲	ساخت مدل انفیس:	۵۷
۴-۷-۳-۳	طراحی انفیس:	۵۸
۴-۸	جمع بندی:	۶۰
۵	فصل پنجم (یافته‌های پژوهش)	۶۱
۵-۱	مقدمه:	۶۲
۵-۲	نتایج به کارگیری معیار t_2 روی مجموعه داده:	۶۲
۵-۳	پیاده‌سازی مدل شبکه عصبی و الگوریتم ژنتیک و بحث بر روی نتایج:	۶۴
۵-۳-۱	نتایج آموزش مدل شبکه عصبی و الگوریتم ژنتیک:	۶۴
۵-۳-۲	نتایج آزمایش مدل شبکه عصبی و ژنتیک:	۶۵
۵-۴	پیاده‌سازی مدل سیستم استنتاج تطبیقی فازی - عصبی و بحث بر روی نتایج:	۶۷
۵-۴-۱	نتایج آموزش مدل سیستم استنتاج تطبیقی فازی - عصبی:	۶۷
۵-۴-۲	نتایج آزمایش مدل استنتاج تطبیقی فازی - عصبی:	۶۹
۶	فصل ششم (نتیجه گیری و پیشنهادات)	۷۳
۶-۱	نتیجه گیری:	۷۴
۶-۲	پیشنهادهای:	۷۵
منابع		۷۷

فهرست اشکال

- شکل (۱-۲): تاثیرات پایین نگه داشتن خرده حفاری [۱۴]. ۱۰
- شکل (۲-۲): گردش منظم [۱۸]. ۱۳
- شکل (۳-۲): گردش سیال با جت نازل [۱۸]. ۱۳
- شکل (۴-۲): توصیف شماتیکی رشته حفاری در دو حالت معلق و ته چاهی [۲۱]. ۱۴
- شکل (۵-۲): تاثیر وزن روی نرخ نفوذ [۱۸]. ۱۶
- شکل (۶-۲): تاثیر سرعت چرخش روی نرخ نفوذ [۱۸]. ۱۷
- شکل (۷-۲): شماتیک دندان مته در حالات مختلف ساییدگی [۱۸]. ۱۹
- شکل (۱-۲): ساختار شبکه عصبی مورد استفاده اهرات [۲۴]. ۲۳
- شکل (۱-۳): طرح کلی آموزش و خروجی پیش بینی شده شبکه [۲۵]. ۲۴
- شکل (۲-۳): داده‌های آزمایش و خروجی پیش بینی شده توسط شبکه [۲۵]. ۲۵
- شکل (۴-۳): مته‌های انتخاب شده توسط شبکه عصبی در اعماق مختلف [۲۵]. ۲۶
- شکل (۵-۳): نمودار رگرسیونی فرسایش دندان مته برای داده‌های میدانی و پیش بینی شده [۲۶]. ۲۷
- شکل (۶-۳): نمودار رگرسیونی فرسایش یاتاقان مته برای داده‌های واقعی و پیش بینی شده [۲۶] ... ۲۸
- شکل (۷-۳): نمودار رگرسیونی داده‌های میدانی برای پیش بینی عمر مته [۲۶]. ۲۸
- شکل (۸-۳): تخمین فرسایش یاتاقان مته با کد ۵۱۷ توسط مدل [۲۷]. ۳۰
- شکل (۹-۳): تخمین فرسایش یاتاقان مته با کد ۴۳۷ توسط مدل [۲۷]. ۳۰
- شکل (۱۰-۳): ساختار شبکه عصبی کوهن [۲۸]. ۳۲
- شکل (۱-۴): نمودار فراوانی داده‌های عملیاتی. ۳۹
- شکل (۲-۴): داده پرت ۲ در یک دمای سری زمانی، [۳۲]. ۴۵
- شکل (۳-۴): نمایش داده های پرت گروهی توسط نوار قلب [۳۳]. ۴۶
- شکل (۴-۴): فرایند آموزش مدل الگوریتم ژنتیک - شبکه عصبی. ۵۳
- شکل (۵-۴): ساختار انفیس با دو ورودی [۴۲]. ۵۶
- شکل (۶-۴): تابع عضویت گوسی [۴۲]. ۵۶
- شکل (۱-۵): پراکندگی داده‌ها براساس دو مولفه اصلی. ۶۳

- شکل (۲-۵): نمایش تعدادی از داده‌های جدا شده از مجموعه داده‌ها ۶۳
- شکل (۳-۵): ماتریس طبقه‌بندی اطلاعات درجه فرسایش مته در حالت ثبت شده سر چاهی و مقادیر پیش بینی شده توسط مدل شبکه عصبی ۶۴
- شکل (۴-۵): نمودار رگرسیون برای دسته خروجی‌های تعیین شده توسط مدل و دسته‌های واقعی میدانی ۶۵
- شکل (۵-۵): ماتریس طبقه‌بندی اطلاعات درجه فرسایش مته در حالت واقعی و مقادیر دسته بندی شده توسط مدل شبکه عصبی برای داده های آزمایش ۶۶
- شکل (۶-۵): نمودار رگرسیون برای دسته خروجی‌های تعیین شده توسط مدل و دسته‌های واقعی میدانی ۶۷
- شکل (۷-۵): مقایسه درجه فرسایش مته در حالت واقعی و مقادیر پیش بینی شده داده آموزش توسط انفیس ۶۸
- شکل (۸-۵): نمودار رگرسیونی داده درجه فرسایش مته در حالت واقعی و مقادیر پیش بینی شده توسط مدل انفیس ۶۷
- شکل (۹-۵): نمودار دامنه خطا داده‌های آموزش ۶۹
- شکل (۱۰-۵): نمودار فراوانی خطای داده‌های آموزش ۶۹
- شکل (۱۱-۵): نمودار مقایسه درجه فرسایش مته در حالت واقعی و مقادیر پیش بینی شده آزمایش توسط مدل انفیس ۶۹
- شکل (۱۲-۵): نمودار رگرسیونی داده‌های آزمایش درجه فرسایش مته در حالت واقعی و مقادیر پیش بینی شده توسط مدل انفیس ۷۰
- شکل (۱۳-۵): نمودار دامنه خطا داده‌های آزمایش ۷۱
- شکل (۱۴-۵): نمودار فراوانی داده‌های آزمایش ۷۱

فهرست جداول

- جدول (۱-۲): ساختار برنده مته های مخروطی ۱۹
- جدول (۱-۳): یک نمونه از متغیرهای ورودی و IADC پیش بینی شده توسط مته [۲۵] ۲۵
- جدول (۲-۳): نتایج مدل شبکه عصبی فیروز آبادی ۳۴
- جدول (۱-۴): نمونه از پارامترهای ثبت شده سر چاهی یا ثبت مته ۳۹
- جدول (۳-۴): ترتیب سازندها بر حسب عمق ۴۱

۱. فصل اول

کلیات

۱-۱ مقدمه:

در صنعت حفاری زمان حاصل از عملیات حفر چاه نقش تعیین کننده‌ای در هزینه‌های حاصل شده ایفا می‌کند. همواره کاهش زمان حفاری به منظور کنترل هر چه بهتر هزینه‌های ایجاد شده، یکی از دغدغه‌های صنعت می‌باشد. نرخ نفوذ حفاری یکی از فاکتورهای موثر در زمان و در نتیجه هزینه عملیات حفاری است. فرسایش مته به دلیل کمتر کردن قدرت برندگی مته باعث کاهش نرخ نفوذ حفاری خواهد بود. مته‌های مخروطی تحت تاثیر دو نوع فرسایش در یاتاقان‌ها و دندانه‌های خود قرار می‌گیرند، در این پایان‌نامه به فرسایش دندانه‌های مته پرداخته شده است. دندانه‌های مته حفاری براساس طول، بین شرایط کاملاً سالم و غیر قابل استفاده، به ترتیب بین اعداد صفر تا هشت درجه بندی می‌شوند. هر چقدر زمان حفاری با مته افزایش پیدا کند، مته تحت تاثیر فرسایش بیشتری قرار می‌گیرد. با افزایش فرسایش مته، طول دندانه‌ها کاهش پیدا کرده و در نتیجه درجه فرسایش مته بالاتر می‌رود. افزایش تدریجی درجه فرسایش مته، موجب کاهش قدرت برندگی مته برای حفاری سنگ‌های درون چاه می‌شود. روش سنتی تعیین درجه فرسایش مته، نیازمند خروج مته از داخل چاه و اندازه‌گیری مستقیم دندانه‌ها، برای آگاهی از شرایط مته می‌باشد. دستیابی به مته در حین حفاری، آگاهی از شرایط مته را برای مهندسين حفار در زمان عملیات حفر چاه مشکل می‌سازد. عدم تعیین شرایط مته در حین حفاری سبب می‌شود تا مته با وجود از دست دادن شرایط مطلوب دندانه به حفاری ادامه دهد. ادامه حفاری با شرایط نامطلوب مته از نظر ساییدگی دندانه‌ها سبب کاهش نرخ نفوذ و به تبع آن افزایش زمان حفاری می‌شود. در عملیات حفاری، افزایش زمان منجر به بیشتر شدن هزینه خواهد شد، این امر به هیچ عنوان برای صنعت مطلوب نخواهد بود.

۲-۱ پیشینه تحقیق:

با گذشت زمان احساس نیاز برای بهبود بخشیدن به عملیات حفاری افزایش یافت. مطالعات فراوانی در سال‌های اخیر برای بررسی فاکتورهای موثر در عملیات حفاری انجام شده است. همواره تلاش برای انتخاب مناسب فاکتورهای حفاری برای حفر یک چاه در شرایط مطلوب صورت می‌پذیرد. در میان مطالعات انجام شده در زمینه بهبود بخشی به عملیات حفاری، نرخ نفوذ بیشترین سهم را به خود اختصاص داده است، تا مدلهایی در رابطه با فاکتورهای موثر بر این ویژگی طراحی شود. از مهمترین مدل‌ها در زمینه نرخ نفوذ می‌توان به مدل بورگی - یانگ^۱، ماوور^۲، بینگهام^۳ و واکر^۴ اشاره کرد. این مطالعات در نهایت به یک رابطه ریاضی برای نرخ نفوذ نسبت به تعداد محدودی از پارامترهای حفاری دست پیدا کردند. عدم قطعیت موجود در روابط ریاضی به دست آمده توسط این محققین از محدودیات مطالعات آن‌ها بود. مطالعات دیگری در زمینه استفاده از شبکه‌های عصبی با روش آموزش گرادیان، به دلیل کارآمدی آنها در حل مسائل غیر خطی جهت مدل‌سازی نرخ نفوذ حفاری انجام شد، [۱-۳]. فرسایش مته به عنوان یکی از فاکتورهای موثر در کاهش نرخ نفوذ است. مطالعات و تحقیقات گسترده‌ای براساس مشاهدات میدانی و یا تحقیقات انجام شده آزمایشگاهی برای پیش‌بینی فرسایش مته در چند دهه اخیر انجام شده است. مدل‌های متنوعی بر پایه معادلات ریاضی و البته شبکه‌های عصبی انجام شده، که به برخی از آنها در ادامه اشاره خواهد شد. گال و وودز [۴]، مدل ریاضی برای تعیین وزن روی مته و سرعت چرخش مته، در زمینه افزایش بازدهی مته و در نهایت کاهش هزینه‌های حفاری برای سازندهای نرم ارائه دادند. کانینگهام [۵]، یک رابطه ریاضی مبتنی بر داده‌های آزمایشگاهی و بر اساس روابط بین فرسایش مته، نرخ نفوذ و سرعت چرخش مته، ارائه داد. این روابط همگی بیانگر کاهش قدرت مته حفاری

¹ Bourgoyne&Young

²Maurer

³Bingham

⁴Walker

و افزایش هزینه‌های حفاری براساس نرخ نفوذ در صورت افزایش ساییدگی مته می‌باشند. مشکل اصلی این روش برای تعیین فرسایش سرمته، به کارگیری وزن روی مته ثابت و سرعت چرخش مته ثابت است. با ورود ابزار نمودارگیری همزمان با حفاری، مدل‌های پیش‌بینی کننده دیگری مبتنی بر نتایج تجربی به دست آمد. هاربرت [۶]، روشی را بر پایه اطلاعات مته در زمان حفاری ارائه نمود که نیازمند تابع گشتاور مبتنی بر وزن مته می‌باشد. این معادله از داده‌های حین حفاری به دست می‌آید. عدم کارایی این معادله در شرایط تغییر وزن روی مته و همچنین تغییرات لیتولوژی، باعث عدم استقبال از آن گردید. لساگ و همکاران [۷]، به منظور آگاهی از شکست‌های یاتاقان مته درون چاه، آنالیزی بر پایه داده‌های میدانی و آزمایشگاهی ارائه دادند. تاریخچه‌ای از اطلاعات داده‌های سطحی و داخل چاه از شکست و نقص یاتاقان مته‌های مخروطی، توسط ایشان جمع‌آوری شد. سپس داده‌ها توسط اطلاعات نمودارگیری برای تاثیر تغییر لیتولوژی روی مته مورد بررسی قرار گرفت. تحقیقات آزمایشگاهی جداگانه‌ای نیز برای بررسی تاثیر مشکل یاتاقان روی سرعت مخروط‌ها، گشتاور و ایجاد حرارت انجام شد. لساگ و همکاران با بررسی داده‌های نمودارگیری و مقایسه آنها با داده‌های آزمایشگاهی، تاثیر پارامترهای متفاوت از قبیل گشتاور و وزن روی مته را روی فرسودگی یاتاقان مته مورد بررسی قرار دادند، در انتها به این نتیجه رسیدند که پیش‌بینی شرایط فرسایش یاتاقان مته در سطح از این طریق امکان پذیر نخواهد بود.

۳-۱ ضرورت انجام تحقیق :

افزایش راندمان حفاری و در نتیجه کاهش هزینه‌ها، یکی از دغدغه‌های اصلی شرکت‌های فعال در زمینه حفاری است. برای مثال در سال ۲۰۰۶ در یکی از پروژه‌های کشور مکزیک با طراحی مته مناسب و افزایش نرخ نفوذ حفاری، منجر به کاهش سه روزه در عملیات حفاری و ۱/۵ میلیون دلار آمریکا گردید، [۸]. تشخیص درجه فرسایش مته در حین عملیات حفاری بسیار با اهمیت است. طول مناسب دندان‌های مته، موجب قدرت برندگی مته درون چاه و در نتیجه نرخ نفوذ مطلوب می‌شود. با افزایش مدت

کارایی مته حفاری، دندانه‌های مته در اثر تماس با سازند ساییده، و در نتیجه قدرت برش مته کاسته می‌شود. اطلاع از شرایط دندانه‌های مته حین حفاری بدون نیاز به صرف زمان برای بیرون کشیدن مته از داخل چاه، کمک شایانی به مهندسین برای کنترل نرخ نفوذ، تسریع در عملیات حفاری و جلوگیری از حوادث ناخواسته می‌کند. تکنیک‌های متفاوتی از جمله ترکیب مدل‌های موجود انرژی مخصوص مکانیکی، انرژی سنگ و مدل مته خوری سنگ با بهره بردن از پارامترهای حفاری و لیتولوژی سازند، برای پیش بینی فرسایش مته ارائه شده است، [۹]. این تکنیک‌ها به دلیل فقدان الگوریتمی مناسب و همچنین خطای بالای روابط ریاضی در تشخیص روابط پیچیده، به خوبی توانایی انجام پیش بینی فرسایش مته را از خود نشان ندادند. در این میان ابزار هوش مصنوعی در طی چند دهه اخیر کاربردها و توانایی‌های زیادی در ساخت مدل‌های غیر خطی و پیچیده از خود نشان داده است. هوش محاسباتی را می‌توان یکی از موفق ترین این ابزارها دانست، [۱۰]. با استفاده از قدرت هوش محاسباتی در پیش بینی و بهینه سازی روابط پیچیده بین پارامترهای مختلف، سعی بر ساخت مدل جهت پیش بینی میزان فرسایش مته خواهد شد. با پیش بینی صحیحی از درجه فرسایش مته در حین عملیات حفاری بدون نیاز به خروج مته از درون چاه، می‌توان نیاز به تعویض و جابجایی مته را تشخیص داد. آگاهی از شرایط مته مانع از کاهش نرخ نفوذ حفاری و تحمیل هزینه‌های اضافی برای مانده‌یابی یا حفاری‌های جهت دار، برای گذر از مشکل پیش آمده می‌شود.

۴-۱ اهداف :

هدف از این پایان‌نامه به کارگیری قابلیت هوش مصنوعی در تخمین روابط پیچیده غیر خطی برای طراحی مدل‌هایی است، که قادر به پیش بینی صحیح از شرایط مته درون چاه با استفاده از پارامترهای ثبت شده سر چاهی به عنوان ورودی مدل باشند. به عبارت دیگر با ترکیب منطق فازی و شبکه عصبی،

شبکه عصبی و الگوریتم ژنتیک به مدل‌هایی دست یافت، که اجزا آنها نمی‌توانستند به آن برسند، و محدودیت هر کدام از آنها را در پیش بینی مسائل پیچیده غیر خطی مرتفع سازند.

در این پژوهش با دستیابی به اطلاعات ثبت شده سر چاهی بعد از بیرون آمدن هر مته از درون چاه، مجموعه داده‌های مورد استفاده برای مدل به دست خواهد آمد. با استفاده از کدنویسی در نرم افزار متلب مدل‌های مورد نظر طراحی می‌شود. در هر کدام از مدل‌ها، مجموعه داده به دسته‌های گوناگون آموزش، آزمایش تقسیم شده و مدل‌ها با استفاده از داده‌های مربوط، آموزش خواهد دید. در انتها بر اساس داده‌های آزمایش، صحت و دقت مدل طراحی شده برای پیش بینی درجه فرسایش مورد ارزیابی قرار خواهد گرفت. نتایج در انتها با یکدیگر مقایسه می‌شود تا توانایی هر کدام از مدل‌ها در پیش‌بینی میزان فرسایش مته درون چاهی مورد بررسی قرار گیرد.

۵-۱ ساختار پایان نامه:

در این فصل کلیات موضوع اعم از روش‌های استفاده شده توسط محققین پیشین، ضرورت تحقیق، اهداف و روش تحقیق به صورت کلی مورد بحث قرار گرفت. در فصل دوم به انواع پارامترهای ثبت شده سر چاهی در عملیات حفاری، انواع مته‌های حفاری، روش‌های حفاری و ارتباط این پارامترها با یکدیگر اشاره خواهد شد. در فصل سوم به معرفی هوش مصنوعی پرداخته می‌شود. داده‌های استفاده شده و روش کار پایان‌نامه در فصل چهارم اشاره و معرفی می‌شود. در فصل پنجم به بررسی نتایج به دست آمده پرداخته خواهد شد، در انتها نتایج و پیشنهادات مورد بحث قرار خواهد گرفت.

