

کاربرد شبکه‌های عصبی و الگوریتم‌های ژنتیک در پیش‌بینی و بهینه‌سازی فرآیند نمک‌زدایی

سید هادی ریاضی*، دانشگاه صنعت نفت اهواز • محمد زمان زرگرنژاد، شرکت ملی مناطق نفت‌خیز جنوب

چکیده

در طول فرآیند نمک‌زدایی، سعی بر این است که لایه امولسیون در سطح مشترک بین آب و نفت از بین برود. در صنایع نفت، معمولاً امولسیون باعث پراکنده شدن قطرات آب در فاز پیوسته نفت می‌گردد. در امولسیون‌های نفت‌خام، عوامل امولسیون‌کننده موجود در سطح مشترک نفت و آب، از فرآیند انعقاد جلوگیری می‌کنند. این عوامل امولسیون‌کننده شامل ذرات رس و رسوبات معدنی ترکیبات شیمیایی و طبیعی مانند آسفالتین، رزین و واکس در نفت خام هستند. تکنیک‌های زیادی جهت به‌حداقل رساندن اثرات امولسیون در جداکننده‌های نفت و گاز وجود دارد. این تکنیک‌ها شامل تزریق مواد امولسیون‌زدا، افزایش دمای نفت، تفکیک ثقلی در ظروف بزرگ با زمان ماند بالا و همچنین ولتاژ الکتروستاتیک می‌باشد. هدف از انجام این مقاله بهبود کنترل تزریق مواد امولسیون‌زداست. طی این مطالعه مدلی با استفاده از هوش مصنوعی برای پوشش محدوده عملیاتی گسترده‌ای از تمام پارامترهای موثر بر میزان مصرف مواد امولسیون‌زدا طراحی می‌شود. مدل طراحی شده به‌عنوان یک جعبه سیاه کنترل می‌تواند در داخل کنترل‌کننده مورد استفاده قرار گیرد. در این مدل، تمام پارامترهای موثر بر میزان مصرف امولسیون‌زدا به‌عنوان ورودی و میزان مصرف مواد امولسیون‌زدا به‌عنوان خروجی مدل قرار می‌گیرند. آزمایش این طرح کنترل، کاهش موثر در میزان مصرف مواد امولسیون‌زدا را در مقایسه با روش‌های خطی موجود نشان می‌دهد. در نهایت، مدل دیگری برای برآورد آنلاین میزان نمک موجود در نفت تولیدی توسعه داده شده است. در این مدل، غلظت نمک در نفت خروجی به‌عنوان خروجی مدل و باقی پارامترها به‌عنوان ورودی مدل قرار می‌گیرند. با استفاده از ابزارهای بهینه‌سازی مانند ژنتیک الگوریتم، میزان بهینه امولسیون‌زدا در حالتی که غلظت نمک تا 10 PTB کاهش می‌یابد، به‌دست می‌آید.

اطلاعات مقاله

تاریخ ارسال نویسنده: ۹۶/۰۳/۱۱

تاریخ ارسال به داور: ۹۶/۰۳/۲۷

تاریخ پذیرش داور: ۹۶/۰۵/۲۴

واژگان کلیدی:

نمک‌زدایی، امولسیون‌زدا، شبکه عصبی مصنوعی، الگوریتم ژنتیک

مقدمه

نمک در نفت خشک وجود ندارد بلکه در آب همراه نفت خام حل شده است. آب ترکیب شده با نفت به دو صورت آزاد یا امولسیونی وجود دارد. آب آزاد همراه نفت به راحتی به کمک جداکننده‌های ثقلی از نفت جدا می‌شود [۲]. آب موجود در نفت به صورت امولسیونی در مراحل مختلف تولید نفت خام تشکیل شده است. پایداری امولسیون باعث ماندگاری قطرات آب در نفت می‌شود و از انعقاد آنان جلوگیری می‌کند. با افزایش پایداری امولسیون، هزینه‌های مورد نیاز جهت کاهش نمک و آب موجود در نفت ورودی جداکننده‌های نفت گاز نیز افزایش می‌یابد. بنابراین به دلایل اقتصادی و عملیاتی، جداسازی آب همراه قبل از انتقال یا پالایش نفت ضروری است. یکی از موثرترین و پربازده‌ترین روش‌ها جهت غلبه بر پایداری امولسیون، افزودن امولسیون‌زدای شیمیایی به نفت می‌باشد. مواد امولسیون‌زدا با ناپایدار کردن غشای بین قطرات آب و نفت، جداسازی آب از نفت را تسهیل می‌بخشد. در سال‌های اخیر، کنترل میزان مواد امولسیون‌زدا به صورت خودکار انجام می‌شود. کنترل‌کننده از معادلات خطی مختلف در بازه‌های

اجرای فرآیندهای مختلف بر روی نفت خام با غلظت نمک بالا (غلظت بالای ۲۰ پوند نمک به ازای هر ۱۰۰۰ بشکه ی نفت) باعث آسیب‌رسانی به خطوط لوله و تجهیزات مربوطه می‌شود. به این دلیل، پالایشگاه‌ها در جداکننده‌های نفت گاز بالا دستی، تجهیزات نمک‌زدایی نصب می‌کنند. در سال‌های اخیر، با توجه به رشد تقاضای نفت در جهان، فرآیند نمک‌زدایی به سرعت توسعه یافته است. به‌موجب توسعه این فرآیند، انتظار پالایشگاه‌ها به منظور بهبود کیفیت نفت ورودی خصوصاً نفتی با غلظت نمک پایین افزایش یافته است. وجود غلظت بالای نمک در نفت خام ورودی به پالایشگاه اثرات زیر را به همراه خواهد داشت [۱]:

- افزایش سرعت خوردگی در خطوط لوله انتقال و تجهیزات پالایشگاهی
- کاهش طول عمر پمپ‌ها در اثر افزایش افت فشار به‌واسطه رسوبات نمکی
- غیر فعال شدن فعالیت‌های کاتالیستی به‌علت حضور ترکیبات فلزی موجود در نمک‌ها

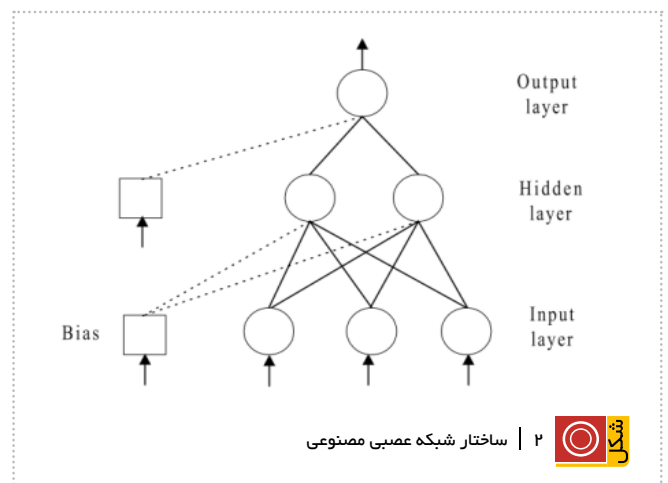
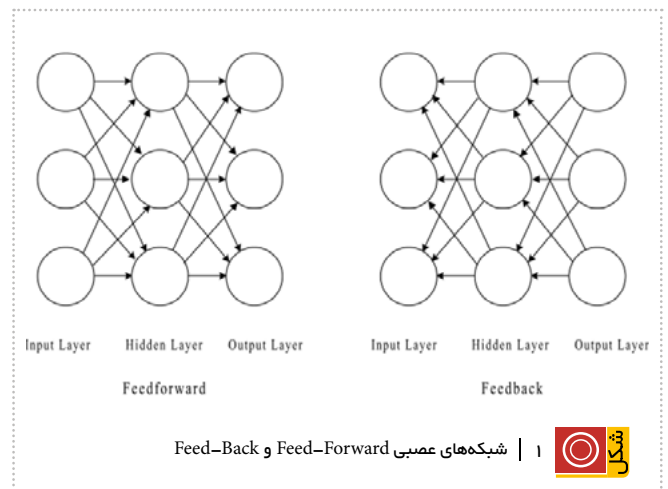
* نویسنده‌ی عهده‌دار مکاتبات (seiedhadiri@zangi.com)

