

## مدل سازی فرایند تبدیل خشک متان به کمک پلازما با استفاده از شبکه عصبی مصنوعی و الگوریتم ژنتیک

سید مرتضی فاضلی<sup>۱</sup>، فاطمه راوری<sup>۲</sup>، حمیدرضا بزرگزاده<sup>۳\*</sup> و جعفر صادق زاده اهری<sup>۴</sup>

۱- دانشجوی دکترای شیمی فیزیک، دانشکده شیمی، دانشگاه پیام نور، تهران، ایران

۲- استادیار شیمی فیزیک، دانشکده شیمی، دانشگاه پیام نور، تهران، ایران

۳- دانشیار، شیمی فیزیک، پژوهشگاه صنعت نفت، تهران، ایران

۴- استادیار، مهندسی شیمی، پژوهشگاه صنعت نفت، تهران، ایران

دریافت: بهمن ۱۳۹۵، بازنگری: اسفند ۱۳۹۵، پذیرش: اردیبهشت ۱۳۹۶

**چکیده:** پیش بینی فرآورده های (هیدروژن و کربن مونوکسید) تبدیل خشک متان به کمک پلازما در فشار جوی با استفاده از شبکه عصبی مصنوعی شبیه سازی شد. داده های تجربی مورد نیاز برای مدل سازی شبکه عصبی مصنوعی از یک واکنشگاه پلاسمایی تخلیه کرونا جمع آوری شد. اثر عامل های فرایندی (توان تخلیه پلازما، دبی خوراک ورودی) بر کارایی تبدیل متان و گزینش پذیری نسبت به فرآورده های مورد بررسی قرار گرفتند. شبکه پیش خور با الگوریتم پس انتشار خطا، تابع آموزش انتشار رو به عقب لونیبرگ مارکوارت، تابع فعال سازی سیگموئیدی برای لایه مخفی و تابع فعال سازی خطی برای لایه خروجی، مناسب ترین شبکه عصبی به دست آمده در این پژوهش است. برای مثال، مدل شبکه عصبی مصنوعی تبدیل متان ۲۵/۱۲٪ و گزینش پذیری نسبت به هیدروژن و کربن مونوکسید به ترتیب ۷۱/۱۵٪ و ۷۴/۸۵٪ را در توان تخلیه ۴ وات پیش بینی کرد که مقادیر خطای مدل برای درصد تبدیل متان، گزینش پذیری نسبت به هیدروژن و کربن مونوکسید به ترتیب برابر ۰/۴۷٪، ۱/۲٪ و ۰/۲٪ است. برای رسیدن به شرایط بهینه عملیاتی در فرایند تبدیل از ترکیب الگوریتم ژنتیک و شبکه عصبی مصنوعی استفاده شد. نتیجه ها نشان دادند که شدت جریان خوراک ورودی بهینه ۱۷۵ میلی لیتر بر دقیقه و توان تخلیه بهینه ۶ وات بود. در این شرایط درصد تبدیل متان ۲۵/۸۵٪ و گزینش پذیری نسبت به هیدروژن برابر ۶۵/۱۵٪ به دست آمد. اختلاف کوچک در شرایط عملیاتی بهینه بین مقادیر پیش بینی شده و تجربی، تأیید می کند که مدل شبکه عصبی مصنوعی ترکیب شده با الگوریتم ژنتیک، ابزاری مناسب برای مدل سازی و بهینه سازی فرایند تبدیل خشک متان به کمک پلازماست.

**واژه های کلیدی:** شبکه عصبی مصنوعی، تبدیل خشک متان، پلازما، مدل سازی، بهینه سازی

### مقدمه

گازهای گلخانه ای (آب، کربن دی اکسید) و در نتیجه گرمایش جهانی می شود [۱ و ۲]. یکی از مهم ترین مواد در نفت خام، گاز طبیعی و صنایع شیمیایی هیدروژن است که به عنوان منبع انرژی پاک شناخته می شود و علاقه مندی زیادی برای تبدیل متان

امروزه به تقریب ۸۵٪ انرژی مصرفی از احتراق سوخت های فسیلی (مانند زغال سنگ، نفت خام و گاز طبیعی) به دست می آید. فعالیت های انسانی و استفاده از منابع فسیلی منجر به انتشار

استفاده شده است [۱۵ تا ۱۹]. برای مثال، ایستادی و امین<sup>۱۱</sup> به مطالعه مدل‌سازی فرایند تبدیل متان به کمک پلاسما تخلیه سد دی‌الکتریک بر پایه‌ی شبکه عصبی مصنوعی پرداختند و نتیجه‌های جالب توجهی به دست آوردند [۲۰]. در ضمن، لئو و همکارانش<sup>۱۲</sup> به بررسی تبدیل متان در غیاب اکسیدکننده، در واکنشگاه پلاسما تخلیه سد دی‌الکتریک پرداخته و نتیجه‌ها نشان داد که شبکه عصبی مصنوعی ابزاری کارآمد و قدرتمند در پیش‌بینی فرایند تبدیل متان است [۲۱].

پژوهش‌های تجربی و عددی جهت اصلاح فرایند تبدیل و بهبود بازده فراورده‌های هدف، لازم است. اخیراً دانشمندان سازوکار واکنش تبدیل به کمک پلاسما را به صورت تجربی و عددی بررسی کردند [۲۲ تا ۲۴]. امین و ایستادی ابزارهای گوناگون را جهت بهینه‌سازی ترکیب شبکه عصبی و الگوریتم ژنتیک در مدل‌سازی فرایند تبدیل خشک متان به کمک پلاسما مورد مطالعه قرار دادند و در نهایت بیان کردند که ترکیب شبکه عصبی-الگوریتم ژنتیک ابزاری مفید برای مدل‌سازی و بهینه‌سازی فرایندها در واکنشگاه پلاسما است [۲۵]. در پژوهشی دیگر، امین و همکارانش به بررسی عددی و مدل‌سازی فرایند تبدیل خشک متان در واکنشگاه پلاسما تخلیه سد دی‌الکتریک با استفاده از شبکه عصبی و روش پاسخ سطح<sup>۱۳</sup> پرداختند، نتیجه‌های بررسی‌های آن‌ها نشان داد که خروجی‌های به دست آمده از شبکه عصبی با واقعیت نزدیکی خوبی دارد [۲۶]. ایمان اکبری و همکارانش [۲۷] مدل‌سازی و بهینه‌سازی واحد تولید هیدروژن براساس تبدیل متان با بخار آب را به وسیله‌ی شبکه‌ی عصبی مصنوعی و الگوریتم ژنتیک را انجام دادند. عامل‌های دبی فرآورده و انرژی مصرفی به عنوان عامل‌های خروجی مدل در نظر گرفته شدند. نتیجه‌های مدل‌سازی با دقت بسیار خوب، خطای متوسط مطلق، خطای متوسط نسبی و خطای احتمالی بین داده‌های واقعی و مدل را پیش‌بینی کرد. پس از مدل‌سازی 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

(مهم‌ترین ترکیب گاز طبیعی) به هیدروژن و مواد شیمیایی با ارزش مانند: هیدروکربن‌ها و متانول به عنوان سوخت‌های جایگزین وجود دارد تا آنجا که فناوری‌های زیادی (تبدیل با بخار آب<sup>۱</sup>، اکسایش جزئی<sup>۲</sup> و تبدیل خشک<sup>۳</sup>) برای تبدیل متان مورد بررسی قرار گرفتند [۳ تا ۵].

