

مدل سازی و بهینه سازی واحد تولید هیدروژن با شبکه ی عصبی مصنوعی و الگوریتم ژنتیک

ایمان اکبری^۱، سید محمد قریشی^{۲*}، نرجس السادات رضوی^۳، سید مهرداد قریشی^۴ و مجید وفائی جهان^۵

- ۱- دانشجوی دکترای مهندسی شیمی، دانشکده مهندسی شیمی، دانشگاه صنعتی اصفهان، اصفهان، ایران
- ۲- استاد مهندسی شیمی، دانشکده مهندسی شیمی، دانشگاه صنعتی اصفهان، اصفهان، ایران
- ۳- کارشناس ارشد مهندسی شیمی، دانشکده مهندسی شیمی، دانشگاه کاشان، کاشان، ایران
- ۴- دانشجوی کارشناسی ارشد مهندسی نرم افزار، دانشکده مهندسی کامپیوتر، دانشگاه امام رضا، مشهد، ایران
- ۵- استادیار مهندسی نرم افزار، دانشکده مهندسی کامپیوتر، واحد مشهد، دانشگاه آزاد اسلامی، مشهد، ایران

دریافت: تیر ۱۳۹۲، بازنگری: شهریور ۱۳۹۲، پذیرش: مهر ۱۳۹۲

چکیده: هدف اصلی این پژوهش، مدل سازی واحد صنعتی تولید هیدروژن براساس تبدیل متان با بخار آب با کاربرد شبکه ی عصبی مصنوعی است. عامل های دبی فراورده و انرژی مصرفی به عنوان عامل های خروجی مدل در نظر گرفته شد و دو شبکه ی عصبی مجزا برای پیش بینی این دو عامل مدنظر قرار گرفت. نتیجه های مدل سازی با دقت بسیار خوب، خطای متوسط مطلق، خطای متوسط نسبی و خطای احتمالی بین داده های واقعی کارخانه و مدل را به ترتیب برابر با ۲/۱۴، ۱/۲۱ و ۲/۹ و برای شبکه ی اول و ۰/۳۷، ۰/۸۴ و ۰/۵۵ برای شبکه ی دوم پیش بینی کرد. بر اساس تجزیه حساسیت، دمای گاز سنتز خروجی از مبدل، بیشترین تأثیر را بر تولید هیدروژن و دبی جریان گاز اتلافی به عنوان تأثیرگذارترین عامل بر میزان مصرف انرژی واحد شناخته شدند. پس از مدل سازی واحد، از الگوریتم ژنتیک به منظور یافتن شرایط عملیاتی بهینه استفاده شد. به این صورت که سود ناخالص به دست آمده از فرایند به عنوان تابع هدف مدنظر قرار گرفت و عامل های عملیاتی به منظور دستیابی به حداکثر سود با استفاده از الگوریتم ژنتیک بهینه شد. نتیجه های الگوریتم ژنتیک سود به دست آمده از فرایند را ۴۲/۵۶ دلار بر ساعت پیش بینی کرد که ۲۵ درصد بیشتر از میانگین سود واحد در شرایط واقعی است.

واژه های کلیدی: هیدروژن، تبدیل متان با بخار آب، مدل سازی، شبکه ی عصبی مصنوعی، بهینه سازی، الگوریتم ژنتیک

مقدمه

بدون گوگرد در حال افزایش است [۱ و ۲]. بیشترین میزان هیدروژن از سوخت های فسیلی با روش های گازی شکل کردن زغال سنگ، اکسایش جزیی و تبدیل هیدروکربن ها تولید می شود. به طور کلی فرایند تبدیل به فرایندی گفته می شود که طی آن جریانی حاوی هیدروکربن یا الکل ها، آب و یا اکسیژن، از روی کاتالیست در شرایط بهینه ی عملیاتی عبور داده شود [۳ تا ۹]. از بین هیدروکربن ها، متان

هیدروژن یک حامل انرژی با استانداردهای بسیار استثنایی به عنوان خوراک فرایندهای پتروشیمی و پالایش که با محیط زیست نیز هماهنگ است، از اهمیت ویژه ای برخوردار است. تقاضای جهانی برای هیدروژن، به دلیل نیاز به فراوری مواد خام سنگین و کثیف و ترکیب آن ها با مواد مطلوب به منظور تولید سوخت های پاک تر

جمله هوا فضا، اتومبیل‌سازی، دفاعی، نفت و گاز، روباتیک، برق و الکترونیک کاربردهای زیادی پیدا کرده‌اند.

نرون به عنوان کوچک‌ترین واحد پردازشگر داده‌ها در یک شبکه‌ی عصبی مصنوعی، اساس عملکرد آن را تشکیل می‌دهد. از ترکیب چند نرون، سلول ساخته می‌شود که بسته به نوع آن، سلول وظیفه‌ی خاصی را در شبکه به عهده دارد. چگونگی اتصال سلول‌های عصبی در لایه‌های متفاوت، مشخص‌کننده‌ی ساختار شبکه است که معماری شبکه نام دارد [۱۲]. کاربرد شبکه‌های عصبی مصنوعی شامل مراحل آموزش، بازخوانی و الگوریتم پس انتشار خطاست. پاره‌ای از دلایل‌هایی که موجب شده تا شبکه‌های عصبی مصنوعی مورد توجه قرار گیرند، به قرار زیر اند:

- شبکه‌های عصبی مصنوعی قادر به تشخیص رابطه‌ی بین متغیرهای ورودی و خروجی بدون نیاز به ملاحظات فیزیکی صریح هستند،
- حتی زمانی که مجموعه‌های آموزشی دارای خطای اندازه‌گیری باشند، عملکرد خوبی دارند،
- قادرند خود را با مشکلات و تغییرات به‌وجود آمده سازگار کنند،
- سایر مشخصات پردازش اطلاعات در شبکه را دارند و وقتی یک‌بار مورد آموزش قرار گیرند به آسانی قابل کاربرد هستند [۱۳].
- در صورت عدم درک کامل مسایل که تجزیه معنادار با روش‌های فیزیکی امکان پذیر نیست کاربرد شبکه‌ها مورد توجه بیشتری قرار می‌گیرند،
- شبکه‌ها قادر به مدل‌سازی فرایندهای غیرخطی بدون حل معادلات پیچیده‌ی مشتقات جزئی هستند،
- بر خلاف روش هم‌گرایی، شبکه‌ها نیازی به فرض کردن فرم ریاضی رابطه‌ی ورودی و خروجی ندارند [۱۴].

الگوریتم ژنتیک

در فرایندهای مهندسی، الگوریتم ژنتیک یکی از روش‌هایی است که به‌خوبی قادر است فرایند تولید، انتخاب بهترین طرح و یافتن جواب بهینه را انجام دهد. الگوریتم ژنتیک از اصول زایش

با توجه به ارزانی و در دسترس بودن، منبع مناسب‌تری برای تولید هیدروژن در واکنش تبدیل متان با بخار آب^۱ به عنوان اصلی‌ترین روش تولید هیدروژن در صنایع مورد استفاده قرار می‌گیرد. فرایند تولید هیدروژن در تبدیل با بخار متان شامل چهار مرحله‌ی اصلی پیش‌تصفیه‌ی خوراک، واکنش تبدیل گاز طبیعی، واکنش انتقال آب-گاز و خالص‌سازی هیدروژن است.

