



بررسی اهمیت و کاربرد شبکه‌های عصبی مصنوعی در مطالعات مهندسی نفت.

افشین تاتار^۱، مصیب کمری^۲

دانشگاه صنعتی سهند

Afshin.Tatar@gmail.com

چکیده

شبکه‌های عصبی مصنوعی یکی از شاخه‌های هوش مصنوعی است که الهام گرفته از سیستم عصبی انسان می‌باشد. این شیوه در برابر مجموعه داده‌های غیر خطی و پیچیده بهتر از روش‌های رگرسیون کلاسیک و دیگر روش‌های آماری عمل می‌کند. ابتدا قسمتی از داده‌ها برای آموزش شبکه استفاده می‌شود و پس از اینکه شبکه با الگوی حاکم بر آن‌ها آشنا شد، با کمک قسمت دیگر داده‌ها مورد آزمون قرار می‌گیرد. اخیراً در بسیاری از رشته‌های مهندسی، در برخورد با مسائل مربوط به مدل سازی، تشخیص الگو و تخمین پارامترها، از این ابزار بهره گرفته می‌شود. در این مطالعه، برخی از مهم‌ترین کاربردهای شبکه‌های عصبی مصنوعی در مهندسی نفت بررسی شده است که از آن جمله می‌توان به کاربرد آن در مسائل مختلف از جمله پیش‌بینی تخلخل و تراوایی سازند، طراحی شکاف هیدرولیکی، جریان دوفازی در خطوط لوله، تخمین پارامترهای سیال، دبی چاه، میزان بازیافت نفت، رسوب آسفالتین، توصیف سازند، ساخت نمودارهای مصنوعی پتروفیزیکی و نیز لایه‌بندی مخزن اشاره کرد. همچنین برخی از تحقیقات مهم انجام شده در این ارتباط به عنوان نمونه معرفی شده‌اند.

واژه‌های کلیدی: شبکه‌های عصبی مصنوعی، مهندسی نفت، پیش‌بینی، چاه پیمایی، داده‌های مغزه

^۱ کارشناسی ارشد مهندسی مخازن هیدروکربوری، دانشگاه صنعتی سهند

^۲ کارشناسی ارشد مهندسی مخازن هیدروکربوری، شرکت ملی مناطق نفت‌خیز جنوب، ارزیابی مخازن



۱- مقدمه

شبکه‌های عصبی مصنوعی به عنوان زیر شاخه‌ای از هوش مصنوعی که از الگوی عملکرد مغز انسان الهام گرفته است، در چند دهه گذشته بسط و توسعه داده شده است. در دهه اخیر، استفاده از آن به عنوان یک ابزار دقیق و توانمند در حل مسائل پیچیده و غیرخطی که حل آن‌ها با روش‌های متداول کلاسیک دشوار بود، گسترش یافته و جایگاه خود را در علوم مهندسی پیدا کرد. در این میان، مهندسی نفت نیز فرصت را غنیمت شمرده و از این ابزار برای تحلیل مسایل مربوط به صنعت نفت و گاز بهره‌مند شده‌اند. کاربردهای بسیار زیادی از شبکه‌های عصبی در مهندسی نفت و گاز وجود دارد که بخشی از آن شامل توسعه میادین، تفسیر مدل‌های چاه‌آزمایی، بررسی تکمیل چاه، پیش‌بینی آسیب سازند، پیش‌بینی نفوذپذیری سنگ مخزن، مخازن شکافدار، جریان دو فاز در خط لوله، افت فشار و گرادیان دما در خطوط لوله و... می‌شود که به همراه پیشینه تحقیقات مربوط، در ادامه مورد بررسی قرار می‌گیرند [1].

۱-۱ تخمین تخلخل

تخلخل یکی از پارامترهای کلیدی در ارزیابی سازند است. شناخت و ارزیابی پارامترهای پتروفیزیکی مخازن هیدروکربوری مانند تخلخل، با استفاده از داده‌های چاه‌پیمایی همواره با خطاهای گوناگون همراه است و عوامل مختلف، دقت این روش‌ها را پایین می‌آورند. به علاوه نمی‌توان در تمامی چاه‌های حفاری شده به منظور اندازه‌گیری این پارامترها، عملیات مغزه‌گیری انجام داد؛ لذا سعی می‌شود تا با تلفیق نمودارهای مختلف چاه‌پیمایی دقت برآورد پارامترهای پتروفیزیکی را افزایش داد. از طرف دیگر، تکنیک‌های جدید چاه‌پیمایی برای تعیین تخلخل سازند به طور دقیق ایجاد شده است. یکی از روش‌های برآورد تخلخل و دیگر پارامترهای مخزن به کمک اطلاعات چاه‌پیمایی، استفاده از شبکه‌های عصبی مصنوعی است. با استفاده از این روش می‌توان به کمک داده‌های رقومی چاه‌پیمایی به عنوان پارامترهای ورودی شبکه، ارتباطی مناسب بین این داده‌ها و پارامترهای پتروفیزیکی به دست آمده از مغزه^۱ برقرار کرد و در موارد فاقد مغزه در مخزن، با استفاده از شبکه آموزش دیده، پارامترهای پتروفیزیکی را برآورد نمود [۲].

سوتو و همکارانش^۲ روش شبکه عصبی پس‌انتشار^۳ با چهار لایه را برای تخمین تراوایی و تخلخل از داده‌های لاگ^۴ مطرح کردند [۳]. لیم و همکارانش^۵ از شبکه‌های عصبی، جهت طبقه‌بندی رخساره سنگ و تخمین تراوایی و تخلخل استفاده کرده‌اند [۴، ۵]. همداء^۶ و همکارش با استفاده از دو شبکه عصبی مجزا از اندازه‌گیری‌های چاه‌آزمایی، تخمینی از تخلخل سازند و اشباع آب^۷ مخزن سنگ رسی به دست آوردند که نتایج نسبتاً رضایت‌بخشی داشته است [۶].

