



ارائه شده توسط :

سایت ترجمه فا

مرجع جدیدترین مقالات ترجمه شده

از نشریات معتربر

تخمین خلوص تری اتیلن گلیکول یا TEG در واحدهای دهیدراسیون گاز طبیعی با استفاده از شبکه عصبی فازی

چکیده

گاز طبیعی معمولاً حاوی مقدار زیادی آب می‌باشد و طی عملیات تولیدی کاملاً اشباع می‌گردد. در واحدهای دهیدراسیون گاز طبیعی، بخار آب از طبقه بندی گاز طبیعی حذف می‌گردد تا مشخصات فروش یا سایر الزامات فراوری گاز طبقه پایین رعایت گردد. بسیاری روشهای اصول در پروسه دهیدراسیون گاز طبیعی برای کسب سطح بالایی از خلوص تری اتیلن گلیکول یا TEG تدوین شده‌اند. در میان اینها، کاهش فشار در ریبویلر در یک درجه حرارت ثابت منجر به خلوص بالاتر گلیکول می‌شود. هدف اصلی این مقاله تدوین یک مدل هوشمند براساس شبکه عصبی خوب اثبات شده استاندارد با تغذیه رو به جلو و انتشار رو به عقب برای پیشگویی صحیح خلوص PEG براساس شرایط عملیاتی ریبویلر می‌باشد. ظرفیت مدل مبتنی بر عصبی ارائه شده در تخمین خلوص TEG با بکارگیری چندین پارامتر آماری ارزیابی شده است. مشخص گردیده است که تکنیک هوشمند مطرح شده داده‌های گزارش شده در متون علمی را با درصد انحراف مطلق متوسط حول 0.30% مجدداً ایجاد کرده است.

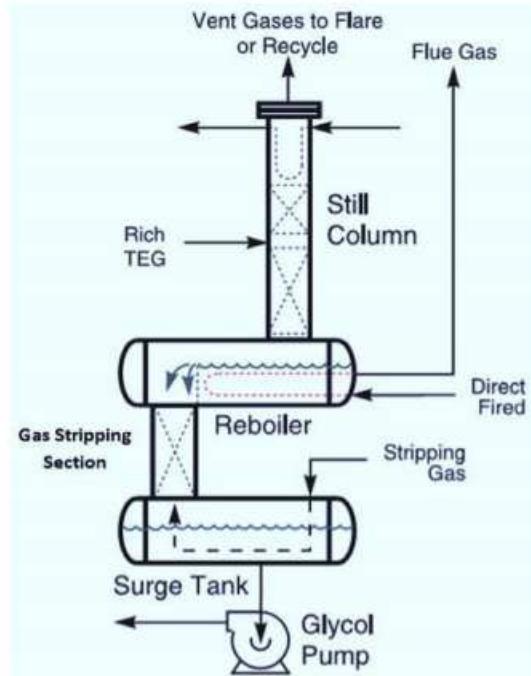
کلیدواژه‌ها: TEG، دهیدراسیون گاز طبیعی، تغییظ کننده مجدد گلیکول، ANN، پیشگویی

اختصاری‌ها: ANN شبکه عصبی مصنوعی، BPNN، شبکه عصبی انتشار رو به عقب، DEG دی اتیلن گلیکول، FFNN، شبکه عصبی تغذیه رو به جلو، FLN، شبکه‌های ارتباط عملیاتی، LM، Levenberg-Marquardt، MLP، ادراک چندلایه ای، MSE، خطای میانگین مربع، NG، گاز طبیعی، RBFN، شبکه عملیاتی پایه شعاعی، TREG، تری اتیلن گلیکول، TEG.

۱- مقدمه

کلا، مقدار زیادی آب با گاز طبیعی (NG) در مخزن همراه است. به همین دلیل، NG تولید شده کاملاً اشباح است یا در نقطه شبند آب قرار دارد. با هدف رویارویی با مشخصات فروش یا سایر پروسه‌های گاز رده پایین مانند بازستانی مایع گاز، عملیات دهیدراسیون گاز در صنعت NG بکار گرفته می‌شود تا بخار آب را حذف سازد. از نقطه نظر اقتصادی و ایمنی، محتواهای رطوبت آب NG باید زیر یک حد آستانه خاص نگهداری گردد. در مواردی که افت نقطه شبند باید در ردیف 15 تا 49 درجه سانتیگراد باشد، گلیکولها عموماً بکار می‌روند. در میان گلیکولهای مختلف مانند دی‌اتیلن گلیکول یا DEG، تری‌اتیلن گلیکول یا TEG، و تتراتیلن گلیکول یا TREG، که به عنوان خشکسازهای مایع بکار می‌روند، متداولترین انتخاب برای دی‌هیدراسیون NG همان TREG است. عملیات و نگهداری تجهیزات دهیدراسیون خشکساز مایع ساده است. این نوع دهیدراسیون می‌تواند به سادگی برای عملیات بدون مراقب اتوماتیک سازی شود. دهیدراسیون گلیکول در یک تولید راه دور به خوبی نمونه چنین کاری است.

