

پیش‌بینی ضریب نفوذ مولکولی گاز در نفت خام با استفاده از مدل سازی شبکه‌های عصبی مصنوعی

عباس شهرآبادی*، پژوهشگاه صنعت نفت • محبوبه دریاپور، افروز جعفری، دانشگاه آزاد اسلامی واحد ماهشهر • محمد جامی‌الاحمدی، دانشگاه صنعت نفت اهواز |

اطلاعات مقاله

تاریخ ارسال نویسنده: ۹۶/۰۵/۲۳
تاریخ ارسال به داور: ۹۶/۰۵/۲۸
تاریخ پذیرش داور: ۹۶/۰۷/۰۶

واژگان کلیدی:

مدل‌سازی، ضریب نفوذ مولکولی، شبکه‌های عصبی مصنوعی، پرسپترون چندلایه، الگوریتم پس‌انتشار خطا

چکیده

در این مطالعه یک شبکه‌ی عصبی مصنوعی جهت پیش‌بینی ضریب نفوذ مولکولی گاز در نفت در شرایط واقعی مخزن در دما و فشار زیاد طراحی و استفاده شد. جهت به دست آوردن متغیرهای ورودی شبکه روابط تجربی ارائه شده در نوشته‌جات به‌طور کامل مرور و مشخص شد که متغیرهای متعددی از قبیل دما، فشار، گرانیوی گاز و مایع، جرم مولکولی گاز و مایع، حجم مولی گاز و مایع و کشش سطحی از جمله متغیرهای مؤثرند. بنابراین متغیرهای مذکور به‌عنوان ورودی شبکه در نظر گرفته شدند. در این کار از شبکه‌ی پرسپترون چندلایه برای پیش‌بینی و الگوریتم آموزش پس‌انتشار خطا استفاده شده و همچنین توابع آستانه‌ی مختلفی برای یافتن حالت بهینه‌ی آن ارزیابی شد. سپس با مراجعه به گزارش‌ها و مقالات تعداد ۱۷۲ داده‌ی آزمایشگاهی ضریب نفوذ جمع‌آوری و ۹۰ درصد داده‌ها جهت آموزش شبکه و بقیه برای آزمایش شبکه استفاده گردید. نتایج نشان می‌دهد مدل ارائه شده در این تحقیق ضریب نفوذ مولکولی متان در نفت خام را با دقت خوبی پیش‌بینی می‌کند و بنابراین می‌توان از این روش جهت پیش‌بینی ضرایب نفوذ استفاده کرد.

مقدمه

بر اساس معادله‌ی استوکس-اینشتن^۱ است که طبق رابطه‌ی ۲- نفوذ و گرانیوی با یکدیگر به‌طور معکوس مرتبط هستند [۴]:

$$D_{AB}^0 = \frac{\kappa_B T}{6\pi\mu_B r_A} \quad (2)$$

که در آن D_{AB}^0 ضریب نفوذ در حلال بی‌نهایت رقیق B و κ_B ثابت بولتزمن، μ_B گرانیوی حلال و r_A شعاع نفوذ مولکول هاست. این رابطه‌ی ساده تنها اگر مولکول‌های حلال خیلی بزرگ باشند معتبر است. از دیگر روابط تجربی که توسط آنها می‌توان ضریب نفوذ بی‌نهایت رقیق در مایعات را بر حسب خواص حلال و جزء حل‌شونده به‌دست آورد رابطه‌ی ویک-چنگ^۲ است (رابطه‌ی ۳- [۵]):

$$\frac{D_{AB}^0}{T} = \frac{7/4 \times 10^{-8} \sqrt{(Mw_B \Phi)}}{v_{AB}^{0/6}} \quad (3)$$

بر اساس همین رابطه و تصحیح آن توسط شیل^۳ [۶] و ردی^۴ [۷] روابط دیگری نیز ارائه شد. برای تعیین ضریب نفوذ در فشار زیاد استفاده از اصل حالات متناظر بهترین گزینه است [۸]:

$$\frac{\rho D}{\rho_0 D_0} = F(\rho_r, T_r, Z_r) \quad (4)$$

در سال‌های اخیر، مسأله‌ی انتقال جرم توسط مکانیسم نفوذ مولکولی در مخازن نفتی، وقتی در شرایط عدم تعادل گاز به مخزن تزریق می‌شود اهمیت ویژه‌ای یافته است [۱ و ۲]. وقتی گاز در تماس با مایع قرار می‌گیرد به‌دلیل وجود گرادیان غلظت، جرم از سطح مایع به توده‌ی مایع انتقال می‌یابد. شار مولی انتقال جرم توسط قانون اول فیک طبق رابطه‌ی ۱- ارائه شده است [۳]:

$$j_A = -D_{AB} \frac{\partial C_A}{\partial x} \quad (1)$$

ثابت تناسب، ضریب نفوذ مولکولی نام دارد. در طراحی پروژه‌های ازدیاد برداشت از مخازن و نیز بررسی موقعیت هیدرودینامیکی سیستم از ضریب نفوذ متان در هیدروکربن‌ها به‌عنوان داده‌ی پایه‌ای استفاده می‌شود. از نظر تجربی روش‌های مختلفی جهت تخمین ضریب نفوذ متان در هیدروکربن‌های نفتی مختلف پیشنهاد شده است. معمولاً برای پیش‌بینی ضریب نفوذ گازها در مایعات در دماها و فشارهای زیاد باید دو گام طی شود. ابتدا ضریب نفوذ در حالت بی‌نهایت رقیق، D_{AB}^0 با روش مناسب به‌دست می‌آید. سپس توسط دیگر روابط پیشنهاد شده اثرات متغیرهای عملیاتی مثل فشار روی ضریب نفوذ اعمال شود. روابط تجربی توسعه‌یافته برای فشارهای کم در سیستم‌های گاز-مایع

این ساختار با تعیین تعداد لایه‌ها، تعداد نرون‌ها در هر لایه، تابع محرک (کنترل‌کننده خروجی هر نرون)، روش آموزش، الگوریتم تصحیح وزن‌ها و نوع مدل، تعیین می‌شود [۲۱].

مدل‌سازی به روش شبکه‌های عصبی مصنوعی جهت تخمین توابع پیچیده در ارزیابی تعادل و خواص انتقالی، نظیر محاسبات تعادلی بخار-مایع [۲۳ و ۲۴]، حلالیت [۲۵ و ۲۶]، ضریب هدایت گرمایی [۲۷-۲۹] بسیار مناسب هستند. مروری بر مفاهیم شبکه‌های عصبی توسط اسلام‌لویان انجام شده است. او با استفاده از شبکه‌ای سه‌لایه و با انتخاب متغیرهای دما، دمای بحرانی، حجم بحرانی و وزن ملکولی توانست ضریب نفوذ را در شرایط اتمسفری تخمین بزند [۳۰]. بیگ‌زاده و همکاران از شبکه‌های عصبی مصنوعی جهت پیش‌بینی ضریب نفوذ ملکولی گازها در مایعات استفاده کردند. الگوریتم به کار رفته توسط آنها لوبرگ-مار کوارت است. در این مطالعه از متغیرهای حجم مولی، گرانیوی و کسر مولی هر جزء به عنوان ورودی شبکه استفاده گردید و شبکه‌ی آنها با دقت خوبی ضریب را پیش‌بینی نمود [۳۱].

در این مطالعه از یک شبکه‌ی پرسپترون چندلایه به همراه الگوریتم پس‌انتشار خطا استفاده شد که به عنوان یکی از قوی‌ترین الگوریتم‌های مورد استفاده در شبکه‌های عصبی مصنوعی، به خصوص جهت تخمین توابع پیچیده شناخته شده است. همچنین تمامی متغیرهای مؤثر به عنوان ورودی شبکه در نظر گرفته شد که این متغیرها شامل دما، فشار، گرانیوی گاز و مایع، جرم مولکولی گاز و مایع، حجم مولی گاز و مایع و کشش سطحی هستند و تابعیت ضریب نفوذ طبق رابطه‌ی ۷- است:

$$D = F(T, P, \mu_g, \mu_L, Mw_g, Mw_L, v_g, v_L, \sigma) \quad (7)$$

۱- طراحی شبکه و نتایج

در ابتدا باید شبکه‌ی عصبی مناسبی جهت تعیین ضریب نفوذ مولکولی در نظر گرفته و به تعیین ورودی‌ها و خروجی‌های ضروری و تشکیل لایه‌ها و تعداد نرون‌های مورد نیاز در هر لایه پرداخته شود. در مرحله‌ی اول انتخاب متغیرها (به عنوان ورودی بسیار مؤثر در بهینه‌سازی شبکه‌ی عصبی) است انجام می‌شود. متغیرهای ورودی باید طوری انتخاب گردند که بیشترین رابطه را با خروجی داشته باشند؛ به طوری که هرگونه کاهش یا افزایش در روند ورودی مورد نظر، در خروجی اثر گذاشته و باعث تغییر و نوسان روند خروجی نیز گردد. برای انتخاب ورودی‌ها و دست یافتن به روابط بین ورودی‌ها و خروجی‌ها راه‌های زیادی وجود دارد که راحت‌ترین آنها استفاده از روابط

