

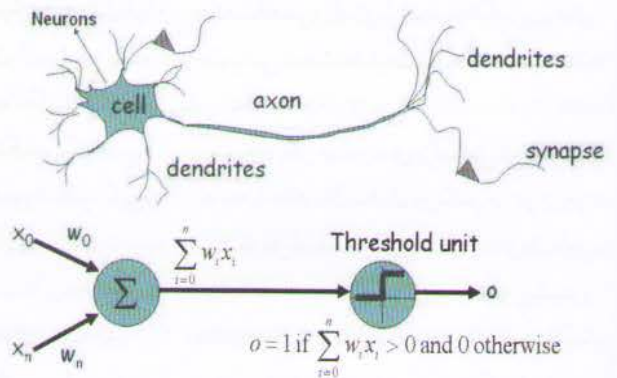
کاربرد شبکه های عصبی مصنوعی در مهندسی نفت

چکیده

استفاده از شبکه های عصبی در شاخه های مختلف مهندسی روز به روز در حال افزایش است، به طوری که امروزه آگاهی از نحوه عملکرد و استفاده از آن برای مهندسين امری ضروری به نظر می رسد. این مقاله ضمن معرفی ساختار و چگونگی کارکرد شبکه های عصبی، به برخی از کاربردهای آن در مهندسی نفت اشاره خواهد کرد. شبکه های عصبی مصنوعی وسایلی پردازشگری هستند که به صورت خیلی ابتدایی بر اساس ساختار عصبی مغز پستانداران اما در مقیاس خیلی کوچکتر مدل سازی شده اند. این وسایل قادرند مسایلی را که راه حل الگوریتمیک بسیار پیچیده ای دارند، با دقت بیشتری نسبت به روش های متداول حل کنند. در مهندسی نفت از شبکه های عصبی در زمینه های مختلفی از قبیل پیش بینی میزان نفوذپذیری سازند، تعیین رفتار PVT نفت خام و تفسیر لاگ، استفاده شده است.

مقدمه

تصور کنید که شما به عنوان یک مهندس نفت بر روی اندازه گیری میزان نفوذپذیری (Permeability) سنگ های مخازن نفتی کار می کنید. فرض کنید که اطلاعاتی از قبیل تخلخل، جنس دانه، نوع سیال پرکننده حفرات، محیط رسوبی و فشار منفذی را در مورد چند نمونه سنگ مخزن که توسط مغزه گیری (coreing) به دست آمده است در اختیار دارید. از طرفی میزان نفوذپذیری این چند نمونه را هم به روش آزمایشگاهی محاسبه کرده اید. حال شما این اطلاعات و میزان نفوذپذیری را به یک برنامه کامپیوتری می دهید. شما هیچ اطلاعی در مورد نحوه تاثیر این اطلاعات (پارامترها) بر مقدار نفوذپذیری سنگ مخزن ندارید. برنامه مذکور مدتی فکر می کند، داده های سیستم شما را تجزیه و تحلیل می کند، روابط پیچیده بین پارامترها را یافته و مدل ریاضی آنها را می سازد، به طوری که شما می توانید از این به بعد اطلاعات مربوط به یک نمونه سنگ جدید را به برنامه داده و برنامه به راحتی میزان نفوذپذیری آن را به شما



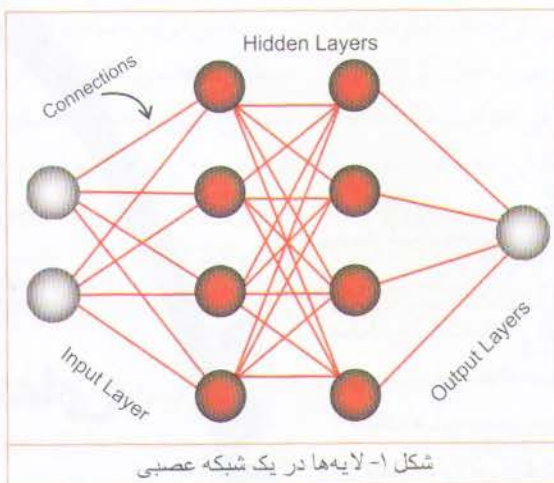
- علی امین زاده، کارشناس امور پژوهش و توسعه شرکت مهندسی

و توسعه نفت

- مهران سرمد، دانشجوی رشته مهندسی شیمی دانشگاه امیرکبیر

بدهد. این عمل، اساس کار شبکه‌های عصبی مصنوعی (Artificial Neural Network=ANN) است.