در این مقاله، یک واحد هیدروژن در مجتمع فولاد مبارکه‌ی اصفهان با ظرفیت نامی تولید ۲۵۰ نرمال مترمکعب در ساعت با خلوص ۹۹/۹۹۹ درصد مورد بررسی قرار گرفت. با توجه به محدودیت‌های پیش‌روی شبیه‌سازی فرایند با استفاده از نرم‌افزارهای تجاری (در دسترس نبودن سینتیک واکنش‌ها، فاصله گرفتن از شرایط عملیاتی و غیره)، از شبکه‌ی عصبی مصنوعی^۲ برای مدل‌سازی واحد صنعتی هیدروژن استفاده شد. در نهایت فرایند مورد نظر با الگوریتم ژنتیک^۳ بهینه‌سازی شد. لذا اهداف این مقاله در دو بخش مدل‌سازی با شبکه‌ی عصبی مصنوعی و بهینه‌سازی با الگوریتم ژنتیک واحد تولید هیدروژن طبقه‌بندی می‌شود که تاکنون پژوهش مستقلی در برگیرنده‌ی تمامی موارد فوق ارایه نشده است. شبکه‌ی عصبی مصنوعی و الگوریتم ژنتیک، دو روش نوین ایجاد شده با استفاده از علوم کامپیوتری و بر مبنای خلقت موجودات زنده هستند که اولی برای مدل‌سازی سامانه‌های پیچیده و دومی برای بهینه‌سازی کاربرد دارد.

شبکه‌ی عصبی مصنوعی

در ساختار کلی شبکه‌های عصبی مصنوعی از شبکه‌ی بیولوژیکی انسان الهام گرفته شده است [۱۰]. در شرایطی که مجموعه قوانین لازم برای حل مسأله وجود نداشته باشد و یا شناخت پدیده بسیار پیچیده باشد، دانشمندان را به فکر کاربرد یک سامانه هوش مصنوعی انداخت که قابلیت یادگیری، خلاقیت و انعطاف‌پذیری انسان را داشته باشد. در این راستا روش‌های محاسباتی عصبی ارایه شد که در آن تکیه‌ی اساسی بر تربیت تدریجی سامانه است [۱۱]. در دهه‌های اخیر شبکه‌های عصبی به‌تقریب در تمام علوم از

1. Steam methane reforming (SMR)

2. Artificial neural network (ANN)

3. Genetic algorithm (GA)

جمعیت حاضر با فرزندان جایگزین می‌شوند و نسل بعدی شکل می‌گیرد.

الگوریتم زمانی متوقف می‌شود که یکی از شرط‌های توقف به شرح زیر صورت گیرد:

- ۱- تعداد نسل‌ها: الگوریتم زمانی متوقف می‌شود که تعداد نسل‌ها به مقدار معینی برسد؛
- ۲- محدودیت زمانی: در جعبه ابزار الگوریتم ژنتیک می‌توان این محدودیت را در واحد ثانیه تعیین نمود؛
- ۳- محدودیت شایستگی: الگوریتم زمانی متوقف می‌شود که بهترین مقدار شایستگی در جمعیت حاضر، کوچک‌تر یا مساوی یک مقدار معین شود؛
- ۴- رکود نسلی: اگر در نسل‌ها به تعداد معینی، هیچ‌گونه پیشرفتی حاصل نشود، الگوریتم متوقف می‌شود؛
- ۵- رکود زمانی: در صورتی که در تابع هدف برای مدت زمان معینی هیچ‌گونه پیشرفتی حاصل نشود، الگوریتم متوقف می‌شود.

الگوریتم ژنتیک از سه روش برای تولید افراد نسل بعدی استفاده می‌نماید:

- ۱- تشخیص افراد نخبه: فرزندان نخبه در واقع افرادی از جمعیت حاضر با بهترین مقدار شایستگی هستند. این افراد به صورت اتوماتیک به نسل بعدی انتقال می‌یابند؛
- ۲- تولید فرزندان تلفیقی: با ترکیب بردارهای مربوط به دو والدین ایجاد می‌شوند؛
- ۳- تولید فرزندان جهش یافته: با ایجاد یک تغییر تصادفی یا جهش در یکی از والدین ایجاد می‌شوند.

شرح واحد تولید هیبروژن

همان‌گونه که بیان شد، هدف از این مقاله مدل‌سازی واحد تولید هیبروژن مجتمع فولاد مبارکه است. این واحد تحت لیسانس شرکت کارلیک آلمان با ظرفیت نامی ۲۵۰ نرمال متر مکعب هیبروژن در ساعت احداث شده است. نمودار جریانی این واحد در شکل ۱ نشان داده شده است.

و تکامل موجودات زنده الهام گرفته شده است. الگوریتم ژنتیک برای تولید نسل بعدی از نسل حاضر از سه گروه قوانین اصلی استفاده می‌کند [۱۵]:

- ۱- قانون انتخاب: افرادی که برای تولید نسل بعدی مورد استفاده قرار می‌گیرند، انتخاب می‌شوند؛
- ۲- قانون تلفیق: دو والد را با هم ترکیب کرده و فرزندان نسل بعد را تولید می‌کند؛
- ۳- قانون جهش: یک تغییر تصادفی را بر روی افراد اعمال کرده و افراد جدیدی را در جمعیت تولید می‌کند.

اصطلاحات مورد استفاده در الگوریتم ژنتیک عبارتند از:

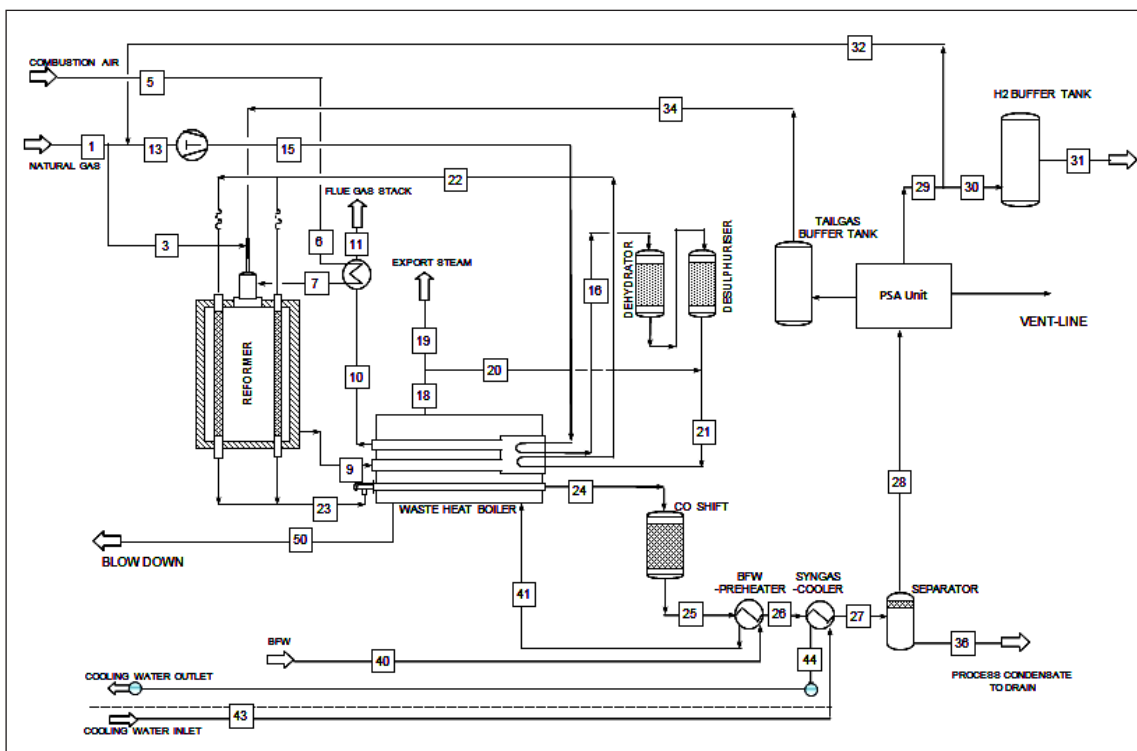
- تابع شایستگی: تابع هدف است که لازم است بهینه‌سازی شود؛
- افراد: یک فرد عبارت است از هر نقطه‌ای که قابل اعمال به تابع شایستگی است؛
- جمعیت و نسل‌ها: یک آرایه از افراد است.

طرح کلی آرایه شده به شرح زیر، چگونگی عملکرد الگوریتم ژنتیک را نشان می‌دهد:

- ۱- الگوریتم با تولید یک جمعیت آغازین تصادفی کار خود را آغاز می‌کند؛
- ۲- الگوریتم در ادامه یک ترتیب از جمعیت‌های جدید را ایجاد می‌کند (نسل‌ها).

برای تولید نسل جدید، الگوریتم مراحل زیر را انجام می‌دهد:

- ۱- به هر عضو از جمعیت حاضر یک امتیاز می‌دهد. این کار با محاسبه مقدار شایستگی هر یک از افراد حاضر در جمعیت انجام می‌شود؛
- ۲- امتیازهای شایستگی به دست آمده به کمک مقیاس‌بندی به گستره‌ی قابل استفاده‌تری از مقادیر تبدیل می‌شوند؛
- ۳- والدین بر اساس مقدار شایستگی‌های دریافتی افراد، انتخاب می‌شوند. در واقع از افراد شایسته‌تر به عنوان والدین استفاده می‌شود؛
- ۴- فرزندان به کمک والدین تولید می‌شوند. فرزندان با ایجاد تغییرات تصادفی روی یکی از والدین (جهش) و یا ترکیب بردارهای مربوط به هر دو والدین (تلفیق)، تولید می‌شوند؛



شکل ۱ طرح شماتیک فرایند تولید هیدروژن فولاد مبارکه

به متان برابر با ۲٫۷ (کیلوگرم بخار به نرمال متر مکعب گاز طبیعی) که بیشتر از مقدار استوکیومتری است، وارد تبدیل کننده می‌شود. مقدار اضافی بخار، باعث جلوگیری از ایجاد کک بر روی سطح کاتالیست می‌شود.

در تبدیل کننده، واکنش تبدیل با بخار متان، اتان، پروپان و دیگر هیدروکربن‌های سبک موجود در گاز طبیعی انجام شده و هیدروژن و کربن مونواکسید تولید می‌شود. این جریان گاز (موسوم به گاز سنتز) پس از تبادل گرما در بویلر بازیاب، وارد واکنشگاه انتقال می‌شود. در این واکنشگاه، به منظور افزایش بازده هیدروژن تولیدی، کربن مونواکسید تولیدی در مرحله‌ی قبل، طی واکنشی موسوم به واکنش انتقال آب- گاز، با بخار آب واکنش داده و هیدروژن و دی‌اکسید کربن تولید می‌شود. بازده واکنش تبدیل حدود ۸۰ درصد بوده و غلظت کربن مونواکسید خروجی باید کمتر از ۱٫۹ درصد مولی باشد.

تولید هیدروژن در این واحد با استفاده از فرایند تبدیل گاز طبیعی صورت می‌گیرد. گاز طبیعی، به عنوان خوراک (جریان ۱۳) فرایند تبدیل به‌وسیله کمپرسور رفت و برگشتی^۱ تا فشار ۱۷ بار فشرده و در بویلر بازیافت گرما، با جریان‌های گاز خروجی از تبدیل کننده و گازهای به‌دست آمده از احتراق تبادل گرما انجام داده و تا دمای ۵۰۰ درجه‌ی سانتی‌گراد پیش گرم می‌شود. جریان ذکر شده وارد دو واکنشگاه هیدراتور^۲ و گوگرد زدا^۳ می‌شود تا ترکیب‌های گوگردی گاز که به عنوان سم کاتالیست‌های تبدیل به‌حساب می‌آیند از خوراک حذف شوند. جریان خروجی از ستون‌های هیدراتور و گوگرد زدا با بخار فرایندی که در بویلر بازیاب و با استفاده از آب تغذیه‌ی بویلر (BFW) تولید شده است، مخلوط شده و به عنوان خوراک واحد تبدیل در می‌آید. اما قبل از ورود به واکنشگاه تبدیل، بار دیگر در بویلر تا دمای ۵۰۰ درجه‌ی سانتی‌گراد گرم می‌شود. جریان ورودی (جریان شماره‌ی ۲۲) به تبدیل کننده با نسبت بخار

1. Reciprocating Compressor

2. Hydrator

3. Desulphuriser

انرژی به تنهایی و بدون در نظر گرفتن مقدار تولید، چندان منطقی نیست. از این رو، تولید فرآورده هیدروژن به عنوان عامل خروجی دیگر شبکه‌ی عصبی در نظر گرفته شد. با پیش‌بینی این دو عامل، می‌توان عملکرد واحد را مورد بررسی قرار داد. مقدار هیدروژن تولیدی در واحد در هر ساعت با تجهیزات اندازه‌گیری اتوماتیک، ثبت می‌شود. با کاربرد میانگین حسابی، مقدار انرژی مصرفی در کوره را می‌توان بر اساس معادله ۱ در نظر گرفت:

$$FGENERGY = \quad (1)$$

$$= \frac{37259 \times NGENERGYF + 7550.4 \times TAILGASF}{(37259 + 7550.4)}$$

$$= 0.8315 \times NGENERGYF + 0.1685 \times TAILGASF$$

در رابطه‌ی فوق، $FGENERGY$ دبی سوخت مصرفی در کوره، $NGENERGYF$ دبی گاز طبیعی مصرفی به عنوان سوخت (Nm^3/h) و $TAILGASF$ دبی گاز اتلافی برگشتی (Nm^3/h) است. بنابراین، خروجی دیگر شبکه (مصرف انرژی کوره)، که با رابطه‌ی فوق به دو عامل عملیاتی واحد وابسته است، در نظر گرفته شد. در جدول ۱ عامل‌های خروجی و مقدارهای آن‌ها در طراحی نشان داده شده‌اند.

