

## بررسی تشکیل هیدرات‌های گازی در خطوط لوله گاز با استفاده از مدل شبکه عصبی مصنوعی و سیستم فازی عصبی (انفیس)

بهزاد ولی‌پور عالم<sup>\*</sup>، دانشگاه علوم تحقیقات تهران • علی اسفندیاری بیات هیأت علمی دانشکده نفت دانشگاه آزاد اسلامی علوم تحقیقات تهران • مهدی ولی‌پور، دانشگاه آزاد اسلامی واحد شهر قدس

### چکیده

هیدرات‌های گازی در فرآورش گاز طبیعی و تجهیزات فرآیندی سیال تولیدی از میادین نفت و گاز، اعم پالایشگاه‌ها، پتروشیمی و دستگاه‌های موجود در صنایع شیمیایی، در صورت حضور هم‌زمان مولکول‌های سبک هیدروکربوری و آب، در شرایط ترمودینامیکی فشار بالا و دمای پایین تشکیل می‌شود. پدیده هیدرات‌های گازی ترکیبی از گازهای سبک مثل متان، اتان یا دی‌اکسید کربن با مولکول‌های آب است که تحت شرایط خاص دمایی و فشاری ماده‌ای شبیه یخ را تشکیل می‌دهد که حجم زیادی از گاز را در خود جای می‌دهد. هیدرات‌های گازی عموماً به صورت جامد در آمده و توان عملیاتی خط لوله انتقال گاز را کاهش داده یا حتی به انسداد کلی خط لوله منجر می‌شود. لذا تعیین شرایط تشکیل هیدرات در یک فرآیند تولید تا انتقال گاز به منظور جلوگیری از تشکیل هیدرات اهمیت دارد.

این موضوع در این مقاله با دو مدل داده‌محور<sup>۱</sup>، یعنی شبکه عصبی مصنوعی و سیستم فازی-عصبی (مدل انفیس) به عنوان ابزاری برای تخمین فشار و دمای تشکیل هیدرات در خطوط لوله گاز با استفاده از داده‌های تجربی، توسعه داده شد. بنابراین ساختار بهینه هر یک از این مدل‌های داده‌محور برای سیستم‌های مورد نظر، براساس پارامترهای آماری تعیین شد. مقادیر حاصل از شبکه عصبی و مدل انفیس با نتایج به دست آمده از روابط تجربی و مدل مقایسه (HWHYD) ترمودینامیکی دانشگاه هریوت وات مورد مقایسه قرار گرفت. 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.

### اصلاحات مقاله

تاریخ ارسال نویسنده: ۹۶/۰۷/۲۲

تاریخ ارسال به داور: ۹۶/۰۸/۱۳

تاریخ پذیرش داور: ۹۶/۰۸/۲۸

### واژگان کلیدی:

شار تشکیل هیدرات، مدل شبکه عصبی مصنوعی، سیستم فازی عصبی، مدل انفیس، گاز طبیعی

### مقدمه

هیدرات‌های گازی ترکیبی با شبکه بلوری هستند که از پیوستن و قرار گرفتن مولکول‌های گازهای سبک به عنوان مهمان در شبکه‌های کریستالی مولکول‌های آب (به عنوان میزبان) متناسب با دما و فشار فرآیند به وجود می‌آیند. برای شبیه‌سازی دقیق شرایط تشکیل هیدرات عمدتاً از مدل‌های ترمودینامیکی استفاده می‌شود و در این زمینه فعالیت‌های بسیار زیاد و متنوعی انجام شده است. اما مدل‌های ترمودینامیکی دارای ضعف‌ها و مشکلات قابل توجهی هستند. به طور مثال هر یک از مدل‌های ترمودینامیکی برای سیستم‌های خاص و محدودی به لحاظ اجزای تشکیل دهنده، توسعه داده شده و این مدل‌ها برای استفاده در سیستم‌های چند جزئی نیاز به پارامترهای متعددی از جمله فاکتورهای توصیف برخورد دوتایی مولکول‌ها دارند که این پارامترها عمدتاً تابعی از دما و اجزای سیستم هستند. برای به دست آوردن این پارامترها و به کار بردن مدل‌های ترمودینامیکی، نیاز به محاسبات تعادل فازی پیچیده‌ای است که از طریق حل به روش حدس و خطا نتیجه بخش خواهد بود. بنابراین استفاده از روش‌هایی براساس روابط ذاتی میان داده‌ها، نگاشت غیرخطی بین متغیرهای مستقل و وابسته ضرورت دارد.

مزیت مدل‌های داده‌محور شامل آموزش مستقیم مدل از روی داده‌ها بدون نیاز به در نظر گرفتن فرض اولیه و دانش قبلی از روابط پارامترهای مورد مطالعه و قابلیت ارائه یک رابطه ریاضی حسب برقراری ارتباط منطقی بین مجموعه‌ای از ورودی‌ها و خروجی‌ها برای تخمین خروجی متناظر با ورودی دلخواه است [۱، ۲ و ۳].