شبکه‌های عصبی مصنوعی در واقع از ساختار پیچیده مغز پستانداران الهام گرفته شده‌اند که در آنها میلیون‌ها سلول عصبی از طریق ارتباطاتی که با یکدیگر دارند به حل مسایل یا ذخیره‌سازی اطلاعات می‌پردازند.



وظیفه شبکه‌های عصبی یادگیری است، تقریباً چیزی شبیه یادگیری یک کودک خردسال. در این شبکه‌ها یادگیری از طریق کسب تجربه به کمک مثال انجام می‌شود. بدین معنا که اغلب (و نه همواره) مجموعه‌ای از ورودی‌ها و خروجی‌های درست به شبکه عصبی داده می‌شود و شبکه عصبی با استفاده از این مثال‌ها مدل ریاضی پیچیده‌ای می‌سازد که در صورت دادن ورودی‌های جدید، پاسخ‌های درستی را تولید می‌کند.

نحوه مدل‌سازی شبکه عصبی
شبکه‌های عصبی از تعدادی لایه تشکیل شده‌اند. اطلاعات از طریق لایه ورودی به شبکه وارد می‌شوند. لایه میانی یا مخفی (Hidden Layer) که ممکن است تعداد آن بیش از یکی باشد، بسته به نوع مساله شامل نرون‌هایی (گره‌هایی) است که وظیفه مهم برقراری ارتباط بین ورودی و خروجی را برعهده دارند. عمل پردازش در این لایه (لایه‌ها) از طریق سیستم ارتباطات وزنی صورت می‌گیرد. وزن‌های ارتباطی، قدرت (ارزش) خود را متناسب با اهمیت اطلاعاتی که از هر نرون می‌آید، مشخص می‌کنند. به بیان دیگر اطلاعات

نظارت (Supervised) و بدون نظارت (Unsupervised) تقسیم‌بندی می‌شوند.

در یادگیری تحت نظارت، یک معلم وجود دارد که در مرحله یادگیری به شبکه می‌گوید چقدر خوب کار می‌کند (تقویت یادگیری) یا می‌گوید که رفتار صحیح چه باید باشد (یادگیری کاملاً نظارتی). در یادگیری بدون نظارت شبکه خودکار عمل

می‌کند. شبکه در این حالت فقط به داده‌هایی که به آن داده می‌شود نگاه می‌کند، سپس بعضی از ویژگی‌های مجموعه داده‌ها را پیدا کرده و یاد می‌گیرد که این ویژگی‌ها را در خروجی خود منعکس کند. این که این خصوصیات دقیقاً چه هستند، به مدل خاص شبکه و روش یادگیری بستگی دارد.

بیشتر کاربردهای شبکه‌های عصبی در صنعت نفت و گاز بر اساس الگوریتم‌های آموزشی تحت نظارت پایه‌گذاری شده است.

نوع دیگر طبقه‌بندی بر اساس توپولوژی یا نحوه اتصال سلول به یکدیگر در داخل شبکه می‌باشد. این طبقه‌بندی شامل شبکه‌های با تغذیه پیشرو (Feed-Forward Networks) و شبکه‌های با تغذیه برگشتی (Feed-Backward Networks) است.

در حالت تغذیه پیشرو یک ورودی وجود دارد که اطلاعات را دریافت می‌کند. تعدادی لایه مخفی وجود دارند که اطلاعات را از لایه‌های قبلی می‌گیرند و در نهایت یک لایه خروجی وجود دارد که نتیجه محاسبات به آن می‌رود و جواب‌ها در آن قرار می‌گیرند. هر سلول در هر لایه به کلیه سلول‌های لایه مجاور

موجود، در این وزن‌ها کدبندی می‌شود. دانش شبکه عصبی در وزن‌های ارتباطی آن ذخیره می‌گردد و در نهایت پاسخ به لایه خارجی فرستاده می‌شود. (شکل ۱)

به هر سلول عصبی یک گره گفته می‌شود. تعداد گره‌های لایه ورودی به تعداد ورودی‌ها و تعداد گره‌های لایه خروجی بستگی به پیشگویی مورد نظر ما دارد. مثلاً اگر قرار است شبکه مثبت یا منفی بودن نتیجه یک آزمایش را مشخص کند، وجود یک گره در لایه خروجی کافی خواهد بود، اما اگر قرار است گروه خونی بیمار را پیشگویی کند، به تعداد گروه‌های خونی مورد نظر، گره خواهیم داشت.