به تازگی واکنشگاه‌های پلاسما به عنوان یک روش نوین برای فرایند تبدیل متان مورد استفاده قرار گرفتند. از جمله مزایای به کارگیری واکنشگاه پلاسما سرد در تبدیل متان می‌توان به غیرتعادلی بودن، نیاز به انرژی ورودی کم و ظرفیت عملکرد واکنش‌های شیمیایی و فیزیکی گاز در دمای پایین نام برد. همچنین، این روش بر مشکل دماهای زیاد و کاربرد کاتالیست‌های گران قیمت در فرایندهای کاتالیستی غلبه می‌کند [۴ و ۵].

فرایند تبدیل متان با استفاده از انواع متفاوت پلاسما مانند تخلیه کرونا<sup>۴</sup>، تخلیه قوسی لغزان<sup>۵</sup>، تخلیه سد دی‌الکتریک<sup>۶</sup>، جرقه<sup>۷</sup> و تخلیه تابناک<sup>۸</sup> مورد مطالعه قرار گرفته است [۳ و ۶ تا ۹]. مشرفی و همکارانش [۳] فرایند تبدیل خشک متان را به کمک پلاسما تخلیه جرقه با الکتروود چرخان مورد بررسی قرار دادند و شرایط متفاوت عملیاتی (تغییرات نسبت خوراک، توان تخلیه و فاصله الکتروودها) را برای دستیابی به نتیجه‌های بهتر بررسی کردند. یان و همکارانش [۱۰] تبدیل خشک متان به کمک پلاسما را جهت بررسی اثرات طبیعت<sup>۹</sup> تخلیه، بر کارایی واکنشگاه پلاسما و در نتیجه مقدارهای تبدیل واکنش‌دهنده‌ها و گزینش‌پذیری فراورده‌ها، مطالعه کردند. از آنجا که فرایند تبدیل پلاسما متان بسیار پیچیده است، یافتن شرایط بهینه برای عامل‌های واکنش و پیش‌بینی گزینش‌پذیری فراورده‌ها از جهت نظری همواره با مشکل همراه بوده و مدل‌های سینتیکی و ریاضی برای حل و تشریح این مشکل برای رسیدن به شرایط بهینه‌ی پیش‌بینی، پیشنهاد شده‌اند [۱۱ تا ۱۴]. شبکه عصبی مصنوعی<sup>۱۰</sup> یک مدل ریاضی پرکاربرد در زمینه شیمی و مهندسی شیمی است که از آن در انواع متفاوت فرایندهای تبدیل متان به کمک پلاسما

1. Steam methane reforming (SMR)

2. Partial oxidation (PO)

3. Dry methane reforming (DMR)

4. Corona

5. Gliding arc discharge

6. Dielectric barrier discharge (DBD)

7. Spark

8. Glow discharge

9. Nature

10. Artificial neural network (ANN)

11. Istadi and Amin

12. Liu et al

13. Response surface methodology (RSM)

این پژوهش در شکل‌های ۱ و ۲ به ترتیب نشان داده شده‌اند. سامانه خوراک‌دهی واکنشگاهی مورد استفاده شامل چهار شیر کنترل‌کننده جرمی (MFC) از نوع Brooks 5850TR برای گازهای هیدروژن، اکسیژن، آرگون و متان و یک دستگاه ۰۱۵۴ Read-Out شرکت Brooks برای کنترل دقیق جریان گازهای ورودی بود. گاز تنظیم شده از MFCها پس از عبور از شیرهای یک‌طرفه مخلوط شده و پس از عبور از مخلوط‌کننده گازها به سمت واکنشگاه هدایت شد. خوراک ورودی گازهای متان، کربن‌دی‌اکسید با نسبت مولی (CH<sub>4</sub>/CO<sub>2</sub>) برابر با ۰/۵ و شدت جریان‌های متفاوت (۵۰ تا ۲۵۰ میلی‌لیتر در دقیقه) و گاز آرگون با رقت ۶۰٪ مولی را شامل شد. گاز خوراک از طریق خط دیگری به‌طور مستقیم برای تجزیه دقیق به سمت GC و از طریق خط دیگری برای اندازه‌گیری دبی با فلومتر هدایت شد. برای گرفتن آب فراورده‌های تولید شده، خروجی واکنشگاه از دو تله یخ عبور داده و به‌طور مستقیم برای تجزیه به سمت GC هدایت شد [۲۸].