۱-۲ تخمین تراوایی

تراوایی یکی از مهم‌ترین ویژگی‌های سازندهای هیدروکربوری و همچنین یکی از مهم‌ترین اطلاعات مورد نیاز در طراحی و مدیریت عملیات‌های ازدیاد برداشت است. محاسبه دقیق تراوایی سازند، امروزه یکی از چالش‌های مهندسان نفت است. با اطلاع از میزان دقیق تراوایی، مهندسان نفت می‌توانند فرآیندهای تولید از یک میدان را به طور مطلوب مدیریت کنند. اگرچه تراوایی سازند معمولاً در آزمایشگاه و از آزمایشات مغزه اندازه‌گیری می‌شود، اما مغزه‌گیری پرهزینه بوده و تنها برای تعداد و یا بازه‌های محدودی از چاه‌های یک میدان انجام می‌شود [۵-۱۱].

¹ Core

² Soto et al.

³ Back Propagation

⁴ Log


⁵ Lim and Kim

⁶ Elshafei and Hamada

⁷ Water Saturation



داشتن مقادیر نمونه برای تراوایی در موقعیت‌های مکانی مختلف، به خصوص در جایی که چاه‌های تولیدی یا تزریقی حفر شده‌اند، می‌تواند در مطالعات شبیه‌سازی مخزن به صورت مطلوبی مفید واقع شود. یک روش رایج دیگر برای به‌دست آوردن تراوایی مخزن، از طریق چاه‌آزمایی است. عملیات چاه‌آزمایی به دو دلیل پرهزینه است؛ یکی به دلیل انجام تست‌ها و دیگری از دست دادن تولید در بازه تست چاه؛ به همین دلیل فقط بعضی از تست‌ها در هر میدانی قابل اجراست. تخمین تراوایی سازند برای چاه‌های بدون مغزه، از طریق رسم نمودار تراوایی بر حسب تخلخل برای چندین چاه و ارائه یک رابطه، تقریباً کار غیرممکنی است. در مخازن با ناهمگنی زیاد، روابط به‌دست آمده هیچ گونه اعتباری نخواهند داشت. نمودار تخلخل بر حسب تراوایی برای یک چاه نمونه است. پراکندگی این نمودار، صحت مطلب ذکر شده را برای مخازن ناهمگن نشان می‌دهد. اگر چه می‌دانیم که تراوایی وابسته به تخلخل است، اما یک رابطه غیر خطی و پیچیده با تخلخل دارد. به دلیل اینکه عوامل دیگری در تراوایی سازند (علاوه بر تخلخل) سهیم هستند. رسم تخلخل بر حسب تراوایی و انجام رگرسیون، تخمین نامناسبی خواهد بود [۱۱].



شکل ۱. نمونه‌ای از رابطه بین تخلخل و تراوایی برای انجام رگرسیون [۱۱].

شبکه‌های عصبی مصنوعی، روش‌های پردازش اطلاعات موازی^۱، توزیع یافته^۲، آنالوگ^۳ و غیر الگوریتمی^۴ هستند که به عنوان یک ابزار قوی در تشخیص الگوهای پیچیده به کار می‌روند. به این دلیل که شبکه‌های عصبی، عملیات پردازش داده را به صورت موازی و توزیع شده انجام می‌دهند، قادر خواهند بود که روابط بسیار پیچیده بین چندین متغیر را که به شبکه ارائه شده‌اند کشف نمایند [۱۱]. در تحقیقی که توسط محقق و همکاران در سال ۱۹۹۵ انجام گرفته است، از شبکه‌های عصبی مصنوعی برای تخمین تراوایی سازند به وسیله داده‌های فراهم شده از لاگ‌های چاه‌پیمایی بهره گرفته شده است. در گذشته، بسیاری سعی کرده‌اند که برای تخمین تراوایی از این نمودارها استفاده کنند. مسائل حل شده با این داده‌ها دو مشکل داشت؛ یکی تعداد محدود متغیرها (تنها متغیر تخلخل) و دیگری استفاده از آنالیز رگرسیون به عنوان اصلی‌ترین ابزار برای ارتباط. در این تحقیق، با استفاده از لاگ‌های چاه‌پیمایی، تعداد متغیرهای وابسته را افزایش داده‌اند. شبکه‌های عصبی یک سیستم ذاتاً

¹ Parallel


² Distributive

³ Analog

⁴ Nonalgorithmic



موازی هستند که این مسأله آن‌ها را قادر می‌سازد تا در تخمین تراوایی سازند از داده‌های چاه‌پیمایی، موفق عمل کنند. در تحقیق مذکور، از شبکه عصبی پس انتشار تغذیه پیشرو^۱ استفاده شده است. در طول طراحی و توسعه شبکه عصبی برای این تحقیق، از یک شبکه با سه لایه و ۱۵ نرون در لایه پنهان (میانی) استفاده شده است. در طول آموزش، شبکه به صورت پیوسته تلاش می‌کند که خودش را تصحیح کند و به حداقل خطای ممکن برای مثال‌هایی که در معرض آن‌ها قرار گرفته است، دست یابد. نتایج نشان می‌دهد که تخمین عصبی تراوایی سازند با استفاده از داده‌های چاه‌پیمایی، یک شیوه کاربردی است و نیز در دسترس بودن داده مغزه قابل اطمینان برای فرایند آموزش و دانش کافی روی تئوری‌های مبنا و همچنین تمرین روی شبکه‌های عصبی برای دستیابی به نتایج مطلوب الزامی است [۱۱].




شکل ۲. مقادیر اندازه‌گیری شده تراوایی در آزمایشگاه در قیاس با مقادیر پیش‌بینی شده توسط شبکه‌های عصبی توسعه داده شده [۱۱].