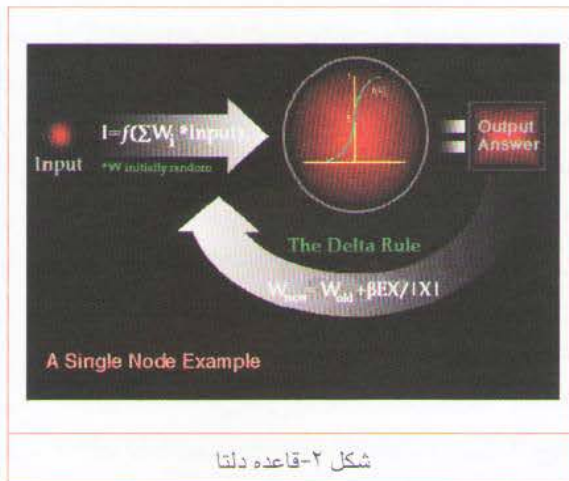
قواعد یادگیری شبکه‌های عصبی
در حال حاضر تعداد بسیار زیادی قاعده یادگیری برای شبکه‌های عصبی وجود دارد. هیچ‌کس دقیقاً تعداد آنها را نمی‌داند. انواع جدیدی نیز به‌طور مداوم ابداع می‌شوند. دانشمندان طبقه‌بندی‌های مختلفی برای شبکه‌های عصبی در اختیار ما قرار داده‌اند. یکی از این طبقه‌بندی‌ها که محبوبیت زیادی دارد بر اساس متدهای آموزشی است که طبق آن شبکه‌های عصبی به دو گروه شبکه‌های عصبی تحت

می‌شود. در این حالت مدل به دست آمده قادر خواهد بود که داده‌های مشابهی را که در مرحله یادگیری مورد استفاده قرار گرفته است دقیقاً پیش‌بینی کند، اما اگر داده جدیدی که در مرحله یادگیری استفاده نشده است به آن داده شود، سیستم عملکرد بسیار بدی خواهد داشت و خطای پیش‌بینی زیاد خواهد بود.

به منظور جلوگیری از این پدیده از روش اعتبارسنجی متقاطع (Cross Validation) استفاده می‌شود. در این تکنیک مجموعه داده‌های اولیه به سه دسته آموزش، تست و اعتبار تقسیم‌بندی می‌شوند. اعتبار شبکه همزمان با آموزش در هر دور سنجیده می‌شود و درست وقتی که خطای روی داده‌های اعتبار شروع به بالا رفتن می‌کند، آموزش شبکه قطع می‌شود.

تفاوت روش محاسباتی متداول با روش محاسباتی شبکه‌های عصبی
در روش‌های معمولی، گام‌های محاسباتی از پیش تعیین شده و دارای توالی منطقی هستند. در مقایسه، ANN‌ها نه توالی دارند و نه الزاماً از پیش تعیین شده هستند. در این حالت پردازشگرهای پیچیده مرکزی وجود ندارند، بلکه تعداد زیادی پردازشگر ساده وجود دارد که کاری جز گرفتن جمع وزنی ورودی‌هایشان از دیگر پردازشگرها ندارند.

مدل‌سازی کلاسیک از نخستین قدم خطای بزرگی را مرتکب می‌شود که فقط در سیستم‌های ساده (خطی یا نزدیک به خطی) قابل صرف نظر است.



شکل ۲- قاعده دلتا

جدید مجدداً خطا خواهد داشت. بنابراین روش توزیع معکوس مجدداً دست به کار شده و وزن‌ها را طوری تغییر می‌دهد که کمترین خطا را (هم برای این نمونه و هم برای نمونه قبلی) ایجاد کند. به این ترتیب پس از خواندن تعداد نمونه کافی به ورودی شبکه، اصطلاحاً شبکه Converge یا همگرا شده، یعنی میزان خطا به حداقل مقدار خود رسیده است. این به معنای موفقیت در مرحله یادگیری است و شبکه آماده است تا برای پیشگویی به کار رود (شکل ۳). توجه به این نکته اهمیت دارد که اگر تعداد نرون‌ها و لایه‌های میانی (پنهان) مورد استفاده، بیش از حد معمول باشد، سیستم به جای تجزیه و تحلیل داده‌ها، آنها را حفظ می‌کند و اصطلاحاً دچار Over Training (Over Fitting Oscillation)