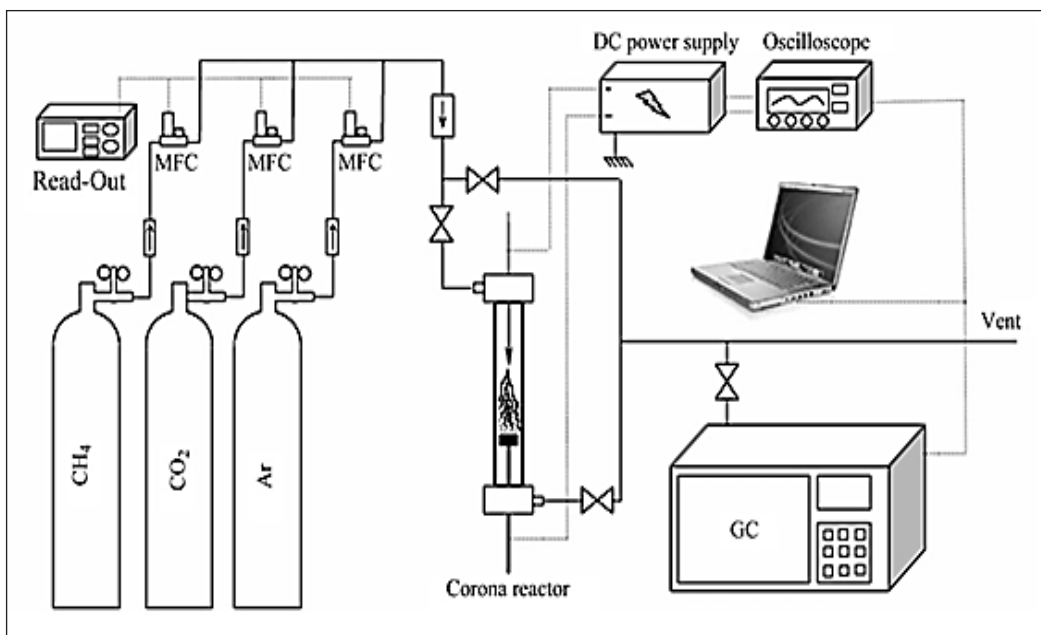
هدف مدنظر قرار گرفت و عامل‌های عملیاتی به‌منظور دست‌یابی به حداکثر سود با استفاده از الگوریتم ژنتیک بهینه شد. نتیجه‌های الگوریتم ژنتیک سود به‌دست آمده از فرایند را بیشتر از میانگین سود واحد در شرایط واقعی پیش‌بینی کرد. با توجه به پژوهش‌های انجام‌گرفته، هنوز تعداد مطالعات در زمینه بهینه‌سازی تبدیل خشک متان به کمک پلازما بسیار اندک به‌نظر می‌رسد.

در این پژوهش، یک مدل بر اساس شبکه عصبی مصنوعی برای مطالعه اثر عامل‌های فرایندی (توان تخلیه پلازما، دبی خوراک ورودی) بر کارایی واکنش، تبدیل متان و گزینش‌پذیری فراورده‌ها ارایه و درضمن یک نقطه بهینه برای این فرایند تعیین شده و نتیجه‌های به‌دست آمده تجربی با نتیجه‌های شبکه عصبی مصنوعی مقایسه می‌شود.

### بخش تجربی

#### آزمون‌های واکنشگاهی


طرح‌واره مراحل تجربی و شکل واکنشگاه مورد استفاده در



شکل ۱ طرح‌واره سامانه واکنشگاه پلاسمایی [۲۸]

1. Mass flow controller

سایر فرآورده‌ها استفاده می‌شد. دستگاه GC برای تجزیه گازهای متان، اتان، اتیلن، استیلن، پروپان، پروپیلن، کربن دی‌اکسید، کربن مونوکسید، هیدروژن، اکسیژن و نیتروژن به‌طور دقیق درجه‌بندی شده بود. برای درجه‌بندی GC از مخلوط دوتایی گازهای موردنظر با گاز حامل آرگون و درصدهای متفاوت استفاده شد. از آنجایی که گاز حامل دستگاه GC گاز آرگون بود، تنها پیک خروجی محصول موردنظر دیده می‌شود. سطح زیر پیک به همراه زمان اقامت آن به‌عنوان نقطه درجه‌بندی برای درصدی مشخص در نظر گرفته شد [۲۸].



شکل ۲ طرح‌واره واکنشگاه پلاسمایی کرونا [۲۸]

معادله واکنش تبدیل خشک متان به‌صورت معادله ۱ است، در ضمن درصد تبدیل متان و کربن دی‌اکسید، همچنین، گزینش‌پذیری نسبت به هیدروژن و کربن مونوکسید به ترتیب با استفاده از معادله‌های ۲ تا ۴ محاسبه شدند:



$$X_{\text{CH}_4} = \frac{\text{تعدادمول‌های CH}_4 \text{ تبدیل شده}}{\text{تعدادمول‌های CH}_4 \text{ ورودی}} \times 100 \quad (۲)$$

$$S_{\text{H}_2} (\%) = \frac{\text{تعدادمول‌های H}_2 \text{ تولید شده}}{2 \times \text{تعدادمول‌های CH}_4 \text{ مصرف شده}} \times 100 \quad (۳)$$

$$S_{\text{CO}} (\%) = \frac{\text{تعدادمول‌های CO تولید شده}}{\text{تعدادمول‌های CH}_4 \text{ مصرف شده} + \text{تعدادمول‌های CO}_2 \text{ مصرف شده}} \times 100 \quad (۴)$$

شبکه عصبی مصنوعی

شبکه عصبی مصنوعی الگویی برگرفته از شبکه عصبی انسان است که برای پردازش اطلاعات به‌وجود آمده است و مهم‌ترین ویژگی آن قدرت یادگیری است. امروزه از شبکه عصبی در

در شکل ۲ نمای کلی واکنشگاه و محل قرار گرفتن الکترودها نشان داده شده است. تخلیه پایدار الکتریکی DC از الکترودها، منجر به تشکیل محیط پلاسما و گازهای یونیزه شده در فضای بین دو الکترود تنگستن می‌شد. الکترود بالایی به ضخامت ۲ میلی‌متر در مرکز یک لوله کوارتز با قطر داخلی ۷ میلی‌متر قرار داده شد. الکترود مسطح تنگستن با قطر ۶٫۵ میلی‌متر، حدود ۱۳ میلی‌متر پایین‌تر از نوک الکترود بالایی قرار داشت. این دو الکترود به‌صورت میله و صفحه در داخل لوله کوارتز قرار داشتند. الکترود صفحه‌ای پایینی در تمام آزمایش‌ها در پتانسیل صفر (زمین) و الکترود میله‌ای در پتانسیل‌های متفاوت قرار داشت. الکترود میله‌ای عمود بر الکترود صفحه‌ای در مرکز بود. بدنه اصلی واکنشگاه از جنس کوارتز با ضخامت ۰٫۵ میلی‌متر بود. ولتاژ ۱۲ کیلوولتی و جریانی حدود ۵ میلی‌آمپر به‌وسیله‌ی تأمین‌کننده ولتاژ، تأمین می‌شد [۲۷].

