

پیش‌بینی درصد حجمی سیال و لیتولوژی ماتریکس مخزن با استفاده از شبکه عصبی و انفیس

محمد بانשי* شرکت توسعه پتروایران

چکیده

در روش‌های رایج برای یافتن درصد لیتولوژی ماتریکس و سیالات، از اطلاعات چاه‌نگاری و نتایج آزمایش‌های مغزه و هم‌چنین آزمایش‌های پتروفیزیکی استفاده می‌شود که هزینه‌های فراوانی دارد. بنابراین طراحی مدلی که قادر به پیش‌بینی درصد لیتولوژی تنها با استفاده از داده‌های چاه‌نگاری باشد، بسیار مقرون‌به‌صرفه خواهد بود. در این تحقیق با استفاده از شبکه‌های عصبی و انفیس چنین مدلی طراحی شده است. اطلاعات مربوط به حدود ۱۵۰۰ نقطه چند چاه از میدانی در جنوب ایران که توسط کارشناسان پتروفیزیک ارزیابی شده‌اند موجود است. ابتدا به کمک مدل انفیس و روش سعی و خطا بهترین نمودارها برای پیش‌بینی لیتولوژی انتخاب شدند (نمودارهای نوترون، صوتی، چگالی، گاما، پف و هدایت الکتریکی). سپس این نمودارها به‌عنوان متغیرهای ورودی به شبکه‌های تابع شعاعی و چند لایه پس‌انتشار اعمال شدند. با استفاده از توابع مختلف و با در نظر گرفتن معیارهای اعتبارسنجی نظیر کمینه مربع خطا، ضریب هم‌بستگی و نمودار مقایسه، بهترین مدل‌ها برای پیش‌بینی درصد لیتولوژی ماتریکس و سیالات مخزن با استفاده از نمودارهای چاه‌نگاری انتخاب شدند. در نهایت با توجه به نتایج حاصل از جداول و شکل‌ها، کارایی دقیق این مدل و مقرون‌به‌صرفه بودن آن به اثبات رسید.

واژگان کلیدی: انفیس، شبکه پایه شعاعی و چند لایه، لیتولوژی ماتریکس و سیالات، نمودار چاه‌نگاری

مقدمه

پیش‌بینی صحیح درصد لیتولوژی ماتریکس و سیالات سازند از مهم‌ترین نیازهای صنعت نفت می‌باشد. به دلیل غیرقابل مشاهده بودن لایه‌های زیرین، تنها راه برای به دست آوردن اطلاعات دقیق استفاده از چاه‌نگاری، نمونه‌گیری و آزمایش‌های پتروفیزیکی گران‌قیمت می‌باشد. از سویی کمبود یا غیرقطعی بودن اطلاعات باعث بروز مشکلات فراوان می‌شود و از سوی دیگر انجام تمامی آزمایش‌ها نیز وقت گیر و پرهزینه خواهد بود. بنابراین مهندسان و برنامه‌نویسان سعی در ایجاد مدلی برای کاهش این آزمایش‌ها و دست‌یابی به نتایج دقیق‌تر دارند [۱ و ۲].

یافتن ارتباط بین نمودارهای چاه‌نگاری باعث کاهش اجرای برخی از آنها در چاه‌های دیگر شده یا در صورت خرابی و ناقص بودن برخی از نمودارها، می‌توان آنها را به کمک دیگر نمودارها پیش‌بینی کرد. اگر اطلاعات نمودارگیری مربوط به چند چاه از یک میدان موجود باشد، مهندسان می‌توانند به کمک آزمایش‌های مغزه، درصد لیتولوژی و سیالات آن قسمت را به وسیله مدل‌سازی‌های نرم‌افزار ژئولاگ و اطلاعات زمین‌شناسی به دست آورند. پس از آن با یافتن رابطه بین نمودارها و لیتولوژی می‌توان بدون انجام آزمایش‌های مغزه، لیتولوژی را برای چاه‌های دیگر نیز پیش‌بینی کرد. این کار باعث صرفه‌جویی در زمان و هزینه خواهد شد.

