

الله اعلم
الله اعلم



دانشکده مهندسی معدن، نفت و ژئوفیزیک

گروه نفت و ژئوفیزیک

پایان نامه کارشناسی ارشد

ارزیابی تراوایی سنگ مخزن با استفاده از روش آنالیز تصویر و نتایج لاگ NMR در جنوب
ایران

نگارنده: مهناز عابدینی

استاد راهنما:

دکتر منصور ضیائی

استاد مشاور:

مهندس جواد قیاسی فریز

شهریور ۱۳۹۶

تقدیم به پدر بزرگوارم

کوهی استوار و حامی من در طول تمام زندگی،

تقدیم به مادر مهربانم

سنگ صبوری که الفبای زندگی به من آموخت،

و تقدیم به خواهران و برادرانم

تشکر و قدردانی

پروردگار بخشنده را سپاس که یاری‌رسان من در تمامی مراحل زندگی بوده و الطاف خویش را از من دریغ ننموده است. بر خود لازم می‌دانم از یاری استادان و دوستانی که در نگارش این مجموعه مرا یاری نمودند، تشکر و قدردانی نمایم:

از استاد محترم، آقای دکتر منصور ضیائی که راهنمایی این پایان‌نامه را عهده‌دار شدند و با رهنمودهای خود، مسیر انجام این تحقیق را هموار نمودند، تشکر و قدردانی می‌نمایم.

از آقای مهندس جواد قیاسی فریز که زحمت مشاوره این پایان‌نامه را بر عهده گرفتند و با راهنمایی‌های خود، تکمیل این پایان‌نامه را میسر نمودند، تشکر می‌نمایم.

از استادان محترم، آقای دکتر امین روشندل کاهو و آقای دکتر مهرداد سلیمانی منفرد که زحمت داوری این پایان‌نامه را برعهده داشتند، کمال تشکر و سپاس را دارم.

از مهندس مهدی ضیائی برای راهنمایی‌های بی‌دریغ خود و از دوستان مهربانم که مرا در انجام این تحقیق یاری نمودند، تشکر می‌نمایم.

وظیفه خود می‌دانم که از پدر و مادر عزیزم به خاطر زحمات و حمایت‌هایشان در مسیر انجام این تحقیق، تشکر و قدردانی نمایم.

تعهد نامه

اینجانب مهنراز عابدینی دانشجوی دوره کارشناسی ارشد رشته مهندسی اکتشاف نفت دانشکده مهندسی معدن، نفت و ژئوفیزیک دانشگاه صنعتی شاهرود نویسنده پایان نامه: ارزیابی تراوایی سنگ مخزن با استفاده از روش آنالیز تصویر و نتایج لاگ NMR در جنوب ایران تحت راهنمایی دکتر منصور ضیائی متعهد می شوم:

- تحقیقات در این پایان نامه توسط اینجانب انجام شده است و از صحت و اصالت برخوردار است.
- در استفاده از نتایج پژوهش های 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 صنعتی شاهرود می باشد و مقالات مستخرج با نام «دانشگاه صنعتی شاهرود» و یا «Shahrood University of Technology» به چاپ خواهد رسید.
- حقوق معنوی تمام افرادی که در به دست آمدن نتایج اصلی پایان نامه تأثیرگذار بوده اند، در مقالات مستخرج از پایان نامه رعایت می گردد.
- در کلیه مراحل انجام این پایان نامه، در مواردی که از موجود زنده (یا بافت های 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 اخلاقی انسانی رعایت شده است.

تاریخ: ۱۳۹۶/۰۶/۱۱

مهنراز عابدینی

مالکیت نتایج و حق نشر

- کلیه حقوق معنوی این اثر و محصولات آن (مقالات مستخرج، کتاب، برنامه های رایانه ای، نرم افزارها و تجهیزات ساخته شده) متعلق به دانشگاه صنعتی 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:

مشخصه‌های مخزن، نقش بسیار مهمی در مدیریت و توسعه مخازن ایفا می‌کنند. تراوایی، توانایی سنگ متخلخل برای عبور سیال و یکی از مهم‌ترین ویژگی‌های سنگ مخزن است، زیرا تولید هیدروکربن به تراوایی مخازن بستگی دارد. این پارامتر، در آزمایشگاه با تزریق هوا بر روی نمونه‌های مغزه، و یا آزمایش چاه اندازه‌گیری می‌شود. این روش‌ها پرهزینه و زمان‌بر هستند. در سال‌های اخیر، با پیشرفت‌های سخت‌افزاری و نرم‌افزاری، توانایی سیستم‌های هوشمند و آنالیز تصویر اثبات شده است. بنابراین، آنالیز تصویر و سیستم‌های هوشمند به منظور کاهش زمان و هزینه در پیش‌بینی تراوایی مورد استفاده قرار گرفته است. مطالعه حاضر، شامل دو قسمت است.

در قسمت اول، تراوایی با استفاده از آنالیز تصویر پتروگرافی و سیستم‌های هوشمند پیش‌بینی شد. مقاطع نازک مربوط به چاه A میدان گازی پارس جنوبی مورد استفاده قرار گرفت. آنالیز تصویر پتروگرافی برای اندازه‌گیری تخلخل بین‌دانه‌ای، تخلخل درون‌دانه‌ای، تخلخل قالبی، ریزتخلخل، تخلخل نوری، مقدار سیمان، کلسیت، دولومیت و انیدریت، نوع بافت و میانگین ضریب شکل هندسی فضاهای خالی مورد استفاده قرار گرفت. از سه سیستم هوشمند شامل شبکه عصبی کم‌عمق، منطق فازی و عصبی فازی برای پیش‌بینی تراوایی استفاده شد.

تراوایی با استفاده از سیستم‌های هوشمند و ویژگی‌های پتروگرافی پیش‌بینی شد. میانگین مربعات خطای شبکه عصبی کم‌عمق، منطق فازی و عصبی فازی برای داده‌های نرمال تست، به ترتیب، $0/0107$ ، $0/0080$ و $0/0081$ محاسبه شد. میانگین خطای مطلق شبکه عصبی کم‌عمق، منطق فازی و عصبی فازی برای داده‌های واقعی تست، به ترتیب، $11/54$ ، $11/17$ و $10/85$ میلی‌داری محاسبه شد که متناظر با مقادیر ضریب همبستگی $0/9397$ ، $0/9588$ و $0/9558$ است.

مفهوم ماشین کمیته برای بهبود دقت پیش‌بینی استفاده شد. بنابراین، دو نوع ماشین کمیته برای ترکیب تراوایی پیش‌بینی شده از سیستم‌های هوشمند مورد استفاده قرار گرفت: میانگین‌گیری ساده و میانگین‌گیری وزن‌دار. در میانگین‌گیری وزن‌دار، از الگوریتم بهینه‌سازی ازدحام ذرات برای تعیین سهم

هر سیستم هوشمند استفاده شد. میانگین مربعات خطای ماشین‌های کمیته مبتنی بر میانگین‌گیری ساده و وزن‌دار، برای داده‌های نرمال تست، به ترتیب، ۰/۰۰۷۲ و ۰/۰۰۶۶ محاسبه شد. میانگین خطای مطلق ماشین‌های کمیته مبتنی بر میانگین‌گیری ساده و وزن‌دار، برای داده‌های واقعی تست، به ترتیب، ۹/۰۳ و ۸/۹۴ میلی‌داریسی محاسبه شد که متناظر با مقادیر ضریب همبستگی ۰/۹۶۲۳ و ۰/۹۶۲۲ است. مقایسه نتایج قسمت اول با داده مغزه، نشان می‌دهد که آنالیز تصویر و سیستم‌های هوشمند برای پیش‌بینی تراوایی، موفقیت‌آمیز به کار برده شدند و ماشین‌های کمیته مبتنی بر سیستم‌های هوشمند، پیش‌بینی دقیق‌تری فراهم آوردند.

در قسمت دوم، تراوایی NMR با نتایج قسمت اول مقایسه شد. تراوایی NMR چاه A در دسترس نبود. بنابراین، از اطلاعات چاه B شامل لاگ‌های GR، NPHI، PEF و RHOB به عنوان ورودی‌ها و تراوایی NMR به عنوان خروجی، برای ساخت شبکه عصبی عمیق استفاده شد. میانگین مربعات خطای شبکه عصبی عمیق برای داده‌های نرمال آموزش، ۰/۰۰۲۰ محاسبه شد. این مدل برای پیش‌بینی تراوایی NMR چاه A مورد استفاده قرار گرفت. بنابراین، اطلاعات چاه A شامل لاگ‌های GR، NPHI، PEF و RHOB به مدل، وارد و تراوایی NMR پیش‌بینی شد. تراوایی مغزه و تراوایی NMR پیش‌بینی شده در مقابل عمق، رسم شدند و ضریب همبستگی محاسبه شد. مقدار ضریب همبستگی ۰/۹۷۶۵ نشان می‌دهد که تراوایی مغزه و تراوایی NMR پیش‌بینی شده، همبستگی خوبی دارند. بنابراین تراوایی پیش‌بینی شده با آنالیز تصویر و سیستم‌های هوشمند با تراوایی NMR پیش‌بینی شده، مقایسه شد.

مقایسه نتایج قسمت اول با تراوایی NMR پیش‌بینی شده نشان می‌دهد که مجموعه داده‌های پتروگرافی و سیستم‌های هوشمند عملکرد خوبی داشتند.

کلمات کلیدی: تراوایی، آنالیز تصویر پتروگرافی، سیستم‌های هوشمند، ماشین کمیته، شبکه عصبی

عمیق، تراوایی NMR

لیست مقالات مستخرج از پایان نامه

- عابدینی، م.، ضیائی، م. و قیاسی فریز، ج.، "ارزیابی تراوایی سنگ مخزن با استفاده از آنالیز تصاویر مقاطع نازک و سیستم‌های هوشمند"، دومین کنفرانس ملی ژئومکانیک نفت - کاهش مخاطرات اکتشاف و تولید، تهران، بهمن ۱۳۹۵.

- عابدینی، م.، ضیائی، م. و قیاسی فریز، ج.، "پیش‌بینی تراوایی سنگ مخزن با استفاده از روش آنالیز تصویر پتروگرافی و مقایسه با نتایج لاگ NMR"، سومین همایش انجمن رسوب‌شناسی ایران با تاکید بر رسوب‌شناسی مخازن هیدروکربوری، تهران، اردیبهشت ۱۳۹۶.

- Abedini, M., Ziaii, M. and Ghiasi-Freez, J., "The application of committee machine with particle swarm optimization to the assessment of permeability based on thin section image analysis", **International Journal of Mining & Geo-Engineering**, (2017).

فهرست مطالب

فصل اول: کلیات.....	۱
۱-۱ مقدمه.....	۲
۲-۱ بیان مسأله.....	۲
۳-۱ ضرورت و اهمیت مطالعه.....	۲
۴-۱ اهداف مطالعه.....	۳
۵-۱ ناحیه مورد مطالعه: میدان پارس جنوبی.....	۴
۱-۵-۱ موقعیت جغرافیایی.....	۴
۱-۵-۲ تاریخچه حفاری میدان.....	۴
۱-۵-۳ ساختار میدان.....	۵
۱-۵-۴ سازندهای مخزنی میدان.....	۶
۱-۴-۵-۱ سازند کنگان.....	۶
۱-۴-۵-۲ سازند دالان.....	۷
۶-۱ پیشینه تحقیق.....	۸
۷-۱ روش مطالعه.....	۲۰
۸-۱ ساختار پایان نامه.....	۲۳
فصل دوم: ارزیابی تراوایی در سازندهای کنگان و دالان.....	۲۵
۱-۲ مقدمه.....	۲۶
۲-۲ تراوایی.....	۲۶
۱-۲-۲ طبقه بندی تراوایی.....	۲۸
۲-۲-۲ روشهای تعیین تراوایی.....	۲۸
۳-۲ تغییرات تراوایی در سازندهای کنگان و دالان.....	۳۱
فصل سوم: آنالیز تصویر و سیستمهای هوشمند.....	۳۳
۱-۳ مقدمه.....	۳۴
۲-۳ آنالیز تصویر.....	۳۴
۱-۲-۳ تصویر دیجیتال.....	۳۴
۲-۲-۳ مدل رنگی RGB.....	۳۵
۱-۲-۲-۳ بخش بندی تصویر در فضای بردار RGB.....	۳۵
۳-۲-۳ مراحل مطالعه مقاطع نازک با استفاده از آنالیز تصویر.....	۳۶

۳۷	تهیه مقاطع نازک اشباع شده با اپوکسی آبی رنگ
۳۷	تهیه تصاویر از مقاطع نازک
۳۸	بخش‌بندی تصاویر
۳۸	استخراج ویژگی‌ها برای تشخیص الگو
۳۹	طراحی مدل‌های هوشمند برای تفکیک الگو
۳۹	سیستم‌های هوشمند
۴۰	شبکه عصبی مصنوعی
۴۰	ساختار شبکه عصبی
۴۲	یادگیری شبکه عصبی
۴۶	طبقه‌بندی شبکه عصبی
۴۷	شبکه عصبی کم عمق
۴۸	شبکه عصبی عمیق
۵۲	مزایا و معایب شبکه‌های عصبی
۵۲	منطق فازی
۵۳	سیستم‌های فازی
۵۴	سیستم‌های فازی خالص
۵۴	سیستم‌های فازی تاکاگی - سوگنو
۵۵	سیستم‌های فازی با فازی‌ساز و غیرفازی‌ساز
۵۵	سیستم‌های استنتاج فازی
۵۶	سیستم‌های عصبی فازی
۵۷	ماشین کمیته
۵۸	ماشین کمیته با میانگین‌گیری ساده
۵۸	ماشین کمیته با میانگین‌گیری وزن‌دار
۵۸	الگوریتم بهینه‌سازی ازدحام ذرات
۵۹	طرح کلی الگوریتم PSO
۶۳	فصل چهارم: پیش‌بینی تراوایی
۶۴	مقدمه
۶۴	استخراج داده‌های پتروگرافی
۶۷	آماده‌سازی داده‌ها
۶۷	انتخاب داده‌های مناسب
۶۸	بررسی ضریب همبستگی
۷۰	استفاده از شبکه عصبی کم عمق
۷۱	نرمال‌سازی داده‌ها
۷۲	پیش‌بینی تراوایی با استفاده از سیستم‌های هوشمند

۷۲	۴-۴-۱ پیش‌بینی تراوایی با استفاده از شبکه عصبی کم‌عمق.....
۷۴	۴-۴-۲ پیش‌بینی تراوایی با استفاده از مدل منطق فازی.....
۷۶	۴-۴-۳ پیش‌بینی تراوایی با استفاده از مدل عصبی فازی.....
۷۷	۴-۴-۴ ماشین کمیت‌ه مبتنی بر سیستم‌های هوشمند.....
۷۸	۴-۴-۱ ماشین کمیت‌ه با میانگین‌گیری ساده.....
۷۹	۴-۴-۲ ماشین کمیت‌ه با میانگین‌گیری وزن‌دار.....
۸۰	۴-۵ استفاده از نتایج لاگ NMR.....
۸۰	۴-۵-۱ انتخاب و آماده‌سازی داده‌ها.....
۸۲	۴-۵-۲ مدل‌سازی با شبکه عصبی عمیق.....
۸۴	۴-۵-۳ مقایسه نتایج سیستم‌های هوشمند با تراوایی لاگ NMR.....
۸۷	فصل پنجم: نتیجه‌گیری و پیشنهادها.....
۸۸	۵-۱ نتیجه‌گیری.....
۹۲	۵-۲ پیشنهادها.....
۹۳	منابع.....

فهرست شکل ها

- شکل (۱-۱): موقعیت جغرافیایی میدان پارس جنوبی در ایران - گنبد شمالی در قطر..... ۵
- شکل (۲-۱): فلوچارت نحوه انتخاب نوع و تعداد ویژگی‌های پتروگرافی مناسب جهت طراحی سیستم‌های هوشمند..... ۲۱
- شکل (۳-۱): فلوچارت طراحی ماشین کمیته مبتنی بر سیستم‌های هوشمند..... ۲۱
- شکل (۴-۱): فلوچارت طراحی شبکه عصبی عمیق براساس لاگ‌های چاه‌پیمایی چاه B..... ۲۲
- شکل (۵-۱): پیش‌بینی تراوایی لاگ NMR چاه A با استفاده از مدل شبکه عصبی عمیق..... ۲۲
- شکل (۱-۳): نمایش در بر گرفتن مناطق داده برای بخش‌بندی بردار RGB..... ۳۶
- شکل (۲-۳): بخش‌بندی تصویر..... ۳۸
- شکل (۳-۳): ساختار یک نورون با بردار ورودی..... ۴۰
- شکل (۴-۳): توابع تصمیم‌گیری..... ۴۱
- شکل (۵-۳): شبکه عصبی پیشرو تشکیل شده از سه لایه..... ۴۷
- شکل (۶-۳): یک لایه از نورون‌های LOG SIGMOID..... ۴۷
- شکل (۷-۳): ساختار شبکه پیشرو..... ۴۸
- شکل (۸-۳): ساختار شبکه AE..... ۴۹
- شکل (۹-۳): ساختار AE اول در شبکه SAE..... ۵۰
- شکل (۱۰-۳): ساختار AE دوم در شبکه SAE..... ۵۰
- شکل (۱۱-۳): ساختار لایه طبقه‌بندی کننده SOFTMAX در شبکه SAE..... ۵۱
- شکل (۱۲-۳): ساختار شبکه SAE با دو لایه پنهان..... ۵۱
- شکل (۱۳-۳): چهار نوع تابع عضویت..... ۵۳
- شکل (۱۴-۳): سیستم فازی خالص..... ۵۴
- شکل (۱۵-۳): سیستم فازی تاکاگی - سوگنو..... ۵۴
- شکل (۱۶-۳): سیستم فازی با فازی‌ساز و غیر فازی‌ساز..... ۵۵
- شکل (۱۷-۳): عملکرد سیستم عصبی فازی برای تنظیم پارامترهای توابع عضویت..... ۵۷
- شکل (۱۸-۳): نمایش فرضی موقعیت یک ذره در فضای جستجو..... ۶۰
- شکل (۱۹-۳): فلوچارت الگوریتم PSO..... ۶۲
- شکل (۱-۴): تصاویر مقاطع نازک..... ۶۶
- شکل (۲-۴): نمایش همبستگی پارامترهای پتروگرافی با تراوایی مغزه..... ۶۸
- شکل (۳-۴): نمودار مقایسه تراوایی پیش‌بینی شده با مدل شبکه عصبی کم‌عمق و تراوایی مغزه..... ۷۳
- شکل (۴-۴): توابع عضویت برای ویژگی‌های تخلخل بین‌دانه‌ای و میانگین ضریب شکل هندسی در مدل منطق فازی..... ۷۵
- شکل (۵-۴): نمودار مقایسه تراوایی پیش‌بینی شده با مدل منطق فازی و تراوایی مغزه..... ۷۶
- شکل (۶-۴): نمودار مقایسه تراوایی پیش‌بینی شده با مدل عصبی فازی و تراوایی مغزه..... ۷۷
- شکل (۷-۴): نمودار مقایسه تراوایی پیش‌بینی شده با ماشین کمیته با میانگین‌گیری ساده و تراوایی مغزه..... ۷۸
- شکل (۸-۴): نمودار مقایسه تراوایی پیش‌بینی شده با ماشین کمیته با میانگین‌گیری وزن‌دار و تراوایی مغزه..... ۸۰

- شکل (۹-۴): نمایش تراوایی NMR پیش‌بینی شده و تراوایی مغزه در مقابل عمق ۸۳
- شکل (۱۰-۴): نمودارهای مقایسه تراوایی پیش‌بینی شده با سیستم‌های هوشمند و تراوایی NMR ۸۴
- شکل (۱۱-۴): نمودارهای مقایسه تراوایی پیش‌بینی شده از ماشین‌های کمیت و تراوایی NMR ۸۵
- شکل (۱-۵): مقایسه نتایج سیستم‌های هوشمند با تراوایی مغزه و تراوایی NMR پیش‌بینی شده ۹۱

فهرست جدول‌ها

جدول (۱-۲): بررسی ارتباط تراوایی و کیفیت مخزن	۲۸
جدول (۲-۲): روند تغییرات تراوایی در سازندهای کنگان و دالان	۳۲
جدول (۳-۲): روند تغییرات تخلخل در سازندهای کنگان و دالان	۳۲
جدول (۱-۴): مقادیر MSE آموزش و ضریب همبستگی شبکه‌های عصبی کم‌عمق براساس تعداد و نوع ویژگی‌ها	۷۱
جدول (۲-۴): مشخصات شبکه عصبی کم‌عمق	۷۳
جدول (۳-۴): مقدار MSE آموزش برای سیستم‌های فازی با شعاع خوشه‌سازی متفاوت	۷۴
جدول (۴-۴): مقدار MSE آموزش برای سیستم‌های عصبی فازی با شعاع خوشه‌سازی متفاوت	۷۷
جدول (۵-۴): مشخصات شبکه عصبی عمیق	۸۲
جدول (۱-۵): مقادیر خطا و ضریب همبستگی سیستم‌های هوشمند	۸۹
جدول (۲-۵): مقادیر خطا و ضریب همبستگی ماشین‌های کمیته مبتنی بر سیستم‌های هوشمند	۸۹
جدول (۳-۵): نتایج حاصل از مقایسه تراوایی پیش‌بینی شده از سیستم‌های هوشمند با تراوایی NMR پیش‌بینی شده	۹۰

فصل اول: کلیات

۱-۱ مقدمه

تعیین ویژگی‌های مخزنی و پیش‌بینی تولید در بخش‌های مختلف چاه، امری ضروری است. تراوایی یکی از مهم‌ترین ویژگی‌های سنگ مخزن و اهمیت آن در این است که تولید نفت از مخازن، تابع مستقیم تراوایی است. تعیین تراوایی با روش‌های مختلفی صورت می‌گیرد که معمولاً پرهزینه و زمان‌بر هستند. در سال‌های اخیر، با پیشرفت‌های نرم‌افزاری و سخت‌افزاری، استفاده از روش‌های هوشمند و مطالعات در زمینه آنالیز تصاویر تهیه شده از مقاطع نازک برای ارزیابی و شناخت ویژگی‌های سنگ مخزن گسترش یافته است.

۱-۲ بیان مسأله

پتروفیزیک شاخه‌ای از دانش است که به بررسی ویژگی‌های فیزیک سنگ می‌پردازد. هدف علم پتروفیزیک، تعیین ویژگی‌های سنگ مخزن است. تراوایی یکی از مهم‌ترین ویژگی‌های سنگ مخزن و از فاکتورهای موثر در تولید است. با اطلاع از ویژگی‌های سنگ مخزن، می‌توان به توصیف سنگ مخزن^۱ و تعیین زون‌های بهره‌ده^۲ پرداخت و با شناخت بهتر فاکتورهای موثر در تولید، می‌توان ارزیابی دقیق‌تری برای توسعه میدان انجام داد.

تعیین تراوایی با استفاده از روش‌های مختلفی صورت می‌پذیرد که معمولاً گران و زمان‌بر هستند. بنابراین، استفاده از آنالیز تصویر و سیستم‌های هوشمند به منظور تعیین خواص سنگ مخزن مانند تراوایی برای به حداقل رساندن زمان و هزینه، مورد توجه قرار می‌گیرد.

۱-۳ ضرورت و اهمیت مطالعه

تراوایی با استفاده از آنالیز مغزه و یا روش آزمایش چاه^۳ به دست می‌آید. روش‌های آنالیز مغزه، گران و زمان‌بر و نیازمند آزمایشگاه و دستگاه‌های مخصوصی هستند. روش آزمایش چاه نیز پرهزینه و وقت‌گیر

^۱ Reservoir characterization

^۲ Pay zone

^۳ Well test

است. تراوایی از فرمول‌های تجربی و داده^۱ NMR نیز به دست می‌آید اما نمودارگیری NMR نیز پرهزینه است. همچنین می‌توان تراوایی را از فرمول‌های تجربی با استفاده از لاگ‌های چاه‌پیمایی پیش‌بینی نمود که این روش برای همه سازندها به خوبی جواب نمی‌دهد. از روش رگرسیون چندگانه با استفاده از لاگ‌های چاه‌پیمایی نیز برای پیش‌بینی تراوایی استفاده می‌شود که نمی‌تواند مقادیر تراوایی را به طور دقیق محاسبه نماید. بنابراین، با توجه به اهمیت تراوایی در مواردی مانند توصیف مخازن، تعیین زون‌های بهره‌ده و تولید هیدروکربن و توجه به هزینه و زمان و ارائه پاسخ‌های مناسب، استفاده از سیستم‌های هوشمند و روش‌های آنالیز تصویر مورد توجه قرار می‌گیرد.

۴-۱ اهداف مطالعه

هدف کلی، تعیین یکی از ویژگی‌های پتروفیزیکی مخزن یعنی تراوایی با استفاده از آنالیز تصویر و سیستم‌های هوشمند به منظور ارائه پاسخ‌های با دقت مناسب و به حداقل رساندن هزینه و زمان است. اهداف این مطالعه، به صورت جزئی بیان می‌شود:

۱. استخراج ویژگی‌های پتروگرافی از تصاویر مقاطع نازک با آنالیز تصویر
۲. استفاده از ویژگی‌های پتروگرافی برای مدل‌سازی تراوایی با سیستم‌های هوشمند شامل شبکه عصبی کم‌عمق^۲، منطق فازی^۳ و عصبی فازی^۴
۳. استفاده از دو نوع ماشین کمیته مبتنی بر سیستم‌های هوشمند^۵ با میانگین‌گیری ساده^۶ و وزن‌دار^۷ برای ترکیب نتایج سیستم‌های هوشمند به منظور کاهش خطا در مدل‌سازی تراوایی
۴. مدل‌سازی با شبکه عصبی عمیق^۸ جهت پیش‌بینی تراوایی لاگ NMR

^۱ Nuclear magnetic resonance (NMR)

^۲ Shallow neural network (Sh-NN)

^۳ Fuzzy logic (FL)

^۴ Neuro fuzzy (NF)

^۵ Committee machine with intelligent systems (CMIS)

^۶ Simple averaging (SA)

^۷ Weighted averaging (WA)

^۸ Deep neural network (D-NN)

۵. مقایسه نتایج به دست آمده از مدل سازی تراوایی با سیستم های هوشمند و آنالیز تصویر، با تراوایی لاگ NMR پیش بینی شده

۱-۵ ناحیه مورد مطالعه: میدان پارس جنوبی

۱-۵-۱ موقعیت جغرافیایی

میدان پارس جنوبی، بزرگ ترین میدان گازی دنیا، ادامه میدان گازی گنبد شمالی^۱ قطر است. میدان گنبد شمالی در سال ۱۹۷۱ میلادی - ۱۳۵۰ شمسی در قطر، و میدان پارس جنوبی در سال ۱۳۶۹ شمسی با حفاری های اکتشافی و نتایج لرزه ای، در ایران کشف شده است [۱]. این میدان در موقعیت ۵۲ تا ۵۲/۵ درجه شرقی و ۲۶/۵ تا ۲۷ درجه شمالی، در ۱۰۵ کیلومتری جنوب غربی بندر عسلویه در آب های خلیج فارس واقع شده است [۲] و [۳] (شکل (۱-۱)). مساحت کل این میدان ۹۷۰۰ کیلومتر مربع که ۳۷۰۰ کیلومتر مربع از آن متعلق به ایران است [۱].


۱-۵-۲ تاریخچه حفاری میدان

در سال ۱۳۶۷، عملیات لرزه نگاری دریایی در منطقه ای از آب های خلیج فارس در مقابل آب های قطر به نام بلوک پنج، اطلاعات مهمی در مورد گسترش شمالی ساختمان گنبد شمالی در قطر به داخل آب های ایران عرضه نمود که در ایران، پارس جنوبی نامیده شد. مرحله دوم لرزه نگاری در سال های ۶۹ - ۱۳۶۸ در مناطق دیگر انجام پذیرفت و ابعاد گسترده تری از وسعت میدان را تا حد قابل اطمینانی مشخص نمود. براساس اطلاعات به دست آمده از برداشت های لرزه نگاری، حفاری اولین چاه اکتشافی در منطقه قله ساختمان نزدیک به خط میانی آب های خلیج فارس در اسفند ماه ۱۳۶۹ شروع شد. نتیجه بررسی های حفاری، وجود مواد هیدروکربنی در طبقات جهرم، داریان، گدوان و فلهیان، سورمه بالایی و مقادیر عظیمی از هیدروکربن های گازی در سازندهای کنگان و دالان را مشخص نمود [۲] و [۳].