۲. فصل دوم

پارامترهای حفاری

۱-۲ مقدمه:

زمان را می‌توان به عنوان یکی از فاکتورهای موثر در افزایش هزینه در عملیات حفاری نام برد. نرخ نفوذ یکی از عوامل افزایش و کاهش زمان عملیات حفاری است. با افزایش نرخ نفوذ، سرعت حفاری افزایش و در نتیجه زمان عملیات حفاری کاهش می‌یابد. یکی از عواملی که می‌تواند نقش بسزایی در نرخ نفوذ و سرعت حفاری ایفا کند، مته و شرایط و قدرت برندگی مته استفاده شده درون چاه است.

در این فصل ابتدا به معرفی پارامترهای عملیات حفاری پرداخته شده است. انتخاب صحیح این پارامترها درحین حفاری تاثیر به سزایی در عملیات حفاری خواهد داشت. در ادامه این فصل به بحث و بررسی نوع مته‌های حفاری پرداخته خواهد شد. در صنعت حفاری، مته حفاری به عنوان یک ابزار طراحی شده برای ایجاد یک سوراخ استوانه‌ای (چاه) توسط روش‌های چرخشی حفاری در پوسته‌ی زمین، برای دسترسی و استخراج هیدروکربن‌هایی همانند نفت خام و گاز طبیعی شناخته می‌شود. در انتهای این فصل به فرسایش مته‌های حفاری و شرایط معرفی استاندارد این فرسایش اشاره خواهد شد.

۲-۲ پارامترهای حفاری :

پارامترهای حفاری به دو دسته پارامترهای قابل کنترل و غیر قابل کنترل تقسیم می‌شوند. پارامتر-های دسته اول توسط طراحی حفاری قابل کنترل می‌باشند و نسبت به پارامترهای محیط قابلیت انعطاف بیشتری دارند. تغییر در پارامترهای حفاری به عنوان پارامترهای قابل کنترل مرتبط با خواص زمین شناسی است. به دلیل شرایط اقتصادی و زمین شناسی، کنترل این عوامل نسبت به عوامل محیطی ارزانتر و قابل دسترس‌تر خواهد بود، [۱۲، ۱۱]. نوع مته، سایز مته، سرعت چرخش مته، فشار پمپ، به عنوان پارامترهای قابل کنترل توسط حفار شناخته می‌شوند، در حالیکه خواص سنگ و شرایط زمین، پارامترهای غیر قابل کنترل می‌باشند، [۱۳]. بنابراین یک مهندس حفار در منطقه عملیاتی تنها با استفاده از

پارامترهای قابل کنترل، قادر به افزایش بازدهی حفر یک چاه خواهد بود. در ادامه چندین پارامتر حفاری قابل کنترل توسط یک حفر مورد بررسی قرار خواهد گرفت.

۲-۲-۱ نرخ نفوذ حفاری:


نرخ نفوذ حفاری عبارت است از پیش روی مته حفاری درون سنگ یا سازند در واحد زمان. این پارامتر با واحد متر بر ساعت یا فوت بر دقیقه به کار برده می‌شود. این پارامتر را می‌توان به عنوان یکی از عوامل تاثیرگذار در هزینه‌های حفاری به شمار آورد. افزایش نرخ نفوذ حفاری حکایت از افزایش سرعت حفر یک چاه برای یک متر از مشخص در زمان کوتاه‌تر دارد. افزایش نرخ نفوذ حفاری در زمانی که پارامترهای دیگر حفاری در حالت ثابتی نگه داشته شده‌اند، باعث کمتر شدن زمان حفاری و در نتیجه کاهش هزینه‌های عملیات حفاری می‌شود. با بررسی نرخ نفوذ، تغییرات در لیتولوژی سازند، تراکم سنگ و یا حضور یک پدیده غیر متعارف، همچون شکاف یا وجود حفره‌هایی در سازند مشخص می‌شود. نرخ نفوذ ارتباط نزدیکی با سختی لایه‌های مورد حفاری دارد، بنابراین این پارامتر خیلی مهم، نیازمند به ثبت و تفسیر است. در ادامه به چند پارامتر تاثیر گذار روی نرخ نفوذ حفاری اشاره می‌شود.

۲-۲-۲ اثر پایین نگه داشتن خرده‌های حفاری^۱:

این رخداد در زمان ایجاد تراویده گل یا مسدود شدن شکاف‌های حفاری شده توسط مته با خرده‌های حفاری اتفاق می‌افتد. جلوگیری از ورود فاز مایع گل به داخل شکاف منجر به اعمال یک اختلاف فشار مثبت در سرتاسر سطح بالای تراشه‌های حفاری می‌شود. در واقع اختلاف فشار بین هیدرواستاتیک گل و فشار حفره به عنوان فشار پایین نگه دارنده خرده‌های حفاری نامیده می‌شود، [۱۴]. این فشار اعمال شده مانع نفوذ سیال سازند در زمان حفاری به داخل چاه می‌شود. هرچند اعمال فشار بالاتر از سطح تعادل باشد، باعث پایین نگه داشتن خرده‌های حفاری نیز خواهد شد. تاثیرات چرخش مته و گل حفاری در

^۱Chip Hole Down Effect

داخل چاه باعث خنثی شدن این نیرو، و در نتیجه بیرون کشیدن خرده‌های حفاری است، (شکل (۱-۲)). این اختلاف نیرو به عنوان یکی از تاثیر گذارترین پارامترها روی نرخ نفوذ حفاری به خصوص در سازندهای نرم خواهد بود.



شکل (۱-۲): تاثیرات پایین نگه داشتن خرده حفاری [۱۴].

۳-۲-۲ نوع مته :

برای انتخاب صحیح مته، اطلاع از وضعیت کمی و کیفی فراسایش مته در چند چاه اطراف بسیار حائز اهمیت می‌باشد، [۱۵]. انتخاب نوع مته حفاری جزو اساسی‌ترین ابزار مورد استفاده در فرایند حفر یک چاه به شمار می‌آید و تاثیر بسزایی بر نرخ نفوذ حفاری دارد. در موارد استفاده از مته‌های مخروطی در یک سازند نرم، مته‌هایی با دندان‌های بلند و زاویه انحراف^۱ زیاد، نرخ نفوذ مناسب‌تری نسبت به سازندهای سخت خواهند داشت. دندان‌های بلند در سازندهای سخت ساییده و نرخ نفوذ را کاهش می‌دهند. مته‌های سایشی برای دستیابی به نرخ نفوذ با استفاده از شکست گوه ای^۲ سنگ طراحی شده‌اند. چرخش مته وابسته به تعداد برندها و زاویه‌ی انتهایی این برندها است. عرض و تعداد تیغه‌ها برای تعیین تعداد

^۱ Cone offset angel

^{۲۲} Wedging failure

مناسب برنده‌ها مورد ارزیابی قرار می‌گیرد. کمترین هزینه‌های حفاری بر حسب عمق، با دستیابی به دندانه های بلند که دارای پایداری طولانی‌تر، با استحکام بیشتر یا تاقان مته در شرایط عملیاتی حاصل خواهد شد. انتخاب مته مناسب برای حفاری یک سازند، به دلیل تنوع مته‌های موجود کار ساده‌ای نیست و عوامل متفاوتی همانند: هزینه حفاری بر حسب مترژ، وزن روی مته، نرخ نفوذ و مته خوری سنگ را شامل می‌شود، [۱۶].

۴-۲-۲ هیدرولیک مته :

برای خروج کارآمد خرده‌ها در حین حفاری چندین عامل برای دستیابی به یک پاک‌سازی مناسب برای چاه نیاز است. بالا بردن بازدهی انتقال خرده‌ها وابسته به ایجاد انرژی کافی سیال حفاری، برای هل دادن خرده‌ها به بیرون چاه است. سیال حفاری باید قادر به معلق نگه داشتن ذرات جامد باشد، [۱۷]. هیدرولیک مته را می‌توان به عنوان یک فاکتور تاثیرگذار در تمیزسازی انتهایی چاه نام برد. هر چه سرعت حفاری بیشتر باشد، مقدار خرده‌های حفاری تولید شده بیشتر است، بنابراین به انرژی هیدرولیکی بیشتری جهت انتقال خرده‌های حفاری به سطح نیاز است. در صورت عدم انتقال خرده‌های حفاری به سطح زمین، این خرده‌ها اطراف مته را می‌پوشانند. با طراحی اندازه نازل‌های مته می‌توان انرژی هیدرولیکی لازم جهت انتقال خرده‌های حفاری را فراهم نمود. هیدرولیک مته علاوه بر پاک‌سازی ته چاه باعث خنک شدن مته نیز می‌شود. انواع اولیه مته‌های مخروطی دارای یک سیستم گردش منظم با یک تا سه سوراخ در مرکز مته بودند. در این مته‌ها سیال کار شستشوی را از مرکز مته انجام می‌داد، همانند آنچه در شکل (۲-۲) مشاهده می‌کنید. این نوع سیستم گردش به دلیل اینکه سیال را به صورت مساوی بین دندانه‌های داخلی و خارجی پخش نمی‌کرد، زیاد کارآمد نبود. یک نوع کارمدر مته‌های سنگی با جت نازل^۱ در سال ۱۹۴۲ معرفی شد، (شکل (۲-۳)). جت نازل یک پیشرفت مهم در هیدرولیک مته بود.

¹ Jet nozzle

امروزه نازل مته به عنوان یک سیستم استاندارد در مته‌های مخروطی مورد استفاده قرار می‌گیرد. هدف سرعت بالای جت سیال به این دلیل است که قادر به تمیز نگه داشتن دندانه‌های مته در انتهای چاه باشد. سیال اغلب در مسیر حرکتی درون چاه منجر به خنک کردن یاتاقان مته نیز خواهد شد. جت مته دارای سه نازل می‌باشد. این نازل‌ها در دیواره کنار کاج مته روی هر کدام از بازوها قرار گرفته است، سایز آنها براساس بازدهی خواسته شده از هیدرولیک مته قابل تغییر می‌باشد، [۱۶]. امکان قرارگیری یک جت اضافی نیز در مرکز مته وجود دارد. این جت مانع از گلی شدن مته^۱ و کاهش نرخ نفوذ می‌شود. سیستم‌های هیدرولیک در دو حالت هدفدار یا خنثی، در کاربردهای خاص مورد استفاده قرار می‌گیرد. پیکربندی خنثی برای سیستم هیدرولیک، به این معنی است که نازل، سیال را بین کاج به سمت گوشه‌ی دیواره چاه هدایت خواهد کرد. پیکربندی هدفدار، حالتی است که نازل‌ها در موقعیتی قرار می‌گیرند تا سیال ناحیه‌های کنار چاه و دندانه‌های نزدیک به آن را تمیز کند. گاز و هوای فشرده را می‌توان به عنوان سیال، توسط جت نازل و مته‌های با قابلیت گردش منظم به کار برد.

سه نوع از جت نازل‌ها وجود دارند:

- جت نازل پوششی^۲

بیشترین مقاومت را در برابر فرسودگی و یا آشفستگی بیش از حد فراهم می‌کند

- جت نازل استاندارد^۳

در مواردی که خوردگی از اهمیت زیادی برخوردار نیست استفاده می‌شود.


- جت نازل هوا^۴

^۱ balling


^۲ shrouded nozzle jets

^۳ standard jet nozzels

^۴ air jet nozzels



شکل (۲-۳): گردش سیال با جت نازل [۱۸]



شکل (۲-۲): گردش منظم [۱۸]

مشاهد ویژگی‌های اشاره شده هیدرولیک در مته‌های الماسی نقش پررنگ‌تری نسبت به مته‌های مخروطی ایفا می‌کند، [۱۹]. یک مته پلی کریستالین الماس مصنوعی^۱ (PDC) برای دستیابی به یک هیدرولیک مناسب ۶ تا ۹ نازل دارد. سرعت نازل برای بهینه کردن خواص هیدرولیک مورد محاسبه قرار می‌گیرد. این کار توسط معادله زیر انجام می‌شود، [۲۰].

$$V_n = \frac{418.3 \cdot Q}{\sum d_j^2} \quad (۱-۳)$$

V_n سرعت نازل (فوت بر ثانیه)، Q دبی جریان (گالن بر دقیقه) و d_j سایز نازل (اینچ) می‌باشد. جت نازل که امروزه به عنوان یک سیستم استاندارد در مته‌های مخروطی استفاده می‌شود، بخش اصلی هیدرولیک مته است. در زیر به پارامترهای دیگری که نقش مهمی در سیستم هیدرولیک مته دارند، اشاره شده است:

- ویژگی‌های سیال حفاری، وزن گل (پوند بر گالن)
- فشار رها شده از جت نازل


^۱ Polycrystalline Diamond Compact

- سطح کلی جریان

مته‌های الماس مصنوعی در مقایسه با مته‌های مخروطی بیشتر از سه نازل برای تمیز کردن اطراف مته استفاده می‌کنند. سایز و طراحی مته مشخص کننده‌ی تعداد نازل‌ها و جهت آن می‌باشد.

۵-۲-۲ وزن روی مته :

یک رشته حفاری درون یک چاه عمودی همراه با هوک^۱ یا قلاب در شکل (۴-۲) نشان داده شده است. رشته حفاری غالباً شامل لوله‌های حفاری و ابزار ته چاهی^۲ است. حمل مته توسط رشته حفاری انجام، و توسط قلاب از بالای دکل آویخته می‌شود. در بخش الف شکل (۴-۲)، رشته حفاری با فاصله از انتهای چاه قرار دارد. در این حالت تمام بار رشته حفاری روی قلاب قرار می‌گیرد. در این شرایط تمام رشته حفاری در معرض کشش قرار گرفته است. کمترین کشش روی مته و بیشترین کشش در بالاترین نقطه‌ی رشته حفاری اعمال می‌شود.



شکل (۴-۲): توصیف شماتیکی رشته حفاری در دو حالت معلق و ته چاهی [۲۱]

¹ Hook

² Bottom hole assembly

قسمت ب شکل (۲-۴) رشته حفاری را در حالت قرارگیری در انتهای چاه نشان می‌دهد. در این حالت وزن بخشی از طول رشته که در حالت فشارشی پایین‌تر از نقطه خنثی قرار دارد، روی مته اعمال می‌شود. وزن روی قلاب در وضعیتی که مته در انتها چاه قرار دارد، نسبت به حالت معلق مته، به اندازه‌ی وزن روی مته کمتر خواهد بود.

برآورد وزن روی مته بر اساس اندازه گیری‌های سطحی در چندین گام صورت می‌پذیرد. گام اول محاسبه وزن پایا رشته حفاری^۱ (swds) می‌باشد. برای محاسبه وزن پایا رشته حفاری، نیاز به آگاهی از چند عامل وجود دارد:

- شیب چاه
- وزن اجزاء رشته حفاری
- چگالی سیال حفاری برای محاسبه ضریب شناوری


برای محاسبه وزن پایا رشته حفاری، معادلات استاندارد مورد استفاده قرار می‌گیرد. زمانی که مته در حالت معلق و سپس در انتهای چاه قرار می‌گیرد، یک طول کوتاهی به رشته حفاری اضافه شده و موقعیت ابزار ته چاهی تغییر می‌کند. به همین دلیل نیاز به محاسبه دوباره وزن رشته حفاری پایا در حالتی که مته برای ادامه حفاری در انتهای چاه قرار دارد، وجود خواهد داشت. غالباً در حفاری زیر سطح تعادلی، چگالی سیال حفاری متغیر خواهد بود، بنابراین باید ضریب شناوری^۲ مورد محاسبه قرار گیرد. در طول عملیات حفاری، واحدهای نمودارگیری گل همه داده‌های مورد نیاز را ثبت می‌کنند. عمق چاه و عمق مته، برای آگاهی از شرایط قرارگیری مته درون چاه نیاز است. عمق چاه مرتبط با عمق انتهایی حفاری شده می‌باشد. اگر مته هنوز به انتهای چاه نرسیده باشد رشته حفاری به سمت پایین حرکت کرده، اندازه بار قلاب با وزن رشته حفاری پایا مورد مقایسه قرار می‌گیرد، اختلاف مقادیر بدین معنی می‌باشد

¹ Static Weight of Drill String

² Buoyancy Factor

که فاقد نیروی اصطحکاک محوری است، و هندسه چاه عمودی خواهد بود. مته در انتهای چاه، بخشی از وزن رشته حفاری را متحمل خواهد شد. تحمل بخشی از وزن رشته حفاری توسط مته، کاهش در بار قلاب را به دنبال خواهد داشت. بنابراین مقادیر انتهایی وزن روی مته، مستقیم از اندازه گیری بار قلاب در سطح برای یک چاه عمودی قابل اندازه گیری می‌باشد، [۲۱].


اثر وزن روی مته بر سرعت حفاری در سنگ‌های مختلف متفاوت است. وزن روی مته یک فاکتور موثر در افزایش سرعت حفاری می‌باشد. برای سازندهای نرم سرعت حفاری متناسب با وزن‌های پایین روی مته می‌باشد. گاهی در سازندهای بسیار نرم بدون اعمال وزنی روی مته، حفاری فقط با انرژی هیدرولیکی گل صورت می‌گیرد. مطالعات نشان می‌دهد که با افزایش وزن روی مته، در صورت ثابت ماندن سرعت چرخش مته، نرخ نفوذ حفاری متناسب با وزن روی مته افزایش می‌یابد. اعمال بیش از حد وزن روی مته نه تنها موفق به افزایش نرخ نفوذ نخواهد شد بلکه به مته نیز صدمه وارد می‌کند، [۱۶]. دامنه وزن روی مته اغلب توسط طراحی مته تعیین می‌شود. مته برای حفاری سازندهای نرم دارای دندان‌های پراکنده و بلند می‌باشد. این مساله فضای محدودتری برای یاتاقان ایجاد کرده که در نتیجه مقاومت در برابر وزن را برای مته کاهش می‌دهد. مته‌هایی با دندان‌های کوتاه‌تر فضای بیشتری برای یاتاقان مته فراهم می‌کند و قادر به تحمل وزن بیشتری می‌باشد. شکل (۲-۵) تاثیر وزن روی مته را بر نرخ نفوذ نشان می‌دهد.



