

شبیه‌سازی شرایط تشکیل هیدرات‌گازی در حضور و عدم حضور بازدارنده‌های ترمودینامیکی با استفاده از روابط تجربی و مدل‌های داده‌محور

پژوهش نفت

سال بیست و یکم
شماره ۶۵
صفحه ۹۷-۸۲، ۱۳۹۰

سیدمجتبی حسینی نسب^۱، محسن وفایی سفتی^{۱*} و امیرعباس ایزدپناه^۲

۱- دانشگاه تربیت مدرس، گروه مهندسی شیمی

۲- دانشگاه خلیج فارس بوشهر، گروه مهندسی شیمی

Vafaiesm@modares.ac.ir

گردید. از بین دو مدل داده‌محور، مدل انفیس در همه موارد از لحاظ تمامی معیارهای عملکردی، پاسخ بهتری نسبت به شبکه عصبی مصنوعی نشان داد. همچنین مدل انفیس نسبت به روابط تجربی و مدل ترمودینامیکی دانشگاه هریوت وات از دقت بالاتری برخوردار بود.

واژه‌های کلیدی: تخمین، فشار تشکیل هیدرات، مدل داده‌محور، شبکه عصبی مصنوعی، مدل انفیس

مقدمه

هیدرات‌های گازی ترکیبی با شبکه بلوری هستند که از پیوستن و قرار گرفتن مولکول‌های گازهای سبک به عنوان مهمان در حفرات موجود در مولکول‌های آب به عنوان میزبان، تحت شرایط مناسبی از دما و فشار به وجود می‌آیند.

برای شبیه‌سازی دقیق شرایط تشکیل هیدرات‌ها عمدتاً از روش مدل‌های ترمودینامیکی استفاده می‌شود که در این

چکیده

هیدرات‌های گازی در تأسیسات مختلف مربوط به جابه‌جایی گاز طبیعی و تجهیزات فرآیندی در میادین نفت و گاز، پالایشگاه‌ها، پتروشیمی و دستگاه‌های موجود در صنایع شیمیایی، در صورت حضور هم‌زمان گاز طبیعی و آب، در شرایط فشار بالا و دمای پایین تشکیل می‌گردد. به منظور جلوگیری از تشکیل هیدرات، دما و فشار تشکیل هیدرات تخمین زده می‌شود. در این مقاله دو مدل داده‌محور یعنی شبکه عصبی مصنوعی و سیستم فازی-عصبی (مدل انفیس) به عنوان ابزاری جایگزین جهت تخمین فشار تشکیل هیدرات برای سیستم‌های گازی مختلف با استفاده از داده‌های تجربی موجود در این زمینه، توسعه داده شد. جهت رسیدن به این هدف، ساختار بهینه هر یک از این مدل‌های داده‌محور برای سیستم‌های مورد بررسی، با استفاده از پارامترهای آماری تعیین گردید. مقادیر حاصل از کاربرد شبکه عصبی و مدل انفیس با نتایج به‌دست آمده از روابط تجربی و مدل ترمودینامیکی دانشگاه هریوت وات (HWHYD) مقایسه

(انفیس) در تخمین دما و یا فشار تشکیل هیدرات در هیچ کاری گزارش نشده است. در این تحقیق جهت شبیه‌سازی شرایط تشکیل هیدرات برای سیستم‌های گازی مختلف در حضور و عدم حضور بازدارنده‌های ترمودینامیکی، دو مدل داده محور شبکه عصبی مصنوعی و سیستم فازی-عصبی (مدل انفیس) به کار رفت. نتایج نشان داد که دو مدل داده محور به کار رفته به نحو مطلوبی قادر به پیش‌بینی فشار تشکیل هیدرات می‌باشند و مدل انفیس که ترکیبی از دو روش سیستم فازی و شبکه عصبی مصنوعی است تخمین بسیار مناسب‌تری نسبت به دیگر روش‌ها می‌دهد.

شبکه عصبی

شبکه‌های عصبی مدل‌های محاسباتی هستند که قادرند رابطه میان ورودی‌ها و خروجی‌های یک سیستم فیزیکی را توسط شبکه‌ای از گره‌های متصل به هم، تعیین نمایند. در شبکه عصبی میزان فعالیت هر یک از این اتصالات، توسط اطلاعات تاریخی طی فرآیند یادگیری تنظیم می‌شود و در نهایت، مدل قادر خواهد بود قوانین مرتبط میان ورودی‌ها و خروجی‌ها را کشف نماید، هر چند این قوانین غیر خطی و پیچیده باشند [۱۹].

ساختار شبکه‌های عصبی مصنوعی که معماری به آن گفته می‌شود، به شکلی است که نرون‌ها در دسته‌هایی که لایه نام دارند، مرتب می‌شوند شکل ۱ معماری معمولی شبکه عصبی متشکل از سه لایه است، لایه ورودی که داده‌ها را در شبکه توزیع می‌کند، لایه پنهان که داده‌ها را پردازش کرده و لایه خروجی که نتایج را به ازای ورودی‌های مشخص استخراج می‌کند.

سیستم استنتاج تطبیقی عصبی-فازی

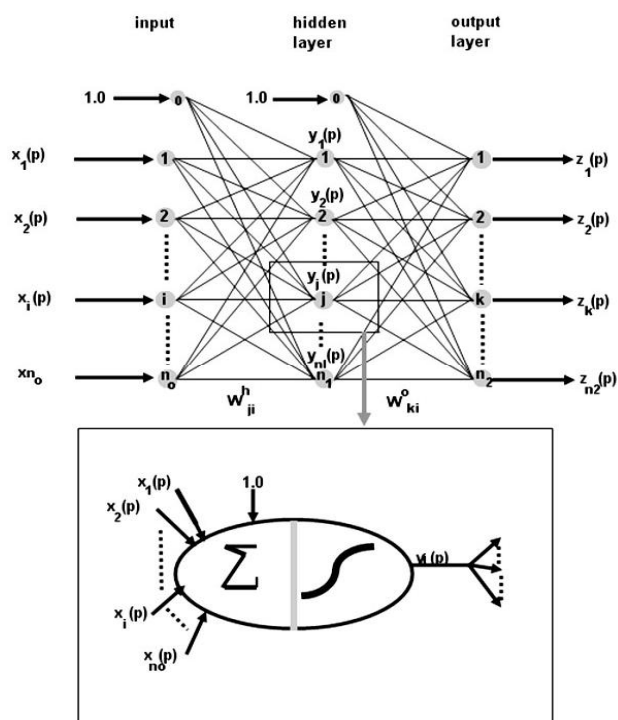
در شبکه عصبی-فازی ابتدا قسمت عصبی برای یادگیری شبکه، طبقه‌بندی توانایی‌ها و به منظور پیوند و اصلاح الگو به کار می‌رود. قسمت عصبی شبکه به طور خودکار، قواعد منطق فازی و توابع عضویت را در طول دوره تناوب یادگیری، ایجاد می‌کند.

زمینه کارهای بسیار زیاد و متنوعی انجام گرفته است. مدل‌های ترمودینامیکی دارای ضعف‌ها و مشکلات قابل توجهی است. از جمله مشکلات این است که هر یک از مدل‌های ترمودینامیکی برای سیستم‌های خاص و محدودی به لحاظ اجزای تشکیل دهنده، توسعه داده شده است. مدل‌های ترمودینامیکی جهت استفاده در سیستم‌های چند جزئی نیاز به پارامترهای برخورد دوتایی متعددی دارد که این پارامترها عمدتاً تابعیتی از دما و اجزای سیستم دارند. برای به دست آوردن این پارامترها و به کار بردن مدل‌های ترمودینامیکی، نیاز به محاسبات تعادل فازی پیچیده و خسته کننده از طریق حدس و خطا می‌باشد. بنابراین لزوم استفاده از روش‌هایی که در آنها بر اساس روابط ذاتی میان داده‌ها، نگاشتی غیرخطی بین متغیرهای مستقل و وابسته برقرار گردد، احساس می‌شود. یکی از روش‌های جدید در حل مسائل مهندسی، استفاده از مدل‌های داده محور^۱ از قبیل شبکه عصبی مصنوعی و سیستم‌های فازی-عصبی می‌باشد. مزیت مدل‌های داده محور عبارت است از آموزش مستقیم مدل از روی داده‌ها بدون نیاز به در نظر گرفتن فرض اولیه و دانش قبلی از روابط بین پارامترهای مورد مطالعه و همچنین قابلیت ارائه یک رابطه بین مجموعه‌ای از ورودی‌ها و خروجی‌ها برای تخمین خروجی متناظر با ورودی دلخواه [۱-۳]. مدل‌های داده محور مذکور توانایی تخمین هر تابع غیر خطی پیوسته و تحمل پذیری در مقابل خطا را دارا می‌باشند [۴ و ۵]. این قابلیت‌ها و کارکردهای شبکه عصبی مصنوعی و سیستم فازی-عصبی (مدل انفیس)^۲ باعث شد تا این دو مدل داده محور، به عنوان ابزاری جایگزین جهت تخمین خواص ترمودینامیکی مختلف مانند ویسکوزیته [۶ و ۷]، دانسیته و ضریب تراکم‌پذیری^۳ [۸]، فشار بخار [۹]، ضریب حرارتی [۱۰] و خواص تعادلی بخار-مایع [۱۱-۱۴] به کار روند. Elkamel و Elgibaly به وسیله شبکه عصبی مصنوعی، فشار تشکیل هیدرات و مقدار بازدارنده ترمودینامیکی لازم برای سیستم‌های متنوعی از هیدرات را تخمین زدند [۱۵ و ۱۶]. Heydari و همکاران [۱۷] و همچنین Zahedi و همکاران [۱۸] از شبکه عصبی برای تخمین دمای تشکیل هیدرات بهره بردند. استفاده از سیستم استنتاج تطبیقی عصبی-فازی

1. Data-Driven Model

2. ANFIS

3. Compressibility Factor



شکل ۱- شماتیک یک شبکه چند پرسپترون [۱۹].