تصویر 1- نشان دهنده بخش دفع کننده گاز در واحد دهیدراسیون NG می‌باشد. به خوبی مشخص است که کاهش فشار در ریبویلر (تغليظ کننده مجدد) دریک درجه حرارت ثابت درخلوص بالاتر گلیکول نقش دارد. طیف عملیاتی بیشتر تغليظ کننده‌های مجدد بین 1.7-5.2 kPa فشار است. در تغليظ کننده‌های مجدد جو استاندارد، فشارهای بیش از 7 kPa می‌تواند منجر به از دست رفتن گلیکول از ستون تقطیر و کاهش هم غلظت گلیکول کم و کارایی دهیدراسیون گردد. وانگهی، فشارهای بیش از 7 kPa به طور متداول مرتبط با آب اضافه در گلیکول می‌باشد. متعاقباً، یک سرعت بخار خروجی از دستگاه تقطیر به قدر کافی بزرگ برای خارج سازی گلیکول ایجاد خواهد شد. ازسوی دیگر، فشارهای کمتر از جو مسئول افزایش در غلظت گلیکول کم می‌باشد. این نتیجه کاهش درجه حرارت جوشیدن مخلوط غلیظ گلیکول/آب می‌باشد.



شکل 1- شمای بخش دفع کننده گاز در واحد دهیدراسيون NG

در نتیجه مسائل فوق الذکر، ضروری است که خلوص TEG را به شکل تابعی از فشار و درجه حرارت تغليظ کننده مجدد محاسبه نمود. هدف اصلی مطالعه کنونی ایجاد مدلی مبتنی بر عصبی برای پیشگویی صحیح خلوص TEG با بنیان ادراک چندلایه ای MLP، شبکه عصبی مصنوعی ANN به عنوان یک الگوریتم خوب تثبیت شده از رهیافت یادگیری ماشینی است. تا انجا که نویسنده مقاله می دارد، هیچ کار منتشره ای در زمینه مدلسازی خلوص PEG بر حسب درجه حرارت ریبویلر در سطوح مختلف فشار در سیستم های دهیدراسيون گاز بوسیله شبکه های عصبی MLP وجود ندارد. مرور کلی ANNها، عملیات محاسباتی برای ایجاد یک مدل مناسب و نتایج مدل کنونی بقیه این مقاله را تشکیل می دهد. اخرين بخش نتیجه گیری اين مقاله است.

2-شبکه عصبی با انتشار رو به عقب یا BPNN: یک مرور کلی

در واقع، ANN نام خود را از واحدهای پردازش ساده در مغز به نام نرون گرفته است که به طور متقابل با یک شبکه به هم متصل است که سیگنالها را بین انها رد و بدل می کند. در 1943، اولین عصب مصنوعی توسط McCulloch & Pitts تولید گردید. یک شما از یک عصب مصنوعی در شکل 2 به تصویر کشیده شده است.

نرون نشان داده شده m در شکل 2 می تواند به شکل ذیل نشان داده شود:

$$r_m = \sum_{i=1}^n (w_{mi}x_i + b_m) \quad (1)$$

$$y_m = F(r_m) \quad (2)$$

که در آن x_1, x_2, \dots, x_n ورودی ها می باشند. r_m نشان دهنده وزن می باشد. خروجی

ترکیب کننده خطی است. b_m اصطلاح تورش یا سوگیری می باشد. f تابع فعالسازی است و y_m سیگنال خروجی نرون است.

ANNها به شکل سیستم های پردازش اطلاعات موازی توانایی قابل توجهی برای مشتق سازی روابط ریاضی خطی یا غیرخطی با بکارگیری تعدادی از ترتیبات ورودی-خروجی از پایگاه داده های معینی دارد. به طور معمول، ANNها به نحوی تنظیم یا آموزش دیده اند که اهداف دلخواه از ورودی های خاص حاصل خواهد گردید. این نوع تکنیک های هوشمند می تواند به طور موفقیت آمیزی برای سروکار داشتن با بسیاری انواع مسائل مانند پیشگویی ها، تشخیص الگو، و طبقه بندی بکار گرفته شود. عموما باور برآین است که شبکه های عصبی با تغذیه رو به جلو یا MLPها شامل FFNNها، شبکه های خطی عملیاتی یا FLNها، و شبکه های تابع اساس شعاعی یا RBFNها تشخیص دهنده طبقه بندی کننده غیرخطی مستحکم و قابل اعتمادی می باشند.

MLPها که مشهورترین FFNNها بکارگیری شده توسط مهندسان شیمی، نفت و گاز طبیعی است، شامل لایه ورودی، لایه های مخفی و لایه خروجی است. شکل 3 نشان دهنده یک شبکه MLP سه لایه استاندارد با گره های شاخه زننده ورودی A نرونهای H در لایه مخفی و نرونهای ورودی O می باشد. تعداد پارامترهای مستقل تاثیرگذار بر اهداف تعیین کننده تعداد گره های شاخه زننده ورودی است. تعداد اهداف، تعداد نرونهای لایه خروجی را تعریف می کند. معمولا، تعداد بهینه نرونها در لایه های مخفی با عملیات آزمون و خطا مشخص می شود. قدرت شبکه MLP به دلیل توانایی اش برای نمایش توابع غیرخطی است. برای ترکیب غیرخطی ها با MLPها، چندین نوع توابع فعالسازی مانند تابع انتقال حدآستانه، تابع انتقال لگاریتم-سیگموئیدی، و تابع انتقال تانژانت-سیگموئیدی را می توان استفاده کرد.