شکل (۲-۵): تاثیر وزن روی نرخ نفوذ [۱۸]

۶-۲-۲ سرعت چرخش مته :

حفاری و نفوذ در سنگ در اثر تماس مته با سنگ صورت می‌گیرد. هر چقدر تعداد تماس‌ها در یک واحد زمانی بیشتر شود مقدار انرژی که از مته به سنگ اعمال می‌شود، بیشتر بوده و سرعت حفاری افزایش می‌یابد. بنابراین هر چه سرعت دوران مته بیشتر شود، سرعت حفاری نیز افزایش پیدا می‌کند. البته رابطه خطی بین این دو پارامتر وجود ندارد و تا یک سرعت چرخش خاص افزایش سرعت حفاری مشهود است. بعد از یک مقدار مشخص، افزایش سرعت دوران تاثیر زیادی روی نرخ نفوذ ندارد، زیرا خرده‌های حفاری به موقع از چاه خارج نمی‌شوند و تمیز شدن چاه به خوبی صورت نمی‌گیرد. افزایش بیش از حد سرعت چرخش مته باعث از بین رفتن دندان‌های مته و ساییده شدن سریع آنها می‌گردد. شکل (۶-۲) تاثیر سرعت چرخش را روی نرخ نفوذ نشان می‌دهد. این شکل نشان می‌دهد که نرخ نفوذ حفاری از نقطه a به سمت نقطه b با افزایش سرعت چرخش افزایش می‌یابد، اما از نقطه b به سمت نقطه c با افزایش سرعت چرخش، نرخ نفوذ کاهش می‌یابد، [۲۲]. سرعت چرخش به وسیله یک سنسور الکترو-مگنتیک اندازه‌گیری می‌شود. غالباً این سرعت متناسب با شرایط حفاری انتخاب می‌شود. همیشه یک سرعت چرخش ثابت ترجیح داده می‌شود، زیرا مقدار بالای آن منجر به افزایش نرخ نفوذ و در نتیجه تغییرات لیتولوژی قابل شناسایی نخواهد بود.



شکل (۶-۲): تاثیر سرعت چرخش روی نرخ نفوذ [۱۸]

۷-۲-۲ دبی جریان گل:

حجم گل تزریق شده توسط پمپ حفاری بر حسب زمان، به درون چاه برای خنک سازی و بیرون راندن خرده‌های حاصل از حفاری سازند دبی جریان گل معرفی، و با واحدهای گالن بر دقیقه یا لیتر بر ساعت مشخص می‌شود. یک دبی جریان ثابت (فشار سیال) برای چاه توسط یک پمپ فراهم می‌شود. بخاطر محدودیت در قرار دادن یک مبدل نزدیک نازل مته، فشار در سطح زمین اندازه‌گیری می‌شود. میزان پمپاژ گل یکی از مهمترین پارامترها در امر تمیز سازی چاه‌های جهت‌دار به شمار می‌آید. مقادیر بالای دبی گل باعث ایجاد جریان آشفته در فضای حلقوی شده و مانع از ته نشین شدن خرده‌های حفاری می‌گردد، [۲۳].

۸-۲-۲ فرسایش مته :

در حین حفاری آگاهی از شرایط مته یا حالت فرسایش آن حائز اهمیت است. مته‌های حفاری ابتدا بر اساس طول دندانان درجه‌بندی می‌شوند. درجه صفر به مته‌های جدید تعلق می‌گیرد. با کارکرد مته در زمان حفر سازند، درجه ساییدگی مته افزایش می‌یابد. نهایتاً دندان‌های مته در درجه ۸ کاملاً از بین می‌روند. اگر یک مته بیش از اندازه مورد استفاده قرار بگیرد، بازدهی و کارآمدی خود را از دست خواهد داد. با فرسایش دندان‌های مته، سطح تماس با سازند بیشتر می‌شود، در واقع مساحتی از دندانان که باید در سازند نفوذ پیدا کند، افزایش می‌یابد که مستلزم اعمال بار بیشتری روی مته است، تا سرعت حفاری در حد متعادل باقی بماند. زمانی که یاتاقان یا دندانان مته حفاری کارایی خود را از دست بدهند، مورد تعویض قرار می‌گیرند. عمر مته براساس زمان مورد نیاز برای فرسایش کامل دندان‌های مته در نظر گرفته می‌شود. فرسایش دندان‌های مته را برای بیرون کشیدن نسبت به شرایط یاتاقان مته مد نظر قرار می‌دهند، [۱۹].

۳-۲ درجه بندی فرسایش مته مخروطی:

سیستم درجه بندی فرسایش مته های مخروطی همزمان با مته های الماس مصنوعی دز سال ۱۹۸۷ معرفی شد. درجه بندی مته های مخروطی تقریباً با مته های تیغه ثابت یکسان است، تنها در برخی از ستون ها، تفاوت هایی مشاهده می شود. با این حال، یک نسخه از نمایش شرایط فرسایش مته در گزارش- های میدانی در جدول (۱-۲) ارائه شده است.

جدول (۱-۲): ساختار برنده مته های مخروطی

توضیحات تکمیلی	فرسایش ثانویه	قطر مته	یاتاقان	موقعیت فرسایش	ویژگی فرسایش	دندانه خارجی	دندانه داخلی	پارامتر
۸	۷	۶	۵	۴	۳	۲	۱	کد

در صنعت، فرسایش دندانه مته با کدهای ۸-۰ گزارش می شود. نمایی از درجات فرسایش دندانه ها در شکل (۷-۲) نشان داده شده است. ساختار دندانه با استفاده از یک معیار طولی از صفر در حالت بدون فرسایش تا ۸ که نشان دهنده غیر قابل استفاده بودن مته است، اندازه گیری می شود. به طور مثال، اگر نصفی از ارتفاع اولیه مته ساییده شود، مته با درجه فرسایش T4 را نشان خواهد داد. این بدین معناست که $\frac{4}{8}$ دندانه را از دست داده است. فرسایش مته در اغلب موارد کامل نخواهد بود. نشان دادن درجه فرسایش با یک کد بسیار سخت می باشد، در این مواقع میانگین فرسایش دندانه کد دقیق تری را ایجاد خواهد کرد.



شکل (۷-۲): شماتیک دندانه مته در حالات مختلف ساییدگی [۱۸]

۴-۲ جمع بندی:

عملیات حفاری یکی از پرهزینه‌ترین فعالیت‌های بخش بالادستی صنعت نفت محسوب می‌شود. هرگونه فعالیت و اقدام لازم به منظور استفاده مناسب و علمی از امکانات موجود در جهت کاهش هزینه‌ها، امری اجتناب‌ناپذیر تلقی می‌گردد. از عوامل ایجاد این هزینه‌ها می‌توان به تاخیر در جابجایی و برپایی دکل حفاری، خرابی و مستهلک شدن قطعات دستگاه، عدم اعمال بار و سرعت چرخش مناسب جهت سازندهای مختلف، استفاده نامناسب از سرمت‌ها اشاره کرد. برای انتخاب صحیح مته جهت حفاری یک چاه خاص، مهندسين باید دانش عملی از انواع مته‌های موجود و نحوه صحیح استفاده از این مته‌ها را برای حفاری سازندهای نرم، سخت و مشکلاتی همچون انحراف چاه، محتوای جامد گل، اندازه چاه داشته باشند. به کارگیری از توصیف کمی و کیفی خوردگی مته‌های استفاده شده درون چاه‌های مجاور، معیار مفیدی برای انتخاب و مقدار خوردگی مته در حفر یک چاه جدید است. برای توصیف و دسته‌بندی مته‌ها، انجمن بین المللی پیمانکاران حفاری مته‌ها را با استفاده از عدد و حروف الفبا تقسیم بندی کردند. تقسیم بندی مته‌ها در کنار پارامترهای مهم حفاری به طور مختصر در این فصل مورد بررسی قرار گرفت.

۳. فصل سوم

بررسی پیشینه پژوهش

مطالعات و تحقیق‌های گسترده‌ای برای آگاهی از شرایط مته حفاری و تعیین میزان فرسایش آن صورت گرفته است. در طول چند دهه، پژوهش‌ها بر اساس مشاهدات واقعی در میدان یا تحقیقات انجام شده در آزمایشگاه منجر به ارائه مقالات و نظریات بسیاری شده است. با معرفی هوش مصنوعی به عنوان یک ابزار در مدل‌سازی سیستم‌های پیچیده‌ی غیرخطی و به کارگیری آن در مسائل موجود در صنعت نفت، نتایج قابل قبولی به دست آمده است. در ادامه، به بررسی برخی از مطالعه‌های انجام شده توسط محققین درباره تعیین میزان فرسایش مته پرداخته خواهد شد.

۲-۳ عیب‌یابی مته‌های حفاری با استفاده از شبکه عصبی:


ارهارت و همکارانش [۲۴]، تحقیقی تحت عنوان عیب‌یابی مته‌های حفاری با استفاده از شبکه عصبی تخمین‌گر ارائه دادند. در این مقاله از یک شبکه عصبی به منظور تعیین درجه فرسایش مته در حین حفاری استفاده شده است. به دلیل عدم توانایی روش‌های متداول در تولید تخمینی با کیفیت مناسب از میزان فرسایش دندانه‌های مته، یک شبکه عصبی مصنوعی با استفاده از داده‌های آزمایشگاهی برای تعیین درجه ساییدگی مته حفاری آموزش داده شد. این شبکه عصبی یک سیستم سه لایه پیش رو^۱ همراه با توابع انتقال سیگموئیدی^۲ برای تمامی گره‌ها می‌باشد. در این مدل از الگوریتم آموزشی پس انتشار خطا^۳ برای آموزش استفاده شده است. اطلاعات شامل ۱۷۳ مجموعه داده می‌باشد. هر کدام از آنها شامل مقادیر لیتولوژی، گشتاور، سرعت چرخش مته، نرخ نفوذ حفاری، وزن روی مته و نیروی هیدرولیکی گل حفاری است. در شکل (۱-۳) ورودی و خروجی شبکه نشان داده شده است. شبکه عصبی با استفاده از پنج پارامتر حفاری و پارامتر لیتولوژی به عنوان ورودی آموزش مورد استفاده قرار گرفت، سپس درجه مته به

^۱ Feedforward

^۲ Sigmoid

^۳ Back-propagation

عنوان خروجی شبکه با مقادیر واقعی درجه فرسایش مته حفاری مقایسه گردید. در مواردی که اختلافاتی وجود داشت، وزن‌های شبکه توسط الگوریتم پس انتشار خطا مجدد تنظیم می‌شود. پس از چندین مرحله تکرار، شبکه قادر می‌گردد که خروجی صحیح را برای هر مجموعه از ورودی‌ها تولید نماید. شبکه عصبی توسط کل داده‌ها آموزش دیده و سپس آزمایش شده است. تخمین مقادیر درجه مته به خوبی توسط این شبکه عصبی صورت گرفت.




شکل (۱-۲): ساختار شبکه عصبی مورد استفاده اهرات [۲۴].

۳-۳ بهینه سازی پارامترهای حفاری جهت انتخاب بهترین مته:


مقدار مناسب نرخ نفوذ کاهش چشمگیری در زمان عملیات حفاری را منجر می‌شود. اهمیت این موضوع توجه مهندسين را به منظور دستیابی به روشی برای تعیین یک مقدار بهینه از نرخ نفوذ حفاری به خود جلب کرده است. تحقیقات بسیاری در این زمینه و در پی آن انتخاب یک مته مناسب بر اساس کد-

های انجمن بین المللی پیمانکاری حفاری (IADC)^۱ که در بهترین شرایط درون چاه قرار بگیرد، انجام شده است. عاشوری [۲۵]، مدلی برای محاسبه بهینه پارامترهای حفاری جهت انتخاب بهترین مته با استفاده از روش های هوش مصنوعی ارائه داد. در این تحقیق، یک شبکه عصبی سه لایه ای تغذیه پیش رو توسعه داده شد. این شبکه شامل لایه های ورودی، نهفته و خروجی می باشد (شامل ۱۰ نرون در دو لایه اول و یک نرون در لایه خروجی است). در قدم اول آن دسته از داده هایی که به دلایل درست کار نکردن سنسورهای ثبت داده ها، تنظیم نبودن سنسورها و خطاهای رایج انسانی ثبت شده اند، فیلتر می شود. مجموعه داده های در دسترس به سه دسته تقسیم می شود. ۶۰ درصد داده ها برای تعلیم، ۲۰ درصد در فرایند تایید و ۲۰ درصد باقیمانده برای آزمایش نتایج به دست آمده به به کار برده شده اند. برای اولین مرحله طراحی یک مته مناسب براساس نرخ نفوذ دلخواه انتخاب می شود. در این مدل اندازه مته، سطح حوزه جریان، عمق ورود مته، عمق نهایی، فاصله حفاری، وزن روی مته، چرخش رشته حفاری در هر دقیقه، سرعت نفوذ، جریان گردش گل، فشار گل، میانگین استحکام فشاری سازند و وزن گل، ورودی های شبکه را تشکیل می دهند. در حالیکه IADC مته ها به عنوان خروجی تنظیم می شود. پس از انجام آموزش شبکه، شکل (۲-۳) طرح کلی آموزش و خروجی پیش بینی شده را با ضریب انطباق ۰/۹۰۶ نشان می دهد. سپس مجموعه اطلاعات خروجی آزمایش، به شبکه عصبی نشان داده می شود. نتایج داده های آزمایش در شکل (۳-۲) نشان داده شده است.



شکل (۱-۳): طرح کلی آموزش و خروجی پیش بینی شده شبکه [۲۵].

¹ International Association of Drilling Contractors



شکل (۲-۳): داده‌های آزمایش و خروجی پیش‌بینی شده توسط شبکه [۲۵]

در این روش همه پارامترهای مهم در عملکرد مته برای ساختن تابع IADC جهت فراهم کردن انتخاب مته مناسب در نظر گرفته شده‌اند. پارامترهای استفاده شده حفاری به جز مقاومت فشاری سنگ، از رکوردهای مته به دست می‌آیند. معادله تعیین مقاومت فشار سنگ با استفاده از لاگ صوتی از رابطه زیر به دست می‌آید:


$$c_o = 0.77 * \left(\frac{304.8}{\Delta t}\right)^{293} \quad (۱-۳)$$

برای بررسی نتایج به دست آمده IADC مته از مدل شبکه عصبی، یک مجموعه نمونه از متغیرهای ورودی و IADC پیش‌بینی شده مته که موافق یا سازگار با این مورد می‌باشد، آزمایش شد. نتایج مدل IADC به وسیله شبکه عصبی در جدول (۱-۳) نشان داده شده است.

جدول (۱-۳): یک نمونه از متغیرهای ورودی و IADC پیش‌بینی شده توسط مته [۲۵]

ورودی	اقت فشار	وزن ۴	سطح جریان	دبی جریان	سرعت چرخش	وزن روی مته	عمق ورودی	سایز مته	نرخ نفوذ
	۵۰۰	۷۸۷	۴۵	۷۰۰	۱۲۰	۲۱	۲۳۱	۸.۵	۴۷
خروجی	کد IADC مته ۴۰۱.۲								

بعد از به تایید رسیدن مدل به دست آمده توسط شبکه عصبی هوشمند، مته‌های انتخاب شده توسط مدل، در اعماق مختلف در شکل (۴-۳) نمایش داده شد.




شکل (۳-۴): مته های انتخاب شده توسط شبکه عصبی در اعماق مختلف [۲۵].

مدل ساخته شده برای پیش‌بینی مته مناسب، به طوری طراحی شده است که مته‌ای براساس سرعت حفاری دلخواه ارائه شود. خصوصیات سازند، عمق پمپاژ، شرایط هیدرولیک، تعداد نازل‌ها و مجموع مساحت آنها، اندازه حفره، سرعت دوران رشته حفاری و وزن روی مته، به عنوان ورودی به مدل داده می‌شود و مته متناسب با این شرایط به وسیله مدل انتخاب می‌گردد. این مطالعه رویکرد جدیدی بر مبنای داده‌های چاه‌های حفر شده برای انتخاب بهینه مته با استفاده از هوش مصنوعی ارائه داد.

۴-۳ مدل تشخیص عمر دندان و شکست یاتاقان مته


بیلگسو و همکاران [۲۶]، با به کارگیری شبکه عصبی، روشی برای پیش‌بینی فرسایش دندان‌ها و یاتاقان‌های مته ارائه دادند. در مدل آنها چندین شبکه عصبی برای پیش‌بینی میزان فرسایش دندان‌ها و یاتاقان‌های مته حفاری طراحی شد. حدود ۸۰۰۰ داده میدانی با استفاده از شبیه‌ساز حفاری به وجود آمده است. داده‌های شبیه ساز حفاری براساس تابعی از زمان برای فرسایش دندان و یاتاقان مته حفاری ساخته شد. تمامی این شبکه‌ها به صورت سه لایه می‌باشند. شبکه از الگوریتم آموزشی پس انتشار خطا استفاده شده است. مدل‌های شبکه عصبی مورد نظر در این مطالعه از هشتاد نرون مخفی، نه یا ده پارامتر ورودی و یک یا دو پارامتر خروجی تشکیل شده‌اند. شبکه عصبی اول و دوم به ترتیب برای پیش‌بینی میزان فرسایش دندان‌های مته و فرسایش یاتاقان‌های مته طراحی شده است. یک شبکه عصبی سوم نیز

برای پیش‌بینی میزان فرسایش دندان‌های مته و فرسایش یاتاقان‌های مته به طور همزمان طراحی شده است. یک مجموعه ثانویه از اطلاعات حفاری مربوط به چندین چاه در ایالات متحده برای طراحی یک شبکه عصبی جدید مورد استفاده قرار گرفت. تقریباً ۵۰۰ مجموعه اطلاعاتی از پارامترهای حفاری در این مجموعه اطلاعات وجود دارد. پارامترهای ورودی مدل بیلگسو شامل: نوع مته، طول حفاری براساس فوت، نوع سازند و نرخ جریان گل می‌باشد. لایه مخفی در این شبکه عصبی شامل ۲۴ نرون بوده و پارامتر خروجی عمر مته بر اساس زمان می‌باشد. محققین داده‌ها را در دو بخش تقسیم کردند. بخش اول داده‌ها برای طراحی و آموزش شبکه عصبی و بخش دوم برای آزمایش شبکه عصبی مورد استفاده قرار گرفته است. بخش دوم شامل ۱۰٪ کل اطلاعات می‌باشد که به صورت تصادفی انتخاب شده اند. شبکه عصبی با استفاده از داده‌های بخش اول تا زمانی که نتایج درستی تولید نماید، مورد آموزش قرار گرفت. شکل (۳-۵) مقادیر پیش‌بینی شده فرسایش دندان مته توسط مدل در برابر مقادیر واقعی برای داده‌های آزمایش را با ضریب همبستگی ۰/۹۷۷ نشان می‌دهد.