جدول ۱ عامل‌های خروجی شبکه‌ی عصبی

ردیف	عامل	علامت اختصاری	مقدار عامل در طراحی
۱	دبی هیدروژن تولیدی	H2PRODUCT	۲۵۰ (Nm^3/h)
۲	سوخت مصرفی در کوره*	FGENERGYF	۵۳.۵۸ (Nm^3/h)

* سوخت مصرفی کوره با استفاده از معادله ۱ به شکل زیر محاسبه شده است:

$$FGENERGY = 0.8315 \times 31.2 + 0.1685 \times 164 = 53.58$$

با توجه به عامل‌های خروجی، متغیرهای تأثیرگذار بر این عامل‌ها به عنوان متغیرهای ورودی انتخاب شد. فرایند انتخاب متغیرهای ورودی پیچیده و بسیار تأثیرگذار است. در این تحقیق با توجه به نتیجه‌های به‌دست آمده از شبیه‌سازی واحد هیدروژن با نرم افزار Hysys و مبانی فیزیکی فرایند، از بین ۷۶ عامل متفاوتی که در واحد اندازه‌گیری و ثبت می‌شوند، بیست عامل در

جریان خروجی از واکنشگاه انتقال حاوی حدود ۵۶ درصد هیدروژن و ناخالصی‌هایی نظیر کربن‌دی‌اکسید، کربن‌مونواکسید، آب و دیگر ترکیب‌ها بوده که باید به منظور دستیابی به فرآورده خالص، جداسازی این ترکیب‌ها از هیدروژن انجام شود.

به منظور جداسازی، در ابتدا و برای حذف آب از جریان گاز، دمای جریان از ۴۱۱ درجه‌ی سانتی‌گراد تا ۳۵ درجه‌ی سانتی‌گراد کاهش می‌یابد تا محتوای آب موجود در جریان متراکم شده و توسط یک جداکننده‌ی دو فاز از جریان اصلی حذف شود. مخلوط گازهای خروجی از قسمت تبدیل واحد هیدروژن، در نهایت برای خالص‌سازی و دستیابی به گاز هیدروژن با درجه‌ی خلوص بالا، وارد برج‌های جذب و دفع سطحی می‌شوند. این برج‌ها دارای لایه‌های متفاوت مواد جاذب سطحی (کربن فعال، آلومینا، سیلیکاژل، غریال مولکولی) برای جذب ناخالصی‌های کربن‌مونواکسید، دی‌اکسیدکربن، متان و بخار آب هستند. عمل جذب روی این جاذب‌ها در فشار ۱۳/۵ بار انجام می‌شود و گاز هیدروژن با خلوص ۹۹.۹۹۹ درصد و هم‌چنین گاز اتلافی^۱ شامل ناخالصی‌ها با فشار کم تولید می‌شود.

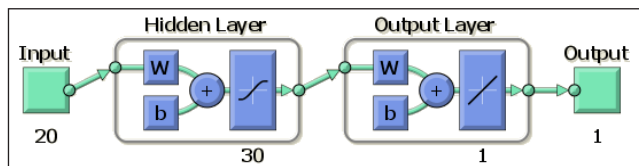
جریان اتلافی خروجی از مرحله‌ی دفع که حاوی ۳۸ درصد هیدروژن و ۴۰ درصد کربن‌مونواکسید است، می‌تواند به عنوان سوخت در کوره مورد استفاده قرار گیرد. بنابراین، این جریان به همراه گاز طبیعی در کوره تبدیل سوزانده می‌شود تا از انرژی گرمایی آن برای گرمایش تبدیل‌کننده استفاده شود.

مدل‌سازی واحد تولید هیدروژن با شبکه‌ی عصبی

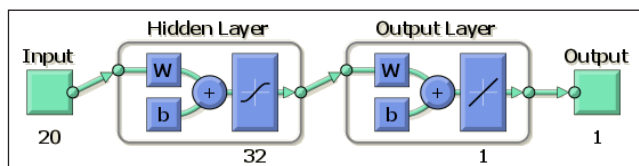
با توجه به این‌که شبکه‌ی عصبی مصنوعی بدون نیاز به رابطه‌های ویژه حاکم بر فرایند و تنها با استفاده از داده‌های ورودی و خروجی به مدل‌سازی فرایند می‌پردازد، از این روش جهت مدل‌سازی واحد تولید هیدروژن استفاده شد. با توجه به اهمیت مصرف انرژی و لزوم ارزیابی راهکارهایی برای کاهش مصرف آن در فرایندهای شیمیایی، در این پژوهش مصرف انرژی در واحد تولید هیدروژن به عنوان یکی از عامل‌های خروجی شبکه‌ی عصبی در نظر گرفته شد. از طرف دیگر بررسی مصرف

جدول ۲ عامل‌های ورودی به شبکه‌ی عصبی

مقدار عامل در شرایط طراحی	علامت اختصاری	عامل	ردیف
۹۳ (Nm ³ /h)	NGFEEDF	دبی جریان گاز طبیعی و هیدروژن برگشتی	۱
۴۱۷ (Nm ³ /h)	PSAFEEDF	دبی جریان ورودی به PSA	۲
۱۶۴ (Nm ³ /h)	TAILF	دبی جریان Tail بازگشتی	۳
۲۴۳ (kg/h)	STEAMF	دبی خوراک بخار	۴
۲٫۲ (Nm ³ /h)	REH2F	دبی جریان هیدروژن بازگشتی	۵
۶۹۵ (Nm ³ /h)	COMBAF	دبی هوای احتراق	۶
۱٫۶ (mol %)	O2	محتوی اکسیژن خروجی از استک	۷
۸۵۰ (°C)	SGRT	دمای جریان خروجی از ریفرمر	۸
۳۳۰ (°C)	SHIT	دمای جریان ورودی به راکتور شیفت	۹
۴۱۱ (°C)	SHOT	دمای جریان خروجی از راکتور شیفت	۱۰
۱۰۲۰ (°C)	FUFGT	دمای گازهای خروجی از کوره	۱۱
۳۵۰ (°C)	HYTI	دمای ورودی به Hydrator	۱۲
۱۲۰ (°C)	SGPHT	دمای گاز سنتز خروجی از مبدل پیش‌گرمکن	۱۳
۳۵ (°C)	DSTI	دمای ورودی به Desulphurizer	۱۴
۲۵۰ (°C)	COMBAT	دمای هوای احتراق ورودی به کوره	۱۵
۳۵ (°C)	SGSEPT	دمای ورودی به Separator	۱۶
۵۰۰ (°C)	RFEEDT	دمای جریان ورودی به ریفرمر	۱۷
۱۴٫۲ (bar_g)	PSAPI	فشار جریان ورودی به PSA	۱۸
۵٫۲ (bar_g)	TAILBTP	فشار تانک بافر Tail gas	۱۹
۰٫۲ (bar_g)	H2BT	فشار H ₂ بافر	۲۰