برای آموزش دادن MLP-ANN برای تنظیم مقادیر وزنهای سیناپسی بین سلولهای محاسباتی موجود شبکه، لازم است یک الگوریتم یادگیری مناسب به کار بسته شود. شبکه عصبی با انتشار رو به عقب یا BPNN به عنوان

یک نوع مشهور شبکه های MLP، از الگوریتم یادگیری BP برای اجرای پروسه یادگیری استفاده می کند.

الگوریتم BP یک پارادیگم اموزشی نظارت شده است که شامل روش نزولی برای به حداقل رساندن خطای میان

اهداف و پیشگویی های شبکه می باشد. معادله ۳ نشان دهنده تابع هزینه e برای ارزیابی خطای می باشد:

$$e = \frac{1}{2}(t - o)^2 \quad (3)$$

که در آن t و o نشان دهنده مقدار هدف و خروجی شبکه به ترتیب می باشد.

با توجه به این حقیقت که روش LM بهترین عملکرد را بر سایر الگوریتم های BP ارائه می کند، در این مطالعه،

BPNN با تکنیک LM یا Levenberg-Marquardt آموزش دیده اند. LM یک روش حل تکراری است که

حاصل جمع مربعات خطاهای را به حداقل می رساند.

3- تدوین یک مدل هوشمند برای پیشگویی خلوص TEG

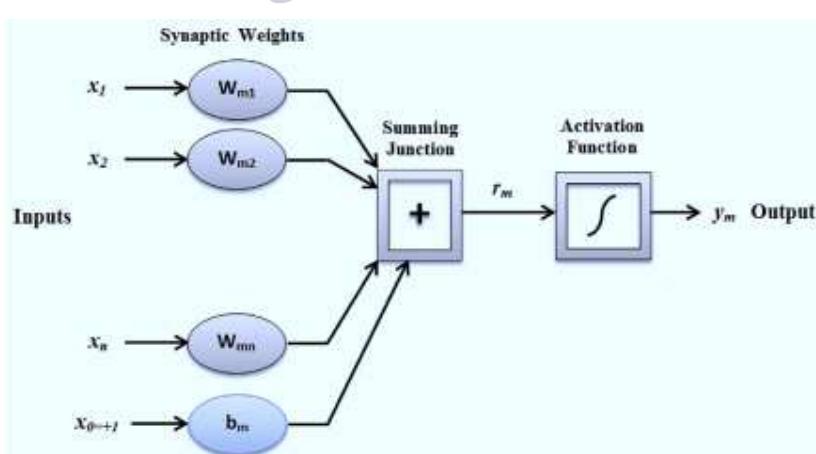
هدف اصلی مطالعه کنونی تدوین یک مدل BPNN برای برآورد خلوص TEG در سیستم های دهیدراسیون گاز

است. طراحی BPNN برای کاربرد مورد نظر مرحله به مرحله در این قسمت توضیح داده می شود. داده های

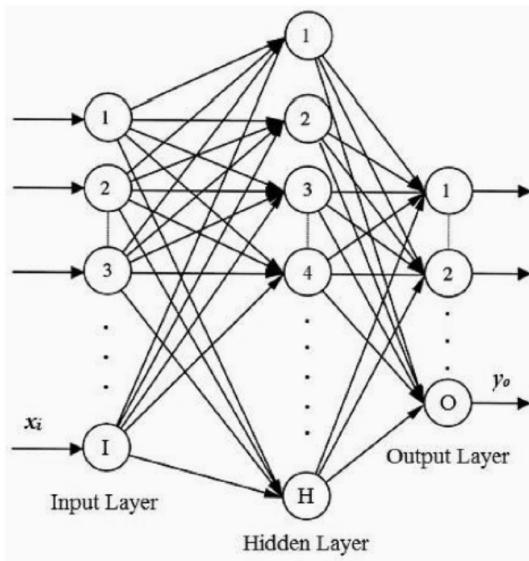
لازم برای تدوین این مدل شامل داده های خلوص TEG گزارش شده و داده های غلظت به عنوان تابعی از درجه

حرارت و فشار تغليظ کننده مجدد (ربویلر) می باشد. طیف عملیاتی پایگاه داده جمع آوری شده برای خلوص

TEG در جدول ۱ ارائه گردیده است.



شکل 2- مدل نمونه یک نرون مصنوعی



شکل 3-یک MLP معمولی 3 لایه

اول اینکه، کلیه نقاط داده جمع آوری شده از متون علمی آزاد بین 0.105 و 0.805 با بکارگیری معادله 4 نرمالسازی گردید. این مرحله پیش پردازش با هدف اصلاح توزیع پارامترهای ورودی برای کاهش تفاوت میان ورودی های شبکه و ارزشهای هدف منطبقه اجرا گردیده است.