عصبی مصنوعی فرآیند موردنظر را مدل‌سازی نموده‌اند. در این تحقیق، با استفاده از آنالیز حساسیت، جریان و دمای آب تزریقی در نمک‌زدای اول و جریان آب و نفت تزریقی و دمای آب تزریقی در نمک‌زدای دوم به‌عنوان ورودی شبکه عصبی در نظر گرفته شده‌اند. این پارامترها بیشترین تاثیر بر میزان آب خروجی واحد نمک‌زدایی (خروجی مدل شبکه عصبی) را دارا می‌باشند. بعضی از پارامترهای سیستم ثابت نمی‌باشند و دارای اثرات غیرخطی بر روی غلظت نمک موجود در نفت خروجی می‌باشند مانند نرخ نفت‌خام ورودی، دمای نفت‌خام و برش آب. در این شرایط استفاده از کنترل‌کننده‌ای غیرخطی که توانایی تنظیم چنین پارامترهایی را به کمک وفق دادن رفتار خویش دارد، موردنیاز است. مطابق توصیفات بالا، این تحقیق تکنیک جدیدی به‌عنوان کنترل هوشمند جهت کنترل نرخ تزریق مواد امولسیون‌زدا ارائه می‌دهد. تکنیک ارائه شده شبکه‌های عصبی مصنوعی می‌باشد. به‌منظور نشان دادن ضرورت تغییرات طرح کنترل نرخ مواد امولسیون‌زدا، عملکرد کنترل‌کننده‌های موجود در جداکننده‌های نفت گاز مناطق نفت‌خیز جنوب ارزیابی خواهد شد. برای رسیدن به این منظور، شبکه‌های عصبی با استفاده از مجموعه داده‌های به‌دست آمده از جداکننده‌های نفت گاز مناطق نفت‌خیز جنوب طراحی می‌شوند. شبکه‌ی طراحی شده جهت پیش‌بینی نرخ مصرف مواد امولسیون‌زدا در شرایط عملیاتی یکسان استفاده می‌گردد. شبکه ایجاد شده جهت جایگزین شدن با کنترل‌کننده‌های خطی موجود در جداکننده‌های نفت گاز مناطق نفت‌خیز جنوب ارائه می‌شود. هم‌اکنون در جداکننده‌های نفت گاز موجود در مناطق نفت‌خیز جنوب، تحلیلگر آنالیز نمک وجود ندارد. مدل‌های موجود نیازمند به نگهداری مکرر می‌باشند و همچنین از دقت کافی برخوردار نیستند. بنابراین هدف دوم از این پروژه ایجاد و توسعه یک شبکه طراحی شده مناسب به‌منظور پیش‌بینی غلظت نمک موجود در نفت خروجی می‌باشد. این روش کمک شایانی به خواندن آنالیز غلظت نمک با حداکثر سرعت ممکن می‌نماید. همچنین با استفاده از شبکه مورد استفاده جهت پیش‌بینی غلظت نمک، مقدار نرخ امولسیون‌زدایی که غلظت نمک را به ۱۰PTB می‌رساند، به‌دست می‌آید. بنابراین سومین و مهم‌ترین هدف این پروژه بهینه‌سازی نرخ امولسیون‌زدا جهت رسیدن به غلظت نمک ۱۰PTB می‌باشد. نتایج این مطالعه جهت کاهش هزینه‌های مربوط به فرآیند نمک‌زدایی سودمند خواهد بود. این کاهش هزینه عمدتاً مربوط به کاهش نرخ مصرف امولسیون‌زدا می‌باشد.

۱- شبکه‌های عصبی مصنوعی

شبکه‌های عصبی مصنوعی نوعی مدل آماری است که بر اساس کارکرد مغز انسان طراحی شده است. این نوع مدل با توانایی‌ای که در اختیار دارد می‌تواند ورودی‌های معینی را دریافت کند و طی یک سری پردازش‌های موجود در مدل، نتیجه مطلوب را ارائه دهد. شبکه‌های عصبی از واحدهای ساده‌ای به نام نورون ساخته می‌شوند

مختلف پارامترهای عملیاتی استفاده می‌نمایند. بعضی از این پارامترهای عملیاتی عبارتند از: دمای نفت ورودی، ولتاژ الکتروستاتیک نمک‌زدا، برش آب و سرعت جریانی نفت ورودی. عملکرد کنترل‌کننده براساس میزان نمک موجود در نفت تولیدی بررسی می‌شود. میزان نمک مجاز در نفت تولیدی در مرحله نهایی برابر ۱۰PTB می‌باشد. جهت یافتن عملی‌ترین استراتژی کنترل برای مصرف مواد امولسیون‌زدا، پارامترهای موثر بر میزان نمک موجود در نفت‌خام باید در شرایط بهینه‌ی خود قرار گیرند. این پارامترها عبارت‌اند از دمای نفت‌خام، ولتاژ الکتروستاتیک نمک‌زدا، ولتاژ الکتروستاتیک نمک‌زدا، نرخ آب شست‌وشو، میزان آب موجود در نفت‌خام ورودی، نرخ جریانی کلی نفت‌خام، نوع و نرخ جریانی مواد امولسیون‌زدا. آل-آیبی و همکارانش [۳] عملکرد فرآیند نمک‌زدا / نمزدا را بررسی کرده‌اند. این مطالعه شامل بررسی اثرات غلظت مواد امولسیون‌زدا، حرارت، نرخ آب شست‌وشو، غلظت نمک و زمان اختلاط با آب شست‌وشو می‌باشد. در این کار، عملکرد فرآیند نمک‌زدا / نمزدا با محاسبه‌ی میزان شوری و برش آب که وابسته به پنج پارامتری که در بالا ذکر شده است مورد ارزیابی قرار گرفت. آقای صفوی و همکارانش [۴] با استفاده از داده‌های به‌دست آمده از واحد نمک‌زدایی پالایشگاه بندرعباس، با استفاده از شبکه‌های



و سلول‌هایی نظیر آنچه که در مغز انسان وجود دارد را ارائه می‌دهند.

۱-۲- الگوریتم ژنتیک

ایده اصلی الگوریتم‌های تکاملی در سال ۱۹۶۰ میلادی توسط ریچنبرگ مطرح گردید. الگوریتم‌های ژنتیک که منشعب از این نوع الگوریتم‌ها می‌باشد، در حقیقت روش جستجوی کامپیوتری بر پایه الگوریتم‌های بهینه‌سازی و بر اساس ساختار ژن‌ها و کروموزم‌هاست که توسط جان هلند (۱۹۷۰) در دانشگاه میشیگان مطرح شد [۶]. الگوریتم‌های ژنتیک یکی از قویترین روش‌های برگرفته از طبیعت است که به جستجوی فضای مسأله به صورت تصادفی هدایت شده پرداخته که این جستجو در قالب تلاش جهت ایجاد جواب‌هایی بهتر، در هر نسل نسبت به جواب‌های نسل قبل صورت می‌گیرد و یکی از بهترین شیوه‌های بهینه‌سازی عددی در مسائل علوم و مهندسی را ارائه می‌کند. مراحل الگوریتم ژنتیک در شکل ۳- نشان داده شده است. ابتدا پاسخ مسئله در قالب یک ساختار کروموزمی تعریف می‌شود (کد گذاری). با معرفی تابع برازش، کیفیت پاسخ‌های ارائه شده در هر کروموزم به صورت عدد بیان می‌گردد. سپس تعداد معینی کروموزم به صورت تصادفی تولید شده که این کروموزم‌ها به عنوان جمعیت اولیه شناخته می‌شوند. در این مرحله تعدادی پاسخ برای مسئله وجود دارد که

در یک شبکه، نورون‌ها بوسیله اتصالات وزنی به یکدیگر متصل می‌شوند. از طریق تنظیم این وزن‌ها، فرآیند آموزش درون شبکه به دست می‌آید. شبکه‌های عصبی از مجموعه لایه‌هایی تشکیل می‌شود که لایه اول شامل ورودی‌ها و لایه آخر شامل خروجی‌ها می‌باشد. لایه‌های نهان نیز بین لایه‌های ورودی و خروجی قرار می‌گیرند. شبکه‌های عصبی براساس نوع فیزیک مسئله می‌توانند تک‌لایه یا چندلایه باشند. فرآیند آنالیز داده‌ها با ورود پارامترهای خوراک به لایه اول نورون‌ها آغاز می‌گردد و سپس داده‌ها برای تنظیمات بیشتر به نورون‌های لایه دوم انتشار می‌یابند. سپس نتایج به لایه بعدی انتقال می‌گردد و این فرآیند ادامه می‌یابد تا به لایه داده‌های خروجی برسد.