که مدل‌های داده محور (در این تحقیق منظور از مدل‌های داده محور شبکه عصبی مصنوعی و مدل انفیس می‌باشد)، بر اساس شرایط ورودی و خروجی سیستم‌ها یا به نوعی شرایط اولیه و نهایی، به تخمین متغیر مدنظر می‌پردازند، چهار الگو برای ارتباط پارامترهای موثر در شرایط تشکیل هیدرات به منظور توسعه مدل‌های داده محور، در نظر گرفته شد. این الگوها بر مبنای اینکه فشار تشکیل هیدرات وابسته به کدام مشخصه از سیستم‌های تشکیل هیدرات باشد، معرفی شده است. پارامترهای تأثیرگذار در تشکیل هیدرات عبارتند از: دما و فشار تشکیل هیدرات، جزء مولی یا ترکیب درصد اجزای گازی، دانسیته گاز و ترکیب درصد وزنی بازدارنده‌ها. در این پژوهش، فشار تشکیل هیدرات تابعی از دیگر متغیرهای مذکور فرض شده و از مدل‌های داده محور جهت پیش‌بینی فشار تشکیل هیدرات با استفاده از متغیرهای متبوع آن که در هر یک از چهار الگو آمده، استفاده می‌گردد. بنابراین برای بررسی کارایی مدل‌های داده محور در تخمین فشار تشکیل هیدرات در هر یک از سیستم‌هایی که شرایط متفاوتی به لحاظ عناصر تشکیل دهنده دارد، چهار الگوی A، B، C و D فرض گردید که بسته به نوع سیستم، فشار تشکیل هیدرات تابعی

در مجموع، حتی پس از یادگیری، شبکه عصبی به اصلاح توابع عضویت و قواعد منطق فازی ادامه می‌دهد. از طرف دیگر، منطق فازی برای استنباط و مهیا نمودن یک خروجی غیر فازی شده نیز مورد استفاده قرار می‌گیرد [۲۰]. به صورت کلی می‌توان بیان کرد که از شبکه عصبی در طراحی بهینه سیستم استنتاج فازی (FIS) استفاده می‌شود. ترکیب سیستم‌های فازی که مبتنی بر قواعد منطقی‌اند و روش شبکه‌های عصبی مصنوعی که توان استخراج دانش از اطلاعات عددی را دارند، منجر به ارائه سیستم استنتاج تطبیقی عصبی-فازی شده است. این سیستم یک شبکه پس‌خور چند لایه است که از الگوریتم‌های یادگیری شبکه عصبی به منظور طراحی نگاشت غیر خطی بین فضای ورودی و خروجی استفاده می‌کند.

روش کار

تشکیل هیدرات در سیستم‌های گازی مختلف اتفاق می‌افتد. به طور مثال در سیستم‌های گازی حاوی مواد هیدروکربنی، غیر هیدروکربنی و یا ترکیبی از این دو حالت نیز هیدرات تشکیل می‌شود. سیستم‌های گازی می‌تواند در حضور و یا عدم حضور بازدارنده‌ها باشد. از آنجایی

۱۴۶۰ داده تعادل فازی هیدرات مورد استفاده قرار گرفت بخش عمده این داده‌ها از کتاب جامع اسلون [۲۱] استخراج گردید. این داده‌ها مربوط به سال‌های ۱۹۳۴ تا ۲۰۰۸ می‌باشد که از منابع مختلف به وسیله نویسنده کتاب گردآوری شده است.

توسعه شبکه عصبی مصنوعی

قبل از به‌کارگیری داده‌های خام اولیه در آموزش و تست شبکه، باید آنها را نرمالیزه کرد. در غیر این صورت الگوریتم یادگیری همراه با داده‌های خام، نمی‌تواند عملکرد مناسبی داشته باشد و شبکه در طول فرآیند آموزش همگرا نشده و نتایج مطلوب تولید نخواهد شد [۵].

در این تحقیق از تابع سیگموئید استفاده شده که خروجی این تابع بین ۰ و ۱ می‌باشد. بنابراین داده‌های ورودی با استفاده از رابطه (۵) بین دو عدد ۰/۱ و ۰/۹ نرمال شدند [۲۲].

$$x_i = 0.8 \left(\frac{x - x_{\min}}{x_{\max} - x_{\min}} \right) + 0.1 \quad (5)$$

در این رابطه، x_i : مقدار نرمال شده، x : مقدار واقعی و x_{\min} و x_{\max} به ترتیب مقادیر حداقل و حداکثر داده‌ها می‌باشند.

شبکه‌های عصبی پرسپترون پیش‌خور دو لایه با توابع سیگموئید، در لایه اول قادرند هر تابعی را با دقت دلخواه تقریب بزنند [۲۳]. از این رو از شبکه‌های عصبی پیش‌خور از نوع پرسپترون چند لایه با الگوریتم آموزش پس انتشار خطا استفاده شد. همچنین از تابع سیگموئیدی به‌عنوان تابع فعالیت در لایه میانی و خروجی و تابع خطی برای لایه ورودی استفاده گردید. برای آموزش شبکه عصبی، روش استاندارد انتشار برگشتی^۳ خطا مورد استفاده قرار گرفت. جهت دستیابی به بهترین الگوریتم یادگیری، از سه الگوریتم یادگیری، Levenberg- Scaled Conjugate، Marquardt (LM) Gradient (SCG) و Pola-CGP Ribiere (Conjugated Gradient) [۲۴-۲۶] استفاده گردید. برای آموزش و امتحان دو مدل داده محور و جلوگیری از برازش بیش از حد^۴ از روش توقف زود هنگام^۵ [۲۷] استفاده شد.

1. Appearance Molecular Weight

2. Back-Propagation

3. Overfitting

4. Early Stopping

از متغیرهای تأثیرگذار در تشکیل هیدرات در نظر گرفته می‌شود [۱۵].

چهار الگوی A، B، C و D بر اساس متغیر ورودی به مدل داده محور، از هم متمایز می‌شوند. در واقع این چهار الگو به نوعی ورودی و خروجی را برای مدل‌های داده محور معرفی می‌کنند که این الگوها با جزئیات در ذیل آمده است. در الگوی A، رابطه در نظر گرفته شده بر اساس این فرض است که فشار (P) به دما (T) و دانسیته گاز (γ) بستگی دارد. بدین معنی که دما و دانسیته گاز به عنوان ورودی و فشار به عنوان خروجی مدل داده محور در نظر گرفته شده است.

$$P = f_1(T, \gamma) \quad (1)$$

(γ) از حاصل تقسیم وزن مولکولی گاز خالص یا وزن مولکولی ظاهری^۱ (AMW) مخلوط گاز بر وزن مولکولی ظاهری هوا تعیین می‌شود، یعنی: $\gamma = AMW/28.9625$ یا $\gamma = \sum (y_i M_i) / 28.9625$

الگوی A برای هیدروکربن‌های خالص تشکیل دهنده هیدرات مانند: متان، پروپان، ایزوبوتان، نرمال بوتان و همچنین مخلوطی از این گازها تست شده است. در الگوی B رابطه مدنظر بر حسب دما و ترکیب درصد عناصر گازی و مخلوطی از آنها به صورت زیر ارائه شده است:

$$P = f_2(T, y_{C_1}, y_{C_2}, y_{C_3}, y_{i-C_4}, y_{n-C_4}) \quad (2)$$

که y درصد مولی هر جزء در مخلوط است. در الگوی C، علاوه بر متغیرهای مدل B، عناصر تشکیل دهنده غیرهیدروکربنی هیدرات مانند دی‌اکسیدکربن، نیتروژن و سولفید هیدروژن هم در نظر گرفته می‌شود:

$$P = f_3(T, y_{C_1}, y_{C_2}, y_{C_3}, y_{i-C_4}, y_{n-C_4}, y_{CO_2}, y_{N_2}, y_{H_2S}) \quad (3)$$