مروری بر کارهای گذشته حاکی از روابط زیادی در قالب معادله‌ی فوق در شرایط عملیاتی است. مثلاً سیگموند^۵ تعدادی داده‌ی آزمایشگاهی به دست آورده و رابطه‌ی ۵- را پیشنهاد کرد [۹]:

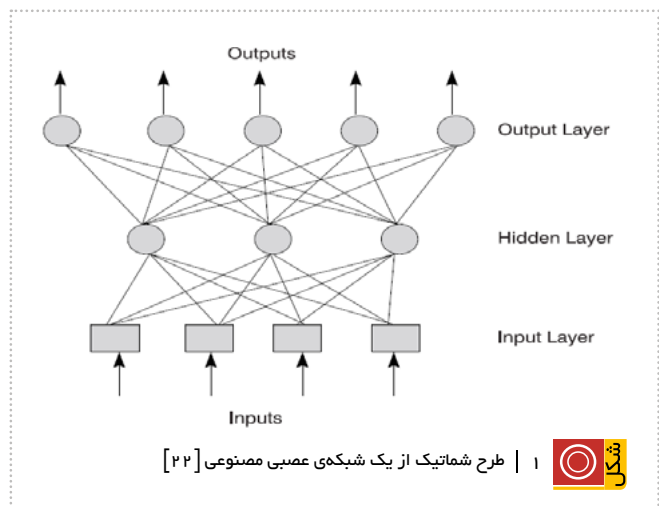
$$\frac{\rho D}{\rho_0 D_0} = 0.99589 + 0.09601\rho_r - 0.22035\rho_r^2 + 0.032874\rho_r^3 \quad (5)$$

که در آن $\rho_0 D_0$ حاصل ضرب چگالی در ضریب نفوذ در فشار کم است و چگالی کاهیده‌ی مورد استفاده در معادله طبق رابطه‌ی ۶- استفاده می‌شود:

$$\rho_r = \frac{\rho}{\rho_c} \quad (6)$$

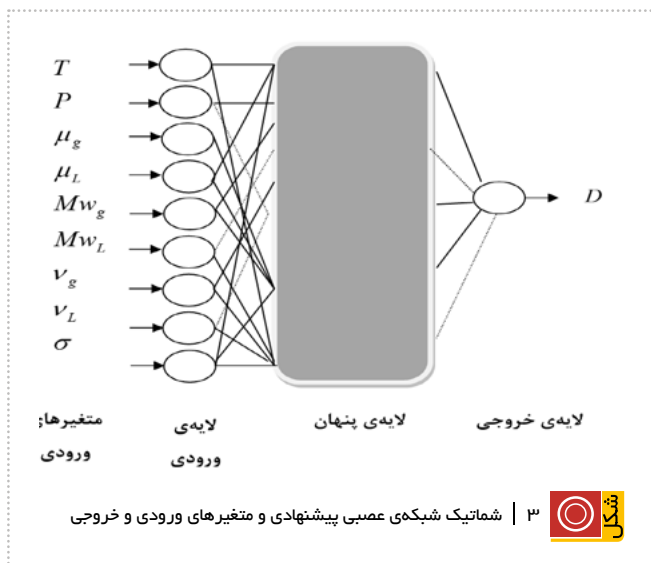
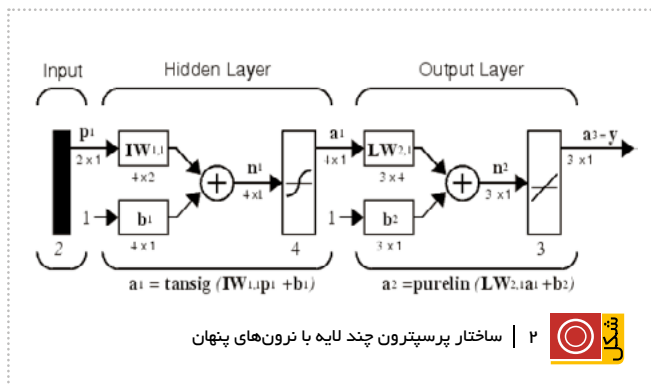
تعدادی دیگر از روابط تجربی برای پیش‌بینی ضریب نفوذ در فشار زیاد ارائه شده که اغلب آنها از فرم معادله‌ی سیگموند پیروی می‌کنند [۱۶-۱۰]. برخی از این معادلات و شرایط کاربردی آنها توسط جامی‌الاحمدی و همکاران مرور و با داده‌های آزمایشگاهی مقایسه شده‌اند [۱۷]. این ارزیابی حاکی از تناقضات زیادی در پیش‌بینی ضریب نفوذ و نیز روند (شیب) تغییرات آنست.