۳-۱ شکاف هیدرولیکی

نظریه‌های متعددی راجع به طراحی بهینه شکاف هیدرولیکی وجود دارد. تاکنون مدل‌های دو و سه بعدی برای طراحی و نظارت شکاف استفاده شده است. استفاده از این مدل‌ها، مستلزم داشتن اطلاعات تفصیلی و کافی درباره ویژگی‌ها و مکانیک سنگ مخزن است. به دست آوردن این اطلاعات، به دلیل ناهمگن بودن یا هزینه‌های زیاد، دشوار به نظر می‌رسد. یک شرکت گازی در شمال شرقی اوهایو، عملیات حفر ۷۶۲ چاه ذخیره‌ای را در سازند Clinton-Medina انجام داد. همه چاه‌ها، به وسیله شکاف هیدرولیکی تحریک شدند. تعیین دقیق ویژگی‌های سنگ و مخزن Clinton برای طراحی شکاف هیدرولیکی به دلیل ناهمگنی و شکاف‌های طبیعی، کار بسیار سختی بود لذا از یک شبکه عصبی برای بهینه سازی طراحی شکاف و پیش‌بینی عملکرد چاه از اطلاعات چاه‌های یک ناحیه جغرافیایی نزدیک با چندین شکاف هیدرولیکی، استفاده شد. پیش‌بینی موفق چنین مسائلی برای هر شرکتی پر منفعت خواهد بود، زیرا باعث کاهش هزینه ایجاد شکاف‌هایی که افزایشی در تولید در پی ندارد، می‌شود. ارزش چنین پیش‌بینی‌های دقیقی، زمانی بهتر فهمیده می‌شود که اطلاعات کافی برای محاسبات و طراحی مهندسی شکاف‌دهی وجود نداشته باشد. تخمین عملکرد چاه شکاف دهی شده را به وسیله شبکه‌های عصبی در مقابل نتایج واقعی نشان می‌دهد. لازم به ذکر است که Q100 معیار عملکرد چاهی است که به وسیله شرکت استفاده شده است [۱۲].

¹ Feed-Forward Back Propagation




شکل ۳. مقایسه پیش‌بینی شبکه عصبی با عملکرد واقعی چاه شکافدار [۱۲].

۱-۴ جریان دو فازی در خطوط لوله

یکی دیگر از کاربردهای شبکه‌های عصبی، استفاده از آن‌ها در تعیین پارامترهای خطوط لوله دو فاز است. میزان انباشتگی مایع^۱، الگوی جریان^۲ و فشار پایین دستی^۳ سه پارامتری هستند که در تحقیقات مربوط به این زمینه، مورد ارزیابی قرار گرفته‌اند. حرکت هم‌زمان مایع و گاز در کنار یکدیگر و لزوم تعیین پارامترهای دو فاز در حل مسائل مکانیک سیالاتی مانند افت فشار، منجر به پیچیدگی مسأله می‌شود؛ لذا هر یک از پارامترهای فوق تابعی از خصوصیات دیگری مانند قطر لوله، ضخامت آن، دما، فشار، سرعت نفت و گاز و خصوصیات ترمودینامیکی سیالات خواهند بود [۱۳].

در یکی از کامل‌ترین کارهای انجام گرفته، شپین^۴ و همکاران در سال ۲۰۰۲ به بررسی میزان انباشتگی مایع در خطوط لوله دو فاز افقی پرداخته‌اند. در این کار نیز از ساختار شبکه MLP (پرسپترون چند لایه) به عنوان یک ساختار متداول و کارا استفاده شده که در شکل ۴ نشان داده شده است [۱۳].



شکل ۴. شبکه به کار رفته در مطالعه شپین برای بررسی میزان انباشتگی مایع در خطوط لوله دو فاز افقی [۱۳].

¹ Liquid Holdup
² Flow Pattern
³ Bottom Hole Pressure
⁴ Shippen



این شبکه هفت داده ورودی را برای پیش‌بینی انباشتگی مایع به کار برده است. نویسنده اشاره کرده است که تفاوت اساسی مدل یک شبکه عصبی با مدل‌های مکانیکی متداول در این است که شبکه‌های عصبی قادرند به خوبی و با دقت بسیار داده‌های موجود را آموزش دیده و در محدوده داده‌های فوق پیش‌بینی کنند. در حالی که مدل‌های مکانیکی موجود بر اساس قوانین پایه مکانیک سیالات پایه گذاری شده‌اند تا جریان را مدل کنند و این بدین معنی است که اگر چه آن‌ها دقت پایین‌تری در پیش‌بینی خود دارند ولی قابل تعمیم به همه شرایط هستند در حالی که برون‌یابی به هیچ عنوان در یک شبکه عصبی توصیه نمی‌شود. این نکته مهم باید در تمام موارد استفاده از شبکه‌های عصبی لحاظ شود [۱۳].

۵-۱ تخمین ویسکوزیته نفت خام

در مهندسی نفت، توصیف خواص سیالات مخزن نقش مهمی را در توسعه استراتژیک عملیات و مدیریت مخزن دارد. ویسکوزیته (گرانروی) یکی از این ویژگی‌هاست که معمولاً از آنالیز آزمایشگاهی نمونه‌های سیال مخزن به دست می‌آید. برای حل مسأله اندازه‌گیری ویسکوزیته از آزمایشگاه که زمان‌بر و هزینه‌بردار است، معادلات حالت و روابط تجربی برای پیش‌بینی ویژگی‌های سیال توسعه داده شده‌اند. یکی از عمومی‌ترین روش‌هایی که بر مبنای محاسبات نرم افزاری است، روش شبکه‌های عصبی مصنوعی است [۱۴].