از یک دستگاه کروماتوگرافی گازی Agilent 6890N مجهز به دو آشکارساز شعله‌ای (FID) و گرمایی (TCD) برای تجزیه دقیق فرآورده‌ها استفاده می‌شد. این دستگاه GC مجهز به ۵ ستون برای جداسازی اجزاء گازی بود. یک ستون ۵۰ متری موبینه برای جداسازی هیدروکربن‌های C<sub>۱</sub>-C<sub>۹</sub>، سه ستون ۰٫۹۱ و ۲٫۴۴ و ۱٫۲۲ متری Haysep Q, HaysepN و یک ستون ۳٫۰۵ متری غربال مولکولی 13X46/60 برای تجزیه و جداسازی

مدل مورد نیاز است. مدل ارائه شده بر اساس شبکه عصبی مصنوعی به داده‌های آزمایشی بدون نویز<sup>۶</sup> و با توزیع مناسب از نظر آماری نیاز دارد. از روش طراحی ترکیب مرکزی<sup>۷</sup> برای طراحی آزمایش‌ها استفاده شد. این روش محدوده‌ای گسترده از متغیرها را شامل شده و برهم‌کنش متغیرهای ورودی را به‌خوبی بررسی می‌کند [۳۰]. گستره و مقادیر متغیرهای به‌دست آمده از روش طراحی ترکیب مرکزی در جدول‌های ۱ و ۲ نشان داده شده‌اند. مدل‌های شبکه عصبی متفاوت با توجه به مقادیر مشخص شده در جدول ۳ توسعه یافتند. در ضمن، جدول ۳ داده‌های تجربی به‌دست آمده از واکنشگاه پلاسمای کرونا را نشان می‌دهد که برای اعتبارسنجی و آموزش مدل شبکه عصبی مصنوعی استفاده شده است.

جدول ۱ طراحی ترکیب مرکزی آزمایش‌ها

گستره و مقادیر			متغیرها
+۱	صفر	-۱	
۲۵۰	۱۵۰	۵۰	دبی خوراک ورودی (میلی‌لیتر در دقیقه)
۱۰	۷	۴	توان تخلیه پلاσμα (وات)

توجه: "۱" - "کمینه مقدار، "۱" + "بیشینه مقدار و "صفر" نقطه مرکزی است. در ضمن آرگون ۶۰٪ مولی و نسبت  $\text{CH}_4/\text{CO}_2$  برابر ۰٫۵ است.

داده‌های نرمال شده به‌طور تصادفی در سه زیرمجموعه‌ی آموزش شبکه ۶۰٪ داده‌ها، برای اعتبار سنجی و آزمون شبکه هرکدام ۲۰٪ داده‌ها تقسیم و به‌کار گرفته شدند. تعداد کل آزمایش‌ها ۲۵ عدد بوده است. تعداد مطلوب و بهینه‌ی نرون‌ها با آزمون‌وخطا تعیین شده است. شبکه‌های عصبی نهایی و آزمایش‌های طراحی شده بر اساس کمترین میزان میانگین مربع خطا (MSE)<sup>۸</sup>، بیشترین مقدار ضریب همبستگی  $R^2$  آموزش و آزمون داده‌ها انتخاب شدند [۱۵]. این عامل‌ها به‌صورت زیر تعریف می‌شوند:

$$\text{MSE} = \frac{1}{n} \sum_i^n (X_{\text{obs}} - X_{\text{cal}})^2 \quad (5)$$

مدل‌سازی مجموعه‌های پیچیده استفاده می‌شود [۱۵ تا ۲۲]. شبکه عصبی شامل لایه‌های ورودی، لایه‌های پنهان و لایه خروجی است که از نرون‌ها تشکیل می‌شوند. هر نرون با استفاده از توابع فعال‌سازی (تانژانت سیگموئیدی<sup>۱</sup>، لگاریتم سیگموئیدی<sup>۲</sup> و خطی<sup>۳</sup>) خروجی را محاسبه و به لایه بعد منتقل می‌کند. داده‌ها برای مدل‌سازی به سه گروه آموزش، اعتبارسنجی و آزمون تقسیم می‌شوند [۲۹].

در این پژوهش از جعبه‌ابزار شبکه‌های عصبی، نرم‌افزار متلب<sup>۴</sup> نسخه (a ۲۰۱۰ R: ۷) استفاده شد و یک شبکه عصبی پرسپترون چندلایه با الگوریتم آموزش پس انتشار خطا (لونبرگ مارکوآرت<sup>۵</sup>) تشکیل شد. برای یافتن مناسب‌ترین ترکیب ساختمانی برای شبکه پرسپترون چندلایه، ساختارهای متفاوتی همراه با توابع انتقال متفاوت مورد بررسی قرار گرفت و در نهایت مشخص شد که شبکه سه لایه‌ای (یعنی تنها یک لایه پنهان) مناسب‌ترین ساختمان برای این کاربرد است. از میان توابع انتقال نیز تابع انتقال سیگموئیدی برای لایه پنهان و تابع انتقال خطی برای لایه خروجی استفاده شدند. در ورودی شبکه عصبی ۲ متغیر مستقل (دبی خوراک ورودی و توان تخلیه پلاσμα) و در خروجی یک متغیر وابسته (تبدیل متان، یا گزینش‌پذیری هیدروژن یا کربن مونوکسید) وجود دارد.

استفاده از داده‌ها به‌صورت خام، باعث کاهش سرعت و دقت شبکه عصبی می‌شود. برای جلوگیری از چنین حالتی و یکسان کردن ارزش داده‌ها برای شبکه، عمل نرمال‌سازی داده‌ها صورت می‌گیرد. عمل نرمال‌سازی مانع از کوچک شدن بیش‌ازحد وزن‌ها و سیرشدن زود هنگام نرون‌ها می‌شود. به‌منظور دستیابی به یک همگرایی سریع، مقادیر ورودی و هدف می‌بایست در گستره مشخص قرار بگیرند. بنابراین، داده‌های تجربی پیش از آموزش در بازه‌ی ۱- تا ۱ نرمال شدند.

#### طراحی آزمایش

در مدل‌سازی تعدادی از داده‌های تجربی برای اعتبارسنجی

- |                             |           |                      |           |                            |               |
|-----------------------------|-----------|----------------------|-----------|----------------------------|---------------|
| 1. Tansig                   | 2. Logsig | 3. Purelin           | 4. MATLAB | 5. Levenberg marquardt     | 6. Noise-free |
| 7. Central composite design |           | 8. Mean square error |           | 9. Correlation coefficient |               |