یک روش مناسب جهت مدل‌سازی و پیش‌بینی ضریب نفوذ استفاده از شبکه‌های عصبی مصنوعی است که اخیراً به عنوان ابزاری قدرتمند برای مدل‌سازی فرآیندهای پیچیده توسعه یافته است [۱۹-۱۸]. شبکه‌های عصبی مصنوعی با الهام از ساختار مغز و عملکرد موازی آن، داده را پردازش کرده، مدل‌های توزیع شده را یاد می‌گیرند و قادرند روابط پیچیده‌ی بین متغیرها را شناسایی کنند [۲۰]. ساختار یک شبکه‌ی عصبی مصنوعی از سه لایه تشکیل شده است. لایه‌ی ورودی که اطلاعات ورودی به مدل به آن معرفی می‌شود، لایه یا لایه‌های مخفی که در واقع پردازش‌کننده‌ی اطلاعات هستند و لایه‌ی خروجی که نتایج حاصل از عملکرد مدل، تولید و ارائه می‌شود. در شکل ۱- این ساختار نشان داده شده است.



نرون‌ها وجود ندارد باید این متغیرها را از روش سعی و خطا تعیین کرد. بنابراین شبکه‌های متعددی با تعداد نرون‌ها و لایه‌های مخفی مختلفی طراحی شدند. هدف از ایجاد تغییر در تعداد نرون‌ها و لایه‌های پنهان، تعیین تعداد بهینه‌ی عنصر پردازشگر (نرون) و لایه‌ی میانی است که قادر به یادگیری روابط موجود بین متغیرهای ورودی و خروجی با کمترین خطا و مدت زمان محاسبه باشد. بنابراین از میان شبکه‌های مختلف، بهترین شبکه از نوع شبکه‌ی پرسپترون چند لایه با ساختار لایه‌ای به صورت (۱-۲-۱) انتخاب شد. در شکل-۲ نمونه‌ای از یک شبکه‌ی پرسپترون چند لایه نشان داده شده است.

بنابراین، با استفاده از نرم‌افزار مطلب و به روش حدس و خطا، مورفولوژی شبکه‌ی عصبی طراحی شده بدین صورت است: دو لایه‌ی میانی (پنهان) هجده نرون در روی هر لایه، به تعداد هر ورودی مورد استفاده در شبکه‌ی یک نرون و در مجموع ۳۰ نرون در لایه‌ی ورودی تعبیه می‌گردد. شکل-۳ شماتیک شبکه‌ی عصبی پیشنهادی و متغیرهای ورودی و خروجی را نشان می‌دهد. از دیگر موارد مهم انتخاب الگوریتم آموزش شبکه است که در این مطالعه از الگوریتم پس‌انتشار خطای جلورونده^۶ برای



تجربی ارائه شده توسط محققان مختلف است. این روابط همچنین برای محاسبه‌ی ضریب نفوذ مولکولی گاز در مایع با در نظر گرفتن محدودیت‌هایی به کار می‌روند. با توجه به این روابط و ضرایب متغیرهای آن، می‌توان تا حدودی فهمید که ضریب نفوذ مولکولی گازها در مایعات (خروجی شبکه عصبی)، تحت تأثیر چه متغیرهایی (ورودی‌های شبکه) هستند و این اثر چقدر است؟ با مروری بر چنین روابطی ورودی‌های شبکه بدین صورت انتخاب شد: دما، فشار، حجم مولی مایع، حجم مولی گاز، جرم مولکولی مایع، جرم مولکولی گاز، گرانشی مایع، گرانشی گاز، کشش سطحی. در جدول-۱ محدودی تغییرات هر یک از ورودی‌ها و حدود تغییرات ضریب نفوذ مولکولی به‌عنوان متغیر خروجی آمده است.

در مرحله‌ی بعد انتخاب نوع شبکه از مهم‌ترین مراحل طراحی است. شبکه‌ی پرسپترون چند لایه به‌طور وسیعی به‌عنوان مدل‌های بسیار کارآ، جهت یادگیری روابط غیرخطی بین متغیرهای ورودی و خروجی استفاده می‌شوند. توپولوژی شبکه شامل سه لایه از نرون‌هاست که عبارتند از لایه‌ی ورودی، لایه‌ی پنهان و لایه‌ی خروجی. تعداد نرون‌های لایه‌ی ورودی و خروجی معادل متغیرهای ورودی و خروجی در نظر گرفته می‌شود. در مرحله‌ی بعد، تعداد لایه‌ها و تعداد نرون‌های موجود در لایه‌ی مخفی، جزء مهم‌ترین متغیرهای طراحی شبکه به‌شمار می‌روند. با توجه به اینکه تئوری دقیقی جهت انتخاب تعداد لایه‌های درونی و همچنین تعداد