مدل‌های داده‌محور مذکور توانایی تخمین هر تابع غیرخطی پیوسته و مقاومت در مقابل خطا را دارد [۴ و ۵]. این قابلیت‌ها و کارکردهای شبکه عصبی مصنوعی و سیستم فازی-عصبی (مدل انفیس)<sup>۲</sup> باعث شده تا این دو مدل، به عنوان ابزاری جایگزین برای تخمین خواص ترمودینامیکی مختلف مانند ویسکوزیته [۶ و ۷]، دانسیته و ضریب تراکم‌پذیری [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 Zahedi و همکاران [۱۸] از شبکه عصبی برای تخمین دمای تشکیل هیدرات استفاده کردند. اما استفاده از سیستم استنتاج تطبیقی عصبی-فازی (انفیس) در تخمین دما و یا فشار تشکیل هیدرات در هیچ کاری گزارش نشده است.

یکی از روش‌های جدید در حل مسائل مهندسی، استفاده از مدل‌های داده‌محور از قبیل شبکه عصبی مصنوعی و سیستم‌های فازی-عصبی است.

\* نویسنده‌ی عهده‌دار مکاتبات (valipouroil2009@gmail.com)


### ۳- پارامترهای تأثیرگذار بر تشکیل هیدرات

تشکیل هیدرات در سیستم‌های گازی مختلف رخ می‌دهد. به طور مثال در سیستم‌های گازی حاوی مواد هیدروکربنی، غیرهیدروکربنی و یا ترکیبی از این دو حالت هیدرات تشکیل می‌شود. از آنجایی که در مدل‌های داده‌محور (در این مطالعه، مدل‌های داده‌محور شبکه عصبی مصنوعی و مدل انفیس)، براساس شرایط ورودی و خروجی سیستم‌ها یا شرایط اولیه و نهایی، متغیرها تخمین زده می‌شود، چهار الگو برای ارتباط پارامترهای موثر در شرایط تشکیل هیدرات به منظور توسعه مدل‌های داده‌محور، در نظر گرفته شد. این الگوها بر مبنای آنکه فشار تشکیل هیدرات وابسته به کدام مشخصه از سیستم‌های تشکیل هیدرات است، معرفی شده است.

پارامترهای تأثیرگذار در تشکیل هیدرات شامل دما و فشار تشکیل هیدرات، جزء مولی یا ترکیب درصد اجزای گازی، دانسیته گاز و ترکیب درصد وزنی بازدارنده‌ها است.

در این مطالعه فشار تشکیل هیدرات تابعی از دیگر متغیرهای مذکور فرض شده و از مدل‌های داده‌محور جهت پیش‌بینی فشار تشکیل هیدرات با استفاده از متغیرهای متبوع آن استفاده می‌شود. بنابراین برای بررسی کارایی مدل‌های داده‌محور در تخمین فشار تشکیل هیدرات - در هر یک از سیستم‌ها با شرایط متفاوت از نظر عناصر تشکیل دهنده - چهار الگوی A، B، C و D فرض می‌شود که براساس نوع سیستم، فشار تشکیل هیدرات تابعی از متغیرهای تأثیرگذار در تشکیل هیدرات در نظر گرفته می‌شود [۱۵]. چهار الگوی A، B، C و D براساس متغیر ورودی به مدل داده‌محور از هم متمایز می‌شوند و ورودی و خروجی را برای مدل‌های داده‌محور معرفی می‌کنند. در الگوی A، فرض شده 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 داده‌محور در نظر گرفته شده است.

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



شکل ۱ | شماتیک یک شبکه چند پرسپترون [۱۹]

در این تحقیق جهت شبیه‌سازی تشکیل هیدرات در خطوط لوله‌های انتقال گاز در حضور و عدم حضور بازدارنده‌های ترمودینامیکی، دو مدل داده‌محور شبکه عصبی مصنوعی و سیستم فازی-عصبی (مدل انفیس) استفاده شد. نتایج نشان داد که دو مدل داده‌محور به نحو مطلوبی قادر به پیش‌بینی فشار (نرخ تشکیل) هیدرات است و مدل انفیس که ترکیبی از دو روش سیستم فازی و شبکه عصبی مصنوعی است، نتایج مطلوب‌تری نسبت به دیگر روش‌ها دارد.

### ۱- 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 کنند. در شبکه عصبی میزان فعالیت هر یک از این اتصالات، توسط تاریخچه‌ای از اطلاعات موجود طی فرآیند یادگیری تنظیم می‌شود و در نهایت، مدل قادر خواهد بود، قوانین مرتبط میان ورودی‌ها و خروجی‌ها را کشف کند، هر چند این قوانین غیرخطی و پیچیده باشند [۱۹].

در ساختار شبکه‌های عصبی مصنوعی که به آن معم شهود، نورون‌ها در دسته‌هایی بنام لایه مرتب می‌شوند. برای نمونه 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.