و نهایتاً الگوی D که در این مدل جزء مولی هیدروکربن‌های غیر عامل تشکیل هیدرات مانند ایزوپنتان، نرمال پنتان (یکجا با عنوان پنتان) و C6⁺ و همچنین بازدارنده‌ها مانند متانول، کلرید سدیم، اتیلن گلیکول، کلرید کلسیم و اتانول به همراه سایر متغیرهای الگوی C، به عنوان متغیرهای ورودی در نظر گرفته شده است. یعنی:

$$P = f_4(T, y_{C_1}, y_{C_2}, y_{C_3}, y_{i-C_4}, y_{n-C_4}, y_{CO_2}, y_{N_2}, y_{H_2S}, y_{C_6^+}, y_{MeOH}, y_{EG}, y_{NaCl}, y_{CaCl_2}) \quad (4)$$

برای توسعه و اعتبارسنجی مدل‌های داده محور، بیش از

و نهایتاً تولید سیستم استنتاج فازی از روش خوشه‌سازی تفریقی استفاده شده است [۳۰]. برای به‌دست آوردن مدلی با پارامترهای بهینه و عملکرد بالا، پایگاه استنتاج فازی مدل انفیس با به‌کارگیری توابع عضویت مختلف و همچنین با تعداد متفاوتی از این توابع عضویت طراحی شد. برای دستیابی به این مهم، پیدا کردن تابع عضویتی که به بهترین شکل مدل انفیس را جوابگو باشد، به عنوان هدف اول شبیه‌سازی کامپیوتری جهت کاربر مدل انفیس برای پیشگویی ترسیم شد و هدف دوم، پیدا کردن تعداد بهینه تابع عضویت که مناسب‌ترین عملکرد برای مدل داده محور مذکور را داشته باشد، در نظر گرفته شد. در طراحی مدل انفیس از توابع عضویت مختلف به تعداد دو تا شش تابع عضویت برای هر پارامتر ورودی استفاده گردید.

نتایج و بحث

نتایج توسعه مدل‌های داده محور بر مبنای الگوی A

در این مرحله، هدف عبارت است از توسعه مدل‌های داده محور شبکه عصبی و مدل انفیس، برای تخمین فشار تشکیل هیدرات با استفاده از دانسیته گاز و دما این کار برای مواردی که ترکیب گاز مشخص نیست، سودمند است. تعداد ۶۷۴ نقطه شامل دما، فشار و دانسیته گاز با دقت از روی منحنی گاز-دانسیته^۱ [۳۱] تهیه گردید و مدل‌های داده محور با داده‌های به‌دست آمده از این طریق، توسعه داده شد. به طور خاص شبکه عصبی مصنوعی و مدل انفیس برای گازهایی با دانسیته‌های (۰/۵۵۴، ۰/۶، ۰/۷، ۰/۸، ۰/۹، ۱) جهت پیش بینی فشار تشکیل به کار برده شد. شبکه عصبی LM-10، یعنی شبکه‌ای با الگوریتم یادگیری Levenberg-Marquard و ۱۰ نرون در لایه پنهانی و مدل انفیس با ساختار Gaussmf-4، یعنی با تابع عضویت Gaussmf و تعداد ۴ تابع عضویت بهترین عملکرد را داشته‌اند. جهت ارزیابی دو مدل داده محور به‌کار رفته بر مبنای الگوی A، نتایج به‌دست آمده با روابط تجربی Kobayashi [۳۲]، Mottie [۳۳] و Hammerschmidt [۳۴] که از معروف‌ترین روابط در این موضوع می‌باشد، مقایسه شده است.

در این روش کل داده‌ها به‌طور تصادفی به سه دسته آموزش، برازش متقابل (نظارت) و آزمون تقسیم می‌شوند [۲۸]. بدین منظور ۶۰٪ از داده‌های موجود برای آموزش، ۲۰٪ برای برازش متقابل و مابقی برای آزمایش شبکه در نظر گرفته شد. در تحقیق حاضر در ساختار تمامی شبکه‌ها، طراحی بهینه با یک لایه مخفی صورت پذیرفت و تعداد بهینه نرون‌های لایه مخفی نیز به روش سعی و خطا به دست آمد [۲۹]. تعداد نرون در لایه مخفی، از ۷ تا ۱۵ (۷، ۱۰، ۱۳ و ۱۵) تغییر داده شد تا با به‌کارگیری توابع یادگیری مختلف در الگوریتم آموزش پس انتشار خطا در مرحله آموزش، براساس پارامترهای آماری، بهترین تابع یادگیری و مناسب‌ترین تعداد نرون در لایه مخفی به‌دست آید. معیار گزینش شبکه بهینه در مرحله آموزش، تولید کمترین مقدار پارامترهای آماری ریشه میانگین مجذور خطا (RMSE)، خطای انحراف میانگین (COV) و بیشترین مقدار ضریب تعیین (R^2) در خروجی‌های آن بود.

معیارهای ارزیابی مدل‌ها

برای اطمینان از عملکرد یک مدل پیش بینی از جنبه‌های مختلف و همچنین مقایسه آن با روش‌های دیگر، پارامترهای آماری متعددی به‌طور همزمان مورد استفاده قرار گرفت. در این تحقیق از سه پارامتر R^2 ، RMSE، COV برای تعیین بهترین ساختار شبکه‌های ANN و ANFIS و همچنین پارامترهای میانگین درصد خطای مطلق (MAPE) و میانگین خطای متوسط (MAE)، برای مقایسه مدل‌های داده محور بهینه با روش‌های دیگر استفاده شد. در جدول ۱، معادلات مربوط به محاسبه این شاخص‌های آماری اراده شده است.

توسعه مدل انفیس

ویژگی شبکه عصبی-فازی تطبیقی به‌کار رفته در این پژوهش به شرح زیر است: سیستم استنتاج فازی Takagi-Sugeno درجه یک شبکه عصبی پیش‌خور از نوع پرسپترون چند لایه (MLP)، تابع ورودی از تفاوت دو تابع سیگموئید و تابع خروجی خطی، تابع میانگین متحرک برای غیرفازی نمودن با الگوریتم یادگیری ترکیبی که ادغامی از روش پس انتشار خطا و روش حداقل مربعات خطا می‌باشد. در این تحقیق، برای دسته‌بندی خودکار و تحلیل داده‌ها

جدول ۱- شاخص‌های آماری انتخاب شده در تعیین بهترین ساختار شبکه

نام شاخص آماری	معادله مربوطه
ضریب تعیین ^۱	$R^2 = 1 - \left(\frac{\sum_{i=1}^N (\text{exp}_i - \text{pre}_i)^2}{\sum_{i=1}^N \text{pre}_i^2} \right)$
ریشه مجذور مربعات خطا ^۲	$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (\text{exp}_i - \text{pre}_i)^2}$
ضریب پراکندگی ^۳	$COV = \frac{RMSE}{ \text{exp} } \times 100$
میانگین نسبی درصد خطای مطلق ^۴	$MAPE (\%) = \frac{1}{N} \sum_{i=1}^N \left 100 \frac{(\text{exp}_i - \text{pre}_i)}{\text{exp}_i} \right $
میانگین خطای مطلق ^۵	$MAE = \frac{1}{N} \text{exp}_i - \text{pre}_i $
	توضیحات: در روابط فوق، N: تعداد نمونه، exp: مقادیر تجربی، pre: مقادیر پیش‌بینی شده به‌وسیله مدل‌ها و روابط و (exp): میانگین مقادیر تجربی می‌باشند.

تابع هدف که مجموع قدرمطلق انحراف متوسط دما و

فشار می‌باشد، طبق رابطه زیر استفاده گردید:

$$O.F. = \sum_{i=1}^n \left[\left(\left| \frac{P_{\text{exp}} - P_{\text{cal}}}{P_{\text{exp}}} \right| + \left| \frac{T_{\text{exp}} - T_{\text{cal}}}{T_{\text{exp}}} \right| \right) \right] \quad (11)$$

در رابطه فوق P_{exp} و T_{exp} به ترتیب فشار و دمای تجربی، P_{cal} و T_{cal} فشار و دمای محاسبه شده با استفاده از رابطه مدنظر و n تعداد داده‌های به کار رفته در بهینه کردن پارامترهای معادلات می‌باشد. از روش بهینه‌سازی Nelder-Mead ثابت‌های این سه معادله به همراه خطای استاندارد هر کدام از ثوابت محاسبه گردید که نتایج آن در جداول ۲ تا ۵ ارائه شده است. نتایج پیش‌بینی شبکه عصبی و مدل انفیس بهینه در حالت جامع، (هنگامی که دانسیته گاز مقادیری بین ۰/۵۵۴ تا ۱ را دارد)، با روابط تجربی Mottie، Kobayashi و Hammerschmidt برای داده‌های تجربی که در بسط و توسعه این مدل‌ها و روابط استفاده نشده‌اند، در جدول ۶ مقایسه شده است. همچنین پیش‌بینی مدل‌ها و روابط تجربی به همراه مقادیر تجربی، در شکل‌های ۲ تا ۶ در کنار هم رسم شده است.