جدول ۱ | محدودی داده‌های ورودی و خروجی جهت آموزش، آزمایش و ارزیابی شبکه

متغیر	متغیر	حد اقل	حد اکثر
دما (°C)	۲۰	۸۵	
فشار (kPa)	۱۱۹۰	۳۳۰۰۰	
گرانشی فاز مایع (cP)	۰/۱۷۱۱	۰/۳۹۷۴	
گرانشی فاز گاز (cP)	۰/۰۱۰۲	۰/۰۲۸۵	
حجم مخصوص فاز مایع (m ³ /kg)	۰/۱۱۰۱۳	۰/۲۱۱۱۴	
حجم مخصوص فاز گاز (m ³ /kg)	۰/۰۷۵۱۶	۰/۲۰۳۰۷	
جرم مولکولی مایع (g/mole)	۷۰/۱۷	۱۵۵	
جرم مولکولی گاز (g/mole)	۱۶/۰۵	۱۷/۸۳	
کشش بین سطحی (dyne/cm)	۰/۶۷	۱۷/۷۴۲۲	
ضریب نفوذ (m ² /sec)	۱/۷۴ × ۱۰ ^{-۸}	۷/۵۱ × ۱۰ ^{-۹}	

شود. زمان آموزش باید به اندازه‌ی کافی طولانی باشد تا شبکه بتواند تمامی نمونه‌های ایجاد شده را یاد بگیرد. همچنین باید از آموزش اضافی شبکه جلوگیری به عمل آید. این پدیده باعث به یاد سپردن داده‌های ورودی توسط شبکه می‌شود. تنها متغیری که نیاز به آموزش دارد تابع وزن‌های خطی در لایه‌ی خروجی است. بنابراین از داده‌های آزمایشگاهی که از پژوهش‌های قبلی [۱۷ و ۱۵ و ۹] در این زمینه گردآوری شده بود برای دستیابی بدین مهم استفاده شده که ۹۰ درصد از این داده‌ها (۱۵۵ نقطه) جهت آموزش شبکه‌ی عصبی مورد نظر و از ۱۰ درصد (حدود ۱۷ نقطه) نیز برای آزمایش و ارزیابی عملکرد شبکه استفاده گردید. طی آموزش با ناظر شبکه باید شبکه‌ای با مقادیر صحیح ضریب نفوذ ملکولی به‌ازای هر ورودی ایجاد شود. شبکه با پس‌انتشار دادن خطای موجود بین ضرایب نفوذ پیش‌بینی شده و مقادیر واقعی آن همگرا خواهد شد. در مرحله‌ی آموزش وزن‌های شبکه به‌طور دائم تا نزدیک شدن خروجی شبکه (ضریب نفوذ ملکولی) به خروجی هدف یا همگرا شدن (بدون حفظ کردن) تغییر می‌یابد. در صورت موفقیت، با همان وزن‌ها شبکه به مرحله‌ی آزمایش می‌رود. در شکل-۵ نتایج حاصل از عملیات آموزش شبکه نشان داده شده است. همان‌طور که مشاهده می‌شود نتایج رضایت‌بخش بوده و مرحله‌ی آموزش شبکه به‌خوبی به پایان رسیده است. در نمودار شکل-۱۵ اکثر نقاط به خط میانی نزدیک بوده و از آن فاصله نمی‌گیرند. برای ارزیابی عملکرد مدل از متغیر ضریب همبستگی که طبق رابطه‌ی ۸- تعریف می‌شود استفاده گردید:

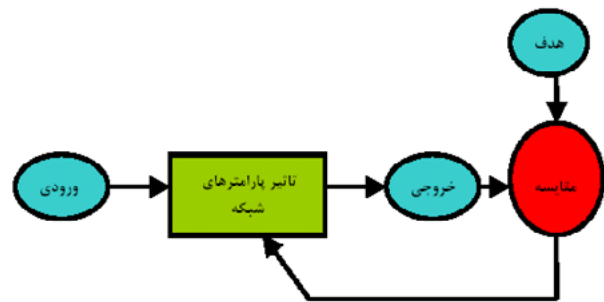
$$R^2 = 1 - \frac{\sum_{i=1}^N (D^{model} - D^{Exp})^2}{\sum_{i=1}^N (\bar{D} - D^{Exp})^2} \quad (8)$$