^۱ North dome

۳-۵-۱ ساختار میدان

ساختار پارس جنوبی و تداوم اصلی جنوبی آن که گنبد شمالی قطر نامیده می‌شود، دارای یال‌های ملایم بوده که تشکیل دهنده یکی از قله‌های ساختمانی برآمدگی قطر - پارس جنوبی بر روی پلاتفرم کربناته منطقه خاورمیانه است. این ساختار دارای امتداد شمال شرقی - جنوب غربی، یکی از برجستگی‌های حاصل از برآمدگی ناحیه‌ای موسوم به کمان قطر^۱ که از جنوب شبه جزیره قطر تا جنوب ناحیه فارس در ایران، امتداد یافته است و خلیج فارس را به دو حوضه رسوبی تبخیری تقسیم می‌کند [۲] و [۳].



شکل (۱-۱): موقعیت جغرافیایی میدان پارس جنوبی در ایران - گنبد شمالی در قطر [۴]

^۱ Qatar arch

۱-۵-۴ سازندهای مخزنی میدان

سازندهای دالان و کنگان با سن پرموتریاس، مخازن اصلی این میدان را تشکیل می‌دهند که غالباً حاوی گاز و محصولات میعانی هستند. سنگ‌شناسی این دو سازند، بیشتر از دولومیت، آهک و انیدریت است.

۱-۴-۵-۱ سازند کنگان

سازند کنگان متعلق به تریاس زیرین است که مرز پایینی آن با سازند دالان ناپیوستگی دارد. مرز بالایی این سازند با بخش شیلی آغار از سازند دشتک، پیوسته و هم‌شیب است. ضخامت سازند کنگان در برش مقطع، ۱۷۸ متر و در چاه‌های حفاری شده، ۱۵۰ تا ۱۵۵ متر است.

سازند کنگان از لحاظ مخزنی به دو واحد K_1 و K_2 تقسیم می‌شود. ضخامت واحد K_1 تقریباً ۱۵۰ متر و مصادف با بخش بالایی سازند کنگان و شامل توالی دولومیت و آهک و لایه‌های انیدریتی است. براساس سنگ‌شناسی به سه بخش K_{1a} ، K_{1b} و K_{1c} تقسیم می‌شود که K_{1a} واحد دولومیتی در بالا، K_{1b} واحد آهکی در وسط و K_{1c} واحد دولومیتی - انیدریتی در پایین است. وجود لایه‌ها و پلاگ‌های انیدریتی در بخش دولومیتی زیر واحد K_{1a} باعث کیفیت پایین تا متوسط مخزنی شده است. زیر واحد K_{1b} به علت وجود پلاگ‌های انیدریتی و سیمان‌های آواری به طور کلی دارای کیفیت پایین تا متوسط مخزنی است. برخی لایه‌های دولومیتی متخلخل دانه‌پشتیبان با کیفیت بالای مخزنی در بخش میانی و بالایی زیر واحد K_{1c} وجود دارند، اما به طور کلی، این زیر واحد به علت سیمانی شدن و پلاگ‌های انیدریتی با کیفیت پایین تا متوسط مخزنی شناخته شده است.

ضخامت واحد مخزنی K_2 تقریباً ۴۰ تا ۴۵ متر و از لحاظ سنگ‌شناسی غالباً دولومیت و لایه‌های انیدریتی (بخش‌های بالایی) و آهک (بخش‌های پایینی) است. براساس تفاوت خصوصیات سنگ‌شناسی و مخزنی، به دو زیر واحد مخزنی K_{2a} و K_{2b} تقسیم می‌شود. زیر واحد K_{2a} عمدتاً دولومیتی با میان‌لایه‌های انیدریتی و K_{2b} اغلب آهکی با توالی دولومیت است. زیر واحد K_{2a} شامل دو بخش گل‌پشتیبان در بالا با کیفیت پایین مخزنی و دانه‌پشتیبان در پایین با کیفیت بالای مخزنی است. زیر واحد K_{2b} به دلیل وجود تخلخل قابل مشاهده دارای کیفیت مخزنی بالایی است و هیچ اثری از پلاگ‌های انیدریتی دیده نمی‌شود [۳].

۱-۵-۴-۲ سازند دالان

سازند دالان با سنگ‌شناسی آهک و دولومیت، یکی از بزرگ‌ترین مخازن گاز در حوضه خلیج فارس است. برش نمونه این سازند، تحت الارضی است و ضخامت آن به ۷۴۸ متر می‌رسد.

سازند دالان شامل واحدهای K_3 و K_4 است که از عمق ۲۹۱۳/۶ تا ۳۲۷۴/۷ متر قرار دارد. واحد K_3 با ضخامت تقریباً ۱۲۵ متر و به سن پرمین بالایی است. براساس تفاوت خصوصیات سنگ‌شناسی و مخزنی به سه زیرواحد مخزنی شامل K_{3a} ، K_{3b} و K_{3c} تقسیم می‌شود. زیرواحد K_{3a} از لحاظ سنگ‌شناسی غالباً دولومیت و شامل تعداد کمی لایه‌های متخلخل است. در کل این زیرواحد، خصوصیات مخزنی پایین تا متوسط را داراست. زیرواحد K_{3b} از لحاظ سنگ‌شناسی غالباً دولومیت با میان‌لایه‌هایی از انیدریت است. به دلیل وجود تخلخل‌های پر شده با سیمان انیدریتی، جزء واحدهای مخزنی طبقه‌بندی نمی‌شود. زیرواحد K_{3c} از لایه‌های انیدریتی ضخیم در بالا و پایین تشکیل شده و سنگ‌شناسی غالب این واحد، دولومیت با رخساره‌های غیرمتخلخل گل‌پشتیبان است. در بخش پایینی این زیرواحد، فواصل دانه‌پشتیبان با خصوصیات مخزنی خوب قابل مشاهده است.

واحد K_4 به عنوان توده مخزنی عمده در خلیج فارس شناخته شده است. سنگ‌شناسی غالب این واحد، دولومیت، رخساره‌های آهکی در بخش میانی، آهک دولومیتی و دولومیت آهکی است. این واحد براساس تفاوت خصوصیات سنگ‌شناسی و مخزنی، به سه زیرواحد مخزنی شامل K_{4a} ، K_{4b} و K_{4c} تقسیم می‌شود. زیرواحد K_{4a} به لحاظ سنگ‌شناسی غالباً دولومیت است. به دلیل دولومیتی شدن ثانویه و انحلال دیاژنتیکی، مقدار تخلخل ثانویه افزایش یافته است و براساس خصوصیات مخزنی، کیفیت مخزنی مناسبی را نشان می‌دهد. زیرواحد K_{4b} ارائه‌کننده مهم‌ترین بخش مخزنی میدان و سنگ‌شناسی غالب، آهک با تخلخل قالبی است. تخلخل‌های قالبی و بین‌دانه‌ای، تخلخل‌های غالب موجود در این بازه هستند. زیرواحد K_{4c} از لحاظ سنگ‌شناسی غالباً دولومیت با لایه‌هایی از انیدریت است. به طور کلی دارای تنوعی از کیفیت بد تا خوب مخزنی به دلیل پلاگ‌های انیدریتی در بخش‌های زیرین است [۳].

۱-۶ پیشینه تحقیق

مطالعات مختلفی در زمینه کاربرد آنالیز تصویر برای پیش‌بینی تراوایی انجام شده است:

بريمن و بلیر^۱، (۱۹۸۶) تصاویر SEM^۲ از مقاطع چندین نمونه متخلخل را با استفاده از روش‌های پردازش تصویر، رقمی و آنالیز نمودند و تخلخل و مساحت سطح ویژه را با توابع همبستگی دونقطه‌ای، پیش‌بینی کردند. سپس، برای پیش‌بینی تراوایی از رابطه تجربی کوزنی - کارمن^۳، مقادیر تخلخل و مساحت سطح ویژه تصویر را با مقادیر مشخص فاکتورهای سازندی ترکیب نمودند. نتایج نشان داده که برای نمونه‌های ماسه‌سنگی، تطابق خوبی با اندازه‌گیری‌های آزمایشگاهی وجود داشته است [۵].

کاسکن و واردلو^۴، (۱۹۹۳) مدلی تجربی برای پیش‌بینی تراوایی از ماسه‌سنگ‌ها با استفاده از داده به دست آمده از آنالیز تصاویر مقاطع نازک ارائه دادند. در این مطالعه از ۵۴ نمونه ماسه‌سنگ از یک مخزن نفتی آمریکای شمالی استفاده کردند. برای پیش‌بینی تراوایی، تخلخل و توزیع قطر بزرگ‌ترین دایره محاط شده در مساحت فضاهای خالی را از تصاویر استخراج نمودند. نتایج نشان داده، آنالیز رگرسیون بین داده به دست آمده از تصاویر و تراوایی مغزه، با ضریب تعیین $r^2 = 0.9$ ، تطابق خوبی را نشان داده است. پیش‌بینی تراوایی از نمونه‌هایی که برای آزمایش‌های متداول خیلی کوچک‌اند، از نتایج این مطالعه بوده که ارزیابی مقرون به صرفه‌ای از سازند و توصیف بهتر مخزن را فراهم نموده است [۶].

بلیر و همکاران، (۱۹۹۶) روشی برای پیش‌بینی تراوایی، براساس ویژگی‌های آماری هندسی ریز^۵ قابل مشاهده در تصاویر SEM پیشنهاد نمودند. در این روش، یک تابع همبستگی دونقطه‌ای را فرموله کردند و از آن برای پیش‌بینی تخلخل و مساحت سطح ویژه و ویژگی‌های دیگر مانند اندازه فضای خالی و دانه استفاده نمودند. سپس، تراوایی را با تخلخل و مساحت سطح ویژه و رابطه کوزنی - کارمن پیش‌بینی

¹ Berryman and Blair

² Scanning electron microscope (SEM)

³ Kozney and Carman

⁴ Coskun and Wardlaw

⁵ Coefficient of determination

⁶ Microgeometry

نمودند. مقایسه تراوایی پیش‌بینی شده در نمونه‌های ماسه‌سنگی با اندازه‌گیری‌های آزمایشگاهی، تطابق خوبی داشته است [۷].

انسلمتی^۱ و همکاران، (۱۹۹۸) از آنالیز تصویر دیجیتال برای تعیین ویژگی‌های فضای خالی و از نتایج به دست آمده برای توجیه تنوع تراوایی در نمونه‌های کربناته استفاده نمودند. تصاویر مقاطع نازک را با OM^۲ و ESEM^۳ تهیه کردند. تصاویر OM و ESEM به ترتیب بیانگر اطلاعات درشت‌تخلخل^۴ و ریزتخلخل^۵ است. سپس تصاویر را به درشت‌تخلخل و فاز ماتریکس (OM) یا ریزتخلخل و فاز جامد (ESEM)، تقسیم کردند و از آنالیز تصویر برای شناسایی فضاهای خالی و اندازه‌گیری مساحت و محیط فضای خالی استفاده نمودند. با مقایسه تخلخل مغزه با مقادیر درشت‌تخلخل و ریزتخلخل مشخص نمودند که اطلاعات متدولوژی با اطلاعات مغزه همخوانی داشته است. با توزیع و اطلاعات شکل فضای خالی نتیجه گرفته شده از اطلاعات درشت‌تخلخل و ریزتخلخل، توزیع مشخصه‌های فیزیکی در تراوایی را مورد بررسی قرار دادند و نتیجه گرفتند، تراوایی عمدتاً توسط شکل درشت‌تخلخل در نمونه‌های با تراوایی بالا، و توسط مقدار ریزتخلخل ذاتی در نمونه‌های با تراوایی کم کنترل شده است. سپس، با آموزش شبکه عصبی، تأثیر چهار ویژگی پتروگرافی (درشت‌تخلخل، ریزتخلخل، میانگین ضریب شکل هندسی و میانگین اندازه فضاهای خالی) بر تراوایی را مورد بررسی قرار دادند و نتیجه گرفتند که میانگین اندازه فضاهای خالی کمترین تأثیر را بر تراوایی داشته است [۸].

علی و چوات^۶، (۱۹۹۹) از شبکه‌های عصبی به دلیل توانایی درک روابط غیرخطی بین ورودی‌های چندگانه و انواع خروجی‌ها، و اطلاعات پتروگرافی برای پیش‌بینی تراوایی استفاده کردند. به منظور کاهش بعد نوزده عنصر پتروگرافی جمع‌آوری شده، از منطق فازی استفاده نمودند تا عناصر پتروگرافی تأثیرگذار برای کاهش خطای پیش‌بینی مشخص گردد. از ۳، ۵ و ۱۰ عنصر پتروگرافی تأثیرگذار، برای آموزش

¹ Anselmetti

² Optical microscope (OM)

³ Environmental scan electron microscope (ESEM)

⁴ Macroporosity

⁵ Microporosity

⁶ Ali And Chawathe

روابط پیچیده عناصر پتروگرافی و تراوایی، در شبکه عصبی استفاده کردند. نتایج به دست آمده بیانگر قابلیت ویژگی‌های پتروگرافی در پیش‌بینی تراوایی است. در میدان‌های قدیمی که آنالیز پتروگرافی متداول است، این روش ممکن است به پیش‌بینی تراوایی، ضمیمه شود [۹].

سولیمار و فابریسیس^۱، (۱۹۹۹) به پیش‌بینی تراوایی با آنالیز تصاویر BSEM^۲ از مقاطع صیقلی ماسه‌سنگی پرداختند. برای پیش‌بینی تخلخل، مقدار رس و دانه، از تفاوت‌هایی که در سطوح خاکستری به دلیل تغییرات چگالی وجود دارد، استفاده نمودند. تصویر را به دو فاز فضای خالی و دانه‌ها ساده‌سازی و مساحت سطح ویژه فاز جامد را محاسبه کردند و برای محاسبه تراوایی از رابطه کوزنی - کارمن استفاده نمودند. سپس، ویژگی‌های پتروفیزیکی شامل تخلخل و تراوایی را با نتایج آزمایشگاهی مقایسه کردند. نتایج نشان داده، در بزرگ‌نمایی ۱۵۰X تصویر، ریزتخلخل بخش رس قابل شناسایی نبوده و تخلخل تصویر در این بزرگ‌نمایی، نزدیک به تخلخل موثر برای ارزیابی تراوایی بوده است [۱۰].

گارنهم و هتفیلد^۳، (۲۰۰۱) از آنالیز تصاویر SEM به منظور درک بهتر رابطه تراوایی - تخلخل و بهبود پیش‌بینی تراوایی در یک مخزن استفاده کردند. به جای تخلخل مغزه در نمودار تراوایی - تخلخل از تخلخل تصویر استفاده نمودند تا رابطه قوی‌تری تعیین شود. بنابراین تحقیقاتی برای یافتن دلیل این رابطه بهبود یافته با در نظر گرفتن توزیع اندازه فضای خالی انجام دادند. نتایج نشان داده که محاسبه تخلخل تصویر شامل ریزتخلخل نبوده و ریزتخلخل در جریان سیال مشارکتی نداشته، درحالی‌که ریزتخلخل در اندازه‌گیری تخلخل در آنالیز مغزه وجود داشته است [۱۱].

اگومنت پیترسن^۴ و همکاران، (۲۰۰۲) به مرور بیش از ۲۰۰ کاربرد شبکه عصبی در آنالیز تصویر و نقش شبکه‌های عصبی در حال حاضر و آینده پرداختند. داده‌های مصنوعی را براساس مشکلات حل نشده مرتبط با کاربرد روش‌ها در آنالیز تصویر به خصوص کاربرد شبکه‌های عصبی ایجاد کردند و دورنمایی از کاربرد شبکه‌های عصبی و ارتباط آنها را با توسعه‌های نوین ارائه دادند [۱۲].

¹ Solymer and Fabricius

² Backscattered scanning electron microscope (BSEM)

³ Garnham and Hatfield

⁴ Egmont-Petersen

لاک^۱ و همکاران، (۲۰۰۲) مدلی برای پیش‌بینی تراوایی از نمونه مغزه سنگ رسوبی براساس آنالیز تصویر دو بعدی و ساختار فضای خالی آن ارائه دادند. ساختار فضای خالی را به صورت شبکه مکعبی از لوله‌های فضای خالی در نظر گرفتند. مساحت و محیط فضاهای خالی را از آنالیز تصویر SEM مقاطع نازک به دست آوردند. میزان هدایت^۲ هر لوله را از مساحت و محیط اندازه‌گیری شده با استفاده از تقریب شعاع هیدرولیک^۳ پیش‌بینی کردند و سپس، از EMT^۴ برای یافتن هدایت موثر یک لوله، براساس توزیع هدایت‌های اندازه‌گیری شده، استفاده نمودند. این فرآیند در چندین مخزن ماسه‌سنگی دریای شمال اجرا شده و نتایج موفقیت‌آمیزی داشته است [۱۳].

جرگوشنسکی^۵ و همکاران، (۲۰۰۴) متدولوژی برای پیش‌بینی تراوایی سنگ‌های رسوبی از تصاویر دو بعدی فضای خالی ارائه دادند. با استفاده از مساحت و محیط فضای خالی، قابلیت هدایت هیدرولیکی^۶ و سپس تراوایی سنگ را با EMT پیش‌بینی کردند. این متدولوژی را بر روی تصاویر SEM بیش از ۲۰ نمونه مغزه از مخزن دریای شمال اعمال کردند. در مقابل روش‌هایی که به ایجاد ساختار سه بعدی فضای خالی و حل معادلات جریان شبکه نیازمندند، متدولوژی پیشنهادی دارای حداقل محاسبات است. نتایج نشان داده، روش پیشنهادی عملکرد نسبتاً خوبی داشته است و اگر نمونه‌ها قبل از تهیه مقاطع و تصاویر، با اپوکسی اشباع شوند، فضای خالی غیرمتصل قابل شناسایی بوده و با حذف فضاهای خالی که جزئی از شبکه فضاهای خالی متصل نیستند، عملکرد روش بهبود می‌یابد [۱۴].

شمس نیا، (۱۳۸۵) تأثیر هندسه منافذ بر کیفیت مخزنی را در سازندهای کنگان و دالان مورد بررسی قرار داد. ویژگی‌های هندسی تخلخل مانند مساحت، محیط، قطر و درصد تخلخل را با استفاده از نرم‌افزار تحلیل گر تصاویر از ۵۳ مقطع نازک استخراج و با اطلاعات مغزه مقایسه نمود و روابط موجود بین ویژگی‌های هندسی و تراوایی را به دست آورد. نتایج نشان داده که تخلخل قابل مشاهده در مقاطع،

¹ Lock

² Conductance

³ Hydraulic radius approximation

⁴ Effective medium approximation-theory (EMA or EMT)

⁵ Jurgawczynski

⁶ Hydraulic conductivity

رابطه نزدیکی با تراوایی داشته است و علاوه بر تخلخل، مجموع ویژگی‌های هندسی تخلخل نیز در مقدار تراوایی موثر بوده‌اند [۳].

زیمرمن^۱ و همکاران، (۲۰۰۷) مدلی براساس آنالیز تصویر دو بعدی و ساختار فضاهای خالی آن، برای پیش‌بینی تراوایی از نمونه مغزه سنگ رسوبی ارائه دادند. از مساحت و محیط فضای خالی مشاهده شده در تصاویر SEM به عنوان ورودی مدل و از تقریب شعاع هیدرولیکی برای پیش‌بینی میزان هدایت فضاهای خالی استفاده نمودند. سپس، از EMT برای یافتن هدایت موثر فضاهای خالی استفاده کردند. از تصحیحات مختلفی برای تبدیل هندسه فضای خالی استفاده کردند که این تصحیحات، تفاوت عمده این مدل با سایر روش‌ها براساس آنالیز تصویر است. نتایج نشان داده، متدولوژی پیشنهادی نسبت به روش‌های تجربی مانند کوزنی - کارمن، دقت بیشتری داشته است [۱۵].

ال کاروسی و بلانت^۲، (۲۰۰۸) برای استخراج مدل‌های شبکه از تصاویر فضای خالی در نمونه‌های کربناته استفاده نمودند. بدین منظور، از تصویر دو بعدی مقطع نازک استفاده کردند و آن را به صورت آماری، به نماینده سه بعدی از فضاهای خالی تبدیل نمودند. سپس مدل شبکه را از این تصویر استخراج کردند. نتایج نشان داده، تراوایی مطلق پیش‌بینی شده از شبکه، با مقدار اندازه‌گیری شده از مغزه همچنین، با مقدار محاسبه شده با LBM^۳ از تصویر سه بعدی فضای خالی، تطابق داشته است [۱۶].

حسین^۴، (۲۰۱۱) از آنالیز تصاویر مقاطع نازک برای پیش‌بینی تراوایی نسبی استفاده نمود. رابطه کوزنی - کارمن، رابطه‌ای ساده و قدرتمند برای پیش‌بینی تراوایی مطلق از تخلخل و مساحت سطح ویژه است. برای پیش‌بینی تراوایی نسبی، فرضیه داری را بر روی رابطه کوزنی - کارمن اعمال نمود. سپس، از شبیه‌سازی عددی و آنالیز تصویر برای بررسی ثبات مدل تراوایی نسبی تقریب کوزنی استفاده نمود. نتایج نشان داده، تراوایی پیش‌بینی شده از شبیه‌سازی عددی و آنالیز تصویر، تطابق خوبی با تراوایی

¹ Zimmerman

² Al-Kharusi and Blunt

³ Lattice Boltzmann method (LBM)

⁴ Hossain

پیش‌بینی شده از مدل کوزنی داشته، به علاوه، تراوایی نسبی پیش‌بینی شده از شبیه‌سازی جریان LBM نیز به خوبی با تراوایی پیش‌بینی شده از رابطه کوزنی تطابق داشته است [۱۷].

هو و استرون^۱، (۲۰۱۱) از آنالیز تصویر برای ارزیابی اندازه بحرانی فضای خالی برای پیش‌بینی تراوایی خمیره سیمان استفاده کردند. ساختار فضاهای خالی را با استفاده از آنالیز تصاویر BSEM مقاطع پولیش خورده بررسی کردند. برای پیش‌بینی تراوایی از تئوری GEM^۲ با استفاده از تخلخل و اندازه بحرانی فضای خالی استفاده نمودند. نتایج نشان داده، تراوایی پیش‌بینی شده در مقایسه با نتایج آزمایشگاهی، تطابق خوبی داشته است [۱۸].

مستقیمی و بلانت، (۲۰۱۳) به محاسبه تراوایی مطلق در تصاویر Micro-CT^۳ پرداختند و نتایج آن را با تراوایی تعیین شده از LBM مقایسه نمودند. نتایج به دست آمده با اندازه‌گیری‌های آزمایشگاهی از نمونه‌های مغزه، تطابق داشته است. همچنین، نشان دادند که معادله کوزنی - کارمن برای سیستم‌های ناهمگن^۴، می‌تواند تراوایی را بیش از حد ارزیابی نماید. به علاوه، ناهمسان‌گردی^۵ تراوایی را در مقیاس فضای خالی، مورد بررسی قرار دادند. نتایج نشان داده، در ماسه‌سنگ‌ها، تراوایی با میانگین ۲۵ درصد در جهات مختلف تغییر نموده و ناهمسان‌گردی در کرنات‌ها، بیش از ۵۰ درصد بوده که نشان دهنده وجود فضای خالی متصل در یک جهت و فضای خالی غیرمتصل در جهت دیگر است [۱۹].

نبوی^۶، (۲۰۱۴) به محاسبه تخلخل، تراوایی و کشیدگی^۷ دانه با آنالیز تصویر دیجیتال برای ماسه‌سنگ‌های متخلخل پرداخت. دو معادله برای محاسبه تخلخل و تراوایی با کشیدگی دانه، معرفی و ضریب همبستگی تخلخل و کشیدگی، و تراوایی و کشیدگی را به ترتیب، ۰/۹۲ و ۰/۸۲ محاسبه نمود. معادله‌ای براساس رابطه قطر فضای خالی و کشیدگی دانه با ضریب همبستگی ۰/۸۰ بیان نمود. سپس، با آنالیز رگرسیون چندگانه و ارائه معادله برای کشیدگی، تخلخل و تراوایی، توانایی محاسبه کشیدگی

¹ Hu and Stroeven

² General effective media (GEM)

³ Micro-computed tomography (Micro-CT)

⁴ Heterogeneous

⁵ Anisotropy

⁶ Nabaway

⁷ Elongation

را بررسی نمود. نتایج نشان داده، تخلخل، تراوایی و قطر فضای خالی، عمدتاً با ناهمسان‌گردی شکل یا کشیدگی دانه کنترل شده است [۲۰].

ویناردی^۱ و همکاران، (۲۰۱۵) به پیش‌بینی تراوایی با قانون دارسی از طریق شبیه‌سازی واحد جریان در در تصویر دیجیتال با استفاده از LBM پرداختند. همچنین، از دو نوع معادله کوزنی - کارمن برای محاسبه تراوایی نمونه‌ها استفاده نمودند. معادله اول، به فاکتور شکل فضای خالی، تخلخل، ضریب پیچاپچی و مساحت سطح ویژه و معادله دوم به شعاع فضای خالی، تخلخل و ضریب پیچاپچی بستگی دارد. برای هر دو روش، از آنالیز تصاویر دیجیتال به دست آمده از Micro-CT استفاده نمودند. ابتدا، این روش‌ها را بر روی سه مدل لوله ساده که شعاع‌های متفاوتی داشتند، بررسی کردند و از نتایج قانون دارسی به عنوان مرجع استفاده نمودند. محاسبات نشان داده، معادله دوم، تفاوت کمتری با مرجع داشته است. سپس، برای تایید نتایج به دست آمده، این روش‌ها را بر روی ماسه‌سنگ‌ها اعمال نمودند [۲۱].

سریساتیاکورن^۲، (۲۰۱۶) تراوایی را با استفاده از روش‌های یادگیری عمیق^۳ مانند شبکه عصبی چندلایه^۴ و شبکه عصبی کانولوشن^۵ از تصاویر دو بعدی و سه بعدی Micro-CT پیش‌بینی نمود. از ویژگی‌های هندسی استخراج شده از تصاویر سه بعدی دودویی^۶ مانند تخلخل، مساحت سطح ویژه و انتگرال میانگین انحنا^۷ به عنوان ورودی شبکه عصبی چندلایه و از تصاویر دو بعدی و سه بعدی دودویی به عنوان ورودی شبکه عصبی کانولوشن استفاده کرد. نتایج نشان داده، به جای استفاده از شبیه‌سازی‌های متداول مانند LBM، امکان پیش‌بینی تراوایی با روش‌های یادگیری عمیق و آنالیز تصویر وجود داشته است [۲۲].

¹ Winardhi

² Srisutthiyakorn

³ Deep learning

⁴ Multilayer neural network (MNN)

⁵ Convolutional neural network (CNN)

⁶ Binary

⁷ Integral of mean curvature

سکسنا^۱ و همکاران، (۲۰۱۷) روشی برای پیش‌بینی تراوایی از مقاطع نازک مربوط به سازندهای ماسه‌سنگی و کربناته ارائه دادند. در مرحله اول، تراوایی را با استفاده از LBM از مقاطع نازک، محاسبه نمودند. در مرحله دوم، با تبدیل‌های دو بعدی - سه بعدی جدید، تراوایی مقاطع نازک را به تراوایی سه بعدی سنگ با استفاده از پارامترهای کالیبراسیون مرتبط ساختند. مدل پیشنهادی را با استفاده از اطلاعات سه بعدی در دسترس از ساختارهای ریز سنگ (مانند تصاویر SEM) کالیبره نمودند. نتایج نشان داده، تراوایی ماسه‌سنگ‌ها با دقت خوبی پیش‌بینی شده، اما پیش‌بینی تراوایی کربنات‌ها، به دلیل پیچیدگی‌های ساختارهای ریز، چالش برانگیز، و پارامترهای مدل، به کالیبراسیون بیشتری نیازمند است [۲۳].

مطالعات انجام شده، بیانگر کاربرد داده‌های حاصل از آنالیز تصاویر با فرمول‌های تجربی، روش‌های شبیه‌سازی، آنالیز رگرسیونی و سیستم‌های هوشمند برای پیش‌بینی تراوایی است. فرمول‌های تجربی به علت طبیعت پیچیده کربنات‌ها، قادر به پیش‌بینی دقیق تراوایی نیستند اما برای ماسه‌سنگ‌ها عملکرد خوبی دارند. از آنالیز رگرسیونی برای برقراری ارتباط بین تراوایی و ویژگی‌های استخراج شده از تصاویر استفاده می‌شود که نتایج دقیقی در پیش‌بینی تراوایی ندارد اما در تعیین روند تغییرات تراوایی، کارآمد است. آنالیز تصویر و سیستم‌های هوشمند به ویژه روش‌های یادگیری عمیق، مجموعه‌ای دقیق و کارآمد برای پیش‌بینی تراوایی و جایگزین خوبی برای روش‌های تعیین تراوایی مانند شبیه‌سازی است. به طور کلی، محققان مختلفی، قابلیت داده‌های استخراج شده با آنالیز تصاویر را برای پیش‌بینی تراوایی اثبات نموده‌اند. بنابراین، در این مطالعه، از آنالیز تصویر برای استخراج ویژگی‌های لازم در طراحی سیستم‌های هوشمند برای پیش‌بینی تراوایی استفاده شد.