شکل (۳-۵): نمودار رگرسیونی فرسایش دندان مته برای داده‌های میدانی و پیش‌بینی شده [۲۶].

شکل (۳-۶) نتایج به دست آمده از شبکه عصبی طراحی شده دوم برای پیش‌بینی میزان فرسایش یاتاقان‌های مته را با ضریب همبستگی ۰/۹۹۷ نشان می‌دهد. این شبکه عصبی از پارامترهای مشابه با شبکه عصبی اول طراحی شده برای پیش‌بینی میزان فرسایش دندان مته، استفاده کرده است.



شکل (۳-۶): نمودار رگرسیونی فرسایش یاتاقان مته برای داده‌های واقعی و پیش بینی شده [۲۶]

شکل (۳-۷) نتایج به دست آمده از داده‌های میدانی برای پیش‌بینی عمر مته با ضریب همبستگی 0.902 را نشان می‌دهد. شرایط مته در این داده‌ها پس از خارج ساختن آن از درون چاه ثبت شده است. اگرچه دو مجموعه از داده‌های آزمایشی از خط مستقیم منحرف شده‌اند، اما باقی زمان‌های اندازه‌گیری شده داده‌ها تناسب مناسبی با داده‌های واقعی دارند.



شکل (۳-۷): نمودار رگرسیونی داده‌های میدانی برای پیش‌بینی عمر مته [۲۶]

در نتیجه بیلگسو و همکاران با توسعه چند مدل شبکه عصبی نتایج قابل قبول و موفقیت آمیزی در پیش‌بینی فرسایش دندان و یاتاقان مته به دست آوردند. استفاده از مجموعه وسیع داده‌های شبیه ساز، پوشش کاملی از شرایط متفاوت دندان‌ها و یاتاقان مته فراهم ساخت. ایجاد داده‌های شبیه‌ساز براساس تابعیت فرسایش دندان و یاتاقان مته از زمان، مدل طراحی شده را از مسیر صحیح آموزش بر اساس

شرایط میدانی منحرف کرده، و در واقع مسیر آموزش از پیش تعیین شده‌ای به مدل اعمال می‌کند. استفاده از داده‌های شبیه‌ساز را می‌توان به عنوان یک محدودیت بزرگ برای این مدل در نظر گرفت.


۵-۳ مدل فرسایش یاتاقان برای مته های مخروطی

هارلند و همکارانش [۲۷]، مدلی دیگر برای پیش بینی وضعیت فرسایش یاتاقان مته از طریق آنالیز رگرسیونی غیر خطی چند متغیره مبتنی بر داده‌های میدانی توسعه دادند. این مدل چهار متغیر وزن روی مته، چرخش مته در دقیقه، سایز مته و زمان حفاری را در بر می‌گیرد. برای تعیین بهترین رگرسیون داده‌های میدانی تعدادی از مته‌ها بر اساس شرایط نادیده گرفته شده‌اند. داده‌های بیش از ۵۰۰ مته در این مدل استفاده شده است. محققان دو پارامتر وزن روی مته و سرعت چرخش مته را به عنوان دو پارامتر مهم حفاری در رابطه با فرسایش مته معرفی کردند. در حقیقت فرسایش مته را می‌توان به عنوان فرایند پیچیده‌ای که با پارامترهای زیادی همانند نوع مته، سازند، ابزار ته چاهی و شرایط ته چاه سرکار دارد نام برد. دو پارامتر مستقل وزن روی مته و سرعت چرخش برای این مدل انتخاب می‌شوند. مدل فرسایش مته به زمان حفاری و سایز مته نیاز دارد. برای انعطاف پذیری بیشتر مدل، هر کدام از متغیرها با استفاده از ضرایب متفاوت توان دهی شده است. مدل انتهایی به صورت زیر حاصل خواهد شد:


$$B_w = K * (D_b)^a * T^b (WOB)^c * (RPM)^d \quad (۲-۳)$$

در معادله بالا پارامتر D_b قطر مته، a ضریب ثابت، k ضریب به دست آمده توسط داده‌های میدانی، T زمان حفاری، b ضریب ثابت، WOB وزن روی مته، c ضریب ثابت، RPM سرعت چرخش مته، d ضریب ثابت و B_w درجه فرسایش را معرفی می‌کند.

بعد از تعیین ضرایب توسط آنالیز رگرسیونی، مدل قادر به پیش بینی فرسایش مته خواهد بود. دو نمونه از تخمین مدل برای فرسایش یاتاقان مته در عمق‌های متفاوت در شکل‌های (۳-۸) و (۳-۹) نشان داده شده است. محدودیت این مدل در تعیین فرسایش مته در حین حفاری، مانع از توسعه بیشتر آن شد.



شکل (۳-۸): تخمین فرسایش یاتاقان مته با کد ۵۱۷ توسط مدل [۲۷]



شکل (۳-۹): تخمین فرسایش یاتاقان مته با کد ۴۳۷ توسط مدل [۲۷].

۳-۶ مدل ارزیابی شرایط فرسایش زود رس مته

سالاخوف و یامالیو [۲۸]، پژوهشی در زمینه ارزیابی شرایط فعلی سیستم حفاری به همراه پیشنهاداتی برای اصلاح پارامترهای اصلی کنترل حفاری، جهت بهبود بازدهی حین حفاری با کاهش احتمال فرسایش زودرس مته ارائه دادند. تئوری اساسی در نظریه ارائه شده بر پایه برخی از المان‌های آنالیز فراکتال^۱ همانند شبکه عصبی مصنوعی می‌باشد. بسیاری از سیستم‌های چند متغیره پیچیده، که شامل سیستم حفاری نیز می‌شوند، به صورت الگوهای نامتغیر مقیاسی^۲ یا فراکتالی خواص زمان - فضا^۳،

¹ Fractal Analysis

² Scale Invariance

³Fractality of Spatial-Time Properties

می‌باشد. بر این اساس برخی از روش‌های مهندسی برای مدل‌سازی و روش‌های عیب‌یابی، گسترش و مورد استفاده قرار گرفته‌اند.

در مطالعه سالاخوف، سیستم از اجزای حفاری (ادوات سطحی، رشته حفاری، مته حفاری و غیره) همراه با سازند در حال حفاری، تشکیل شده است. پارامترهای کنترلی حفاری، شامل پارامترهای قابل تغییر در حین حفاری مانند وزن قلاب، سرعت گردش مته، نرخ جریان گل و همچنین پارامترهایی که با کمی تاخیر تغییر می‌کنند، مانند خواص گل می‌باشد. در اینجا از یک سیستم نظارتی هوشمند استفاده شده است. در این سیستم نظارتی هوشمند از یک شاخص کلی مانند پارامتر خروجی استفاده می‌شود. این سیستم مبتنی بر شبکه عصبی به عنوان یک شاخه‌ای از هوش مصنوعی بنا نهاده شده است. این شبکه عصبی از نوع کوهنن^۱ می‌باشد. این شبکه برای کاربردهای شناسایی الگو سیستم‌های کنترل پیشرفته به کار برده می‌شود.

در پیکر بندی شبکه ارائه شده از سلول‌های عصبی قرار دادی یا کلاسیک که توسط عملگر جمع خطی اجزاء وزن نشان داده می‌شود، استفاده خواهد شد. خروجی این سلول‌های عصبی توسط فرمول زیر مشتق خواهد شد:

$$Y = F(\sum W_i * x_i) \quad (3-3)$$

در این رابطه x_i مقدار ورودی و W_i فاکتور وزنی یک ورودی مشخص را نشان می‌دهد. Y خروجی سلول عصبی و F تابع فعال‌سازی سلول را مشخص می‌کند.

در پژوهش هارلند، شبکه عصبی تنها دارای یک لایه می‌باشد که در شکل (۳-۱۰) نشان داده شده است. عملکرد شبکه به دسته‌بندی سیگنال‌های ورودی، به یک ابر فضای n بعدی^۲ تعلق دارد، برای تعداد مشخصی از دسته‌ها محدود شده است. تعداد لایه‌های سلول‌های عصبی می‌بایست با تعداد دسته‌ها،


^۱ Kohonen Neural Network

^۲ N-dimensional hyperspace

مطابقت داشته باشد. دز شبکه عصبی کوهنن کلاسیک، تابع فعال سازی هر سلول خطی بوده و به شکل زیر می باشد:

$$Y_k = D * S_k \quad (۴-۳)$$

در این رابطه Y_k خروجی نرون k ، D فاکتور تناسب، S_k جمع وزنی ورودی سلول عصبی k می باشد. معمولاً مقادیر اولیه وزن های شبکه عصبی توسط اعداد کوچک تصادفی تعیین می شوند. در شبکه کوهنن، این روش می توان به کار گرفته شود، اما به دلیل زمان بر بودن آن مطلوب نمی باشد. بنابراین روش دیگری به نام ترکیب محدب^۱ مورد استفاده قرار گرفت.



شکل (۳-۱۰): ساختار شبکه عصبی کوهنن [۲۸]

در شبکه کوهنن مقادیر ورودی باید نرمال شوند که توسط دو فرمول زیر این امر صورت می گیرد.

$$(x / (\sum |x|^2)) \quad (۵-۳)$$

نرمال سازی داده های ورودی باعث افزایش سرعت آموزش شبکه عصبی می گردد. فرآیند آموزش شبکه عصبی توسط یک حلقه ای تکراری در چند مرحله صورت می پذیرد. فاکتورهای وزن به دست آمده برای نرون ها توسط رابطه زیر اصلاح خواهد شد:

$$w_m = w_m + a * (x_m - w_m) \quad (۶-۳)$$

¹ Convex Combination

در این رابطه w_m فاکتور وزنی ورودی m ، x_m مقدار ورودی m ، a سرعت آموزش شبکه (معمولا عدد کوچک مثبت مورد استفاده قرار می‌گیرد) می‌باشند. انتخاب مقدار مناسب برای ضریب a ، تاثیر مهمی بر روی سرعت آموزش شبکه عصبی خواهد داشت. در این پژوهش سرعت مطلوب آموزش برابر 0.25% در نظر گرفته شده است. هدف از آموزش شبکه عصبی، یادگیری شبکه برای تولید بزرگترین سیگنال خروجی در یک نرون، برای بردارهای ورودی مشابه می‌باشد. امکان مشخص نمودن اینکه در فرایند آموزش کدام نرون چه دسته‌ای را تعریف می‌کند، غیر ممکن می‌باشد.

پس از اینکه فرایند آموزش شبکه عصبی تکمیل گردید، شبکه آماده به کار می‌باشد. فرایند شناسایی در بسیاری از موارد، مشابه با آموزش می‌باشد. در ابتدا این فرایند، یک بردار دسته‌بندی شده به عنوان ورودی به شبکه اعمال می‌گردد، پس از آن نیاز است تا تعداد نرون‌های پیروز تشخیص داده شوند که این امر نتیجه شناسایی می‌باشد.

به منظور استفاده این روش برای ارزیابی وضعیت مته، اطلاعات ضبط شده از پارامترهای عملیاتی خاص (فشار ورودی گل و وزن روی مته) دو چاه مورد استفاده قرار گرفته است. شبکه عصبی با تعیین معیارهای ورودی مورد نیاز یا به عبارت دیگر تعداد کلاس‌های k_i شروع به کار می‌کند. شبکه عصبی آموزش دیده مقدار $Y \in D_i$ را که مشخص کننده شرایط واقعی مته است را تعیین می‌کند.

۷-۳ تشخیص فرسایش مته بر اساس مدل بیلگسو در ایران

فیروز آبادی [۲۹]، در سال ۱۳۹۰ با استفاده از توانایی شبکه‌های عصبی تخمین‌گر در مدل سازی و یادگیری روابط غیر خطی و پیچیده با به کارگیری داده‌های بیش از پنجاه چاه، مدلی جهت پیش بینی میزان فرسایش دندان و یاتاقان مته حفاری ارائه داد. پارامترهای ورودی اندازه مته، عمق ورودی مته، عمق خروجی مته، طول حفاری، سرعت نفوذ مته، سرعت چرخش مته، نوع سازند و فشار پمپ در ساخت این شبکه مورد استفاده قرار گرفت. این محقق پس از انجام چندین آزمایش با ساختار و تعداد نرون‌های

متفاوت، در نهایت کمترین میزان خطا را برای یک مدل سه لایه، با الگوریتم تحت آموزش پیش رو- پس انتشار به دست آورد. لایه ورودی این مدل شامل ۱۰ ورودی، لایه ی پنهان شامل ۵۰ عدد نرون و لایه خروجی متشکل از یک نرون که نماینده یک خروجی شبکه خواهد بود. در این مدل تعداد نرون ها و لایه ها به صورت اختیاری انتخاب شده است. این مدل بر خلاف آنچه در مدل بیلگسو اتفاق افتاد، داده ها را به سه به بخش آموزش، اعتبار سنجی و آزمایش تقسیم بندی کرد. در ساخت شبکه مورد نظر ۲۰٪ داده ها به عنوان داده ی اعتبار سنجی، ۲۵٪ درصد داده ها به عنوان داده های آزمایش و مابقی داده ها به طور تصادفی به داده های آموزش اختصاص یافته است. برای جلوگیری از حفظ کردن داده ها به جای تجزیه و تحلیل که اصطلاحاً دچار بیش برآزش^۱ می شود از داده های اعتبار سنجی استفاده شد. نتایج به دست آمده از این مدل برای سه دسته از داده ها در جدول (۲-۳) آورده شده است.

جدول (۲-۳): نتایج مدل شبکه عصبی فیروز آبادی

ضریب همبستگی	میانگین مربعات خطا	درصد نمونه	پایگاه داده
۰/۹۹۸۸	۰/۰۰۰۲	۵۵	آموزش
۰/۹۷۵۶	۰/۰۰۵۹	۲۰	اعتبارسنجی
۰/۹۴۰۲	۰/۰۰۶۱	۲۵	آزمایش

۸-۳ جمع بندی:

تمام تحقیق های ارائه شده در این فصل سعی در طراحی مدل هایی کارآمد، و در عین حال قابل کاربرد در حین حفاری با کمترین خطا بودند. تحقیقات انجام شده تا به امروز در این زمینه پیش بینی فرسایش مته با چندین محدودیت روبرو می باشد. از جمله این محدودیت ها شامل، استفاده از داده های وسیع و گسترده در ساخت مدل اشاره کرد که غالباً در شرایط میدانی قابل کاربرد نیست. از طرفی استفاده از داده های شبیه ساز حفاری که خروجی به دست آمده از آن، شامل درجه فرسایش یا تاقان و دندان مته، براساس تابعی از پارامترهای ثبت شده سرچاهی است، پیش بینی و آموزش صحیح مدل را

¹ overfitting

مورد سوال قرار می‌دهد. در مدل بیلگسو، شبیه‌ساز حفاری، خروجی‌ها را به عنوان تابعی از زمان ایجاد کرده است و به عنوان خروجی واقعی در ساخت مدل استفاده می‌کند. استفاده از روش‌های آموزش گرادیان کاهشی در شبکه‌های عصبی که منجر به قرار گرفتن در نقاط مینم محلی می‌شود، از دیگر محدودیت‌های این مطالعه‌ها می‌باشد. در این تحقیق علاوه بر برطرف کردن محدودیت‌های تحقیق‌های گذشته سعی بر ساخت مدل‌های کارآمدتری دارد. این پایان‌نامه سعی دارد تا با به کارگیری تعداد چاه‌های کمتر و در نتیجه مجموعه داده‌ی کوچک‌تر مدل‌هایی ساخته شود که علاوه بر مدل مناسب نسبت به گذشته با بهره‌گیری از داده‌های کمتر، در ارتقاء قابلیت عمومیت یافتن و شناخت ماهیت مساله و در نظر گرفتن عدم قطعیت‌های موجود در پیش بینی میزان فرسایش مته گامی فراتر قرار دهد.

۴. فصل چهارم

داده‌های مورد مطالعه

و روش کار

۴-۱ مقدمه:

در سال‌های اخیر تمایلات به سمت استفاده از هوش مصنوعی برای حل مسائل واقعی گسترش یافته است. موفقیت در به کارگیری هوش مصنوعی برای مدل کردن سیستم‌های پیچیده و روابط غیر خطی مستلزم در اختیار داشتن مجموعه داده‌های مناسب، کافی و صحیح از محیط مورد مطالعه می‌باشد.

در این فصل ابتدا به توصیف داده‌های جمع آوری شده از سی چاه حفر شده در یکی از میادین نفت و گاز جنوبی پرداخته می‌شود. نوع سازندها و لیتولوژی این چاه‌ها مورد بررسی قرار خواهد گرفت. خطاهای رایج بسیاری از جمله خطاهای انسانی در جمع آوری پارامترهای حفاری سرچاهی تاثیرگذار است. روش شناسی استفاده از تکنیک حذف داده‌های پرت معرفی خواهد شد. در ادامه تکنیک استفاده شده برای حذف داده‌های پرت در این پایان‌نامه ذکر می‌شود. روش کار این پایان‌نامه برای آموزش یک شبکه عصبی توسط الگوریتم ژنتیک در این فصل معرفی می‌شود. در ابتدا به تعیین ساختار شبکه عصبی اشاره می‌شود. گام‌های مختلف در فرایند بهینه‌سازی وزن و بایاس‌های شبکه عصبی با الگوریتم ژنتیک مورد بررسی قرار می‌گیرد. در انتها طراحی و ایجاد یک مدل استنتاج تطبیقی فازی و عصبی و مراحل آموزش این مدل در پیش بینی درجه فرسایش مته اشاره خواهد شد.

۴-۲ روش جمع آوری اطلاعات:

در طی عملیات حفاری، پارامترهای مورد استفاده مته برای حفر چاه، به صورت روزانه به عنوان گزارش‌های روزانه حفاری ثبت می‌شوند. در انتهای حفر چاه، مجموعه گزارش‌های روزانه حفاری و اطلاعات هر مته در زمان حفر چاه در غالب فرمی به نام ثبت مته^۱ تهیه می‌شود. ثبت مته در واقع، تاریخچه اطلاعات کارایی مته درون یک چاه از ابتدا تا انتهای حفاری است. ثبت مته شامل اطلاعاتی از قبیل: سایز مته، نوع مته، عمق ورودی مته به درون چاه، عمق خروج مته از درون چاه، مدت زمان استفاده

¹ Bit Record

از مته درون چاه، اطلاعات هیدرولیک جریان گل و نازل مته، وزن اعمال شده روی مته، سرعت چرخش مته، نرخ نفوذ مته حفاری، فشار سازند و شرایط مته می‌باشد. یک نمونه از ثبت مته در جدول (۱-۴) نمایش داده شده است.