۱- شبکه‌های عصبی مصنوعی

امروزه شبکه‌های عصبی و مجموعه‌های فازی و کاربردشان در هوش مصنوعی به‌عنوان معنی جدید فن‌آوری پیشرفته محسوب می‌شوند. شبکه‌های عصبی می‌توانند مسائلی که محاسبات معمول قادر به حل آنها نیستند را حل کنند. مهندسان نفت زمانی از این شبکه‌ها استفاده می‌کنند که داده‌های کافی برای تفسیر در اختیار نداشته باشند. یکی دیگر از دلایلی که از این شبکه‌ها استفاده می‌شود هزینه فراوان عملیات چاه‌پیمایی، چاه‌آزمایی و ... است. بنابراین استفاده از این شبکه‌ها تا حد زیادی می‌تواند از لحاظ اقتصادی مقرون‌به‌صرفه باشد.

هر شبکه از تعداد دلخواهی سلول، گره یا نرون تشکیل می‌شود که مجموعه ورودی را به خروجی ربط می‌دهند. مطالعه شبکه‌های عصبی مصنوعی از سیستم‌های یادگیری طبیعی الهام گرفته که در آنها مجموعه‌ای پیچیده از نرون‌های متصل به هم در کار یادگیری دخیل هستند. شبکه عصبی با استفاده از پردازش‌گرهایی به نام نرون تلاش می‌کند با شناخت روابط ذاتی بین داده‌ها، نگاشتی میان فضای ورودی (لایه ورودی) و فضای مطلوب (لایه خروجی) ارائه دهد. لایه یا لایه‌های مخفی، اطلاعات دریافت شده از لایه ورودی را پردازش کرده و در اختیار لایه خروجی قرار می‌دهند. هر شبکه با دریافت مثال‌هایی، آموزش می‌بیند. آموزش فرآیندی است که در نهایت منجر به یادگیری می‌شود. یادگیری زمانی

* نویسنده عهده‌دار مکاتبات (mohammadbaneshi@yahoo.com)



اتفاق می افتد که وزنهای ارتباطی بین لایه‌ها چنان تغییر کند که اختلاف مقادیر پیش‌بینی شده و محاسبه شده در حد قابل قبولی باشد. با دست‌یابی به این شرایط فرآیند یادگیری محقق می‌شود. این وزن‌ها حافظه و دانش شبکه را بیان می‌کنند. شبکه عصبی آموزش دیده می‌تواند برای پیش‌بینی خروجی‌های متناسب با مجموعه جدید داده‌ها به کار رود [۸ و ۷].

۲- مراحل تحقیق

۲-۱- جمع‌آوری اطلاعات

داده‌های موجود در این تحقیق شامل ۲۵۰۰ نقطه از چند چاه در یکی از میادین جنوبی ایران است. در هر نقطه اطلاعات مربوط به چاه‌نگاری و هم‌چنین درصد لیتولوژی که توسط کارشناسان پتروفیزیک ارزیابی

۱ | انتخاب بهترین متغیرهای ورودی با مدل انفیس

متغیرهای ورودی	متغیر خروجی	کمترین مربع خطای دسته آموزش	کمترین مربع خطای دسته آزمون	ضریب هم‌بستگی خروجی و داده واقعی
CXO & CT& DT & GR & RHOB & NPHI & PE	V. Calcite	۰/۰۰۱۱	۰/۰۰۹۴	۰/۹۳۷
CT& DT & GR & RHOB & NPHI & PE	V. calcite	۰/۰۰۱۲	۰/۰۰۸۲	۰/۹۴۵
CXO & CT& DT & GR & RHOB & NPHI & PE	V. Dolomite	۰/۰۰۱۵	۰/۰۲۰۲	۰/۸۱
CT& DT & GR & RHOB & NPHI & PE	V. dolomite	۰/۰۰۱۵	۰/۰۱۱	۰/۸۹
CXO & CT& DT & GR & RHOB & NPHI & PE	V. Illite	۰/۰۰۰۰۳۲	۰/۰۰۰۰۵۷	۰/۸۳۵
CT& DT & GR & RHOB & NPHI & PE	V. Illite	۰/۰۰۰۰۶۶	۰/۰۰۱۸	۰/۵۲۴
CXO & CT& DT & GR & RHOB & NPHI & PE	V. Oil	۰/۰۰۰۰۱۵	۰/۰۰۰۰۷۵	۰/۹۵۳
CT& DT & GR & RHOB & NPHI & PE	V. Oil	۰/۰۰۰۰۰۲	۰/۰۰۰۰۳۷	۰/۷۸۹
CXO & CT& DT & GR & RHOB & NPHI & PE	V. Water	۰/۰۰۰۰۰۶۳	۰/۰۰۰۰۰۷۹	۰/۹۴۶
CT& DT & GR & RHOB & NPHI & PE	V. Water	۰/۰۰۰۰۱۱	۰/۰۰۰۰۰۳	۰/۹۷۷