شکل ۲ ساختمان شبکه‌ی عصبی اول (ANNH2)



شکل ۳ ساختمان شبکه‌ی عصبی دوم (ANNFG)

جدول ۲ به عنوان عامل‌های ورودی برای مدل‌سازی با شبکه‌ی عصبی در نظر گرفته شدند. در این پژوهش از شبکه‌های عصبی پرسپترون چند لایه پیشرو برای مدل‌سازی استفاده شده است. این شبکه شامل یک لایه‌ی ورودی، یک یا چند لایه‌ی پنهان و یک لایه‌ی خروجی است. بیست عامل مذکور در جدول ۲ به عنوان ورودی‌های شبکه و دو عامل دبی هیدروژن تولیدی و سوخت مصرفی به عنوان خروجی‌های شبکه در نظر گرفته شدند. برای جلوگیری از پیچیدگی در شبکه، می‌توان برای هر خروجی، یک شبکه‌ی مجزا تعریف کرد، به‌گونه‌ای که هر شبکه با بیست نرون در لایه‌ی ورودی و یک نرون در لایه‌ی خروجی طراحی شده است. در این پژوهش برای مدل‌سازی این دو شبکه، از نرم‌افزار متلب^۱ استفاده شده است. در این پژوهش از روش انتخاب کمترین تعداد نرون در لایه‌ی پنهان استفاده شده است. بدین صورت که برای آموزش شبکه، ابتدا ۶۰۰ داده‌ای که برای مدل‌سازی شبکه در نظر گرفته شده‌اند، به‌طور تصادفی به سه قسمت تقسیم شدند، به‌گونه‌ای که ۸۰ درصد داده‌ها، برای آموزش و ۱۰ درصد داده‌ها برای ارزیابی و ۱۰ درصد داده‌ها برای آزمون شبکه استفاده شد.

برای آموزش شبکه‌ی اول، داده‌های ورودی به صورت یک بستر شامل ۶۰۰ سطر و ۲۰ ستون که هر ستون دربرگیرنده‌ی یک عامل عملیاتی و سطرها، تعداد داده‌ها است، به عنوان ورودی و H₂PRODUCT به صورت یک بستر ۶۰۰ سطر و یک ستون به عنوان خروجی، در نظر گرفته شده‌اند. شبکه‌ی عصبی مصنوعی آموزش دیده برای خروجی اول (H₂PRODUCT) شبکه‌ی هیدروژن (ANNH₂) نامیده می‌شود. ساختمان شبکه‌ی عصبی اول در شکل ۲ نشان داده شده است. برای آموزش شبکه‌ی عصبی دوم، داده‌های ورودی مانند شبکه‌ی اول به سامانه وارد شد. عامل خروجی (FGENERGYF) به صورت یک بستر با ۱ ستون و ۶۰۰ سطر برای این شبکه در نظر گرفته شد.

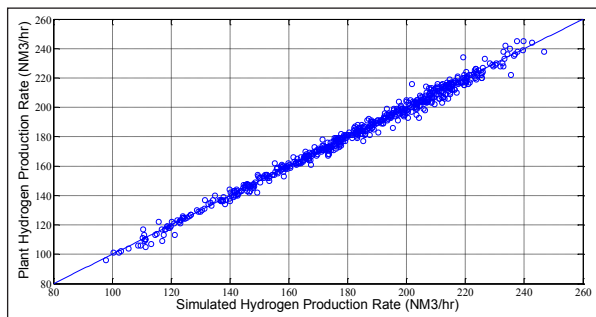
شبکه‌ی عصبی مصنوعی آموزش دیده برای خروجی دوم (FGENERGYF) را شبکه‌ی دوم (ANNFG) نامیدیم. شبکه‌ی عصبی دوم در شکل ۳ ارائه شده است.

از مدل سازی شبکه، کلیه داده های مدل سازی به عنوان ورودی به شبکه ی عصبی مدل شده وارد شدند و شبکه، خروجی متناظر با این ورودی را محاسبه کرد. در جدول ۳ مقادارهای خطاها برای داده های مدل سازی شبکه ی عصبی مصنوعی اول نشان داده شده اند. خطای میانگین نسبی نشان می دهد که میانگین اختلاف مقادارهای واقعی و پیش بینی مدل، تنها ۱٫۲۱ درصد است که نشان از دقت بالای شبکه ی عصبی دارد.

جدول ۳ مقادارهای خطا برای داده های مدل سازی شبکه ی عصبی مصنوعی اول (ANNH2)

خطای احتمالی (PE)	خطای متوسط نسبی (ARE)	خطای متوسط مطلق (AAE)
۲٫۹	۱٫۲۱	۲٫۱۴

در ضمن مقادارهای پیش بینی مدل بر حسب مقادارهای واقعی در شکل ۴ ترسیم شده اند که نقاط نمودار فاصله ی چندانی از خط ۴۵ درجه نداشته و این امر گویای مطابقت نزدیک مقادارهای پیش بینی شده مدل با مقادارهای واقعی است.



شکل ۴ مقایسه ی تولید هیدروژن واقعی با پیش بینی شده مدل

با توجه به نتیجه های فوق و مقادارهای قابل قبول خطای شبکه ی عصبی اول، دقت این شبکه برای پیش بینی تولید هیدروژن مورد تأیید بوده و می توان از آن برای مدل سازی واحد بر اساس ۲۰ عامل ورودی استفاده کرد. در بخش بعد از این شبکه برای بهینه سازی با استفاده از الگوریتم ژنتیک استفاده شده است.

بنابراین، شبکه های عصبی اول و دوم به ترتیب با ۳۰ نرون و ۳۲ نرون برای مدل سازی واحد هیدروژن در خصوص پیش بینی تولید هیدروژن و مصرف انرژی بر اساس ۲۰ عامل عملیاتی واحد تعیین شدند.