1. Coefficient of Determination
2. Root Mean Squar Error
3. Coefficient of Variation
4. Mean Absolute Percentage Error
5. Mean Absolute Error
6. Nonlinear Regression Analysis

رابطه Mottie

دو معادله دما و فشار صریح برای این رابطه به صورت ذیل وجود دارد که ثابت‌های آن برای هر دو حالت به دست آمده است.

$$\text{Log}(P) = a_1 + a_2 T + a_3 T^2 + a_4 \gamma_g + a_5 \gamma_g^2 + a_6 T \gamma_g \quad (6)$$

$$T = b_1 + b_2 \text{Log}(P) + b_3 \text{Log}(P)^2 + b_4 \gamma_g + b_5 \gamma_g^2 + b_6 \gamma_g \text{Log}(P) \quad (7)$$

رابطه Hammerschmit

Hammerschmit رابطه دمایی تشکیل هیدرات را به صورت زیر ارائه کرد:

$$T = aP^\beta \quad (8)$$

بازنویسی این رابطه بر حسب فشار تشکیل هیدرات به شکل زیر است:

$$P = (T/\alpha)^{1/\beta} \quad (9)$$

رابطه کاهش یافته Kobayashi

در اینجا رابطه Kobayashi با حذف ۴ ترم و کاهش پارامترهای آن از ۱۵ به ۱۱ آورده شده است:

$$T = 1/[A_0 + A_1(\ln P) + A_2(\ln P)^2 + A_3(\ln P)^3 + A_4(\ln \gamma) + A_5(\ln \gamma)^2 + A_6(\ln \gamma)^3 + A_7(\ln P)(\ln \gamma) + A_8(\ln P)(\ln \gamma)^2 + A_9(\ln P)^2(\ln \gamma) + A_{10}(\ln P)^2(\ln \gamma)^2] \quad (10)$$

ثابت‌های روابط تجربی فوق از روش آنالیز برازش غیرخطی^۶ Nelder-Mead [۳۵] به دست آمد. از این روش برای محاسبه مقادیر بهینه ثابت‌ها از طریق مینیمم کردن

جدول ۲- ثابت‌های معادله ۶ به همراه خطای استاندارد هر یک از ثابت‌ها

خطای استاندارد	اندازه ضریب	ضرایب	خطای استاندارد	اندازه ضریب	ضرایب
$1/796694E-5$	$162/8287$	a_4	$1/397764E-2$	$-152/9132$	a_1
$3/076875E-7$	$-55/6539$	a_5	$3/829677E-3$	$32/2076$	a_2
$4/547328E-2$	$-8/0644$	a_6	$3/934606E-4$	$-1/1256$	a_3

جدول ۳- ثابت‌های معادله ۷ به همراه خطای استاندارد هر یک از ثابت‌ها

خطای استاندارد	اندازه ضریب	ضرایب	خطای استاندارد	اندازه ضریب	ضرایب
$9/282471E-3$	$-9/3218$	b_4	$1/816661E-1$	$8/7737$	b_1
$3/77821E-2$	$3/5528$	b_5	$2/047528E-1$	$-0/0255$	b_2
$4/101932E-2$	$0/0312$	b_6	$6/397091E-4$	$7/8172E-4$	b_3

جدول ۴- ثابت‌های معادلات ۸ و ۹ به همراه خطای استاندارد هر یک از ثابت‌ها


خطای استاندارد	اندازه ضریب	ضرایب
$2/471904E-1$	$14/7593$	α
$6/299044E-2$	$0/2101$	β

جدول ۵- ثابت‌های معادله (۲۱) به همراه خطای استاندارد هر یک از ثابت‌ها

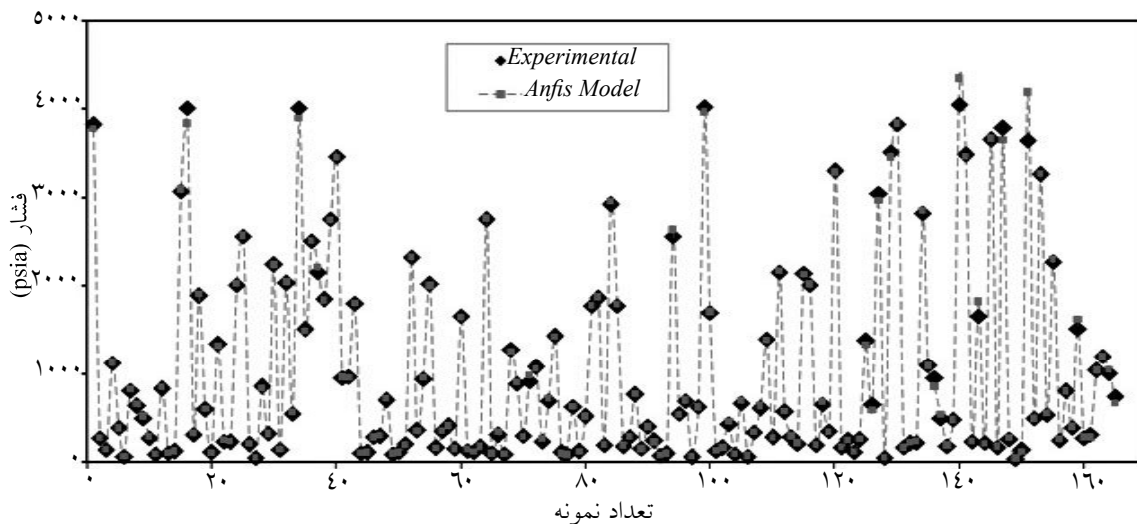
خطای استاندارد	اندازه ضریب	ضرایب	خطای استاندارد	اندازه ضریب	ضرایب
$1/608001E-4$	$-2/16992E-3$	A_6	$1/491795E-3$	$-2/998764E-3$	A_0
$-3/233519E-4$	$7/114145E-4$	A_7	$3/034751E-4$	$1/615272E-3$	A_1
$5/745757E-4$	$2/062154E-3$	A_8	$2/061456E-5$	$-1/241929E-4$	A_2
$1/087459E-5$	$-2/288624E-5$	A_9	$4/677437E-7$	$3/012534E-6$	A_3
$1/892436E-5$	$-7/04474E-5$	A_{10}	$2/394345E-3$	$-5/788643E-3$	A_4
			$4/324969E-3$	$-1/636478E-2$	A_5

جدول ۶- شاخص‌های آماری مدل‌های داده محور بهینه و روابط تجربی مورد بررسی برای کل داده‌های تجربی در نظر گرفته شده با دانسیته گاز بین ۰/۵۵۴ تا ۱.

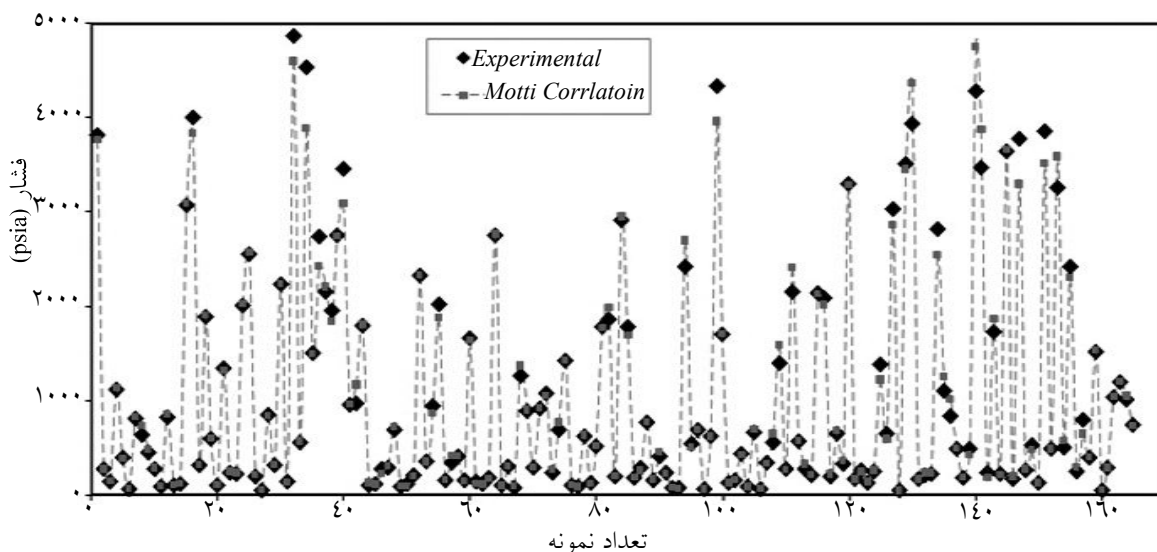
Methods	تعداد نقاط	MAE	MAPE	R ²	E _{max}
ANN	۲۱۲	۴۵/۰۵۹۱	۴/۹۰۹۱	۰/۹۹۲۵	۱۹۵/۰۷
ANFIS	۲۱۲	۲۲/۴۵۳۷	۲/۸۰۰۳	۰/۹۹۷۴	۱۷۵/۷۵۸
Kobayashi	۲۱۲	۹۷/۳۹۹۶	۱۰/۸۲۸۸	۰/۹۸۰۳	۲۹۱/۶۶۴۱
Hammerschmidt	۲۱۲	۲۵۲/۲۵۴۵	۳۰/۹۸۸	۰/۹۱۵۵	۱۱۳۷/۹۶۱۲
Mottie	۲۱۲	۵۸/۵۷۰۲	۵/۴۵۱۱	۰/۹۸۹۱	۲۷۵/۵۷۴