۲ | بهینه‌سازی شبکه با تابع پایه شعاعی

متغیرهای ورودی	متغیر خروجی	spread	کمترین مربع خطای دسته آموزش	کمترین مربع خطای دسته آزمون	ضریب هم‌بستگی خروجی و داده واقعی
CT& DT & GR & RHOB & NPHI & PE	V. calcite	۰/۴	۰/۰۰۰۰۲۵	۰/۰۰۰۵	۰/۸۵۱
CT& DT & GR & RHOB & NPHI & PE	V. calcite	۰/۶	۰/۰۰۰۰۹۹	۰/۰۰۰۴۱	۰/۸۸۲
CT& DT & GR & RHOB & NPHI & PE	V. calcite	۰/۷	۰/۰۰۰۰۱۵	۰/۰۰۰۳۹	۰/۸۹۴
CT& DT & GR & RHOB & NPHI & PE	V. calcite	۰/۸	۰/۰۰۰۰۲۲	۰/۰۰۰۳۸	۰/۹۱۲
CT& DT & GR & RHOB & NPHI & PE	V. calcite	۰/۹	۰/۰۰۰۰۰۳	۰/۰۰۰۰۳۹	۰/۹۰۹
CT& DT & GR & RHOB & NPHI & PE	V. calcite	۱	۰/۰۰۰۰۴۳	۰/۰۰۰۰۴۱	۰/۹۱۳
CT& DT & GR & RHOB & NPHI & PE	V. dolomite	۰/۸	۰/۰۰۰۰۲۱	۰/۰۰۰۰۳۴	۰/۸۶۷
CT& DT & GR & RHOB & NPHI & PE	V. illit	۰/۸	۰/۰۰۰۰۰۴۷	۰/۰۰۰۰۰۶۶	۰/۹۱۹
CT& DT & GR & RHOB & NPHI & PE	V. Oil	۰/۸	۰/۰۰۰۰۰۴۶	۰/۰۰۰۰۰۱۵	۰/۹۶۷
CT& DT & GR & RHOB & NPHI & PE	V. Water	۰/۸	۰/۰۰۰۰۰۱۹	۰/۰۰۰۰۰۲۷	۰/۹۴۶

شده موجود می‌باشد. این ارزیابی‌ها به کمک اطلاعات زمین‌شناسی و آزمایش‌های پتروفیزیکی و با استفاده از نرم‌افزار ژئولاگ با صرف زمان طولانی جهت مدل‌سازی انجام شده‌اند و صحت آنها مورد تأیید می‌باشد.

زیر در طراحی یک مدل شبکه عصبی دنبال شود [۷ و ۸]:

۲-۲-۱- آماده‌سازی داده‌های مورد استفاده

اطلاعاتی که برای ایجاد یک مدل به کار می‌رود در مرحله نخست باید معتبر بوده و دقت و صحت زیادی داشته باشد. داده‌هایی که با خطا همراه هستند نیز باید حذف شده و همه در یک محدوده قرار گیرند تا شبکه به مشکل اشباع حافظه دچار نشود. برای این منظور داده‌ها را

۲-۲-۲ مدل‌سازی

نخستین و مهم‌ترین موضوع در کاربردی بودن یک مدل، دقت زیاد و معتبر بودن پیش‌بینی آنست. برای دستیابی به این هدف باید مراحل