در اتصال بین لایه‌ای، دو نوع عمده از اتصالات بین نورون‌های شبکه وجود دارند که عبارت‌اند از Feedforward Network و Feedback Network. در شبکه feedforward سیگنال‌ها تنها در یک جهت از لایه ورودی به سمت لایه‌های نهان و در نهایت لایه خروجی جریان یابند. در شبکه feedback سیگنال‌ها می‌توانند در نورون‌های یک لایه یکسان یا در لایه‌های قبلی جریان یابند. هر دو نوع این اتصالات بین نورون‌ها در شکل ۱- نشان داده شده است. هدف شبکه‌های عصبی یادگیری براساس اتصالات منطقی بین الگوهای پارامترهای ورودی و خروجی، آنالیز و یا یافتن ساختار الگوهای پارامترهای ورودی می‌باشد. با فراهم کردن شبکه‌های عصبی با داده‌های موجود، شبکه آموزش دیده از طریق اصلاح وزن‌های اتصالاتی بین نورون‌ها به دست می‌آید (شکل ۲- [۵]).

۱-۱- عملکرد مدل

برای تعیین عملکرد مدل، معمولاً ضریب تعیین R^2 مورد استفاده قرار می‌گیرد. در شبکه عصبی، R^2 دقت مدل را در پیش‌بینی خروجی‌ها اندازه‌گیری می‌کند.

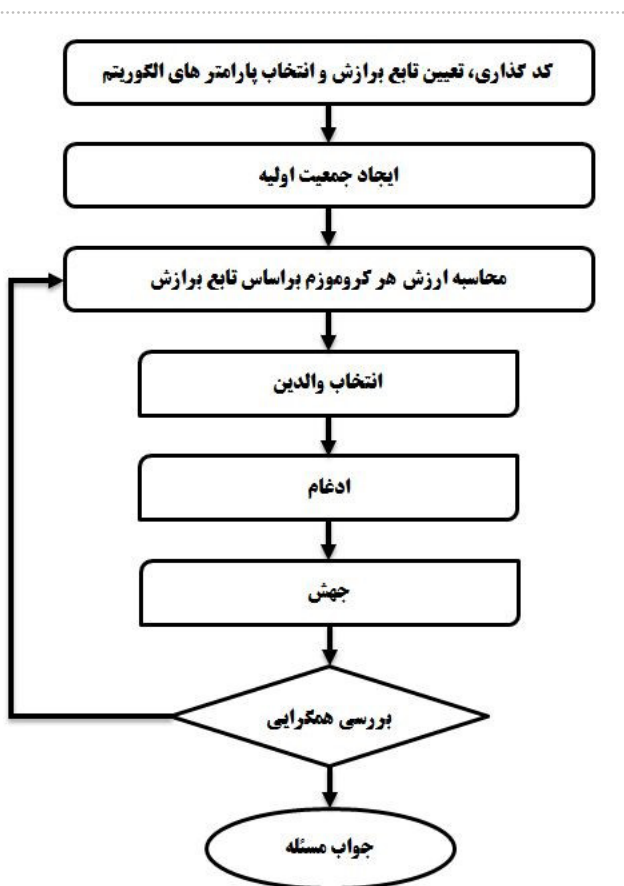
$$R^2 = 1 - \frac{\sum(Y_R - Y_S)^2}{\sum(Y_R - \frac{\sum Y_R}{N})^2} \quad (1)$$

Y_S و Y_R به ترتیب داده‌های واقعی، داده‌های شبیه‌سازی شده (پیش‌بینی شده) و تعداد کل داده‌های مورد استفاده می‌باشد.

در بسیاری از مدل‌ها، ضریب تعیین نمی‌تواند به تنهایی عملکرد مدل را بیان کند. در این موارد از پارامترهای دیگری نظیر MSE استفاده می‌شود. در این پروژه، عملکرد شبکه عصبی در پیش‌بینی خروجی‌ها توسط MSE و R^2 مورد ارزیابی قرار می‌گیرد. MSE طبق معادله زیر بیان می‌شود:

$$MSE = \frac{1}{N} \sum (Y_R - Y_S)^2 \quad (2)$$

در یک مدل دقیق مقدار R^2 نزدیک به یک و مقدار MSE نزدیک به صفر می‌باشد. عملکرد الگوریتم‌های ارائه شده در این تحقیق با توجه به دو تکنیک بالا برای یافتن ساختار بهینه شبکه، مورد



واحد نمک‌زدایی مورد ارزیابی واقع شد. بعد از ارزیابی‌های انجام شده، واحد نمک‌زدایی که بهترین ترکیب از محدوده‌های عملیاتی از پارامترهای نرخ آب شست‌وشو، نرخ تولید نفت و نرخ مصرف امولسیون زدا را فراهم می‌کند، انتخاب گردید. برای به حداکثر رساندن محدوده داده‌های دمای نفت، این نوع داده‌ها در یک چارچوب زمانی یکساله با در نظر گرفتن عامل آب و هوای فصلی، جمع‌آوری شده‌اند. بنابراین تمام داده‌های مورد استفاده در این کار، کاملاً واقعی و مورد اطمینان می‌باشند. عواملی که نقش مهمی در تعیین نرخ مصرف امولسیون‌زدا دارند، در جدول ۱- با مقادیر حداقل و حداکثر خود لیست شده‌اند. داده‌های جمع‌آوری شده نشان می‌دهند که نرخ مصرف امولسیون‌زدا به‌دست آمده از یک کنترل کننده خطی بین 18 GPD و 1 GPD

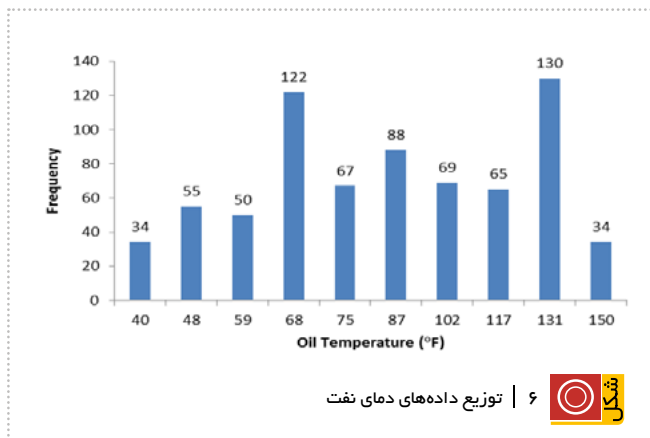
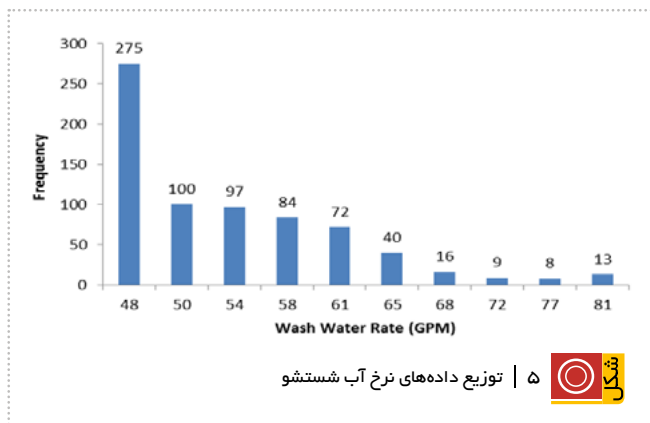

عمدتاً از کیفیت پایینی برخوردار هستند. میزان کیفیت هر کروموزم از جمعیت بر اساس تابع برازش مشخص می‌شود. حال با استفاده از روش مناسب (روشی که در آن احتمال انتخاب کروموزم با مقدار برازش بهتر بیشتر از کروموزم دارای مقدار برازش ضعیف‌تر باشد) دو کروموزم جهت تولید مثل انتخاب می‌گردد. سپس با استفاده از این دو کروموزم، کروموزم جدیدی ایجاد می‌شود (جفت‌گیری). با یک احتمال مشخص تعدادی از ژن‌های بعضی از کروموزم‌ها تغییر می‌یابد. انجام مراحل انتخاب، جفت‌گیری و جهش باعث ایجاد جمعیت جدید (نسل جدید) از کروموزم‌ها می‌گردد. در صورت همگرایی کروموزم‌ها به پاسخ مطلوب، عملیات تولید نسل متوقف می‌گردد. در غیر این صورت، ایجاد هر نسل از نسل قبلی تا رسیدن به جواب مطلوب یا برقراری شرط پایان الگوریتم ادامه می‌یابد.