جدول 1-طیف های عملیاتی پایگاه داده های جمع آوری شده برای خلوص TEG

پارامتر	می نیمم	ماکریم	میانگین
Wt%, TEG خلوص، به	0.954	0.998	0.983
فشار به kPa	67	122	93.04
درجه حرارت به °C	149	204	174.22

جدول 2-نتایج شبکه های MLP ساخته شده برای پیشگویی خلوص TEG

نوع شناسی شبکه	آموزش		روایی سازی		تست	
	MSE	R مقدار	MSE	R مقدار	MSE	R مقدار

2-1-1	4.9E-4	0.9882	9.2E-4	0.9495	2.1E-4	0.9442
2-2-1	4.5E-4	0.9880	1.4 E-4	0.9969	1.7 E-4	0.9950
2-3-1	2.9E-4	0.9919	5.4 E-4	0.9984	1.6 E-4	0.9693
2-4-1	2.1E-4	0.9949	1.5 E-4	0.9802	1.4 E-4	0.9551
2-5-1	2.7E-5	0.9993	4.8E-5	0.9988	2.1E-5	0.9996
2-6-1	1.3E-5	0.9996	7.2E-6	0.9998	3.8E-5	0.9994
2-7-1	1.1E-5	0.9997	8.8E-6	0.9997	9.9E-6	0.9998
2-8-1	1.1E-5	0.9997	1.9E-5	0.9998	1.0E-5	0.9997
2-9-1	1.0E-5	0.9997	8.7E-6	0.9994	3.6E-6	0.9998
2-10-1	8.7E-6	0.9998	1.2E-5	0.9993	7.2E-6	0.9999
2-11-1	6.7E-6	0.9998	6.7E-6	0.9998	7.6E-6	0.9988

$$b_{\text{norm}} = 0.7 \frac{\ln\left(\frac{(b-b_{\min})}{(b_{\max}-b_{\min})} + 1\right)}{\ln(2)} + 0.15 \quad (4)$$

که در آن b داده هایی است که نرمالسازی گردیده است. b_{\min} و b_{\max} ماکزیمم و مینیمم داده های اصلی به

ترتیب می باشد. b_{norm} نشان دهنده داده های نرمالسازی شده است که تغییرشکل یافته است.

مرحله بعدی تشکیل دهنده تقسیم پایگاه داده ها به سه مجموعه فرعی داده ها از جمله داده های آموزشی ، داده

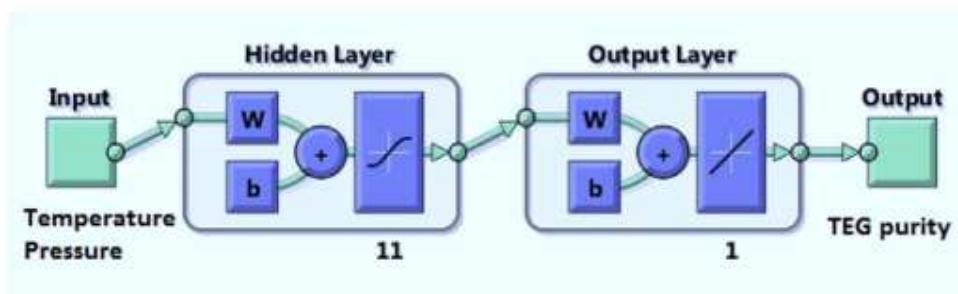
های روایی سازی، و داده های تست می باشد. پایگاه داده آموزشی در پروسه آموزشی برای تنظیم وزنهای

سیناپسی شبکه ساخته شده استفاده می شود. یک مسئله طاقت فرسا با شبکه های عصبی، تمایل ایشان به

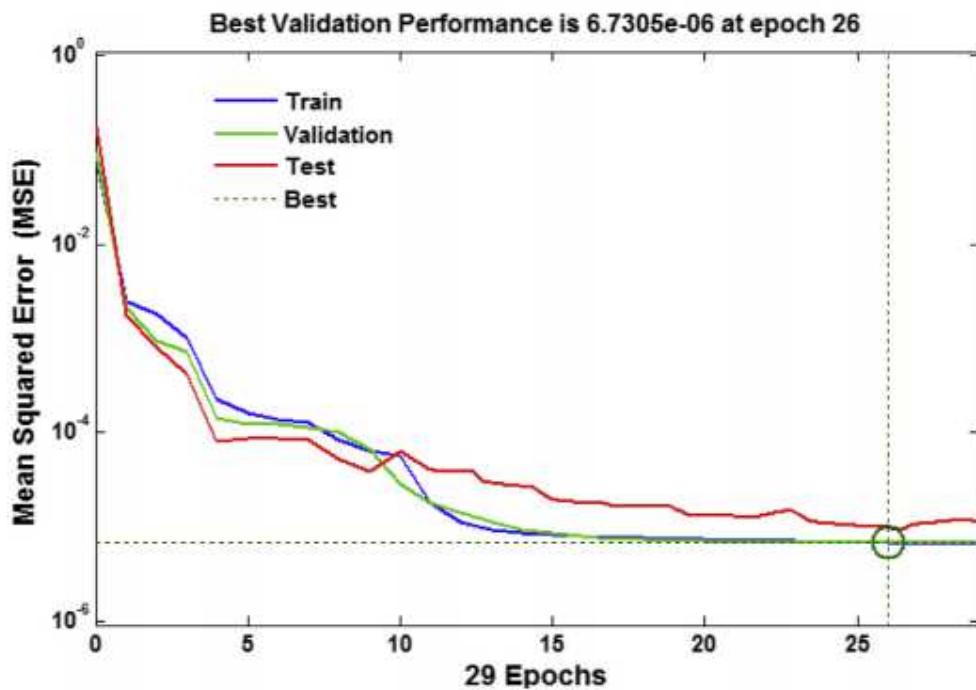
تناسب بیش از حد می باشد. این مسئله هنگامی تشدید می یابد که این مدل بسیاری پارامتر داشته باشد.

مجموعه داده ها برای روایی سازی برای احتساب از تدوین یک مدل با تناسب بیش از حد بکار گرفته می شود.