بهبودسازی شبکه چندلایه پس انتشار

متغیرهای ورودی	متغیر خروجی	تعداد نرون‌های هر لایه	تابع محرک لایه‌های مخفی	تابع آموزش شبکه	تعداد دوره‌های آموزش	کمترین مربع خطای دسته آموزش	کمترین مربع خطای دسته آزمون	ضریب هم‌بستگی خروجی و داده واقعی
CT & DT & GR & RHOB & NPHI & PE	V. calcite	۸ ۱	logsig	lm	۱۰۰	۰/۰۰۱۲	۰/۰۰۱۴	۰/۹۶۲
CT & DT & GR & RHOB & NPHI & PE	V. calcite	۸ ۱	logsig	lm	۱۵۰	۰/۰۰۰۹۴	۰/۰۰۰۵۲	۰/۹۸۶
CT & DT & GR & RHOB & NPHI & PE	V. calcite	۸ ۱	logsig	lm	۲۰۰	۰/۰۰۰۷۹	۰/۰۰۰۵۸	۰/۹۸۴
CT & DT & GR & RHOB & NPHI & PE	V. calcite	۱۶ ۱	logsig	lm	۱۵۰	۰/۰۰۰۵۲	۰/۰۰۰۷۱	۰/۹۸۱
CT & DT & GR & RHOB & NPHI & PE	V. calcite	۶ ۱۶ ۱	logsig	lm	۱۵۰	۰/۰۰۰۳۶	۰/۰۰۱۸	۰/۹۵۱
CT & DT & GR & RHOB & NPHI & PE	V. calcite	۶ ۱۶ ۱	logsig	bfgr	۱۵۰	۰/۰۰۰۹۲	۰/۰۰۰۶۳	۰/۹۸۶
CT & DT & GR & RHOB & NPHI & PE	V. calcite	۶ ۱۶ ۱	tansig	bfgr	۱۵۰	۰/۰۰۰۷	۰/۰۰۰۶۶	۰/۹۸۴
CT & DT & GR & RHOB & NPHI & PE	V. calcite	۸ ۱	logsig	bfgr	۱۵۰	۰/۰۰۱۳	۰/۰۰۰۳۲	۰/۹۹۳
CT & DT & GR & RHOB & NPHI & PE	V. calcite	۸ ۱	logsig	cgp	۱۵۰	۰/۰۰۱۴	۰/۰۰۰۵۵	۰/۹۸۷
CT & DT & GR & RHOB & NPHI & PE	V. calcite	۸ ۱	logsig	oss	۱۵۰	۰/۰۰۱۴	۰/۰۰۰۵۳	۰/۹۸۸
CT & DT & GR & RHOB & NPHI & PE	V. calcite	۸ ۱	logsig	scg	۱۵۰	۰/۰۰۱۶	۰/۰۰۰۸۳	۰/۹۷۸
CT & DT & GR & RHOB & NPHI & PE	V. calcite	۸ ۱	logsig	rp	۱۵۰	۰/۰۰۱۵	۰/۰۰۰۴	۰/۹۹
CT & DT & GR & RHOB & NPHI & PE	V. calcite	۸ ۱	logsig	gd	۱۵۰	۰/۰۰۹۷	۰/۰۰۵۸	۰/۹۰۵
CT & DT & GR & RHOB & NPHI & PE	V. calcite	۸ ۱	logsig	gda	۱۵۰	۰/۰۰۴۳	۰/۰۰۲۲	۰/۹۳۸
CT & DT & GR & RHOB & NPHI & PE	V. calcite	۸ ۱	logsig	gdx	۱۵۰	۰/۰۰۲۳	۰/۰۰۰۸۲	۰/۹۸۱
CT & DT & GR & RHOB & NPHI & PE	V. dolomite	۸ ۱	logsig	bfgr	۱۵۰	۰/۰۰۰۹۸	۰/۰۰۲۷	۰/۹۹۲
CT & DT & GR & RHOB & NPHI & PE	V. illit	۸ ۱	logsig	bfgr	۱۵۰	۰/۰۰۰۰۲۹	۰/۰۰۰۰۰۷	۰/۹۸۷
CT & DT & GR & RHOB & NPHI & PE	V. Oil	۸ ۱	logsig	bfgr	۱۵۰	۰/۰۰۰۰۲۲	۰/۰۰۰۰۳۶	۰/۹۹۹
CT & DT & GR & RHOB & NPHI & PE	V. Water	۸ ۱	logsig	bfgr	۱۵۰	۰/۰۰۰۰۰۳	۰/۰۰۰۰۰۲	۰/۹۹۵