نتیجه ها و بحث

مدل سازی شبکه ی عصبی

برای مقایسه ی کمی عملکرد مدل های پیشنهادی، می توان افزون بر رسم مقادارهای پیش بینی مدل با مقادیر واقعی، از معیارهای خطای متوسط مطلق^۱، خطای متوسط نسبی^۲، و خطای احتمالی^۳ به شرح زیر استفاده کرد [۱۷].

$$AAE = \frac{1}{n} \sum_{i=1}^n |X_{model} - X_{plant}| \quad (2)$$

$$ARE = \left(\frac{1}{n} \sum_{i=1}^n \frac{|X_{model} - X_{plant}|}{X_{plant}} \right) \times 100 \quad (3)$$

$$PE = \sqrt{\frac{1}{n} \sum_{i=1}^n (X_{model} - X_{plant})^2} \quad (4)$$

در روابط فوق، مقدار X_{model} مقدار عامل پیش بینی شده به وسیله مدل، X_{plant} مقدار عامل واقعی فرایند و n تعداد داده ها است. آزمون شبکه به این صورت انجام می شود که پس از این که شبکه آموزش دیده به دست آمد، داده های آزمون، به عنوان ورودی به شبکه وارد شده و شبکه، خروجی را برای این داده ها محاسبه می کند. به این کار در اصطلاح شبیه سازی می گویند. از این کار می توان برای ارزیابی دقت پیش بینی مدل استفاده نمود.

نتیجه های مدل سازی شبکه ی عصبی اول

شبکه ی عصبی اول (ANNH2) با ۲۰ نرون در لایه ی ورودی، ۳۰ نرون در لایه ی پنهان و ۱ نرون در لایه ی خروجی، برای مدل سازی مقدار تولید هیدروژن (H2PRODUCT) طراحی شد. فرایند آموزش این شبکه با داده های مدل سازی چندین مرتبه تکرار شد تا شبکه ای با حداقل خطای احتمالی به دست آمد. پس

1. Average absolute error (AAE)

2. Average relative error (ARE)

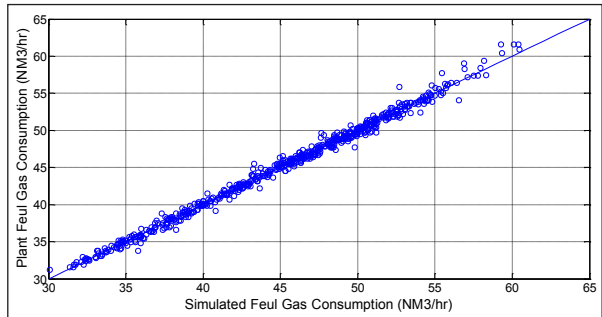
3. Probable error (PE)

نتیجه‌های مدل‌سازی شبکه‌ی عصبی دوم

به منظور مدل‌سازی میزان مصرف انرژی در کوره‌ی تبدیل، از شبکه‌ی عصبی دوم (ANNFG) با ۲۰ نرون در لایه‌ی ورودی، ۳۲ نرون در لایه‌ی پنهان و ۱ نرون در لایه‌ی خروجی استفاده شد. مشابه با شبکه‌ی اول برای این شبکه نیز پس از مدل‌سازی شبکه، کلیه‌ی داده‌های مدل‌سازی به عنوان ورودی به شبکه‌ی عصبی مدل شده وارد شدند و خروجی متناظر با این ورودی‌ها به‌وسیله‌ی شبکه محاسبه شد. مقادیرهای خطاهای متفاوت در جدول ۴ نشان داده شده است. مطابق جدول فوق، خطای این شبکه کمتر از شبکه‌ی اول است. در شکل ۵، مقادیرهای پیش‌بینی مدل بر حسب مقادیرهای واقعی برای این شبکه نیز نشان داده شده‌اند.

جدول ۴ مقادیرهای خطا برای داده‌های مدل‌سازی شبکه‌ی عصبی مصنوعی دوم (ANNFG)

خطای احتمالی (PE)	خطای متوسط نسبی (ARE)	خطای متوسط مطلق (AAE)
۰٫۵۵	۰٫۸۴	۰٫۳۷



شکل ۴ مقایسه‌ی تولید هیدروژن واقعی با پیش‌بینی شده مدل

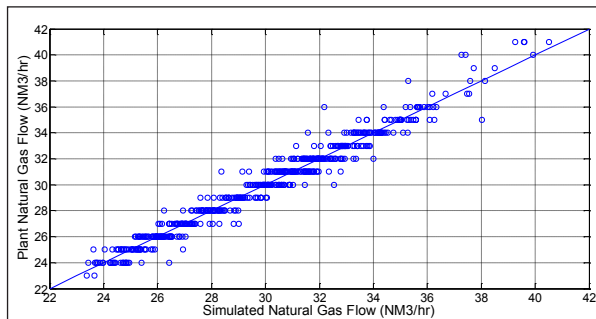
با توجه به جدول فوق، میانگین تفاوت بین مصرفی پیش‌بینی شده به‌وسیله مدل با مقادیرهای واقعی، کمتر از ۰٫۶ متر مکعب بر ساعت است که این امر نشان از دقت بالای شبکه‌ی عصبی دوم دارد.

اما هدف از ایجاد این شبکه، پیش‌بینی مصرف گاز طبیعی به عنوان انرژی مصرفی در واحد است. درحالی‌که خروجی این شبکه،

میزان انرژی مصرفی (ترکیبی از گاز طبیعی و گاز اتلافی) را ارایه می‌دهد. بنابراین، خروجی این شبکه را باید به دبی گاز طبیعی مصرفی تبدیل نمود. با رابطه‌ی ۵ می‌توان دبی گاز طبیعی مصرفی در کوره را تعیین کرد.

$$NGENERGYF = \frac{FGENERGY - 0.1685 \times TAILGASF}{0.8315} \quad (5)$$

بنابراین، با استفاده از خروجی محاسبه شده توسط شبکه‌ی عصبی دوم (FGENERGY) و دبی گاز اتلافی (TAILGASF)، که یکی از عامل‌های ورودی شبکه است، می‌توان دبی گاز طبیعی مصرفی به عنوان سوخت را به دست آورد. در شکل ۶ دبی گاز طبیعی پیش‌بینی شده با مدل و مقادیرهای واقعی ترسیم شده‌است. مقادیرهای خطای مطلق، نسبی و احتمالی داده‌های مدل‌سازی برای گاز طبیعی محاسبه شده و در جدول ۵ نشان داده شده است. همان‌گونه که مشاهده می‌شود، خطای پیش‌بینی مصرف گاز طبیعی با استفاده از شبکه‌ی عصبی دوم، مقدار قابل قبولی است. در نتیجه این شبکه نیز، مشابه شبکه‌ی عصبی اول، عملکرد مناسبی برای پیش‌بینی عملکرد واحد تولید هیدروژن دارد. با ذکر این نکته که خطای شبکه‌ی عصبی دوم کمی پایین‌تر از شبکه‌ی عصبی اول است. بنابراین با مجموع این دو شبکه می‌توان عملکرد واحد تولید هیدروژن (تولید فراورده و مصرف انرژی) را با استفاده از بیست عامل عملیاتی واحد به عنوان ورودی مورد بررسی قرار داد.