مجموعه تست برای ارزیابی توانایی تخمین مدل ساخته شده استفاده می شود.



شکل 4- ساختار بهترین BPNN برای پیشگویی خلوص TEG



شکل ۵- اجرای BPNN تدوین شده با نوع ۱-۱۱-۲ در تخمین خلوص TEG

مرحله سوم در عملیات مدلسازی، براورد ساختار BPNN برای داشتن بهترین پیشگویی ها می باشد. یک

به عنوان نوعی از شبکه های MLP با یک لایه مخفی منفرد برای مدلسازی خلوص TEG یعنی ψ به

عنوان تابعی از فشار و درجه حرارت ریبویلر بکار گرفته شده است:

$$\psi = f(T, P) \quad (5)$$

که در آن T و P نشانه درجه حرارت و فشار در ریبویلر به ترتیب می باشد. همانگونه که قبلا اشاره گردید، تعداد گره های شاخه زننده لایه ورودی و تعداد نرونهای لایه خروجی برابر با متغیرهای مستقل و پارامترهای مستقل به ترتیب می باشد. اما هیچ قانون جهانی برای تعیین تعداد نرونها مخفی وجود ندارد. در این مقاله، میانگین خطای مربع یا MSE همانگونه که با معادله ۶ تعریف شده است، و مقدار R به عنوان معیارهایی برای تحقیق روی صحت شبکه های ساخته شده دارای نرونها مخفی مختلف انتخاب می گردد.

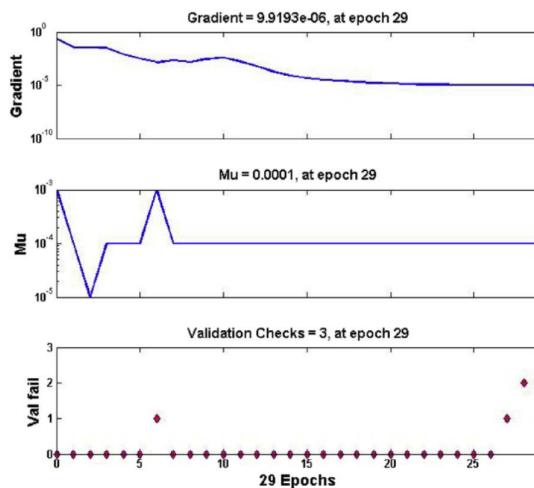
$$MSE = \frac{1}{n} \sum_{i=1}^n (t_i - o_i)^2 \quad (6)$$

آخرین مسئله توابع انتقالی شبکه است. برای لایه خروجی یک تابع انتقال خطی تعیین شده است. لایه مخفی از یک تابع انتقال تانژانت-سیگموئیدی استفاده می کند. تانژانت-سیگموئید خروجی هایی بین -1 و $+1$ تولید می کند و می تواند به شکل ذیل ظاهر گردد:

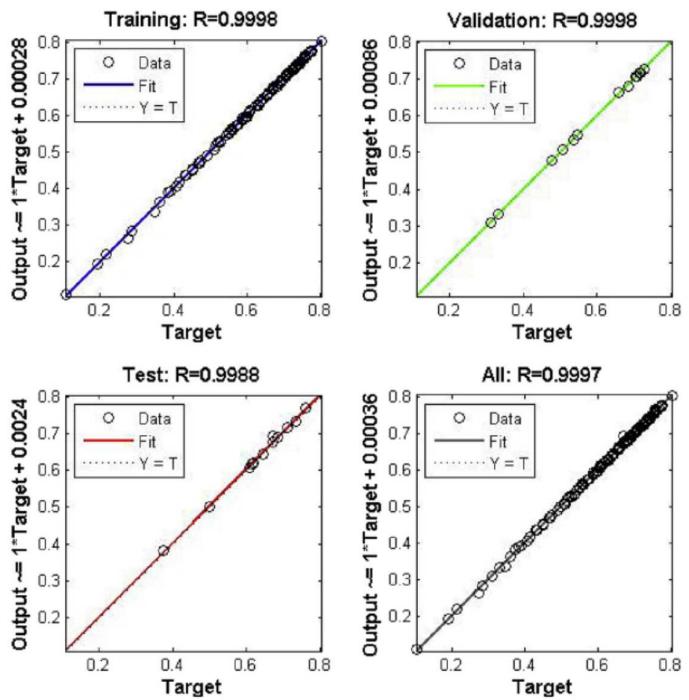
$$f(x) = \frac{2}{1 + \exp(-2x)} - 1 \quad (7)$$