شکل ۳- نحوه محاسبات در روش توزیع معکوس خطا

بعدی متصل است. اتصال به خود سلول‌ها، به لایه قبلی و پرش اطلاعات در طول لایه‌ها مجاز نیست. بنابراین جریان اطلاعات همیشه از ورودی به سوی خروجی است. در حالی که در روش تغذیه برگشتی، جهت جریان یک طرفه نبوده و حالت چرخشی دارد. اغلب کاربرد شبکه‌های عصبی امروزی مربوط به توپولوژی تغذیه پیشرو است.

معرفی روش پس انتشار

وقتی یک شبکه عصبی برای اولین بار با یک الگو روبرو می‌شود، روابط بین عناصر را به صورت تصادفی حدس می‌زند، سپس بررسی می‌کند که تا چه اندازه پاسخش از واقعیت دور است و در نتیجه یک انطباق مناسب با وزن‌های ارتباطی انجام می‌دهد (کاهش خطا). معمول‌ترین روال برای کاهش این خطا، روش توزیع معکوس خطا است (Backwards Propagation of error) که در ۹۵٪ کاربردهای امروزی شبکه‌های عصبی، روش مورد استفاده به همراه توپولوژی Feed Forward است. (شکل ۲) در این روش پس از محاسبه خطای پیشگویی برای نمونه اول ورودی به

سیستم، وزن‌های سیناپسی از آخرین لایه به سوی نخستین لایه به تدریج طوری تغییر می‌کنند که خطای پیشگویی کمتر شود. در واقع BP سرشکن کردن خطا بر روی سلول‌های (گره‌های) یک لایه و نیز لایه‌های بعدی است. پس از این، اطلاعات نمونه دوم به شبکه خوانده می‌شود. مسلماً با همان وزن‌های سیناپسی نمونه

شماره ۱۵ - شهریور ۱۳۸۴

دارند. Goda در سال ۲۰۰۳ از دو شبکه عصبی مرتبط به هم برای تعیین مقادیر P_{ob} و P_b استفاده کرد. در این مطالعه، شبکه اول شامل یک لایه ورودی با چهار نرون (API, T)، دانسیته نسبی گاز و R_g دو لایه میانی هر کدام با ده نرون و یک لایه خروجی با یک نرون (P_b) می باشد. شبکه دوم که مرتبط به شبکه اول است، شامل یک لایه ورودی با پنج نرون (API, T)، دانسیته نسبی گاز، R_g و P_b پیش بینی شده توسط شبکه اول) دو لایه میانی هر کدام شامل هشت نرون و یک لایه خروجی با یک نرون (B_{ob}) می باشد.

این مطالعات نشان می دهد که شبکه های عصبی از دقت بسیار بهتری برای پیش بینی خواص PVT نفت خام نسبت به سایر روش ها برخوردارند.

تعیین میزان نفوذپذیری سازند

نفوذپذیری (Permeability) مهم ترین پارامتر تعیین کننده سنگ در میزان جریان سیالات مخزن است. به طور معمول تفسیر آنالیز مغزه (Core) و تست چاه (Well Test)، قابل اعتمادترین روش ها برای به دست آوردن میزان نفوذپذیری سازند به حساب می آیند که هر دوی این روشها بسیار پرهزینه هستند. اگرچه نمودارهای چاه (Well Log) اطلاعات با ارزشی درباره سنگ می دهند، اما ارتباط بین نفوذپذیری سنگ و پارامترهایی که می توان با استفاده از لاگ ها تعیین کرد (میزان اشعه گامای ساطع شده، مقاومت الکتریکی و چگالی سنگ) یکی از موضوعات مورد بحث در مهندسی نفت است.

دانشمندان با استفاده از ابزارهای محاسباتی متداول موجود

PVT براساس داده های به دست آمده از لایه های زمین که به راحتی اندازه گیری می شوند، پایه گذاری شده اند. این داده ها عبارتند از فشار مخزن، دمای مخزن و وزن مخصوص نفت و گاز. مطالعه دقیق این روابط نشان می دهد که آنها از دقت کافی برای تعیین خواص نفت خام، در میدان های مختلف نفتی برخوردار نیستند، زیرا معمولاً برای ایجاد این نوع روابط از داده های مناطق مشخصی استفاده شده است.