چگالی (RHOB)، گاما (GR)، هدایت الکتریکی (CR)، فوتو الکترون (PE) و نمودار صوتی (DT) به عنوان بهترین متغیرهای ورودی انتخاب شدند.

۲-۲-۴- بینه سازی شبکه عصبی

بعد از انتخاب ورودی‌های مناسب، یک شبکه عصبی چندلایه و یک شبکه پایه شعاعی با ساختار ساده طراحی می‌شود. سپس جهت بینه‌سازی این شبکه‌ها متغیرهای شبکه شامل تابع آموزش، تعداد لایه‌ها و نرون‌ها و نوع توابع محرک در توابع چندلایه و مقدار spread در توابع پایه شعاعی را تغییر داده و بهترین حالت انتخاب می‌شود [۶۵].

نتایج حاصل از بینه‌سازی توابع پایه شعاعی در جدول ۲ ارائه شده است. نتایج این جدول بر این اساس به دست آمده که ابتدا حجم کلسیت به عنوان متغیر خروجی در نظر گرفته می‌شود و سپس بر اساس آن مقدار spread بینه‌سازی می‌شود. همان‌طور که مشاهده می‌شود با کاهش مقدار spread، خطای شبکه در پیش‌بینی خروجی به سمت صفر میل می‌کند. اما این کاهش خطا فقط برای دسته آموزش صادق است. در واقع شبکه پایه شعاعی به جای یادگیری، همه داده‌های دریافتی را حفظ می‌کند. این اتفاق بیش‌برازش نامیده می‌شود. در این حالت شبکه

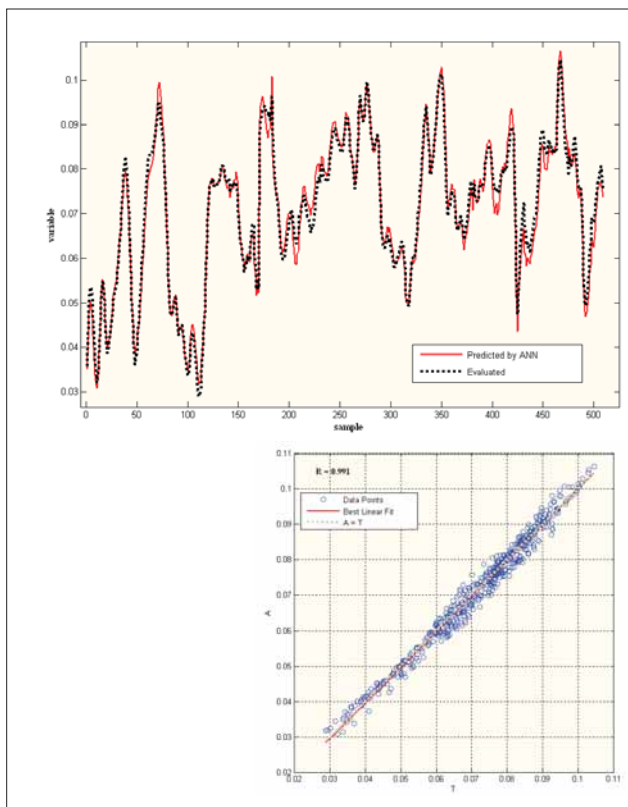
نرمال‌سازی می‌کنند تا همگی در محدوده صفر و یک قرار گیرند.