4-نتایج و بحث

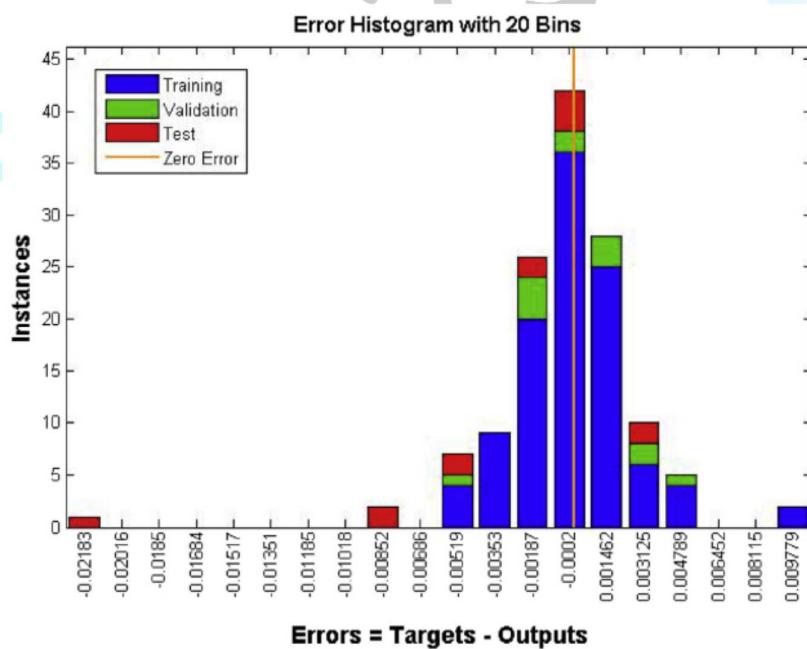
تعداد نرونها مخفی BPNN از 1 تا 11 متغیر بود تا بهترین مدل مبتنی بر عصبی را برای پیشگویی صحیح خلوص TEG بیابد. برای هر شبکه ساخته شده هم MSE و هم مقدار R اندازه گیری می شود. مقادیر بدست آمده برای پارامترهای آماری در جدول 2 آمده است. طبق جدول 2، بهترین نوع شبکه برای مدلسازی خلوص TEG با 1-11-2 می باشد. BPNN ارائه شده با ساختار 1-11-2 پایین ترین MSE را در مقایسه با سایر شبکه های تدوین شده دارد. وانگهی، مقادیر ضرایب همبستگی برای شبکه انتخابی به طور کافی نزدیک به $+1$ می باشد. تصویر گرافیکی ساختار BPNN پیشنهادی در شکل 4 نشان داده شده است. در رابطه با تعداد نرونها مخفی، می توان نتیجه گیری نمود که شبکه سه لایه MLP آموزش دیده با الگوریتم آموزشی BP همواره پیشگویی های رضایت بخشی را هنگامی که لایه های مخفی حاوی 11 نرون می باشند، فراهم می سازد. با اینحساب،



شکل 6-رسم نمودار حالت آموزشی بهترین BPNN برای تخمین خلوص TEG



شکل 7- مقادیر R روابی آموزشی و مجموعه های تست برای BPNN انتخابی



شکل 8- هیستوگرام مقادیر خطا برای بهترین BPNN

اجرای شبکه های دارای لایه های مخفی بیشتر در این کار ارزیابی نگردیده است.

شکل 5 نشان دهنده توانایی تخمین شبکه با 11 نرون در لایه مخفی از لحاظ MSE است. رسم حالت اموزشی دارای تعداد بهینه نرونها مخفی در شکل 6 فراهم شده است. رسم عرضی برای شبکه انتخابی برای آموزش، روایی سازی و مجموعه های تست در شکل 7 رسم گردیده است. توزیع خطاهای میان داده های گزارش شده برای خلوص TEG و پیشگویی های بهترین BPNN در شکل 8 نشان داده شده است. خلاصه بهترین نتایج برای تخمین خلوص TEG در مقایسه با برخی داده های گزارش شده در جدول 3 آورده شده است. همانگونه که می توان از جدول 3 دید، پیشگویی های BPNN ارائه شده در توافق خوبی با داده های گزارش شده در متون علمی است. طبق این حقیقت که BPNN تدوین شده به شکل یک مدل ریاضی طبقه بندی گردیده است، می تواند به طور موفقیت امیزی در طیف های عملیاتی بانک داده های جمع آوری گردیده استفاده شود.

جدول 3-پیشگویی های بهترین BPNN در مقایسه با داده های معمولی

kPa فشار،	درجه حرارت، °C	خلوص TEG، فراکسیون وزنی		درصد انحراف مطلق
		گزارش شده	پیشگویی شده	
67	149	0.9780	0.9779	0.01
	160	0.9845	0.9802	0.43
	171	0.9890	0.9869	0.21
	185	0.9926	0.9887	0.39
	204	0.9957	0.9953	0.04
	154	0.9770	0.9775	0.05
	163	0.9825	0.9795	0.30
	177	0.9882	0.9861	0.21
	182	0.9900	0.9891	0.09
	199	0.9939	0.9930	0.09
93	157	0.9745	0.9766	0.21
	166	0.9810	0.9791	0.19
	174	0.9850	0.9804	0.46
	188	0.9900	0.9821	0.80
	196	0.9917	0.9928	0.10
	151.5	0.9667	0.9739	0.74
	166	0.9785	0.9782	0.03
101	179.5	0.9857	0.9807	0.50
	190.5	0.9896	0.9821	0.75
	201.5	0.9918	0.9828	0.91
	149	0.9590	0.9580	0.10
	157	0.9685	0.9683	0.02
110	163	0.9735	0.9764	0.30
	177	0.9870	0.9812	0.59
	188	0.9980	0.9911	0.69
	151.5	0.9580	0.9611	0.32
	166	0.9735	0.9734	0.01
122	182	0.9840	0.9800	0.40
	193	0.9880	0.9818	0.63
	204	0.9903	0.9923	0.20
	درصد انحراف مطلق متوسط			0.32