مطالعات چند سال اخیر نشان می دهد که شبکه های عصبی مصنوعی از قابلیت بسیار خوبی برای پیش بینی خواص PVT برخوردارند. اگرچه برای ایجاد این نوع شبکه ها همانند روابط تجربی PVT از داده های مناطق خاصی استفاده می شود، اما چون ANN از روش های تجربی یا آماری متداول برای محاسبات خود استفاده نمی کند، لذا فرایند پیش بینی آن محدود به یک یا چند میدان نفتی خاص نمی شود. برای مثال در ANN نیز شبیه روابط تجربی PVT، برای تعیین P_b (فشار نقطه حباب) یا B_{ob} (ضریب حجمی تشکیل نفت) فرض شده است که آنها توابعی از T (دمای مخزن) و γ_g (وزن مخصوص گاز) و R_g (نسبت گاز محلول به نفت) هستند که البته این شبکه ها تفاوت هایی نیز با هم

نخستین قدم در روش کلاسیک برای بررسی داده ها، بررسی شاخص هایی مثل میانگین، انحراف معیار و... است. از این مرحله به بعد در روش کلاسیک، کاری با تک تک نمونه ها نداریم و اهمیت فردی آنها از بین می رود. در واقع روش کلاسیک با عملی شبیه همگن کردن داده ها، پیچیدگی روابط آنها را محو می کند و به این دلیل از کشف این پیچیدگی ها باز می ماند. به این ترتیب سیستم کلاسیک در استخراج معنی از داده ها ضعیف و با بازده پایین عمل می کند و در بسیاری از موارد از کشف روابط بین داده ها ناکام می ماند.

اگر می توانستیم سیستمی داشته باشیم که با اهمیت دادن به فرد فرد داده ها آنها را تجزیه و تحلیل کند و نیز بدون پیش داوری در مورد شکل تابع هر پارامتر (خطی یا غیر خطی بدون تابع) آن را ذخیره و ارزیابی کند، چنین سیستمی می توانست نتایج بیشتری را از عمق داده ها بیرون بکشد. شبکه های عصبی مصنوعی این قابلیت را دارند و به همین خاطر بسیار مورد توجه قرار گرفته اند.

کاربردهای شبکه های عصبی مصنوعی در مطالعات نفتی تعیین خواص PVT نفت خام هنگام نبود اندازه گیری های

آزمایشگاهی برای تعیین خواص PVT نفت خام، دو روش که به طور معمول مورد استفاده قرار می گیرند عبارتند از معادله حالت (EoS) و روابط تجربی PVT. معادله حالت براساس آگاهی از جزئیات ترکیبات سیالات مخزن پایه گذاری شده است که تعیین این گونه کمیت ها بسیار گران و وقت گیر است. در حالی که روابط



و مدل پیشگویی فشار جریان ته‌چاهی در جریان عمودی چندفازی از جمله دیگر کاربردهای شبکه‌های عصبی مصنوعی در مهندسی نفت هستند.

نتیجه‌گیری

باتوجه به آنچه بیان شد، ممکن است این سوال مطرح شود که در آینده چه اتفاقی رخ خواهد داد. مثلاً آیا در ده سال آینده شبکه‌های عصبی جایگاه خاصی به عنوان یک ابزار علمی-مهندسی خواهند یافت، یا بالعکس دچار افت شده و کمتر مطرح خواهند شد؟ آنچه که می‌توان در حال حاضر به طور قطع گفت آن است که شبکه‌های عصبی به عنوان یک ابزار علمی که بتواند برای راه‌حل‌های خاص و مناسب مورد استفاده قرار بگیرد، جایگاه مهمی خواهند داشت.

باید توجه کرد که در حال حاضر اطلاعات موجود درباره نحوه عملکرد مغز بسیار محدود است و مهم‌ترین پیشرفت‌ها در شبکه‌های عصبی در آینده مطرح خواهند شد، زمانی که اطلاعات بیشتری از چگونگی عملکرد مغز و نرون‌های بیولوژیک در دست باشد.