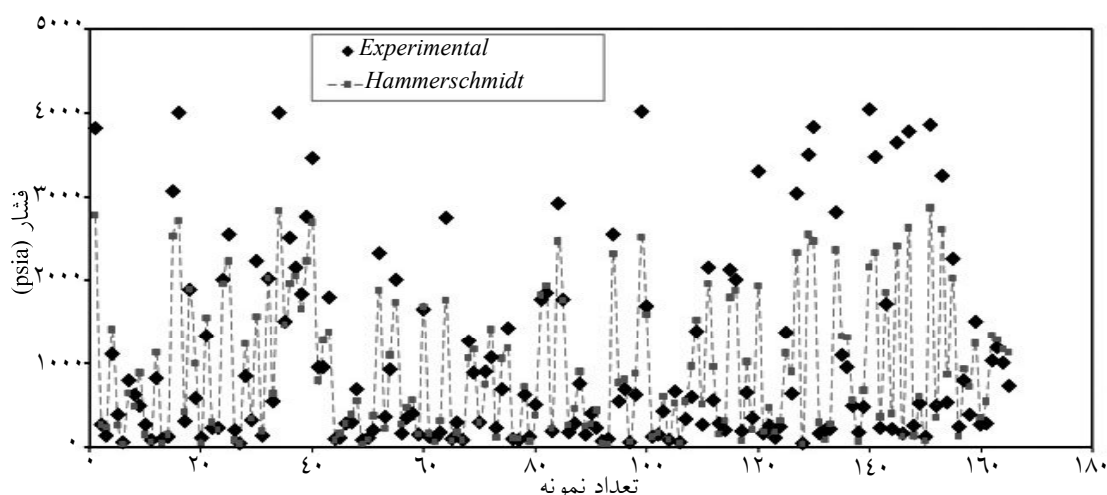
شکل ۲- مقایسه بین مقادیر تجربی و نتایج به‌دست آمده از شبکه عصبی مصنوعی (ANN) در تخمین فشار تشکیل هیدرات



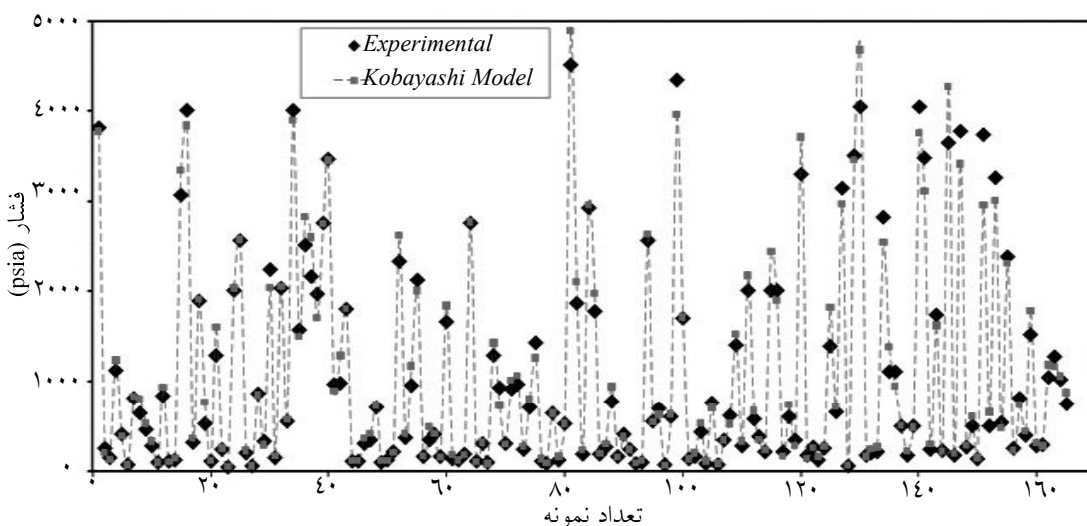
شکل ۳- مقایسه بین مقادیر تجربی و نتایج به‌دست آمده از مدل انفیس (ANFIS) در تخمین فشار تشکیل هیدرات



شکل ۴- مقایسه بین مقادیر تجربی و نتایج به‌دست آمده از رابطه Mottie در تخمین فشار تشکیل هیدرات



شکل ۵- مقایسه بین مقادیر تجربی و نتایج به دست آمده از رابطه Hammerschmidt در تخمین فشار تشکیل هیدرات



شکل ۶- مقایسه بین مقادیر تجربی و نتایج به دست آمده از رابطه Kobayashi در تخمین فشار تشکیل هیدرات

شبکه عصبی است. به این دلیل که در مدل انفیس داده‌ها بر حسب میزان پراکندگی حول چند داده به عنوان مرکز خوشه، کلاسه‌بندی می‌شوند و برای هر دسته از داده‌ها با استفاده از تعریف کردن قوانین و تنظیم پارامترهای مختلف سیستم استنتاج فازی طی مرحله آموزش به وسیله شبکه عصبی، سیستم فازی-عصبی (انفیس) طراحی شده و به شبیه‌سازی فشار تشکیل هیدرات برای هر دسته از داده‌ها می‌پردازد و نتیجه نهایی از برآیند مقادیر تخمینی برای هر دسته از داده‌ها گزارش می‌شود این مزیت عمده و تفاوت اساسی سیستم فازی-عصبی نسبت به شبکه عصبی می‌باشد. اما در مقابل، شبکه عصبی برای کل داده‌ها با پراکندگی‌های مختلف، با یک استراتژی به پیش‌بینی می‌پردازد و همین نکته اصلی‌ترین دلیل پایین‌تر بودن دقت شبکه عصبی نسبت به مدل انفیس است.

از مقایسه‌ای که بین مقادیر تجربی و تخمین‌های شبکه عصبی، مدل انفیس و روابط تجربی به صورت‌های متفاوت انجام شد، مشخص گردید که نتایج به دست آمده از مدل‌های داده محور دارای دقت بالاتری نسبت به هر سه رابطه تجربی است. رابطه Hammerschmidt تخمین‌های غیر دقیقی از فشار تشکیل هیدرات می‌دهد و این رابطه صرفاً جهت تعیین حدس اولیه از شرایط تشکیل هیدرات کاربرد دارد. روابط Kobayashi و Mottie فشار تشکیل هیدرات را به خوبی پیش‌بینی می‌کند، ولی با توجه به تعداد بالای ثابت‌ها در روابط تجربی Kobayashi و Mottie، استفاده از این روابط به دلیل لزوم محاسبه ثوابت آن در شرایط مختلف، دشوار بوده و این امر ضرورت استفاده از مدل‌های داده محور را تأیید می‌نماید. از بین دو مدل داده محور، مدل انفیس دارای پاسخ بهتری نسبت به

[۳۹] برای مدل کردن فاز هیدرات، به منظور شبیه‌سازی فشار تشکیل هیدرات استفاده شده است. جزئیات بیشتر در مورد این مدل ترمودینامیکی در مراجع [۴۰ و ۴۱] آورده شده است.

پارامترهای آماری جدول ۷ نشان می‌دهد که در مورد هر دو سیستم گازی متان-اتان و متان-اتان-پروپان، مدل‌های داده محور، نسبت به مدل ترمودینامیکی HWHYD، فشار تشکیل هیدرات را با دقت بالاتری پیش‌بینی می‌کند.

برتری نتایج تخمین مدل انفیس نسبت به شبکه عصبی بدین علت می‌باشد که سیستم فازی اغتشاش کمتری نسبت به شبکه عصبی از خود نشان می‌دهد. همچنین این شبکه‌های عصبی مبتنی بر الگوریتم پس انتشار خطا، دارای ضعف‌هایی نظیر گیر کردن شبکه در نقطه مینیمم محلی^۲ و یا پایین بودن سرعت همگرایی^۳ محاسبات است که بر دقت تخمین تأثیر می‌گذارند. مشکل دیگر شبکه‌های عصبی، نیاز این روش به داده‌های بسیار زیاد برای رسیدن به پاسخ جامع قابل اطمینان با خطای پایین می‌باشد. اما در مقابل، روش فازی-عصبی این امکان را فراهم می‌آورد تا بتوان از داده‌های کمتری برای رسیدن به پاسخ دلخواه بهره برد.