حیدری و همکاران برای اندازه‌گیری ویسکوزیته نفت خام برای سه حالت، ویسکوزیته نفت اشباع، ویسکوزیته در بالای نقطه حباب و ویسکوزیته در زیر فشار اشباع اقدام کردند و با استفاده از مدل Khan و روش گوی غلتان، ویسکوزیته را تخمین زدند. سپس با استفاده از این داده‌ها، یک شبکه عصبی پس انتشار آموزش داده شد. با آموزش شبکه، می‌توان ویسکوزیته را بدون استفاده از مدل Khan و شرایط آزمایشگاهی، تحت هر شرایط دیگری با دقت قابل قبولی تخمین زد. نتایج نشان می‌دهد که این شبکه عصبی توانایی بالایی در تخمین ویسکوزیته نفت خام دارد [۱۵].

۶-۱ پیش‌بینی دبی چاه

فراوش و همکاران آزمایشاتی روی نمونه‌های مغزه از جنس ماسه‌سنگ، جهت بررسی حرکت سیالات در مخازن شکافدار و تحت شرایط تنش مختلف انجام دادند. از این داده‌ها جهت بررسی کار آیی شبکه‌های عصبی و مقایسه نتایج آن با نتایج آزمایشگاهی استفاده شده است [۱۶]. در این روش از چهار پارامتر فشار، اختلاف فشار دو سر مغزه، نوع مغزه از لحاظ ترک‌دار بودن و میزان تراوایی، به عنوان داده‌های ورودی و مقادیر دبی پ به عنوان خروجی استفاده شدند. با روش سعی و خطا مشخص شد که وقتی از چهار نرون لایه میانی استفاده شود، خطای شبکه به حداقل می‌رسد. [۱۶].

در این بررسی دبی محاسبه شده توسط شبکه عصبی در پنج مورد از شش سری داده‌های تست شبکه، قابل قبول بوده، ولی در یکی از موارد دارای خطا بود. خطا در اندازه‌گیری داده‌ها در این مورد خاص و یا عدم دقت شبکه که ناشی از ناکافی بودن داده‌های آموزش است، علت این انحراف عنوان شده است [۱۶].

۷-۱ تخمین میزان بازیافت نفت طی فرایند آشام

فرایند آشام یکی از مهم‌ترین روش‌های بازیافت نفت از مخازن آب‌دوست است. در این فرایند سیال نفت که غیر ترک‌کننده است، توسط سیال آب که ترک‌کننده است، در محیط متخلخل جابه‌جا می‌شود. تعیین میزان بازیافت نفت در فرایند آشام، از طریق شبیه‌سازی فرایند در آزمایشگاه صورت می‌گیرد [۱۷].


فراوش و عبدی با استفاده از شبکه‌های عصبی مصنوعی و اطلاعات مربوط به چند آزمایش مغزه، میزان بازیافت برای دو نمونه مغزه حاوی نفت سبک و سنگین، تخمین زدند. برای این منظور از سه پارامتر دبی تزریق، حجم سیال تزریقی و جرم نفت درون مغزه به عنوان داده‌های ورودی و میزان بازیافت به عنوان داده خروجی استفاده شد. شبکه عصبی مورد استفاده، شبکه پس انتشار با تغذیه پیشرو است که شامل یک لایه پنهان است. به روش سعی و خطا مشخص شد که با سه نرون لایه میانی، خطای شبکه به حداقل می‌رسد [۱۷].

۸-۱ تخمین رسوب آسفالتین در نفت خام



اجزای آلی سنگین و مرکب رسوبات آسفالتینی، باعث ایجاد مشکلات زیادی در تولید نفت خام می‌شوند. رسوب مواد جامد در اطراف تفکیک کننده‌ها^۱، پمپ‌ها، تانکرها و دیگر ابزارها به ویژه لوله‌های درون چاه، باعث افزایش قابل توجه هزینه‌های تولید می‌شود. برخی از اثرات جانبی مختلف رسوب آسفالتین از جمله: تغییر ناگهانی pH، اختلاط جریان‌های نفت خام، ناسازگاری مواد شیمیایی آلی، تحریک^۲ و افزایش افت فشار، شناخته شده است. جهت جلوگیری از رسوب آسفالتین، مدلی دقیق برای پیش‌بینی مقدار و شرایط رسوب مورد نیاز است. زاهدی و همکاران با استفاده از داده‌های حاصل از شش نمونه نفت خام، مدل شبکه عصبی را برای تخمین میزان رسوب آسفالتین مطرح کرده‌اند [۱۸].

در پدیده رسوب آسفالتین، نوع حلال، نسبت حلال به نفت، فشار، دما و ترکیب نفت، تأثیر زیادی بر رسوب دارند. زاهدی و همکاران، اندازه‌گیری‌های تجربی را در دمای محیط و فشار اتمسفر انجام دادند. در این مدل، آن‌ها از آموزش پس انتشار با یک لایه پنهان استفاده کردند. همچنین از توابع انتقالی Logistic Sigmoid و Purelin برای طراحی شبکه عصبی استفاده کردند. هر یک از شبکه‌ها با داده‌ها آموزش دیده و با بقیه آن‌ها تست شدند. در این پژوهش، ساختارهای مختلف شبکه‌های عصبی با الگوریتم‌های آموزشی متفاوت، مورد آزمایش قرار گرفته است. ترسیم پراکنده در شکل ۵، مقایسه‌ای بین داده‌های آزمایشگاهی با داده‌های به‌دست آمده از شبکه عصبی که در قسمت آموزشی آن استفاده نشده (داده‌های تست شبکه) انجام گرفته است. چنانچه مشاهده می‌شود، نتایج حاصل از مدل شبکه عصبی به داده‌های آزمایشگاهی بسیار نزدیک است [۱۸].



شکل ۵. ترسیم پراکنده داده‌های به‌دست آزمایشگاهی (درصد وزنی) نسبت به مقادیر پیش‌بینی شده توسط شبکه [۱۸].