### ۲- سیستم استنتاج تطبیقی عصبی-فازی

در شبکه عصبی-فازی ابتدا قسمت عصبی برای یادگیری شبکه، طبقه‌بندی قابلیت‌ها و 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 و حتی پس از یادگیری به اصلاح توابع عضویت و قواعد منطق فازی ادامه می‌دهد. همچنین منطق فازی برای استنباط و مهیا کردن یک خروجی غیرفازی شده استفاده می‌شود [۲۰]. به طور کلی می‌توان گفت که از شبکه عصبی در طراحی بهینه سیستم استنتاج فازی (FIS) استفاده می‌شود. ترکیب سیستم‌های فازی مبتنی بر قواعد منطقی و 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 غیرخطی بین فضای ورودی و خروجی استفاده می‌کند.

این داده‌ها از کتاب جامع اسلون [۲۱] استخراج شد. این داده‌ها مربوط به سال‌های ۱۹۳۴ تا ۲۰۰۸ است که از منابع مختلف به وسیله نویسنده گردآوری شده است.

#### ۴- توسعه شبکه عصبی مصنوعی

قبل از به کارگیری 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 مطالعه از تابع سیگموئید استفاده شد که خروجی این تابع بین ۰ و ۱ است. بنابراین داده‌های ورودی با استفاده از رابطه (۵) بین دو عدد ۰/۱ و ۰/۹ نرمال شدند [۲۲].

$$X_i = 0.8 \frac{X - X_{min}}{X_{max} - X_{min}} + 0.1 \quad (5)$$

در این رابطه  $X_i$  مقدار نرمال شده،  $X$  مقدار واقعی و  $x_{min}$  و  $x_{max}$  مقادیر حداقل و حداکثر داده‌ها است. 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 به عنوان تابع فعالیت در لایه میانی و خروجی و تابع خطی برای لایه ورودی استفاده شد. برای آموزش شبکه عصبی، روش استاندارد انتشار برگشتی<sup>۴</sup> خطا مورد استفاده قرار گرفت و برای دستیابی به بهترین الگوریتم یادگیری، از سه الگوریتم یادگیری استفاده شد [۲۶-۲۴]. برای آموزش و امتحان دو مدل داده محور<sup>۵</sup> و جلوگیری از برازش بیش از حد از روش توقف زود هنگام<sup>۶</sup> استفاده شد [۲۷]. در این روش کل داده‌ها به طور تصادفی به سه دسته آموزش، برازش متقابل (نظارت) و آزمون تقسیم می‌شوند [۲۸].

بدین منظور ۶۰ درصد از داده‌های موجود برای آموزش، ۲۰ درصد برای برازش متقابل و مابقی برای آزمایش شبکه در نظر گرفته شد. در این مطالعه در ساختار تمامی شبکه‌ها، طراحی بهینه با یک لایه مخفی انجام شد و تعداد بهینه نرون‌های لایه مخفی به روش سعی و خطا به دست آمد [۲۹]. تعداد نرون در لایه مخفی، از ۷ تا ۱۵ (۷، ۱۰، ۱۳، ۱۵) تغییر داده شد تا براساس پارامترهای آماری و به کارگیری توابع یادگیری مختلف در الگوریتم آموزش و پس انتشار خطا در مرحله آموزش، بهترین تابع یادگیری و مناسب‌ترین تعداد نرون در لایه مخفی به دست آید. معیار گزینش شبکه بهینه در مرحله آموزش، تولید کمترین مقدار پارامترهای

( $\gamma$ ) از حاصل تقسیم وزن مولکولی گاز خالص یا وزن مولکولی ظاهری<sup>۲</sup> (AMW) مخلوط گاز بر وزن مولکولی ظاهری<sup>۳</sup> هوا تعیین می‌شود.

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 بر حسب دما و ترکیب درصد عناصر گازی و مخلوطی از آنها به صورت زیر ارائه شده است.

$$P = f_2(T, y_{c1}, y_{c2}, y_{c3}, y_{i-c4}, y_{n-c4}) \quad (2)$$

$\gamma$  درصد مولی هر جزء در مخلوط است. در الگوی C، علاوه بر متغیرهای مدل B، عناصر تشکیل دهنده غیر هیدروکربنی هیدرات مانند دی‌اکسید کربن، نیتروژن و سولفید هیدروژن هم لحاظ می‌شود:

$$P = f_3(T, y_{c1}, y_{c2}, y_{c3}, y_{i-c4}, y_{n-c4}, y_{CO_2}, y_{N_2}, y_{H_2S}) \quad (3)$$

در الگوی D جزء مولی هیدروکربن‌های غیر عامل تشکیل هیدرات مانند ایزوپنتان، نرمال پنتان (یکجا با عنوان پنتان) و  $C_{6+}$  و همچنین بازدارنده‌ها مانند متانول، کلرید سدیم، اتیلن گلیکول، کلرید کلسیم و اتانول به عنوان متغیرهای الگوی C به عنوان متغیرهای ورودی در نظر گرفته شده است.