۲- پردازش داده‌ها و طراحی شبکه عصبی مصنوعی

داده‌های مورد استفاده در این کار، از یکی از واحدهای نمک‌زدایی موجود در میدان نفتی اهواز جمع‌آوری شده‌اند. در این تحقیق از شبکه عصبی مصنوعی جهت پیش‌بینی نرخ مصرف امولسیون زدا و پیش‌بینی غلظت نمک در نفت خروجی استفاده می‌گردد. از الگوریتم پس انتشار خطا جهت آموزش شبکه و محاسبه خطا استفاده می‌شود. تعداد لایه‌ها، تعداد نورون‌ها و ترکیب مناسبی از توابع انتقال از طریق رویه خطا و آزمایش به‌دست می‌آیند.

۲-۱- جمع‌آوری داده‌ها

اگر داده‌های جمع‌آوری شده محدوده وسیعی از موثرترین عوامل بر ناپایداری امولسیون در واحد نمک‌زدا را در بر گیرند، نتایج حاصل از این کار، کارایی قابل توجهی خواهد داشت. برای اطمینان از اینکه داده‌های جمع‌آوری شده محدوده مناسبی را پوشش می‌دهند، چندین



۱ | عوامل موثر در امولسیون‌زدا

| عامل | حداقل | حداکثر | واحد |
|-----------------------|-------|--------|--------------------|
| برش آب | ۵ | ۲۰ | % |
| نرخ آب شست‌وشو | ۸۴ | ۱۸ | GPM^3 |
| دمای نفت | ۰۴ | ۱۵۰ | $^{\circ}\text{F}$ |
| ولتاژ نمزدا | ۰۰۰۰۱ | ۳۵۰۰۰ | Volt |
| ولتاژ نمک‌زدا | ۰۰۰۰۱ | ۳۵۰۰۰ | Volt |
| نرخ جریان نفت ورودی | ۰۲ | ۱۳۲ | MBD^4 |
| غلظت نمک در نفت ورودی | ۰۵۳ | ۴۲۰۰ | PTB |

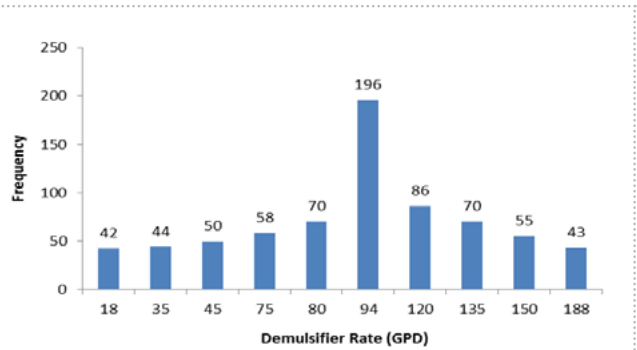
۱۸۸ می باشد. توزیع و فراوانی داده‌های نرخ مصرف امولسیونزدا و پارامترهای موثر بر آن در شکل‌های ۴ تا ۱۱ نشان داده شده است.

۲-۲- روش جمع‌آوری داده‌ها


در واحد نمک‌زدایی موردنظر، تمامی عوامل ذکر شده در جدول ۱-۱ به غیر از غلظت نمک به صورت آنلاین توسط فرستنده‌های نصب شده در میدان اندازه‌گیری می‌شوند و سپس داده‌های اندازه‌گیری شده به سیستم کنترل فرستاده و در سرورهای خاصی به نام Plant Infor-mation (PI) کپی و ذخیره می‌شوند. غلظت نمک نیز سه بار در روز اندازه‌گیری و به صورت فایل الکترونیکی ذخیره می‌گردد. فایل‌های الکترونیکی داده‌های مربوط به نمونه نفت را برای اندازه‌گیری غلظت نمک در یک زمان دقیق جمع‌آوری می‌کند. هدف از این کار این است که پارامترهای دیگر نیز در همان زمان اندازه‌گیری شوند. به عنوان مثال، فایل‌های الکترونیکی موجود غلظت نمک را در ساعت ۸:۱۵ صبح، ۲۰۰۰ PTB نشان می‌دهند. بنابراین سایر پارامترهای موجود در جدول ۱-۱ از سرور PI در همان زمان اندازه‌گیری می‌شوند.

۲-۳- پردازش داده‌ها

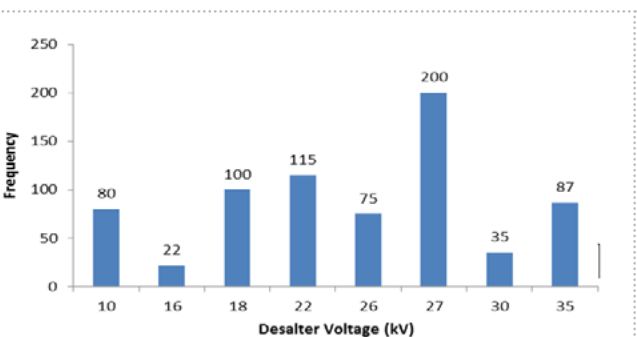
در شبکه‌های عصبی و آنالیزهای آماری، نویزها از مهم‌ترین عواملی



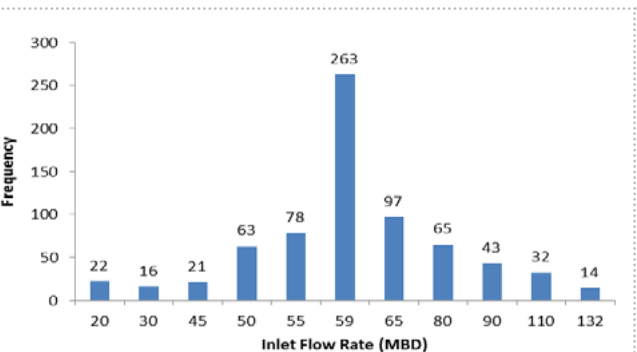
شکل ۷ | توزیع داده‌های نرخ مصرف امولسیونزدا



شکل ۸ | توزیع داده‌های ولتاژ نمزدا




شکل ۹ | توزیع داده‌های ولتاژ نمکزدا



شکل ۱۰ | توزیع داده‌های نرخ جریان نفت ورودی

۲ | عملکرد شبکه طراحی شده با روش‌های مختلف نرمال‌سازی

| خطای شبکه | معادله | روش نرمال‌سازی |
|-----------|---|------------------------------|
| ۰/۹۹۸ | $X_{inorm} = \frac{X_i}{X_{imax}}$ | Normalization to The Maximum |
| ۰/۸۵۹ | $X_{inorm} = \frac{X_i - X_{imin}}{X_{imax} - X_{imin}}$ | Simple Range Scaling |
| ۱/۶۶۵ | $X_{inorm} = \frac{X_i - X_{iavg}}{R_{imax}}$ <small>R_{imax} بیشترین محدوده بین مقدار متوسط و مقدار حداقل یا حداکثر می‌باشد.</small> | Zero-Mean Normalization |



شکل ۱۱ | توزیع داده‌های غلظت نمک در نفت ورودی

۲-۴-۲-۴-۴-۲ نرمال سازی داده‌ها

حتی اگر داده‌ها بازتابی از رفتار سیستم واقعی باشند، شبکه آموزش دیده به دلیل عدم نرمال‌سازی داده‌ها یا نرمال‌سازی آنها با روش نامناسب، نتایجی با درجه خطای بالا تولید می‌کند. برای مشخص نمودن بهترین روش نرمال‌سازی در این مطالعه، داده‌های مورد نیاز جهت ساخت شبکه با روش‌های نرمال‌سازی مختلف تهیه می‌شوند. جدول ۲-۳ به روش نرمال‌سازی استفاده شده در این کار و همچنین خطای شبکه آموزش دیده ناشی از نرمال‌سازی داده‌ها با سه روش مطرح شده را نشان می‌دهد. با توجه به خطاهای به دست آمده در این جدول، روش Simple Range Scaling با کمترین خطا، جهت نرمال‌سازی داده‌ها در این کار انتخاب شده است.

۲-۵-۲-۵-۲ طراحی شبکه عصبی

هدف از توسعه یک شبکه عصبی، تولید شبکه‌ای است که برای متغیرهای خروجی کمترین خطا بین داده‌های واقعی و پیش‌بینی شده را ایجاد نماید. در اینجا این سوال مطرح می‌شود که معیار طراحی بهینه یک شبکه در انتخاب توابع انتقال، تعداد لایه‌های نهان و تعداد نورون‌های هر لایه چیست.