نزدیک بودن این مقدار به واحد نشان‌دهنده‌ی آنست که خروجی واقعی به هدف نزدیک شده است. اما اگر خروجی شبکه با مقادیر هدف کمی فرق داشته باشد خط متناظر عبوری از بین این نقاط نیز از خط ۴۵° فاصله می‌گیرد که مقدار این فاصله همان خطای R^2 است. مرحله‌ی بعد

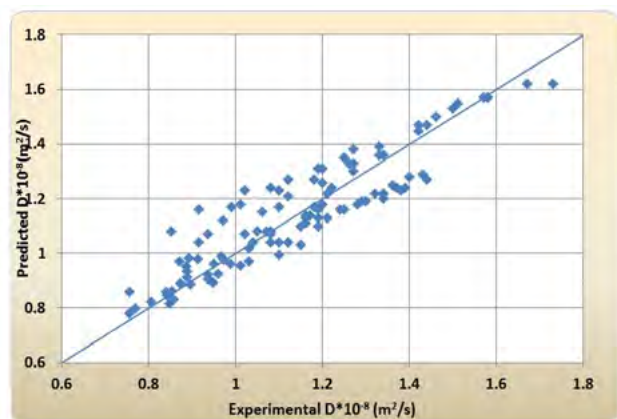
جدول ۲ | مقایسه‌ی خطاهای حاصل از مدل‌سازی ضریب نفوذ متان در نخت‌خام توسط شبکه‌ی عصبی MLP

مرحله	R^2
مرحله‌ی آموزش	۰/۸۸۷
مرحله‌ی آزمایش	۰/۸۹۴

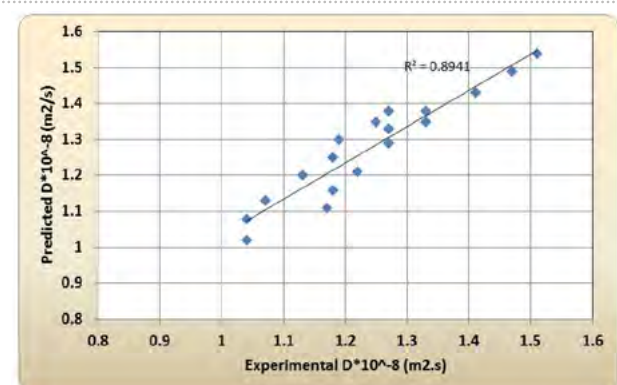
دستیابی به اهداف مورد نظر استفاده شد. در شکل-۴ شمای ساده‌ای از الگوریتم عملیاتی که توسط این نوع شبکه برای تنظیم مشخصه‌های آن استفاده می‌شود ارائه شده است. همان‌طور که در شکل-۴ نیز دیده می‌شود نرخ یادگیری شبکه با توجه به کمینه‌سازی زمان آموزش آن تنظیم می‌گردد. در طول آموزش باید چندین متغیر به‌دقت بررسی



شکل ۴ | شمایی از الگوریتم شبکه‌ی پس‌انتشار خطا



شکل ۵ | مقایسه‌ی ضرایب نفوذ پیش‌بینی شده توسط شبکه‌ی عصبی طراحی شده با مقادیر آزمایشگاهی در مرحله‌ی آموزش شبکه



شکل ۶ | مقایسه‌ی ضرایب نفوذ پیش‌بینی شده توسط شبکه‌ی عصبی طراحی شده با مقادیر آزمایشگاهی در مرحله‌ی آموزش شبکه

نتیجه گیری

در این مطالعه جهت پیش‌بینی ضریب نفوذ ملکولی گاز در نفت خام در شرایط مخزن نفتی، از شبکه‌ی عصبی مصنوعی استفاده شد. در این کار متغیرهایی مثل دما، فشار، حجم مولی مایع، حجم مولی گاز، جرم مولکولی مایع، جرم مولکولی گاز و گرانشی مایع، گرانشی گاز و کشش سطحی به‌عنوان ورودی شبکه در نظر گرفته شد. از تعداد ۱۷۲ داده‌ی آزمایشگاهی اندازه‌گیری شده توسط محققان قبلی، به ترتیب ۹۰ درصد جهت آموزش شبکه و بقیه جهت پیش‌بینی به کار گرفته شد. شبکه‌های مختلف با تعداد لایه‌ها و نرون‌های مختلفی مورد آزمون قرار گرفت و در نهایت شبکه از نوع پرسپترون چند لایه با الگوریتم آموزش پس‌انتشار خطا به تعداد دو لایه‌ی پنهان جهت ادامه کار انتخاب گردید. با آزمایش این شبکه‌ی نهایی، ضریب همبستگی ۰/۸۹۴ محاسبه شد. نتایج این تحقیق نشان‌دهنده‌ی آنست که استفاده از چنین شبکه‌هایی می‌تواند جایگزینی برای حل مسائل پیچیده باشد. در این مورد که ضریب نفوذ ملکولی تابعی از متغیرهای زیادی بود و طبیعت بسیار پیچیده‌ای داشت استفاده شد و نتایج مطلوبی به‌دست آمد.