$$P = f_3(T, y_{c1}, y_{c2}, y_{c3}, y_{i-c4}, y_{n-c4}, y_{CO_2}, y_{N_2}, y_{H_2S}, y_{c5}, y_{c6+}, W_{MeOH}, W_{EG}, W_{NaCl}, W_{CaCl_2}) \quad (4)$$

در این مطالعه برای توسعه و اعتبارسنجی مدل‌های داده محور، بیش از ۱۴۶۰ داده تعادل فازی هیدرات مورد استفاده قرار گرفت که بخش عمده

شاخص‌های آماری انتخاب شده در تعیین بهترین ساختار شبکه	
معادل مربوطه	نام شاخص آماری
ضریب تعیین <sup>۷</sup>	$R^2 = 1 - \frac{\sum_{i=1}^n (exp\ i - pre)^2}{\sum_{i=1}^n pre\ i^2}$
ریشه مجذور مربعیت خطا <sup>۸</sup>	$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^n (exp\ i - pre\ i)^2}$
ضریب پراکنندگی <sup>۹</sup>	$COV = \frac{RMSE}{c_{xp}} \times 100$
میانگین نسبی درصد خطای مطلق <sup>۱۰</sup>	$MAPE(\%) = \frac{1}{N} \sum_{i=1}^N \left( 100 \frac{(exp\ i - pre\ i)}{exp\ i} \right)$
میانگین خطای مطلق <sup>۱۱</sup>	$MAE = \frac{1}{N} \sum_{i=1}^N  exp\ i - pre\ i $

آماري ریشه میانگین مجذور خطا، خطای انحراف میانگین و بیشترین مقدار ضریب تعیین  $R^2$  در خروجی ها بود.

#### ۵- معیارهای ارزیابی مدل ها

برای اطمینان از عملکرد یک مدل پیش بینی از جنبه های مختلف و همچنین مقایسه آن با روش های دیگر، پارامترهای آماری متعددی به طور همزمان مورد استفاده قرار گرفت. در این تحقیق از سه پارامتر مجذور خطا، خطای انحراف میانگین و مقدار ضریب تعیین  $R^2$  برای تعیین بهترین ساختار شبکه های ANN، ANFIS و همچنین پارامترهای میانگین درصد خطای مطلق و میانگین خطای متوسط برای مقایسه مدل های داده محور بهینه با روش های دیگر استفاده شد. در جدول-۱، معادلات مربوط به محاسبه این شاخص های آماری ارائه شده است.

در روابط فوق، N تعداد نمونه، exp مقادیر تجربی، pre مقادیر پیش بینی شده بوسیله مدل ها و روابط و (exp): میانگین مقادیر تجربی است.

#### ۶- روابط تشکیل هیدرات

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

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

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

رابطه Hammerschmit

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

$$T = \alpha P^B \quad (8)$$

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.

$$T = 1/A_0 + A_1(\text{Lnp}) + A_2(\text{Lnp})^2 + A_3(\text{Lnp})^3 + A_4(\text{Lny}) + A_5(\text{Lny}) + p \quad (10)$$

$$A_6(\text{Lny})^3 + A_7(\text{Lnp})(\text{Lny}) + A_8(\text{Lnp})(\text{Lny})^2 + A_9(\text{Lnp})^2(\text{Lny}) + A_{10}(\text{Lnp})^2(\text{Lny})^2$$

ثابت های روابط تجربی فوق از روش آنالیز برازش غیرخطی Nelder-Mead<sup>۱۱</sup> به دست آمد [۳۵]. از این روش برای محاسبه مقادیر بهینه ثابت ها از طریق مینیمم کردن تابع هدف مجموع قدرمطلق انحراف متوسط دما و فشار، طبق رابطه زیر استفاده شد.

$$OF = \sum_{n=1}^n \left( \frac{P_{exp} - P_{pre}}{P_{exp}} + \frac{T_{exp} - T_{pre}}{T_{exp}} \right) \quad (11)$$

در رابطه فوق  $T_{exp}$  و  $P_{exp}$  به ترتیب فشار و دمای تجربی،  $T_{cal}$  و  $P_{cal}$  فشار و دمای محاسبه شده با استفاده از رابطه مدنظر و n تعداد داده های به کار رفته در بهینه کردن پارامترهای معادلات است. از روش بهینه سازی Nelder-Mead ثابت های این سه معادله به همراه خطای استاندارد هر کدام از ثوابت محاسبه شد که نتایج آن در جداول-۲ تا ۵ ارائه شده است. نتایج پیش بینی شبکه عصبی و مدل انفیس بهینه در حالت جامع (هنگامی که دانسیته گاز مقداری بین ۰/۵۵۴ تا ۱ را دارد)، با روابط تجربی، Mottie، Kobayashi و Hammerschmidt برای داده های تجربی در جدول-۶ مقایسه شده است. همچنین پیش بینی مدل ها و روابط تجربی به همراه مقادیر تجربی، در شکل های-۲ تا ۶ رسم شده است.