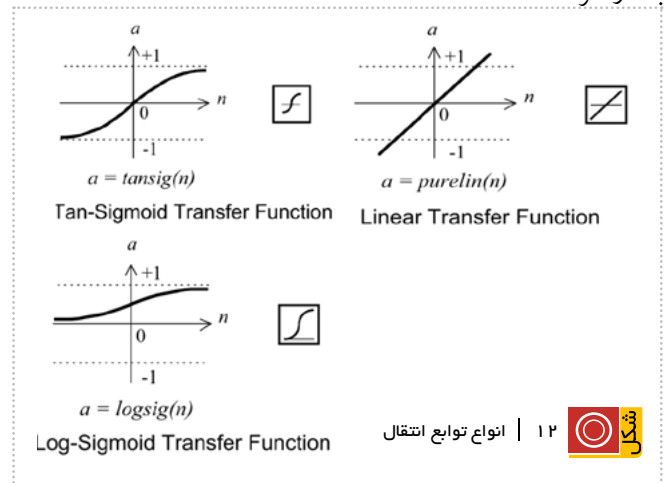
۲-۵-۲-۱-۵-۲ انتخاب تابع انتقال

انتخاب تابع انتقال تاثیر به‌سزایی بر دقت خروجی شبکه می‌گذارد. معمولاً سه تابع انتقال اصلی برای مدل‌سازی شبکه عصبی وجود دارد که شامل توابع Purelin و Tansig ، Logsig می‌باشند (شکل ۱۲-۱). برای تعیین بهترین ترکیب از توابع انتقال در شبکه با یک یا دو لایه نهان، توابع انتقال مختلفی برای توسعه شبکه استفاده می‌شود. آزمایش عملکرد شبکه با یک لایه نهان که شامل ۳۰ نورون می‌باشد، نشان می‌دهد که استفاده از تابع انتقال Tansig بین لایه ورودی و لایه نهان به همراه استفاده از تابع انتقال Purelin بین لایه نهان و لایه خروجی، بالاترین مقدار ضریب تعیین (R^2) و کمترین مقدار MSE را تولید می‌نماید. نتایج آزمایش در جدول ۳-۱ نشان داده شده است. رویه‌ای مشابه برای شبکه‌ای با دو لایه نهان اعمال می‌گردد. نتایج نشان می‌دهند که بهترین ترکیب توابع انتقال استفاده از تابع Tansig بین لایه ورودی و لایه نهان اول، استفاده از تابع Logsig بین لایه نهان اول و دوم و استفاده از تابع Purelin بین لایه نهان دوم و لایه خروجی می‌باشد.

۲-۵-۲-۲-۵-۲ تعداد لایه‌ها

تعیین تعداد لایه‌های نهان جهت ایجاد یک شبکه با کمترین خطا در پیش‌بینی خروجی‌های موردنظر، امری ضروری است. معمولاً برای تعیین تعداد بهینه لایه‌های نهان از رویه خطا و آزمایش استفاده می‌شود و بنابراین، ساختاری با کمترین تعداد لایه‌های نهان با درجه خطای قابل قبول انتخاب می‌گردد. هرچه تعداد لایه‌های نهان یک شبکه کمتر باشد، زمان کمتری برای آموزش شبکه مورد نیاز است. جدول ۴-

می‌باشند که باعث ایجاد رفتار متفاوت بعضی از نقاط نسبت به مجموعه کلی داده‌ها می‌شوند. نویزهای موجود در داده‌های آموزش شبکه را به فضای گسترده‌تری از جواب‌ها سوق می‌دهد که منجر به کاهش شدید دقت نتایج شبکه می‌گردد. در این کار، برای تشخیص نویزهای موجود در داده‌های جمع‌آوری شده، مرور اجمالی بصری برای یافتن داده‌های مشکوک انجام شده است. هفت متغیر فرآیند که از طریق ابزارهای موجود در میدان اندازه‌گیری می‌شوند، با توجه به تغییرات مورد انتظار در بازه زمانی، به سه گروه تقسیم بندی می‌گردند. اولین گروه شامل پارامترهایی می‌باشد که تغییرات چندانی با زمان ندارند؛ مانند دمای نفت و برش آب در نفت ورودی. هرگونه تغییر ناگهانی در متغیر اندازه‌گیری شده توسط ابزارهای موجود، منجر به کاهش دقت اندازه‌گیری می‌شود. این امر باعث می‌شود که داده‌های به دست آمده را اشتباهاً نویز تلقی کنیم. پس موارد از این قبیل را باید از نویزها مستثنی کنیم. در صورت عدم وجود تغییرات ناگهانی، باید به نویز بودن داده‌های اندازه‌گیری شده شک کرد. دومین گروه شامل ولتاژهای مربوط به نمک‌زدا و نمزدا می‌باشد که تغییرات ملایمی در یک دوره کوتاه زمانی دارند اما اثرات آنها در شرایط غیر عادی بطور قابل ملاحظه‌ای در خدمت رسیدن به اهداف این کار می‌باشد. در این گروه، برای چک کردن وجود نویزها، از روند بازیابی و تراوش^۵ ولتاژ استفاده می‌گردد. اگر بازیابی ولتاژ در یک دوره زمانی معقول اتفاق افتد، داده‌های مربوطه قابل اطمینان بوده و باید آنها را در آموزش شبکه در نظر گرفت. در غیر این صورت باید مورد استثنا واقع شوند. سومین گروه شامل متغیرهای جریانی می‌باشد که تغییرات زیادی در یک دوره کوتاه زمانی دارند. هنگامی که پارامترهای مربوط به این گروه رفتار غیر معقولی از خود نشان می‌دهند، برای جلوگیری از اشتباه افتادن شبکه، داده‌های مورد نظر از مجموعه داده‌ها باید حذف گردند زیرا ارزیابی مقادیر اندازه‌گیری شده چنین پارامترهایی غیرممکن می‌باشد. بعد از ارزیابی داده‌های جمع‌آوری شده، ۹ داده نویز به دست آمد. از بین این ۹ داده، ۶ داده ناشی از بد عمل کردن ابزارهای اندازه‌گیری بود. این ۶ داده از مجموعه داده‌ها حذف گردیدند. ۳ داده نویز باقی مانده نیز تصحیح و برای شرایط فرآیند واقعی به کار گرفته شدند.



۲-۵-۳- مقدار دهی اولیه وزن‌ها

بعد از تعیین تعداد لایه‌ها و تعداد نورون‌های هر یک از این لایه‌ها و قبل از آغاز فرآیند آموزش شبکه، وزن‌های شبکه باید تنظیم گردند. در غیر اینصورت متلب (نرم‌افزار مورد استفاده در این کار) با مقادیر تصادفی مقدار دهی اولیه وزن‌ها را انجام خواهد داد. فرآیند آموزش شبکه عصبی با الگوریتم پس‌انتشار خطا را می‌توان به‌عنوان یک فرآیند بهینه‌سازی جهت به حداقل رساندن خطا از طریق دستکاری وزن‌های شبکه توصیف نمود. الگوریتم پس‌انتشار خطا از تکنیک‌های بهینه‌سازی محلی برای رسیدن به حداقل خطا استفاده می‌نمایند [۸]. تعریف مینیمم محلی توسط الگوریتم از مراحل اساسی فرآیند آموزش و به تبع آن تعیین خروجی شبکه می‌باشد. در صورتی که مینیمم‌های انتخابی به مینیمم مطلق نزدیک باشد، پاسخ شبکه به مقدار واقعی نزدیک می‌گردد. در غیر این صورت شبکه عصبی عملکرد ضعیفی جهت تولید پاسخ‌های نزدیک به فرآیند واقعی خواهد داشت. تعیین مینیمم‌های محلی در رویه پس‌انتشار خطا به کمک فرآیند مقداردهی اولیه وزن‌های شبکه کنترل می‌گردد. علاوه بر این، مقداردهی اولیه وزن‌ها، نقش مهمی در سرعت همگرایی شبکه ایفا می‌کند [۸]. روش مورد استفاده در مقداردهی اولیه وزن‌ها در این کار بسیار ساده بوده ولی عملکرد بالایی دارد. در این روش ابتدا مقدار صفر به‌عنوان مقدار اولیه همه اتصالات وزنی لایه‌های

ساختارهای مختلف شبکه به همراه عملکرد آن را نشان می‌دهد. طبق نتایج به‌دست آمده، شبکه با دو لایه نهان بهترین عملکرد را دارد. توانایی شبکه عصبی جهت یادگیری توابع نگاشت پیچیده با انتخاب درست تعداد نورون‌های موجود در لایه‌های نهان بهبود می‌یابد [۷]. تعداد نورون‌های موجود در لایه‌های نهان تاثیر به‌سزایی در عملکرد شبکه عصبی خواهد گذاشت. استفاده از تعداد نورون کم، مانع از یادگیری دقیق اغلب الگوهای موجود توسط شبکه عصبی می‌شود. از سویی دیگر، وجود تعداد بالای نورون‌ها منجر به حفظ کردن الگوها شده و در نتیجه مانع از یادگیری تشخیص ویژگی‌های اساسی آنها توسط شبکه عصبی می‌گردد. جدول ۵- عملکرد یک شبکه دو لایه را با تعداد نورون‌های مختلف نشان می‌دهد. برای تعیین تعداد نورون، باید کمترین تعداد نورون که باعث عملکرد مناسب شبکه می‌گردد، انتخاب شود. با توجه به نتایج جدول ۵- شبکه‌ای دو لایه با تعداد نورون ۳۰:۲۰ جهت استفاده در این تحقیق انتخاب می‌گردد.