مطالعات مختلفی برای پیش‌بینی تراوایی با سیستم‌های هوشمند و لاگ‌های چاه‌پیمایی انجام شده است:

^۱ Saxena

محقق و همکاران، (۱۹۹۴) از شبکه عصبی با الگوریتم پس‌انتشار خطا^۱ با استفاده از لاگ‌های GR، RHOB و DIL و تراوایی مغزه، به مدل‌سازی تراوایی پرداختند. مقایسه تراوایی پیش‌بینی شده با تراوایی مغزه نشان داده که روش پیشنهادی می‌تواند در مواقعی که تعداد نمونه‌های کمی برای اندازه‌گیری‌های آزمایشگاهی وجود دارد، مقادیر قابل اعتمادی از تراوایی را پیش‌بینی نماید [۲۴].

هله^۲ و همکاران، (۲۰۰۱) از شبکه عصبی پس‌انتشار خطا با تعداد زیادی نورون^۳ در لایه پنهان^۴ به دلیل پیچیدگی روابط و لاگ‌های GR، RHOB، NPHI و DT برای مدل‌سازی تراوایی استفاده کردند. میانگین اختلاف تراوایی پیش‌بینی شده و تراوایی مغزه را حدود ۴۰۰ میلی‌داری به دلیل عدم هماهنگی عمق مغزه - لاگ در قسمت‌های ناهمگن مخزن محاسبه نمودند [۲۵].

بدارینید^۵ و همکاران، (۲۰۰۲) تراوایی را با شبکه عصبی و لاگ‌های Resistivity، RHOB، NPHI، Caliper و GR در یک مخزن کربناته پیش‌بینی نمودند. در مرحله اول، نوع سنگ را با لاگ‌ها و دو اثر^۶ به دست آمده از تناظر لاگ‌های Resistivity به عنوان ورودی شبکه عصبی پیش‌بینی نمودند. در مرحله دوم، برای پیش‌بینی تراوایی، از نوع سنگ به دست آمده از مرحله اول و لاگ‌ها، برای طراحی شبکه عصبی استفاده نمودند. نتایج نشان داده، تراوایی پیش‌بینی شده، تطابق خوبی با تراوایی مغزه داشته است. به علاوه، قابلیت پیش‌بینی در چاهی که مغزه‌گیری نداشته و در مجاورت چاه مغزه‌گیری شده قرار گرفته، اثبات شده است [۲۶].

لیم^۷، (۲۰۰۵) از روش منطق فازی برای انتخاب لاگ‌های چاه‌پیمایی که رابطه خوبی با تراوایی مغزه داشتند، استفاده کرد. سپس، از شبکه عصبی برای ایجاد ارتباط بین تراوایی مغزه و لاگ‌های NPHI، DT، GR، RHOB و SP انتخاب شده از منطق فازی استفاده نمود. ضریب همبستگی برای تراوایی پیش‌بینی شده از شبکه عصبی و تراوایی مغزه را ۰/۹۹۹۸ محاسبه کرد. نتایج نشان داده که پیش‌بینی

¹ Backpropagation

² Helle

³ Neuron

⁴ Hidden layer

⁵ Badarinadh

⁶ Trace

⁷ Lim

تراوایی، دقت خوبی داشته است و این مدل هوشمند می‌تواند به عنوان ابزار قوی برای پیش‌بینی ویژگی‌های مخزنی از لاگ‌های چاه‌پیمایی در پروژه‌های توسعه نفت و گاز طبیعی مورد استفاده قرار گیرد [۲۷].

احمدی و همکاران، (۱۳۸۵) از شبکه عصبی با الگوریتم پس‌انتشار خطا و لاگ‌های چاه‌پیمایی و تراوایی مغزه برای ایجاد مدل تراوایی در میدان پارس جنوبی استفاده نمودند. میانگین مربعات خطا^۱ و میانگین خطای مطلق^۲ تراوایی پیش‌بینی شده با داده‌های نرمال تست را به ترتیب، ۰/۰۰۶۵ و ۰/۱۵۹۶ محاسبه کردند. نتایج نشان داده که مدل طراحی شده به خوبی قادر به پیش‌بینی تراوایی در مخزن مورد مطالعه بوده است [۲۸].

کدخدایی ایلخچی و همکاران، (۲۰۰۶) تراوایی را با استفاده از روش منطق فازی و لاگ‌های چاه‌پیمایی در یک میدان گازی پیش‌بینی نمودند. سپس، از شبکه عصبی پس‌انتشار برای تأیید نتایج فازی استفاده کردند. از سه چاه برای ساخت مدل هوشمند، و یک چاه برای ارزیابی اعتبار مدل استفاده نمودند. نتایج نشان داده، روش منطق فازی برای پیش‌بینی تراوایی، عملکرد موفقیت‌آمیزی داشته است [۲۹].

امینی، (۱۳۸۷) به پیش‌بینی تراوایی با روش منطق فازی از لاگ‌های چاه‌پیمایی و تراوایی مغزه پرداخت. سپس میزان تراوایی سازندها را در چاه آزمون برآورد نمود. مقادیر ضریب همبستگی بین تراوایی مغزه و تراوایی پیش‌بینی شده با روش منطق فازی را برای چاه‌های آموزش و آزمون به ترتیب ۰/۹۳ و ۰/۹۲ محاسبه نمود. نتایج نشان داده که منطق فازی عملکرد مناسبی در پیش‌بینی تراوایی داشته است [۳۰].

مهرکی و همکاران، (۱۳۸۹) از شبکه عصبی پیشرو^۳ با الگوریتم پس‌انتشار خطا و لاگ‌های DT، RHOB و GR با تراوایی مغزه برای ارزیابی تراوایی سازند آسماری استفاده کردند. مقادیر ضریب همبستگی تراوایی پیش‌بینی شده از شبکه عصبی و تراوایی مغزه را برای مجموعه آموزش و تست به ترتیب، ۰/۸۵

^۱ Mean squared error (MSE)

^۲ Mean absolute error (MAE)

^۳ Feedforward

و ۰/۸۲ محاسبه نمودند. نتایج نشان داده که شبکه عملکرد خوبی داشته است. بنابراین نتایج حاصل از شبکه را به چاه C که فاقد اطلاعات مغزه بود، تعمیم دادند. [۳۱].

کاظم شیرودی و همکاران، (۲۰۱۲) به ارزیابی تراوایی با لاگ‌های چاه‌پیمایی و شبکه عصبی و منطق فازی در دو چاه در مخزن سورمه در میدان بلال پرداختند و نتایج را با تراوایی مغزه مقایسه نمودند. نتایج نشان داده است که این سیستم‌های هوشمند برای پیش‌بینی تراوایی، موفقیت‌آمیز عمل کرده‌اند. [۳۲].

مهری، (۱۳۹۳) از شبکه عصبی، منطق فازی و عصبی فازی برای تعیین تراوایی از لاگ‌های چاه‌پیمایی و تراوایی مغزه در میدان درود استفاده کرد. مقادیر ضریب همبستگی بین تراوایی پیش‌بینی شده و تراوایی مغزه را برای داده‌های آموزش، اعتبارسنجی و تست در روش شبکه عصبی به ترتیب برابر با ۰/۹۴، ۰/۹۱ و ۰/۹۲، در روش منطق فازی برای داده‌های آموزش و تست به ترتیب برابر با ۰/۸۷ و ۰/۹ و در روش عصبی فازی برای داده‌های آموزش، اعتبارسنجی و تست به ترتیب برابر با ۰/۹۷، ۰/۹۶ و ۰/۹۴ محاسبه نمود. نتایج نشان داده که سیستم عصبی فازی، دقت و قابلیت تعمیم بیشتری در پیش‌بینی تراوایی داشته است [۳۳].

وردیان و همکاران، (۲۰۱۶) از لاگ‌های چاه‌پیمایی و سیستم عصبی فازی برای پیش‌بینی تراوایی در یک مخزن با شکستگی طبیعی استفاده نمودند. میانگین مربعات خطای سیستم عصبی فازی برای داده نرمال و ضریب همبستگی را به ترتیب، نزدیک به صفر و نزدیک به یک محاسبه کردند. نتایج نشان داده، سیستم عصبی فازی، ابزاری قدرتمند برای تعیین تراوایی در مخازن با شکستگی طبیعی بوده است. [۳۴].

ژو^۱ و همکاران، (۲۰۱۷) به پیش‌بینی تراوایی با استفاده از الگوریتم هوشمند ترکیبی و داده لاگ NMR یک مخزن ماسه‌سنگی پرداختند. در الگوریتم هوشمند ترکیبی، سه الگوریتم^۲ Adaboost، بهینه‌سازی

^۱ Zhu

^۲ Adaptive boosting (Adaboost)

و شبکه عصبی پسانتشار خطای بهبود یافته را براساس آنالیز تئوری، با هم ترکیب نمودند. اندازه‌گیری‌های آزمایشگاهی تراوایی بر روی ۱۹۶ انجام شده است. همچنین، داده طیفی T_2 متناظر از لاگ NMR را برای مدل، استخراج نمودند. نتایج نشان داده که الگوریتم هوشمند ترکیبی و داده لاگ NMR، نسبت به دیگر مدل‌های موجود، دقت بیشتری داشته و دقت ارزیابی آن با توسعه هوش مصنوعی قابل افزایش است [۳۵].

مطالعات انجام شده، نتایج موفقیت‌آمیزی داشته که بیانگر عملکرد مناسب سیستم‌های هوشمند و لاگ‌های چاه‌پیمایی در ارزیابی تراوایی بوده است. به علاوه، برخی محققان، نتایج به دست آمده را به چاه دیگری در میدان مورد مطالعه تعمیم داده‌اند. بنابراین، در این مطالعه، از قابلیت سیستم هوشمند و لاگ‌های چاه‌پیمایی برای پیش‌بینی تراوایی NMR استفاده شد و سپس، نتایج به دست آمده به چاه مورد نظر تعمیم داده شد.

مطالعات مختلفی در زمینه کاربرد ماشین کمیته برای ترکیب نتایج سیستم‌های هوشمند انجام شده است:

لبنی و همکاران، (۲۰۱۰) از دو نوع ماشین کمیته مبتنی بر سیستم‌های هوشمند با میانگین‌گیری ساده و وزن‌دار، برای ایجاد همبستگی کمی بین پارامترهای لاگ NMR و لاگ‌های چاه‌پیمایی در میدان پارس جنوبی استفاده کردند. در روش میانگین‌گیری وزن‌دار، با استفاده از الگوریتم ژنتیک، سهم هر سیستم هوشمند را تعیین نمودند. از لاگ‌های دو چاه برای ساخت مدل‌ها و چاه سوم برای اعتبارسنجی مدل‌های پیشنهادی استفاده نمودند. نتایج نشان داده که ماشین کمیته با الگوریتم ژنتیک، عملکرد بهتری نسبت به سیستم‌های هوشمند منفرد داشته است [۳۶].

صادقی و همکاران، (۲۰۱۱) از ترکیب فرمول‌های تجربی، رگرسیون چندگانه و روش عصبی فازی با ماشین کمیته، برای ارزیابی تراوایی از اطلاعات لاگ‌های چاه‌پیمایی و مغزه در یک مخزن کربناته در میدان نفتی بلال استفاده کردند. ترکیب بهینه وزن‌ها را در ماشین کمیته با الگوریتم ژنتیک تعیین

نمودند. نتایج نشان داده که ماشین کمیته با الگوریتم ژنتیک نتایج دقیق تری نسبت به روش‌های منفرد فراهم کرده است [۳۷].

قیاسی فریز و همکاران، (۲۰۱۲) مدلی بهبود یافته با استفاده از آنالیز تصویر، لاگ‌های متداول و سیستم‌های هوشمند برای پیش‌بینی تراوایی، طراحی و برای ترکیب نتایج حاصل از سیستم‌های هوشمند از دو نوع ماشین کمیته استفاده کردند: میانگین‌گیری معمولی و وزن‌دار. برای تعیین سهم هر سیستم در میانگین‌گیری وزن‌دار از الگوریتم ژنتیک استفاده کردند. نتایج نشان داده که هر دو ماشین کمیته عملکرد بهتری نسبت به سیستم‌های هوشمند به صورت منفرد داشته‌اند [۳۸].

امینا و اوریزانتو^۱، (۲۰۱۵) برای ایجاد رابطه کمی بین پارامترهای لاگ NMR و لاگ‌های چاه‌پیمایی از سیستم‌های هوشمند و مفهوم ماشین کمیته با میانگین‌گیری ساده و وزن‌دار استفاده کردند. سهم بهینه هر سیستم را در ساخت ماشین کمیته با میانگین‌گیری وزن‌دار، با الگوریتم ژنتیک تعیین نمودند. نتایج نشان داده، عملکرد بالای الگوریتم ژنتیک، مدل را بهینه ساخته و نسبت به سیستم‌های هوشمند منفرد، عملکرد بهتری داشته است [۳۹].

نتایج مطالعات نشان داده، دقت ماشین کمیته در مقایسه با سیستم‌های هوشمند منفرد، افزایش یافته است. به علاوه، در ماشین کمیته با میانگین‌گیری وزن‌دار، از الگوریتم ژنتیک برای تعیین سهم هر یک از سیستم‌های هوشمند استفاده شده است. در این مطالعه، از ماشین کمیته برای ترکیب نتایج سیستم‌های هوشمند، همچنین، از الگوریتم بهینه‌سازی ازدحام ذرات^۲ برای ایجاد بهترین ترکیب این سیستم‌ها در تشکیل ماشین کمیته با میانگین‌گیری وزن‌دار استفاده شد.


۱-۷ روش مطالعه

استفاده از آنالیز تصویر و سیستم‌های هوشمند جهت پیش‌بینی تراوایی، اساس تحقیق حاضر است. در این مطالعه، ویژگی‌های پتروگرافی با روش آنالیز تصویر از مقاطع نازک، استخراج و با استفاده از بررسی

¹ Aminah and Auriyanto


² Particle swarm optimization (PSO)

ضریب همبستگی و شبکه عصبی کم‌عمق، نوع و تعداد ویژگی‌های مناسب برای طراحی سیستم‌های هوشمند تعیین شد (شکل (۲-۱)).




شکل (۲-۱): فلوچارت نحوه انتخاب نوع و تعداد ویژگی‌های پتروگرافی مناسب جهت طراحی سیستم‌های هوشمند

سپس سیستم‌های هوشمند شامل شبکه عصبی کم‌عمق، منطق فازی و عصبی فازی با استفاده از ویژگی‌های پتروگرافی انتخابی و تراوایی مغزه، طراحی شدند. با تشکیل ماشین کمیته با میانگین‌گیری ساده و وزن‌دار، سهم هر یک از سیستم‌های هوشمند در پیش‌بینی تراوایی تعیین شد (شکل (۳-۱)).




شکل (۳-۱): فلوچارت طراحی ماشین کمیته مبتنی بر سیستم‌های هوشمند

به منظور اعتبارسنجی مدل‌های طراحی شده، از نتایج لاگ NMR استفاده شد. اطلاعات پتروگرافی از مقاطع تهیه شده از چاه A در میدان پارس جنوبی استخراج شدند که نمودارگیری NMR این چاه در دسترس نبود. بنابراین، ابتدا با استفاده از لاگ‌های GR، NPHI، PEF و RHOB و تراوایی لاگ NMR چاه B در میدان پارس جنوبی، شبکه عصبی عمیق طراحی شد (شکل (۴-۱)).



شکل (۴-۱): فلوچارت طراحی شبکه عصبی عمیق براساس لاگ‌های چاه‌پیمایی چاه B

سپس، لاگ‌های چاه‌پیمایی GR، NPHI، PEF و RHOB چاه A به شبکه عصبی عمیق طراحی شده، وارد و تراوایی لاگ NMR مربوط به این چاه، پیش‌بینی شد (شکل (۵-۱)).



شکل (۵-۱): پیش‌بینی تراوایی لاگ NMR چاه A با استفاده از مدل شبکه عصبی عمیق

۸-۱ ساختار پایان نامه

در ادامه، مطالب زیر مورد بررسی قرار گرفته است:

در فصل دوم با عنوان "ارزیابی تراوایی در سازندهای کنگان و دالان"، به بررسی تراوایی و روش‌های اندازه‌گیری و پیش‌بینی آن پرداخته شد و سپس روند تغییرات تراوایی در سازندهای کنگان و دالان مورد بررسی قرار گرفت.

در فصل سوم با عنوان "آنالیز تصویر و سیستم‌های هوشمند"، ابتدا به بررسی آنالیز تصویر و مراحل مطالعه مقاطع نازک با این روش پرداخته شد، سپس انواع سیستم‌های هوشمند مورد استفاده در این مطالعه و ساختار ماشین کمیته مبتنی بر این سیستم‌ها مورد بررسی قرار گرفت.

در فصل چهارم با عنوان "پیش‌بینی تراوایی"، ابتدا با استفاده از آنالیز تصویر و سیستم‌های هوشمند، مدل‌سازی انجام شد و برای ترکیب نتایج حاصل از سیستم‌های هوشمند، از ماشین کمیته استفاده شد. سپس نتایج سیستم‌های هوشمند با تراوایی لاگ NMR مقایسه شد.

در فصل پنجم به جمع‌بندی کلی از نتایج به دست آمده و ارائه پیشنهادها پرداخته شد.

فصل دوم: ارزیابی تراوایی در سازندهای کنگان و دالان

۱-۲ مقدمه

تراوایی، توانایی عبور یک سیال از محیط متخلخل را نشان می‌دهد و یکی از مهم‌ترین ویژگی‌های سنگ مخزن است که تولید نفت از مخازن را تحت تأثیر قرار می‌دهد. سازند تراواست که متخلخل بوده و این فضاها متخلخل به هم متصل باشند. معمولاً در مخازن ماسه‌سنگی به دلیل همگن^۱ بودن، با افزایش تخلخل، مقدار تراوایی نیز افزایش می‌یابد ولی در مخازن کربناته که در اینجا مورد مطالعه است، به دلیل ناهمگن بودن، این رابطه برقرار نیست. برای اندازه‌گیری تراوایی از روش‌های آنالیز مغزه و آزمایش چاه استفاده می‌شود که پرهزینه و زمان‌بر هستند. از فرمول‌های تجربی و داده NMR نیز برای تعیین تراوایی استفاده می‌شود که لاگ NMR نیز پرهزینه است. فرمول‌های تجربی و لاگ‌های چاه‌پیمایی برای پیش‌بینی تراوایی مورد استفاده قرار می‌گیرند که به علت طبیعت بسیار پیچیده مساله، دقیق و قابل اعتماد نیستند. بنابراین، در سال‌های اخیر، استفاده از آنالیز تصویر و سیستم‌های هوشمند برای کاهش زمان و هزینه در مطالعات نفتی، گسترش یافته و می‌تواند کارآمد باشد. در این فصل، به معرفی، طبقه‌بندی و روش‌های تعیین تراوایی پرداخته شد و روند تغییرات آن در سازندهای کنگان و دالان در چاه A میدان پارس جنوبی مورد بررسی قرار گرفت.

۲-۲ تراوایی

سنگ مخزن علاوه بر متخلخل بودن باید توانایی این را داشته باشد که سیالات نفت از درون فضاها خالی به هم متصل آن جریان پیدا کنند. توانایی سنگ برای هدایت سیالات به صورت تراوایی بیان می‌شود. تراوایی سنگ به تخلخل موثر آن بستگی دارد. در نتیجه به وسیله اندازه دانه، شکل دانه، توزیع اندازه دانه (جورشدگی)^۲، انباشت دانه و درجه استحکام و سیمانی شدن تأثیرپذیر می‌شود. نوع رس یا سیمان در بین دانه‌های ماسه نیز بر روی تراوایی تأثیر می‌گذارد. مهندس فرانسوی هنری داری^۳ معادله جریان سیال را توسعه داده است. این معادله به صورت دیفرانسیل با فرمول (۱-۲) بیان می‌شود:

¹ Homogeneous

² Sorting

³ Henry Darcy

$$u = \frac{q}{A_c} = -\frac{k}{\mu} \frac{dp}{dl} \quad (1-2)$$

که در آن، u سرعت سیال برحسب (cm/s)، q آهنگ جریان (cm²/s)، k تراوایی سنگ متخلخل داری (D)، A_c مساحت مقطع عرضی سنگ (cm²)، μ گرانیوی^۱ سیال سانتی پواز (cP)، l طول نمونه سنگ (cm)، dp/dl گرادیان فشار در جهت جریان (atm/cm) است [۴۰].

تراوایی در فرمول (۱-۲)، بر حسب تراوایی "مطلق"، اگر سنگ ۱۰۰ درصد با یک سیال یا فاز تکی از قبیل نفت، گاز یا آب، اشباع شده باشد، بیان می شود. تراوایی، در حضور بیش از یک سیال، "تراوایی موثر" (k_o, k_g, k_w به ترتیب تراوایی موثر نفت، گاز و آب) نامیده می شود. سیالات در حین حرکت از درون کانال های متخلخل سنگ با هم فصل مشترک دارند، بنابراین مجموع تراوایی های موثر تمام فازها همیشه کم تر از تراوایی مطلق خواهد بود. نسبت تراوایی موثر هر فاز به تراوایی مطلق سنگ، "تراوایی نسبی" (k_r) آن فاز نامیده می شود. تراوایی نسبی نفت (k_{ro})، گاز (k_{rg}) و آب (k_{rw}) به ترتیب با فرمول های (۲-۲)، (۳-۲) و (۴-۲) بیان می شوند [۴۲].

$$k_{ro} = \frac{k_o}{k} \quad (2-2)$$

$$k_{rg} = \frac{k_g}{k} \quad (3-2)$$

$$k_{rw} = \frac{k_w}{k} \quad (4-2)$$

کمینه تراوایی برای این که از لحاظ اقتصادی مفید باشد تابع عواملی مانند نوع و گرانیوی هیدروکربن، فشار سازند، اشباع آب، قیمت هیدروکربن، ضخامت بخش های تولیدی خالص به کل ضخامت و عمق چاه است [۴۱]. تراوایی اکثر سنگ های مخزن نفت کم تر از ۱ داری است. بنابراین واحد کوچک تری از تراوایی، میلی داری (mD) در صنعت نفت و گاز به طور وسیع مورد استفاده قرار می گیرد [۴۰]. حداقل تراوایی لازم برای تولید نفت، ۰/۰۱ میلی داری در نظر گرفته می شود [۳۸].

در این مطالعه، از تراوایی مطلق افقی مغزه استفاده شد.

^۱ Viscosity

۲-۲-۱ طبقه بندی تراوایی

از نظر زمین‌شناسی تراوایی یک مخزن به دو دسته اولیه و ثانویه تقسیم می‌شود: تراوایی اولیه که در زمان ته‌نشینی رسوبات در سنگ ایجاد می‌شود و تابع اندازه، شکل و سایر خصوصیات ذرات سازنده رسوب است و تراوایی ثانویه که در اثر عوامل سنگ‌شدگی^۱ بعد از رسوب‌گذاری مانند تراکم، سیمانی شدن، شکستگی و انحلال ایجاد می‌شود. تراکم و سیمانی شدن عموماً تراوایی را کاهش اما شکستگی و انحلال، تراوایی را افزایش می‌دهند [۴۰]. کیفیت مخزن ممکن است به صورت جدول (۱-۲) مورد قضاوت قرار گیرد:

جدول (۱-۲): بررسی ارتباط تراوایی و کیفیت مخزن [۴۰]

محدوده تراوایی (mD)	$K < 1$	$1 < K < 10$	$10 < K < 50$	$50 < K < 250$	$K > 250$
کیفیت مخزن	ضعیف	ضعیف تا متوسط	متوسط	خوب	بسیار خوب

تقسیم بندی جدول (۱-۲)، نسبی بوده و با توجه به عوامل اقتصادی می‌تواند تغییر کند. به عنوان مثال تا ۲۰ سال پیش به سنگی با تراوایی کمتر از ۵۰ میلی‌داری به چشم سنگ با بهره کم اقتصادی و تراوایی پایین نگاه می‌شد ولی امروزه این نظر در مورد سنگ با تراوایی کمتر از یک میلی‌داری وجود دارد [۴۲].

۲-۲-۲ روش‌های تعیین تراوایی

برای اندازه‌گیری تراوایی سنگ مخزن، از روش‌های آنالیز مغزه و آزمایش چاه استفاده می‌شود. برای اندازه‌گیری تراوایی در آزمایشگاه، ابتدا استوانه‌های کوچک سنگ در آستری غیرتراوا طوری قرار می‌گیرند که راه نفوذ سیال تزریقی به بدنه نمونه وجود نداشته باشد. سپس سیالی با غلظت مشخص از یک سر نمونه با طول و قطر مشخص، جریان می‌یابد. حال با در دست داشتن مقدار دبی خروجی و افت فشار بین سر و ته نمونه، مقدار تراوایی قابل اندازه‌گیری است. معمولاً دقیق‌ترین مقدار تراوایی با استفاده از همین روش به دست می‌آید [۴۲]. استفاده از ابزارهای مغزه‌گیری و آوردن نمونه‌ها از ناحیه تولیدی

^۱ Diagenesis

به سطح و اندازه‌گیری تراوایی تحت شرایط مخزن، فرآیندی پرهزینه، زمان‌بر و دشوار است و اغلب بر روی تعداد کمی از چاه‌های یک میدان صورت می‌پذیرد [۴۳] و [۴۴].

در آزمایش‌های چاه، فشار مخزن با تولید، کاهش پیدا می‌کند، بنابراین با در دست داشتن مقدار افت فشار و دبی می‌توان قابلیت انتقال را به دست آورد، سپس، تراوایی متوسط از تقسیم قابلیت انتقال بر ارتفاع فاصله عمودی مورد آزمایش به دست می‌آید. این روش با خطا همراه است زیرا ارتفاع عمودی فاصله آزمایش شده به خوبی معلوم نیست [۲۴] و [۴۲]. به علاوه، این روش هزینه بالایی دارد و فقط انجام تعداد محدودی آزمایش چاه در هر میدان امکان‌پذیر است [۴۳] و [۴۴].

برای پیش‌بینی تراوایی می‌توان از روش‌های تجربی، آنالیز رگرسیونی و سیستم‌های هوشمند با استفاده از لاگ‌های چاه‌پیمایی استفاده نمود. در اکثر چاه‌های یک میدان، عملیات چاه‌نگاری انجام می‌شود.

NMR به اصلی فیزیکی یعنی پاسخ هسته به میدان مغناطیسی منتسب است. در ابزارهای NMR، از آهنرباهای دائمی برای جهت دادن به پروتون‌ها استفاده می‌شود. بسیاری از هسته‌ها دارای گشتاور مغناطیسی هستند و مانند آهنربای چرخنده عمل می‌کنند که می‌توانند در واکنش با میدان مغناطیسی خارجی، سیگنال‌های قابل اندازه‌گیری تولید نمایند. هیدروژن دارای گشتاور مغناطیسی بزرگ است که در آب و هیدروکربن‌های موجود در فضاهای متخلخل وجود دارد. دستگاه NMR، دامنه و زوال سیگنال‌ها را اندازه‌گیری می‌کند. دامنه سیگنال متناسب با تعداد هیدروژن‌های موجود است و برای به دست آوردن تخلخل، کالیبره می‌شود. بنابراین، با اندازه‌گیری سیگنال‌های حاصل از هیدروژن، می‌توان به حضور آب و هیدروکربن در فضاهای خالی پی برد. زوال سیگنال یا زمان آسایش، به اندازه فضاهای متخلخل وابسته است. فضاهای متخلخل کوچک، زمان آرامش را کاهش می‌دهند و فضاهای متخلخل بزرگ، دارای زمان آرامش طولانی هستند. بنابراین، توزیع زمان‌های آرامش، یک اندازه‌گیری از توزیع اندازه فضاهای متخلخل است و برای به دست آوردن برخی ویژگی‌های پتروفیزیکی مانند تراوایی به کار می‌رود [۴۵] و [۴۶].

از فرمول‌های تجربی و داده‌های لاگ NMR برای پیش‌بینی تراوایی استفاده می‌شود [۴۳]، [۴۵]، [۴۷] و [۴۸]. با توجه به این که لاگ NMR، قادر به تشخیص محیط‌های متخلخل است، می‌تواند ابزاری دقیق‌تر نسبت به سایر روش‌های پیش‌بینی تراوایی باشد [۴۳]. لاگ NMR، پرهزینه و در چاه‌های گازی دارای نویز^۱ بالاست، به علاوه نمودارگیری NMR، فقط در تعداد محدودی از چاه‌ها انجام می‌پذیرد [۴۴] و [۴۹].

از فرمول‌های تجربی و لاگ‌های چاه‌پیمایی نیز برای پیش‌بینی تراوایی استفاده می‌شود [۴۳] و [۵۰]. معمولاً به علت طبیعت بسیار پیچیده مسأله، دقیق و قابل اعتماد نیستند [۳۳] و [۴۳]. به طور کلی از روش‌های تجربی می‌توان در مخازن همگن استفاده کرد و دارای معایب زیادی در پیش‌بینی خواص مخزن هستند [۲۴].