جدول (۱-۴): نمونه از پارامترهای ثبت شده سر چاهی یا ثبت مته

سایز مته (inch)	کد IADC	عمق ورودی (meters)	عمق خروجی (meters)	زمان حفاری (hours)	نرخ نفوذ (m/hr)	وزن روی مته (Klbs)	سرعت چرخش Rate/min	جریان (gpm)	فرسایش مته		
									I	O	R
۲۶"	۱-۱-۵	۹۷/۸	۱۷۱	۴/۵	۱۶/۲۷	۰-۵	۲۵-۹۵	۵۰۰	۱	۱	TD
۲۶"	۱-۱-۵	۱۷۱	۹۰۸	۶۰/۱	۱۲/۲۶	۱۶-۲۰	۱۳۰-۱۴۰	۴۰۰	۵	۶	DSF

پارامترهای ثبت شده حفاری غالباً در اختیار شرکت‌های سازنده مته قرار می‌گیرد. براساس این پارامترها، عملکرد مته‌های جدید ساخته شده را بهبود می‌بخشند. در واقع این اطلاعات، یکی از ارزشمندترین اطلاعات در دسترس برای مهندسين حفاری و شرکت‌های سازنده مته می‌باشد. ساخت مته توسط شرکت‌های متفاوت آمریکایی، اروپایی و آسیایی انجام می‌شود. امروزه ساخت مته در داخل کشور نیز توسط کارخانجات متفاوتی صورت می‌گیرد. فارغ از کیفیت شرکت‌های مختلف سازنده مته، تمام تولیدکننده‌ها موظف‌اند مته‌هایی براساس استانداردهای بین‌المللی ساخته و به صنعت ارائه دهند. بیشتر مته‌ها در حفر چاه‌های این میدان توسط شرکت‌های آمریکایی اسمیث^۱ و هاگز^۲ تامین شده است. نمودار فراوانی داده‌های استفاده شده در پایان‌نامه در شکل (۱-۴) آورده شده است.

^۱ Smith

^۲ Hughes



شکل (۴-۱): نمودار فراوانی داده‌های عملیاتی

۳-۴ معرفی میدان:

سازندهای حفر شده در این میدان شامل سازند آغاچاری، گچساران، آسماری، پابده، گورپی، ایلام و سروک می‌باشد. توالی این سازندها بر حسب عمق‌های پایین به سمت عمق‌های بالا در جدول (۴-۳) نشان داده شده است.

مشخصات سازندها در مسیر حفاری‌های انجام شده به شرح زیر می‌باشد:

- سازند آغاچاری:

این سازند در گذشته فارس فوقانی نامیده می‌شد. ضخامت این سازند در این محل حدود ۲۰۰۰ متر می‌باشد. سن زمین شناسی این سازند بین دوره میوسن تا پلیوسن تخمین زده شده است. این سازند با لیتولوژی از ماسه سنگ، مارن و رگه‌هایی از گچ با مته‌های حفاری در تماس است.

جدول (۳-۴): ترتیب سازندها بر حسب عمق

سازند	سر سازند(متر)-عمق
آغاجاری	۲۰۳۳- سطح
گچساران- بخش هفتم و ششم	۲۰۴۰-۲۳۰۰
گچساران- بخش پنجم	۲۳۰۰-۲۵۰۰
گچساران- بخش چهارم	۲۵۰۰-۲۷۰۰
گچساران- بخش سوم	۲۵۰۰-۲۸۰۰
گچساران- بخش دوم	۲۸۰۰-۲۹۰۰
گچساران- بخش اول	۲۹۰۰-۲۹۸۰
آسماری	۲۹۸۰-۳۳۷۰
پابده	۳۳۷۰-۳۵۸۳
گورپی	۳۵۸۳-۳۷۵۰
ایلام	۳۷۵۰-۳۸۵۰
سروک	۳۸۵۰-۴۲۰۰

• سازند گچساران:

سازند گچساران در این میدان شامل هفت بخش می‌باشد. بخش ششم و هفتم در بالای سازند گچساران با انیدریت، مارن و سنگ‌های آهکی تشکیل شده است. ضخامت این دو بخش بین ۲۵۰ تا ۳۰۰ متر است. بخش پنجم سازند گچساران به طور عمده از لایه‌های ضخیم مارن خاکستری، انیدریت و سنگ آهک در

عمق ۲۳۰۰ متری با ضخامت حدود ۲۰۰ متر در مسیر حفاری قرار می‌گیرد. بخش چهارم سازند با لایه‌های ضخیم نمکی و لایه‌های محدود انیدریت و مارن خاکستری به ضخامت ۲۰۰ متر، بالای بخش‌های دو و سه قرار دارد. بخش سوم این سازند دارای لایه‌های متناوب از مارن‌های خاکستری، انیدریت، نمک و مقدار محدودی از لایه‌های سنگ آهک در این بخش مشاهده می‌شود. بخش دوم سازند، بطور عمده، تناوبی از انیدریت و مارن خاکستری همراه با لایه‌های نمک است. این بخش از سازند مستقیم به پوش سنگ^۱ متصل است. بخش اول سازند گچساران و آخرین بخش این سازند، به عنوان اولین سنگ پوش مخزن آسماری معرفی می‌شود. این بخش شامل انیدریت و مارن خاکستری با ضخامت بین ۸۰-۱۰۰ متر می‌باشد. سن سازند گچساران به دوره میوسن پیشین می‌رسد.

• سازند آسماری:

این سازند دارای پراکندگی از لایه‌های سنگ آهک تقریباً سخت با تخلخل پایین و مارن می‌باشد. این سازند با ضخامت ۴۰۰ متر در عمق ۳۰۰۰ متری در مسیر حفر چاه واقع شده است. این سازند پس از سازند آسماری مهمترین سنگ مخزن حوضه زاگرس است. سن این سازند دوره الیگوسن تا میوسن پیشین است.

• سازند پابده:

مرزهای این سازند در این میدان با سازند آسماری به صورت تدریجی است. قسمت عمده لیتولوژی این سازند از شیل، مارن‌های خاکستری و آهک‌های رسی تشکیل شده است. این سازند در اعماق ۳۳۷۰ تا ۳۵۹۰ متری زیر سازند آسماری و بالای سازند گورپی قرار گرفته است. سن این سازند دوره پالئوسن فوقانی تا الیگوسن است.

¹ Cap Rock

• سازند گورپی:

این سازند دارای پراکندگی‌هایی از آهک مارنی، مارن خاکستری و در نهایت شامل بخشی از سنگ آهک و شیل می‌باشد. سازند گورپی در عمق ۳۷۵۰ متری به سازند ایلام می‌رسد. سن این سازند به دوره پالئوسن و کرتاسه پیشین برمی‌گردد.

• سازند ایلام:

محل الگوی این سازند در ایلام است. جنس آن از آهک مارنی، آهک و مارن است. سن تشکیل این سازند از سانتونین پیش تا کامپانین است. این سازند دارای ذخایر فرعی و کوچک نفتی در میادین آب تیمور، اهواز، امام حسن، منصوری و دارخوین است.

• سازند سروک:

این سازند بطور کلی از سنگ آهک تشکیل شده است. نقاطی از این سازند با لایه‌هایی از گچ، آهک مارنی و شیل همراه است. محل الگوی سازند سروک در گروه بنگستان در شمال خوزستان است. این سازند به عنوان آخرین بخش حفاری شده در میدان معرفی می‌شود. سن این سازند به دوره آلبین برمی‌گردد.

۴-۴ ناسازگاری‌ها و داده‌های پرت:

تشخیص داده‌های پرت می‌تواند به عنوان یک مرحله پیش پردازش در مسیر داده کاوی، و یا مستقلاً به عنوان یک عملیات داده کاوی مطرح شود. رشته‌های فنی، در نهایت با مجموعه‌ای از داده‌ها با حجم‌های کم یا زیاد سرکار دارند، اما مهم‌ترین کار، به دست آوردن چنین پایگاه داده‌ای نیست. باید قادر بود تا سطح بالاتری از دانش را با توجه به پایگاه داده مذکور به دست آورد. با حذف داده‌های پرت می‌توان در ساخت و آموزش مدل‌های مبتنی بر هوش مصنوعی به دقت بهتری دسترسی پیدا کرد.

۴-۴-۱ تعریف داده پرت:

یک داده‌ی پرت، داده‌ای است که به طور قابل توجهی متفاوت‌تر از داده‌های دیگر باشد. در واقع انحراف قابل ملاحظه‌ای نسبت به داده‌های دیگر دارد. به نظر می‌رسد این نوع داده‌ها با مکانیسم متفاوت دیگری تولید شده است، [۳۰]. داده‌های پرت اغلب اشاره به ناسازگاری، تناقض، ناهمبستگی و انحراف در داده کاوی دارد. در بیشتر موارد این نوع داده به وسیله یک یا چندین فرایند در سیستم تولید می‌شود، که روند غیر طبیعی در رفتار این فرایندها منجر به تولید داده‌های پرت شود. بنابراین یک داده‌ی پرت می‌تواند اطلاعات مفیدی درباره رفتار ناسازگار سیستم باشد که روی داده‌ها تاثیر می‌گذارد. داده‌های پرت در نتیجه منجر به افزایش خطای سیستم می‌شود. چندین نوع داده پرت وجود دارد، در ادامه به آنها اشاره می‌شود.

۴-۴-۲ داده‌های پرت سراسری^۱:

داده‌هایی که فارغ از زمان، مکان و محل رخداد، خارج از محدوده مد نظر باشد، همانند مجموعه‌ای از قد افراد که بین ۱۸۰ تا ۱۹۰ سانتی متر است اما یک نفر با قد ۲۱۰ سانتی متری در این مجموعه وجود داشته باشد. این نوع داده‌ها با یک دانش کمی نیز قابل مشاهده است. ساده‌ترین شکل از داده‌های پرت که به راحتی نیز شناسایی می‌شوند، داده‌های پرت سراسری هستند.


۴-۴-۳ داده‌های پرت حوزه‌ای^۲:

این نوع از داده‌های پرت وابسته به زمان، مکان و پارامترهای متفاوت دیگری می‌باشند. تشخیص این نوع داده‌ها مشکل‌تر است و نیازمند دانش در مورد داده‌های مورد رخ داد می‌باشد. به عبارت دیگر اگر یک داده در یک زمینه خاص غیر عادی باشد (نه در همه‌ی زمینه‌ها)، به عنوان یک داده پرت حوزه‌ای یا پرت به صورت مشروط شناسایی می‌شود، [۳۱]. هر داده‌ای بر اساس دو نوع ویژگی رفتاری و حوزه‌ای مورد

¹ Global or poiny Outlier

² Contextual Outliers


بررسی قرار می‌گیرد. ویژگی رفتاری، ویژگی مشخصه‌های غیر حوزه‌ای یک داده را تعریف می‌کند. ویژگی حوزه‌ای، برای تعیین همسایگی داده مورد استفاده قرار می‌گیرد. به عنوان مثال در شکل (۲-۴) یک مجموعه دما نسبت به زمان در ماه‌های یک منطقه را نشان می‌دهد. دمای t_1 رخ داده در طول زمستان مقداری نرمال اما همان دما در t_2 برای فصل تابستان یک داده‌ی پرت محسوب می‌شود.



شکل (۲-۴): داده پرت t_2 در یک دمای سری زمانی، [۳۲].

۴-۴-۴ داده پرت گروهی:

مجموعه‌ای از داده‌ها، هنگامی یک داده‌ی پرت گروهی محسوب می‌شوند که گروهی از آنها اختلاف فاحشی با مابقی داده‌ها داشته باشند، از این رو امکان دارد هر یک از آنها به تنهایی پرت نباشند. برای شناسایی داده‌های پرت گروهی به دانشی نیاز است که روابط میان داده‌ها را برای یافتن گروه‌هایی از داده‌های پرت مدل‌سازی کند، [۳۱]. به عنوان مثال در نوار قلب نشان داده شده در شکل (۳-۴)، بخش مشخص شده به دلیل یک مقدار پایین در یک مدت طولانی به عنوان داده گروهی ناسازگار مشخص می‌شود.



شکل (۳-۴): نمایش داده های پرت گروهی توسط نوار قلب [۳۳]

۵-۴ تشخیص داده های پرت:

برای تشخیص انواع داده های پرت می توان با تکیه بر تکنیک های مبتنی بر روش های متفاوتی همچون روش نظارت شده، روش نیمه نظارت شده و نظارت نشده که در ادامه توضیحی در مورد هر کدام از این روش ها داده شده است استفاده کرد:

۴-۵-۱ روش نظارت شده^۱:

روش های آموزش نظارت شده بر اساس فرض در دسترس بودن یک مجموعه داده آموزش است که کلاس پرت بودن داده ها را مشخص می کند. تکنیک های معمول در چنین مواردی، ساخت مدل های پیش بینی برای شناخت دسته های نرمال نسبت به دسته های پرت می باشد. داده های نشان داده نشده به مدل برای تعلق نوع داده به هر کدام از دسته های مد نظر به مدل داده می شوند. دو موضوع اساسی در تشخیص داده های پرت تحت نظارت رخ می دهد. اولی، کم بودن داده های پرت نسبت به داده های عادی در داده های آموزش و دومی، چالش برانگیزی تعیین دقت برای دسته داده های پرت است، [۳۲].

۴-۵-۲ روش غیر نظارت شده^۲:

این روش به مجموعه داده های آموزش نیاز ندارند، اغلب بسیار پر کاربرد تر از روش دیگر می باشد. تکنیک های مبتنی بر این روش فرض می کند که داده های عادی نسبت به داده های پرت بسیار

پرتکرارتر می‌باشند. بنابراین در صورت صحیح نبودن این فرض چنین روش‌هایی دارای خطای بالایی خواهند بود.

۴-۵-۳ روش نیمه نظارت شده^۳:

این نوع روش فرض می‌کند که داده‌های آموزش تنها برای داده‌های نرمال می‌باشد. از آنجایی که این روش به علامت برای دسته داده‌های پرت نیاز ندارد، بنابراین نسب به روش‌های نظارت شده دارای کاربرد بیشتری می‌باشند. تکنیک‌های معمول به کار برده شده در این روش، ساخت مدلی مرتبط با رفتار داده-های عادی و در نتیجه به کارگیری مدل برای تشخیص رفتار غیر عادی سایر داده‌ها می‌باشد. مجموعه‌ای محدود از این نوع روش وجود دارد که تنها داده‌های پرت را به عنوان مجموعه در دسترس برای آموزش فرض می‌کند، [۳۴،۳۵].

۴-۶ روش شناسی تشخیص داده پرت در پایان‌نامه:

در این پایان‌نامه سعی شده تا با استفاده از تکنیک شعاع نرمال شده داده یا معیار t_2 ، به عنوان زیر مجموعه‌ای از روش‌های غیر نظارت شده، داده‌های پرت شناسایی شده و از مجموعه داده‌ها حذف شوند، تا در نهایت به یک مدل ساده با آموزش مناسب دست یافته شود. در این تکنیک از اصل مجاورت برای تشخیص داده‌های پرت استفاده می‌شود، در روش‌های تشخیص داده‌های پرت که مبتنی بر فاصله هستند، با تعیین یک شعاع، همسایگی داده تعریف می‌شود. هنگامی یک داده، داده‌ی پرت تلقی می‌شود که در شعاع تعیین شده قرار نگیرد، و در همسایگی آن به اندازه‌ی کافی نقاط دیگر وجود نداشته باشند.

در این تکنیک از شعاع نرمال شده آماری مبتنی بر آنالیز مولفه‌های اصلی^۱ برای تشخیص داده‌های پرت استفاده شده است. آنالیز مولفه‌های اصلی یک روش برای ساده سازی داده‌های چند متغیره می‌باشد. در این تکنیک سعی شده تا با تغییر فضای داده‌ها به یک فضای نرمال شده توسط اعمال مولفه‌های اصلی،

¹ Principal Component Analysis

داده‌های متفاوت تشخیص و از مجموعه داده‌ها کنار گذاشته شود. تعیین مختصات جدید داده‌های اولیه، بر اساس مولفه‌های اصلی صورت می‌پذیرد. در این روش متغیرهای موجود در یک فضای چند حالته همبسته به یک مجموعه از مولفه‌های غیر همبسته خلاصه می‌شوند، که هر یک از آنها ترکیب خطی از متغیرهای اصلی می‌باشند. مولفه‌های غیر همبسته به دست آمده، مولفه‌های اصلی نامیده می‌شوند. این مولفه‌ها از بردارهای ویژه ماتریس کواریانس یا ماتریس همبستگی متغیرهای اصلی به دست می‌آیند. در واقع هدف، انتقال داده‌های اولیه به یک فضای نرمال شده، بدون تغییر در ابعاد ماتریکس داده‌ها است، تا فاصله داده‌ها از مرکز محاسبه شود. محاسبه این فاصله به طریق زیر انجام می‌شود:

$$Z = VX\partial^T \quad \text{معادله (۱-۴)}$$

V مولفه‌های اصلی ماتریکس کواریانس متغیرهای اولیه، X ماتریکس داده‌های اولیه، ∂^t ترانهاده انحراف معیار و Z ماتریکس نرمال شده داده‌ها می‌باشد. تکنیک T^2 را می‌توان متناسب با نرم^۱ بردار نرمال شده Z به صورت زیر در نظر گرفت:

$$T^2 = ZZ^T \quad \text{معادله (۲-۴)}$$

با جایگزینی معادله (۱-۴) در معادله (۲-۴):

$$T^2 = X * V * \partial^{-1} * V^T * X^T \quad \text{معادله (۳-۴)}$$

در واقع وقتی معادله بالا مساوی α^2 باشد، معادله‌ی دایره‌ای با شعاع α^2 در فضای نرمال شده در نظر گرفته خواهد شد:

$$X * V * \partial^{-1} * V^T * X^T = \alpha^2 \quad \text{معادله (۴-۴)}$$

¹ Norm

با افزایش مقادیر پایه t_2 برای سنجش داده‌ها محدوده‌ی در برگیری داده‌های نرمال افزایش پیدا می‌کند و بالعکس با کوچک‌تر کردن معیار t_2 با افزایش داده‌های پرت رو برو خواهیم شد. بعد از پیاده‌سازی این تکنیک روی مجموعه داده‌های در دسترس هر دسته داده‌ی پرت از مجموع داده‌ها جدا خواهد شد.