جدول ۳ | توابع انتقال انتخابی در یک شبکه با یک لایه نهان

| عملکرد شبکه | | تابع انتقال | |
|-------------|----------------|---------------|--------------|
| MSE | R ^۲ | Hidden-Output | Input-Hidden |
| ۲۳ | ۰/۹۰۸ | Purelin | Tansig |
| ۳۶ | ۰/۸۷۶ | Purelin | Logsig |
| ۴۲ | ۰/۸۶۶ | Logsig | Tansig |
| ۳۲ | ۰/۸۸۱ | Tansig | Logsig |
| ۴۰ | ۰/۸۶۹ | Logsig | Purelin |
| ۳۸ | ۰/۸۷۲ | Tansig | Purelin |
| ۲۹ | ۰/۹۰۴ | Tansig | Tansig |
| ۲۸ | ۰/۸۹۵ | Logsig | Logsig |

جدول ۵ | عملکرد شبکه عصبی تک لایه با تعداد نورون‌های مختلف

| MSE | R ^۲ | تعداد نورون‌ها |
|-----|----------------|----------------|
| ۲۱ | ۰/۹۰۴۷ | ۱۰-۲۰ |
| ۱۷ | ۰/۹۲۹۸ | ۲۰-۳۰ |
| ۲۳ | ۰/۹۰۰۴ | ۳۰-۴۰ |


جدول ۶ | عملکرد شبکه با دو روش مقداردهی اولیه وزن‌ها

| MSE | R ^۲ | روش مقداردهی اولیه |
|-----|----------------|--|
| ۲۰ | ۰/۹۱۲۵ | Weight and Bias Update |
| ۳۹ | ۰/۸۶۹۷ | Random Initialization method (Trail 1) |
| ۲۵ | ۰/۸۹۹۵ | Random Initialization method (Trail 2) |
| ۲۹ | ۰/۸۹۱۰ | Random Initialization method (Trail 3) |
| ۲۸ | ۰/۸۹۳۷ | Random Initialization method (Trail 4) |
| ۳۴ | ۰/۸۷۰۵ | Random Initialization method (Trail 5) |


جدول ۴ | عملکرد شبکه با یک یا دو لایه نهان

| MSE | R ^۲ | تعداد نورون‌ها | تعداد لایه‌ها |
|-----|----------------|----------------|------------------|
| ۲۹ | ۰/۸۴۰۷ | ۱۰ | ۳ (یک لایه نهان) |
| ۲۶ | ۰/۸۵۶۷ | ۲۰ | ۳ (یک لایه نهان) |
| ۲۳ | ۰/۸۸۶۶ | ۳۰ | ۳ (یک لایه نهان) |
| ۱۸ | ۰/۹۰۴۷ | ۱۰-۲۰ | ۴ (دو لایه نهان) |
| ۱۶ | ۰/۹۲۹۸ | ۲۰-۳۰ | ۴ (دو لایه نهان) |
| ۲۰ | ۰/۹۰۰۴ | ۳۰-۴۰ | ۴ (دو لایه نهان) |

محاسبه شده می باشد. شکل-۱۳ مقایسه بین داده‌های واقعی و پیش‌بینی شده را نشان می دهد. مدل ایجاد شده توسط شبکه عصبی در محدوده تعریف شده برای نرخ مصرف امولسیون زدا (GPD [188-18]) به درستی عمل می کند. این مدل برای داده‌های خارج از محدوده تعریف شده، عملکرد خوبی نخواهد داشت. نرخ مصرف امولسیون‌زدا تنها در هنگام آغاز به کار واحد، هنگام خاموش شدن واحد و یا نوسانات موجود در ترانسفورماتورها از حد مجاز تجاوز می نماید. براساس آنالیزهای انجام شده بر روی مجموعه داده‌های آموزش، در مرحله تعمیم، عملکرد شبکه جهت پیش‌بینی خروجی براساس مجموعه داده‌های جدید ارزیابی می شود. مجموعه داده‌های جدید شامل ۱۰۴ داده می باشند که به صورت تصادفی انتخاب شده‌اند. از آنجایی که شبکه عصبی مصنوعی در برون‌یابی داده‌ها ضعیف می باشد، داده‌های جدید باید درون محدوده داده‌های آموزش قرار داشته باشند. عملکرد این مرحله برحسب R^2 و MSE، به ترتیب ۰/۹۲۴۷ و ۱۵/۲ می باشد. در شکل-۱۴ داده‌های شبیه‌سازی شده در برابر داده‌های واقعی به دست آمده از واحد رسم شده‌اند. در این شکل، هر چقدر داده‌ها به خط $y=x$ نزدیک تر باشند، میزان R^2 بالاتر می رود و نشان‌دهنده عملکرد قابل قبول مدل است.



شکل ۱۳ | نمودار مقایسه داده‌های واقعی و شبیه‌سازی شده بر اساس مجموعه داده‌های مورد استفاده در آموزش شبکه



شکل ۱۴ | نمودار مقایسه داده‌های واقعی و شبیه‌سازی شده بر اساس مجموعه داده‌های جدید (استفاده نشده در آموزش شبکه)

اول و دوم قرار می گیرد. همچنین برای بایاس‌های لایه اول و دوم، مقدار یک در نظر گرفته می شود. سپس شبکه آموزش می بیند و مقادیر وزنی و بایاس لایه‌ها ذخیره می گردد. در ادامه، حلقه‌ای تعریف می شود که با استفاده از آن، شبکه از وزن و بایاس محاسبه شده برای آموزش خود استفاده کند. در این شرایط، در صورتی که عملکرد شبکه رو به بهبودی رود، وزن‌ها و بایاس‌های تولید شده جایگزین مقادیر قدیمی آنها می گردند. اجرای این رویه بر شبکه عصبی منجر به افزایش عملکرد شبکه می شود به طوری که MSE کاهش یافته و R^2 افزایش می یابد. جدول-۶ عملکرد شبکه به دست آمده از روش ارائه شده را با روش مقارنه اولیه تصادفی برای ۵ مرحله مختلف مقایسه می نماید.

۳- نتایج و بحث‌ها

شبکه عصبی مصنوعی طراحی شده در بخش قبل، عملکرد قابل قبولی را در R^2 و MSE از خود نشان داده است. در این بخش، توانایی شبکه عصبی در پیش‌بینی خروجی (نرخ مصرف امولسیون‌زدا) ارزیابی خواهد شد. سپس با استفاده از نرخ تزریق پیش‌بینی شده امولسیون‌زدا و یک شبکه آموزش دیده جدید (مطابق ساختار شبکه مورد استفاده در پیش‌بینی نرخ مصرف امولسیون‌زدا) به پیش‌بینی غلظت نمک موجود در نفت خروجی پرداخته می شود. نتایج به دست آمده از شبکه‌های ساخته شده با داده‌های واقعی به دست آمده از واحد نمک‌زدایی در همان شرایط عملیاتی، مقایسه می گردد. همچنین از شبکه مورد نظر جهت پیش‌بینی غلظت نمک در نفت، برای بهینه‌سازی نرخ مصرف امولسیون‌زدا در شرایطی که غلظت نمک به ۱۰ PTB کاهش یابد، استفاده می گردد. در این شرایط با استفاده از ژنتیک الگوریتم، مقدار بهینه نرخ مصرف امولسیون‌زدا در دماهای مختلف به دست می آید.