۲-۲-۲- تقسیم‌بندی داده‌ها

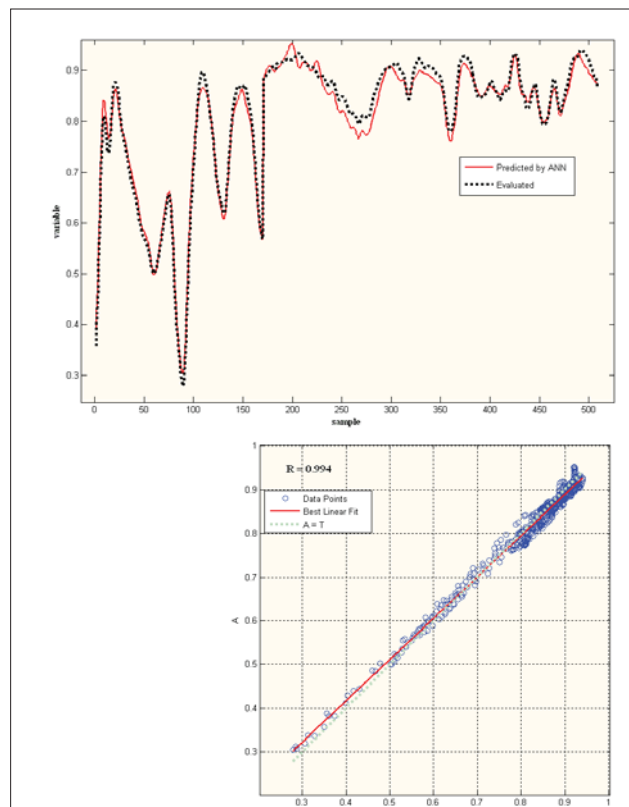
برای این منظور ۸۰ درصد داده‌ها برای آموزش و باقیمانده برای آزمون دسته‌بندی می‌شوند. شبکه عصبی نیز مانند هر مدل دیگری برای افزایش کارایی خود از درون‌یابی نیز استفاده می‌کند. بنابراین در انتخاب دسته آموزش باید به این نکته توجه کرد که بیشینه و کمینه هر متغیر در این دسته قرار بگیرد.

۲-۲-۳- انتخاب متغیرهای ورودی شبکه

در این تحقیق برای یافتن بهترین متغیرهای ورودی از مدل انفیس استفاده شده است. از آنجا که ساختار این مدل نسبت به پرسپترون چندلایه و توابع پایه شعاعی ساده‌تر است، تغییرات نوع ورودی و تعداد متغیرها نسبت به جواب حاصل را بهتر می‌توان بررسی کرد. بدین صورت که با استفاده از مدل انفیس و تغییر ورودی‌ها و مشاهده ضریب هم‌بستگی و کمینه مربع خطای حاصل می‌توان بهترین ترکیب ماتریس ورودی را پیدا کرد. در جدول ۱- نتایج این بررسی نشان داده شده است. پس از بررسی نتایج در نهایت نمودارهای نوترون (NPHI)،



شکل ۲ | مقایسه بین داده‌های واقعی و خروجی شبکه عصبی (درصد حجمی ایلیت)



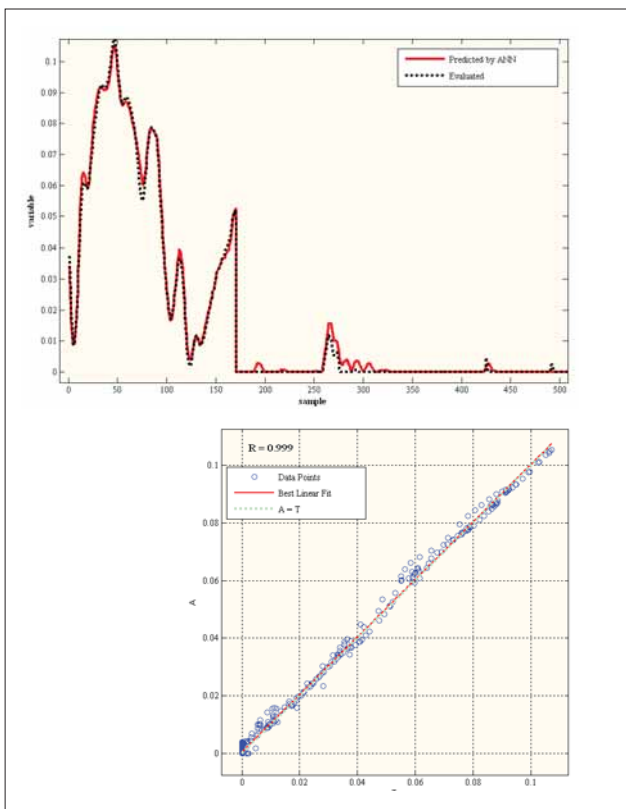
شکل ۱ | مقایسه بین داده‌های واقعی و خروجی شبکه عصبی (درصد حجمی کلسیت)