آزمایش و ارزیابی شبکه است که این کار با ۱۷ نقطه با موفقیت انجام گردید. در مرحله‌ی آزمایش، ورودی‌های جدید به شبکه خوراندند شد که شبکه قبلاً در مرحله‌ی آموزش این داده‌ها را ندیده بود. این شبکه سپس توانست با توجه به آموزش‌های مرحله‌ی قبل خروجی‌های مربوطه را پیش‌بینی کند. پس از اتمام مرحله‌ی آزمایش و پیش‌بینی خروجی‌ها یا همان ضرایب نفوذ ملکولی توسط شبکه، می‌توان نمودار پراکندگی خروجی‌های واقعی و هدف را مانند مرحله‌ی قبل (آموزش)، برای مرحله‌ی آزمایش نیز رسم کرد. خطای R^2 یا ضریب همبستگی در حقیقت همان تفاوت بین داده‌های واقعی و داده‌های هدف است. این خطا نشان‌دهنده‌ی کیفیت شبکه طراحی شده که خود تابع متغیرهایی است که در قسمت‌های قبلی این متغیرها تک‌تک تشریح شد. شکل ۶- همگرایی بین داده‌های حقیقی و خروجی شبکه‌ی عصبی را در مرحله‌ی آزمایش نشان می‌دهد که تقریباً حدود ۰/۹ است. در جدول ۲- خطاهای حاصل از این مدل‌سازی ارائه شده است.

پانویس‌ها

- | | | |
|-------------------|----------------------------------|-----------------|
| 1. Stokes-Enstein | 4. Reddy | 7. Overtraining |
| 2. Wilke -Change | 5. Sigmund | |
| 3. Scheibel | 6. Feed Forward Back Propagation | |

منابع

- [1] Burger, J. E. and Mohanty, K. K., "Mass transfer from by-passed zones during gas injection". SPE 30768, Presented at the Annual Technical Conference and Exhibition held in Dallas, Texas, USA, 22-25 October, 1995
- [2] LeGallo, Y., LeRomancecer, J. F. and Bourbiaux, B., "Mass transfer in fractured reservoirs during gas injection: experimental and numerical modeling" SPE 38924, Texas, 5-8 October, 1997
- [3] Treybal, Robert E, "Mass Transfer Operations" Published by McGraw-Hill Education, ISBN 10: 0070651892
- [4] Christina Cruickshank Miller, "The Stokes-Einstein Law for Diffusion in Solution" Proceedings of the Royal Society of London. Series A, Containing Papers of a Mathematical and Physical Character, Vol. 106, No. 740 (Dec. 1, 1924), pp. 724-749
- [5] Ramalingam Sitaraman, S. H. Ibrahim, N. R. Kuloor, "A Generalized Equation for Diffusion in Liquids" J. Chem. Eng. Data, 1963, 8 (2), pp 198-201
- [6] Scheibel, E.G. "Correspondence. Liquid diffusivities. Viscosity of gases." Ind. Eng. Chem., Vol. 46, (1954).
- [7] K.A. Reddy, L.K. Doraiswamy, "Estimating liquid diffusivity" Ind. Eng. Chem. Res., 6 (1967)
- [8] S. Murad, "Generalized corresponding states correlation for self-diffusion coefficients of fluids" Chemical Engineering Science, Volume 36, Issue 12, 1981, Pages 1867-1869
- [9] Sigmund, P.M., 1976. Prediction of molecular diffusion at reservoir conditions: Part I. Measurement and prediction of binary dense gas diffusion coefficients. Can. J. Pet. Technol. 48-52 (April-June).