نتایج توسعه شبکه عصبی و مدل انفیس بر مبنای الگوی B
مدل داده محور توسعه داده شده بر مبنای الگوی B طبق رابطه ۲، سیستم‌های تشکیل هیدراتی را شامل می‌شود که مواد تشکیل دهنده، فقط عناصر هیدروکربنی باشند. بنابراین جهت توسعه شبکه عصبی و مدل انفیس، دو سیستم دوتایی و سه‌تایی تشکیل هیدرات یعنی متان-اتان و متان-اتان-پروپان به عنوان نمونه، برای تخمین فشار تشکیل هیدرات در نظر گرفته شد. بعد از توسعه شبکه عصبی و مدل انفیس با ساختارهای مختلف، برای مخلوط گازی متان-اتان شبکه عصبی با ساختار LM-13 و مدل انفیس Gbellmf-4 و برای مخلوط گازی متان-اتان-پروپان شبکه عصبی SCG-10 و مدل انفیس Gbellmf-5 بهترین عملکرد را به عنوان ساختار بهینه از خود نشان دادند. تخمین‌های به دست آمده از ساختار شبکه عصبی مصنوعی و مدل انفیس با مدل ترمودینامیکی دانشگاه هریوت وات [۳۶] (نرم‌افزار HWHYD)، با ارائه پارامترهای آماری R^2 ، $RMSE$ ، MSE و $MAPE$ در جدول ۷ مقایسه شده‌اند. در مدل ترمودینامیکی دانشگاه هریوت وات یا همان نرم‌افزار HWHYD، از معادله حالت اصلاح شده Valderrama-Patel-Teja [۳۷]، با قوانین اختلاط عدم وابسته به دانسیته^۱ [۳۸] برای مدل کردن فازهای بخار و مایع و از تئوری واندوالس-پلاتیو

جدول ۷- شاخص‌های آماری مدل‌های داده محور بهینه و مدل ترمودینامیکی دانشگاه هریوت وات (HWHYD) برای مخلوط گازی متان-اتان و متان-اتان-پروپان

شاخص‌های آماری	مخلوط گازی متان-اتان			مخلوط گازی متان-اتان-پروپان		
	شبکه عصبی	مدل انفیس	مدل HWHYD	شبکه عصبی	مدل انفیس	مدل HWHYD
R^2	۰/۹۹۷۵	۰/۹۹۸۶	۰/۹۹۶۲	۰/۹۹۲۱	۰/۹۹۳۴	۰/۹۹۲۸
RMSE	۷۷۹/۶۲۵	۶۳۶/۱۳۲۹	۹۷۵/۲۶۰۳	۶۴/۸۷۱۳	۵۷/۱۷۷۵	۶۱/۳۵۱۷
MAPE	۷/۴۵۰۷	۳/۲۲۴۲	۱۰/۷۶۵۲	۳/۰۵۶۵	۲/۵۷۷۲	۲/۹۹۰۴
MSE	۶/۶۴۳۲E+۵	۵/۸۱۰۲E+۵	۶/۵۹۷۱E+۶	۴/۱۴۹۲E+۳	۳/۹۹۰۲E+۳	۴/۳۶۸۱E+۵
MAE	۵۶۳/۹۹۳۷	۴۳۳/۹۷۸۶	۸۷۴/۳۱۲۷	۵۵/۱۳۰۲	۴۶/۴۸۳۶	۵۴/۵۳۰۷

1. Nondensity Dependent Mixing Rules

2. Local Minimum

3. Convergency Rate

و غیر هیدروکربنی درکنار هم و در نتیجه عدم توانایی مدل ترمودینامیکی در لحاظ کردن اثر متقابل بین اجزا در قالب پارامترهای برخورد نسبت داد.

نتایج توسعه مدل انفیس بر مبنای الگوی D

الگوی D، جامع تر از بقیه الگوهای باشد. این الگو تقریباً تمامی حالات یک سیستم به لحاظ عناصر و اجزای تشکیل دهنده که در آن تشکیل هیدرات محتمل است، را در بر می گیرد. شبکه عصبی زمانی که تعداد داده های آموزشی کم باشد، جواب مناسبی نمی دهد و دقیقاً همین نکته از مزیت های عمده مدل انفیس بر شبکه عصبی است که انفیس با تعداد کم داده آموزشی نیز جوابی با دقت بالا می دهد. با توجه به این نکته و همچنین از آنجایی که در توسعه مدل های داده محور بر مبنای الگوهای A، B و C، مدل انفیس عملکرد دقیق تری نسبت به شبکه عصبی مصنوعی داشت، جهت تخمین فشار تشکیل هیدرات بر مبنای الگوی D، تنها از مدل داده محور انفیس استفاده شده است. دو نمونه سیستم مخلوط گازی در حضور بازدارنده الکلی و الکترولیتی مورد بررسی قرار گرفت: مخلوط گازی متان-پروپان در مجاورت بازدارنده متانول و مخلوط گازی متان-نیترژن در مجاورت بازدارنده کلرید سدیم. در اینجا الگوی مختلفی از مدل انفیس برای تخمین فشار تشکیل هیدرات دو سیستم مورد نظر برای غلظت های مختلفی از بازدارنده ها به کار رفت. ساختار بهینه مدل انفیس در غلظت های مختلفی از بازدارنده برای دو سیستم مورد نظر در جدول ۹ ارائه شده است.

جدول ۸- شاخص های آماری مدل های داده محور بهینه و مدل ترمودینامیکی دانشگاه هریوت وات (HWHYD) برای یک گازی طبیعی

Methods	R ²	MSE	MAPE	RMSE	MAE
شبه عصبی مصنوعی	۰/۹۹۳۴	۴/۸۷۲E+۴	۵/۹۴۰۹	۲۰۸/۶۳۷	۱۶۱/۲۶۱۸
مدل انفیس	۰/۹۹۳۷	۴/۰۷۳E+۴	۵/۷۶۶۸	۲۰۱/۱۸۷	۱۴۶/۲۱۸
مدل HWHYD	۰/۹۸۸۶	۸/۲۶۹E+۴	۱۰/۳۴۸۶	۲۷۴/۱۵۹	۲۱۶/۲۸۷۱


جدول ۹- مشخصات ساختار بهینه مدل انفیس برای سیستم مخلوط گازی در حضور بازدارنده

سیستم های مورد بررسی	غلظت بازدارنده بر حسب ترکیب درصد وزنی (%wt)	ساختار بهینه مدل انفیس
مخلوط گازی متان-پروپان + متانول	۱۰٪	Trampf-3
	۲۰٪	Trampf-6
	۳۵٪	Trampf-3
مخلوط گازی متان-نیترژن + کلرید سدیم	۵٪	Gauss2mf-3
	۱۵٪	Gaussmf-4

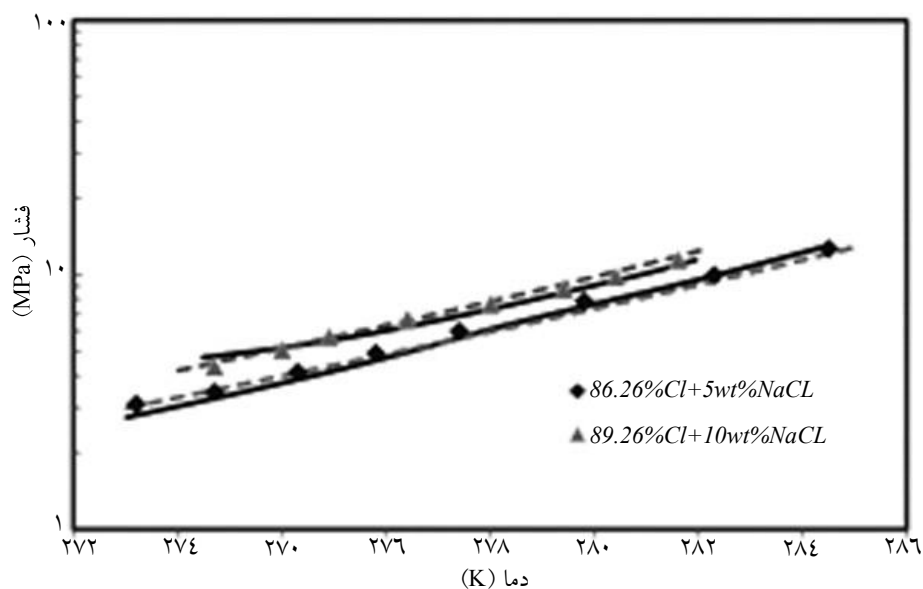
نتایج توسعه شبکه عصبی و مدل انفیس بر مبنای الگوی C در الگوی C، طبق رابطه ۳، فشار تشکیل هیدرات، تابعی از دما و جزء مولی عناصر گازی هیدروکربنی و غیر هیدروکربنی تشکیل دهنده هیدرات در نظر گرفته شده است. به عنوان نمونه یک سیستم گاز طبیعی، مخلوطی از گازهای متان، اتان، پروپان، بوتان، دی اکسید کربن، سولفید هیدروژن و نیترژن جهت تخمین فشار تشکیل هیدرات به وسیله شبکه عصبی مصنوعی و مدل انفیس بر مبنای الگوی C استفاده گردید. توپولوژی های مختلف در توسعه شبکه عصبی و مدل انفیس به کار رفت و ساختار بهینه براساس ارزیابی شاخص های آماری هریوت وات از این دو مدل داده محور، تعیین شد. بدین ترتیب شبکه عصبی 10-SCG، یعنی شبکه ای با الگوریتم یادگیری SCG و ۱۰ نرون در لایه پنهان و مدل انفیس Gaussmf-3، یعنی ساختاری با ۳ عدد از تابع عضویت گوسین، مناسب ترین عملکرد را داشته است. تخمین های شبکه عصبی مصنوعی و مدل انفیس با ساختار بهینه با مقادیر مدل ترمودینامیکی در تخمین فشار تشکیل هیدرات در قالب چند معیار آماری در جدول ۸ مقایسه شده است. نتایج نشان می دهد که مدل ترمودینامیکی دانشگاه هریوت وات (نرم افزار HWHYD) از دقت پایین تری نسبت به مدل های داده محور برخوردار است. علت اصلی پایین بودن دقت مدل HWHYD را می توان به تعداد بالای اجزای موجود در ترکیب گاز، وجود گازهای هیدروکربنی