از آنالیز رگرسیونی چندگانه و لاگ‌های چاه‌پیمایی برای ایجاد رابطه بین لاگ‌های چاه‌پیمایی و تراوایی استفاده می‌شود [۵۱]، [۵۲] و [۵۳]. امکان حذف داده‌های پرت، سبب افزایش ضریب همبستگی نتایج می‌شود. آنالیز رگرسیونی قادر به پیش‌بینی روند تغییرات تراوایی است و معمولاً نمی‌تواند تراوایی را به طور دقیق محاسبه نماید [۲۴]، [۵۲] و [۵۳].

از سیستم‌های هوشمند با استفاده از لاگ‌های چاه‌پیمایی نیز برای پیش‌بینی تراوایی استفاده می‌شود [۵۴] و [۵۵]. دقت نتایج به دست آمده از سیستم‌های هوشمند در اغلب موارد، بالاست و امکان پیش‌بینی و تعیین روند تغییرات در ویژگی‌های مخزنی را فراهم می‌آورد.

همچنین می‌توان از داده‌های حاصل از آنالیز تصویر با فرمول‌های تجربی، روش‌های شبیه‌سازی، آنالیز رگرسیونی و سیستم‌های هوشمند برای پیش‌بینی تراوایی استفاده نمود. تهیه مقاطع از نمونه‌هایی که برای آزمایش‌های متداول تعیین تراوایی کوچک هستند نیز امکان‌پذیر است.

رابطه کوزنی - کارمن از جمله فرمول‌های تجربی مشهوری است که برای پیش‌بینی تراوایی استفاده می‌شود و تراوایی را به عنوان تابعی از تخلخل و مساحت سطح ویژه بیان می‌کند (فرمول (۲-۵)):

¹ Noise

$$k = \left(\frac{1}{5s_{vgr}^2}\right) \times \frac{\varphi^3}{(1-\varphi)^2} \quad (5-2)$$

در فرمول (۵-۲)، K تراوایی برحسب (cm^2) یا (μm^2) ، φ تخلخل به صورت کسری و S_{vgr} مساحت سطح ویژه ماده متخلخل برحسب (cm^{-1}) یا (μm^{-1}) است. این رابطه، برای سنگ‌هایی که دارای تخلخل بین‌بلوری و دانه‌ای باشند، صدق می‌کند [۴۰]. مطالعات مختلفی برای پیش‌بینی تراوایی ماسه‌سنگ‌ها انجام شده که تخلخل و مساحت سطح ویژه با آنالیز تصویر استخراج شده‌اند [۵]، [۷] و [۱۰]. این رابطه در سیستم‌های ناهمگن، ممکن است تراوایی را بیش از حد، ارزیابی کند [۱۹].

از آنالیز تصویر و روش‌های شبیه‌سازی نیز برای تعیین تراوایی استفاده می‌شود [۱۳]، [۱۴]، [۱۵]، [۱۶]، [۱۸] و [۲۳]. به علاوه، مجموعه رابطه کوزنی - کارمن و روش‌های شبیه‌سازی نیز برای پیش‌بینی تراوایی مورد استفاده قرار می‌گیرند [۱۷]، [۱۹] و [۲۱].

از روش آنالیز رگرسیون برای برقراری ارتباط بین تخلخل یا ویژگی‌های فضاهای خالی استخراج شده از آنالیز تصویر با تراوایی استفاده می‌شود [۳]، [۶] و [۲۰]. نتایج مطالعات نشان داده که تخلخل و ویژگی‌های فضاهای خالی می‌توانند تراوایی را کنترل کنند.

از سیستم‌های هوشمند و داده‌های به دست آمده از آنالیز تصویر نیز برای پیش‌بینی تراوایی استفاده می‌شود [۸]، [۹]، [۲۲] و [۳۸]. به طور کلی، مطالعات متعددی برای پیش‌بینی تراوایی، با استفاده از آنالیز تصویر و لاگ‌های چاه پیمایی و بهره بردن از قابلیت سیستم‌های هوشمند، برای به حداقل رساندن زمان و هزینه گسترش یافته است.

۳-۲ تغییرات تراوایی در سازندهای کنگان و دالان

روند تغییرات تراوایی در زیرواحدهای سازندهای کنگان و دالان در جدول (۲-۲) ذکر شده است. برای بررسی ارزش مخزنی هر یک از زیرواحدها، علاوه بر اطلاعات جدول (۲-۲)، به مطالعات سنگ‌شناسی، نوع تخلخل و تغییرات سنگ‌شدگی نیاز است. در سازند کنگان، بیشترین مقدار تراوایی در زیرواحد K_{1c} مشاهده می‌شود که با توجه به مطالعات سنگ‌شناسی، به دلیل وجود لایه‌های دولومیتی متخلخل است.

در سازند دالان، بیشترین مقدار تراوایی مربوط به زیرواحد K_{4b} است که این تراوایی بالا در نتیجه وجود آهک و آهک دولومیتی با تخلخل بین دانه‌ای است. زیرواحد K_{4b} مهم‌ترین بخش مخزنی میدان است. به منظور شناخت بهتر هر یک از زیرواحدها، روند تغییرات تخلخل در زیرواحدهای سازندهای کنگان و دالان در جدول (۲-۳) ذکر شده است. با توجه به تغییرات تراوایی و تخلخل می‌توان گفت، اعماق با مقدار بالای تخلخل و تراوایی دارای بهترین ارزش مخزنی هستند.

جدول (۲-۳): روند تغییرات تراوایی در سازندهای کنگان و دالان

سازند	واحد	زیر واحد	عمق (m)	بیشینه تراوایی (mD)	کمینه تراوایی (mD)	میانگین تراوایی (mD)
کنگان	K ₁	K _{1a}	۲۸۶۰ - ۲۸۷۳/۵	۹/۱۸	۰/۱۰۳	۲/۶۸
		K _{1b}	۲۸۷۳/۵ - ۲۹۰۲/۶	۲۶/۶۱	۰/۰۳۴	۱/۸۹
		K _{1c}	۲۹۰۲/۶ - ۲۹۴۵/۵	۳۹۹/۹۹	۰/۰۰۵	۱۱/۰۱
	K ₂	K _{2a}	۲۹۴۵/۵ - ۲۹۵۷/۶	۱۸۱/۴۹	۰/۰۷۹	۳۵/۳۶
		K _{2b}	۲۹۵۷/۶ - ۲۹۹۳/۶	۱۰۴/۸۲	۰/۰۳۷	۴/۷۶
	دالان	K ₃	K _{3a}	۲۹۹۳/۶ - ۳۰۱۹/۵	۲۷۷/۴۱	۰/۰۳۳
K _{3b}			۳۰۱۹/۵ - ۳۰۹۰	۱۰۵	۰/۰۰۱	۲/۲۲
K _{3c}			۳۰۹۰ - ۳۱۱۶	۱۶۵	۰/۰۳۴	۴/۸۱
K ₄		K _{4a}	۳۱۱۶ - ۳۱۳۵	۱۱۵	۰/۰۴۵	۱۶/۰۵
		K _{4b}	۳۱۳۵ - ۳۲۰۵/۵	۷۲۳/۲	۰/۰۴۲	۱۵/۱۳
		K _{4c}	۳۲۰۵/۵ - ۳۲۷۴/۷	۳۴۶	۰/۰۲۳	۱۶/۹۴

جدول (۳-۲): روند تغییرات تخلخل در سازندهای کنگان و دالان

سازند	واحد	زیر واحد	عمق (m)	بیشینه تخلخل	کمینه تخلخل	میانگین تخلخل
کنگان	K ₁	K _{1a}	۲۸۶۰ - ۲۸۷۳/۵	۱۹/۵	۱/۴۵	۹/۱
		K _{1b}	۲۸۷۳/۵ - ۲۹۰۲/۶	۲۹/۵۴	۰/۰۱	۶/۲۵
		K _{1c}	۲۹۰۲/۶ - ۲۹۴۵/۵	۲۹/۱۶	۰/۱۳۱	۵/۸۵
	K ₂	K _{2a}	۲۹۴۵/۵ - ۲۹۵۷/۶	۲۸/۱۵	۰/۷۹۹	۱۱/۸۷
		K _{2b}	۲۹۵۷/۶ - ۲۹۹۳/۶	۲۸/۰۳	۰/۵۴۱	۹/۸۵
	دالان	K ₃	K _{3a}	۲۹۹۳/۶ - ۳۰۱۹/۵	۲۴/۱۸	۰/۴۴
K _{3b}			۳۰۱۹/۵ - ۳۰۹۰	۶/۴۵	۰/۰۲۶	۱/۹۷
K _{3c}			۳۰۹۰ - ۳۱۱۶	۱۶/۲۶	۰/۴۱۳	۴/۹۶
K ₄		K _{4a}	۳۱۱۶ - ۳۱۳۵	۲۶/۶۵	۰/۹۳	۱۴/۵۲
		K _{4b}	۳۱۳۵ - ۳۲۰۵/۵	۳۶/۶۳	۰/۴۷۱	۲۱/۲۶
		K _{4c}	۳۲۰۵/۵ - ۳۲۷۴/۷	۲۴/۴۳	۰/۱۰۸	۵/۳۳

فصل سوم: آنالیز تصویر و سیستم‌های هوشمند

۳-۱ مقدمه

با دشوار شدن مسائل و مشکلات در صنعت نفت، روش‌های قدیمی که معمولاً زمان‌بر و پرهزینه هستند، نمی‌تواند پاسخ‌گوی تمام نیازهای مهندسين و کارشناسان برای حل مسائل باشد. بنابراین از روش‌های متفاوتی استفاده می‌شود تا مسائل جدید از دیدگاهی نو بررسی شود. بدین ترتیب از ترکیب روش‌های قدیمی و شیوه‌های مختلف هوش مصنوعی و جمع‌آوری داده به منظور رسیدن به جواب در مسائل جدید استفاده می‌شود. در این میان از روش‌هایی مانند شبکه عصبی، منطق فازی و عصبی فازی و الگوریتم‌های بهینه‌سازی برای حل مسائل مختلف استفاده شده است. همچنین، آنالیز تصویر می‌تواند ابزاری مفید برای افزایش دقت و کوتاه نمودن زمان مطالعات در علوم زمین باشد.

۳-۲ آنالیز تصویر

مجموعه فرآیندهایی که برای شناخت ویژگی‌های خاص بر روی تصویر انجام می‌پذیرد، آنالیز تصویر نامیده می‌شود [۵۶]. اهرلیچ^۱ و همکارانش از پیشگامان آنالیز تصویر هستند که در سال ۱۹۹۱ الگوریتمی برای شناسایی فضاهای خالی سنگ ارائه دادند [۵۷]. در سال‌های اخیر، مطالعات مختلفی در زمینه طبقه‌بندی تخلخل، شناسایی بافت سنگ‌های کربناته و پیش‌بینی تخلخل با روش آنالیز تصویر و سیستم‌های هوشمند صورت گرفته که نتایج موفقیت‌آمیزی داشته است [۵۸]، [۵۹]، [۶۰]، [۶۱] و [۶۲]. در این مطالعه از آنالیز تصویر و سیستم‌های هوشمند برای پیش‌بینی تراوایی استفاده شد.

۳-۲-۱ تصویر دیجیتال

تصویر دیجیتال، ماتریسی دو بعدی یا سه بعدی از اعداد حقیقی، صحیح یا دودویی است که هر عنصر آن، پیکسل که واحد اطلاعاتی یک تصویرند، نامیده می‌شود. هر پیکسل نمایانگر میزان روشنایی آن نقطه از تصویر است. با توجه به حساسیت چشم انسان، کل محدوده روشنایی قابل نمایش به ۲۵۵ سطح تقسیم می‌شود که سطح روشنایی هر پیکسل عددی بین ۰ تا ۲۵۵ است [۴۹].

¹ Ehrlich

۲-۲-۳ مدل رنگی RGB

در مدل RGB، مقدار هر پیکسل به صورت مولفه‌های اولیه قرمز، سبز و آبی ظاهر می‌شود. سطح روشنایی هر مولفه می‌تواند مقداری بین ۰ تا ۲۵۵ داشته باشد و رنگ هر پیکسل با ترکیب مقادیر مختلف سه مولفه قرمز، سبز و آبی مشخص می‌شود. بنابراین، تصاویری که در مدل رنگی RGB نشان داده می‌شوند، در هر پیکسل، سه مولفه یعنی برای هر رنگ اولیه، یک مولفه دارند [۶۳].

۲-۲-۳-۱ بخش‌بندی تصویر در فضای بردار RGB

بخش‌بندی، حوزه‌ای است که در آن، با استفاده از مدل رنگی RGB، به طور کلی نتایج بهتری به دست می‌آید. بخش‌بندی یا قطعه‌بندی فرآیندی است که تصویر را به ناحیه‌هایی تقسیم می‌کند. هدف، بخش‌بندی اشیایی با بازه رنگ خاص در تصویر RGB است. با توجه به نقاط رنگی نمونه‌ای که نماینده رنگ مورد نظر هستند، تخمینی از رنگ "میانگین" به دست می‌آید که قرار است بخش‌بندی شود. رنگ میانگین، با بردار a در RGB نمایش داده می‌شود. هدف بخش‌بندی، دسته‌بندی هر پیکسل RGB در تصویر مورد نظر است، به طوری که دارای رنگی در بازه خاص باشد یا خیر. برای انجام این مقایسه، باید معیار شباهت در دست باشد.

یکی از ساده‌ترین معیارها، فاصله اقلیدسی است. فرض کنید z یک نقطه اختیاری در فضای RGB باشد. گفته می‌شود z مشابه با a است اگر فاصله بین آنها کمتر از حد آستانه‌ای مانند D_0 باشد. فاصله اقلیدسی بین z و a به صورت فرمول (۱-۳) تعیین می‌شود:


$$D(z, a) = \|z - a\| = [(z - a)^T(z - a)]^{\frac{1}{2}} = [(z_R - a_R)^2 + (z_G - a_G)^2 + (z_B - a_B)^2]^{\frac{1}{2}} \quad (1-3)$$

که زیرنویس‌های R ، G و B نشان دهنده مولفه‌های RGB بردارهای a و z هستند. مکان هندسی نقاطی که $D(z, a) \leq D_0$ باشد، کره‌ای به شعاع D_0 است که در قسمت الف شکل (۱-۳) آورده شده است.

¹ Segmentation

نقاط موجود در این کره، معیار رنگ مشخص شده را برآورد می‌کنند ولی نقاط خارج از کره برآورد نمی‌کنند. رمزگذاری این دو مجموعه از نقاط، تصویر بخش‌بندی شده دودویی را تولید می‌نماید.

پیاده‌سازی فرمول (۱-۳)، دارای محاسبات زیادی است. روش مناسب‌تر این است که از جعبه انقیاد^۱ استفاده شود که در قسمت ب شکل (۱-۳) نمایش داده شده است. در این روش، مرکز جعبه a و ابعادش در امتداد هر محور رنگ، متناسب با انحراف معیار نمونه‌ها در امتداد هر محور انتخاب شده است. محاسبه انحراف معیارها، فقط یک بار با استفاده از داده‌های رنگ انجام می‌شود. با توجه به یک نقطه رنگی، که بر روی سطح باشد یا نباشد، یا داخل جعبه باشد، بخش‌بندی انجام می‌شود. اما، تعیین اینکه نقطه در داخل یا خارج جعبه است، در مقایسه با حصار کره‌ای، محاسبات ساده‌تری دارد [۶۳].



شکل (۱-۳): نمایش در بر گرفتن مناطق داده برای بخش‌بندی بردار RGB، الف) حصار کره‌ای، ب) جعبه انقیاد

به طور کلی، نتیجه رمز کردن هر نقطه، سیاه است اگر روی سطح یا داخل جعبه باشد، در غیر این صورت، سفید است. بنابراین، بخش‌بندی در تصویر رنگی RGB، یک تصویر سیاه و سفید است [۶۳].

۳-۲-۳ مراحل مطالعه مقاطع نازک با استفاده از آنالیز تصویر

تحلیل تصاویر بدین صورت انجام می‌پذیرد:

۱. تهیه مقاطع نازک اشباع شده با اپوکسی آبی رنگ

۲. تهیه تصاویر از مقاطع نازک

۳. بخش‌بندی تصاویر

^۱ Bounding Box

۴. استخراج ویژگی‌ها برای تشخیص الگو

۵. طراحی مدل‌های هوشمند برای تفکیک الگو

۳-۲-۱-۳ تهیه مقاطع نازک اشباع شده با اپوکسی آبی رنگ

ابتدا با ترکیب ۳۰۰ میلی گرم پودر اپوکسی و ۹۰ میلی گرم استن، محلول اپوکسی آبی تهیه می‌شود. نمونه مورد نظر در داخل کاغذ آلومینیوم قرار گرفته و محلول اپوکسی آبی به آن اضافه می‌شود، به صورتی که نمونه در آن غرق نشود. سپس به مدت چند ساعت، نمونه در حالت خلأ قرار می‌گیرد تا اپوکسی در آن نفوذ کند. تهیه مقاطع نازک نیز مانند مقاطع معمولی است با این تفاوت که از سمباده نرم‌تری برای سایش نمونه استفاده می‌شود [۴۹].

مزیت استفاده از اپوکسی آبی این است که احتمال کمی وجود دارد که اجزای سنگ به طور طبیعی آبی رنگ باشند، بنابراین تشخیص فضاهای خالی از سایر قسمت‌های سنگ در مقاطع، امکان‌پذیر می‌شود [۵۷].


۳-۲-۲-۳ تهیه تصاویر از مقاطع نازک

تصاویر با استفاده از میکروسکوپ مجهز به دوربین دیجیتال تهیه می‌شود. دوربین توسط کابلی به کامپیوتر متصل و تصویر مقاطع با نرم‌افزار نصب شده بر روی کامپیوتر، تهیه می‌شود. عکس تهیه شده به صورت یک فایل ذخیره می‌شود. تعیین بزرگ‌نمایی تصاویر به دست آمده از مقاطع نازک، به دقت زیادی نیاز دارد. در بزرگ‌نمایی‌های بالا، ریزتخلخل‌ها مورد بررسی قرار می‌گیرند و درشت‌تخلخل‌ها بیش از حد معمول در نظر گرفته می‌شوند. در بزرگ‌نمایی‌های پایین نیز، جزئیات فضای بین‌دانه‌ای کاهش می‌یابد [۵۷]. بعد از بررسی بزرگ‌نمایی‌های مختلف، این نتیجه حاصل شد که بزرگ‌نمایی $12/5X$ تصویر مناسبی برای اهداف مورد نظر فراهم می‌کند. این بزرگ‌نمایی با عدسی شیئ $1/25X$ و عدسی چشمی $10X$ به دست می‌آید.

۳-۳-۲-۳ بخش‌بندی تصاویر

با هدف توصیف و شناخت اولیه فضاهای خالی و جداسازی آنها از سایر بخش‌ها، تصویر به دو بخش تقسیم می‌شود. به این کار، بخش‌بندی گفته می‌شود. بخش‌بندی تصویر عبارت است از جدا نمودن پیکسل‌هایی از تصویر که به گروه خاصی اختصاص دارند [۵۶]. هدف، جدا کردن فضاهای خالی از سایر بخش‌های سنگ است. با توجه به تزریق اپوکسی آبی به نمونه‌ها، فضاهای خالی، با رنگ آبی مشخص می‌شوند.

در این مطالعه، از نرم‌افزار Image Pro Plus برای بخش‌بندی تصاویر استفاده شده است. تصویر بخش‌بندی شده، یک تصویر سیاه و سفید یا دودویی است که فضاهای خالی به رنگ سیاه جدا شدند (شکل (۳-۲)).



شکل (۳-۲): بخش‌بندی تصویر، الف) تصویر RGB، ب) تصویر بخش‌بندی شده

۳-۳-۲-۴ استخراج ویژگی‌ها برای تشخیص الگو

تصاویر به منظور استخراج ویژگی‌ها، آنالیز می‌شوند. ویژگی‌ها باید به گونه‌ای انتخاب و محاسبه شوند تا قابلیت تشخیص الگو وجود داشته باشد. الگو، بیان توصیفی یا کمی یک شیء یا هر چیز دیگر است. مجموعه‌ای از الگوها دارای خاصیت مشترک، مشخص کننده یک کلاس الگو هستند [۶۴]. ویژگی‌ها با مطالعات میکروسکوپی از تصاویر رنگی مقاطع نازک و آنالیز تصاویر دودویی استخراج شده‌اند.

۳-۲-۵ طراحی مدل‌های هوشمند برای تفکیک الگو

در این مرحله مشخص می‌شود که هر الگو به چه دسته‌ای تعلق دارد. یک الگوریتم تشخیص الگو از ابتدا قادر به تفکیک کلاس‌های مختلف نیست و باید آموزش داده شود. آموزش زمانی پایان می‌پذیرد که الگوریتم به درستی، دسته‌بندی الگوها به کلاس‌های مختلف را انجام دهد. آن‌گاه از این الگوریتم به عنوان یک سیستم متخصص برای دسته‌بندی الگوهایی از همان نوع استفاده می‌شود. در هر مسأله تشخیص الگو، پیش‌پردازش داده‌ها و نوع الگوریتم تصمیم‌گیری توسط مشخصات مسأله تعیین می‌شود [۴۹].

۳-۳ سیستم‌های هوشمند

در این مطالعه، از سیستم‌های هوشمند شامل شبکه‌های عصبی، منطق فازی و عصبی فازی استفاده شد که در گروه مدل‌های جعبه سیاه^۱ قرار می‌گیرند [۶۵]. مدل‌های جعبه سیاه، داده محور هستند و اساس کار آنها این است که بر مبنای بخشی از داده‌های موجود، نگاشتی بین داده‌های ورودی و خروجی ایجاد می‌شود. پس از توسعه نگاشت با استفاده از بخشی از اطلاعات موجود که آن را آموزش شبکه نیز می‌نامند، قابلیت پیش‌بینی مدل توسعه داده شده برای بخش دیگر داده‌ها که قبلاً استفاده نشده، ارزیابی می‌شود [۶۶].

سیستم‌های هوشمند با دقت قابل قبول و بدون صرف زمان زیاد و هزینه‌های آزمایشگاهی گران قیمت، می‌توانند تراوایی را پیش‌بینی نمایند. استفاده از آنالیز تصویر و سیستم‌های هوشمند نتایج موفقیت‌آمیزی در پیش‌بینی تراوایی داشته است. به علاوه، محققان زیادی برای پیش‌بینی تراوایی از لاگ‌های چاه‌پیمایی و سیستم‌های هوشمند استفاده کردند.


^۱ Black box models

۳-۳-۱ شبکه عصبی مصنوعی

شبکه عصبی مصنوعی، از سیستم عصبی انسان الهام گرفته شده و از شمار زیادی عناصر پردازشی به نام نورون تشکیل شده است که برای حل یک مسأله با هم هماهنگ عمل می‌کنند. شبکه عصبی، طی فرآیند آموزش، از محیط اطراف برای شناخت و تعیین ماهیت استفاده می‌کند. سپس از اتصال بین نورون‌ها و با وزن‌دهی به نورون‌ها این شناخت را ذخیره می‌نماید [۶۷].

۳-۳-۱-۱ ساختار شبکه عصبی

شبکه عصبی شامل اجزای سازنده لایه‌ها و وزن‌هاست. رفتار شبکه نیز وابسته به ارتباط بین اعضاست. نورون‌ها عنصر اساسی و پردازشگر اصلی شبکه هستند. ساختار یک نورون با بردار ورودی در شکل (۳-۳) نشان داده شده است.



شکل (۳-۳): ساختار یک نورون با بردار ورودی [۶۸] و [۶۹]

اگر مولفه‌های بردار ورودی با $P_1, P_2, \dots, P_R$ نشان داده شود، هر یک از این مولفه‌ها در وزن متناظر W_1 ، $W_2, \dots, W_R$ ضرب و سپس وارد تابع تصمیم‌گیری یا انتقال f^1 می‌شوند. خروجی این تابع، یک عدد اسکالر به نام a است. هر نورون می‌تواند پارامتر دیگری به نام b یا بایاس هم داشته باشد. مقدار بایاس با مجموع حاصلضرب ورودی‌ها جمع می‌شود و خروجی نهایی را ایجاد می‌کند (فرمول (۳-۲)) [۶۸] و [۶۹].

$$n = w_{11}P_1 + w_{12}P_2 + \dots + w_{1R}P_R + b \quad (۳-۲)$$

¹ Transfer function


یک نورون می‌تواند از توابع انتقال متنوعی برای تولید خروجی استفاده کند. سه مورد از مهم‌ترین توابع تصمیم‌گیری معرفی می‌شوند [۶۸] و [۶۹]:

الف. تابع Log Sigmoid: خروجی این تابع مقادیر بین ۰ تا ۱ و ورودی آن بین منفی بینهایت تا مثبت بینهایت تغییر می‌کند. در شبکه‌های چندلایه معمولاً از این تابع، به عنوان تابع تصمیم‌گیری استفاده می‌شود. در قسمت الف شکل (۳-۴)، یک تابع Log Sigmoid نمایش داده شده است.

ب. تابع Tan Sigmoid: خروجی این تابع مقادیر بین -۱ تا ۱ و ورودی آن بین منفی بینهایت تا مثبت بینهایت تغییر می‌کند. شبکه‌های چند لایه از این تابع نیز می‌توانند استفاده کنند. قسمت ب شکل (۳-۴)، یک تابع Tan Sigmoid را نشان می‌دهد.

ج. تابع Purelin: یکی دیگر از توابع تصمیم‌گیری، که تابعی خطی است، در قسمت ج شکل (۳-۴)، نشان داده شده است.

با توجه به شکل (۳-۴)، در صورتی که آخرین لایه یک شبکه دارای نورون‌های سیگموئیدی باشد، خروجی آن در بازه ۰ تا ۱ (برای تابع Log Sigmoid) و -۱ تا ۱ (برای تابع Tan Sigmoid) و در صورتی که دارای نورون خطی باشد، خروجی آن در هر بازه‌ای می‌تواند تغییر کند.



شکل (۳-۴): توابع تصمیم‌گیری، الف) log sigmoid، ب) tan sigmoid و ج) purelin [۶۸] و [۶۹]

در حالت کلی در شبکه‌های عصبی سه نوع لایه نورونی می‌تواند وجود داشته باشد [۷۰]:

۱. **لایه ورودی**^۱: اطلاعات خامی که به شبکه تغذیه می‌شود را دریافت می‌کند. تعداد نورون‌ها در لایه

ورودی برابر با تعداد ورودی‌های شبکه است. هر نورون در لایه ورودی با همه نورون‌های لایه پنهان

ارتباط دارد، به صورتی که پردازش اطلاعات به صورت موازی و همزمان انجام می‌پذیرد.

۲. **لایه پنهان**: این لایه اطلاعات تهیه شده از محیط را تجزیه و تحلیل می‌کند. تعداد نورون‌ها برحسب

پیچیدگی رابطه بین ورودی‌ها و تعداد لایه‌های پنهان با توجه به تعداد نورون‌های لایه ورودی و خروجی،

تعداد مجموعه‌های داده‌های آموزشی، پیچیدگی طبقه‌بندی، میزان نویز موجود در داده‌ها، نوع توابع

مورد استفاده و نوع الگوریتم آموزشی متفاوت است. تعداد لایه‌های پنهان و تعداد نورون‌ها در لایه پنهان

در میزان خطا تأثیرگذار هستند.

۳. **لایه خروجی**^۲: این لایه، نتایج تجزیه و تحلیل را از لایه پنهان دریافت و به تفسیر معناداری تبدیل

می‌کند. در واقع عملکرد واحد خروجی بسته به فعالیت واحد پنهان و وزن ارتباط بین واحد پنهان و

خروجی است.

۳-۱-۲ یادگیری شبکه عصبی

دو شیوه برای یادگیری وجود دارد:

۱. **یادگیری بدون نظارت**^۳: وزن‌ها براساس ورودی‌ها اصلاح می‌شوند و خروجی مطلوب وجود ندارد تا

با خروجی شبکه مقایسه شود. وزن‌ها براساس خروجی حاصل از ورودی تغییر می‌کنند تا در مرحله

بعدی پاسخ مناسبی برای این ورودی وجود داشته باشد. بنابراین، تنها اطلاعاتی که دریافت می‌شوند،

ورودی‌ها هستند و خروجی متناظر به شبکه معرفی نمی‌شود. به عبارتی، عمل خوشه‌یابی انجام می‌شود

[۶۴].

¹ Input Layer

² Output Layer

³ Unsupervised learning

۲. یادگیری با نظارت^۱: ورودی‌ها و خروجی‌های متناظر با آنها به شبکه معرفی می‌شوند. وزن‌ها و بایاس‌های شبکه براساس ورودی‌ها و خروجی‌ها آموزش داده می‌شوند تا تابع خطا یا عملکرد^۲ در شبکه کمینه شود. تابع خطا معمولاً میانگین مربعات اختلاف بین خروجی شبکه و خروجی مطلوب است. ابتدا، شبکه با استفاده از داده‌های آموزشی موجود، آموزش می‌بیند و سپس با ارائه بردار ورودی به شبکه که ممکن است شبکه آن را قبلاً فرا گرفته باشد با نگرفته باشد، کلاس آن را تشخیص می‌دهد [۷۱].