۹-۱ تخمین خواص PVT نفت خام

خواص سیالات مخزن در محاسبات مهندسی نفت مثل محاسبات موازنه جرم، آنالیز تست چاه، تخمین ذخیره مخزن، محاسبات عملکرد جریان درون چاهی و شبیه‌سازی عددی مخازن، حائز اهمیت است. به طور ایده‌آل، این خصوصیات باید از اندازه‌گیری‌های واقعی به‌دست آیند. با این وجود، این اندازه‌گیری‌ها یا در دسترس نیستند یا بسیار هزینه بردار است. در بعضی از موارد، روابط تجربی برای پیش‌بینی خواص مورد نیاز استفاده می‌شوند. بنابراین، تمامی محاسبات به دقت رابطه به کار برده شده برای تخمین خواص سیال بستگی دارد [۱۹-۲۱].

¹ Separators

² Stimulation



روابط تجربی زیادی برای پیش‌بینی خواص PVT وجود دارد که اکثر آن‌ها با استفاده از رگرسیون خطی یا غیرخطی و یا تکنیک‌های گرافیکی توسعه داده شده‌اند. هر رابطه برای یک ناحیه جغرافیایی و یک محدوده مشخصی از خواص سیال مخزن با ترکیب و گراویته API یکسان ارائه شده است [۲۱].

عثمان و همکاران از یک مدل شبکه عصبی مصنوعی برای پیش‌بینی فاکتور حجمی سازند در فشار حباب بهره گرفتند. این مدل با استفاده از ۸۰۳ داده منتشر شده از میدان‌های خاورمیانه، مالزی، کلمبیا و خلیج مکزیک توسعه داده شده است. نصف داده‌ها برای آموزش مدل‌های شبکه عصبی مصنوعی، یک چهارم برای تصدیق روابط برقرار شده در طول فرآیند آموزش و یک چهارم باقی‌مانده برای تست مدل‌هایی که پایداری روند و دقتشان استفاده شد. نتایج نشان داد که این مدل، پیش‌بینی‌های بهتر و دقیق‌تری نسبت به روابط تجربی فراهم می‌کند. مدل ارائه شده در این مقاله، پیش‌بینی‌های B_{ob}^1 را در فشار حباب با خطای مطلق ۱/۷۸۹ درصد و انحراف استاندارد ۲/۲۰۵۳ و ضریب همبستگی ۰/۹۸۸ به دست آورد. تست‌های حساسیت‌سنجی برای بررسی رفتار مقادیر پیش‌بینی شده B_{ob} برای هر تغییر در دمای مخزن، GOR، گراویته گاز و گراویته نفت نیز انجام شد [۲۱].

نتایج آماری جهت‌مقایسه در جدول ۱ ارائه شده است. مدل ارائه شده، بیشترین دقت را در پیش‌بینی مقادیر B_{ob} ، کوچک‌ترین خطای مینیمم، کوچک‌ترین خطای ریشه دوم میانگین حسابی و بزرگ‌ترین ضریب همبستگی را بین دیگر روابط به دست آورد [۲۱].

جدول ۱. نتایج آماری روابط تجربی مختلف در قیاس با شبکه عصبی [۲۱].

Correlations	R
Standing	۰/۹۷۴۲
Vazquez & Beggs	۰/۹۸۴۲
Glaso	۰/۹۷۱۵
Al-Marhoun (1988)	۰/۹۸۱۱
Al-Marhoun (1992)	۰/۹۸۰۶
ANN	۰/۹۸۷۸

غربی و همکاران، مدل‌های مبنا یافته بر اساس شبکه عصبی برای تخمین ویژگی‌های PVT نمونه‌های نفت خام را ارائه کردند. داده‌هایی که به شبکه آموزش داده شد، شامل ۵۲۰۰ مجموعه داده PVT از سراسر دنیا است. این داده‌ها از میدان‌های نفتی در شمال و جنوب آمریکا، دریای شمال، آسیای جنوب شرقی، خاورمیانه و آفریقا جمع آوری شدند [۲۲].

این مدل شبکه عصبی توسعه یافته، قادر به پیش‌بینی نسبت گاز به نفت و فاکتور حجمی سازند به عنوان تابعی از فشار نقطه حباب، دانسیته نسبی گاز، وزن مخصوص نفت و دمای مخزن است. این مقاله نشان می‌دهد که یک شبکه عصبی مصنوعی که به صورت موفق‌آمیز آموزش داده شده است، ابزار پیش‌بینی قابل اطمینانی است که می‌تواند ویژگی‌های PVT را بهتر از روابط موجود تخمین بزند. این مدل‌های PVT شبکه عصبی را می‌توان در شبیه‌سازی‌های مخزنی و نرم افزار بهینه‌سازی تولید جای داد. همان طور که در این تحقیق نشان داده شده، مدل شبکه‌های عصبی در قیاس با دیگر روابط، از دقت بسیار بالایی برخوردارند. مدل شبکه عصبی مصنوعی برای پیش‌بینی P_b دارای ضریب همبستگی ۹۶ درصد، و برای B_{ob} ، ۹۸/۸۹ درصد بوده است. ضریب همبستگی تخمین P_b برای دیگر روش‌ها در محدوده ۶۸/۵۸ درصد برای Al-Marhoun و

¹ Oil volume factor in bubble pint



۹۳/۱۱ Farshad می‌باشد. برای Bob، محدوده مقادیر از ۹۴/۷۲ درصد برای رابطه Glas تا ۹۸/۲۴ برای رابطه Kartoatmodjo است [۲۲].