۷-۴ روش کار طراحی سیستم‌های هوشمند در پایان‌نامه:

۱-۷-۴ مدل اول: توسعه مدل الگوریتم ژنتیک و شبکه عصبی تشخیص الگو^۱:

ایده اولیه ترکیب شبکه عصبی و الگوریتم ژنتیک در اواخر سال ۱۹۸۰ معرفی شد. این سوال مطرح می‌شود که چرا زمانی که هر دو از روش‌های محاسباتی هستند، باید با هم ترکیب شوند. مساله پارامتر-هایی از شبکه‌های عصبی است که قبل از شروع هر گونه آموزشی تنظیم شوند. هیچگونه قانون روشنی برای چگونگی تنظیم این پارامترها وجود ندارد. این پارامترها در موفقیت آموزش تعیین کننده خواهند بود. با ترکیب الگوریتم ژنتیک و شبکه عصبی، الگوریتم ژنتیک در یافتن این پارامترها (وزن‌ها و بایاس‌های شبکه) مورد استفاده قرار می‌گیرد. برای پیاده‌سازی این مدل در نرم افزار متلب گام‌های متفاوتی نیاز به کدنویسی دارد :

- بارگذاری داده
- تقسیم داده ها
- نرمال سازی داده
- ساختار شبکه
- آموزش شبکه
- ارزیابی شبکه

¹ Pattern Recognition Neural Network

۴-۷-۱-۱ بارگذاری داده‌ها:

در بارگذاری داده یک ماتریس اکسل از داده‌های در دسترس جمع آوری می‌شود. هشت ستون اول فایل، به عنوان ورودی و ستون آخر به عنوان خروجی مورد نظر شبکه قرار داده شده است. با فراخوانی این فایل در محیط متلب داده‌های ورودی و خروجی برای اعمال به مدل جداسازی خواهد شد.

۴-۷-۱-۲ تقسیم داده‌ها:

دسترسی به داده یکی از مهمترین فاکتورها در آموزش سیستم‌های هوشمند می‌باشد. مجموعه داده باید نماینده تمام حالات مساله را مد نظر قرار دهند، و همچنین الگوهای کافی برای مجموعه آزمایش و آموزش باشند. داده‌های انتخابی برای آموزش شبکه باید نماینده کاملی از فضای مساله باشد. اگر شبکه آزادی زیادی برای آموزش قرار دهد، خطای حاصل از آموزش شبکه بسیار کوچک درحالیکه شبکه قادر به پیش بینی صحیح داده‌های آزمایش نخواهد بود. برای جلوگیری از این اتفاق تمام داده‌ها در دو دسته مجموعه آموزش برای آموزش شبکه، و مجموعه آزمایش، برای آزمایش قابلیت تعمیم شبکه مورد استفاده قرار گرفت. داده‌های هر دو دسته به دلیل بهره‌گیری از تمام فضای داده‌ها به صورت تصادفی و پراکنده از مجموعه داده جدا می‌شوند. در این پایان‌نامه ۷۰ درصد داده‌ها به مجموعه آموزش شبکه اختصاص داده شده و مابقی داده‌ها به مجموعه آزمایش تعلق می‌گیرد.

۴-۷-۱-۳ نرمال سازی داده :

اختلاف در دامنه تغییرات و ابعاد پارامترها مورد استفاده در مدل، باعث ایجاد محدودیت‌هایی در فرآیند آموزش شبکه خواهد شد. برای رفع این مشکل در محیط متلب از روش‌های نرمال‌سازی استفاده می‌شود. توابع نرمال‌سازی، داده‌ها را در یک بازه مشخص همگن می‌کند. در این مدل رابطه زیر در جهت نرمال سازی داده مورد استفاده قرار گرفت:

$$X = \frac{x - X_{\min}}{X_{\max} - X_{\min}} * 2 - 1 \quad (5-4)$$

در رابطه فوق، x مقدار میدانی هر یک از ورودی‌ها، مقادیر $X_{\max}$ و $X_{\min}$ بیشترین و کمترین مقادیر هر ستون از داده‌ها که مربوط به یک ورودی یا خروجی می‌باشد را مشخص می‌کند. بنابراین تمام داده‌های موجود در یک بازه مشخص $X \in [-1, 1]$ همگن سازی یا نرمالایز می‌شوند.

۴-۱-۷-۴ ساختار شبکه:

ساختار شبکه عصبی در موفقیت آن بسیار موثر است. برخلاف شبکه‌های عصبی تخمین‌گر، افزایش لایه‌های میانی در ساختار یک شبکه عصبی طبقه‌بندی باعث به دام افتادن در نقاط مینیمم محلی می‌گردد. در این مدل برای طبقه‌بندی الگوهای ورودی به شش طبقه خروجی، از یک لایه میانی در ساختار شبکه عصبی استفاده شده است. در شبکه‌های عصبی طبقه‌بندی برای دستیابی به یک پردازش مناسب و حل پیچیدگی‌های مساله، تعداد نرون‌های لایه میانی مورد تغییر قرار می‌گیرد. در این مدل سعی شده تا شبکه عصبی، الگوهای ورودی‌ها را در شش طبقه خروجی شناسایی کند. این مدل در ساختار خود از هشت پارامتر به عنوان هشت ورودی به لایه میانی برای تشخیص شش دسته از خروجی در لایه آخر استفاده می‌کند.

۴-۱-۷-۵ آموزش شبکه عصبی با استفاده از الگوریتم ژنتیک:

نقطه اشتراک الگوریتم‌های هی هیینه ساز تکاملی و در کنار آنها الگوریتم ژنتیک با مبحث شبکه عصبی، نقطه‌ای است که شبکه عصبی بعد از تعیین ساختار خود، در فرایند آموزش شبکه به یک مسئله بهینه ساز ختم می‌شود. الگوریتم ژنتیک به عنوان روش آموزش این مدل مورد استفاده قرار می‌گیرد. در این روش، جستجو در فضای مساله جهت یافتن جواب بهتر و بهینه صورت می‌گیرد، [۳۶].

بعد از ایجاد ساختار شبکه عصبی و تعیین مقدار وزن و بایاس‌های مجهول مساله، در گام اول الگوریتم ژنتیک با یک جمعیت اولیه تصادفی برای حل مساله شروع می‌شود. بعد از تقسیم داده‌ها به دو

فضای آموزش و آزمایش و همگن کردن این مجموعه‌ها، جمعیت‌های اولیه‌ای از وزن‌ها و بایاس‌ها به صورت تصادفی ایجاد می‌شود. این وزن‌ها و بایاس‌ها به عنوان مجهولات مساله پشت سرهم به شکل یک کروموزوم چیده می‌شوند. برای هر کدام از این مجهولات در کروموزوم یک بایت، و هر بایت از تعدادی بیت (صفر و یک) تعریف خواهد شد. در طول هر چرخه‌ی الگوریتم ژنتیک، این کروموزوم‌ها برای عملکرد بهتر مورد تغییر قرار می‌گیرند. هر چقدر مجهولات مساله در بازه بزرگتری قرار بگیرند، شانس بیشتری برای نزدیک شدن به نقطه مینمم محلی^۱ وجود خواهد داشت. اما انتخاب بازه بزرگ برای مجهولات نیاز به تکرار و تغییر زیاد کروموزوم‌ها دارد. در این مدل بازه وزن‌ها و بایاس‌ها بین $[-0.25, 0.25]$ انتخاب شده است. انتخاب این بازه از وزن‌ها و بایاس‌ها شانس آموزش بیشتری ایجاد خواهد کرد.

در گام دوم، ۶۰ درصد از کروموزوم‌های اولیه به صورت تصادفی انتخاب و به صورت دوتایی کنار همدیگر قرار می‌گیرند. عملگر تقاطع^۲ در الگوریتم ژنتیک، دو کروموزوم جدید، از ترکیب دو کروموزوم والد ایجاد می‌کند. تقاطع توسط گرفتن بخشی از اطلاعات رشته بایتهی کروموزوم والد اول و کروموزوم والد دوم و ترکیب آن‌ها در تولید کروموزوم‌های جدید عمل می‌کند. این یک فرایند تصادفی است که در نهایت کروموزوم‌های جدید ایجاد، و به دسته اولیه اضافه می‌شود.

در گام سوم کروموزوم‌های ایجاد شده در مرحله قبلی دچار تبدیل^۳ تصادفی در بیت‌های خود خواهد شد. در این پایان‌نامه ۵ درصد از بیت‌های کروموزوم‌های جدید به صورت تصادفی تبدیل می‌شوند. این تبدیل در بیت‌های کروموزوم به عنوان عملگر جهش ژنتیکی شناخته می‌شود. با دستیابی به فضای جستجوی بزرگتر توسط جهش یافتگی کروموزوم، الگوریتم سعی در یافتن به جواب‌های بهتری را خواهد داشت.


¹ Local Minimum Point

² Crossover

³ Toggle

در گام بعدی داده‌های آموزش برای مجموعه کروموزوم‌ها، به شبکه نشان داده شده است. مجموعه مربعات خطا^۱ به عنوان تابع هزینه^۲، برای هر کدام از این کروموزوم‌ها محاسبه می‌شود. تابعی مبتنی بر مجموعه مربعات خطابه نام تابع تناسب^۳ تعریف می‌شود. در این پایان‌نامه از تابع چرخ رولت به عنوان عملگر انتخاب استفاده شده است. مبتنی بر تابع تناسب تمامی کروموزوم‌ها برای انتخاب شانس خواهند داشت. کروموزوم‌هایی که تابع خطا را کمینه می‌کند، از شانس انتخاب بیشتری برخوردار می‌شوند.

بعد از انتخاب کروموزوم‌ها، تولید نسل جدید براساس عملگرهای تقاطع، جهش و انتخاب روی این اوزان تا تحقق‌پذیری و دستیابی به شرط توقف ادامه پیدا کرد. فرایند بهینه‌سازی براساس الگوریتم ژنتیک در مسیر تکامل وزن‌های شبکه پیش می‌رود، تا مقادیر پیش بینی شده خروجی مدل به مقادیر واقعی نزدیک‌تر و مقدار خطا به حداقل برسد. روند کلی از این ترکیب در شکل (۴-۴) نشان داده شده است. بررسی مجموعه مربعات خطای داده‌های آزمون در هر مرحله صورت می‌گیرد. افزایش مداوم مجموعه خطای داده‌های آزمون، به عنوان شرط توقف آموزش معرفی می‌شود. بعد از توقف آموزش، اولین جمعیت وزن‌ها قبل از شروع توالی افزایش مجموعه مربعات خطای داده‌های آزمایش، به عنوان مناسب‌ترین وزن و بایاس برای شبکه عصبی انتخاب می‌شود.



شکل(۴-۴): فرایند آموزش مدل الگوریتم ژنتیک - شبکه عصبی

¹Total Sum of Square Errors

² Cost Function

³Fitness Function

۴-۷-۲ مدل دوم: سیستم استنتاج تطبیقی نرو - فازی:

سیستم‌های نرو - فازی در زمینه سیستم‌های کنترل و آنالیز داده به کار می‌رود. سیستم‌های نرو - فازی یک ابزار کارآمد برای سرکار داشتن با سیستم‌های پیچیده هستند. این سیستم‌ها از اطلاعات زبانی و عددی استفاده می‌کنند. چندین راه برای ترکیب شبکه عصبی و سیستم‌های فازی وجود دارد. عموماً سیستم‌های نرو- فازی در سه نوع، وابسته به چگونگی ترکیب عملکرد شبکه‌های عصبی و سیستم‌های فازی دسته بندی می‌شوند [۳۷،۳۸]. در این پایان‌نامه از سیستم استنتاج تطبیقی فازی- عصبی برای ساخت مدل استفاده شده است.

۴-۷-۳ سیستم استنتاج تطبیقی فازی - عصبی:

امروزه تکنیک فازی - عصبی به دلیل ترکیب دو تکنیک شبکه عصبی و منطق فازی به نام سیستم استنتاج تطبیقی فازی - عصبی^۱ (انفیس) شناخته شده است. انفیس به عنوان یک ابزار اصلی در مسائل هوش محاسباتی مورد استفاده قرار می‌گیرد. جانگ در سال ۱۹۹۳ این دو تکنیک منطق فازی و شبکه عصبی را برای بهره‌گیری از مزیت‌های هر دوی آنها باهم ترکیب کرد و سیستم‌های استنتاج تطبیقی نرو - فازی یا انفیس را معرفی کرد، [۳۸]. از مزیت‌های انفیس می‌توان به ارتباط با دانش زبانی منطق فازی و بهره‌گیری از قابلیت آموزش پذیری، بهبود بخشی و خودآموزی شبکه عصبی اشاره کرد. هدف این کار طراحی یک سیستم برای به کارگیری سیستم فازی در نمایش دانش با روش‌های تفسیری و توانایی شبکه‌های عصبی در یادگیری مستقیم از داده‌ها، برای تنظیم پارامترهای تابع عضویت به منظور افزایش عملکرد سیستم می‌باشد.

انفیس یک تکنیک نرو - فازی است که اتصالی بین شبکه عصبی و سیستم استنتاج فازی برقرار کرده است. در واقع می‌توان به انفیس از دیدگاه طراحی سیستم فازی با استفاده از اطلاعات ورودی و خروجی

¹ Adaptive Neural – Fuzzy Inferenc System


نگاه کرد. انفیس تلاش می‌کند تا رفتار فازی را با عدد کمی کند و نشان دهد که رفتار سیستم فازی با توجه به داده‌های نشان داده شده صحیح است. روش انفیس، هیبرید منطق فازی و شبکه‌های عصبی را در بر می‌گیرد. انفیس عدم قطعیت سیستم مدل شده را در نظر می‌گیرد، در صورتیکه شبکه عصبی تطبیق-پذیری با محیط را ایجاد می‌کند. با به کارگیری این روش ترکیبی، در ابتدا یک مدل فازی اولیه همراه با متغیرهای ورودی، با کمک از قوانین استخراج شده‌ی داده ورودی - خروجی به دست می‌آید. در گام بعدی شبکه عصبی برای تنظیم قوانین مدل فازی ابتدایی برای تولید مدل انفیس نهایی به کار می‌رود.

۴-۷-۳-۱ ساختار انفیس:

انفیس یک سیستم هوشمند ترکیبی است که یک سیستم فازی سوگنو را به دلیل تولید قوانین فازی برای یک رویکرد سیستماتیک از داده‌های ورودی - خروجی اجرا می‌کند، [۳۹]. برای ساده‌سازی توصیف ساختار انفیس در این بخش سیستم استنتاج فازی با اعمال دو ورودی و یک خروجی نمایش داده می‌شود. قوانین اگر - آنگاه فازی تاکاگی سو گنو فازی بصورت زیر بیان می‌شود، [۴۰].

$$\text{if } x \text{ is } A \text{ and } y \text{ is } B \text{ then } z \text{ is } f(x, y) \quad (۴-۶)$$

جاییکه A و B مجموعه‌های فازی ابتدایی، و z یک تابع قطعی انتهایی می‌باشد. معمولا تابع z یک چند جمله‌ای برای متغیرهای x و y می‌باشد. اما می‌تواند هر تابع دیگری که توانایی توصیف تقریبی خروجی سیستم را در ناحیه فازی که به وسیله سوابق تعیین شده است نیز باشد. زمانیکه تابع z ثابت است یک مدل صفر فازی سوگنو شکل می‌گیرد، این مدل به عنوان یک مورد خاص از سیستم استنتاج فازی ممدانی نیز در نظر گرفته می‌شود. در آن هر قانون، برآمده از یک تک فازی مشخص است، [۴۱]. ساختار انفیس شامل یک شبکه عصبی ۵ لایه پیشرو می‌باشد همانند آنچه در شکل (۴-۵) نشان داده شده است.




شکل (۴-۵): ساختار انفیس با دو ورودی [۴۲]

لایه اول:

این لایه ورودی‌های عددی را به مجموعه‌های فازی تبدیل می‌کند که به عنوان لایه فازی سازی شناخته می‌شود. این لایه درجه عضویت را برای هر مجموعه از ورودی‌ها و وابستگی آن به تابع عضویت انتخاب شده را تعریف می‌کند. برای مثال تابع عضویت گوسی در شکل (۴-۶) نشان داده شده است. خروجی گره-ای از لایه ۱ برابر است با:

$$O_{1,j} = \mu_{A_i} = \exp\left(-\frac{1}{2}\left(\frac{x_1 - c_i}{\sigma_i}\right)^2\right) \quad (۷-۴)$$

جاییکه پارامتر σ_i, c_i یک مجموعه فرضی نامیده می‌شود که به ترتیب معرف مرکز و عرض مجموعه فازی A می‌باشد.



شکل (۴-۶): تابع عضویت گوسی [۴۲]

لایه دوم:

در این لایه گره یک عملیات حداقل و حداکثر فازی، با عملگرهای and و or روی ورودی گره انجام می-شود. خروجی نرون ها توانایی تعلق قوانین را در غالب درجه عضویت تولید می کند.

$$O_{2,i} = w_i = \mu_{Ai}(x1) \times \mu_{Bi}(x2) \quad (8-4)$$

لایه سوم:

لایه نرمال سازی نامیده می شود که از نسبت وزن عادی هر گره نسبت به مجموعه وزن های همان گره به دست می آید:

$$O_{3,i} = \bar{w}_i = \frac{w_i}{w_1 + w_2 + w_3 + w_4} \quad (9-4)$$

لایه چهارم :

وزن های نرمال سازی شده به عنوان خروجی های وزن دار در این لایه مورد محاسبه قرا می گیرد:

$$O_{4,i} = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i) \quad (10-4)$$

که $\{q,p,r\}$ مجموعه ای از پارامترهای نهایی است که با استفاده از برآورد حداقل مربعات تعریف می شود.