الگوریتم‌های آموزشی متعددی وجود دارد که هر یک مشخصه خاص خود را دارند و برای کاربردهای متعددی استفاده می‌شوند. فهم اینکه سرعت کدام الگوریتم آموزشی برای یک مسئله خاص بیشتر است، کار آسانی نیست. این موضوع به پارامترهای بسیاری مانند پیچیدگی مسئله، تعداد داده‌های ورودی، تعداد وزن‌ها و بایاس‌ها در شبکه و حداکثر خطای قابل قبول بستگی دارد [۴۹].

الگوریتم پس‌انتشار خطا، یکی از روش‌های آموزش شبکه‌های عصبی است. این الگوریتم از نوع الگوریتم‌های یادگیری با نظارت و بیشتر برای آموزش شبکه‌های "پیشرو" مناسب است. واژه "Backpropagation" مخفف عبارت "Backwards propagation of errors" به معنی انتشار بازگشتی خطاهاست. این الگوریتم از دو مسیر رفت و برگشت، تشکیل شده است. در مسیر رفت، ابتدا بردار ورودی به شبکه اعمال و با در نظر گرفتن مقادیر کاملاً تصادفی برای وزن‌ها و بایاس‌های شبکه، تأثیرات آن از لایه‌های میانی به لایه‌های خروجی منتشر می‌شود. بردار تشکیل شده در لایه خروجی، پاسخ شبکه را بیان می‌کند. در مسیر برگشت، ابتدا خطای بین جواب‌های متناظر شبکه با جواب‌های آموزشی با استفاده از تابع عملکرد محاسبه می‌شود. سپس با استفاده از روش‌های موجود، مشخصه‌های شبکه برای کاهش خطای محاسبه شده اصلاح می‌شوند [۷۲].

یکی از توابع عملکرد، Cross-Entropy است که اندازه‌گیری از وابستگی بین خروجی مطلوب و خروجی شبکه را نمایش می‌دهد و براساس فرمول (۳-۳) تعریف می‌شود:

$$CE = -t \times \log(y) \quad (3-3)$$

¹ Supervised learning

² Performance function

که در آن، t خروجی مطلوب و y خروجی شبکه است. Entropy، اندازه‌گیری از عدم قطعیت است که امکان جستجوی الگوها را در داده‌های وسیع، فراهم می‌آورد و میانگین‌گیری وزنی اطلاعات احتمالات^۱ را محاسبه می‌نماید [۶۹].

روش‌های مختلفی مانند گرادیان نزولی^۲، شبه - نیوتون^۳، لوببرگ - مارکوات^۴ و گرادیان مزدوج^۵ برای الگوریتم پسانتشار خطا وجود دارند که از الگوریتم‌های تکرار^۶ هستند. در تمام این روش‌ها از گرادیان تابع عملکرد برای کاهش خطای شبکه و در نتیجه تنظیم مشخصه‌های شبکه استفاده می‌شود.

در روش لوببرگ - مارکوات، وزن‌ها و بایاس‌های شبکه، در جهتی تغییر می‌کنند که تابع عملکرد با سرعت بیشتری کاهش یابد و بین روش‌های گرادیان نزولی و شبه - نیوتون، درونیابی می‌شود. در این روش، مقادیر تصادفی برای بردار p تعریف می‌شود و در هر مرحله تکرار، طبق فرمول (۳-۴)، بردار p با تخمین جدید $p+q$ جایگزین می‌شود:

$$f(p + q) \approx f(p) + Jq \quad (۳-۴)$$

که J ژاکوبین f در p است. برای دستیابی به q ، توابع $f_i(p + q)$ با خطی‌سازی، تخمین زده می‌شوند. در تابع عملکرد MSE، فرمول (۳-۵) برقرار است:

$$\Delta_q S = 0 \quad (۳-۵)$$

با خطی‌سازی فرمول (۳-۵)، فرمول (۳-۶)، به دست می‌آید:

$$(J^T J)q = -J^T f \quad (۳-۶)$$

که q با وارون نمودن $J^T J$ به دست می‌آید. سپس، با نسخه میرا شده^۷ جایگزین می‌شود:

$$(J^T J + \lambda)q = -J^T f \quad (۳-۷)$$

¹ Weighted average of information by probability

² Gradient descent

³ Quasi-Newton

⁴ Levenberg-Marquardt

⁵ Conjugate gradient

⁶ Iterative algorithm

⁷ Damped version

که λ ضریب میزایی نامنفی است و در هر تکرار تنظیم می‌شود. اگر کاهش تابع عملکرد MSE تند باشد، مقدار کوچک‌تری از λ مورد استفاده قرار می‌گیرد و الگوریتم لونبرگ - مارکوات به الگوریتم شبه - نیوتون نزدیک‌تر می‌شود. اگر با یک تکرار، کاهش تابع عملکرد MSE کافی نباشد، λ افزایش یافته و الگوریتم لونبرگ - مارکوات به الگوریتم گرادیان نزولی نزدیک‌تر می‌شود [۷۳] و [۷۴].

روش گرادیان مزدوج برای تعداد داده‌های زیاد می‌تواند عملکرد موفقیت‌آمیزی داشته باشد. برای حل معادلات خطی $Ax=b$ ، یک فرض اولیه x_0 در نظر گرفته می‌شود (فرمول (۸-۳)) [۷۵]. در غیاب اطلاعات درباره دستگاه معادلات خطی مورد نظر، $x_0=0$ فرض می‌شود که باعث ساده‌سازی محاسبات اولیه می‌گردد [۷۶].

$$r_0 = b - Ax_0, \quad p_0 = r_0 \quad (۸-۳)$$

پس از محاسبات اولیه، روند کلی برای $J=0$ تا برقراری شرایط همگرایی ادامه می‌یابد (فرمول‌های (۳-۳) تا (۹-۳)) [۷۵]. مهم‌ترین جزء روش گرادیان مزدوج، هسته محاسباتی^۱ ضرب ماتریس در بردار است [۷۶].

$$\gamma_i = \frac{(r_j, r_j)}{(Ap_j, p_j)} \quad (۹-۳)$$

$$x_{j+1} = x_j + \gamma_j p_j \quad (۱۰-۳)$$

$$r_{j+1} = r_j - \gamma_j Ap_j \quad (۱۱-۳)$$

$$\rho_j = \frac{(r_{j+1}, r_{j+1})}{(r_j, r_j)} \quad (۱۲-۳)$$

$$p_{j+1} = r_{j+1} + \rho_j p_j \quad (۱۳-۳)$$

به طور کلی، روش لونبرگ - مارکوات سریع‌تر از بقیه همگرا می‌شود [۶۸]. بنابراین، معمولاً برای تنظیم مشخصه‌های مدل از روش لونبرگ - مارکوات استفاده می‌شود.

^۱ Compute kernel

انتخاب صحیح مجموعه آموزش، تفسیر نتایج شبکه و درک جزئیات درونی شبکه مانند هندسه آن و پارامترهای کنترل کننده یادگیری از نکات حائز اهمیت برای استفاده مطلوب از شبکه هستند. در مورد هندسه شبکه، انتخاب صحیح اندازه لایه پنهان بسیار مهم است. می‌توان از روش سعی و خطا^۱ برای تعیین اندازه لایه پنهان استفاده نمود. هرچه تعداد نورون‌های لایه پنهان افزایش یابد، قابلیت شبکه برای تشخیص الگو بیشتر می‌شود. البته افزایش تعداد نورون‌ها ممکن است موجب بیش‌برازش^۲ شبکه نیز شود، یعنی شبکه، مثال‌های آموزشی را خوب یاد می‌گیرد ولی قدرت تعمیم آن کاهش می‌یابد.

۳-۳-۱-۳ طبقه‌بندی شبکه عصبی

باتوجه به معماری حاکم بر یادگیری، می‌توان تقسیم‌بندی برای شبکه‌های عصبی در نظر گرفت:

- شبکه‌های عصبی با یادگیری کم‌عمق^۳

- شبکه‌های عصبی با یادگیری عمیق

قابلیت شبکه‌ها با عمیق کردن آنها افزایش می‌یابد اما در گذشته به دلیل مشکلاتی مانند نبود سخت‌افزار مناسب، بیش‌برازش شدید و موارد دیگر، افزایش بیش از حد تعداد لایه‌های شبکه عصبی امکان‌پذیر نبود. طی چند سال اخیر با برطرف شدن این مشکلات، بحث یادگیری عمیق رونق گرفته است.

یادگیری با معماری‌های عمیق، یادگیری عمیق نامیده می‌شود که از سال ۲۰۰۶ تاکنون، به یکی از روش‌های مورد علاقه محققان در مسائل مختلف تبدیل شده است [۷۷]، [۷۸] و [۷۹]. زمانی که حجم وسیعی از داده‌ها موجود باشد، با استفاده از یادگیری عمیق که در آن تعداد لایه‌ها بین ورودی و خروجی، نسبت به یادگیری کم‌عمق، افزوده شده است، می‌توان به نتایج بهتری دست یافت.

در این مطالعه، شبکه‌های عصبی با یادگیری کم‌عمق و عمیق، به ترتیب، شبکه‌های عصبی کم‌عمق و عمیق نامیده شدند.


^۱ Try and error

^۲ Over fitting

^۳ Shallow learning


۳-۳-۱-۳-۱ شبکه عصبی کم عمق

شبکه پیشرو با الگوریتم پس انتشار خطا آموزش می‌بیند. در شکل (۳-۵)، ساختار شبکه پیشرو چندلایه نمایش داده شده است [۷۱].



شکل (۳-۵): شبکه عصبی پیشرو تشکیل شده از سه لایه [۷۱]


شبکه‌های پیشرو، اغلب دارای لایه پنهان با نورون‌های سیگموئید و لایه خروجی با نورون‌های خطی هستند. در شکل (۳-۶)، یک لایه از نورون‌های log sigmoid نمایش داده شده است.



شکل (۳-۶): یک لایه از نورون‌های log sigmoid (الف) جزئیات لایه، (ب) دیاگرام لایه، R : تعداد عناصر در بردار ورودی، S : تعداد نورون‌ها در لایه [۶۸]

وجود لایه پنهان از نورون‌هایی با تابع انتقال غیرخطی به شبکه این امکان را می‌دهد که توانایی آموزش رابطه خطی و غیرخطی را بین ورودی‌ها و خروجی‌ها داشته باشد. وجود لایه خروجی از نورون‌هایی با

تابع انتقال خطی باعث می‌شود که خروجی شبکه، هر مقدار را اختیار نماید. در شکل (۷-۳)، ساختار یک شبکه پیشرو با توابع انتقال Log sigmoid و Purelin نمایش داده شده است [۶۸].



شکل (۷-۳): ساختار شبکه پیشرو با توابع انتقال Log sigmoid و Purelin [۶۸]

در این مطالعه، شبکه پیشرو با الگوریتم آموزشی پس‌انتشار خطا - لونبرگ - مارکوات مورد استفاده قرار گرفت.

۳-۳-۱-۳-۲ شبکه عصبی عمیق


یکی از معماری‌های یادگیری عمیق، روش‌های مبتنی بر AE^۱ هستند. AE اولین بار توسط روملهارت^۲ و همکارانش در سال ۱۹۸۶ معرفی شد [۸۰] و یک شبکه عصبی با یادگیری بدون نظارت است که از الگوریتم پس‌انتشار خطا استفاده می‌کند و نقش اساسی در معماری‌های عمیق دارد [۸۱]، [۸۲] و [۸۳]. شبکه AE شامل کدگذار^۳ و کدگشا^۴ است که به ترتیب، ورودی را به یک نمایش جدید برده و سپس نمایش جدید را به صورت ورودی اولیه بازسازی می‌نماید [۶۸]. بنابراین، یک AE آموزش می‌بیند که به جای پیش‌بینی مقدار هدف y در ازای ورودی x ، ورودی x خود را بازسازی نماید. شبکه AE تلاش می‌کند که تابع $h_{w,b}(x) \approx x$ را آموزش ببیند، بدین صورت که خروجی $\hat{x}$ مشابه x باشد (شکل ۳-۳-۸)). بنابراین، بردار خروجی همان ابعاد بردار ورودی را دارد [۸۲] و [۸۴].

^۱ Autoencoder (AE)-based methods

^۲ Rumelhart

^۳ Encoder

^۴ Decoder



شکل (۳-۸): ساختار شبکه AE [۸۲]


شبکه SAE^۱، شبکه عصبی عمیق با یادگیری با نظارت شامل چندین لایه از AE هاست که خروجی هر لایه به عنوان ورودی لایه بعدی در نظر گرفته می شود. بنیجو^۲ و همکارانش در سال ۲۰۰۶ برانبارش AE ها را برای افزایش عملکرد شبکه های عمیق پیشنهاد نمودند [۸۵]. به علاوه، شبکه SAE در مسائل مختلف مورد استفاده قرار گرفته است [۸۶]، [۸۷] و [۸۸].

شبکه SAE با دو لایه پنهان بدین صورت آموزش داده می شود: ابتدا یک AE با ورودی X_k برای یادگیری ویژگی های اولیه^۳ $h_k^{(1)}$ آموزش داده می شود. ورودی X_k با هدف تعیین ویژگی اولیه^۱ $h_k^{(1)}$ برای هر ورودی وارد این AE می شود (شکل (۳-۹)) [۸۲].

^۱ Stacked autoencoder (SAE)


^۲ Benigio

^۳ Primary features



شکل (۳-۹): ساختار AE اول در شبکه SAE [۸۲]


سپس، این ویژگی‌های اولیه به عنوان ورودی به AE دیگری جهت آموزش ویژگی‌های ثانویه $h_k^{(2)}$ وارد می‌شوند. بر این اساس، ویژگی‌های اولیه جهت تعیین ویژگی ثانویه $h_k^{(2)}$ برای هر ویژگی اولیه $h_k^{(1)}$ وارد دومین AE می‌شوند (شکل (۳-۱۰) [۸۲]).



شکل (۳-۱۰): ساختار AE دوم در شبکه SAE [۸۲]


¹ Secondary features

سپس، ویژگی‌های ثانویه $h_k^{(2)}$ به عنوان ورودی، به لایه طبقه‌بندی کننده Softmax وارد می‌شوند و لایه‌ها برای تشکیل شبکه عمیق، به هم متصل می‌شوند (شکل (۳-۱۱)). خروجی هر گره طبقه‌بندی کننده Softmax، احتمال هر کلاس را بیان می‌کند. با استفاده از طبقه‌بندی کننده Softmax، محاسبه گرادینت تابع عملکرد Cross-Entropy در هر گره آسان می‌شود [۶۸].



شکل (۳-۱۱): ساختار لایه طبقه‌بندی کننده Softmax در شبکه SAE [۸۲]

در نهایت، هر سه لایه برای تشکیل SAE شامل دو لایه پنهان و یک لایه طبقه‌بندی کننده Softmax با هم ترکیب می‌شوند (شکل (۳-۱۲)) [۸۲].



شکل (۳-۱۲): ساختار شبکه SAE با دو لایه پنهان [۸۲]

در این مطالعه، شبکه SAE و الگوریتم آموزشی پسانتشار خطا - گرادیان مزدوج مورد استفاده قرار گرفت.

۳-۳-۱-۴ مزایا و معایب شبکه‌های عصبی

از جمله مزایای شبکه عصبی، می‌توان به این موارد اشاره نمود:

- کاربرد در حل طیف وسیعی از مسائل
- کارآمد بودن شبکه در شرایط تغییرات کوچک محیطی با آموزش مختصر
- در دسترس بودن بسته‌های نرم‌افزاری متعدد در این زمینه

از جمله معایب شبکه عصبی عبارت است از:

- عدم ارائه توضیح درمورد پاسخ‌ها و نحوه محاسبه آنها
- مشکل بودن تعمیم شبکه در آینده


۳-۳-۲ منطق فازی

در منطق کلاسیک، هر گزاره دو حالت بیشتر ندارد، یا درست است و یا نادرست. در دنیای واقعی نمی‌توان درباره درستی و یا نادرستی بسیاری از پدیده‌ها با قطعیت نظر داد و لفظ درست و یا نادرست را به کار برد. در بسیاری از تجربه‌های روزمره، یک پدیده می‌تواند نسبتاً درست باشد. اصول منطق فازی برای اولین بار توسط لفعلی عسگرزاده (معروف به لطفی‌زاده) در سال ۱۹۶۵ برای از بین بردن محدودیت‌های منطق کلاسیک ارائه شد [۸۹]. این منطق مشابه مغز انسان، با استفاده از داده‌های کیفی و غیردقیق به یادگیری و نتیجه‌گیری می‌پردازد. منطق فازی مجموعه‌ای از قواعد است که عدم قطعیت در دانش و استدلال انسان را مدل می‌کند. در منطق فازی، دانش افراد خبره با قوانین زبانی^۱ به شکل قواعد اگر - آن‌گاه مدل می‌شود. منطق فازی مبتنی بر نظریه مجموعه‌های فازی است. این نظریه تعمیمی از نظریه کلاسیک مجموعه‌ها در علم ریاضیات است. در تئوری کلاسیک مجموعه‌ها، یک عنصر یا به یک

^۱ Linguistic role

مجموعه تعلق دارد و یا ندارد. در واقع عضویت اجزا به یک مجموعه، از الگوی صفر و یک تبعیت می‌کند. در حالی که تئوری مجموعه‌های فازی، با بسط مفهوم عضویت اجزا، عضویت درجه‌بندی شده (بین ۰ تا ۱) را مطرح می‌کند [۶۶].

تابع عضویت^۱ در یک مجموعه فازی، مشخص کننده میزان عضویت یک عضو در مجموعه است [۹۰]. تابع عضویت، یک منحنی و رابطه‌ای متشکل از مشخصه‌های مختلف است که نحوه نگاشت هر نقطه در فضای ورودی را به صورت درجه عضویت در خروجی یا $\mu(x)$ در محدوده ۰ تا ۱ تعیین می‌کند. انواع مختلف تابع عضویت وجود دارد مانند تابع عضویت ذوزنقه‌ای، مثلثی، گوسی و زنگوله‌ای که به ترتیب `gbwllmf` و `gaussmf`، `trimf`، `trapmf` نامیده می‌شوند که در شکل (۳-۱۳) نمایش داده شده‌اند [۶۶]. انتخاب تابع عضویت با توجه به نوع مسأله تغییر می‌کند. در داده‌های مربوط به علوم زمین، توزیع گوسی بهترین هم‌پوشانی را با داده‌ها دارد [۴۹].



شکل (۳-۱۳): چهار نوع تابع عضویت، الف) ذوزنقه‌ای، ب) مثلثی، ج) گوسی، د) زنگوله‌ای [۹۱]


۳-۲-۱ سیستم‌های فازی

هسته اصلی سیستم‌های فازی، پایگاه دانش و اطلاعاتی است که از قواعد اگر - آنگاه تشکیل شده است. سه نوع سیستم فازی وجود دارد که معرفی می‌شوند [۶۶].

^۱ Membership function

۳-۳-۲-۱ سیستم‌های فازی خالص


سیستم استنتاج فازی^۱، براساس قواعد فازی، مجموعه‌های فازی ورودی را به تعدادی مجموعه فازی به عنوان خروجی‌های مسأله تبدیل می‌کند (شکل (۳-۱۴)). مهم‌ترین مشکل سیستم‌های فازی خالص، نوع ورودی‌ها و خروجی‌هاست. در این حالت، مجموعه‌های فازی که واژه‌های توصیفی هستند، به عنوان ورودی و خروجی سیستم تعریف می‌شوند، در حالی که در سیستم‌های مهندسی، ورودی‌ها و خروجی‌های مسأله، اعداد ریاضی هستند.



شکل (۳-۱۴): سیستم فازی خالص [۶۶]

۳-۳-۲-۲ سیستم‌های فازی تاکاگی - سوگنو^۲

برای حل مشکل سیستم‌های فازی خالص، سیستم تاکاگی - سوگنو ارائه شده است. در این سیستم فازی، ورودی‌ها و خروجی‌های مسأله، متغیرهای ریاضی هستند. بنابراین، بخش "آن گاه" در قواعد فازی از یک عبارت توصیفی با متغیرهای زبانی به یک رابطه ریاضی ساده تبدیل خواهد شد (شکل (۳-۱۵)).




شکل (۳-۱۵): سیستم فازی تاکاگی - سوگنو [۶۶]

^۱ Fuzzy inference system (FIS)

^۲ Takagi-Sugeno

۳-۳-۲-۱ سیستم‌های فازی با فازی‌ساز و غیرفازی‌ساز

این سیستم با اضافه کردن دو ابزار فازی‌ساز و غیرفازی‌ساز در ابتدا و انتهای سیستم فازی خالص، ایجاد می‌شود. در این حالت، متغیرهای ریاضی به عنوان ورودی‌ها، با ورود به فازی‌ساز، به مجموعه‌های فازی تبدیل می‌شوند. سپس سیستم استنتاج فازی، براساس مجموعه‌ای از قواعد فازی، مجموعه‌های فازی ورودی را به مجموعه‌های فازی خروجی تبدیل می‌کند. سپس مجموعه‌های فازی خروجی با ورود به غیرفازی‌ساز، به متغیر ریاضی تبدیل می‌شوند (شکل (۳-۱۶)).



شکل (۳-۱۶): سیستم فازی با فازی‌ساز و غیرفازی‌ساز [۶۶]

۳-۳-۲ سیستم‌های استنتاج فازی

قسمت اصلی منطق فازی، سیستم استنتاج فازی است که براساس مقادیر متغیرهای ورودی، با استفاده از قواعد فازی، متغیر خروجی را تعیین می‌کند. ممدانی و اسیلین^۱ در سال ۱۹۷۵، اولین نوع سیستم استنتاج فازی و تاکاگی و سوگنو در سال ۱۹۸۵، دومین نوع آن را معرفی نمودند [۹۹] و [۱۰۰]. تفاوت عمده این دو سیستم استنتاج فازی در تابع عضویت خروجی است که برای نوع تاکاگی - سوگنو، از نوع ثابت یا خطی است.

این دو سیستم استنتاج در نحوه محاسبه بخش "آن گاه" هر قاعده فازی و تعیین خروجی نهایی مجموعه قواعد فازی به عنوان متغیر خروجی نهایی تفاوت دارند. در سیستم استنتاج فازی ممدانی، بخش "آن گاه" قواعد فازی با اعمال اپراتورهای فازی AND و OR تعیین می‌شود. پس از مشخص شدن بخش

^۱ Mamdani and Assilian

آن گاه هر قاعده فازی، خروجی نهایی مجموعه قواعد فازی، که خود یک مجموعه فازی است، با مقدار بیشینه قواعد فازی تعیین می شود. در سیستم استنتاج فازی تاکاگی - سوگنو، بخش "آن گاه" قواعد فازی، به کمک یک رابطه ریاضی و به صورت یک متغیر عددی تعیین می شود. سپس خروجی نهایی مجموعه قواعد فازی، با متوسط گیری وزنی همه قواعد فازی تعیین می شود [۶۶].

در این مطالعه، سیستم استنتاج فازی تاکاگی - سوگنو مورد استفاده قرار گرفت. از جمله مهم ترین مزایای این سیستم می توان به این موارد اشاره نمود:


- کارآمد بودن از نظر محاسباتی

- سازگار بودن با آنالیز ریاضی

۳-۳-۳ سیستم های عصبی فازی

یکی از معایب سیستم های استنتاج فازی، دشواری و عدم دقت در انتخاب توابع عضویت و ایجاد قوانین فازی است، به ویژه در مواردی که دانش خبره و مهارت لازم در آن وجود ندارد. سیستم های عصبی فازی، ابزاری توانمند برای تعیین قواعد فازی و تنظیم خودکار پارامترهای توابع عضویت است [۶۸]. با بهره گیری همزمان از قابلیت های شبکه عصبی و منطق فازی، سیستم عصبی فازی ایجاد می شود. بنابراین می توان قواعد فازی و مشخصه های تابع عضویت را براساس فرآیند یادگیری (مطابق شبکه عصبی) به صورت بهینه تعیین کرد. بنابراین، یادگیری و استخراج قواعد فازی مورد نیاز در سیستم استنتاج فازی ممکن می شود. یک سیستم عصبی فازی مزایای منطق فازی و شبکه عصبی را همزمان دارد و علاوه بر بیان دانش به صورت متغیرهای زبانی و قابل فهم فازی، از قابلیت آموزش شبکه عصبی نیز برخوردار است [۶۶].

برای تعیین مقادیر بهینه مشخصه های توابع عضویت، برای آموزش شبکه با هدف کاهش اختلاف پیش بینی های شبکه و خروجی های واقعی از الگوریتم بهینه سازی استفاده می شود (شکل (۳-۱۷)). در این مطالعه برای آموزش شبکه عصبی فازی، از الگوریتم پس انتشار استفاده شد.



شکل (۳-۱۷): عملکرد سیستم عصبی فازی برای تنظیم پارامترهای توابع عضویت [۴۹]

سیستم‌های عصبی فازی، پیچیدگی بیشتری نسبت به سیستم‌های فازی دارند که سبب ایجاد محدودیت‌هایی می‌شود [۴۹]:

- فقط سیستم استنتاج فازی تاکاگی - سوگنو را پوشش می‌دهند.
- یک خروجی دارند و توابع عضویت خروجی باید از نوع ثابت یا خطی باشند.

۳-۴ ماشین کمیته

در علوم مهندسی برای حل مسائل و توابع پیچیده، از اصل تقسیم و تسهیل^۱ استفاده می‌شود. طبق این اصل، یک مسئله پیچیده به چندین مسئله ساده‌تر تقسیم می‌شود و به جای حل یک مسئله دشوار، چندین مسئله آسان‌تر حل می‌شود. در نهایت، پاسخ‌های به دست آمده با هم ترکیب می‌شوند و پاسخ مسئله اصلی به دست می‌آید. در سیستم‌های هوشمند نیز می‌توان از این اصل برای رسیدن به پاسخی دقیق‌تر استفاده نمود. بدین منظور، پاسخ‌های به دست آمده از هر یک از سیستم‌های هوشمند با هم ترکیب می‌شوند و ماشین کمیته تشکیل می‌شود. این فرآیند باعث می‌شود مزایای هر یک از سیستم‌های هوشمند در کنار هم قرار گیرند و جواب دقیقی به دست آید [۴۹].

در سال‌های اخیر، ماشین کمیته مبتنی بر سیستم‌های هوشمند برای اهداف مختلف مورد استفاده قرار گرفته و نتایج نشان داده که دقت CMIS در مقایسه با سیستم‌های هوشمند به صورت منفرد، افزایش یافته است [۹۴]، [۹۵]، [۹۶]، [۹۷] و [۹۸].

^۱ Principle of divide and conquer

در این مطالعه، برای ترکیب پاسخ سیستم‌های هوشمند، دو نوع CMIS پیشنهاد شد: میانگین‌گیری ساده و میانگین‌گیری وزن‌دار.

۳-۳-۴-۱ ماشین کمیت با میانگین‌گیری ساده

در این روش، از پاسخ سیستم‌های هوشمند، میانگین گرفته که به آن، میانگین‌گیری ساده گفته می‌شود. سهم هر یک از سیستم‌های هوشمند در تولید خروجی نهایی با هم برابر است [۹۹].

۳-۳-۴-۲ ماشین کمیت با میانگین‌گیری وزن‌دار

در این روش، از الگوریتم بهینه‌سازی ازدحام ذرات برای ایجاد بهترین ترکیب سیستم‌های هوشمند استفاده شد. این روش نسبت به میانگین‌گیری ساده، جواب دقیق‌تری ارائه می‌دهد. سهم هر یک از سیستم‌های هوشمند در تولید خروجی نهایی لزوماً یکسان نیست. برای ایجاد این نوع ماشین کمیت، باید تابع هدف تعریف شود. در این مطالعه، تابع هدف به صورت فرمول (۳-۱۴) تعریف شده که تابع خطاست که باید کمینه شود:

$$MSE = \frac{1}{n} \sum_{i=1}^n (W_1 \times NN_i + W_2 \times FL_i + W_3 \times NF_i - K_i)^2 \quad (3-14)$$

که در آن W_1 ، W_2 و W_3 مقدار سهم هر یک از سیستم‌های هوشمند در تولید خروجی نهایی، K_i مقدار خروجی واقعی و n تعداد داده‌های مورد استفاده برای آموزش سیستم‌های هوشمند است. تابع هدف با الگوریتم بهینه‌سازی ازدحام ذرات بهینه می‌شود.