۱-۱۰ توصیف سازند مخزن

توصیف ناهمگنی مخزن و تعیین پارامترهای پتروفیزیکی، یکی از مسائل کلیدی در ارزیابی مخزن با استفاده از لاگ‌های چاه‌پیمایی است. توصیف ناهمگنی ساختمان مخزن، نیازمند مطالعات منظم داده‌ها با استفاده از تعداد زیادی اندازه‌گیری‌های عددی زمین‌شناسی و ژئوفیزیکی و همچنین ارزیابی دقیق دقت داده‌های به‌دست آمده است. یک جنبه دیگر ارزیابی هر اندازه‌گیری، برآورد کیفیت و کنترل کیفیت داده‌هاست [۲۳-۲۶].

هاروی و همکاران در یک تحقیق، از شبکه‌های عصبی برای تشخیص ناهمگنی در سازندهای پیچیده و ارزیابی مرزهای تولیدی استفاده کردند. آن‌ها برای انجام تحقیق خود از دو چاه بهره‌گرفتند و همچنین از تحلیل‌های آماری چند متغیره در ابتدا برای گروه‌بندی پارامترهای پتروفیزیکی، ژئوفیزیکی و زمین‌شناسی، که از اندازه‌گیری‌های مناطق مختلف زیر چاهی استخراج شده، استفاده کردند. نتایج حاصل از این تکنیک‌ها، مبنای مفیدی برای مقایسه با شبکه عصبی است. یک شبکه عصبی مصنوعی، برای توصیف رخساره‌های مختلف حاضر در هر چاه مورد استفاده قرار گرفت. بسته به موفقیت پاسخ یک روش، تکنیک‌های زیادی برای توصیف مخزن وجود دارند. این تحقیق، پاسخ‌های بعضی از تکنیک‌های آماری را که دارای موفقیت قابل ملاحظه‌ای در توصیف مخزن هستند، با نتایج گرفته شده از شبکه عصبی مصنوعی مقایسه می‌کند. یکی از اهداف این تحقیق یافتن روش‌های تعیین رخساره‌ها در محیط‌های مختلف زمین‌شناسی است. با افزایش تعداد منحنی‌های لاگ، میزان اطلاعات وابسته به مخزن افزایش می‌یابد و تصویری واقعی از طبیعت مخزن به‌دست می‌آید. توصیف ریخت‌شناسی که به وسیله تکنیک‌های آماری و شبکه عصبی گرفته شد، نتایج بسیار خوبی را نشان می‌دهد. در هر دو چاه، اختلافات بین نتایج گرفته شده به وسیله هر تکنیک و دسته‌بندی داده‌های جمع‌آوری شده به وسیله تشریح مغزه، بیش از ۷ درصد نیست. شبکه عصبی نتایج نسبتاً بهتری را برای هر دو چاه با خطاهای ۲/۸۷ و ۴/۸۴ درصد نشان داد. در حالی که این خطاها برای تکنیک‌های آماری ۶/۲۷ و ۲۲/۶۳ درصد بودند [۲۵].

۱-۱۱ کسب اطلاعات سرعت صوت در لایه‌ها

اگر به هر دلیلی اطلاعات چاه‌پیمایی ناقص باشند، چه باید کرد؟ در یکی از مطالعات انجام شده توسط آربوگاست و فرانکلین^۱ (۱۹۹۹)، از ۴۵ حلقه چاه یک منطقه، فقط چهار حلقه از آن‌ها نمودار صوتی داشتند و برای مطالعات آنالیز سرعت که در عملیات لرزه‌ای کاربرد دارد، به اطلاعات بقیه چاه‌ها نیاز بود. برای حل این مشکل از تکنیک شبکه‌های عصبی کمک گرفته شد. به این ترتیب که داده‌های سرعت درون این چهار چاه به داده‌های نمودار گاما و مقاومت آن‌ها نسبت داده و سپس در بقیه چاه‌ها که همگی دارای این نمودار بودند، یک نمودار صوتی مصنوعی ساخته شد [۲۷].

۱-۱۲ تعیین نواحی مختلف در یک مخزن پیچیده

یکی از مسائل کلیدی در تشریح و توصیف سازندهای ناهمگن، توزیع نواحی مختلف و ویژگی‌های آن‌ها است. این نواحی در مخازن نفتی معمولاً روی حرکت، توزیع و تولید هیدروکربن‌ها اثر می‌گذارند. بنابراین تشخیص زون‌ها، دلایل اقتصادی در مدیریت مخزن را دارد. توصیف مخزن بدون تخمین دقیق از اینکه زون‌ها چگونه در مخزن توزیع شده‌اند، در واقع امکان پذیر نیست. تخمین و تعیین این نواحی، نیازمند جمع‌آوری و تفسیر اطلاعات مهندسی و زمین‌شناسی مختلف می‌باشد [۲۸].

در یک تحقیق که توسط وایت^۲ و همکاران انجام شد، به بررسی انجام‌پذیر بودن استفاده از شبکه عصبی مصنوعی به عنوان یک ابزار برای تشخیص و تعیین نواحی مختلف در یک مخزن ناهمگن با استفاده از لاگ‌های ژئوفیزیکی در سازند Big Injun در میدان Granny Creek پرداخته‌اند. شبکه عصبی استفاده شده در این تحقیق را می‌توان با به‌کارگیری همه

¹ Arbogast and Franklin

² White



داده‌های موجود برای آموزش، که نتایج دقیق‌تری را فراهم می‌کند، توسعه داد. نتایجی که وایت و همکاران به آن رسیدند، به شرح زیر است [۲۸]:

۱. به کارگیری شبکه عصبی مصنوعی برای تعیین لایه‌بندی در مخازن ناهمگن امکان‌پذیر است.
 ۲. شبکه توسعه یافته قادر است ریخت‌شناسی، چینه‌شناسی و زون‌بندی را در میدان Granny Creek با استفاده از داده‌های چاه‌پیمایی به‌دست آورد.
 ۳. پیش‌بینی‌های شبکه عصبی، حضور یک زون گذرا در سازند Big Injun در میدان Granny Creek را تایید کرد [۲۸].
- کاربردهای بسیار زیاد دیگری از شبکه‌های عصبی در مهندسی نفت و گاز وجود دارد که شامل توسعه میداین [۲۹]، تفسیر مدل‌های چاه‌آزمایی [۳۰-۳۲]، بررسی تکمیل چاه [۳۳]، پیش‌بینی آسیب سازند [۳۴]، پیش‌بینی نفوذپذیری سنگ مخزن [۱۰]، مخازن شکافدار [۳۵، ۳۶]، جریان دو فاز در خطوط لوله [۱۳، ۳۷-۳۹]، افت فشار و گرادیان دما در خطوط لوله [۴۰] و... می‌شود.