5-خلاصه و نتیجه گیری ها

در مقاله کنونی، سعی به مدلسازی خلوص TEG به عنوان تابعی از فشار و درجه حرارت ریبویلر بوسیله ANN‌ها گردید. تا به اینجا، MLP-ANN سه لایه خوب اثبات شده همراه با الگوریتم یادگیری BP بکار گرفته شد. پارادیگم یادگیری BP بوسیله روش تکراری LM برای حصول بهترین نتایج آموزش گردید. داده‌های لازم برای مدلسازی اهداف از متون قابل اتکا جمع آوری گردید. عملیات آزمون و خطا برای یافتن تعداد بهینه نرونها مخفی بکار گرفته شد. بهترین نوع شناسی شبکه با نظارت بر مقادیر بدست آمده از MSE و مقدار R به شکل BPNN معیار اجرا برای BPNN‌های ساخته شده مختلف به شکل 11-1-2 یافت گردید. طبق نتایج انالیز خطا، مطرح شده با ساختار 11-1-2 تولید مجدد آموزش، روایی سازی و پایگاه داده‌های تست را با MSE‌های کمتر از 10^{-6} نماید.

با اینحساب پیشگویی‌های تکنیک هوشمند ارائه شده در توافق خوبی با داده‌های گزارش شده در متون آزاد می‌باشد.



سمبلهای بکار رفته

b	داده‌هایی که باید نرمالسازی گرددند.
b_{max}	ماکریمم داده‌های اصلی
b_{min}	مینیمم داده‌های اصلی
b_{norm}	داده‌های نرمالسازی شده که تغییر شکل یافته اند.
b_m	اصطلاح سوگیری
e	تابع هزینه
f	تابع فعالسازی
n	تعداد نقاط
o	مقدار پیشگویی شده
P	فشار، kPa
r_m	خروجی ترکیب کننده خطی
t	مقدار هدف
T	درجه حرارت، سانتیگراد
w_{mn}	وزن سیناپسی
X	نقطه داده‌ها
x_n	خروجی نرون
y	خلوص TEG، فراکسیون وزن
y_m	
ψ	