۳-۳-۴-۱-۲ الگوریتم بهینه‌سازی ازدحام ذرات

الگوریتم بهینه‌سازی ازدحام ذرات، اولین بار توسط کندی و ابرهارت^۱ در سال ۱۹۹۵ مطرح شد [۱۰۰]. آنها این الگوریتم را PSO نامیدند زیرا از رفتار گروهی پرندگان در زمان پرواز الهام گرفته شده است. سپس، مطالعات مختلفی بر روی الگوریتم PSO انجام گرفت [۱۰۱]، [۱۰۲] و [۱۰۳]. نتایج مطالعات نشان داده که این الگوریتم، به سرعت همگرا شده اما سرعت همگرایی با نزدیک شدن به مقدار بهینه

¹ Kennedy and Eberhart

کاهش یافته و به اندازه جمعیت حساسیتی نشان نداده است. الگوریتم PSO در حل مسائل و آنالیزهای مختلف و توابع چندهدفه نتایج موفقیت آمیزی داشته است [۱۰۴]، [۱۰۵]، [۱۰۶]، [۱۰۷]، [۱۰۸] و [۱۰۹].

در الگوریتم PSO، ذرات در فضای جستجو جاری می‌شوند. تغییر مکان ذرات در فضای جستجو تحت تأثیر تجربه و دانش خود و همسایگان آنهاست. بنابراین موقعیت دیگر ذرات روی چگونگی جستجوی یک ذره اثر می‌گذارد. نتیجه مدل سازی این رفتار اجتماعی، فرآیند جستجویی است که ذرات به سمت نواحی موفق میل می‌کنند. الگوریتم PSO، از مجموعه‌ای از پاسخ‌های ممکن استفاده می‌کند که این پاسخ‌ها تا زمانی که یک پاسخ بهینه دریافت و یا شرایط پایان الگوریتم مهیا شود، به حرکت خود ادامه می‌دهند.

۳-۳-۴-۲ طرح کلی الگوریتم PSO

در این الگوریتم، حرکت ذرات برای یافتن پاسخ‌های جدیدتر، طبق قاعده‌ای تعیین و در نهایت، منجر به تبادل اطلاعات و همگرایی بین اعضای جمعیت می‌شود. منشأ این حرکت، سه مورد است:

۱. رفتاری که این ذرات، قبلاً نشان می‌دادند.


۲. بهترین موقعیتی که ذرات تاکنون تجربه کردند (بهترین تجربه شخصی^۱).

۳. بهترین موقعیتی که کل ذرات تاکنون تجربه کردند (بهترین تجربه عمومی^۲).

فرض می‌شود، ذره با سرعت $V_i(t)$ در موقعیت $X_i(t)$ قرار دارد. برای حرکت بعدی این ذره، سه حالت وجود دارد. در حالت (۱)، ذره با توجه به رفتار فعلی خود، حرکت را ادامه می‌دهد که همان اینرسی است. در حالت (۲)، حرکت بعدی ذره با توجه به بهترین تجربه شخصی صورت می‌پذیرد. در حالت (۳)، حرکت بعدی ذره با توجه به بهترین تجربه عمومی صورت می‌پذیرد که بیانگر الگوبذیری بالایی از جامعه است (شکل (۳-۱۸)).

¹ Personal best (pbest)

² Global best (gbest)



شکل (۱۸-۳): نمایش فرضی موقعیت یک ذره در فضای جستجو

بنابراین رفتار هر ذره علاوه بر رفتار قبلی خود، تحت تأثیر بهترین تجربه محلی و بهترین تجربه عمومی نیز قرار می‌گیرد. معادله سرعت، بیانگر حرکت ذرات به سمت ناحیه بهینه و براساس این سه عنصر اصلی ارائه می‌شود. بنابراین، سرعت جدید، $V_i(t+1)$ برای ذره در موقعیت $X_i(t)$ ، طبق فرمول (۱۵-۳) به دست می‌آید:

$$V_i(t+1) = W \times \overline{V_i(t)} + C_1 \times r_1 \times (P_{pbest} - X_i(t)) + C_2 \times r_2 \times (P_{gbest} - X_i(t)) \quad (۱۵-۳)$$


که در آن، W وزن اینرسی، $V_i(t)$ بردار سرعت در لحظه t ، C_1 و C_2 فاکتورهای یادگیری که معمولاً ۲ در نظر گرفته می‌شوند، r_1 و r_2 اعداد تصادفی تولید شده به صورت نرمال در بازه $[0, 1]$ ، P_{pbest} موقعیت بهترین تجربه شخصی، P_{gbest} موقعیت بهترین تجربه عمومی، $P_{pbest} - X_i(t)$ فاصله ذره تا بهترین تجربه شخصی و $P_{gbest} - X_i(t)$ فاصله ذره تا بهترین تجربه عمومی است.

با توجه به شکل (۱۸-۳)، اگر $X_i(t)$ نشان دهنده موقعیت ذره در لحظه t باشد، موقعیت ذره با افزودن سرعت $V_i(t+1)$ به موقعیت $X_i(t)$ به صورت فرمول (۱۶-۳) تغییر می‌یابد:

$$X_i(t+1) = X_i(t) + V_i(t+1) \quad (۱۶-۳)$$

که در آن، $X_i(t)$ موقعیت قبلی ذره و $V_i(t+1)$ سرعت جدید ذره است. زمانی که $V_i(t+1)$ به دست می‌آید، $X_i(t+1)$ به روز می‌شود.

بنابراین، طرح کلی الگوریتم بدین صورت است که با ایجاد ذرات اولیه و اختصاص سرعت‌های اولیه به آنها، شروع می‌شود. سپس، مقدار تابع هدف را در موقعیت هر ذره محاسبه می‌نماید و بهترین (کمترین) مقدار تابع هدف و بهترین موقعیت را تعیین می‌کند. سرعت‌های جدید براساس سرعت کنونی، بهترین موقعیت‌های شخصی ذرات و بهترین موقعیت‌های همسایگان آنها انتخاب می‌شوند. سپس، سرعت و موقعیت ذرات به روز می‌شوند. تکرار تا برقراری شرایط خاتمه، ادامه می‌یابد. همگرایی جواب‌ها، تعداد تکرار، عدم بهبود و زمان، از جمله شرط‌های توقف است [۱۱۰]. در شکل (۳-۱۹)، فلوچارت الگوریتم PSO نمایش داده شده است.



شکل (۳-۱۹): فلوچارت الگوریتم PSO [۱۱۱]

فصل چهارم: پیش‌بینی تراوایی

۴-۱ مقدمه

مقاطع نازک حاوی اطلاعات گسترده‌ای در مورد سنگ مانند انواع کانی‌ها، فضاها، خالی و شکستگی‌ها و وضعیت دانه‌بندی است. آنالیز تصاویر مقاطع نازک از دو دیدگاه قابل بررسی است. در دیدگاه اول، با استفاده از روش‌های آنالیز تصویر، قسمت‌های مختلف تصویر از هم تفکیک می‌شود. در دیدگاه دوم، با استفاده از ویژگی‌های استخراج شده از آنالیز تصویر، برخی پارامترهای پتروفیزیکی مانند تراوایی، با سیستم‌های هوشمند پیش‌بینی می‌شود. در این فصل، از آنالیز تصویر و سیستم‌های هوشمند برای پیش‌بینی تراوایی استفاده شد. سپس، ماشین کمیته مبتنی بر سیستم‌های هوشمند برای ترکیب نتایج به دست آمده، مورد استفاده قرار گرفت. برای بررسی عملکرد مدل‌های طراحی شده، میانگین مربعات خطا برای داده‌های نرمال، ضریب همبستگی و میانگین خطای مطلق برای داده‌های واقعی محاسبه شد. مدل‌های طراحی شده، می‌توانند باعث کاهش زمان و هزینه مطالعات مخزنی شوند. به علاوه، در میدان‌های قدیمی که غالباً مغزه‌ها به دلیل هوازدگی، خواص اولیه خود را از دست داده‌اند و فقط مطالعات پتروگرافی آنها موجود است، می‌توانند مورد استفاده قرار گیرند. در بخش آخر، از لاگ‌های چاه‌پیمایی و تراوایی لاگ NMR در چاه B، برای طراحی شبکه عصبی عمیق استفاده شد و با استفاده از مدل طراحی شده، تراوایی لاگ NMR در چاه A پیش‌بینی شد. سپس، نتایج به دست آمده از آنالیز تصویر و سیستم‌های هوشمند با تراوایی NMR پیش‌بینی شده، مقایسه شد.

۴-۲ استخراج داده‌های پتروگرافی

تصاویر مقاطع نازک اشباع شده با اپوکسی آبی رنگ، با میکروسکوپ نوری در بزرگ‌نمایی $12/5X$ تهیه شد. برای طراحی مدل پیش‌بینی تراوایی، یازده پارامتر پتروگرافی مورد استفاده قرار گرفت که برای استخراج این ویژگی‌ها از مطالعات پتروگرافی و نرم‌افزار Image Pro Plus استفاده شد. ویژگی‌های استخراج شده از هر تصویر عبارتند از:

۱- مقدار تخلخل بین‌دانه‌ای و بین‌بلوری

۲- مقدار تخلخل درون‌دانه‌ای

۳- مقدار تخلخل قالبی

۴- مقدار ریزتخلخل

۵- مقدار تخلخل نوری

۶- مقدار کلسیت

۷- مقدار دولومیت

۸- مقدار انیدریت

۹- مقدار سیمان

۱۰- نوع بافت


۱۱- میانگین ضریب شکل هندسی فضاهای خالی

برای تصاویر تهیه شده از هر مقطع، پارامترهای پتروگرافی، محاسبه و سپس میانگین پارامترها برای آن مقطع، در نظر گرفته شد.

تخلخل بین‌دانه‌ای، در صورتی که فضاهای آن با هم مرتبط باشند، نقش موثری در تولید هیدروکربن دارد. تخلخل بین‌بلوری، طی پدیده دولومیتی شدن در مراحل سنگ‌شدگی تشکیل می‌شود و مانند تخلخل بین‌دانه‌ای، رابطه مستقیم با تراوایی دارد. تخلخل درون‌دانه‌ای در فضای درون دانه‌ها تشکیل می‌شود که معمولاً ایزوله است و رابطه خوبی با تراوایی ندارد. تخلخل قالبی، ناشی از انحلال دانه‌های اسکلتی و غیراسکلتی کربناته است که دانه حل می‌شود و قالب آن برجای می‌ماند و به علت ایزوله بودن، معمولاً رابطه‌ای با تراوایی ندارد، مگر این‌که فضاهای آن به هم مرتبط شوند. نقش موثر ریزتخلخل‌ها، در ارتباط انواع مختلف تخلخل با هم و در نتیجه افزایش تراوایی است.

در این مطالعه، فضاهایی با مساحت کمتر از ۵۰۰ میکرومتر مربع، به عنوان ریزتخلخل در نظر گرفته شد [۸]. مجموع فراوانی تخلخل‌های مشاهده شده در تصاویر نیز به عنوان تخلخل نوری در نظر گرفته شد. بدین ترتیب، انواع تخلخل‌ها، در مقاطع، شناسایی و درصد فراوانی آنها ثبت شد.

کانی‌های کلسیت، دولومیت و انیدریت در مقاطع نازک مورد بررسی قرار گرفت و درصد فراوانی آنها ثبت شد. نوع سیمان کلسیتی، انیدریتی و دولومیتی نیز شناسایی و درصد کل سیمان درج شد. برای ویژگی نوع بافت، چهار نوع بافت گرینستون، پکستون، وکستون و مادستون از رده‌بندی دانه‌ها در نظر گرفته و به ترتیب با اعداد ۱، ۲، ۳ و ۴ کدگذاری شد. در شکل (۴-۱)، نمونه‌هایی از بررسی انواع تخلخل‌ها و کانی‌های کلسیت، دولومیت و انیدریت، در تصاویر مقاطع نازک آورده شده است.



شکل (۴-۱): تصاویر مقاطع نازک، الف) کانی دولومیت و سیمان انیدریتی، ب) کانی دولومیت که کلسیتی شده است، ج) کانی دولومیت و سیمان انیدریتی، د) کانی‌های کلسیت و دولومیت و سیمان انیدریتی

شکل هندسی فضاهای خالی تأثیر زیادی بر عملکرد سنگ مخزن دارد. خلل و فرج‌های کشیده نسبت به خلل و فرج‌های گرد، تأثیر متفاوتی بر خواص فیزیکی سنگ دارند. در این مطالعه، از نسبت محیط به مساحت فضاهای خالی استفاده شد. در محیط دو بعدی، یک فضای کشیده، دارای نسبت محیط به مساحت بالا و فضای گرد دارای مقدار پایینی از این نسبت است. ضریب شکل هندسی، نسبت نرمال شده‌ای از محیط به مساحت فضای خالی است. برای محاسبه این نسبت، مربع محیط بر مساحت تقسیم و به گونه‌ای نرمال‌سازی انجام می‌شود که مقدار این نسبت برای شکل دایره‌ای برابر یک شود. این نسبت با γ نمایش داده شد (فرمول (۱-۴)):

$$\gamma = \frac{\text{perimeter}^2}{4\pi \times \text{area}} \quad (1-4)$$

سپس برای محاسبه میانگین ضریب شکل هندسی برای هر تصویر از میانگین‌گیری وزنی استفاده شد (فرمول (۲-۴)):

$$\gamma_{\text{mean}} = \frac{\sum_{i=1}^n (A_i \times \gamma_i)}{\sum_{i=1}^n A_i} \quad (2-4)$$

در فرمول (۲-۴)، A_i مساحت فضای خالی i ام است. در نظر گرفتن مساحت هر فضای خالی باعث می‌شود در نمونه با ریزتخلخل زیاد، فضای خالی کوچک تأثیر زیادی بر روی ضریب شکل هندسی نداشته باشد، زیرا عامل اصلی تعیین کننده ضریب شکل هندسی از شکل فضاهای بزرگ حاصل می‌شود [۸].

۳-۴ آماده‌سازی داده‌ها

۱-۳-۴ انتخاب داده‌های مناسب


به مجموعه‌ای از داده‌های ورودی و خروجی متناظر با آن برای آموزش با نظارت سیستم‌های هوشمند نیاز است. انتخاب مجموعه آموزشی مناسب، اهمیت بسیاری دارد زیرا خروجی نهایی سیستم‌های هوشمند به طور مستقیم تابع مجموعه آموزشی است. هرچه تعداد متغیرهای ورودی به سیستم‌های هوشمند بیشتر باشد، به مجموعه آموزشی وسیع‌تری برای تشخیص الگو نیاز است. زمان لازم برای

آموزش سیستم نیز تابعی از تعداد متغیرهای آموزشی است و هرچه تعداد متغیرها بیشتر باشد، زمان افزایش می‌یابد. همچنین، زیاد بودن تعداد متغیرها، احتمال ایجاد مدل نامناسب را افزایش می‌دهد. بنابراین، حذف متغیرهایی که تأثیر معنی‌داری در پیش‌بینی سیستم ندارند، می‌تواند باعث افزایش دقت شود.


در این مطالعه، برای پیش‌بینی تراوایی، یازده ویژگی پتروگرافی از تصاویر مقاطع نازک استخراج شد.

۴-۳-۱ بررسی ضریب همبستگی


در شکل (۴-۲)، ارتباط هر یک از ویژگی‌های پتروگرافی با تراوایی مغزه، مورد بررسی قرار گرفت. ضرایب همبستگی مثبت و منفی به ترتیب نشان‌دهنده همبستگی مستقیم و معکوس ویژگی پتروگرافی با تراوایی مغزه است. ویژگی پتروگرافی با مقدار ضریب همبستگی بیشتر با تراوایی مغزه، تأثیر بیشتری در طراحی سیستم‌های هوشمند دارد. با توجه به شکل (۴-۲) و مقادیر ضریب همبستگی محاسبه شده، ویژگی‌های تخلخل بین‌دانه‌ای، میانگین ضریب شکل هندسی فضاها، نوع بافت، تخلخل قالبی، مقدار سیمان و تخلخل نوری، نسبت به بقیه ویژگی‌ها، رابطه بیشتری را با تراوایی مغزه داشتند.



شکل (۴-۲): نمایش همبستگی پارامترهای پتروگرافی با تراوایی مغزه



ادامه شکل (۴-۲): نمایش همبستگی پارامترهای پتروگرافی با تراوایی مغزه



ادامه شکل (۴-۲): نمایش همبستگی پارامترهای پتروگرافی با تراوایی مغزه

۴-۳-۱-۲ استفاده از شبکه عصبی کم عمق

برای تعیین تعداد مناسب از ویژگی‌های انتخابی برای آموزش سیستم‌های هوشمند، از شبکه عصبی کم عمق استفاده شد. استفاده از همه ویژگی‌های پتروگرافی مناسب برای طراحی سیستم‌های هوشمند، سبب ایجاد نویز می‌شود و دقت را کاهش می‌دهد.

بدین منظور، ابتدا هر کدام از شش ویژگی پتروگرافی انتخاب شده از بخش ۴-۳-۱-۱، به عنوان ورودی شبکه عصبی کم عمق در نظر گرفته شد. در این مرحله، شش شبکه ایجاد و مقدار MSE برای هر شبکه اندازه‌گیری شد. سپس ویژگی مربوط به شبکه با کم‌ترین مقدار MSE انتخاب و پنج شبکه با دو ورودی ایجاد شد. ورودی اول این پنج شبکه، ویژگی انتخاب شده در مرحله اول و ورودی دوم از میان پنج

ویژگی مناسب به صورت جایگزینی تغییر یافت. سپس شبکه با کمترین مقدار MSE انتخاب و مراحل ذکر شده برای یک شبکه با سه ورودی تکرار شد. این مراحل تا رسیدن به شبکه با شش ویژگی پتروگرافی تکرار شد (جدول (۴-۱)). بنابراین شبکه با کمترین مقدار MSE، تعیین کننده تعداد ویژگی مناسب برای طراحی سیستم‌های هوشمند است.

با توجه به جدول (۴-۱)، سه ویژگی تخلخل بین‌دانه‌ای، نوع بافت و میانگین ضریب شکل هندسی با مقایسه نسبی مقدار MSE کم و همبستگی زیاد، برای طراحی سیستم‌های هوشمند انتخاب شد.

جدول (۴-۱): مقادیر MSE آموزش و ضریب همبستگی شبکه‌های عصبی کم‌عمق براساس تعداد و نوع ویژگی‌ها

ویژگی‌های پتروگرافی	MSE	ضریب همبستگی
تخلخل بین‌دانه‌ای	۰/۰۱۰۱	۰/۹۲۱۵
نوع بافت	۰/۰۰۹۸	۰/۹۳۶۸
نوع بافت-تخلخل بین‌دانه‌ای	۰/۰۰۹۲	۰/۹۶۸۲
نوع بافت-مقدار سیمان	۰/۰۱۸۰	۰/۸۹۱۹
نوع بافت-تخلخل بین‌دانه‌ای-ضریب شکل هندسی	۰/۰۰۹۰	۰/۹۷۰۴
نوع بافت-ضریب شکل هندسی-مقدار سیمان	۰/۰۱۴۰	۰/۹۶۸۸
نوع بافت-تخلخل بین‌دانه‌ای-ضریب شکل هندسی-مقدار سیمان	۰/۰۶۲۲	۰/۹۵۱۴
تخلخل بین‌دانه‌ای-نوع بافت-ضریب شکل هندسی-مقدار سیمان-تخلخل قالبی	۰/۰۷۵۰	۰/۹۶۰۶
تخلخل بین‌دانه‌ای-نوع بافت-ضریب شکل هندسی-مقدار سیمان-تخلخل قالبی-تخلخل نوری	۰/۰۷۹۰	۰/۹۵۰۷

۴-۳-۲ نرمال‌سازی داده‌ها

در سیستم‌های هوشمند به ویژه شبکه‌های عصبی، بهترین حالت برای طراحی هنگامی است که داده‌ها نرمال شده باشند، یعنی تمامی مقادیر در بازه $[0, 1]$ یا $[-1, 1]$ قرار گیرند. یکی از دلایل نرمال کردن داده‌ها برای شبکه‌های عصبی این است که توابع انتقال نمی‌توانند بین مقادیر بسیار بزرگ، تفاوت قائل شوند. بنابراین مهم‌ترین دلیل نرمال نمودن داده‌ها، کمک به آموزش شبکه است.

محدوده وسیع تراوایی در این مطالعه، می‌تواند باعث کاهش عملکرد مدل شود، بنابراین با نرمال‌سازی داده‌ها، عملکرد مدل افزایش می‌یابد. با استفاده از فرمول (۳-۴)، ورودی‌ها و خروجی سیستم‌های هوشمند به بازه [۰, ۱] نرمال شد.

$$X_{\text{normalize}} = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (3-4)$$

در فرمول (۳-۴)، $X_{\min}$ و $X_{\max}$ به ترتیب برابر حداقل و حداکثر مقدار در مجموعه ورودی یا خروجی است. پس از طراحی و آموزش سیستم‌های هوشمند، خروجی به دست آمده، به مقیاس اصلی برده شد.

۴-۴ پیش‌بینی تراوایی با استفاده از سیستم‌های هوشمند

یکی از ویژگی‌های پتروفیزیکی مهم که نقش اساسی در حرکت سیال درون مخزن ایفا می‌کند، تراوایی است. برای مدل‌سازی مخزن از تراوایی استفاده می‌شود. در این مطالعه تلاش شد تا با استفاده از داده‌های پتروگرافی و سیستم‌های هوشمند، مدلی برای پیش‌بینی تراوایی ارائه شود. با توجه به نتایج قسمت ۴-۳، از ویژگی‌های تخلخل بین‌دانه‌ای، میانگین ضریب شکل هندسی فضاهای خالی و نوع بافت به عنوان ورودی‌های مدل استفاده شد. همچنین، از تراوایی مغزه نیز به عنوان خروجی استفاده شد. ۱۱۵ داده مورد استفاده شامل ویژگی‌های پتروگرافی مناسب و تراوایی مغزه، به دو دسته آموزش و تست تقسیم شد. از ۸۵ داده آموزش برای طراحی و از ۳۰ داده تست برای بررسی عملکرد سیستم‌های هوشمند استفاده شد.


۴-۴-۱ پیش‌بینی تراوایی با استفاده از شبکه عصبی کم‌عمق

از الگوریتم‌های مختلف برای به روز کردن وزن‌ها و مقادیر بایاس شبکه عصبی کم‌عمق استفاده می‌شود. در این مطالعه از شبکه پیشرو با الگوریتم آموزشی پس‌انتشار خطا - لونیبرگ - مارکوات استفاده شد. مشخصات شبکه در جدول (۲-۴) ذکر شده است.

جدول (۴-۲): مشخصات شبکه عصبی کم عمق

Feedforward	نوع شبکه
Levenberg-Marquardt backpropagation	الگوریتم آموزشی
TRAINLM	تابع آموزشی
MSE	تابع عملکرد
۱	تعداد لایه های پنهان
۴	تعداد نورون های لایه پنهان
Log-sigmoid	تابع انتقال بین لایه اول و دوم
Purelin	تابع انتقال بین لایه دوم و سوم

پس از آموزش شبکه، داده های تست به مدل معرفی شد. مقادیر MSE آموزش و تست مدل براساس تراوایی نرمال، به ترتیب ۰/۰۰۷۸ و ۰/۰۱۰۷ محاسبه شد. در شکل (۴-۳)، تراوایی پیش بینی شده از مدل برای داده های تست در مقابل تراوایی مغزه نمایش داده شده است. مقدار MAE تست مدل براساس تراوایی واقعی، ۱۱/۵۴ میلی داری محاسبه شد.



شکل (۴-۳): نمودار مقایسه تراوایی پیش بینی شده با مدل شبکه عصبی کم عمق و تراوایی مغزه

۴-۴-۲ پیش‌بینی تراوایی با استفاده از مدل منطق فازی

در مدل منطق فازی، از سیستم استنتاج فازی تاکاگی - سوگنو برای ارزیابی تراوایی و روش خوشه‌سازی تفریقی برای تعیین نوع و مقدار پارامترهای توابع عضویت ورودی و خروجی استفاده شد. هر یک از توابع عضویت نشان‌دهنده یک مجموعه فازی در داده‌هاست. خطا در تعیین توابع عضویت و پارامترهای مربوط به آن، موجب ایجاد خطا در پیش‌بینی تراوایی می‌شود. همچنین، به مجموعه‌ای از قواعد اگر - آنگاه بین توابع عضویت ورودی‌ها و خروجی‌ها نیاز است.


در روش خوشه‌سازی تفریقی، تعیین شعاع خوشه‌سازی فاکتور مهمی است زیرا تأثیر مستقیم بر نوع و مقدار پارامترهای توابع عضویت دارد. شعاع خوشه‌بندی کوچک، خوشه کوچک‌تر با تعداد بیشتر می‌دهد و قواعد بیشتری تولید می‌کند. در مقابل، شعاع خوشه‌بندی بزرگ، خوشه بزرگ‌تر با تعداد کمتر می‌دهد و قواعد کمتری ایجاد می‌کند [۱۱۲].

در خوشه‌سازی تفریقی، مقادیر بین صفر و یک به فواصل $0/1$ به شعاع سیستم فازی نسبت داده شد. بدین ترتیب، ده سیستم فازی با شعاع $0/1$ تا ۱، ایجاد و مقدار MSE برای هر سیستم محاسبه شد. شعاع بهینه، شعاع سیستم فازی با کمترین مقدار MSE است (جدول (۴-۳)).

جدول (۴-۳): مقدار MSE آموزش برای سیستم‌های فازی با شعاع خوشه‌سازی متفاوت


شعاع خوشه‌سازی	مقدار MSE
۰/۱	۰/۲۱۸۷
۰/۲	۲/۷۱e+۱۶
۰/۳	۰/۰۰۶۹
۰/۴	۰/۰۱۱۹
۰/۵	۰/۰۱۱۲
۰/۶	۰/۰۱۱۱
۰/۷	۰/۰۱۱۷
۰/۸	۰/۰۱۳۰
۰/۹	۰/۰۱۲۸
۱	۰/۰۱۲۸

با توجه به جدول (۴-۳)، شعاع ۰/۳ از روش خوشه‌سازی تفریقی انتخاب شد. بنابراین مدل منطق فازی با شعاع ۰/۳ ایجاد شد. این سیستم فازی از هفت قانون اگر - آن‌گاه و توابع عضویت از نوع گوسی در هفت خوشه تشکیل شد (شکل (۴-۴)).



شکل (۴-۴): توابع عضویت برای ویژگی‌های تداخل بین‌دانه‌ای و میانگین ضریب شکل هندسی در مدل منطق فازی

سپس داده‌های تست به مدل معرفی شد. مقادیر MSE آموزش و تست مدل براساس تراوایی نرمال، به ترتیب برابر با ۰/۰۰۶۹ و ۰/۰۰۸۱ محاسبه شد. تراوایی پیش‌بینی شده از مدل به ازای داده‌های تست در مقابل تراوایی مغزه در شکل (۴-۵) نمایش داده شده است. MAE تست مدل براساس تراوایی واقعی، ۱۱/۱۷ میلی‌داری محاسبه شد.



شکل (۴-۵): نمودار مقایسه تراوایی پیش‌بینی شده با مدل منطق فازی و تراوایی مغزه


۴-۴-۳ پیش‌بینی تراوایی با استفاده از مدل عصبی فازی

سیستم عصبی فازی، مزایای روش منطق فازی و شبکه عصبی را هم‌زمان دارد و علاوه بر بیان دانش به صورت متغیرهای زبانی و قابل فهم فازی، از قابلیت آموزش شبکه عصبی نیز برخوردار است. تعیین شعاع خوشه‌سازی بهینه مشابه روش منطق فازی انجام شد. با شعاع خوشه بهینه، مقدار MSE برای هر سیستم، کمینه می‌شود. با توجه به جدول (۴-۴)، شعاع $0/3$ انتخاب شد. بنابراین مدل عصبی فازی با شعاع $0/3$ ایجاد شد. این سیستم، از هفت قانون اگر - آن‌گاه و توابع عضویت از نوع گوسی در هفت خوشه تشکیل شد.

سپس داده‌های تست به مدل عصبی فازی معرفی شد. مقادیر MSE آموزش و تست مدل براساس تراوایی نرمال، به ترتیب $0/0050$ و $0/0080$ محاسبه شد. در شکل (۴-۶)، خروجی مدل به ازای داده‌های تست در مقابل داده مغزه نمایش داده شده است. MAE تست مدل براساس تراوایی واقعی، $10/85$ میلی‌داریسی محاسبه شد.

جدول (۴-۴): مقدار MSE آموزش برای سیستم‌های عصبی فازی با شعاع خوشه‌سازی متفاوت

شعاع خوشه‌سازی	MSE
۰/۱	۰/۰۸۹۵
۰/۲	$۲/۳۳e+۱۴$
۰/۳	۰/۰۰۵۰
۰/۴	۰/۰۰۸۱
۰/۵	۰/۰۰۷۲
۰/۶	۰/۰۰۷۴
۰/۷	۰/۰۰۸۳
۰/۸	۰/۰۱۱۰
۰/۹	۰/۰۱۱۰
۱	۰/۰۱۱۹



شکل (۴-۶): نمودار مقایسه تراوایی پیش‌بینی شده با مدل عصبی فازی و تراوایی مغزه

۴-۴-۴ ماشین کمیته مبتنی بر سیستم‌های هوشمند


به منظور کاهش خطای پیش‌بینی و ترکیب نتایج به دست آمده از مدل‌های شبکه عصبی کم‌عمق، منطق فازی و عصبی فازی از دو نوع ماشین کمیته استفاده شد.