۳-۱- شبکه عصبی مصنوعی جهت پیش‌بینی نرخ مصرف امولسیون‌زدا

در فرآیند طراحی و آموزش شبکه عصبی مصنوعی، دقت شبکه درون حلقه‌ای که وزن‌ها و بایاس‌ها را برای رسیدن به مقادیر بهینه بر حسب R^2 و MSE مقدار دهی می کند، توسعه می یابد. معمولاً آزمایش شبکه عصبی در دو مرحله فراخوانی^۶ و تعمیم^۷ جهت ارزیابی عملکرد آن در پیش‌بینی خروجی‌ها، انجام می شود. در مرحله فراخوانی، مجموعه داده‌هایی که جهت آموزش شبکه استفاده شده‌اند، برای ارزیابی عملکرد شبکه به کار می روند. در مرحله تعمیم، عملکرد شبکه با استفاده از مجموعه داده‌های جدید، ارزیابی می گردد. در مرحله فراخوانی، در طول فرآیند آموزش، عملکرد شبکه در برابر داده‌های واقعی چک می گردد. دقت متوسط مقادیر پیش‌بینی شده برحسب R^2 و MSE، به ترتیب ۰/۹۲۷۸ و ۱۴/۸۱ می باشد. مقدار بالای R^2 نشان‌دهنده توانایی مدل در پیش‌بینی نرخ مصرف امولسیون‌زدا با دقت مناسب می باشد. انحراف متوسط بین خروجی مدل و داده‌های واقعی مربوط به نرخ مصرف امولسیون‌زدا برابر ۳/۸۴ می باشد. این انحراف، جذر دوم MSE

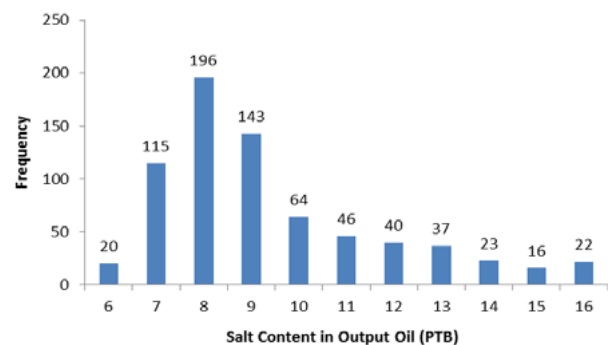
می‌کند. بنابراین نیاز به یک آنالایزور آنلاین نمک ضرورت می‌یابد. آنالایزورهای آنلاین نمک متعددی در بازار وجود دارند اما همه آنها به دلیل نیاز به نگهداری، دقت پایین نتایج و ناتوانی در راه‌اندازی آن بدون حضور یک اپراتور جهت پر کردن با مواد شیمیایی و تنظیم مجدد آن، جهت نصب در واحد مناسب نمی‌باشند. هدف از این بخش، طراحی و آموزش شبکه عصبی مصنوعی براساس داده‌های جمع‌آوری شده جهت پیش‌بینی غلظت نمک می‌باشد. ورودی‌های شبکه عصبی عبارت‌اند از دمای نفت‌خام، ولتاژ الکتروستاتیک نمک‌زدا، ولتاژ الکتروستاتیک نمزدا، نرخ آب شست‌وشو، میزان آب موجود در نفت‌خام ورودی، نرخ جریان کلی نفت‌خام و نرخ جریانی امولسیون‌زدا. در این مورد، یک شبکه عصبی مشابه با شبکه مورد استفاده جهت پیش‌بینی نرخ مصرف امولسیون‌زدا، برای پیش‌بینی غلظت نمک طراحی می‌گردد. شکل ۱۵- توزیع و فراوانی داده‌های مربوط به غلظت نمک را در نفت خروجی از واحد نشان می‌دهد. جهت ارزیابی عملکرد شبکه، از رویه‌ای مشابه با آنچه که در شبیه‌سازی نرخ امولسیون‌زدا به کار گرفته شد، استفاده می‌گردد. مرحله فراخوانی عملکرد شبکه را بر حسب R^2 و MSE، به ترتیب ۰/۹۵۳۴ و ۰/۵۷۹۰ نشان می‌دهد. دقت این مدل در شکل ۱۶- نشان داده شده است. آزمایش این مدل بر روی مجموعه جدیدی از داده‌ها، عملکرد شبکه را بر حسب R^2 و MSE، به ترتیب ۰/۹۴۴۲ و ۰/۶۰۲۳ نشان می‌دهد. در مرحله فراخوانی، بعد از گرد کردن نتایج برای نزدیک شدن آنها به یک عدد صحیح، مدل موردنظر در همه مجموعه داده‌های آموزش، عملکرد خوبی در پیش‌بینی خروجی داشته است به غیر از ۳۰ داده که با اختلاف ۱ PTB از داده‌های واقعی، به دست آمده‌اند. در مرحله تعمیم، بعد از گرد کردن نتایج برای نزدیک شدن آنها به یک عدد صحیح، مدل موردنظر در همه مجموعه داده‌های آزمایش، عملکرد خوبی در پیش‌بینی خروجی داشته است به غیر از ۲۰ داده که ۱۲ عدد از این ۲۰ داده با اختلاف ۱ PTB و باقی‌داده‌ها با اختلاف ۲ PTB از داده‌های واقعی، به دست آمده‌اند. شکل ۱۷- نتایج مرحله تعمیم را نشان می‌دهد.

۳-۳- بهینه‌سازی نرخ تزریق امولسیون‌زدا


در بخش قبل، مدلی جهت پیش‌بینی غلظت نمک در نفت خروجی از واحد ارائه شد. حال اگر غلظت پیش‌بینی شده بیشتر از مقدار قابل قبول یعنی ۱۰ PTB باشد، باید پارامترهای موثر بر غلظت نمک به نحوی تغییر کنند تا غلظت نمک موردنظر کمتر یا مساوی ۱۰ PTB شود. همچنین با توجه به محدودیت‌های اقتصادی، لازم است پارامترهای موثر بر غلظت نمک در مقدار بهینه خود قرار گیرند، به طوری که هم غلظت نمک قابل قبول به دست آید و هم از لحاظ اقتصادی صرفه‌جویی گردد. بنابراین در اینجا یک مسئله بهینه‌سازی ایجاد می‌گردد. در این بخش هدف، حداقل‌سازی غلظت نمک در نفت خروجی و رساندن آن به مقدار ۱۰ PTB با بهینه‌سازی پارامترهای موثر بر آن می‌باشد. پارامترهای مختلفی نظیر نرخ آب شست‌وشو، ولتاژ نمک‌زدا، ولتاژ

۳-۲- شبکه عصبی مصنوعی جهت پیش‌بینی غلظت نمک در نفت خروجی واحد نمک‌زدایی


در عملیات نمک‌زدایی، اندازه‌گیری نمک در نفت تولیدی باید مکرراً جهت کمک به رفع عیب فرآیند در زمانی کوتاه، فراهم شود. معمولاً روش مورد استفاده برای این کار، جمع‌آوری نمونه‌ها و آزمایش به صورت دستی می‌باشد. این روش دستی زمان زیادی جهت تولید داده‌های فوری نیاز دارد. همچنین برای اعمال این روش، تعداد افراد زیادی را هنگامی که سایر بخش‌ها به آنها نیاز دارند، درگیر خود



شکل ۱۵ | توزیع داده‌های غلظت نمک در نفت خروجی



شکل ۱۶ | نتایج مرحله فراخوانی برای تحلیل‌گر نمک طراحی شده با شبکه عصبی در مقایسه با داده‌های واقعی



شکل ۱۷ | نتایج مرحله تعمیم برای تحلیل‌گر نمک طراحی شده با شبکه عصبی در مقایسه با داده‌های واقعی


می‌باشد. بعد از پیش‌بینی نرخ تزریق امولسیون‌زدا نوبت به پیش‌بینی غلظت نمک در نفت خروجی می‌گردد. اگر غلظت نمک پیش‌بینی شده مناسب نبوده یا بیشتر از ۱۰ PTB باشد، با بهینه‌سازی نرخ تزریق امولسیون‌زدا، غلظت نمک باید به کمتر یا مساوی ۱۰ PTB برسد. برای اجرای این مسئله بهینه‌سازی، از ژنتیک الگوریتم استفاده می‌شود. برای بهینه‌سازی، ابتدا تابع هدف^۸ که باید حداقل شود، تعریف می‌گردد. در این تحقیق، تابع هدف به صورت زیر تعریف می‌شود:

$$\text{Objective Function} = \text{MSE (Model output - ۹)} \quad (۳)$$

در این معادله Model output در واقع همان غلظت نمک پیش‌بینی شده در نفت خروجی می‌باشد. برای اطمینان از اینکه در بدترین شرایط، غلظت نمک از ۱۰ PTB تجاوز نمی‌کند، این پارامتر در ۹ تنظیم می‌گردد.