ارتباط بین شکل ردلرزها (Trace) و رخساره‌های زمین‌شناسی روی مقاطع لرزه‌ای است که در نتیجه نقشه توزیع رخساره‌ها به دست خواهد آمد. با در دست داشتن این نقشه می‌توان مقدار تخلخل مفید و نحوه پراکندگی را در مخزن به کمک وارون‌سازی (Inversion) با دقت بیشتر و به تفکیک هر رخساره محاسبه نمود. همچنین می‌توان با ایجاد لرزه‌نگاشت‌های مصنوعی (Synthetic Seismogram) در محل چاه‌ها و نسبت دادن خواص مخزنی به آنها، توزیع این خصوصیات در کل مقطع را دنبال کرد.

تخلیص زون تولید

در یکی از مطالعات جدید، داده‌های نمودار چاه‌هایی که مغزه‌گیری شده بودند در مقابل مقدار نفت هر عمق (که از روی داده‌های مغزه به دست آمده بود) قرار گرفت و به شبکه آموزش داده شد تا بتواند در چاه‌های بدون مغزه، میزان BVO (Bulk Volume Oil) را در اعماق مختلف فقط به کمک نمودار درون‌چاهی محاسبه کند.

مثال‌های دیگر

در یک مثال دیگر مقدار اشباع‌شدگی آب در سازند ماسه‌ای حاوی شیل محاسبه شده است. البته برای این کار فرمول‌های مختلفی وجود دارد که هر کدام اشکالاتی دارند. در این مثال از داده‌های نمودارهای مقاومت، گاما، لیتودنسیته، نوترون و SP برای تعیین اشباع‌شدگی استفاده شده و ارتباط این داده‌ها به کمک تکنیک شبکه‌های عصبی به دست آمده است.

تشخیص میزان آسیب سازند (Formation Damage) ناشی از تزریق سیال

نتوانسته‌اند ارتباط منطقی بین این موارد، ایجاد کنند اما معتقدند که با استفاده از شبکه‌های عصبی می‌توان ارتباطات احتمالی موجود بین داده‌های فوق و میزان نفوذپذیری را تعیین کرد.

تسبب اطلاعات سرعت صوت در لایه‌ها

نمودارهای چاه اطلاعات مهمی از مخزن به ما می‌دهند. اما اگر به هر دلیلی این اطلاعات ناقص باشند چه باید کرد. در یکی از مطالعات انجام شده از ۴۵ چاه یک منطقه فقط ۴ حلقه از آنها نمودار صوتی داشتند و برای مطالعات آنالیز سرعت که در عملیات لرزه‌ای کاربرد دارد، به اطلاعات صوتی بقیه چاه‌ها نیاز بود [Arbogast and Franklin, 1999]. برای حل این مشکل از تکنیک شبکه‌های عصبی کمک گرفته شد. به این ترتیب که داده‌های سرعت درون این ۴ چاه به داده‌های نمودار گاما و مقاومت آنها نسبت داده و سپس در بقیه چاه‌ها که همگی دارای این دو نمودار بودند، یک نمودار صوتی مصنوعی ساخته شد.

توزیع خواص مختلف مخزن در مقاطع لرزه‌ای

یکی از علوم که به میزان زیاد از شبکه‌های عصبی مصنوعی استفاده می‌کند علم ژئوفیزیک می‌باشد. بدین ترتیب که با یافتن ارتباط میان پارامترهای لرزه‌ای و خصوصیات مخزنی سعی در تشخیص نحوه گسترش خواص مخزنی دارد. زیرا تنها در محل چاه‌هاست که داده‌های واقعی را می‌توان کسب کرد و مابین چاه‌ها آنچه موجود است فقط اطلاعاتی است که روی مقاطع لرزه‌ای قابل مشاهده است. برای مثال یکی از کاربردهای آن تعیین

منابع:

- 1- منهای، محمدباقر، ۱۳۸۱، هوش محاسباتی (جلد اول)- مبانی شبکه‌های عصبی، انتشارات دانشگاه صنعتی امیرکبیر
- 2-Arbogast, Jeff S., Franklin, Mark H., 1999, Artificial Neural Networks and high speed resistivity modeling software speed sreservoir characterization, Petroleum Engineer International, 72, 5
- 3-Goda, Hussam M., Prediction of the PVT data using Neural Network computing theory, SPE85650
- 4-Mohaghegh, S., and Ameri, S., 1995, Artificial Neural Network as a valuable tool for petroleum engineers, SPE 29220
- 5-Stergiou, Chrus, What is Neural Network, WWW.doc.ic.ac.uk