جدول ۲ ماتریس طراحی آزمایش‌های فرایند تبدیل خشک

شماره آزمایش	متغیرهای فرایند به صورت کد		متغیرهای فرایند به صورت واقعی	
	توان تخلیه پلاسما (وات)	دبی خوراک ورودی (میلی لیتر در دقیقه)	توان تخلیه پلاسما (وات)	دبی خوراک ورودی (میلی لیتر در دقیقه)
۱	-۱	-۱	۴	۵۰
۲	صفر	-۱	۷	۵۰
۳	+۱	-۱	۱۰	۵۰
۴	+۱	-۱	۱۰	۵۰
۵	-۱	صفر	۴	۱۵۰
۶	-۱	صفر	۴	۱۵۰
۷	-۱	صفر	۴	۱۵۰
۸	صفر	صفر	۷	۱۵۰
۹	صفر	صفر	۷	۱۵۰
۱۰	صفر	صفر	۷	۱۵۰
۱۱	صفر	صفر	۷	۱۵۰
۱۲	صفر	صفر	۷	۱۵۰
۱۳	صفر	صفر	۷	۱۵۰
۱۴	-۱	+۱	۴	۲۵۰
۱۵	-۱	+۱	۴	۲۵۰
۱۶	-۱	+۱	۴	۲۵۰
۱۷	-۱	+۱	۴	۲۵۰
۱۸	-۱	+۱	۴	۲۵۰
۱۹	-۱	+۱	۴	۲۵۰
۲۰	صفر	+۱	۷	۲۵۰
۲۱	صفر	+۱	۷	۲۵۰
۲۲	صفر	+۱	۷	۲۵۰
۲۳	صفر	+۱	۷	۲۵۰
۲۴	صفر	+۱	۷	۲۵۰
۲۵	+۱	+۱	۱۰	۲۵۰
۲۶	+۱	+۱	۱۰	۲۵۰
۲۷	+۱	+۱	۱۰	۲۵۰

توجه: "۱-" کمینه مقدار، "۱+" بیشینه مقدار و "صفر" نقطه مرکزی است. درضمن آرگون ۶۰٪ مولی و نسبت CH<sub>4</sub>CO<sub>2</sub> برابر ۰٫۵ است.

جدول ۳ مقادیر آزمایشی برای مدل‌سازی شبکه عصبی

شماره آزمایش	نسبت به CO (%)	نسبت به H <sub>2</sub> (%)	تبدیل متان (%)	توان تخلیه پلاسما (وات)	دبی خوراک ورودی (میلی لیتر در دقیقه)
۱	۷۳٫۰	۶۱٫۰	۳۳٫۰	۴	۵۰
۲	۷۶٫۰	۶۳٫۰	۵۷٫۰	۷	۵۰
۳	۷۹٫۰	۶۶٫۰	۷۲٫۰	۱۰	۵۰
۴	۷۸٫۰	۶۵٫۵	۷۱٫۰	۱۰	۵۰
۵	۷۰٫۰	۶۴٫۵	۲۵٫۵	۴	۱۵۰
۶	۷۲٫۰	۶۳٫۰	۲۶٫۵	۴	۱۵۰
۷	۷۱٫۵	۶۴٫۰	۲۷٫۰	۴	۱۵۰
۸	۷۸٫۵	۶۴٫۲	۴۵٫۰	۷	۱۵۰
۹	۷۱٫۵	۶۴٫۶	۴۴٫۵	۷	۱۵۰
۱۰	۷۲٫۰	۶۴٫۷	۴۵٫۵	۷	۱۵۰
۱۱	۷۰٫۰	۶۲٫۷	۴۶٫۵	۷	۱۵۰
۱۲	۷۲٫۵	۶۴٫۸	۴۲٫۵	۷	۱۵۰
۱۳	۷۳٫۰	۶۵٫۰	۶۱٫۰	۱۰	۱۵۰
۱۴	۶۸٫۸	۶۵٫۲	۱۸٫۰	۴	۲۵۰
۱۵	۶۷٫۷	۶۶٫۰	۱۷٫۵	۴	۲۵۰
۱۶	۶۸٫۰	۶۶٫۵	۱۷٫۰	۴	۲۵۰
۱۷	۶۸٫۵	۶۶٫۰	۱۶٫۵	۴	۲۵۰
۱۸	۷۰٫۰	۶۵٫۵	۳۵٫۰	۷	۲۵۰
۱۹	۷۱٫۶	۶۵٫۸	۳۷٫۰	۷	۲۵۰
۲۰	۶۹٫۵	۶۶٫۷	۳۵٫۵	۷	۲۵۰
۲۱	۷۰٫۰	۶۷٫۰	۳۲٫۷	۷	۲۵۰
۲۲	۷۱٫۷	۶۷٫۵	۳۴٫۰	۷	۲۵۰
۲۳	۷۲٫۴	۶۶٫۰	۵۰٫۰	۱۰	۲۵۰
۲۴	۷۲٫۰	۶۷٫۰	۴۷٫۰	۱۰	۲۵۰
۲۵	۷۱٫۰	۶۷٫۸	۴۸٫۰	۱۰	۲۵۰

توجه: آرگون ۶۰٪ مولی و نسبت CH<sub>4</sub>CO<sub>2</sub> برابر ۰٫۵ است.

درضمن، از عامل درصد میانگین مطلق خطای نسبی (AARE) نیز برای تعیین و ارزیابی کارایی روش طراحی آزمایش‌ها (طراحی ترکیب مرکزی) استفاده شد که به صورت ذیل تعریف می‌شود:

$$AARE \% = \frac{1}{n} \sum \left| \frac{X_{obs} - X_{cal}}{X_{obs}} \right| \times 100 \quad (7)$$

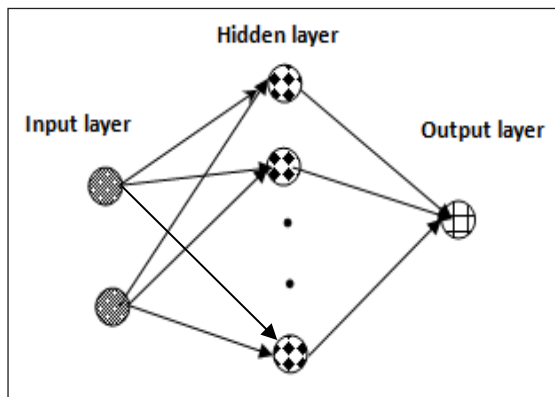
1. Average absolute relative error

$$R^2 = \frac{\sum_{i=1}^n (X_{obs} - X_{cal})^2}{\sum_{i=1}^n (X_{obs} - \bar{X}_{cal})^2} \quad (6)$$

### نتیجه‌ها و بحث

مدل‌سازی شبکه عصبی مصنوعی

شکل ۳ ساختار شماتیک شبکه عصبی چندلایه را که در محیط نرم‌افزار متلب تشکیل شده را نشان می‌دهد. جدول ۴ تمام اطلاعات در مورد شبکه‌های عصبی تشکیل شده و مقایسه خروجی طراحی آزمایش‌ها را نشان می‌دهد.



شکل ۳ ساختار شماتیک شبکه عصبی چندلایه با تابع انتقال سیگموئیدی برای لایه پنهان و تابع انتقال خطی برای لایه خروجی

در شکل ۴، مقدارهای پیش‌بینی مدل برحسب مقدارهای واقعی برای تمام شبکه‌ها نشان داده شده‌اند. توافق خوبی بین نتیجه‌های تجربی و خروجی مدل‌های ارائه شده دیده می‌شود.