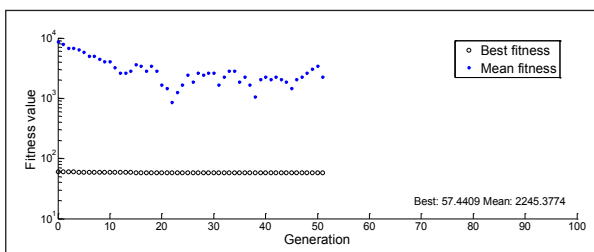
شکل ۶- مقایسه‌ی گاز طبیعی (NGENERGY) واقعی و مقدار پیش‌بینی شده توسط شبکه‌ی عصبی دوم (ANNFG) برای داده‌های مدل‌سازی

متلب، الگوریتم حل مسأله‌ی بهینه‌سازی بسط داده شد. الگوریتم ژنتیک، در نسل‌ها و کروموزوم‌هایی که ایجاد می‌کند با تغییر ۱۹ عامل ورودی مسأله به سمت بیشینه‌سازی تابع هدف که همان سود به‌دست آمده از فرایند است، حرکت می‌کند. با استفاده از فرایند حدس و خطا ویژگی‌های مناسب برای الگوریتم ژنتیک تعیین شد. این ویژگی‌ها در جدول ۶ نشان داده شده است.

جدول ۶ ویژگی‌های الگوریتم ژنتیک استفاده شده در این مقاله

۳۵	تعداد افراد در هر نسل
۴۰۰	تعداد نسل‌ها
۲	تعداد جمعیت نخبه
۰٫۸	کسر تقاطع

برای افزایش سرعت میل به جواب الگوریتم ژنتیک و همچنین تغییر عامل‌های عملیاتی در گستره‌ی مجاز واقعی فرایند تولید هیدروژن مورد مطالعه، لازم است برای متغیرهای عملیاتی مقدارهای کمینه و بیشینه مشخص شود. با توجه به بیشینه واحد و داده‌های موجود، مقدارهای مناسب برای کمینه و بیشینه عامل‌های عملیاتی (به منظور در نظر گرفتن محدودیت‌های فرایند مانند دما و فشار) مطابق آن‌چه در جدول ۷ نشان داده شده است، انتخاب شدند. در نهایت با استفاده از این عامل‌ها و کاربرد الگوریتم ژنتیک، مقدار بیشینه‌ی تابع هدف و عامل‌های متناظر با آن مشخص شدند. لازم به ذکر است که در هر مرحله برای محاسبه‌ی تابع هدف، از شبکه‌های عصبی مدل شده در قسمت قبل استفاده شده است. در شکل ۷ روند دست‌یابی به مقدار بهینه‌ی تابع هدف با الگوریتم ژنتیک (تغییرات تابع هدف در نسل‌های متفاوت) نشان داده شده است.



شکل ۷ روند دست‌یابی به جواب بهینه با الگوریتم ژنتیک

جدول ۵ مقدارهای خطای پیش‌بینی مصرف گاز طبیعی (NGENERGY) برای داده‌های مدل‌سازی شبکه‌ی عصبی مصنوعی دوم

خطای متوسط مطلق (AAE)	خطای متوسط نسبی (ARE)	خطای احتمالی (PE)
۰٫۴۵	۱٫۴۹	۰٫۶۷

نتیجه‌های بهینه‌سازی

با توجه به اطلاعاتی که از میزان مصرف گاز طبیعی به عنوان سوخت در روزهای متفاوت موجود است، بیشترین کارکرد واحد در دبی ۷۰ نرمال متر مکعب خوراک (ظرفیت ۷۵ درصد) صورت گرفته است. بنابراین، در این بخش شرایط بهینه‌ی عملیاتی برای کارکرد واحد با ظرفیت ۷۵ درصد را به دست آورده‌ایم.

به‌طور معمول بهینه‌سازی‌ها به منظور دست‌یابی به کمینه مصرف واکنشگرها و انرژی مصرفی یا دست‌یابی به بیشینه تولید فرآورده انجام می‌شود. در فرایند مورد مطالعه، با فرض دبی ثابت خوراک ورودی (۷۰ نرمال متر مکعب گاز طبیعی)، دو عاملی که در افزایش سوددهی واحد مؤثرند، مقدار هیدروژن تولیدی و مقدار گاز طبیعی مصرفی به عنوان سوخت هستند. در بخش قبل با استفاده از شبکه‌ی عصبی مصنوعی این دو عامل مدل‌سازی شدند. همان‌گونه که مشاهده شد، میزان انرژی مصرفی و نیز گاز طبیعی مصرفی تابع ۲۰ عامل عملیاتی واحد بودند. تغییر هر یک از این ۲۰ عامل می‌تواند منجر به تغییر مصرف انرژی و تولید هیدروژن شود. لذا عامل‌های متعددی روی تابع هدف تأثیرگذارند و بررسی همه‌ی آنها روی تابع هدف و یافتن مقادیر بهینه، مشکل است. از طرفی با توجه به اینکه رابطه‌ی صریح برای تابع هدف بر حسب متغیرهای آن موجود نیست، لذا امکان استفاده از روش‌های کلاسیک بهینه‌سازی مبتنی بر گرادیان وجود ندارد. بنابراین، برای بهینه‌سازی این فرایند از الگوریتم ژنتیک استفاده شد.

نتیجه‌های بهینه‌سازی با الگوریتم ژنتیک

برای بهینه‌سازی ۱۹ عامل عملیاتی واحد هیدروژن، از الگوریتم ژنتیک استفاده شده است. با توجه به تابع هدف ذکر شده در قسمت قبل و استفاده از بانک ابزار الگوریتم ژنتیک در نرم‌افزار

جدول ۷ حد بالا و پایین متغیرهای ورودی الگوریتم ژنتیک

عامل	حد بالا (UB)	حد پایین (LB)
FUFGT	۹۵۰	۹۱۰
SGRT	۷۸۰	۷۴۰
RFEEDT	۳۸۵	۳۶۵
O2	۱/۸	۱/۴
TAILF	۱۳۰	۹۰
COMBAF	۶۸۰	۶۰۰
HYTI	۳۴۰	۲۹۰
STEAMF	۲۰۰	۱۷۰
SHIT	۳۳۰	۲۷۰
SHOT	۳۸۰	۲۹۰
SGSEPT	۳۴	۱۲
PSAFEEDF	۳۱۴	۲۷۰
TAILBTP	۰/۶	۰/۳
H2BT	۱۳/۶	۹/۰
COMBAT	۱۵۰	۱۱۰
SGPHT	۱۳۰	۹۰
PSAPI	۱۴/۰	۱۳/۸
DSTI	۳۰۰	۲۵۰
REH2F	۱/۸	۱/۶