۴-۴-۱ ماشین کمیته با میانگین گیری ساده

در این روش، سهم هر یک از سیستم‌ها در ایجاد خروجی نهایی با هم برابر در نظر گرفته شد، به صورت فرمول (۴-۴):

$$K_{Ave} = \frac{1}{3} (K_{Sh-NN} + K_{FL} + K_{NF}) \quad (۴-۴)$$

که در آن K_{Ave} تراوایی ماشین کمیته با میانگین گیری ساده، K_{Sh-NN} تراوایی مدل شبکه عصبی کم عمق، K_{FL} تراوایی مدل منطق فازی و K_{NF} تراوایی مدل عصبی فازی است [۹۹]. مطابق فرمول (۴-۴)، تراوایی مدل به دست آورده شد. مقدار MSE تست مدل براساس تراوایی نرمال، برابر با ۰/۰۰۷۲ محاسبه شد که نسبت به هر یک از سیستم‌های هوشمند به صورت منفرد، کمتر است. تراوایی پیش‌بینی شده از مدل در مقابل تراوایی مغزه در شکل (۷-۴) نمایش داده شده است. مقدار MAE تست مدل براساس تراوایی واقعی، ۹/۰۳ میلی‌داریسی محاسبه شد.



شکل (۷-۴): نمودار مقایسه تراوایی پیش‌بینی شده با ماشین کمیته با میانگین گیری ساده و تراوایی مغزه

لازم به ذکر است که این نوع ماشین کمیت، همیشه دقت پیش‌بینی را افزایش نمی‌دهد، بنابراین ابزاری دقیق و قابل اعتماد به منظور کاهش خطا در محاسبات نیست. با توجه به این محدودیت، ماشین کمیت با میانگین‌گیری وزن‌دار مورد استفاده قرار گرفت.

۴-۴-۲ ماشین کمیت با میانگین‌گیری وزن‌دار


از الگوریتم PSO برای ایجاد ترکیب بهینه‌ای از نتایج مدل‌های شبکه عصبی کم‌عمق، منطق فازی و عصبی فازی استفاده شد. ماشین کمیت با استفاده از الگوریتم PSO، سهم هر یک از مدل‌ها را در تولید خروجی نهایی محاسبه نمود. برای ایجاد ترکیب بهینه، تابع هدف به صورت فرمول (۴-۵) تعریف شد:

$$MSE = \frac{1}{n} \sum_{i=1}^n (W_1 \times K_{Sh-NN} + W_2 \times K_{FL} + W_3 \times K_{NF} - K_{core})^2 \quad (۴-۵)$$

که در آن، W_1 ، W_2 و W_3 مشخص‌کننده سهم هر یک از مدل‌ها در تولید خروجی نهایی، K_{Sh-NN} ، K_{FL} و K_{NF} به ترتیب تراوایی مدل شبکه عصبی کم‌عمق، منطق فازی و عصبی فازی، K_{core} بیانگر تراوایی مغزه و n تعداد داده‌های آموزش است. فرمول (۴-۵)، مقدار خطای تراوایی پیش‌بینی شده را نشان می‌دهد که الگوریتم PSO، مقدار بهینه آن را برای داده‌های آموزش محاسبه نمود. ضرایب به دست آمده از الگوریتم PSO، به داده‌های تست تعمیم داده شد. بنابراین، مقدار خروجی نهایی ماشین کمیت با الگوریتم PSO برای داده‌های تست با فرمول (۴-۶) محاسبه شد:

$$K_{PSO} = 0.2947 \times K_{Sh-NN} + 0.3198 \times K_{FL} + 0.4000 \times K_{NF} \quad (۴-۶)$$

مقدار MSE تست مدل براساس تراوایی نرمال، ۰/۰۰۶۶ محاسبه شد که کمترین میزان خطا نسبت به سایر روش‌های شبکه عصبی کم‌عمق، منطق فازی، عصبی فازی و ماشین کمیت با میانگین‌گیری ساده است. تراوایی پیش‌بینی شده از مدل در مقابل تراوایی مغزه در شکل (۴-۸) نمایش داده شده است. مقدار MAE تست مدل براساس تراوایی واقعی، ۸/۹۴ میلی‌داری محاسبه شد.



شکل (۴-۸): نمودار مقایسه تراوایی پیش‌بینی شده با ماشین کمیت با میانگین‌گیری وزن‌دار و تراوایی مغزه

۴-۵ استفاده از نتایج لاگ NMR

به منظور اعتبارسنجی نتایج به دست آمده از سیستم‌های هوشمند و ماشین‌های کمیت، علاوه بر داده مغزه، از نتایج لاگ NMR نیز استفاده شد. مقاطع نازک مورد استفاده جهت استخراج ویژگی‌های پتروگرافی و ساخت مدل‌های هوشمند، متعلق به چاه A میدان پارس جنوبی اما نمودارگیری NMR در این چاه انجام نشده است. بنابراین، با تشکیل مدلی هوشمند، با استفاده از اطلاعات چاه‌پیمایی چاه B، تراوایی لاگ NMR برای چاه A پیش‌بینی شد.

۴-۵-۱ انتخاب و آماده‌سازی داده‌ها

لاگ‌های GR، NPHI، PEF و RHOB که در چاه‌های A و B مشترک بودند، انتخاب شدند. اعداد منفی ثبت شده در اطلاعات لاگ‌ها، می‌تواند به دلیل عدم برداشت دستگاه یا برداشت اشتباه باشد که این اعماق، حذف شد. همچنین، اگر اختلاف قطر سرمته حفاری و لاگ Caliper در قسمتی از چاه، بزرگ‌تر

از ۱/۵ اینچ باشد، ریختگی چاه^۱ رخ داده است و اطلاعات مربوط به این قسمت‌ها، قابل استفاده نیستند و باید حذف شوند [۵۱].

لاگ NMR، تراوایی را به صورت مستقیم و پیوسته اندازه‌گیری نمی‌کند، بلکه تراوایی سازند با استفاده از مدل‌های تراوایی مانند Timur-Coates^۲ و SDR^۳ که بر پایه ترکیب روابط تجربی و تئوری هستند، محاسبه می‌شود:

$$K_{\text{Timur-Coates}} = C \times \left(\frac{\text{FFI}}{\text{BVI}}\right)^2 \times \varphi_{\text{NMR}}^4 \quad (۷-۴)$$

$$K_{\text{SDR}} = C \times T_{2\text{ML}}^2 \times \varphi_{\text{NMR}}^4 \quad (۸-۴)$$

در فرمول‌های (۷-۴) و (۸-۴)، $K_{\text{Timur-Coates}}$ تراوایی مدل Timur-Coates (mD)، K_{SDR} تراوایی مدل SDR (mD)، FFI^4 شاخص سیال آزاد، BVI° حجم سیال کاهش ناپذیر، $T_{2\text{ML}}$ متوسط لگاریتمی زمان آرامش (ms)، φ_{NMR} تخلخل لاگ NMR به صورت کسری و C ضریبی که در هر سازند باید محاسبه شود [۴۰] و [۱۱۳]. مدل SDR به وجود نفت سبک و گاز حساس است چون زمان آرامش آنها با آب کمی تفاوت دارد و بر روی متوسط لگاریتمی زمان آرامش اثر می‌گذارد. نتایج مطالعات نشان داده که به همین دلیل، تراوایی حاصل از مدل Timur-Coates تطابق بیشتری با تراوایی مغزه دارد [۴۳] و [۴۵]. بنابراین، در این مطالعه از تراوایی مدل Timur-Coates حاصل از داده NMR (K_{tim}) در چاه B استفاده شد.

با توجه به محدوده وسیع تراوایی NMR، داده‌ها نرمال شدند تا سیستم هوشمند عملکرد بهتری داشته باشد.

هم عمق‌سازی بین داده‌های حاصل از آنالیز مغزه و داده‌های لاگ، تطبیق عمق^۴ نامیده می‌شود [۱۱۴]. روش‌های متفاوتی برای تطبیق عمق وجود دارد که در این مطالعه، از تطابق تخلخل مغزه با لاگ NPHI

^۱ Bad hole flag

^۲ Coates or free fluid

^۳ Schlumberger doll research or mean- T_2

^۴ Free fluid index

^۵ Bulk volume irreducible

^۶ Depth matching

استفاده شد. بدین منظور، نمودار تخلخل مغزه در مقابل عمق، ترسیم و با نمودار NPHI مقایسه شد. در حالت تطابق، این دو نمودار، روندهای همدیگر را تایید می کنند.

۴-۵-۲ مدل سازی با شبکه عصبی عمیق

به دلیل حجم بالای داده های چاه پیمایی، از شبکه عصبی عمیق SAE استفاده شد. شبکه SAE با اطلاعات چاه B شامل لاگ های GR، NPHI، PEF و RHOB به عنوان ورودی ها و و تراوایی لاگ NMR به عنوان خروجی، آموزش داده شد. مشخصات شبکه SAE در جدول (۴-۵) بیان شده است. مقدار MSE آموزش مدل براساس داده های نرمال، ۰/۰۰۲۰ محاسبه شد.


جدول (۴-۵): مشخصات شبکه عصبی عمیق

Stacked autoencoder	نوع شبکه
Conjugate gradient-backpropagation	الگوریتم آموزشی
TRAINSCG	تابع آموزشی
Cross-Entropy	تابع عملکرد
AE اول	
۵۰	تعداد نورون های لایه پنهان
Purelin	تابع انتقال
AE دوم	
۵۰	تعداد نورون های لایه پنهان
Log sigmoid	تابع انتقال

بنابراین، با استفاده از اطلاعات چاه B و شبکه عصبی عمیق SAE، بانک اطلاعاتی برای پیش بینی تراوایی NMR طراحی شد. سپس اطلاعات لاگ های GR، NPHI، PEF و RHOB در چاه A، مربوط به اعماقی که براساس تطبیق عمق، متناسب با اعماق داده مغزه بودند، به مدل طراحی شده، معرفی و تراوایی NMR چاه A پیش بینی شد.

در شکل (۴-۹)، تراوایی مغزه و تراوایی NMR پیش بینی شده در مقابل عمق نمایش داده شده است. مقدار ضریب همبستگی بین تراوایی مغزه و تراوایی NMR پیش بینی شده، ۰/۹۷۶۵ محاسبه شد. با توجه به شکل (۴-۹) و مقدار ضریب همبستگی، تراوایی NMR پیش بینی شده، تطابق خوبی با تراوایی


مغزه داشته است. بنابراین، تراوایی هر یک از سیستم‌های هوشمند با تراوایی NMR پیش‌بینی شده، مقایسه شد.



شکل (۴-۹): نمایش تراوایی NMR پیش‌بینی شده و تراوایی مغزه در مقابل عمق


۴-۵-۳ مقایسه نتایج سیستم‌های هوشمند با تراوایی لاگ NMR

نتایج هر یک از سیستم‌های هوشمند شامل شبکه عصبی کم‌عمق، منطق فازی و عصبی فازی با تراوایی NMR مقایسه شد (شکل (۴-۱۰)). مقادیر MAE تراوایی پیش‌بینی شده از شبکه عصبی کم‌عمق، منطق فازی و عصبی فازی با تراوایی NMR، به ترتیب، ۱۴/۴۲، ۱۴/۲۳ و ۱۴/۳۷ میلی داری محاسبه شد.



شکل (۴-۱۰): نمودارهای مقایسه تراوایی پیش‌بینی شده با سیستم‌های هوشمند و تراوایی NMR

به علاوه، نتایج دو نوع ماشین کمیت مبتنی بر سیستم‌های هوشمند نیز با تراوایی NMR پیش‌بینی شده مقایسه شد (شکل (۴-۱۱)). مقادیر MAE تراوایی پیش‌بینی شده از CMIS-SA و CMIS-WA، با تراوایی NMR، به ترتیب، ۱۳/۴۳ و ۱۲/۷۸ میلی داری محاسبه شد.



شکل (۴-۱۱): نمودارهای مقایسه تراوایی پیش‌بینی شده از ماشین‌های کمیته و تراوایی NMR

فصل پنجم: نتیجه‌گیری و پیشنهادها

۵-۱ نتیجه گیری

- پیش‌بینی تراوایی به خصوص در مخازن کربناته، همواره با دشواری رو به رو بوده است. یک سازند کربناته، پیچیدگی‌های مخزنی و پتروفیزیکی زیادی نسبت به سایر سازندها دارد. اصولاً رسوبات کربناته مستعد دگرسانی فراگیر و سریع هستند که کانی‌شناسی^۱ و ساختمان فضاهای خالی درون سنگ‌های کربناته را تغییر می‌دهد. به ویژه، فرآیندهای سیمانی شدن و انحلال به طور پیوسته ساختمان فضاهای خالی را به منظور افزایش و کاهش و یا از بین بردن تخلخل و متأثر از آن تراوایی، تغییر می‌دهند. در نتیجه، محاسبه تراوایی در کربنات‌ها، با عدم قطعیت زیادی رو به رو است [۵۲].

- پس از بررسی مقاطع نازک مربوط به سازندهای کنگان و دالان در چاه A میدان پارس جنوبی در بزرگ‌نمایی‌های مختلف، بزرگ‌نمایی ۱۲/۵X انتخاب شد زیرا منعکس کننده بهترین اطلاعات از مقاطع این سازندهاست.

- در این مطالعه، برای پیش‌بینی تراوایی، یازده ویژگی پتروگرافی از تصاویر مقاطع نازک استخراج شد. ابتدا به منظور انتخاب ورودی‌های مناسب برای طراحی سیستم‌های هوشمند به بررسی ضریب همبستگی پرداخته شد. ویژگی‌های تخلخل بین‌دانه‌ای، میانگین ضریب شکل هندسی فضاهای خالی، نوع بافت، تخلخل قالبی، مقدار سیمان و تخلخل نوری بیشترین رابطه را با تراوایی مغزه داشتند.

- سپس به منظور انتخاب تعداد مناسب از این ویژگی‌های انتخابی برای طراحی سیستم‌های هوشمند، از شبکه عصبی کم‌عمق استفاده شد. ویژگی‌های تخلخل بین‌دانه‌ای، نوع بافت و میانگین ضریب شکل هندسی فضاهای خالی با مقایسه نسبی مقدار MSE کمتر و ضریب همبستگی بیشتر، برای طراحی سیستم‌های هوشمند انتخاب شدند.

- داده‌های مورد استفاده شامل ویژگی‌های پتروگرافی مناسب و تراوایی مغزه، به دو دسته آموزش و تست تقسیم شد. از داده آموزش برای طراحی و از داده تست برای بررسی عملکرد سیستم‌های هوشمند استفاده شد.

¹ Mineralogy

- برای پیش‌بینی تراوایی، از روش‌های شبکه عصبی کم‌عمق، منطق فازی و عصبی فازی استفاده شد. در جدول (۱-۵) نتایج حاصل از سیستم‌های هوشمند برای پیش‌بینی تراوایی آورده شده است.

جدول (۱-۵): مقادیر خطا و ضریب همبستگی سیستم‌های هوشمند

انواع سیستم‌های هوشمند	MSE داده نرمال		MAE داده واقعی (میلی‌داری)		ضریب همبستگی
	آموزش	تست	تست	تست	
Sh-NN	۰/۰۰۷۸	۰/۰۱۰۷	۱۱/۵۴	۰/۹۳۹۷	
FL	۰/۰۰۶۹	۰/۰۰۸۱	۱۱/۱۷	۰/۹۵۸۸	
NF	۰/۰۰۵۰	۰/۰۰۸۰	۱۰/۸۵	۰/۹۵۵۸	

- از دو نوع ماشین کمیته مبتنی بر سیستم‌های هوشمند، به منظور افزایش دقت در پیش‌بینی تراوایی، استفاده شد: میانگین‌گیری ساده و وزن‌دار. در میانگین‌گیری وزن‌دار، از الگوریتم PSO، برای تعیین سهم هر یک از سیستم‌های هوشمند در طراحی ماشین کمیته استفاده شد. در جدول (۲-۵) نتایج حاصل از ماشین‌های کمیته برای پیش‌بینی تراوایی بیان شده است.

جدول (۲-۵): مقادیر خطا و ضریب همبستگی ماشین‌های کمیته مبتنی بر سیستم‌های هوشمند

انواع CMIS	MSE داده نرمال	MAE داده واقعی (میلی‌داری)	ضریب همبستگی
CMIS-SA	۰/۰۰۷۲	۹/۰۳	۰/۹۶۲۳
CMIS-WA	۰/۰۰۶۶	۸/۹۴	۰/۹۶۲۲

- از مقادیر MSE آموزش، و MSE و MAE تست، به ترتیب برای طراحی و ارزیابی مدل‌های هوشمند استفاده شد. با توجه به مقادیر MSE آموزش در جدول (۱-۵)، هر سه مدل، به خوبی آموزش داده شد. با توجه به مقادیر MSE و MAE تست، مدل‌های فازی و عصبی فازی، عملکرد بهتری داشتند. با توجه به مقادیر MSE و MAE تست در جدول (۲-۵)، می‌توان نتیجه گرفت که ماشین‌های کمیته با کاهش خطا، توانستند تراوایی را با دقت بیشتری پیش‌بینی نمایند.

- برای بررسی میزان تطابق تراوایی پیش‌بینی شده با تراوایی مغزه، می‌توان از ضریب همبستگی استفاده نمود. با توجه به جدول‌های (۱-۵) و (۲-۵)، ضرایب همبستگی بین تراوایی پیش‌بینی شده با

سیستم‌های هوشمند، با تراوایی مغزه در حد قابل قبولی است. به علاوه، تراوایی پیش‌بینی شده از ماشین‌های کمیته نسبت به سیستم‌های هوشمند منفرد، همبستگی بیشتری با تراوایی مغزه داشتند.

- برای اعتبارسنجی تراوایی پیش‌بینی شده با آنالیز تصویر پتروگرافی و سیستم‌های هوشمند، از تراوایی لاگ NMR نیز استفاده شد. نمودارگیری NMR در چاه A در میدان پارس جنوبی انجام نشده است. بنابراین، از اطلاعات چاه‌پیمایی مربوط به چاه B در میدان، برای ساختن مدلی جهت پیش‌بینی تراوایی NMR، استفاده و این مدل به چاه A تعمیم داده شد.

- برای طراحی مدل، از شبکه عصبی عمیق SAE و اطلاعات چاه B شامل لاگ‌های GR، NPHI، PEF و RHOB و تراوایی NMR استفاده شد. مقدار MSE آموزش مدل براساس داده‌های نرمال، ۰/۰۰۲۰ محاسبه شد. با توجه به شکل (۴-۹)، مدل شبکه عصبی عمیق، در پیش‌بینی تراوایی با محدوده بیش‌تر از ۱۰ میلی‌داری، عملکرد بهتری داشته است. سپس لاگ‌های GR، NPHI، PEF و RHOB مربوط به چاه A، وارد مدل شد و تراوایی NMR پیش‌بینی شد.


- روند تغییرات تراوایی NMR پیش‌بینی شده با تراوایی مغزه در مقابل عمق، تطابق خوبی داشت. به علاوه، مقدار ضریب همبستگی بین تراوایی مغزه و تراوایی NMR پیش‌بینی شده، ۰/۹۷۶۵ محاسبه شد. بنابراین، تراوایی پیش‌بینی شده از سیستم‌های هوشمند با تراوایی NMR پیش‌بینی شده مقایسه شد (جدول (۵-۳)).

جدول (۵-۳): نتایج حاصل از مقایسه تراوایی پیش‌بینی شده از سیستم‌های هوشمند با تراوایی NMR پیش‌بینی شده

انواع سیستم‌های هوشمند	MAE داده واقعی (میلی‌داری)	
	تست	
Sh-NN	۱۴/۴۲	۰/۹۲۸۲
FL	۱۴/۲۳	۰/۹۳۹۹
NF	۱۴/۳۷	۰/۹۳۶۷
CMIS-SA	۱۳/۴۳	۰/۹۴۵۵
CMIS-WA	۱۲/۷۸	۰/۹۴۵۱

- مقادیر MAE حاصل از مقایسه تراوایی پیش‌بینی شده از سیستم‌های هوشمند با تراوایی NMR پیش‌بینی شده، بیانگر عملکرد مناسب مدل‌های طراحی شده در پیش‌بینی تراوایی است. به علاوه، ضرایب همبستگی نیز در حد قابل قبولی است.

- در شکل (۵-۱)، مقادیر MAE حاصل از مقایسه تراوایی پیش‌بینی شده از سیستم‌های هوشمند با تراوایی مغزه و تراوایی NMR پیش‌بینی شده آورده شده است. اختلاف کم مقادیر MAE بیانگر عملکرد مناسب مجموعه آنالیز تصویر پتروگرافی و سیستم‌های هوشمند در پیش‌بینی تراوایی است.



شکل (۵-۱): مقایسه نتایج سیستم‌های هوشمند با تراوایی مغزه و تراوایی NMR پیش‌بینی شده

- روش‌های اندازه‌گیری تراوایی شامل مغزه‌گیری و آزمایش چاه، زمان‌بر و پرهزینه هستند و در تعداد محدودی از چاه‌های یک میدان انجام می‌شوند. بنابراین استفاده از قابلیت سیستم‌های هوشمند و آنالیز تصویر، با کاهش هزینه و زمان، ارزیابی مقرون به صرفه‌ای از تراوایی را با دقت مناسب فراهم می‌آورد.

- در میدان‌های قدیمی که ممکن است مغزه‌ها در دسترس نباشد و مطالعات پتروگرافی آنها موجود باشد، مجموعه آنالیز تصویر و سیستم‌های هوشمند، می‌تواند برای پیش‌بینی تراوایی مورد استفاده قرار گیرد. همچنین، این مجموعه، بر روی داده پتروگرافی به دست آمده از خرده‌های حفاری نیز قابل استفاده است. بنابراین، پیش‌بینی تراوایی از نمونه‌هایی که برای آزمایش‌های متداول تعیین تراوایی کوچک‌اند، نیز امکان‌پذیر است.

۵-۲ پیشنهادها

- در این مطالعه، ویژگی‌های پتروگرافی از تصاویر تهیه شده از میکروسکوپ نوری استخراج شد. از میکروسکوپ‌های الکترونی نیز برای مطالعات پتروگرافی استفاده می‌شود. بسیاری از ویژگی‌های سنگ‌شناسی مانند مقدار انواع رس‌ها، بررسی مواد سیمانی و تخلخل‌های بسیار ریز با میکروسکوپ‌های الکترونی مطالعه می‌شوند. به علاوه، میکروسکوپ‌های الکترونی، وضوح^۱ بیشتری نسبت به میکروسکوپ‌های نوری دارند [۱۱۵]. بنابراین، استفاده از اطلاعات حاصل از میکروسکوپ‌های الکترونی می‌تواند در کاهش خطای پیش‌بینی تراوایی، نقش موثری داشته باشد.

- با افزایش تعداد سیستم‌های هوشمندی که در تشکیل ماشین کمیته سهیم هستند، می‌توان نتایج بهتری به دست آورد. همچنین، در میانگین گیری وزن دار، می‌توان از الگوریتم‌های بهینه‌سازی مختلف برای تعیین سهم هر سیستم هوشمند استفاده نمود.

- با افزایش تعداد مقاطع مورد استفاده، می‌توان از انواع شبکه‌های عصبی با یادگیری عمیق مانند شبکه‌های عصبی کانولوشن، برای پیش‌بینی تراوایی استفاده نمود. در یادگیری عمیق، با افزایش تعداد لایه‌ها یا عمیق‌تر شدن شبکه، درک روابط بین ورودی‌ها و خروجی‌ها بیشتر می‌شود. بنابراین، معماری‌های عمیق، می‌توانند نتایج خوبی در مدل‌سازی داشته باشند.

¹ Resolution

- [1]- Kiany, D., (2017), "Iran and Qatar, gas production in South Pars", **Palma Journal**, 16, pp. 150-159.
- [۲]- دهقان زاده، م.، (۱۳۸۴)، پایان نامه ارشد: "مقایسه تخلخل و تراوایی بدست آمده از نمودار NMR و مغزه در یکی از چاه های میدان گازی پارس جنوبی"، دانشکده زمین شناسی، دانشگاه تهران.
- [۳]- شمس نیا، الف.، (۱۳۸۵)، پایان نامه ارشد: "اثر هندسه منافذ روی کیفیت مخزنی سازندهای کنگان و دالان"، دانشکده زمین شناسی، دانشگاه تهران.
- [4]- Aali, J., Rahimpour-Bonab, H. and Kamali, M. R., (2006), "Geochemistry and origin of the world's largest gas field from Persian Gulf, Iran", **Journal of Petroleum Science and Engineering**, 50, 3, pp. 161-175.
- [5]- Berryman, J. G. and Blair, S. C., (1986), "Use of digital image analysis to estimate fluid permeability of porous materials: Application of two-point correlation functions", **Journal of Applied Physics**, 60, 6, pp. 1930-1938.
- [6]- Coskun, S. B. and Wardlaw, N. C., (1993), "Estimation of permeability from image analysis of reservoir sandstones", **Journal of Petroleum Science and Engineering**, 10, 1, pp. 1-16.
- [7]- Blair, S. C., Berge, P. A. and Berryman, J. G., (1996), "Using two-point correlation functions to characterize microgeometry and estimate permeabilities of sandstones and porous glass", **Journal of Geophysical Research: Solid Earth**, 101, B9, pp. 20359-20375.
- [8]- Anselmetti, F. S., Luthi, S. and Eberli, G. P., (1998), "Quantitative characterization of carbonate pore systems by digital image analysis", **Journal of AAPG Bulletin**, 82, 10, pp. 1815-1836.
- [9]- Ali, M. and Chawathé, A., (2000), "Using artificial intelligence to predict permeability from petrographic data", **Journal of Computers & Geosciences**, 26, 8, pp. 915-925.

- [10]- Solymar, M. And Fabricius, I. L., (1999), “Image analysis and estimation of porosity and permeability of arnager greensand, Upper cretaceous, Denmark”, **Journal of Physics and Chemistry of the Earth, Part A: Solid Earth and Geodesy**, 24, 7, pp. 587-591.
- [11]- Garnham, J. and Hatfield, K., (2001), “The application of image analysis to improve permeability prediction”, **Journal of Petrophysics**, 42, 5, pp. 457-467.
- [12]- Egmont-Petersen, M., de Ridder, D. and Handels, H., (2002), “Image processing with neural networks-A review”, **Journal of Pattern Recognition**, 35, 10, pp. 2279-2301.
- [13]- Lock, P. A., Jing, X., Zimmerman, R. W. and Schlueter, E. M., (2002), “Predicting the permeability of sandstone from image analysis of pore structure”, **Journal of Applied Physics**, 92, 10, pp. 6311-6319.
- [14]- Jurgawczynski, M., Zimmerman, R. W. and Jing, X. D., (2004), “Estimating the permeability of carbonate rocks using image analysis and effective medium theory”, International Symposium of the Society of Core Analysts, pp. 1-11, Abu Dhabi, UAE.
- [15]- Zimmerman, R. W., Jing, X., Lock, P. A. and Jurgawczynski, M., (2007), “Permeability predictions based on two-dimensional pore space images”, SPE Annual Technical Conference and Exhibition (ATCE 2007), pp. 1-10, Anaheim, California, USA.
- [16]- Al-Kharusi, A. S. and Blunt, M. J., (2008), “Multiphase flow predictions from carbonate pore space images using extracted network models”, **Journal of Water Resources Research**, 44, 6, pp. 1-14.
- [17]- Hossain, Z., (2011), “Relative permeability prediction from Image Analysis of thin sections”, 73rd EAGE Annual Conference and Exhibition-SPE EUROPEC, pp. 1-10, Vienna, Austria.
- [18]- Hu, J. and Stroeven, P., (2011), “Application of image analysis to assessing critical pore size for permeability prediction of cement paste”, **Journal of Image Analysis & Stereology**, 22, 2, pp.97-103.