که در معادله‌های بالا  $n$  تعداد داده‌های آزمایشگاهی،  $\bar{X}$  میانگین  $X$  برای تمام نمونه‌ها است. عبارت‌های  $X_{obs}$  و  $X_{cal}$  مقادیر واقعی و پیش‌بینی شده را به ترتیب نشان می‌دهند.

### الگوریتم ژنتیک

الگوریتم ژنتیک (GA)<sup>۱</sup> براساس تئوری داروین تکامل یافته است [۳۱]. الگوریتم ژنتیک با یک مجموعه از جمعیت شروع شده و سپس با به‌کارگیری عملگرهای ژنتیک مانند: انتخاب، جهش<sup>۲</sup> و افزونی<sup>۳</sup> پی‌درپی تکرار می‌شود و تا رسیدن به حل نهایی ارتقا و تکامل می‌یابد. به‌دلیل توانایی‌های این الگوریتم، از آن در زمینه‌های کاری متفاوت استفاده می‌شود [۳۲ تا ۳۴]. از جعبه‌ابزار بهینه‌سازی الگوریتم ژنتیک نرم‌افزار متلب نسخه (a ۲۰۱۰ R: ۷) برای این کار بهره گرفته شد. مجموعه بهینه‌ساز پارتو<sup>۴</sup> برای بیشینه‌سازی هم‌زمان تبدیل متان و گزینش‌پذیری فرآورده‌ها (هیدروژن) در فرایند تبدیل خشک متان پلاسمایی به‌کار می‌رود که در آن تبدیل متان و گزینش‌پذیری نسبت به هیدروژن تابعی از دبی خوراک ورودی و توان ورودی پلاسما برای یافتن شرایط بهینه عملیاتی می‌باشند. روابط ۸ و ۹ مسئله بهینه‌سازی را تعریف می‌کنند:

$$f(x_1, x_2) = \max(X_{CH_4} \%) \quad (8)$$

$$h(x_1, x_2) = \max(SH_2 \%) \quad (9)$$

که در معادله‌های بالا  $x_1$  دبی خوراک ورودی و  $x_2$  توان ورودی پلاسما را نشان می‌دهند.

جدول ۴ نتیجه‌های محاسبات و جزئیات مدل‌های شبکه عصبی و طراحی آزمایش‌های استفاده شده برای پیش‌بینی شبکه‌های  $SH_2$ ،  $XCH_4$  و SCO

شبکه	تعداد گره‌ها	R <sup>2</sup>		MSE		AARE%	
		آموزش	آزمون	آموزش	آزمون	آموزش	آزمون
XCH <sub>4</sub> %	(۱-۴-۲)	۰.۹۹۷۴۸	۰.۹۹۳۲۵	۰.۹۸۷	۲.۲۸۷	۳.۶۵	۲.۸۶
SCO%	(۱-۶-۲)	۰.۹۹۹۸۶	۰.۹۹۵۱۲	۰.۰۲۴۲	۰.۱۲۱	۰.۸۷	۱.۹۵
SH <sub>2</sub> %	(۱-۸-۲)	۰.۹۹۱۶۵	۰.۹۸۹۲۸	۰.۲۱۷۳	۲.۱۷۲۵	۴.۸۵	۵.۷۵

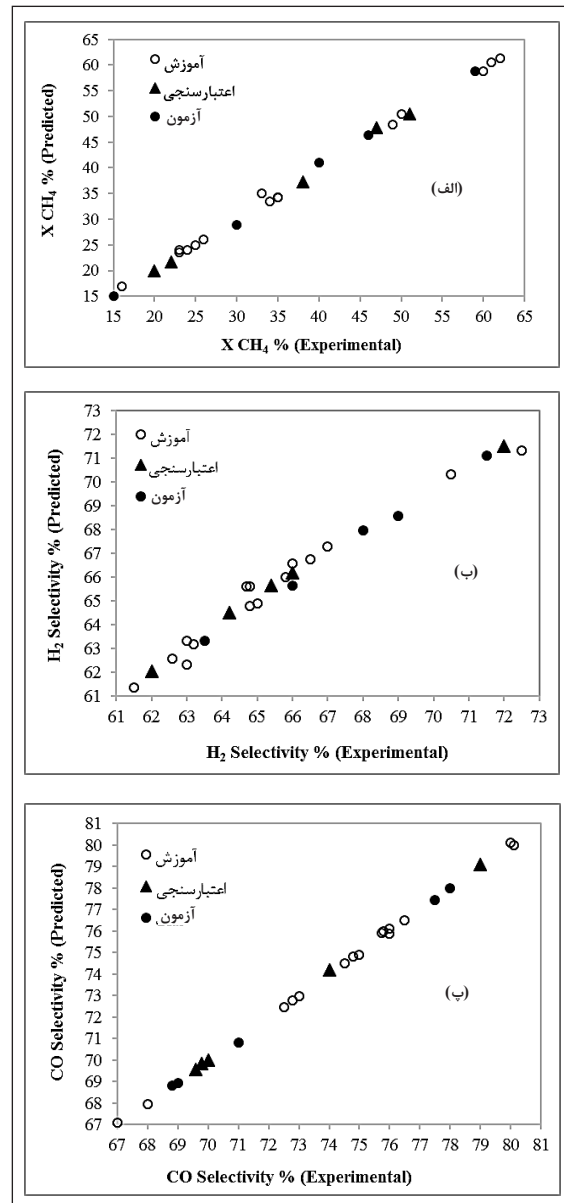
توجه: تعداد نهایی اوزان و بایاس‌های تعدیل شده در دوره آموزشی ۱۷، ۳۱ و ۳۳ برای شبکه‌های  $XCH_4$ ،  $SH_2$ ، SCO است.

1. Genetic algorithm      2. Mutation      3. Crossover      4. Pareto optimal set



نسبت به هیدروژن در فرایند تبدیل پلاسما است. مقدار تبدیل متان به طور خطی با افزایش توان تخلیه بیشتر شده و بیشینه مقدارش به ۶۲٪ در توان تخلیه ۱۰ وات می‌رسد که مدل ANN نیز آن را پیش‌بینی کرده است. گزینش‌پذیری نسبت به هیدروژن با افزایش توان ورودی واکنشگاه کاهش می‌یابد. دلیل این مهم را می‌توان به از بین رفتن مولکول‌های هیدروژن و تبدیل آن به رادیکال‌های آزاد هیدروژن و برهم‌کنش این رادیکال‌ها با اکسیژن اتمی آزاد شده از برهم‌کنش ( $\text{CO}_2 + e \rightarrow \text{CO} + \text{O} + e$ ) و تولید آب نسبت داد. گزینش‌پذیری نسبت به کربن منوکسید از ۷۵٪ به حدود ۸۰٪ افزایش یافته است، زیرا با افزایش توان ورودی کربن، هیدروکربن‌های  $\text{C}_2$  دوباره شکسته شده و امکان تولید کربن منوکسید افزایش می‌یابد. در ضمن مدل بهینه‌شده می‌تواند کارایی واکنش را در سرعت توان پلاسما متفاوت پیش‌بینی کند.