شبیه‌سازی در تخمین فشار تشکیل هیدرات به وسیله توسعه شبکه عصبی مصنوعی و مدل انفیس به دست آمد، مشخص گردید که مدل‌های داده محور به عنوان ابزاری جایگزین در تخمین فشار تشکیل هیدرات به شمار می‌روند. از بین دو مدل داده محور به کار رفته در این تحقیق، مدل انفیس با توجه به ویژگی‌های خاص و دلیل برتری آن که بیشتر توضیح داد شد، نسبت به شبکه عصبی، در تخمین فشار تشکیل هیدرات در سیستم‌های مختلف، عملکرد بهتری از خود نشان داد.

پس از تعیین مدل انفیس با ساختار بهینه، تخمین‌های به دست آمده از این مدل داده محور با نتایج حاصل از مدل ترمودینامیکی دانشگاه هریوت وات در شکل‌های ۷ و ۸ و جداول ۱۰ و ۱۱ مقایسه گردیده است. برای مخلوط گازی متان-نیترژن در حضور بازدارنده کلرید سدیم، مدل انفیس دارای دقتی نسبتاً برابر با مدل ترمودینامیکی HWHYD است. در مورد مخلوط گازی متان-پروپان در حضور بازدارنده متانول، مدل انفیس تخمین دقیق‌تری از فشار تشکیل هیدرات نسبت به مدل ترمودینامیکی دانشگاه هریوت وات نشان داد. با توجه به نتایجی که در بخش



شکل ۷- مقایسه فشار تشکیل هیدرات به وسیله مدل ANFIS و مدل ترمودینامیکی دانشگاه هریوت وات (HWHYD) با مقادیر تجربی برای مخلوط گازی متان-پروپان در حضور بازدارنده متانول (نقطه: مقدار تجربی، خط چین: مدل HWHYD، خط توپر: مدل ANFIS)



شکل ۸- مقایسه فشار تشکیل هیدرات به وسیله مدل ANFIS و مدل ترمودینامیکی دانشگاه هریوت وات (HWHYD) با مقادیر تجربی برای مخلوط گازی متان-نیترژن در حضور بازدارنده کلرید سدیم (نقطه: مقدار تجربی، خط چین: مدل HWHYD، خط توپر: مدل ANFIS)

جدول ۱۰- شاخص‌های آماری مدل انفیس بهینه و مدل ترمودینامیکی دانشگاه هریوت وات (HWHYD) برای مخلوط گازی متان-پروپان در حضور بازدارنده متانول

غلظت بازدارنده	روش‌ها	R ²	RMSE	MAPE	MSE	MAE
%wt ۱۰	ANFIS Model	۰/۹۹۵۱	۰/۳۲۳۹	۲/۷۵۱	۰/۱۶۷۳	۰/۱۰۲۳
	HWHYD Model	۰/۹۹۳۴	۰/۵۲۷۱	۴/۸۳۱	۰/۶۱۵۸	۰/۳۸۳۷
%wt ۲۰	ANFIS Model	۰/۹۹۱۹	۰/۵۶۷۴	۶/۷۰۸۹	۱/۷۴۰۳	۰/۴۷۹۱
	HWHYD Model	۰/۹۸۱۲	۱/۲۱۷	۱۵/۶۲۲۷	۶/۲۷۲۵	۱/۲۷۳۶
%wt ۳۵	ANFIS Model	۰/۹۹۳۲	۰/۷۱۰۸	۵/۱۱۴۸	۰/۴۸۰۸	۰/۳۳۲۵
	HWHYD Model	۰/۹۵۶۲	۱/۴۵۹	۱۲/۶۸۵۱	۲/۵۶۷۱	۱/۰۸۱۱

جدول ۱۱- شاخص‌های آماری مدل انفیس بهینه و مدل ترمودینامیکی دانشگاه هریوت وات (HWHYD) برای مخلوط گازی متان-نیترژن در حضور بازدارنده کلرید سدیم

غلظت بازدارنده	روش‌ها	R ²	RMSE	MAPE	MSE	MAE
%wt ۵	ANFIS Model	۰/۹۹۷۵	۰/۱۴۳۷	۳/۵۶۰۸	۰/۱۳۵۲	۰/۲۸۲۱
	HWHYD Model	۰/۹۹۷۶	۰/۱۶۶۲	۳/۷۰۶۲	۰/۱۴۲۳	۰/۲۸۷۹
%wt ۱۰	ANFIS Model	۰/۹۹۸۱	۰/۱۱۸۵	۲/۱۰۳۹	۰/۰۵۳۲	۰/۲۳۰۱
	HWHYD Model	۰/۹۹۷۵	۰/۱۴۰۱	۲/۸۹۳۲	۰/۰۷۴۱	۰/۲۲۵۸

نتیجه‌گیری

مدل داده محور بر خلاف روش‌های مرسوم ترمودینامیکی نیازی به محاسبه خواص بحرانی اجزای سیستم و قواعد اختلاط ندارد. ضرایب برخورد دوتایی در مدل‌های ترمودینامیکی غالباً تابعیتی از دما دارند که فرض خطی بودن آن، خطای زیادی را موجب می‌شود. همچنین در مدل‌های داده محور، احتیاجی به محاسبات پیچیده، زمان‌بر و چند مرحله‌ای که در مدل‌های ترمودینامیکی و بحث تعادلات فازی وجود دارد، نیست و عملیات محاسبات در شبکه عصبی و سیستم فازی-عصبی (مدل انفیس) تک مرحله‌ای است. همچنین در استفاده از دو مدل داده محور جهت تخمین شرایط تشکیل هیدرات بر خلاف مدل‌های ترمودینامیکی، نیازی به دانستن این نکته که سیستم تشکیل هیدرات مورد بررسی در چه ناحیه فازی اعم از: L_w-H-L_{hc} و $L_w-VL_w-H-L_{hc}-H-V,I-H-V$ قرار گرفته، نمی‌باشد.

تشکر و قدردانی

بخشی از حمایت مالی برای انجام این تحقیق از طریق شرکت ملی گاز ایران تامین شده است و بدین وسیله از حمایت به عمل آمده توسط شرکت ملی گاز ایران تشکر و قدردانی می‌گردد.