نتیجه‌گیری

با توجه به خطای بسیار کم نتیجه‌های به‌دست آمده از شبیه‌سازی با هایپسیس و مقدارهای طراحی، کاربرد این شبیه‌سازی با فرضیات مورد استفاده در این مقاله می‌تواند برای پیش‌بینی عملکرد واحد در شرایط طراحی مفید واقع شود. در صورت کارکرد در شرایط غیر از طراحی، استفاده از شبکه‌ی عصبی برای مدل‌سازی واحد، جواب مناسب‌تری می‌دهد. شبکه‌ای مصنوعی با یک لایه‌ی ورودی، ۳۰ لایه‌ی پنهان و یک لایه‌ی خروجی، بهترین ساختار برای پیش‌بینی مقدار هیدروژن تولیدی در واحد است. خطای احتمالی این شبکه برای داده‌های مدل‌سازی کمتر از ۳ است که گویای دقت بالای شبکه‌ی تدوین شده دارد. شبکه مصنوعی دیگر با یک لایه‌ی ورودی، ۳۲ لایه‌ی پنهان و یک لایه‌ی خروجی، بهترین ساختار برای پیش‌بینی مقدار انرژی مصرفی در واحد مورد مطالعه است. خطای احتمالی این شبکه برای داده‌های مدل‌سازی حدود ۰/۵ است که نشان از دقت بالای شبکه‌ی طراحی شده دارد. بر اساس تجزیه حساسیت، دمای گاز سنتر خروجی از تبدیل‌کننده، بیشترین تأثیر را بر تولید هیدروژن و دبی جریان گاز اتلافی به عنوان تأثیرگذارترین عامل بر میزان مصرف انرژی واحد شناخته شدند. بر طبق نتیجه‌های بهینه‌سازی با الگوریتم ژنتیک، سود به‌دست آمده از فرایند برابر با ۴۲/۵۶ دلار بر ساعت است که ۲۵ درصد بیشتر از میانگین سود واحد در شرایط واقعی می‌باشد.

سپاسگزاری

از دانشگاه کاشان به دلیل حمایت مالی پروژه تشکر و قدردانی می‌شود.

مراجع

- [1] Barigozzi, G.; Carrara, A.; Perdichizzi, A.; Int. J. Hydrogen Energ, 35, 3499–3508, 2010.
- [2] Gambini, M.; Vellini, M.; Int. J. Hydrogen Energ, 30, 593–604, 2005.
- [3] Akamatsu, K., Murakami T., Sugawara, T., Kikuchi R., NakaoShlub Sh.; AIChE Journal,

مقدار هیدروژن تولیدی (H2PRODUCT) متناظر با این عامل‌ها (خروجی شبکه‌ی ANNH2) برابر با ۲۰۲/۶ نرمال‌متر مکعب بر ساعت، مقدار گاز طبیعی مصرفی به عنوان سوخت (NGENERGYF) متناظر با این عامل‌ها (خروجی شبکه‌ی ANNFG) برابر با ۲۵/۸۴ نرمال‌متر مکعب بر ساعت و سود به‌دست آمده از این فرایند برابر با ۴۲/۵۶ دلار بر ساعت به دست آمد. میانگین سود این واحد براساس داده‌های موجود حدود ۳۴ دلار بر ساعت بوده است. با توجه به مقدار به دست آمده در این مقاله در صورت اعمال شرایط عملیاتی بهینه، سود واحد ۲۵ درصد بیش از میانگین سود واحد می‌شود.

- 57, 1882-1888, 2011.
- [4] Eduardo L.G., Oliveira, C.A., Grande A.E.; The Canadian Journal of Chemical Engineering, 87, 945-956, 2009.
- [5] Rakass, S.; Oudghiri-Hassani, H.; Rowntree, P.; Abatzoglou, N.; J. Power Sources; 158, 485-96, 2006.
- [6] Seo, Y-S.; Shirley, A.; Kolaczowski, S.T.; J. Power Sources, 108, 213-25, 2002.
- [7] Tong, J.; Matsumura, Y.; Catal Today, 111, 147-52, 2006.
- [8] Twigg, M.V., Catalyst handbook. Manson, London/PA, 201-218, 1996.
- [9] Barigozzi, G.; Carrara, A.; Perdichizzi, A.; Int. J. Hydrogen Energ, 36, 5311-5320, 2011.
- [10] McCulloch, W.S; B. Math. BioPhysics, 5, 115-133, 1943.
- [11] Rutkowska, D.; Pilinski, M., Rutkowski, L.; Neural networks, genetic algorithms and fuzzy systems, PWN, Warsaw, 67-76, 1996.
- [12] Lennox, B.; Rutherford, P.; Montague, G.A.; Haughina, C.; Compt. Chem. Eng. 22, 1573-1579, 1998.
- [13] Nascimento, O.; Augusto, C.; Giudici, R.; Guardani, R.; Compt. Chem. Eng. 24, 2303-2314, 2000.
- [14] Haykin, S.; Neural Networks: A Comprehensive Foundation. Macmillan, New York, USA, 26-37, 1994.
- [15] Rumelhart, D.E.; McClelland, J.L.; Parallel Recognition in Modern computers. In: Processing: Explorations in the Microstructure of Cognition. MIT Press/Bradford Books, Cambridge, USA; 121-134; 1986.
- [16] Ghoreishi, S.M.; Komeili, S.; J. Supercrit. Fluid. 50, 183-192, 2009.
- [17] Schenker, B.; Agarwal, M.; Compt. Chem. Eng. 20, 175-186, 1996.

Modeling and optimization of hydrogen production plant via artificial neural network and genetic algorithm

I. Akbari¹, M. Ghoreishi^{2,*}, N. Razavi³, M. Ghoreishi⁴, M. Vafaei-Jahan⁵

1. PhD student in Chemical Engineering, Department of Chemical Engineering, Isfahan University of Technology, Isfahan, Iran
2. Prof. of Chemical Engineering, Department of Chemical Engineering, Isfahan University of Technology, Isfahan, Iran
3. MSc. in Chemical Engineering, Department of Chemical Engineering, University of Kashan, Kashan, Iran
4. MSc. student in Software Engineering, Department of Computer Engineering, University of Imam Reza, Mashhad, Iran
5. Assistant Prof. of Software Engineering, Department of Computer Engineering, Islamic Azad University, Mashhad, Iran

Received: July 2013, Revised: September 2013, Accepted: October 2013

Abstract: The main objective of this research was to model an industrial hydrogen plant based on steam methane reforming using artificial neural network (ANN). Two different ANN networks were developed for prediction of hydrogen production rate and corresponding energy consumption using 20 operating parameters as inputs of both networks. The obtained ANN results indicated a very close compatibility with average absolute error, average relative error, and probable error of 2.14, 1.21, and 2.9 for hydrogen production, 0.37, 0.84 and 0.55 for energy consumption, respectively. Based on sensitivity analysis, temperature of synthesized gas from reformer was identified as the most important parameter influencing the hydrogen production, and energy consumption was affected the most by the tail gas flow rate. After ANN modeling, genetic algorithm (GA) was used to optimize plant operating conditions. In this regard, plant gross profit was considered as objective function and GA optimization resulted in the profit of \$42.56/h which is 25% higher than actual average profit.

Keywords: Hydrogen, Steam methane reforming, Modeling, Artificial neural network, Optimization, Genetic algorithm