- [19]- Mostaghimi, P., Blunt, M. J. and Bijeljic, B., (2013), “Computations of absolute permeability on micro-CT images”, **Journal of Mathematical Geosciences**, 45, 1, pp.103-125.
- [20]- Nabawy, B. S., (2014), “Estimating porosity and permeability using digital image analysis (DIA) technique for highly porous sandstones”, **Arabian Journal of Geosciences**, 7, 3, pp. 889-898.
- [21]- Winardhi, C. W., Maulana, F. I. and Latief, F. D. E., (2015), “Permeability estimation of porous rock by means of fluid flow simulation and digital image analysis”, Padjadjaran Earth Dialogues: International Symposium on Geophysical Issues (PEDISGI), pp. 1-6, Bandung, Indonesia.
- [22]- Srisutthiyakorn, N., (2016), “Deep-learning methods for predicting permeability from 2D/3D binary-segmented images”, SEG International Exposition and 86th Annual Meeting, pp. 3042-3046, Dallas, Texas, USA.
- [23]- Saxena, N., Mavko, G., Hofmann, R. and Srisutthiyakorn, N., (2017), “Estimating permeability from thin sections without reconstruction: digital rock study of 3D properties from 2D images”, **Journal of Computers & Geosciences**, 102, pp. 79-99.
- [24]- Mohaghegh, S., Arefi, R., Ameri, S. and Hefner, M. H., (1994), “A methodological approach for reservoir heterogeneity characterization using artificial neural networks”, SPE Annual Technical Conference and Exhibition, pp. 1-5, New Orleans, Louisiana, USA.
- [25]- Helle, H. B., Bhatt, A. and Ursin, B., (2001), “Porosity and permeability prediction from wireline logs using artificial neural networks: a North Sea case study”, **Journal of Geophysical Prospecting**, 49, 4, pp. 431-444.
- [26]- Badarinadh, V., Suryanarayana, K., Youssef, F. Z., Sahouh, K. and Valle, A., (2002), “Log-derived permeability in a heterogeneous carbonate reservoir of Middle East, Abu Dhabi, using artificial neural network”, 10th Abu Dhabi International Petroleum Exhibition and Conference (ADIPEC 2002), pp. 1-13, Abu Dhabi, UAE.

[27]- Lim, J. S., (2005), "Reservoir properties determination using fuzzy logic and neural networks from well data in offshore Korea", **Journal of Petroleum Science and Engineering**, 49, 3, pp. 182-192.

[۲۸]- احمدی، م.، یزدیان، ع. و صائی، م.، (۱۳۸۵)، "پیش‌بینی میزان تراوایی سنگ مخزن با استفاده از داده‌های پتروفیزیکی"، **نشریه علمی-پژوهشی مهندسی معدن**، دوره ۱، شماره ۲، ص ۴۳-۵۲.

[29]- Kadkhodaie Ilkhchi, A., Rezaee, M. and Moallemi, S. A., (2006), "A fuzzy logic approach for estimation of permeability and rock type from conventional well log data: an example from the Kangan reservoir in the Iran Offshore Gas Field", **Journal of Geophysics and Engineering**, 3, 4, pp. 356-369.

[۳۰]- امینی، الف.، (۱۳۸۷)، "برآورد تخلخل و تراوایی در سازندهای نفتی با استفاده از منطق فازی"، دومین کنفرانس مهندسی معدن ایران، ص ۶۷۸-۶۷۳، دانشگاه تهران.

[۳۱]- مهرکی، م.، عاشوری، ح.، نصرالله شکیباصفت، ن. الف. و اهرمی نژاد، ی.، (۱۳۸۹)، "استفاده از تکنیک شبکه‌های عصبی مصنوعی برای تخمین تخلخل و تراوایی در سازند آسماری"، نخستین گردهمایی و همایش ملی بررسی دستاوردهای پژوهشگران علوم زمین ایران، ص ۸-۱، دانشگاه آزاد اسلامی واحد تهران شمال.

[32]- Kazem Shiroodi, S., Ghafoori, M. and Khanian, M., (2012), "Secondary porosity index effect on improving permeability estimation from petrophysical logs utilizing artificial intelligent approaches", **Iranian Journal of Petroleum Geology**, 3, 3, pp. 77-98.

[۳۳] مهری، ی.، (۱۳۹۳)، پایان‌نامه ارشد: "تخمین تراوایی سنگ مخزن با استفاده از داده‌های پتروفیزیکی و بکارگیری شبکه‌های هوشمند مناسب در یکی از میادین نفتی ایران"، دانشکده مهندسی شیمی، دانشگاه سمنان.

[34]- Vardian, M., Nasriani, H. R., Faghihi, R., Vardian, A. and Jowkar, S., (2016), "Porosity and permeability prediction from well logs using an adaptive neuro-fuzzy

inference system in a naturally fractured gas-condensate reservoir”, **Journal of Energy Sources, Part A: Recovery, Utilization, and Environmental Effects**, 38, 3, pp. 435-441.

[35]- Zhu, L.Q., Zhang, C., Wei, Y. and Zhang, C. M., (2017), “Permeability prediction of the tight sandstone reservoirs using hybrid intelligent algorithm and nuclear magnetic resonance logging data”, **Arabian Journal for Science and Engineering**, 42, 4, pp. 1643-1654.

[36]- Labani, M. M., Kadkhodaie-Ilkhchi, A. and Salahshoor, K., (2010), “Estimation of NMR log parameters from conventional well log data using a committee machine with intelligent systems: A case study from the Iranian part of the South Pars gas field, Persian Gulf Basin”, **Journal of Petroleum Science and Engineering**, 72, 1, pp. 175-185.

[37]- Sadeghi, R., Kadkhodaie, A., Rafiei, B., Yosefpour, M. and Khodabakhsh, S., (2011), “A committee machine approach for predicting permeability from well log data: a case study from a heterogeneous carbonate reservoir, Balal oil Field, Persian Gulf”, **Journal of Geopersia**, 1, 2, pp. 1-10.

[38]- Ghiasi-Freez, J., Kadkhodaie-Ilkhchi, A. and Ziaii, M., (2012), “The application of committee machine with intelligent systems to the prediction of permeability from petrographic image analysis and well logs data: a case study from the South Pars gas field, South Iran”, **Journal of Petroleum Science and Technology**, 30, 20, pp. 2122-2136.

[39]- Aminah, R. and Aurijanto, M. D. B., (2015), “Estimation of nuclear magnetic resonance log parameters from well log data using a committee machine with intelligent systems”, 39th Indonesian Petroleum Association Annual Convention & Exhibition (IPA CONVEX), pp. 1841-1846 , Jakarta, Indonesia.

[40]- Tiab, D., Donaldson, E. C., (2004), “**Petrophysics: Theory and Practice of Measuring Reservoir Rock and Fluid Transport Properties**”, second edition, Gulf professional publishing, Elsevier, Burlington, Massachusetts, USA, pp. 100-105.

[41]- Schlumberger, (1998), “**Log Interpretation Principle/Applications**”, seventh printing, Schlumberger educational services, Sugar Land, Texas, USA, pp. 23-24.

[۴۲] - مطیعی، ه.، (۱۳۸۷)، "زمین‌شناسی نفت سنگ‌های کربناتی"، جلد دوم، چاپ اول، انتشارات آراین زمین، تهران، ص ۴۵۱.

[۴۳] - زارعی، س.، زاده بابتنگلی، ع. و موحد، ب.، (۱۳۸۷)، "ارزیابی تراوایی سازند دالان با استفاده از داده‌های نگار CMR، معادله‌های تجربی و مغزه در میدان گازی پارس جنوبی"، **مجله اکتشاف و تولید نفت و گاز**، شماره ۵۵، ص ۳۹-۴۴.

[۴۴] - آغاجریان، م.، کمالی، م. ر.، کدخدایی، ع. و فتح‌اللهی، ص.، (۱۳۹۰)، "تخمین تراوایی و تخلخل موثر و تعیین واحدهای جریان هیدرولیکی با استفاده از شبکه عصبی مصنوعی در میدان نفتی مارون"، **پانزدهمین همایش انجمن زمین‌شناسی ایران**، ص ۸-۱، دانشگاه تربیت معلم.

[۴۵] - زارعی، س.، موحد، ب.، محمد باقری، ع. و مردانی، ع. ر.، (۱۳۸۶)، "ارزیابی تراوایی سازند کنگان با استفاده از داده‌های نگار CMR و مغزه در میدان پارس جنوبی"، **بیست و ششمین گردهمایی علوم زمین**، ص ۷-۱، سازمان زمین‌شناسی و اکتشافات معدنی کشور.

[۴۶] - کردی، م.، مصطفائی، ک. و احمدی، الف.، (۱۳۹۱)، "مروری بر کاربردها و ابزارهای تشدید مغناطیسی هسته (NMR) در چاه پیمایی و عوامل موثر بر اندازه‌گیری آن"، **چهارمین کنفرانس مهندسی معدن ایران**، ص ۶-۱، دانشگاه تهران.

[۴۷] - دهقان‌زاده، م.، بهلولی، ب. و رضایی، م. ر.، (۱۳۸۴)، "مقایسه تخلخل و تراوایی حاصل از نمودار NMR با تخلخل و تراوایی مغزه در یکی از چاه‌های میدان پارس جنوبی"، **بیست و چهارمین گردهمایی علوم زمین**، ص ۸-۱، سازمان زمین‌شناسی و اکتشافات معدنی کشور.

[۴۸] - خلیفه، ش. و کدخدایی، ع.، (۱۳۹۳)، "تخمین تراوایی با کمک لاگ‌های NMR و مقایسه با داده‌های مغزه در سازند فهلان در یکی از میدان‌های کربناته در جنوب ایران"، **همایش ملی زمین‌شناسی و اکتشاف منابع**، ص ۳۰-۱، مرکز همایش‌های عملی همایش نگار، شیراز.

[۴۹]- قیاسی فریز، ج.، (۱۳۸۹)، پایان‌نامه ارشد: "تخمین تخلخل سنگ مخزن از آنالیز تصاویر مقاطع نازک و مقایسه نتایج به دست آمده با سایر روش های پتروفیزیکی"، دانشکده مهندسی معدن، نفت و ژئوفیزیک، دانشگاه صنعتی شاهرود.

[۵۰]- بهلولی، ب.، حق‌زاده، ر. و حسنی، ع.، (۱۳۸۷)، "تعیین پارامترهای پتروفیزیکی در میدان سراجیه قم"، **مجله علوم دانشگاه تهران**، شماره ۲، ص ۶۴-۵۵.

[۵۱]- محمدپور، الف. و رضایی، م. ر.، (۱۳۸۳)، "مقایسه نتایج حاصل از تخمین تراوایی سازند با استفاده از شبکه‌های عصبی مصنوعی و روش آنالیز رگرسیونی"، اولین کنفرانس مهندسی معدن ایران، ص ۱۳-۱، دانشگاه تربیت مدرس.

[۵۲]- روستایی، س.، شکرانه، ف.، رحیم پور بناب، ح. و کدخدایی ایلخچی، ع.، (۱۳۸۸)، "تخمین تراوایی توسط تکنیک منطق فازی و روش های آماری در میدان گاز پارس جنوبی"، **مجله اکتشاف و تولید نفت و گاز**، شماره ۵۹، ص ۴۵-۴۱.

[۵۳]- دهداری، ح. و میاحی، ن.، (۱۳۹۰)، "کاربرد شبکه عصبی مصنوعی در تخمین تراوایی یک مخزن هیدروکربوری"، **مجله اکتشاف و تولید نفت و گاز**، شماره ۸۰، ص ۵۱-۴۶.

[54]- Huang, Y., Gedeon, T. D. and Wong, P. M., (2001), "An integrated neural-fuzzy-genetic-algorithm using hyper-surface membership functions to predict permeability in petroleum reservoirs", **Journal of Engineering Applications of Artificial Intelligence**, 14, 1, pp. 15-21.

[۵۵]- نورافکن، الف.، (۱۳۹۳)، پایان‌نامه ارشد: "تخمین و مقایسه تراوایی حاصل از داده‌های لاگ با استفاده از روش الگوریتم ژنتیک و الگوریتم کلونی مورچه در میدان گازی پارس جنوبی"، پژوهشکده علوم زمین، دانشگاه شهید چمران اهواز.

- [56]- Martinez-Martinez, J., Benavente, D. and García del Cura, M. A., (2007), “Petrographic quantification of brecciated rocks by image analysis, application to the interpretation of elastic wave velocities”, **Journal of Engineering Geology**, 90, 1-2, pp. 41-54.
- [57]- Ehrlich, R., Crabtree, S. J., Horkowitz, K. O. and Horkowitz, J. P., (1991), “Petrography and reservoir physics I: Objective classification of reservoir porosity (1)”, **Journal of AAPG Bulletin**, 75, 10, pp. 1547-1562.
- [58]- Marmo, R., Amodio, S., Tagliaferri, R., Ferreri, V. and Longo, G., (2005), “Textural identification of carbonate rocks by image processing and neural network: Methodology proposal and examples”, **Journal of Computers & Geosciences**, 31, 5, pp. 649-659.
- [59]- Ghiasi-Freez, J., Soleimanpour, I., Kadkhodaie-Ilkhchi, A., Ziaii, M., Sedighi, M. and Hatampour, A., (2012), “Semi-automated porosity identification from thin section images using image analysis and intelligent discriminant classifiers”, **Journal of Computers & Geosciences**, 45, pp. 36-45.
- [60]- Ghiasi-Freez, J., Honarmand-Fard, S. and Ziaii, M., (2014), “The automated dunham classification of carbonate rocks through image processing and an intelligent model”, **Journal of Petroleum Science and Technology**, 32, 1, pp. 100-107.
- [61]- Ghiasi-Freez, J., Ziaii, M., Kadkhodaie-Ilkhchi, A. and Honarmand, J., (2014), “A reservoir rock porosity estimation through image analysis and fuzzy logic techniques”, **Journal of Energy Sources, Part A: Recovery, Utilization, and Environmental Effects**, 36, 12, pp. 1276-1284.
- [62]- Suhaimi, A. A., (2016), MSc thesis: “Pore characterizations and distributions within Niagaran–lower Salina reef complex reservoirs in the Silurian Northern Niagaran Pinnacle Reef Trend, Michigan basin”, Geoscience department, Western Michigan University, pp. 1-198.
- [63]- Gonzalez, R. C. and Woods, R. E., (2006), “**Digital Image Processing**”, Third edition, Prentice hall publishing, Pearson education, Upper Saddle River, New Jersey, USA, pp. 465-468.

[64]- Theodoridis, S. and. Koutroumbas, K., (2003), "**Pattern Recognition**", Second edition, Academic press, Elsevier, San Diego, California, USA, pp. 3-8.

[65]- Ljung, L., (2001), "Black-box models from input-output measurements", In Instrumentation and Measurement Technology Conference (IMTC 2001), pp. 138-146, Budapest, Hungary.

[۶۶]- سعدی، م.، بهجت، ی. و صادقزاده اهری، ج.، (۱۳۹۴)، "معرفی جعبه‌ابزارهای تخصصی

نرم‌افزار **Matlab**"، چاپ اول، انتشارات پژوهشگاه صنعت نفت، تهران، ص ۱۲۰-۹۳.

[۶۷]- منهای، م. ب.، (۱۳۸۱)، "مبانی شبکه‌های عصبی هوش محاسباتی"، جلد اول، چاپ دوم،

انتشارات دانشگاه صنعتی امیر کبیر، تهران، ص ۲۱۶.

[68]- Hudson Beale, M., Hagan, M. T. and Demuth, H. B., (2017), "**Matlab user's Guide: Neural Network Toolbox**", Mathwork Inc., Natick, MA, USA, pp. 2-3.

[69]- Hagan, M. T., Demuth, H. B. and Beale, M. H., (1996), "**Neural Network Design**", PWS Publishing Company, Boston, USA, pp. 2.

[70]- Mohaghegh, S., (2000), "Virtual-intelligence applications in petroleum engineering: part 1—artificial neural networks", **Journal of Petroleum Technology**, 52, 09, pp. 64-73.

[71]- Svozil, D., Kvasnicka, V. and Pospichal, J., (1997), "Introduction to multi-layer feed-forward neural networks", **Journal of Chemometrics and intelligent laboratory systems**, 39, 1, pp. 43-62.

[72]- Duda, R. O., Hart, P. E. and Stork, D. G., (2001), "**Pattern Classification**", Second Edition, John Wiley & Sons Inc., New York, USA, pp. 284-295.

[73]- Levenberg, K., (1944), "A method for the solution of certain non-linear problems in least squares", **Journal of Quarterly of applied mathematics**, 2, 2, pp. 164-168.

[74]- Marquardt, D. W., (1963), "An algorithm for least-squares estimation of nonlinear parameters", **Journal of the society for Industrial and Applied Mathematics**, 11, 2, pp. 431-441.

[75]- Saad, Y., (2003), "**Iterative Methods For Sparse Linear Systems**", second edition, Society for Industrial and Applied Mathematics, Philadelphia, Pennsylvania, USA, pp. 187-190.

[۷۶]- مسیبی، ف.، (۱۳۹۳)، "پیاده‌سازی روش گرادیان مزدوج با کارایی بالا به کمک زبان آزاد محاسباتی روی پردازنده‌های گرافیکی"، نشریه علمی پژوهشی روش‌های عددی در مهندسی، دوره ۳۳، شماره ۱، ص ۱-۱۳.

[77]- Deng, L. and Yu, D., (2014), "Deep learning: methods and applications", **Journal of Foundations and Trends in Signal Processing**, 7, 3-4, pp. 198-201.

[78]- Hinton, G. E., Osindero, S. and Teh, Y. W., (2006), "A fast learning algorithm for deep belief nets", **Journal of Neural computation**, 18, 7, pp. 1527-1554.

[79]- Schmidhuber, J., (2015), "Deep learning in neural networks: An overview", **Journal of Neural networks**, 61, pp. 85-117.

[80]- Rumelhart, D. E., Hinton, G. E., and Williams, R. J., (1986), "Learning internal representations by error propagation", pp. 533-536, In: "**Parallel Distributed Processing-Explorations in the Microstructure of Cognition: Foundations**", Vol. 1, Rumelhart, D. E. and McClelland, J. L., MIT Press, Cambridge, MA, USA.

[81]- Bengio, Y., (2009), "Learning deep architectures for AI", **Foundations and trends in Machine Learning**, 2, 1, pp. 1-127.

[82]- NG, A., Ngiam, J., Foo, C. Y., Mai, Y., and Suen, C., (2010), UFLDL Tutorial: Unsupervised Feature Learning and Deep Learning.

[83]- Baldi, P., (2011), "Autoencoders, unsupervised learning, and deep architectures", ICML-2011 Workshop on Unsupervised and Transfer Learning, pp. 37-49, Bellevue, Washington, USA.

[84]- Arnold, L., Rebecchi, S., Chevallier, S. and Paugam-Moisy, H., (2011), "An introduction to deep learning", 19th European Symposium on Artificial Neural Networks (ESANN 2011), pp. 477-488, Bruges, Belgium.

- [85]- Bengio, Y., Lamblin, P., Popovici, D. and Larochelle, H., (2006), “Greedy layer-wise training of deep networks”, 20th Annual Conference on Neural Information Processing Systems (NIPS 2006), pp. 153-160, Vancouver, Canada, USA.
- [86]- Chen, Y., Lin, Z., Zhao, X., Wang, G. and Gu, Y., (2014), “Deep learning-based classification of hyperspectral data”, **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, 7, 6, pp. 2094-2107.
- [87]- Santara, A., Maji, D., Tejas, D. P., Mitra, P. and Gupta, A., (2015), “Faster learning of deep stacked autoencoders on multi-core systems using synchronized layer-wise pre-training”, European Conference on Machine Learning and Principles and Practices of Knowledge Discovery in Databases (ECML/PKDD 2015): Workshop on Parallel and Distributed Computing for Knowledge Discovery in Data Bases (PDCKDD 2015), pp. 1-12, Porto, Portugal.
- [88]- Vareka, L. and Mautner, P., (2017), “Stacked autoencoders for the P300 component detection”, **Journal of Frontiers in Neuroscience**, 11, pp. 1-9.
- [89]- Zadeh, L. A., (1965), “Fuzzy sets”, **Journal of Information and control**, 8, 3, pp. 338-353.
- [90]- Sivanandam, S. N., Sumathi, S. and Deepa, S. N., (2007), “**Introduction to fuzzy logic using MATLAB**”, Vol. 1, Springer publishing, Berlin, Germany, pp. 73-76.
- [91]- Ying, H., (2000), “**Fuzzy control and modeling: analytical foundations and applications**”, IEEE Press, New York, USA, pp. 310.
- [92]- Mamdani, E. H. and Assilian, S., (1975), “An experiment in linguistic synthesis with a fuzzy logic controller”, **International Journal of Man-machine Studies**, 7, 1, pp. 1-13.
- [93]- Takagi, T. and Sugeno, M., (1985), “Fuzzy identification of systems and its applications to modeling and control”, **Journal of IEEE Transactions on Systems, Man, and Cybernetics**, SMC-15, 1, pp. 116-132.
- [94]- Kadkhodaie-Ilkhchi, A., Rahimpour-Bonab, H. and Rezaee, M., (2009), “A committee machine with intelligent systems for estimation of total organic carbon content

from petrophysical data: an example from Kangan and Dalan reservoirs in South Pars Gas Field, Iran”, **Journal of Computers & Geosciences**, 35, 3, pp. 459-474.

[95]- Asoodeh, M. and Bagheripour, P., (2012), “Prediction of compressional, shear, and stoneley wave velocities from conventional well log data using a committee machine with intelligent systems”, **Journal of Rock Mechanics and Rock Engineering**, 45, 1, pp. 45-63.

[96]- Asoodeh, M., (2013), “Prediction of Poisson's ratio from conventional well log data: a committee machine with intelligent systems approach”, **Journal of Energy Sources, Part A: Recovery, Utilization, and Environmental Effects**, 35, 10, pp. 962-975.

[97]- Hatampour, A., (2013), “Developing a committee machine model for predicting reservoir porosity from image analysis of thin sections”, **Middle-East Journal of Scientific Research**, 13, 11, pp. 1438-1444.

[98]- Rostami, A., Hatampour, A., Amiri, M., Ghiasi-Freez, J. and Heidari, M., (2014), “Developing a committee machine model for predicting reservoir porosity from image analysis of thin sections”, 20th Formation Evaluation Symposium of Japan, pp. 1-10, Chiba, Japan.

[99]- Chen, C. H. and Lin, Z. S., (2006), “A committee machine with empirical formulas for permeability prediction”, **Journal of Computers & Geosciences**, 32, 4, pp. 485-496.

[100]- Kennedy, J. and Eberhart, R., (1995), “Particle swarm optimization”, 1995 IEEE International Conference on Neural networks, pp. 1942-1948, University of Western Australia, Perth, Western Australia.

[101]- Shi, Y. and Eberhart, R., (1998), “A modified particle swarm optimizer”, 1998 IEEE International Conference on Evolutionary Computation-IEEE World Congress on Computational Intelligence (WCCI98), pp. 69-73, William Egan civic and convention center, Anchorage, Alaska, USA.

[102]- Shi, Y. and Eberhart, R. C., (1999), “Empirical study of particle swarm optimization”, 1999 Congress on Evolutionary Computation (CEC99), pp. 1945-1950, Mayflower hotel, Washington D.C., USA.

- [103]- Poli, R., Kennedy, J. and Blackwell, T., (2007), "Particle swarm optimization", **Journal of Swarm intelligence**, 1, 1, pp. 33-57.
- [104]- Eberhart, R. C. and Hu, X., (1999), "Human tremor analysis using particle swarm optimization", 1999 Congress on Evolutionary Computation (CEC99), pp. 1927-1930, Mayflower hotel, Washington D.C., USA.
- [105]- Laskari, E. C., Parsopoulos, K. E. and Vrahatis, M. N., (2002), "Particle swarm optimization for minimax problems", 2002 Congress on Evolutionary Computation (CEC'02), pp. 1576-1581, Hilton Hawaiian Village hotel, Honolulu, Hawaii, USA.
- [106]- Coello, C. A. C., Pulido, G. T. and Lechuga, M. S., (2004), "Handling multiple objectives with particle swarm optimization", **Journal of IEEE Transactions on Evolutionary Computation**, 8, 3, pp. 256-279.
- [107]- Krusienski, D. J. and Jenkins, W. K., (2004), "A particle swarm optimization-least mean squares algorithm for adaptive filtering", 38th Asilomar Conference on Signals, Systems and Computers, pp. 241-245, Asilomar Grounds, Pacific Grove, California, USA.
- [108]- Yan, X., Zhang, C., Luo, W., Li, W., Chen, W. and Liu, H., (2012), "Solve traveling salesman problem using particle swarm optimization algorithm", **International Journal of Computer Science**, 9, pp. 264-271.
- [109]- Kung, C. C. and Chen, K. Y., (2013), "Missile guidance algorithm design using particle swarm optimization", **Journal of Applied Mechanics and Materials**, 284, pp. 2411-2415.
- [110]- Matlab user's Guide, (2017), "**Global Optimization Toolbox**", Mathwork Inc., Natick, MA, USA, pp. 6.
- [111]- Patnaik, S. S. and Panda, A. K., (2012), "Particle swarm optimization and bacterial foraging optimization techniques for optimal current harmonic mitigation by employing active power filter", **Journal of Applied Computational Intelligence and Soft Computing**, 2012, 1, pp. 1-10.

[112]- Chiu, S. L., (1994), "Fuzzy model identification based on cluster estimation", **Journal of Intelligent & Fuzzy Systems**, 2, 3, pp. 267-278.

[113]- Al-Ajmi, F. A. and Holditch, S. A., (2001), "NMR permeability calibration using a non-parametric algorithm and data from a formation in Central Arabia", SPE Middle East Oil Show, pp. 1-9, Manama, Bahrain.

[۱۱۴]- فضلی، ل. و باقری، ح.، (۱۳۹۲)، "مرجع آموزش نرم افزار ژئولاگ: ارزیابی پتروفیزیکی

مخازن هیدروکربوری به روش قطعی و احتمالی"، چاپ اول، انتشارات ستایش، تهران، ص ۶۱.

[115]- Stutzman, P. E., (2001), "Scanning electron microscopy in concrete petrography", Workshop on the Role of Calcium Hydroxide in Concrete, pp. 59-72, Anna Maria island, Florida, USA.

Abstract

Properties of reservoir play a significant role in management and development of hydrocarbon reservoirs. Permeability is the ability of porous rock to transmit fluids and one of the most important properties of reservoir rock, because hydrocarbon production depends on reservoir permeability. This parameter can be measured at the laboratory utilizing air injection analysis, or by using well test. These methods are expensive and time consuming. In recent years, the capabilities of intelligent systems and image analysis has been proven by development of hardware and software of computer. Therefore, image analysis and intelligent systems has been used for permeability prediction to reduce time and money. The current study includes two main parts.

In the first part, the permeability was predicted from petrographic image analysis and intelligent systems. The thin sections of well A in south pars gas field were used. Petrographic image analysis was employed to measure the types of porosity including intergranular, intragranular, moldic, micro and optical, amount of cement, calcite, dolomite and anhydrite, type of texture and mean geometrical shape coefficient of pores. Three intelligent systems including shallow neural network (NN), fuzzy logic (FL) and neuro fuzzy (NF) were used to predict permeability.

The permeability was predicted using the three individual intelligent systems and petrographic features. The mean squared error (MSE) of the NN, FL and NF methods in the normalized test data are 0.0107, 0.0081 and 0.0080, respectively. The mean absolute error (MAE) of the NN, FL and NF methods in the real test data are 11.54, 11.17 and 10.85 mD, which correspond to the R values of 0.9397, 0.9588 and 0.9558, respectively.

The concept of committee machine was used to improve the accuracy of prediction. Hence, two types of committee machine with intelligent systems (CMIS) were used to combine the predicted values of permeability from the individual intelligent systems: simple averaging (SA) and weighted averaging (WA). In the weighted averaging, a particle swarm optimization (PSO) was employed to obtain the optimal contribution of each intelligent system. The MSE of CMIS-SA and CMIS-WA in the normalized test data are 0.0072 and 0.0066, respectively. The MAE of CMIS-SA and CMIS-WA in the real test data are 9.03 and 8.94 mD, which correspond to the R values of 0.9623 and 0.9622, respectively.

Comparing the results of the first step with core data, shows that petrographic image analysis and intelligent systems were successfully applied in permeability prediction. Among the intelligent systems, the committee machine with intelligent systems obtained the most accurate results.

In the second part, the NMR permeability was compared with the results of the first step. The NMR permeability of well A was unavailable. Therefore, a deep neural network was constructed with the information of well B including GR, NPHI, PEF and RHOB logs as inputs and NMR permeability as output. The MSE of the deep neural network in the normalized training data are 0.0020. This model was used for prediction of NMR permeability in well A. So, the information of well A including GR, NPHI, PEF and RHOB logs were input to the model and NMR permeability was predicted. The core permeability and predicted NMR permeability versus depth were plotted and the correlation coefficient was calculated. The R value of 0.9767 shows that the predicted NMR permeability have a good correlation with core permeability. So, the predicted permeability from image analysis and intelligent systems were compared with predicted NMR permeability.

Comparing the results of the first step with predicted NMR permeability, shows that the integration of petrographic data and intelligent systems performed well.

Keywords: permeability, petrographic image analysis, intelligent systems, committee machine, deep neural network, NMR permeability



Shahrood University of Technology
Faculty of Mining, Petroleum and Geophysics Engineering

Master of Science in Petroleum Exploration Engineering

**Reservoir Rock Permeability Assessment Using Image Analysis and Results of
NMR Log In the South of Iran**

By: Mahnaz Abedini

Supervisor:

Dr. Mansour Ziaii

Advisor:

Javad Ghiasi-Freez

September 2017