لایه ۵:

خروجی نهایی را براساس مجموعه ای از سیگنال های ورودی محاسبه می کند:

$$O_{5,i} = \sum_i \bar{w}_i f_i \quad (11-4)$$

۲-۳-۷-۴ ساخت مدل انفیس :

پیاده سازی انفیس در محیط متلب از دو طریق گرافیکی و کدنویسی قابل دسترسی می باشد. در کنار سادگی ابزار گرافیکی برای پیاده سازی انفیس، این ابزار محدودیت هایی نیز برای ساخت مدل ایجاد می-کنند. کاربر دائما باید یکسری مراحل تکراری را طی کند. انجام تنظیمات در ابزار گرافیکی وجود ندارد، از

این رو آزادی عملی که با کدنویسی^۱ به دست می‌آید را نخواهد داشت. برای ساخت مدل سیستم استنتاج تطبیقی فازی عصبی در متلب همانند مدل قبلی چند مرحله باید طی شود:

- بارگذاری داده
- تقسیم داده ها
- نرمال سازی داده
- ساختار شبکه
- آموزش شبکه
- ارزیابی شبکه

در این مدل فرایند بارگذاری داده، نرمال سازی و تقسیم داده‌ها همانند آنچه در مدل اول اشاره شد به کار گرفته می‌شود.

۴-۷-۳ طراحی انفیس:

بعد از بارگذاری داده‌ها در محیط متلب و تقسیم داده‌ها به بخش‌های آموزش و آزمایش، ابتدا داده‌های آموزش با پارامترهای: نوع مته، عمق ورودی و خروجی مته، دبی گل، نرخ نفوذ حفاری، سرعت چرخش مته حفاری، وزن روی مته و همچنین مدت زمان حفاری مته‌های استفاده شده، به عنوان ورودی در نظر گرفته می‌شود. دستیابی به ساختار و طراحی یک مدل انفیس در ابتدا مستلزم به ایجاد یک سیستم استنتاج فازی پایه می‌باشد. این سیستم فازی خام برای پیدا کردن تعداد ورودی‌ها، تعداد متغیر-های زبانی و از این رو تعداد قوانین در مدل نهایی فازی لازم است. این مدل فازی ابتدایی می‌تواند مبتنی بر قوانین فازی به وسیله استفاده از تکنیک خوشه‌بندی تفاضلی، مختصات شبکه‌ای و یا روش‌های خوشه-بندی فازی انتخاب شوند، [۴۲]. در این پایان‌نامه از تکنیک خوشه بندی فازی به دلیل توانایی و سرعت

¹ mfile

بیشتر این تکنیک نسبت به دو تکنیک دیگر برای طراحی سیستم استنتاج فازی استفاده شده است. توضیح مختصری از این تکنیک در ادامه اشاره خواهد شد.

• تکنیک خوشه‌بندی فازی:

این تکنیک به عنوان تعیین درجه عضویت برای ورودی‌های تابع و بیرون کشیدن قوانین موجود در مجموعه داده مورد استفاده قرار می‌گیرد. خوشه‌بندی، فرایندی برای یافتن گروه‌های مناسب درون مجموعه داده‌ها می‌باشد. اعضای هر خوشه دارای ویژگی‌های شبیه به یکدیگر و متفاوت از خوشه‌های دیگر هستند. داده‌ها مورد بررسی قرار می‌گیرند و براساس طرز قرارگیری داده‌ها در فضای تعریف شده، خوشه‌هایی که مراکز آنها برای ایجاد تابع عضویت به کار می‌روند، تعریف می‌شود. اعضای خوشه باید بیشترین درجه تعلق را نسبت به تابع عضویت دارا باشند. برخلاف خوشه‌بندی کلاسیک، خوشه‌بندی فازی^۱ (FCM) یک روش خوشه‌بندی است که اجازه می‌دهد یک داده به طور همزمان به چند خوشه و با درجات عضویت متفاوت تعلق داشته باشد. روش خوشه‌بندی فازی در سال ۱۹۸۱ به عنوان یک روش برای بهینه کردن تابع هدف زیر معرفی شد، [۴۲]:

$$J(U, V) = \sum_{i=1}^n \sum_{j=1}^c (\mu_{ij})^m (d_{ij})^2 \quad (۱۲-۴)n$$

به عنوان m و $\mu_{ij} \in [0,1]$ در حالیکه، v_i برای مرکز خوشه x_i درجه عضویت الگوی μ_{ij} ها، تعداد داده شاخص فازی‌سازی که فازی بودن هر نقطه را کنترل می‌کند با مقدار ۲ انتخاب می‌شود. در روش خوشه-بندی فازی تعداد خوشه‌ها باید توسط کاربر مشخص شود، از طرفی معمولاً تعداد خوشه‌ها نشان دهنده قوانین ایجاد شده برای مدل می‌باشد. در این تحقیق به دلیل کار آمدی و دقت تکنیک خوشه‌بندی فازی، از این روش برای ساخت مدل فازی استفاده شد.

¹ Fuzzy Clustering C-Means

پس از تعیین ساختار سیستم فازی پایه، پارامترهای مربوط به آموزش سیستم استنتاج تطبیقی فازی - عصبی، تنظیم می‌گردد. پارامترهای آموزش شامل اندازه گام ابتدایی، نرخ کاهش و افزایش گام می‌باشند، می‌توان آنها را در جهت بهبود کارایی شبکه تنظیم کرد. پس از پیاده‌سازی مراحل گفته شده، با فراخوانی داده‌های آموزش، مدل با به کارگیری ترکیبی از الگوریتم پس انتشار و حداقل مربعات، پارامترهای توابع عضویت را برای استخراج دانش در جهت تعیین قوانین صحیح از میان داده‌ها، آموزش می‌دهد.

۸-۴ جمع بندی:

در صنعت حفاری پیش‌بینی‌های انسانی براساس تجربیات به دست آمده از حفر چاه‌های گذشته بسیار پررنگ است. این مدل‌ها با بهره‌گیری از داده‌های کافی و صحیح به جواب بهتری دست پیدا خواهند کرد. در این فصل روش شناسی معیار شعاع نرمال شده آماری برای شناسایی و حذف داده‌های پرت مورد استفاده در پایان‌نامه مطرح شده است.

تجربیات استفاده از انواع مته‌ها در حفر چاه‌های مجاور، همواره در حفر یک چاه جدید توسط پیش‌بینی‌های انسانی برای یک مته جدید مورد استفاده قرار می‌گیرد. برای افزایش دقت این نوع پیش‌بینی و آگاهی پیدا کردن از شرایط مته درون چاه، نیاز به شناخت دقیق الگوهای مته‌های استفاده شده و همچنین شناخت صحیح از ماهیت مساله مورد نظر می‌باشد.

در این فصل برای آگاهی دقیق از شرایط مته درون چاه، شبکه‌های عصبی بازشناسی الگو و همچنین سیستم‌های استنتاج تطبیقی فازی - عصبی به عنوان دو مدل در تعیین الگو مته‌های رانده شده در چاه و تشخیص ماهیت مساله طراحی می‌شود. به دلیل محدودیت‌های موجود در پیاده‌سازی این مدل‌ها توسط جعبه ابزار نرم افزار متلب، فرایند طراحی در چندین گام توسط کدنویسی در این فصل انجام شده است. هشت ورودی از جمله نوع مته، نرخ نفوذ، عمق ورودی مته، عمق خروجی مته، وزن روی مته، سرعت چرخش مته و دبی جریان گل با فراخوانی داده‌ها به مدل‌ها اعمال می‌شود.

۵. فصل پنجم


یافته‌های پژوهش

۱-۵ مقدمه:

امروزه مدل‌های هوشمند نقش پررنگی در پروژه‌های تحقیقاتی ایفا می‌کنند. در این فصل توانایی مدل‌های هوشمند در رفتارهایی مشابه رفتارهای هوشمند انسانی از جمله درک شرایط پیچیده، یادگیری و توانایی کسب دانش و استدلال در زمینه حل مسائل حفاری مورد ارزیابی قرار می‌گیرد. در ابتدا نتایج حاصل از به کارگیری تکنیک T^2 برای شناسایی داده‌های پرت ارائه می‌شود. با حذف داده‌های پرت از مجموعه اولیه، مابقی داده‌ها برای آموزش و ارزیابی مدل‌ها فراخوانی می‌شوند. بعد از طراحی مدل‌های مورد بحث در پایان‌نامه، به بررسی نتایج به دست آمده از هر مدل پرداخته می‌شود. در بخش اول به بررسی نتایج حاصل از آموزش یک شبکه عصبی، توسط الگوریتم بهینه‌ساز ژنتیک پرداخته خواهد شد. در ادامه قابلیت تعمیم مدل اول، توسط ارزیابی داده‌های آموزش مورد گفتگو قرار می‌گیرد. در بخش دوم به بررسی نتایج به دست آمده توسط مدل استنتاج تطبیقی فازی - عصبی، با استفاده از داده‌های آموزش و آزمایش اشاره خواهد شد.


۲-۵ نتایج به کارگیری معیار t_2 روی مجموعه داده:

پراکندگی داده‌ها طبق دو مولفه‌ی اصلی اول در شکل (۱-۵) ترسیم شده است. مولفه اصلی اول بیشترین پراکندگی داده‌ها در کل مجموعه داده‌ها را در نظر می‌گیرد. این بدین معنی است که مولفه اصلی اول، حداقل با تعدادی از متغیرها همبسته است. مولفه اصلی دوم، بیشترین واریانس مجموعه داده‌ها که توسط مولفه اول محاسبه نشده است را در نظر می‌گیرد.



شکل (۵-۱): پراکندگی داده‌ها براساس دو مولفه اصلی

بر اساس اندازه گیری فاصله آماری چند متغیره برای هر نقطه مشاهده شده، داده‌هایی که متفاوت تر هستند و با فاصله بیشتری از مرکز داده‌ها قرار می گیرند، بر اساس ایجاد محدودیت معیار T^2 ، از مجموعه داده‌ها کنار گذاشته می‌شوند. با افزایش مقادیر پایه T^2 برای سنجش داده‌ها، محدوده‌ی دربرگیری داده‌های قابل قبول افزایش پیدا می‌کند، بالعکس با کوچک‌تر کردن معیار T^2 ، افزایش داده‌های پرت حاصل خواهد شد. تعدادی از نقاط حذف شده که توسط تکنیک اعمال شده روی مجموعه داده‌ها تشخیص داده شده است، بر اساس شماره‌ی داده مدنظر در ماتریکس داده‌ها، در شکل (۵-۲) مشخص شده است.



شکل (۵-۲): نمایش تعدادی از داده‌های جدا شده از مجموعه داده‌ها

۳-۵ پیاده‌سازی مدل شبکه عصبی و الگوریتم ژنتیک و بحث بر روی نتایج:

۱-۳-۵ نتایج آموزش مدل شبکه عصبی و الگوریتم ژنتیک:


پس از تعیین پارامترهای ورودی و خروجی، اکنون داده‌های موجود بر روی مدل اعمال می‌گردند. پارامترهای نوع مته، مدت زمان حفاری، عمق ورودی و خروجی مته، وزن روی مته، نرخ نفوذ حفاری، دبی پمپ گل و سرعت چرخش مته، به عنوان ورودی وارد شبکه می‌شوند. پس از طی فرایند آموزش و رسیدن به شرط توقف، آموزش شبکه متوقف می‌شود. شبکه، اطلاعات واقعی میدانی را با نتایج به دست آمده از مدل مورد مقایسه قرار می‌دهد. بطور کلی برای بررسی میزان موفقیت و کارایی سیستم‌های طبقه‌بندی، از ماتریس طبقه‌بندی و نرخ طبقه‌بندی صحیح^۱، استفاده می‌شود. شکل (۳-۵)، ماتریس طبقه‌بندی اطلاعات درجه فرسایش مته در حالت واقعی میدانی، نسبت به مقادیر تشخیصی توسط مدل شبکه عصبی را نشان می‌دهد.

طبقه خروجی مدل		طبقه خروجی واقعی					
		۱	۲	۳	۴	۵	۶
۱		٪۹۵.۵۵	٪۴.۴۵	٪۰.۰	٪۰.۰	٪۰.۰	٪۰.۰
۲		٪۴.۲۵	٪۸۷.۲۳	٪۸.۵۱	٪۰.۰	٪۰.۰	٪۰.۰
۳		٪۰.۰	٪۶.۶۶	٪۷۵.۵۵	٪۱۷.۷۷	٪۰.۰	٪۰.۰
۴		٪۰.۰	٪۰.۰	٪۲۳.۶۸	٪۶۳.۱۷	٪۱۳.۱۵	٪۰.۰
۵		٪۰.۰	٪۰.۰	٪۰.۰	٪۷.۶۹	٪۹۲.۰۷	٪۰.۰
۶		٪۰.۰	٪۰.۰	٪۰.۰	٪۰.۰	٪۲۲.۲۲	٪۷۷.۷۷

شکل (۳-۵): ماتریس طبقه بندی اطلاعات درجه فرسایش مته در حالت ثبت شده سر چاهی و مقادیر تعیین شده توسط مدل شبکه عصبی

¹ Correct Classification Rate

شبکه عصبی از ۵۰ مته‌ای که در حالت واقعی برای داده‌های آموزش، در طبقه یک قرار گرفته بودند، ۹۵/۵۵٪ را به درستی در طبقه‌ی یک تشخیص داده است. برای مته‌های طبقه دوم، ۸۷/۲۳٪ مته‌ها در دسته صحیح خود، توسط شبکه تعیین شده است. از ۴۵ الگوی مته دسته سوم، ۳۸ مته دسته چهارم، ۲۶ مته طبقه پنجم و ۹ مته طبقه ششم، به ترتیب ۷۵٪، ۶۳/۱۷٪، ۹۲/۰۷٪ و ۷۷/۷۷٪ مته‌ها به درستی در طبقه صحیح، توسط شبکه عصبی تقسیم‌بندی شده است. نمودار رگرسیون برای دسته خروجی‌های پیش بینی شده توسط مدل و اطلاعات واقعی میدانی با ضریب همبستگی ۰/۹۵۸۵۹، در شکل (۴-۵) نشان داده شده است. نرخ طبقه‌بندی صحیح شبکه عصبی برای داده‌های آموزش در ماتریس طبقه‌بندی برابر ۸۲/۳۸٪ محاسبه شد.



شکل (۴-۵): نمودار رگرسیون برای دسته خروجی‌های تعیین شده توسط مدل و دسته‌های واقعی میدان

۵-۳-۲ نتایج آزمایش مدل شبکه عصبی و ژنتیک:


به کارگیری داده‌های آزمایش به عنوان مجموعه‌ای که در فرایند ساخت به مدل نشان داده نشده است، برای بررسی کارآمدی مدل مورد توجه قرار می‌گیرد. ماتریس طبقه‌بندی و نمودار رگرسیونی برای داده‌های آزمایش ترسیم می‌شود، تا به عنوان شاخص‌هایی از صحت عملکرد طبقه‌بندی و تعمیم مدل مورد بررسی قرار بگیرد. در شکل (۵-۵) ماتریس طبقه‌بندی برای اطلاعات درجه فرسایش مته در حالت واقعی میدانی و نتایج طبقه‌بندی مدل، برای داده‌های آزمایش آورده شده است.

	طبقه خروجی مدل					
	۱	۲	۳	۴	۵	۶
طبقه خروجی واقعی	۱	۹۴.۱۱٪	۵.۸۸٪	۰.۰٪	۰.۰٪	۰.۰٪
	۲	۱۸.۷۵٪	۶۸.۷۵٪	۸.۵۱٪	۰.۰٪	۰.۰٪
	۳	۰.۰٪	۶.۲۵٪	۸۱.۲۵٪	۱۲.۵٪	۰.۰٪
	۴	۰.۰٪	۰.۰٪	۲۲.۲۲٪	۵۵.۵۵٪	۲۲.۲۲٪
	۵	۰.۰٪	۰.۰٪	۰.۰٪	۱۰۰٪	۰.۰٪
	۶	۰.۰٪	۰.۰٪	۰.۰٪	۰.۰٪	۱۰۰٪

شکل (۵-۵): ماتریس طبقه‌بندی اطلاعات درجه فرسایش مته در حالت واقعی و مقادیر طبقه‌بندی شده توسط شبکه

عصبی برای داده‌های آزمایش

از ۱۷ مته قرار گرفته شده در طبقه اول داده‌های آزمایش، شبکه عصبی ۱۶ مته را به درستی در طبقه اول تشخیص داده است. ۵/۸۸٪ مته‌های این طبقه توسط شبکه عصبی به خطا، در طبقه‌ی دوم تشخیص داده شده است. ۶۸/۷۵٪ مته‌های طبقه‌ی دوم در حالت واقعی، توسط شبکه عصبی در طبقه‌ی دوم به درستی تشخیص داده شده است. ۲۷/۲۶٪ مته‌های طبقه دوم، به خطا در طبقه‌های اول و سوم قرار گرفته است. از ۱۶ مته طبقه سوم در حالت واقعی، ۸۱/۲۵٪ مته‌ها توسط شبکه عصبی در طبقه سوم و مابقی در طبقه‌های چهارم و دوم قرار گرفته است. ۵۵/۵۵٪ مته‌های طبقه چهارم در طبقه صحیح و ۴۴/۵۵٪ مته‌ها توسط شبکه عصبی، در طبقه‌های پنجم و چهارم تشخیص داده شده‌اند. تمامی مته‌های قرار گرفته در طبقه پنجم و ششم، توسط شبکه در طبقه‌های صحیح تشخیص داده شده‌اند. نمودار رگرسیون برای طبقه‌های خروجی تعیین شده توسط مدل و طبقه‌های واقعی میدانی، با ضریب همبستگی ۰/۹۶۴۴۴ در شکل (۵-۶) نشان داده شده است. نرخ طبقه‌بندی صحیح شبکه عصبی، برای داده‌های آزمایش در ماتریس طبقه‌بندی برابر ۸۱/۱۱٪ محاسبه شد.




شکل (۵-۶): نمودار رگرسیون برای طبقه خروجی‌های تعیین شده توسط مدل و طبقه‌های واقعی میدانی


۴-۵ پیاده‌سازی مدل سیستم استنتاج تطبیقی فازی - عصبی و بحث بر روی نتایج:

۱-۴-۵ نتایج آموزش مدل سیستم استنتاج تطبیقی فازی - عصبی:

پس از تعیین پارامترهای ورودی و خروجی، اکنون مدل روی داده‌ها اعمال می‌گردد. پارامترهای نوع مته، مدت زمان حفاری، عمق ورودی و خروجی مته، وزن روی مته، نرخ نفوذ حفاری، فشار پمپ گل و سرعت چرخش مته، به عنوان ورودی وارد شبکه می‌شوند. پس از طی فرایند آموزش شبکه، مقادیر واقعی با خروجی‌هایی که توسط مدل انفیس پیش‌بینی شده است، مورد مقایسه قرار می‌گیرد. شکل (۵-۷)، مقایسه‌ای بین داده‌های درجه فرسایش مته در حالت واقعی و مقادیر پیش‌بینی شده توسط انفیس، برای داده‌های مربوط به مرحله آموزش را نشان می‌دهد. منحنی خط چین قرمز در این نمودار، درجه فرسایش مته در حالت واقعی و خطوط آبی، درجه فرسایش مته پیش‌بینی شده توسط مدل را بیان می‌کنند. تطابق مناسب بین داده‌های واقعی و خروجی‌های مدل وجود دارد. همچنین مقدار ضریب همبستگی ۰/۹۷۸۴۱ برای این داده‌ها به دست آمده است. شکل (۵-۸) نمودار رگرسیونی برای داده‌های آموزش را نشان می‌دهد.