مراجع

۱. مجله مهندسی شیمی ایران شماره بیست و دوم، ۱۳۸۵، شبکه‌های عصبی؛ ابزاری دقیق در حل مسائل مهندسی نفت، et al محمدی.
۲. Cruz, L.G., et al., *Application of an Artificial Neural Network (ANN) for the Correction of NMR Total Porosity, Effective Porosity, and the Bulk Volume Irreducible Water Data Obtained From a Heavy-Oil Reservoir Using an Oil-Based-Mud Drilling Fluid in the Samaria: Tertiary Reservoir in Southeastern Mexico*, in *SPE Latin American and Caribbean Petroleum Engineering Conference* 2010: Lima, Peru.
۳. Soto B., R., et al., *Use of Neural Networks to Predict the Permeability and Porosity of Zone "C" of the Cantagallo Field in Colombia*, in *SPE Petroleum Computer Conference* 1997: Dallas, Texas.
۴. Lim, J.-S. and J. Kim, *Reservoir Porosity and Permeability Estimation from Well Logs using Fuzzy Logic and Neural Networks*, in *SPE Asia Pacific Oil and Gas Conference and Exhibition* 2004: Perth, Australia.
۵. Lim, J.-S., H.-j. Park, and J. Kim, *A New Neural Network Approach to Reservoir Permeability Estimation from Well Logs*, in *SPE Asia Pacific Oil & Gas Conference and Exhibition* 2006: Adelaide, Australia.
۶. Hamada, G.M. and M.A. Elshafei, *Neural Network Prediction of Porosity and Permeability of Heterogeneous Gas Sand Reservoirs*, in *SPE Saudi Arabia Section Technical Symposium* 2009: AlKhobar, Saudi Arabia.
۷. Kharrat, R., et al., *Rock type and permeability prediction of a heterogeneous carbonate reservoir using artificial neural networks based on Flow Zone Index approach*, in *SPE Middle East Oil and Gas Show and Conference* 2009: Bahrain, Bahrain.
۸. Naeeni, M.N., et al., *Permeability Prediction of Un-cored Intervals Using New IMLR Method and Artificial Neural Networks: A Case Study of Bangestan Field, Iran*, in *Nigeria Annual International Conference and Exhibition* 2010: Tinapa - Calabar, Nigeria.
۹. Singh, S., *Permeability Prediction Using Artificial Neural Network (ANN): A Case Study of Uinta Basin*. 2005.
۱۰. Wong, P.M., D.J. Henderson, and L.J. Brooks, *Permeability Determination Using Neural Networks in the Ravva Field, Offshore India*. SPE Reservoir Evaluation & Engineering, 1998. 1(2).
۱۱. Mohaghegh, S., et al., *Design and Development of An Artificial Neural Network for Estimation of Formation Permeability*. SPE Computer Applications, 1995. 7(6).
۱۲. Mohaghegh, S. and S. Ameri, *Artificial Neural Network As A Valuable Tool For Petroleum Engineers*. Society of Petroleum Engineers, 1995.
۱۳. Shippen, M.E. and S.L. Scott, *A Neural Network Model for Prediction of Liquid Holdup in Two-Phase Horizontal Flow*, in *SPE Annual Technical Conference and Exhibition* 2002: San Antonio, Texas.
۱۴. Oloso, M., et al., *Prediction of Crude Oil Viscosity and Gas/Oil Ratio Curves Using Recent Advances to Neural Networks*, in *SPE/EAGE Reservoir Characterization and Simulation Conference* : ۲۰۰۹ Abu Dhabi, UAE.
۱۵. اولین همایش ملی نفت، گاز و پتروشیمی، ۱۳۸۸، تخمین لزجت نفت خام با استفاده از هوش مصنوعی، et al حبیبی.
۱۶. داود، کاربرد شبکه‌های عصبی پس‌انتشار جهت تخمین پارامترهای مخزن. پایگاه مقالات فارسی مهندسی نفت (پتروگروپ)، ۱۳۸۶ and فراوش.
۱۷. بررسی عملکرد مواد فعال‌کننده سطحی در ازدیاد برداشت میکروبی نفت با استفاده از شبکه‌های عصبی و منطق فازی. انجمن ال‌تبیگی، ک. سیستم‌های فازی ایران، دانشگاه فردوسی مشهد، ایران.
۱۸. Zahedi, G., et al., *Prediction of asphaltene precipitation in crude oil*. Journal of Petroleum Science and Engineering, 2009.
۱۹. Al-Marhoun, M.A. and E.A. Osman, *Using Artificial Neural Networks to Develop New PVT Correlations for Saudi Crude Oils*, in *Abu Dhabi International Petroleum Exhibition and Conference* 2002: Abu Dhabi, United Arab Emirates.
۲۰. Goda, H.M., et al., *Prediction of the PVT Data using Neural Network Computing Theory*, in *Nigeria Annual International Conference and Exhibition* 2003: Abuja, Nigeria.