۲ | ثابت های معادله-۶ به همراه خطای استاندارد هر یک از ثابت ها

خطای استاندارد	اندازه ضریب	ضرایب	خطای استاندارد	اندازه ضریب	ضرایب
۱/۷۹۶۶۹۴E-۵	۱۶۲/۸۲۸۷	a4	۱/۳۹۷۷۶۴E-۲	-۱۵۲/۹۱۳۲	a1
۳/۰۷۶۸۷۵E-۷	-۵۵/۶۵۳۹	a5	۳/۸۲۹۶۷۷E-۳	۳۲/۲۰۷۶	a2
۴/۵۴۷۳۲۸E-۲	-۸/۰۶۴۴	a6	۳/۹۳۴۶۰۶E-۴	-۱/۱۲۵۶	a3

۳ | ثابت های معادله-۷ به همراه خطای استاندارد هر یک از ثابت ها

خطای استاندارد	اندازه ضریب	ضرایب	خطای استاندارد	اندازه ضریب	ضرایب
۹/۲۸۲۴۷۱E-۳	-۹/۳۲۱۸	b4	۱/۸۱۶۶۶۱E-۱	۸/۷۷۳۷	b1
۳/۶۷۸۲۱E-۲	۳/۵۵۲۸	b5	۲/۰۴۷۵۲۸E-۱	-۰/۰۲۵۵	b2
۴/۱۰۱۹۳۲E-۲	۰/۰۳۱۲	b6	۶/۳۹۷۰۹۱E-۴	۷/۸۱۷۲E-۴	b3

با مقایسه بین مقادیر تجربی و تخمین‌های شبکه عصبی مدل انفیس و روابط تجربی - به صورت‌های متفاوت- مشخص شد که نتایج به دست آمده از مدل‌های داده محور دارای دقت بالاتری نسبت به هر سه روابط تجربی است. از رابطه Hammerschmidt تخمین‌های غیر دقیقی از فشار تشکیل هیدرات محاسبه می‌شود 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، اما با توجه به تعداد بالای ثابت‌ها در روابط تجربی Kobayashi و Mottie، استفاده از این روابط در شرایط مختلف، دشوار بوده و این امر ضرورت استفاده از مدل‌های داده محور را تأیید می‌کند. از بین دو مدل داده محور، مدل انفیس دارای پاسخ بهتری نسبت به شبکه عصبی است. چراکه 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 که این مزیت اصلی و تفاوت اساسی سیستم فازی-عصبی نسبت به شبکه عصبی است. اما در مقابل، شبکه عصبی برای کل داده‌ها با پراکندگی‌های مختلف، با یک استراتژی پیش‌بینی می‌کند و همین نکته اصلی‌ترین دلیل پایین‌تر بودن دقت شبکه عصبی نسبت به مدل انفیس 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 بدلیل اغتشاش کمتر سیستم فازی نسبت به شبکه عصبی است. همچنین این شبکه‌های عصبی مبتنی بر الگوریتم پس انتشار خطا، دارای ضعف‌هایی نظیر گیر کردن شبکه در نقطه مینیمم محلی<sup>۱۳</sup> و یا پایین بودن سرعت همگرایی<sup>۱۴</sup> محاسبات است که بر دقت تخمین تأثیرگذار است. اشکال دیگر شبکه‌های عصبی، نیاز این روش به داده‌های بسیار زیاد برای رسیدن به پاسخ جامع

با مقایسه بین مقادیر تجربی و تخمین‌های شبکه عصبی مدل انفیس و روابط تجربی - به صورت‌های متفاوت- مشخص شد که نتایج به دست آمده از مدل‌های داده محور دارای دقت بالاتری نسبت به هر سه روابط تجربی است. از رابطه Hammerschmidt تخمین‌های غیر دقیقی از فشار تشکیل هیدرات محاسبه می‌شود 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، اما با توجه به تعداد بالای ثابت‌ها در روابط تجربی Kobayashi و Mottie، استفاده از این روابط در شرایط مختلف، دشوار بوده و این امر ضرورت استفاده از مدل‌های داده محور را تأیید می‌کند. از بین دو مدل داده محور، مدل انفیس دارای پاسخ بهتری نسبت به شبکه عصبی است. چراکه 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 که این مزیت اصلی و تفاوت اساسی سیستم فازی-عصبی نسبت به شبکه عصبی است. اما در مقابل، شبکه عصبی برای کل داده‌ها با پراکندگی‌های مختلف، با یک استراتژی پیش‌بینی می‌کند و همین نکته اصلی‌ترین دلیل پایین‌تر بودن دقت شبکه عصبی نسبت به مدل انفیس است.