شکل (۵-۷): مقایسه درجه فرسایش مته در حالت واقعی و مقادیر پیش بینی شده داده آموزش توسط انفیس




شکل (۵-۸): نمودار رگرسیونی داده‌های درجه فرسایش مته در حالت واقعی و مقادیر پیش بینی شده توسط مدل انفیس

دامنه خطای خروجی برای داده‌های آموزش در شکل (۵-۹) نشان داده شده است. همانطور که مشاهده می‌شود، در بدترین حالت خطای خروجی‌های مدل بین مقادیر $0/۲$ و $۰/۴$ - می‌باشد. با رسم نمودار فراوانی خطا در شکل (۵-۱۰)، تمرکز خطای داده‌های آموزش نیز قابل مشاهده است. میانگین مربعات خطا و انحراف معیار این مجموعه از داده‌ها، به ترتیب برابر $۰/۱۶۲$ و $۰/۱۲۷$ است. تطابق مناسب بین داده‌های واقعی و خروجی‌های مدل و همچنین مقدار ضریب همبستگی در کنار مقدار میانگین مربعات خطا و در نتیجه انحراف معیار کمتر، به عنوان شاخصی از عملکرد مناسب مدل در آموزش داده‌ها می‌باشد.




شکل (۵-۹): نمودار دامنه خطا داده‌های آموزش




شکل (۵-۱۰): نمودار فراوانی خطای داده‌های آموزش

۵-۴-۲ نتایج آزمایش مدل استنتاج تطبیقی فازی - عصبی:

داده‌های آزمایش برای ارزیابی و کارآمدی مدل مورد بررسی قرار گرفت. با اعمال ورودی‌های آزمایش به مدل انفیس، خروجی‌های به دست آمده از مدل نسبت به داده‌های واقعی آزمایش مورد مقایسه قرار می‌گیرد. شکل (۵-۱۱) و شکل (۵-۱۲) به ترتیب نمودار مقایسه‌ای و نمودار رگرسیونی داده‌های آزمایش را نشان می‌دهد.




شکل (۵-۱۱): نمودار مقایسه درجه فرسایش مته در حالت واقعی و مقادیر پیش بینی شده آزمایش توسط مدل انفیس




شکل (۵-۱۲): نمودار رگرسیونی داده‌های آزمایش درجه فرسایش مته در حالت واقعی و مقادیر پیش بینی شده توسط

مدل انفیس

نمودار خطای خروجی‌های داده‌های آزمایش در شکل (۵-۱۳) نشان داده شده است. همانطور که مشاهده می‌شود، در بدترین حالت خطای بین دو مقادیر واقعی و خروجی‌های مدل برای داده‌های آزمایش بین $0/6$ تا $-0/4$ می‌باشد. با رسم نمودار فراوانی خطا در شکل (۵-۱۴) تمرکز خطای داده‌های آزمایش نیز قابل مشاهده است. مقدار میانگین مربعات خطا و انحراف معیار این مجموعه از داده‌ها به ترتیب برابر $0/48$ و $0/21$ است. مقدار میانگین مربعات خطا و در نتیجه انحراف معیار به دست آمده در کنار ضریب رگرسیون $0/9252$ ، تطابق مناسب بین داده‌های واقعی و خروجی‌های مدل را نشان می‌دهد.



شکل (۵-۱۳): نمودار دامنه خطا داده‌های آزمایش



شکل (۵-۱۴): نمودار فراوانی داده‌های آزمایش

۶. فصل ششم

نتیجه گیری و پیشنهادات

۱-۶ نتیجه گیری :

- استفاده از تکنیک شعاع نرمال شده آماری روی داده‌ها با به کارگیری محدودیت شعاعی، منجر به شناسایی و حذف الگوهای متفاوت مته و دستیابی به فرآیند آموزش با پیچیدگی کمتر شد.
- مدل شبکه عصبی - ژنتیک براساس الگوهای دریافتی از مته‌های در دسترس، توانست تشخیص مطلوبی نسبت به طبقه بندی فرسایش مته‌ها انجام دهد. به کارگیری الگوریتم بهینه‌ساز، مدل را در راستای افزایش دقت پیش برد. نرخ طبقه‌بندی صحیح تعیین شده بر اساس ماتریس طبقه-بندب مته‌های آموزش و آزمایش با مقادیر $0.82/38\%$ و $0.81/11\%$ ، گویای این مطلب است.
- استفاده از یک شبکه عصبی طبقه‌بندی در مقایسه با شبکه‌های عصبی تخمین‌گر برای آگاهی از شرایط فرسایش مته، بادقت بیشتری عمل می‌کند. شبکه عصبی طبقه‌بندی در این پایان‌نامه مقادیر ضریب همبستگی 0.96 و 0.95 را به ترتیب برای مته‌های آزمون و آزمایش تعیین کرده است.
- در زمان آموزش و آزمون شبکه عصبی طبقه‌بندی، آنچه حائز اهمیت است، به کارگیری تمام جنبه‌های مورد نظر در الگوهای آموزش و آزمون می‌باشد. بطوریکه انتخاب صحیح و مناسب داده‌های آموزش و آزمون تاثیر به سزایی در موفقیت مدل ساخته شده داشت.
- مدل دوم یا انفیس بر پایه هیبرید دو تکنیک فازی و عصبی، با به کارگیری روش‌های آموزشی گرادیان، قوانینی را برای مدل سازی بر پایه داده‌های در دسترس تعیین می‌کند. هر دو مدل بر اساس داده‌های آموزش و آزمایش طراحی شده‌اند. با این تفاوت که مدل اول با استفاده از روش-های تکاملی آموزش داده شده است.
- زمانی که بر همکنش بین پارامترها قابل تشخیص نباشد، انفیس با ایجاد و یافتن قوانین بین پارامترهای ورودی نسبت به خروجی مدل، کارآمد خواهد بود.

- این مدل‌ها به دلیل فقدان به کارگیری پارامترهای مرتبط با خصوصیات سنگ، از جمله مقاومت تراکمی سنگ، به عنوان یکی از فاکتورهای موثر در فرسایش مته که بطور مستقیم در آموزش مدل دخالت نداشته است، قابلیت تعمیم‌دهی به سایر ساختارهای زمین شناسی و حوضه‌های رسوبی را نخواهد داشت.

۲-۶ پیشنهادات:

- استفاده از اطلاعات چاه‌های دارای مسیر حفاری مستقیم و با انحراف کمتر، به افزایش دقت مدل منجر خواهد شد. انحراف مسیر حفاری چاه منجر به فرسایش نامتوازن دندان‌ها-های مته و در نتیجه کاهش دقت مدل می‌گردد. پیشنهاد می‌شود در انتخاب داده‌ها به مسیر حفاری چاه دقت شود.
- بررسی فرسایش مته در روش حفاری با موتورهای درون چاهی، از نظر کاربرد روز افزون در چاه‌های افقی و اهمیت این نوع چاه‌ها، به دلیل سرعت چرخش بالا و فرسایش سریع مته، پیشنهاد می‌شود.
- تعیین میزان تاثیر عوامل مختلف بر فرسایش مته به وسیله آنالیز حساسیت‌سنجی، در بهبود عملیات حفاری از طریق آگاه‌سازی حفار و پرسنل حفاری، موثر خواهد بود.
- راهکارهای جدید و هوشمند برای حل مسائل حفاری در بسیاری از موارد (مثل تشخیص شکست یا تاقان مته) می‌تواند راهگشا باشد. بنابراین بررسی این روش‌ها پیشنهاد می‌گردد.

1. Bataee, M., Mohseni, S., (2011), Application of Artificial Intelligent Systems in ROP Optimization: a Case Study . middle east Unconventional Gas Conference and Exhibition, Paper No.140029
2. Moran, D.P., Ibrahim, H., Purwanto, A., (2010)., Sophisticated ROP Prediction Technology Based on Neural Network Delivers Accurate Results Sophisticated ROP Prediction Technology Based on Neural Network Delivers Accurate Results. IADC/SPE Asia Pacific Drilling Technology Conference and Exhibition, Paper No.132010.
3. Gidh, Y.K., Purwanto, A., Ibrahim.H., (2012). Artificial Neural Network Drilling Parameter Optimization System Improves ROP by Predicting/Managing Bit Wear. Presented at Intelligent Energy International, the Netherland, Paper No.149801.
4. Galle, E.M., Woods., H.B., (1960), How to Calculate Bit Weight and Rotary Speed for lowest Cost Drilling. oil and gas jornal, 167, 76.
5. Cunningham, R.A., (1960), Laboratory Studies of the Effect of Rotary Speed on Rock-Bit Performance and Drilling Cost. Presented at Meeting of Mid-Contenent District.
6. Hurbert, F., (1993). Practical Evaluation of Rock-Bit Wear during Drilling. Journal of Drilling and Completion, Vol.8, 99-104.
7. Lesage, M.L.G., Falconer, I.G., Wand, P.A., Mocann, d.P., (1988), An Analysis of Bit Bearing Failures With Field and Laboratory Data. IADC/SPE Drilling Conference, Paper No.17187.
8. Quiroga, J., Valeria, R., Fernandez, A., Arias, A., Bravo, H., (2006). Innovative Technology/Best PracticesMaximizes ROP. Presentation at the First International Oil Conference and Exhibition, Paper No.103954.
9. Rashidi, B., Hareland, G. and Nygaard, R.,(2008). Real-Time Drill Bit Wear Prediction by Combining Rock Energy and Drilling Strength Concepts. Abu Duabi International petroleum Exhibition & conference, Paper No. 117109.
10. Ng, G.W., (1997), Application of Networks to Adaptive Control of Nonlinear Systems. Willey & Sons Inc.

۱۱. نوروزی، س. (۱۳۹۳) بررسی تاثیر پارامترهای مکانیکی سنگ مخزن بر روی نرخ نفوذ حفاری در یک از میادین نفتی شرکت مهندسی توسعه نفت (متن). پایان نامه کارشناسی ارشد، دانشگاه صنعتی شاهرود.

12. Solberg, S.M., (2012), Improved Drilling Process Through The Determination of Hardness and Lithology Boundaries. Master thesis, Norwegian University of Science and Technology.

13. Rabia, H. (2002). Well Engineering and Construction. Elsevier Science Publishers.

14. Edalatkhah, S., Raoul, R., Hashemi, A., (2010), Bit Selection Optimization Using Artificial Intelligence System, Taylor & Francis Group, 28:1946-1956.

15. Nguyen, J.P., (1996) Oil and Gas Field Development Techniques – Drilling, Editions Technip, page 41-59.

16. Tobenna, C. U. (2010). Hole Cleaning and Hydraulics. University of Stavanger, Norway.

17. Nguyen, D.T., (2012), Drill Bits Technology Introduction of The New Kymera Hybrid Bit. Master thesis, University of Stavanger, Norway.

18. Bourgoyne, A.T., Millheim, K.K., Chenevert, M.E., Young, F.S., (1986), Applied Drilling Engineering, First edition, Richardson. United State

19. Baker Hughes INTEQ, (1995) Drilling Engineering Workbook – A Distributed Learning Course, 80270H Rev. B, December, Chapter 1 and 3.

20. Orogun, H.O., (2013) A Case Study on The Optimization of Hydraulic HorsePower for Efficient Bottom Hole Cleaning In Drilling. Master Thesis, Dalhousie university.

21. Fazelizadeh, M., (2013) . Real Time Torque and Drag Analysis During Directional drilling. PHD Thesis, University of Calgary, Alberta.

۲۲. منظمی، م.، هاشمی، ع. (۱۳۹۱) پیش بینی گیر رشته حفاری چاه‌های جهت‌دار میدان اهواز با استفاده از شبکه های عصبی. کنفرانس بین المللی نفت، گاز، پتروشیمی و نیروگاهی.

23. Hawkins, D., (1980), Identification of Outliers, Chapman and Hall.

24. Arehart, R.A., (1989). Drill Bit Diagnosis with Neural Network. SPE Annual Technical Conference and Exhibition, Paper No. 19558.

۲۵. عاشوری، ح.، مهرکی، م.، قاسم العسگری، م. ک.، (۱۳۸۹). بهینه سازی پارامترهای حفاری جهت انتخاب بهترین مته در یکی از مخازن نفتی با استفاده از شبکه عصبی. اولین همایش ملی فناوری‌های نوین در صنایع نفت و گاز.


26. Bilgesu, H.I., Altmis, U., Ameri, S., Mohaghegh, S., Aminian, K., (1998), A New Approach to Predict Bit Life Based on Tooth or Bearing Failures. SPE Eastern Regional Meeting. Paper No.51082.
 27. Hareland, G., Wu, A., James, J.A., (2009), Bearing Wear Model for Roller Cone Bits. IADC/SPE Middle East Drilling Technology Conference & Exhibition. Paper No.125644.
 28. Salakhov, T.R., Yamaliev, V.U., Dubinesky, U., (2008), A New Approach to Predict Bit Life Base on Tooth or Bearing Failures. SPE Eastern Regional Meeting, No. 51082.
۲۹. فیروزآبادی.م.، استفاده از شبکه های عصبی در پیش بینی میزان فرسایش یاتاقان و دندانه مته های مخروطی در میادین نفتی جنوب ایران، پایان نامه کارشناسی ارشد، دانشگاه صنعت نفت، ۱۳۹۰.
30. Song, X., Wu, M., Jermaine, C., Ranka, S., (2007), Conditional Outlier Detection. IEEE Transactions on Knowledge and Data Engineering 19, 5, 631-645.
 31. Singh, K., Upadhyaya, S., (2012) Outlier Detection: Application And Techniques. International Journal of Computer Science Issues, Vol.9, January.
 32. Hausdorff, J. M., Ivanov, P.C., Mark, R.G., Mietus, J.E., Moody, G.B., Peng, C.K., Stanley, H.E., (2000), Physio Bank, Physio Toolkit, and PhysioNet: Components of a New Research Resource For Complex Physiologic Signals. Circulation 101, 23.
 33. Dasgupta, D., Nino, F., (2000), A Comparison of Negative and Positive Selection Algorithms in Novel Pattern Detection. In Proceedings of the IEEE International Conference on Systems, Man, and Cybernetics. Vol. 1, 125 - 130.
 34. Dasgupta, D., Majumdar, N., (2002), Outlier Detection in Multidimensional Data Using Negative Selection Algorithm. In Proceedings of the IEEE Conference on Evolutionary Computation. Hawaii, 1039 - 1044.
 35. Jayakumar, G.s, Thomas, B.J., (2013), A New Procedure of Clustering Based on Multivariate Outlier Detection. Journal of Data Science, 11, 69-84.
 36. Vieira, J., Morgadodias, F., Mota, A., (2004), Neuro - Fuzzy Systems : A Survey. In 5th WSEAS NNA. International Conference on Neural Networks and Applications.
 37. Nauck, D., Kruse, R., (1999), Obtaining Interpretable Fuzzy Classification Rules From Medical Data. Artificial Intelligence in Medicine, 16, 149 – 169.

38. Jangh, J.S.R., Sun, C.T., (1995). Neuro - Fuzzy Modeling and Control. In The Proceeding of the IEEE, vol. 83, 378–406.
39. Takagi, T., Sugeno, M., (1983), Derivation of Fuzzy Control Rules From Human Operator's Control Action in Proc. IFAC Symp. Fuzzy Inform, Knowledge Representation and Decision Analysis, July, pp. 55–60.
40. Mamdani, E.H., Assilian, S., (1975). An Experiment in Linguistic Synthesis with a Fuzzy Logic Controller. International Journal of Man-Machine Studies, Vol.7, 1–13.
41. Ross, T.J., (2009) Fuzzy logic with Engineering Application. Johny Wiley & Sons, England, pp 648.
42. Negnevitsky, M., (2005) Artificial Intelligence: A Guide to Intelligent Systems. Second Edition, Addison Wesley, Essex, England.

Abstract

Drilling operations is one of the most costly activities in the oil industry upstream. Drilling industry has focused on reducing costs. The time factor can be used in drilling operations as the most effective factor of rising costs. Most of the costs associated with drilling, including personnel costs, drilling rig rental, transport and feeding, directly increase by increasing time of a well drilling. Losing of drill bit into the bore hole, reducing the penetration rate, fishing, redirect the well due to loss of the original route or direction of trajectory and stuck piping due to pressure difference can be named delay in drilling operations. In this study, we try to introduce model against traditional methods of wearing bit control conditions that require direct observation and stop drilling. So engineers be able to control the bit wear condition real-time in drilling of the well bore. Thus, by preventing of rate reduction of drilling penetration rate due to reduced wear bit and cutting power for drilling the formation, it will reduce the cost of the drilling operation. By taking advantage of researches and previous studies had done in this field on the basis of mathematical models and neural networks, we will try to be a step further. New models are based on adaptive neural fuzzy inference systems and other model is neural network model using a genetic optimization algorithm, instead of gradient base algorithm method, in order to compare with fuzzy logic and neural networks and to improve the construction of a model to predict wear of the bit. Model input parameters are included: the drilling penetration rate, weight on bit, rotational speed, pump flow, depth in and depth out, bit size, bit type and time. Degree of the bit wearing is the output. According to the correlation, coefficient value of test data is 0.96444 for the first model, and 0.92524 for second model. result was close to observe value. This models are also reliable for the perediction.

Keywords: Fuzzy logic, Neural Network, bit wear, Adaptive Neural-Fuzzy Inference System (ANFIS).



دانشگاه صنعتی شاهرود

Univesity of Shahrood Technology

Faculty of Mining, Petroleum & Geophysics Engineering

Application of adaptive neural-fuzzy inference system and neural network-genetic algorithm in prediction of bit wearing degree.

Siavash Asghari Rodsari

Supervisor:
Mehrdad Soleimani Monfared
Behnam Mirshekary

December 2015