هم چنین با افزایش تعداد لایه ها و نرون ها مشخص شد که شبکه اشباع شده و بازدهی آن کاهش می یابد و بهینه ترین ساختار استفاده از یک لایه مخفی با هشت نرون است. یکی دیگر از عوامل ارتقاء شبکه استفاده از تابع آموزش مناسب است. انواع مختلفی از توابع آموزش وجود دارد که با توجه به خطای دسته آزمون تابع BFG quasi-Newton back propagation به عنوان مناسب ترین تابع انتخاب شد.


۳-۲- اعتبارسنجی مدل و بررسی آن

چندین روش برای بررسی اعتبار یک مدل وجود دارد. ورودی های دسته آزمون به شبکه اعمال شده و به تعداد نمونه ها از شبکه خروجی به دست می آید. پس از خارج کردن داده های خروجی از حالت نرمال می توان آنها را با داده های واقعی موجود که در یادگیری شبکه استفاده نشده بود، مقایسه کرد. یکی از این روش های مقایسه، استفاده از کمترین مربع خطاست که در جداول پیشین برای هر دو دسته آموزش و آزمون نشان داده شده است. روش دیگر استفاده از ضریب هم بستگی بین داده های خروجی شبکه و داده های واقعی است. در شکل های ۱-۵، ضریب هم بستگی با رسم نمودار

عمومیت خود را از دست می دهد؛ چراکه فقط داده های ورودی را حفظ کرده و به ارتباط بین داده ها پی نبرده است. در نتیجه برای پیش بینی دسته های جدید داده ها خطای زیادی خواهد داشت. از طرفی افزایش spread باعث کاهش قدرت یادگیری شبکه خواهد شد. بنابراین مقدار آن تا جایی افزایش داده می شود که مقدار خطای دسته آزمون کم شده و هم چنین خطای دسته آموزش و آزمون رو به افزایش نرود. مقدار بهینه spread در این شبکه ۰/۸ است و هم چنین مقادیر کمترین مربع خطا و ضریب هم بستگی بین خروجی و داده های واقعی در جدول آمده است. نتایج حاصل از بهینه سازی شبکه چند لایه در جدول ۳ ارائه شده است. ابتدا هشت نرون برای لایه مخفی در نظر گرفته شد که تابع محرک آن از نوع لگاریتم سیگموئید بود. لایه خروجی که شامل یک نرون است از تابع محرک خطی کمک می گیرد. مهم ترین عامل در عمومیت یک شبکه پیش گیری از بیش برآش آنست. با افزایش تعداد دوره های آموزشی از ۱۰۰ به ۱۵۰، هم زمان با افزایش قدرت شبکه در یادگیری، توانایی شبکه در آزمون هم افزایش می یابد. اما با افزایش بیشتر دوره های آموزش، با وجود کاهش خطای دسته آموزش، شبکه دچار بیش برآش شده و خطای دسته آزمون افزایش می یابد. بنابراین مقدار بهینه دوره ها ۱۵۰ عدد تعیین شد.