## ۷- نتایج توسعه شبکه عصبی و مدل انفیس بر مبنای الگوی B

مدل داده محور توسعه داده شده بر مبنای الگوی B طبق رابطه-۲،

خطای استاندارد	اندازه ضریب	ضرایب
۲/۴۷۱۹۰۴E-۱	۱۴/۷۵۹۳	$\alpha$
۶/۲۹۹۰۴۴E-۲	۰/۲۱۰۱	$\beta$

۵- ثابت‌های معادله-۱۱ به همراه خطای استاندارد هر یک از ثابت‌ها

خطای استاندارد	اندازه ضریب	ضرایب	خطای استاندارد	اندازه ضریب	ضرایب
۱/۶۰۸۰۰۱E-۴	-۲/۱۶۹۹۲E-۳	A6	۱/۴۹۱۷۹۵E-۳	-۲/۹۹۸۶۷۴E-۳	A0
-۳/۲۳۳۵۱۹E-۴	۷/۱۱۴۱۴۵E-۴	A7	۳/۰۳۳۴۷۵۱E-۴	۱/۶۱۵۲۷۲E-۳	A1
۵/۷۴۵۷۵۷E-۴	۲/۰۶۲۱۵۴E-۳	A8	۴/۶۷۷۴۳۷E-۷	-۱/۲۴۱۲۹۲E-۴	A2
۱/۰۸۷۴۵۹E-۵	-۲/۲۸۸۶۲۴E-۵	A9	۲/۳۹۴۳۴۵E-۳	۳/۰۱۲۵۳۴E-۶	A3
۱/۸۹۲۴۳۶E-۵	-۷/۰۴۴۷۴E-۵	A10	-۵/۷۸۸۶۴۳E-۳	-۱/۶۳۶۴۷۸E-۲	A4
			۴/۳۲۴۹۶۹E-۳		A5

قابل اطمینان با خطای پایین است. اما در مقابل، روش فازی-عصبی این امکان را فراهم می‌کند تا بتوان از داده‌های کمتری برای رسیدن به پاسخ دلخواه بهره برد.

#### ۸- 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 است. به عنوان نمونه یک سیستم گاز طبیعی، مخلوطی از گازهای متان، اتان، پروپان، بوتان، دی‌اکسید کربن، سولفید هیدروژن و نیتروژن برای تخمین فشار تشکیل هیدرات به وسیله شبکه عصبی مصنوعی و مدل انفیس بر مبنای الگوی C استفاده شد. توپولوژی‌های مختلف در توسعه شبکه عصبی و مدل انفیس به کار رفت و ساختار بهینه براساس ارزیابی شاخص‌های آماری هریک از این دو مدل داده محور، تعیین شد. بدین ترتیب شبکه عصبی ۱۰-SCG، شبکه‌ای با الگوریتم یادگیری SCG و ۱۰ نورون در لایه پنهان و مدل انفیس ۳-Gaussmf، یعنی ساختاری با ۳ عدد از تابع عضویت گوسین، مناسب‌ترین عملکرد را دارد. تخمین‌های شبکه عصبی مصنوعی و مدل انفیس با ساختار بهینه با مقادیر مدل ترمودینامیکی

HWHYD در تخمین فشار تشکیل هیدرات در قالب چند معیار آماری در جدول ۸- مقایسه شده است.

نتایج نشان می‌دهد که مدل ترمودینامیکی دانشگاه هریوت وات از دقت کمتری نسبت به مدل‌های داده محور برخوردار است. علت اصلی پایین بودن دقت مدل HWHYD را می‌توان به تعداد بالای اجزای موجود در ترکیب گاز، وجود گازهای هیدروکربنی و غیر هیدروکربنی در کنار هم و در نتیجه عدم توانایی مدل ترمودینامیکی در لحاظ کردن اثر متقابل بین اجزا در قالب پارامترهای برخوردار دانست.

#### ۹- نتایج توسعه مدل انفیس بر مبنای الگوی D

الگوی D، جامع‌ترین الگو نسبت به سایر الگوها است. این الگو تقریباً تمامی حالات یک سیستم به لحاظ عناصر و اجزای تشکیل دهنده که در آن تشکیل هیدرات محتمل است، را در بر می‌گیرد. شبکه عصبی زمانی که تعداد داده‌های آموزشی کم باشد، جواب مناسبی ندارد و همین نکته از مزیت‌های اصلی مدل انفیس بر شبکه عصبی است که انفیس با تعداد کم داده آموزشی نیز جوابی با دقت بالا دارد. با توجه به این نکته و همچنین از آنجایی که در توسعه مدل‌های داده محور مبنای الگوهای A+B و C بر

شخص‌های آماری مدل‌های داده محور بهینه و روابط تجربی مورد بررسی برای کل داده‌های تجربی در نظر گرفته شده با دانسیته گاز

Methods	تعداد نقاط	MAE	MAPE	R <sup>2</sup>	E <sub>max</sub>
ANN	۲۱۲	۴۵/۰۵۹۱	۴/۹۰۹۱	۰/۹۹۲۵	۱۹۵/۰۷
ANPIS	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