References

- Bahadori, A., 2007. New model predicts solubility in glycols. *Oil Gas J.* 105 (8), 50–55.
- Bahadori, A., 2009a. Estimation of hydrate inhibitor loss in hydrocarbon liquid phase. *Pet. Sci. Technol.* 27 (9), 943–951.
- Bahadori, A., 2009b. Rapid estimation of equilibrium water dew point of natural gas in TEG dehydration systems. *J. Nat. Gas Sci. Eng.* 1 (3), 68–71.
- Bahadori, A., Vuthaluru, H.B., 2009a. Simple methodology for sizing of absorbers for TEG (triethylene glycol) gas dehydration systems. *Energy* 34 (11), 1910–1916.
- Bahadori, A., Vuthaluru, H.B., Mukhatab, S., Tade, M.O., 2008. Predicting hydrate forming pressure of pure alkanes in the presence of inhibitors. *J. Nat. Gas Chem.* 17, 249–255.
- Bahadori, A., Vuthaluru, H.B., 2009b. New method accurately predicts carbon dioxide equilibrium adsorption isotherms. *Int. J. Greenh. Gas Control* 3, 768–772.
- Bahadori, A., Zahedi, G., Zendehboudi, S., Jamili, A., 2014. A new method estimates TEG purity versus recontactor temperature at different levels of pressure in gas dehydration systems. *Int. J. Oil-Gas Coal Technol.* 7 (1), 85–94.
- Bain, A., 1873. Mind and Body: the Theories of Their Relation. D. Appleton and Company, New York.
- Bose, N.K., Liang, P., 1996. Neural Network Fundamentals with Graphs, Algorithms, and Applications. McGraw-Hill Series in Electrical and Computer Engineering. McGraw-Hill, USA.
- Chelgani, S.C., Hower, J.C., Hart, B., 2011. Estimation of free-swelling index based on coal analysis using multivariable regression and artificial neural network. *Fuel Process. Technol.* 92 (3), 349–355.
- Chelgani, S.C., Hower, J.C., Jorjani, E., Mesroghli, S., Bagherieh, A.H., 2008. Prediction of coal grindability based on petrography, proximate and ultimate analysis using multiple regression and artificial neural network models. *Fuel Process. Technol.* 89 (1), 13–20.
- Chouai, A., Laugier, S., Richon, D., 2002. Modeling of thermodynamic properties using neural networks: application to refrigerants. *Fluid Ph. Equilib.* 199 (1–2), 53–62.
- Freeman, J.A., Skapura, D.M., 1991. Neural Networks: Algorithms, Applications, and Programming Techniques. Computational and Neural Systems. Addison-Wesley Publishing Company, USA.
- Gharagheizi, F., Estamianesh, A., Mohammadi, A.H., Eskandari, S., Richon, D., 2013. Assessment test for glycol loss in gaseous system. *Fuel Process. Technol.* 115 (9), 254–260.
- Ghiasi, M.M., 2012. Initial estimation of hydrate formation temperature of sweet natural gases based on new empirical correlation. *J. Nat. Gas Chem.* 21, 508–512.
- Ghiasi, M.M., Bahadori, A., Zendehboudi, S., 2014. Estimation of the water content of natural gas dried by solid calcium chloride dehydrator units. *Fuel* 117 (Part A(0)), 33–42.
- Ghiasi, M.M., Bahadori, A., Zendehboudi, S., Jamili, A., Rezaei-Gomari, S., 2013. Novel methods predict equilibrium vapor methanol content during gas hydrate inhibition. *J. Nat. Gas Sci. Eng.* 15 (0), 69–75.
- Ghiasi, M.M., Ghayem, M.A., 2014. Application of artificial neural network (ANN) in prediction of hydrate formation temperature (in press). *Energy Sources Part A Recovery Util. Environ. Eff.*
- Ghiasi, M.M., Mohammadi, A.H., 2013. Determination of methane-hydrate phase equilibrium in the presence of electrolytes or organic inhibitors by using a semi-theoretical framework. *Energy Technol.* 1 (9), 519–529.
- Giroi, F., Masetti, M., Piemonte, V., 2010. Natural gas dehydration: a triethylene-glycol-water system analysis. *Energy Sources Part A Recovery Util. Environ. Eff.* 32 (20), 1861–1868.
- GPSA, 2004. Gas Processors Suppliers Association, USA.
- Hagan, M.T., Demuth, H.B., Beale, M., 1996. Neural Network Design. PWS Publishing Company, USA.
- Haykin, S.S., 1999. Neural Networks: A Comprehensive Foundation. Prentice Hall International.
- Hornik, K., Stinchcombe, M., White, H., 1989. Multilayer feedforward networks are universal approximators. *Neural Netw.* 2 (5), 359–366.
- James, W., 1890. The Principles of Psychology. Holt and Company, New York.
- Kasabov, N.K., 1996. Foundations of Neural Networks, Fuzzy Systems, and Knowledge Engineering. MIT Press.
- Levenberg, K., 1944. A method for the solution of certain non-linear problems in least squares. *Q. Appl. Math.* 2 (2), 164–168.
- Looney, C.G., 1997. Pattern Recognition Using Neural Networks, Theories and Algorithms for Engineers and Scientists. Oxford University Press, USA.
- Luberau, U., Mothes, R., 2009. Regeneration of triethylene glycol (TEG) with inorganic membranes. *GWF. Gas Erdgas* 150 (12), 752–757.
- Marquardt, D.W., 1963. An algorithm for the least-squares estimation of nonlinear parameters. *SIAM J. Appl. Math.* 11 (2), 431–441.
- Masoudi, R., et al., 2005. Measurement and prediction of gas hydrate and hydrated salt equilibria in aqueous ethylene glycol and electrolyte solutions. *Chem. Eng. Sci.* 60 (15), 4213–4224.
- McCulloch, W., Pitts, W., 1943. A logical calculus of the ideas immanent in nervous activity. *Bull. Math. Biophys.* 5 (4), 115–133.
- Mohammadi, A.H., Richon, D., 2007. Use of artificial neural networks for estimating water content of natural gases. *Ind. Eng. Chem. Res.* 46 (4), 1431–1438.
- Mohammadi, A.H., Samueyan, V., Tohidi, B., 2005. Estimation of water content in sour gases. In: SPE Europe/EAGE Annual Conference Madrid, Spain.
- Nivargi, J.P., Gupta, D.F., Shahi, S.J., Shahi, K.T., 2005. TEG contactor for gas dehydration. *Chem. Eng. World* 40 (9), 77–80.
- Piazza, L., Scalabrin, G., Marchi, P., Richon, D., 2006. Enhancement of the extended corresponding states techniques for thermodynamic modeling. I. Pure fluids. *Int. J. Refrig.* 29 (7), 1182–1194.
- Piemonte, V., Masetti, M., Gironi, F., 2012. A triethylene glycol–water system: a study of the TEG regeneration processes in natural gas dehydration plants. *Energy Sources Part A Recovery, Util. Environ. Eff.* 34 (5), 456–464.
- Press, W.H., Teukolsky, S.A., Vetterling, W.T., Flannery, B.P., 1992. Numerical Recipes in C: the art of Scientific Computing. Cambridge University Press, USA.
- Stamenković, O.S., Rajković, K., Velicković, A.V., Mišić, P.S., Velicković, V.B., 2013. Optimization of base-catalyzed ethanolysis of sunflower oil by regression and artificial neural network models. *Fuel Process. Technol.* 114 (0), 101–108.
- Stewart, M., Arnold, K., 2011. Gas Dehydration Field Manual. Gulf Professional Publishing, MA, USA.
- Wichert, E., Wichert, G.C., 2004. New charts estimate acid gas solubility in TEG. *Hydrocarb. Proces.* 83 (1), 47–48.
- Zendehboudi, S., Ahmadi, M.A., Bahadori, A., Shafei, A., Bahadagli, T., 2013. A developed smart technique to predict minimum miscible pressure—for implications. *Can. J. Chem. Eng.* 91 (7), 1325–1337.



برای خرید فرمت ورد این ترجمه، بدون واتر مارک، اینجا کلیک نمایید.



این مقاله، از سری مقالات ترجمه شده رایگان سایت ترجمه فا میباشد که با فرمت PDF در اختیار شما عزیزان قرار گرفته است. در صورت تمایل میتوانید با کلیک بر روی دکمه های زیر از سایر مقالات نیز استفاده نمایید:

✓ لیست مقالات ترجمه شده

✓ لیست مقالات ترجمه شده رایگان

✓ لیست جدیدترین مقالات انگلیسی ISI

سایت ترجمه فا؛ مرجع جدیدترین مقالات ترجمه شده از نشریات معتبر خارجی