شکل ۱۴ مقایسه بین داده های واقعی و خروجی شبکه عصبی (درصد حجمی نفت)



شکل ۱۳ مقایسه بین داده های واقعی و خروجی شبکه عصبی (درصد حجمی دولومیت)




نشان داده شده است. در نمودارها، دایره‌های کوچک نشان‌دهنده داده‌های خروجی شبکه هستند و خط ممتد سبزرنگ بهترین رگرسیون این نقاط است. از طرفی، خط چین مربوط به بهترین رگرسیون نقاط هدف می‌باشد. ضریب هم‌بستگی بین این دو خط با R نشان داده می‌شود. محورهای افقی و عمودی به ترتیب مربوط به داده‌های واقعی هدف و داده‌های خروجی شبکه هستند. وقتی مقدار R، برابر یک شود به معنای تطابق ۱۰۰ درصد رگرسیون داده‌های واقعی و رگرسیون داده‌های خروجی شبکه است.

یکی از بهترین روش‌ها، رسم نموداری است که برای هر نمونه، هم مقدار واقعی آن و هم مقدار پیش‌بینی شده با شبکه را نمایش داده و به صورت کلی بتوان تفاوت این مقادیر را برای همه نمونه‌ها بررسی کرد. شکل‌های ۱-۵ نشانگر این نمودارها برای مقادیر مختلف متغیرهای خروجی هستند. در محور افقی شماره نمونه‌های دسته آزمون و در محور عمودی مقدار متغیر نشان داده شده است.

نتیجه‌گیری

مقایسه خطای نسبی در نمودارها، کمترین مجموع مربعات خطا و ضریب هم‌بستگی بین داده‌های واقعی و خروجی شبکه نشان داد که مهم‌ترین عامل در کارایی بیشتر شبکه‌های عصبی مصنوعی، انتخاب مناسب داده‌های ورودی، تعداد دوره و توابع آموزشی بهینه است. در نهایت در این مدل برای پیش‌بینی درصد حجمی الیت، کلسیت، دولومیت، آب و نفت از نمودارهای نوترون، صوتی، چگالی، گاما، پف و هدایت الکتریکی استفاده شد و نیاز پرهزینه و وقت‌گیر به آزمایش‌های پتروفیزیکی را مرتفع ساخت. در نهایت با توجه به نتایج حاصل از جداول و شکل‌ها، کارایی دقیق این مدل و مقرون‌به‌صرفه بودن آن به اثبات رسید. ■



شکل ۵ | مقایسه بین داده‌های واقعی و خروجی شبکه عصبی (درصد حجمی آب)

منابع

- [1] Baneshi.M. "Using ANFIS and Neural Networks to Predict the Volume Percentage of Matrix and Fluid" accepted by Energy Sources, Part A: Recovery, Utilization, and Environmental Effects journal, UESO-2011-0748-R1
- [2] Baneshi.M. "Determination of Lithofacies using an Optimized Neural Network and Well Log Data" accepted by Petroleum science and technology journal, LPET-2011-0407-R3
- [3] Baneshi.M, Schaffie.M, Nezamabadi-pour.H, Behzadijo.M, "Predicting log data by using artificial neural networks to approximate petrophysical parameters of formation" accepted by Petroleum science and technology journal, LPET-2010-0580.R4
- [4] Rostamy.M., Baneshi.M., "Reservoir Porosity Estimation From Well Logs Using Neural Networks" the 6th International Chemical Engineering Congress, Kish Island, I.R.Iran, November 2009
- [5] Baneshi.M, Schaffie.M, Nezamabadi-pour.H, Behzadijo.M, "Reservoir Petrophysical Index Prediction Using Neural Network with Selection suitable Feature" National Conference of Energy and Environment, Kerman, I.R.Iran, October 2010
- [6] Baneshi.M, Schaffie.M, Nezamabadi-pour.H, Behzadijo.M, "Designing the Best Artificial Neural Network to Prediction Porosity Index" National Conference of Energy and Environment, Kerman, I.R.Iran, October 2010
- [7] Asquith.G&Krygowski.D, "Basic Well Log Analysis", Published by the American Association of Petroleum Geologists Tulsa, Oklahoma, 2004
- [8] G.M.Hamada. "Neural Network Prediction of Porosity and Permeability of Heterogeneous Gas Sand Reservoir" SPE 126042, 2009