در این پژوهش، شبکه عصبی مصنوعی و سیستم استنتاج تطبیقی فازی-عصبی (مدل انفیس)، توانست با دقت بالایی فشار تشکیل هیدرات را در سیستم‌های مختلف تشکیل هیدرات در قالب چهار الگوی A, B, C و D پیش‌بینی نماید. با به‌کارگیری شاخص‌های آماری از قبیل $RMSE, R^2, MSE$ و MAE این نتیجه به‌دست آمد که مدل انفیس در تمامی موارد نسبت به شبکه عصبی هم‌خوانی بهتری با داده‌های تجربی داشت. الگوی A برای سیستم‌هایی که اطلاعات دانسیته و دما در دسترس است، جواب بسیار مناسبی را در مقایسه با روابط تجربی $Hammerschmidt, Mottie$ و $Kobayashi$ نشان داد. از مقایسه نتایج به‌دست آمده از شبکه عصبی و مدل انفیس بر مبنای سه الگوی B, C و D با مقادیر تجربی و مدل ترمودینامیکی هریوت وات، مشخص شد که در مجموع دو مدل داده محور از درصد خطای کمتری برخوردار است که الگوی D به دلیل جامع بودن آن و در بر گرفتن اکثر حالات موجود برای سیستم تشکیل هیدرات به عنوان الگوی برتر از میان سه الگوی B, C و D انتخاب گردید. مزیت عمده دو مدل داده محور به کار رفته در این تحقیق بر روش‌های ترمودینامیکی بر اساس معادلات حالت موجود در بحث هیدرات این است که

منابع

- [1] Singh T.N., Sinha S. & Singh V.K., "Prediction of thermal conductivity of rock through physico-mechanical properties", Build. Env. Vol. 2 (1), pp. 146–155, 2007.
- [2] Kaul M., Hill R.L. & Walthall C., "Artificial neural networks for corn and soybean yield prediction", Agriculture System 85, pp. 1-18, 2005.
- [3] Torrecilla J.S., Otero L. & Sanz P.D., "A neural network approach for thermal/pressure food processing", Food Engineering Vol. 62: pp. 89-95, 2004.
- [4] Haykin S., *Neural networks: A comprehensive foundation*. McMillan College Publishing Company, New York, 1994.
- [5] Azadeh A., Ghaderi S.F. & Sohrabkhani.S., "Forecasting electrical consumption by integration of Neural Network, time series and ANOVA", Applied Mathematics and Computation, 2006.
- [6] Rai P., Majumdar G.C., Das Gupta S. & De, S., "Prediction of the viscosity of clarified fruit juice using artificial neural network A combined effect of concentration and temperature", J. Food Eng., Vol. 68, pp. 527-533, 2005.
- [7] Bouchard C. & Grandjean A., "A neural network correlation for variation of viscosity of sucrose aqueous solutions with temperature and concentration", Lebensm- Wiss. U. -Technol., Vol. 28, pp. 157-159, 1995.
- [8] Laugier S., Richon D., "Use of artificial neural networks for calculating derived thermodynamic quantities from volumetric property data", Fluid Phase Equilib., Vol. 210, pp. 247-255, 2003.
- [9] Potukuchi W. & Wexler AS., "Predicting vapor pressures using neural networks", Atmos. Environ., Vol. 31, pp. 741-753, 1997.
- [10] Shyam S.S., Oon-Doo B., & Michele M., "Neural networks for predicting thermal conductivity of bakery products", J. Food Eng., Vol. 52, pp. 299-304, 2002.
- [11] Petersen R., Fredenslund A., & Rasmussen P., "Artificial neural networks as a predictive tool for vapor liquid equilibrium", Comput. Chem. Eng., Vol. 18, pp. s63-s67, 1994.
- [12] Sharma R., Singhal D., Ghosh R. & Dwivedi A., "Potential applications of artificial neural networks to thermodynamics: Vapour-liquid equilibrium predictions", Com-put. Chem. Eng., Vol. 23, pp. 385-390, 1999.
- [13] Ganguly S., "Prediction of VLE data using radial basis function network", Comput. Chem. Eng., Vol. 27, pp. 1445- 1454, 2003.
- [14] Hoseini-Nasab S.A., Izadpanah A.M. & Vafaei-Sefti M., "Application of adaptive neuro-fuzzy inference system for estimation of vapor+ liquid equilibria of binary systems, carbon dioxide–ethyl caproate, ethyl caprylate and ethyl caprate", Presented in The 6th International Chemical Engineering Congress and Exhibition (IChEC 2009), Kish Island, Iran, 16-20 November, 2009.
- [15] Elgibaly A. & Elkamel A., "A new correlation for predicting hydrate formation conditions for various gas mixtures and inhibitors Fluid Phase Equilibria", Vol. 152, pp. 23–42, 1998.
- [16] Elgibaly A. & Elkamel A., "Optimal Hydrate Inhibition Policies with the Aid of Neural Networks", Energy & Fuels, Vol. 13, pp. 105-113, (1999).
- [17] Heydari A., Shayesteh K. & Kamalzadeh L., "Prediction of hydrate formation temperature for natural gas using

artificial neural network”, Oil and Gas Business, 2006.

[18] Zahedi G., Karami Z. & Yaghoobi H, “*Prediction of hydrate formation temperature by both statistical models and artificial neural network approaches*”, Energy Conversion and Management, Vol. 50, pp. 2052–2059, (2009).

[۱۹] دلاور م. تحلیل و ارائه مدل نوسانات تراز آب دریاچه ارومیه و آنالیز ریسک مناطق ساحلی. پایان‌نامه کارشناسی ارشد سازه‌های آبی، دانشکده کشاورزی، دانشگاه تربیت مدرس، ۱۳۸۴.

[۲۰] جورابیان م.، هوشمند ر.ا.، منطق فازی و شبکه‌های عصبی (تألیف کارتالوپولس). چاپ اول، انتشارات دانشگاه شهید چمران اهواز، ۳۰۰ ص، ۱۳۸۱.

[21] Sloan E.D., *Clathrate hydrates of natural gases*, Second ed, Mrcel, New York, 1998.

[22] Vakil-Baghmisheh M.T., *Farsi character recognition using artificial neural networks*. PhD Thesis, Faculty of Electrical Engineering, University of Ljubljana, 2002.

[۲۳] منهاج م. ب.، هوش محاسباتی (مبانی شبکه‌های عصبی). جلد اول، انتشارات دانشگاه پلی تکنیک، ۱۳۷۹.

[24] Minns and Hall, *Artificial neural network analysis of heat pumps using refrigerant mixtures*, Energy Conversion and Management Vol. 45 (11–12), pp. 1917–1929, (1996).

[25] Haykin S., *Neural networks, in: A Comprehensive Foundation*, Macmillan College Publishing Company, New York, USA, 1994.

[26] Moller M.F., “*A scaled conjugate gradient algorithm for fast supervised learning*”, Neural Networks Vol. 6 (4), pp. 525–533, 1993.

[27] Coulibaly P., Anctil F., & Bobee B., “*Daily reservoir inflow forecasting using artificial neural networks with stopped training approach*”, Journal of Hydrology, Vol. 230, pp. 244-257, 2000.

[28] Demuth H. & Beale M., *Neural Network Toolbox User’s Guide*, Version 4 (Release 12), The MathWorks, Inc, 2000.

[۲۹] البرزی م.، آشنایی با شبکه‌های عصبی مصنوعی، انتشارات دانشگاه صنعتی شریف، ۱۳۸۰.

[30] Denal M.A., Palis F. & Zeghibid A., “*ANFIS: Based Modeling Control of Non-linear Systems*”. IEEE International Conference on Systems, Man & Cybernetic, pp. 3433–3437, 2006.

[31] Katz D.L., “*Prediction of condition for hydrate formation in natural gases*”, Trans. AIME, Vol. 160, pp. 140, 1945.

[32] Kobayashi R., Song K.Y., & Sloan E.D., “*Phase behavior of water/hydrocarbon systems*”, quoted in Bradley, H.B., Petroleum Engineers Handbook, Richardson: Society of Petroleum Engineers, (1987).

[33] Motiee M., “*Estimate possibility of hydrates*”, Hyd. Proc., pp. 98, July, 1991.

[34] HAMMERSCHMIDT E. G., “*Am. Gas. Assoc.*” Monthly, vol. 18, pp. 278, (1936).

[35] Bazaraa M., Sherali S.H.D., & Shetty C M., *Nonlinear Programming: Theory and Algorithms*, 2nd ed., John Wiley & Sons. Inc., 1993.

[36] Heriot-Watt University Hydrate model: <http://www.pet.hw.ac.uk/research/hydrate/>. (See also: Tohidi, B.; Burgass, R.W.; Danesh, A.; Todd A.C. Hydrate inhibition effect of produced water, Part 1. Ethane and propane simple gas hydrates. SPE 26701. Proc. of the SPE Offshore Europe 93 Conference, pp. 255–264, 1993.

[37] Valderrama J.O., “*A generalized Patel-Teja equation of state for polar and nonpolar fluids and their mixtures*”,

J. Chem. Eng. Jpn., Vol. 23, pp. 87–91, 1990.

[38] Avlonitis D., Danesh A. & Todd A.C., "Prediction of VL and VLL equilibria of mixtures containing petroleum reservoir fluids and methanol with a cubic EOS", Fluid Phase Equilib., Vol. 94, pp. 181–216, (1994).

[39] Van der Waals J.H. & Platteeuw J. C., "Clathrate Solutions", Adv. Chem. Phys., Vol 2, pp. 1–57, (1959).

[40] Avlonitis D., *Thermodynamics of gas hydrate equilibria*, Ph.D. Thesis, Department of Petroleum Engineering, Heriot-Watt University, Edinburgh, UK, 1992.

[41] Tohidi-Kalorazi B., *Gas hydrate equilibria in the presence of electrolyte solutions*, Ph.D. Thesis, Department of Petroleum Engineering, Heriot-Watt University, Edinburgh, UK, 1995.