تأثیر دبی خوراک ورودی در واکنش تبدیل خشک متان به کمک پلاسما شکل ۶ نتیجه‌های تجربی و پیش‌بینی شده را برای تبدیل متان در دبی خوراک ورودی متفاوت نشان می‌دهد. نتیجه‌ها نشان می‌دهد که هماهنگی خوبی بین داده‌های تجربی و پیش‌بینی شده وجود دارد. با افزایش دبی خوراک ورودی از ۵۰ به ۲۵۰ میلی‌لیتر در دقیقه، تبدیل متان به دلیل کاهش زمان ماندگاری متان در حجم تخلیه پلاسما و در نتیجه کاهش برخورد متان با الکترون‌های پرانرژی و گونه‌های فعال، کاهش یافته است، در ضمن اجازه نمی‌دهد پیوند H-H دوباره شکسته شود و رادیکال هیدروژن به فرآورده دیگری چون آب تبدیل شود. نتیجه‌های مشابه در دیگر مطالعات هم گزارش شده است [۳۵]. از طرفی گزینش‌پذیری نسبت به هیدروژن با افزایش دبی خوراک ورودی از ۵۰ به ۲۵۰ میلی‌لیتر در دقیقه، از ۶۱٪ به ۶۶٪ افزایش یافت. دلیل این نتیجه آن است که با افزایش دبی خوراک ورودی، هیدروژن به سرعت از واکنشگاه خارج می‌شود. گزینش‌پذیری نسبت به مونوکسید کربن به دلیل کاهش زمان ماندگاری خوراک در واکنشگاه از ۷۳٪ به ۶۹٪ کاهش یافت. در ضمن مدل بهینه‌شده می‌تواند کارایی واکنش را در دبی خوراک متفاوت پیش‌بینی کند. نتیجه‌ها نشان می‌دهند که دبی خوراک ورودی کم، برای تبدیل بیشتر متان و گزینش‌پذیری کمتر نسبت به مونوکسید کربن بسیار مناسب بوده ولی



شکل ۴ مقایسه مقادیر واقعی با نتیجه‌های پیش‌بینی شده مدل (الف)  $\text{XCH}_4$ ، (ب)  $\text{SH}_2$  و (پ)  $\text{SCO}$ .

تأثیر توان پلاسما در واکنش تبدیل خشک متان به کمک پلاسما همبستگی بسیار خوبی بین نتیجه‌های شبیه‌سازی و تجربی در توان‌های تخلیه متفاوت (۱۰-۴ وات) به دست آمد که در شکل ۵ نشان داده شده است. توان تخلیه عامل مهمی در مقدار تبدیل متان و گزینش‌پذیری



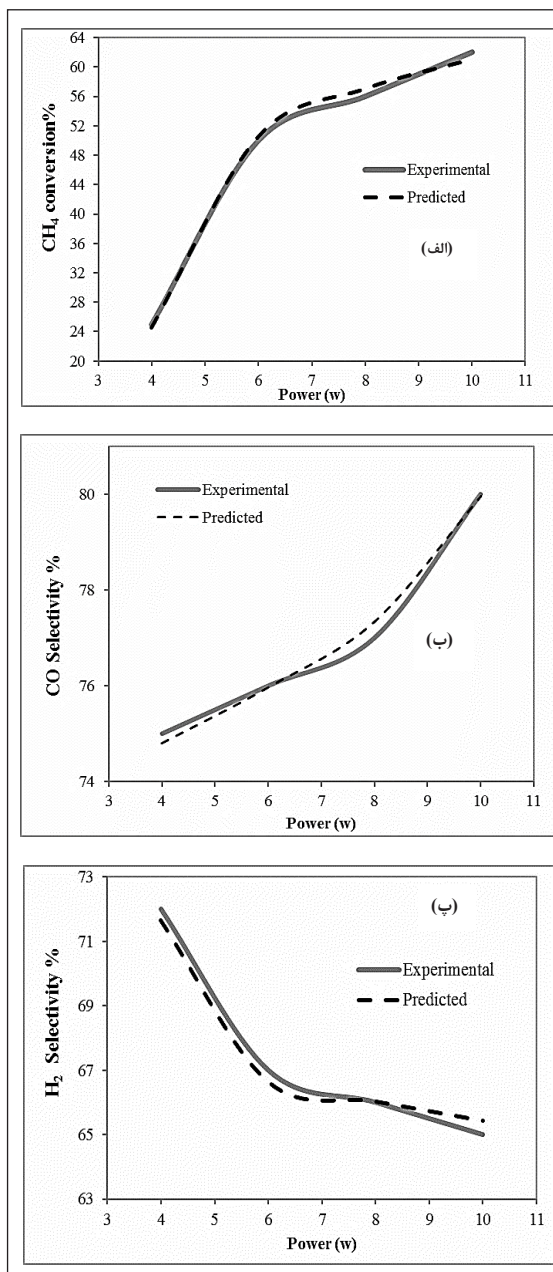


شکل ۶ اثر دبی خوراک ورودی بر الف)  $XCH_4$ ، ب)  $SCO$  و پ)  $SH_2$  (توان تخلیه برابر با ۶ W آرگون ۶۰٪ مولی و نسبت  $CH_4/CO_2$  برابر ۰٫۵ است).

### نتیجه‌های بهینه‌سازی

میزان تبدیل متان و گزینش‌پذیری نسبت به هیدروژن در شرایط عملیاتی (تغییرات دبی خوراک ورودی و تغییرات توان تخلیه پلاسما) بهینه‌سازی شد. نتیجه‌های بهینه‌سازی که در

برای گزینش‌پذیری هیدروژن زیاد خوب نیست. در ضمن خروجی‌ها بیانگر آن بود که مدت‌زمان اقامت (حجم واکنشگاه ۰٫۵ سانتی‌متر مکعب) تقسیم به دبی خوراک ورودی در مناسب‌ترین حالت (۱۷۵ میلی‌لیتر بر دقیقه)، حدود ۰٫۲ ثانیه بوده است [۲۸].