۲۱. Osman, E.A., O.A. Abdel-Wahhab, and M.A. Al-Marhoun, *Prediction of Oil PVT Properties Using Neural Networks*, in *SPE Middle East Oil Show*2001: Bahrain.
۲۲. Gharbi, R.B. and A.M. Elsharkawy, *Universal Neural Network Based Model for Estimating The PVT Properties of Crude Oil Systems*, in *SPE Asia Pacific Oil and Gas Conference and Exhibition*1997: Kuala Lumpur, Malaysia.
۲۳. Ahmed, T., et al., *Application of Neural Network Parameter Prediction in Reservoir Characterization and Simulation - A Case History: The Rabbit Hills Field* Society of Petroleum Engineers, 1۹۹۷,
۲۴. Aminian, K., et al., *A New Approach for Reservoir Characterization*, in *SPE Eastern Regional Meeting*2002: Lexington, Kentucky.
۲۵. Gonçalves, C.A., P.K. Harvey, and M.A. Lovell, *APPLICATION OF A MULTILAYER NEURAL NETWORK AND STATISTICAL TECHNIQUES IN FORMATION CHARACTERISATION*, in *SPWLA 1995*, Society of Petrophysicists & Well Log Analysts.
۲۶. Mohaghegh, S.D., et al., *Reservoir Characterization Through Synthetic Logs*, in *SPE Eastern Regional Meeting*2000: Morgantown, West Virginia.
۲۷. Arbogast, J.S. and M.H. Franklin, *Artificial neural networks and high-speed resistivity modeling software speed reservoir characterization*. Journal Name: Petroleum Engineer International; Journal Volume: 72; Journal Issue: 6; Other Information: PBD: Jun 1999, 1999; p .Medium: X; Size: pp. 39-42.
۲۸. White, A.C., et al., *The Application of ANN for Zone Identification in a Complex Reservoir*, in *SPE Eastern Regional Meeting*1995: Morgantown, West Virginia.
۲۹. Doraisamy, H., T. Ertekin, and A.S. Grader, *Key Parameters Controlling the Performance of Neuro-Simulation Applications in Field Development*, in *SPE Eastern Regional Meeting*1998: Pittsburgh, Pennsylvania.
۳۰. Al-Kaabi, A.U. and W.J. Lee, *An Artificial Neural Network Approach To Identify the Well Test Interpretation Model: Applications*, in *SPE Annual Technical Conference and Exhibition*1990: New Orleans, Louisiana.
۳۱. Juniardi, I.R. and I. Ershaghi, *Complexities of Using Neural Network in Well Test Analysis of Faulted Reservoirs*, in *SPE Western Regional Meeting*1993 :Anchorage, Alaska.
۳۲. Sung, W., et al., *Development of the HT-BP Neural Network System for the Identification of a Well-Test Interpretation Model*. SPE Computer Applications, 1996. 8(4.)
۳۳. Shelley, R.F., et al., *Refork Completion Analysis with the Aid of Artificial Neural Networks*, in *SPE Rocky Mountain Regional/Low-Permeability Reservoirs Symposium*1998: Denver, Colorado.
۳۴. Nikravesh, M., et al., *Prediction of Formation Damage During Fluid Injection into Fractured, Low Permeability Reservoirs via Neural Networks*, in *SPE Formation Damage Control Symposium*1996: Lafayette, Louisiana.
۳۵. Ouenes, A., et al., *Practical use of Neural networks in Tight Gas Fractured Reservoirs: Application to the San Juan Basin*, in *SPE Rocky Mountain Regional/Low-Permeability Reservoirs Symposium*1998: Denver, Colorado.
۳۶. Zellou, A.M., A. Ouenes, and A.K. Banik, *Improved Fractured Reservoir Characterization Using Neural Networks, Geomechanics and 3-D Seismic*, in *SPE Annual Technical Conference and Exhibition*1995: Dallas, Texas.
۳۷. Osman, E.-S.A., *Artificial Neural Networks Models for Identifying Flow Regimes and Predicting Liquid Holdup in Horizontal Multiphase Flow*, in *SPE Middle East Oil Show*2001: Bahrain.
۳۸. Osman, E.-S.A., *Artificial Neural Network Models for Identifying Flow Regimes and Predicting Liquid Holdup in Horizontal Multiphase Flow*. SPE Production & Operations, 2004. 19(1.)
۳۹. Ternyik, I., J., et al., *Virtual Measurement in Pipes: Part 1-Flowing Bottom Hole Pressure Under Multi-Phase Flow and Inclined Wellbore Conditions*, in *SPE Eastern Regional Meeting*1995: Morgantown, West Virginia.
۴۰. Osman, E.-S.A., M.A. Ayoub, and M.A. Aggour, *An Artificial Neural Network Model for Predicting Bottomhole Flowing Pressure in Vertical Multiphase Flow*, in *SPE Middle East Oil and Gas Show and Conference*2005: Kingdom of Bahrain.



Investigation of Importance and Applications of Artificial Neural Networks in Petroleum Industry

Afshin Tatar¹, Mosayeb Kamari²

Sahand University of Technology

Afshin.Tatar@gmail.com

Abstract

Artificial Neural Network is a branch of artificial intelligence that is inspired from human neural system. In dealing with non-linear and complex data, this method shows better performance than classic regression and other statistical methods. First, part of the data is used for training the network and after the recognition the governing pattern, the network is tested by the other part of the data. Recently, in various fields of engineering, this method is used in dealing with modeling, pattern recognition, and parameter prediction problems. In this study, some important applications of artificial neural networks in petroleum industry are investigated, such as formation porosity and permeability prediction, hydraulic fracture design, two-phase flow in pipe lines, prediction of fluid parameters, well flow rate, oil recovery, asphaltene deposition, formation description, developing petrophysical synthetic logs, and reservoir zonation. Furthermore, some important studies in this regard are presented in the following study.

Keywords: Artificial Neural Networks, Petroleum Engineering, Prediction, Well Log, Core Data

¹ M.Sc of petroleum reservoir engineering, Sahad University of Technology

² M.Sc of petroleum reservoir engineering, National Iranian South Oil Company (NISOC), Reservoir evaluation department