۳-۴- شرایط بهینه در دماهای مختلف

با توجه به اینکه دما تاثیر به‌سزایی در تعیین مقدار نرخ تزریق امولسیون‌زدا دارد، به طوری که افزایش دما باعث کاهش مصرف امولسیون‌زدا و به عکس می‌گردد، بنابراین در بهینه‌سازی نرخ تزریق امولسیون‌زدا،



۱۸ | نرخ بهینه تزریق امولسیون‌زدا در دماهای مختلف

۹ | داده‌های واحد نمک‌زدایی اهواز ۳

| واحد | حد اقل | عامل |
|------------------|--------|---------------------------|
| % | ۱۱ | Water Cut |
| GPM | ۹۶ | Wash Water Rate |
| °C | ۱۰ | Oil Temperature |
| Volt | ۲۷۰۰۰ | Dehydrator Voltage |
| Volt | ۲۷۰۰۰ | Desalter Voltage |
| MBD | ۱۲۲ | Total Inlet Rate |
| g/m ³ | ۱۰۰۰۰ | Salt Content in Input Oil |
| lit/hrs | ۳۰ | Demulsifier Rate |

نمزا و نرخ تزریق امولسیون‌زدا و ... بر غلظت نمک تاثیر می‌گذارند. مسئله بهینه‌سازی که در این تحقیق مطرح می‌گردد، درجه پیچیدگی بالایی ندارد زیرا بعضی از پارامترها غیرقابل کنترل هستند و بعضی دیگر امکان کنترل آنها فراهم نمی‌باشد. پارامترهای قابل تنظیم شامل نرخ آب شست‌وشو، ولتاژ نمزدا، ولتاژ نمک‌زدا و نرخ تزریق امولسیون‌زدا می‌باشد. غلظت نمک در نفت خروجی از واحد به‌عنوان متغیر کنترل شده و دمای نفت و غلظت آب در نفت خام به‌عنوان پارامترهای غیرقابل کنترل مطرح می‌شوند. نرخ جریان نفت نیز پارامتری است که از لحاظ اقتصادی امکان کنترل آن فراهم نیست. در این کار با توجه به اهمیت نرخ تزریق امولسیون‌زدا و تاثیری که بر غلظت نمک می‌گذارد و قیمت بالای آن در بازار، مسئله بهینه‌سازی بر بهینه نمودن این پارامتر تمرکز می‌کند. به این ترتیب که برای ساده‌سازی مسئله بهینه‌سازی، سایر پارامترها به‌خصوص پارامترهای قابل کنترل ثابت فرض می‌شوند و تنها پارامتری که به بهینه‌سازی آن پرداخته می‌شود، نرخ تزریق امولسیون‌زدا

۷ | مقدار متوسط پارامترهای موثر بر غلظت نمک

| عامل | حد اقل | متوسط | حد اکثر | واحد |
|---------------------|--------|-------|---------|------|
| برش آب | ۵ | ۷ | ۲۰ | % |
| نرخ آب شست‌وشو | ۴۸ | ۴۸ | ۸۱ | GPM |
| ولتاژ نمزدا | ۱۰۰۰۰ | ۲۷۰۰۰ | ۳۵۰۰۰ | Volt |
| ولتاژ نمک‌زدا | ۱۰۰۰۰ | ۲۷۰۰۰ | ۳۵۰۰۰ | Volt |
| نرخ جریان نفت ورودی | ۲۰ | ۵۹ | ۱۳۲ | MBD |

۸ | نرخ بهینه تزریق امولسیون‌زدا در دماهای مختلف نفت

| دمای نفت (°F) | نرخ بهینه امولسیون‌زدا (GPD) |
|---------------|------------------------------|
| ۴۰ | ۱۶۰ |
| ۴۸ | ۱۴۱ |
| ۵۴ | ۱۳۰ |
| ۶۸ | ۱۱۴ |
| ۷۶ | ۱۰۸ |
| ۹۷ | ۹۴ |
| ۱۱۰ | ۸۴ |
| ۱۲۵ | ۷۳ |
| ۱۳۱ | ۷۰ |
| ۱۴۲ | ۶۸ |

باید شرایط دمایی در نظر گرفته شود. در این بخش، از رویه‌ای کاملاً یکسان با رویه انجام شده در قسمت‌های قبلی استفاده می‌گردد. در این رویه از همان تابع هدف تعریف شده در قسمت قبل و همچنین محدوده داده‌های ذکر شده در جدول ۱- استفاده می‌شود با این تفاوت که دمای نفت ورودی با مقادیر مختلفی که محدوده تعریف شده بین 40°F و 150°F را پوشش می‌دهند، تنظیم می‌گردند. سایر پارامترهای موثر بر غلظت نمک در مقدار متوسط خود قرار می‌گیرند. مقادیر متوسط پارامترها به گونه‌ای انتخاب می‌شوند که با توجه به داده‌های جمع‌آوری شده از واحدهای نمک‌زدایی، داده‌هایی که بیشترین فراوانی را دارند، به عنوان مقدار متوسط پارامتر مربوط انتخاب می‌گردند. در این کار با توجه به هیستوگرام‌های شکل‌های ۴- تا ۱۱، مقدار متوسط پارامترها انتخاب می‌گردد. مقدار متوسط این پارامترها در جدول ۷- آورده شده است. اجرای تغییرات ذکر شده در پاراگراف بالا در برنامه بهینه‌سازی ژنتیک الگوریتم، نتایج به دست آمده در جدول ۸- را به همراه دارد.

نتیجه گیری

نتایج به دست آمده نشان می‌دهد که با افزایش دما نرخ بهینه امولسیون‌زدا جهت رسیدن به غلظت نمک مناسب، کاهش می‌یابد. بنابراین جهت تعیین نرخ بهینه امولسیون‌زدا، باید شرایط فصلی و دمایی در نظر گرفته شود. با ارائه داده‌های عملیاتی برای پارامترهای موثر در نمک‌زدایی، مقدار $24/3391 \text{ lit/hrs}$ برای نرخ امولسیون‌زدا پیش‌بینی گردید. این مقدار جهت پیش‌بینی غلظت نمک در نفت خروجی مورد استفاده قرار گرفت. غلظت نمک به دست آمده کمتر از 10 PTB پیش‌بینی گردید که این حاکی از مناسب بودن نرخ پیش‌بینی شده امولسیون‌زدا می‌باشد. در حالی که تا قبل از این، مقدار 30 lit/hrs در شرایط عملیاتی مورد استفاده قرار می‌گرفت. بنابراین، با استفاده از مدل‌های ارائه شده در این کار و روش بهینه‌سازی هوشمند، حدود ۱۹ درصد در مصرف امولسیون‌زدا صرفه‌جویی گردید.

پانویس‌ها

- | | | |
|-----------------------|----------------------|------------------------|
| 1 - Mean Square Error | 3- Drip and Recovery | 5- Generalization Step |
| 2- Gallon Per Day | 4- Recall Step | 6- Objective Function |

منابع

- [1] Pak, A., and Mohammadi, T., "Wastewater Treatment of Desalting Units", Desalination, Vol. 222, pp. 249-254, 2008.
- [2] Abdel-Aal, H. K., Aggour, M., and Fahim, M. A., "Petroleum and Gas Field Processing", 1st edition, Marcel Dekker, Inc. New York, 2003.
- [3] Al-Otaibi, M. B., Elkamel, A., Nassehi, V., and Abdul-Wahab, S. A., "A Computational Intelligence Based Approach for the Analysis and Optimization of a Crude Oil Desalting and Dehydration Process", Energy & Fuel, Vol.19, pp. 2526-2534, 2005.
- [4] صفوی، محمدعلی و گلپاشا، رحمت اله، "شبه سازی و بررسی عملکرد نمک‌زدای پالایشگاه بندرعباس"، فرآیند نو، فصلنامه تخصصی، شماره ۴۳، پاییز ۱۳۹۲
- [5] Lewis-Beck, M. S., Bryman, A. and Liao, T. F., "The Sage Encyclopaedia of Social Science Research Methods", pp. 725-727, 2007.
- [6] مهدی، علیرضا، "مقدمه‌ای بر الگوریتم ژنتیک و کاربردهای آن"، تهران: انتشارات ناقوس، ۱۳۸۶
- [7] Kamel, I., "Optimization and Neural Network Model", PhD Thesis, Department of Electrical and Computer Engineering, University of New Brunswick, 1999.
- [8] Mercedes, F. R., and Carlos, H. E., "Weight Initialization Methods for Multilayer Feedforward", D-Facto public, European Symposium on Artificial Neural Networks Bruges (Belgium), pp. 25-27, 2001