شخص‌های آماری مدل‌های داده محور بهینه و مدل ترمودینامیکی دانشگاه هریوت وات HWHYD برای مخلوط‌گازی متان-اتان و متان-اتان-پروپان

شاخص‌های آماری	مخلوط‌گازی متان - اتان - پروپان			مخلوط‌گازی متان- اتان		
	شبکه عصبی	مدل انفیس	مدل HWHYD	شبکه عصبی	مدل انفیس	مدل HWHYD
R <sup>1</sup>	۰/۹۹۷۵	۰/۹۹۸۶	۰/۹۹۶۲	۰/۹۹۲۱	۰/۹۹۳۴	۰/۹۹۲۸
RMSE	۷۷۹/۶۲۵	۶۳۶/۱۳۲۹	۹۷۵/۲۶۰۳	۶۴/۳۱۷۸	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

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، نسبت به شبکه عصبی در تخمین فشار تشکیل هیدرات در سیستم‌های مختلف عملکرد بهتری از خود نشان می‌دهد.

### نتیجه‌گیری

در این مطالعه شبکه عصبی مصنوعی و سیستم استنتاج تطبیقی فازی-عصبی (مدل انفیس) توانست با دقت بالایی فشار و دما تشکیل هیدرات را در سیستم‌های مختلف تشکیل هیدرات در قالب چهار الگوی A+B و C و D پیش‌بینی کند. با به کارگیری شاخص‌های آماری از قبیل  $R^2$ ، RMSE، MAPE و MSE این نتیجه به دست آمد که مدل انفیس در تمامی موارد نسبت به شبکه عصبی هم‌خوانی بهتری با داده‌های تجربی دارد.

الگوی A برای سیستم‌هایی که اطلاعات دانسیته و دما در دسترس است، جواب بسیار مناسبی را در مقایسه با روابط تجربی، Mottie و Hammerschmidt و Kobayashi نشان داد.

از مقایسه نتایج به دست آمده از شبکه عصبی و مدل انفیس بر مبنای سه الگوی A، B و C و D با مقادیر تجربی و مدل ترمودینامیکی هریوت وات، مشخص شد که در مجموع دو مدل داده محور از درصد خطای کمتری

مدل انفیس عملکرد دقیق‌تری نسبت به شبکه عصبی مصنوعی دارد، جهت تخمین فشار تشکیل هیدرات بر مبنای الگوی D، تنها از مدل داده محور انفیس استفاده شد. دو نمونه سیستم مخلوط گازی در حضور بازدارنده الکلی و الکترولیتی مخلوط گازی متان-پروپان در مجاورت بازدارنده متانول و مخلوط گازی متان-نیترژن در مجاورت بازدارنده کلرید سدیم بررسی شد. در اینجا الگوی مختلفی از مدل انفیس برای تخمین فشار تشکیل هیدرات دو سیستم برای غلظت‌های مختلفی از بازدارنده‌ها به کار رفت. ساختار بهینه مدل انفیس در غلظت‌های مختلفی از بازدارنده برای دو سیستم مورد نظر در جدول ۹ ارائه شده است.

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 ۲ و ۳ و جداول ۱۰ و ۱۱ مقایسه شد. 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 شبیه‌سازی در تخمین فشار تشکیل هیدرات به وسیله توسعه شبکه عصبی مصنوعی و مدل انفیس به دست آمد، مشخص شد که مدل‌های داده محور به عنوان ابزاری جایگزین در تخمین


۸ | شاخص‌های آماری مدل‌های داده محور بهینه و مدل ترمودینامیکی دانشگاه هریوت وات (HWHYD) برای یک‌گازی طبیعی

Methods	$R^1$	MSE	MAPE	RMSE	MAE
شبکه 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


۹ | مشخصات ساختار بهینه مدل انفیس برای سیستم مخلوط‌گازی در حضور بازدارنده

سیستم‌های مورد بررسی	غلظت بازدارنده بر حسب ترکیب درصد وزی (%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٪	Gauss2mf-4

غالباً تابعیتی از دما دارد که فرض خطی بودن آن، خطای زیادی را سبب 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 برخلاف مدل‌های ترمودینامیکی، نیازی به دانستن ناحیه فازی سیستم تشکیل هیدرات نیست. ■



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 شد. مزیت عمده دو مدل داده محور به کار رفته در این تحقیق بر روش‌های ترمودینامیکی، براساس معادلات حالت موجود در بحث هیدرات است که مدل داده محور برخلاف روش‌های مرسوم ترمودینامیکی نیازی به محاسبه خواص بحرانی اجزای سیستم و قواعد اختلاط ندارد. ضرایب برخورد دوتایی در مدل‌های ترمودینامیکی



شکل ۳ | مقایسه فشار تشکیل هیدرات به وسیله مدل ANFIS و مدل ترمودینامیکی دانشگاه هریوت وات (HWHYD) با مقادیر تجربی برای مخلوط گازی متان-نیتروژن در حضور بازدارنده کلرید سدیم (نقطه: مقدار تجربی، خط چین: مدل HWHYD، خط توپر: مدل ANFIS)