- [10] He, C.-H., Yu, Y.-S. and Su, W.-K. (1998). "Tracer diffusion coefficients of solutes in supercritical solvents." *Fluid Phase Equilib.*, Vol. 142, pp. 281-286.
- [11] Hafskjold, B. and Helbæk, M., "Diffusion coefficient measurements in gas/oil mixtures at high pressure by nuclear magnetic resonance" 3rd Lerkendal Petroleum Engineering Workshop Trondheim, January 20-21, 1993: pp.43-55.
- [12] Riazi, M.R., Whitson, C.H., "Estimation of diffusion coefficients of dense fluids" *Ind. Eng. Chem. Res.* 32, 1993,3081-3088.
- [13] Hayduk, W., Castaneda, R., Bromfield, H., Ray, R.R., "Diffusivities of propane in normal paraffin, chlorobenzene and butanol solvents". *AIChE J.* 19, 1973, 598-861.
- [14] Swapan, K., Buttler, R.M., "Diffusion coefficients of propane and butane in Peace River Bitumen" *Can. J. Chem. Eng.* 74, 1996, 985-992.
- [15] Grogan, A.T., Pinczewski, W.V., Ruskauff, G.J., Orr, F.M., "Diffusion of carbon dioxide at reservoir conditions-models and measurements". *Soc. Pet. Eng., Reservoir. Eng.* 3, 1988, 93-102.
- [16] Riazi, M.R., "A new method for experimental measurement of diffusion coefficients in reservoir fluids". *J. Pet. Sci. Eng.* 14, 1996, 235-250.
- [17] M.Jamialahmadi and M.Emadi and H.Muller-stein-hagen, "Prediction of Diffusion Coefficients of Hydrocarbon Gases in Hydrocarbon Liquids at High Pressure and Temperature", *OIL GAS European Magazine* , 2/2008
- [18] E.A.Osman, and M.A.Al-Marhoun,"Artificial Neural Networks Models for Predicting PVT Properties of Oil Field Brines" *SPE 93765* ,14THBahrain SPE Middle East Oil & Gas Show and Conference, 12-15 March 2005
- [19] Ridha B.Gharbi ,AND Adel M.Elsharkaway,(1997),"Universal Neural Network Based Model for Estimating The PVT Properties of Crude Oil Systems" *SPE 38099* ,the 1997 Asia Pacific Oil & Gas Conference,Malaysia,14-16 April1997
- [20] منہاج، م ب، ۱۳۸۷، مبانی شبکه‌های عصبی (هوش محاسباتی)، انتشارات دانشگاه صنعتی امیرکبیر (واحد تفرش و پلی تکنیک تهران)، جلد اول، چاپ پنجم ۰۸۷۴-۴۶۳-۹۶۴
- [21] Caudill, M. "Neural networks primer: Part I, AI Expert", December, 1987.46-52.
- [22] F.Otero, " Use of Neural Networks in Process Engineering Thermodynamics, diffusion and process control and simulation applications" *CT&F, Ciencia, Tecnologia y Futuro*, Vol 1 Num.4. Dic 1998
- [23] C.A. Faúndeza, F.A. Quieroa, J.O. Valderrama, "Phase equilibrium modeling in ethanol + congener mixtures using an artificial neural network" *Fluid Phase Equilib.* 292 (2010) 29-35.
- [24] V.D. Nguyen, R.R. Tan, Y. Brondial, T. Fuchino, " Prediction of vapor-liquid equilibrium data for ternary systems using artificial neural networks" *Fluid Phase Equilib.* 254 (2007) 188-197.
- [25] M. Safamirzaei, H. Modarress, " Modeling and predicting solubility of n-alkanes in water" *Fluid Phase Equilib.* 309 (2011) 53-61.
- [26] M. Lashkarbolooki, B. Vaferi, M.R. Rahimpour, " Comparison the capability of artificial neural network (ANN) and EOS for prediction of solid solubilities in supercritical carbon dioxide" *Fluid Phase Equilib.* 308 (2011) 35-43.
- [27] A.Z. Hezave, M. Lashkarbolooki, S. Raeissi, " Using artificial neural network to predict the ternary electrical conductivity of ionic liquid systems" *Fluid Phase Equilib.* 314 (2012) 128-133.
- [28] H. Kurt, M. Kayfeci, " Prediction of thermal conductivity of ethylene glycol-water solutions by using artificial neural networks" *Appl. Energy* 86 (2009) 2244-2248.
- [29] R. Eslamloueyan, M.H. Khademi, S. Mazinani, " Using a Multilayer Perceptron Network for Thermal Conductivity Prediction of Aqueous Electrolyte Solutions" *Ind. Eng. Chem. Res.* 50 (2011) 4050-4056.
- [30] D.A. De Mezquia, M.M. Bou-Ali, M. Larrañaga, J.A. Madariaga, C. Santamaría, "Determination of molecular diffusion coefficient in n-alkane binary mixtures: empirical correlations", *J. Phys. Chem. B* 116 (2012) 2814-2819.
- [31] Reza Beigzadeh, Masoud Rahimi, Seyed Reza Shabaniana, "Developing a feed forward neural network multi-layer model for prediction of binary diffusion coefficient in liquids" *Fluid Phase Equilibria*, 331 (2012) 48- 57