شکل ۴ | مقایسه فشار تشکیل هیدرات به وسیله مدل ANFIS و مدل ترمودینامیکی دانشگاه هریوت وات (HWHYD) مقادیر تجربی برای مخلوط گازی متان-پروپان در حضور بازدارنده متانول (نقطه: مقدار تجربی، خط چین: مدل HWHYD، خط توپر: مدل ANFIS)

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 <sup>2</sup>	RMSE	MAPE	MSE	MAE
%wt 10	ANFIS Model	۰/۹۹۵۱	۰/۳۲۳۹	۲/۷۵۱	۰/۱۶۷۳	۰/۱۰۳۳
	HWHYD Model	۰/۹۹۳۴	۰/۵۲۷۱	۴/۸۳۱	۰/۶۱۵۸	۰/۳۸۳۷
%wt 20	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 35	ANFIS Model	۰/۹۹۳۲	۰/۷۱۰۸	۵/۱۱۴۸	۰/۴۸۰۸	۰/۳۳۲۵
	HWHYD Model	۰/۹۵۶۲	۱/۴۵۹	۱۲/۶۸۵۱	۲/۵۶۷۱	۱/۰۸۱۱

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

غلظت بازدارنده	روش‌ها	R <sup>2</sup>	RMSE	MAPE	MSE	MAE
%wt 5	ANFIS Model	۰/۹۹۷۵	۰/۱۴۳۷	۳/۵۶۰۸	۰/۱۳۵۲	۰/۲۸۲۱
	HWHYD Model	۰/۹۹۷۶	۰/۱۶۶۲	۳/۷۰۶۲	۰/۱۴۳۲	۰/۲۸۷۹
%wt 10	ANFIS Model	۰/۹۹۸۱	۰/۱۱۸۵	۲/۱۰۳۹	۰/۰۵۳۲	۰/۲۳۰۱
	HWHYD Model	۰/۹۹۷۵	۰/۱۴۰۱	۲/۸۹۳۲	۰/۰۷۴۱	۰/۲۲۵۸



- |                               |                                      |
|-------------------------------|--------------------------------------|
| 1.Data-Driven Model           | 8.COV                                |
| 2.ANFIS                       | 9.MAPE                               |
| 3.Appearance Molecular Weight | 10.MAE                               |
| 4.Back-Propagation 4          | 11.Nonlinear Regression Analysis     |
| 5.Overfitting                 | 12.Nondensity Dependent Mixing Rules |
| 6.Early Stopping              | 13.Local Minimum                     |
| 7.RMSE                        | 14.Convergency Rate                  |

- [1] Singh T.N., Sinha S. & Singh V.K., “Prediction of thermal conductivity of rock through physicommechanical 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. 89-2004 ,95.
- [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. 5272005 ,533-.
- [7] Bouchard C. & Grandjean A., “A neural network correlation for variation of viscosity of sucrose aqueous solutions with temperature and concentration”, *LebensmWiss. U. Technol.*, Vol. 28, pp. 157159,1995.
- [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. 2472003 ,255-.
- [9] Potukuchi W. & Wexler AS., “Predicting vapor pressures using neural networks”, *Atmos. Environ.*, Vol. 31, pp.7411997 ,753-.
- [10] Shyam S.S., Oon-Doo B., & Michele M., “Neural networks for predicting thermal conductivity of bakeryproducts”, *J. Food Eng.*, Vol. 52, pp. 2992002 ,304-.
- [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 artif neural networks to thermodynamics: Vapourliquid equilibrium predictions”, *Com-put. Chem. Eng.*, Vol. 23, pp. 3851999 ,390-.
- [13]Ganguly S., “Prediction of VLE data using radial basis function network”, *Comput. Chem. Eng.*, Vol. 27, pp.1445- 1454, 2003.
- [14] HoseiniNasab S.A., Izadpanah A.M. & VafaeiSefti 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, 1620-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. 105-1999), 113).
- [17] Heydari A., Shayeŝteh 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. پایان نامه کارشناسی ارشد سازه های آبی، دانشکده کشاورزی، دانشگاه تربیت مدرس، ۱۳۸۰
- [۲۰] جورابیان م.، هوشمند ر.ا.، منطق فازی و شبکه های 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] منهای م. ب.، هوش محاسباتی (مبانی شبکه های 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] لبرزی م.، آشنایی با شبکه های عصبی مصنوعی، انتشارات دانشگاه صنعتی شریف، ۱۳۸۰.
- [30] Denal M.A., Palis F. & Zeghibid A., "ANFIS: Based Modeling Control of Nonlinear 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., & ShettyC M., Nonlinear Programming: Theory and Algorithms, 2nd ed., John Wiley & Sons. Inc., 1993.
- [36] HeriotWatt 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 PatelTeja 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.