شکل ۵ اثر توان تخلیه بر الف)  $XCH_4$ ، ب)  $SCO$  و پ)  $SH_2$  (دبی خوراک ورودی برابر با ۱۷۵ میلی‌لیتر بر دقیقه، آرگون ۶۰٪ مولی و نسبت  $CH_4/CO_2$  برابر ۰٫۵ است)


جدول ۵ مقایسه مقادیر بهینه‌سازی شده و نتیجه‌های تجربی

درصد خطای	نتیجه‌ها		
	پیش‌بینی شده	تجربی	
نسبی			
۱٫۳۷	۲۵٫۸۵	۲۵٫۵	درصد تبدیل متان
۱٫۰۱	۶۵٫۱۵	۶۴٫۵	درصد‌گزینش‌پذیری نسبت به هیدروژن

توجه: در شرایط عملیاتی بهینه، دبی خوراک ورودی ۱۷۵ میلی‌لیتر در دقیقه و توان تخلیه پلاسما ۶ وات بود.

مدل‌سازی شبکه عصبی مصنوعی از یک واکنشگاه پلاسمایی تخلیه کرونا جمع‌آوری شد. اثر عامل‌های فرایندی (توان تخلیه پلاسما، دبی خوراک ورودی) بر کارایی واکنش، برای مثال، تبدیل متان و گزینش‌پذیری فراورده‌های مورد بررسی قرار گرفتند. شبکه پیش‌خور با الگوریتم پس‌انتشار خطا، تابع آموزش انتشار رو به عقب لوبرگ مارکوات، تابع فعال‌سازی سیگموئیدی برای لایه مخفی و تابع فعال‌سازی خطی برای لایه خروجی، مناسب‌ترین شبکه عصبی به‌دست‌آمده در این پژوهش است. تعداد نرون‌های استفاده شده در لایه میانی شبکه بهینه تشکیل شده برای تبدیل متان، گزینش‌پذیری کربن مونوکسید و گزینش‌پذیری هیدروژن به ترتیب ۴، ۶ و ۸ نرون است. برای مثال، مدل شبکه عصبی مصنوعی تبدیل متان ۲۵٫۱۲٪ و گزینش‌پذیری نسبت به هیدروژن و مونوکسیدکربن به ترتیب ۷۱٫۱۵٪ و ۷۴٫۸۵٪ را در توان تخلیه ۴ وات پیش‌بینی کرد که مقادیر خطای مدل برای درصد تبدیل متان، گزینش‌پذیری نسبت به هیدروژن و مونوکسیدکربن به ترتیب برابر ۰٫۴۷٪، ۱٫۲٪ و ۰٫۲٪ است. برای رسیدن به شرایط بهینه عملیاتی در فرایند تبدیل از ترکیب الگوریتم ژنتیک و شبکه عصبی مصنوعی استفاده شد. نتیجه‌ها نشان دادند که دبی خوراک ورودی بهینه ۱۷۵ میلی‌لیتر در دقیقه و توان تخلیه پلاسمای بهینه ۶ وات است. در این شرایط درصد تبدیل متان ۲۵٫۸۵٪ و گزینش‌پذیری هیدروژن برابر ۶۵٫۱۵٪ به‌دست آمد. تفاوت کوچک در شرایط عملیاتی بهینه بین مقادیر پیش‌بینی شده و تجربی (به ترتیب ۱٫۳۷٪ و ۱٫۰۱٪ برای درصد تبدیل متان و گزینش‌پذیری

شکل ۷ نشان داده شده، بیانگر آن است که اگر تبدیل متان افزایش یابد، گزینش‌پذیری نسبت به هیدروژن کاهش خواهد یافت که با نتیجه‌های به‌دست آمده توسط الیاسون<sup>۱</sup> و همکارانش هماهنگی دارد [۳۶]. چند آزمایش اضافی برای اعتبارسنجی نتیجه‌های بهینه‌سازی انجام شد و مقادیر بهینه‌شده با نتیجه‌های تجربی مقایسه شدند که نتیجه‌های آن در جدول ۵ آورده شده‌اند. نتیجه‌ها نشان دادند که دبی خوراک ورودی بهینه ۱۷۵ میلی‌لیتر بر دقیقه و توان تخلیه بهینه ۶ وات است. در این شرایط درصد تبدیل متان ۲۶٫۸۵٪ و گزینش‌پذیری نسبت به هیدروژن برابر ۶۸٫۳۵٪ به‌دست آمد. در ضمن مقایسه خروجی‌ها نشان داد که بین مقادیر پیش‌بینی شده و تجربی اختلاف اندکی وجود دارد. این تفاوت کوچک در شرایط عملیاتی بهینه تأیید می‌کند که مدل شبکه عصبی مصنوعی ترکیب شده با الگوریتم ژنتیک، ابزاری مناسب برای مدل‌سازی و بهینه‌سازی فرایند تبدیل خشک متان به کمک پلاسما است.



شکل ۷ پیشینه‌سازی هم‌زمان درصد تبدیل متان و گزینش‌پذیری نسبت به هیدروژن در فرایند تبدیل خشک متان پلاسمایی در شرایط عملیاتی بهینه (دبی خوراک ورودی ۱۷۵ میلی‌لیتر در دقیقه و توان تخلیه پلاسما ۶ وات)

## نتیجه‌گیری

پیش‌بینی فراورده‌های تبدیل خشک متان (هیدروژن و مونوکسیدکربن) به کمک پلاسما در فشار جوی با استفاده از شبکه عصبی مصنوعی شبیه‌سازی شد. داده‌های تجربی موردنیاز برای

1. Eliasson

درضمن، این پژوهش نتیجه‌های قابل‌قبولی از طرح ترکیب مرکزی و الگوریتم ژنتیک برای تنظیم عامل‌های شبکه عصبی مصنوعی برای بهبود عملکرد آن ارائه کرده است.

نسبت به هیدروژن)، تأیید می‌کند که مدل شبکه عصبی مصنوعی ترکیب شده با الگوریتم ژنتیک، ابزاری مناسب برای مدل‌سازی و بهینه‌سازی فرایند تبدیل خشک متان به کمک پلاسما است.

## مراجع

- [1] Samimi, A.; Zarinabadi, S.; Australian J Basic and Applied Sci, 5(12), 752-756, 2011
- [2] Abbas, H.F.; Wan Daud W.M.A.; Int J of Hydrogen Energy, 35, 1160-1190, 2010.
- [3] Moshrefi, M.M.; Rashidi, F.; Bozorgzadeh, H.R.; Haghighi, M.E.; Plasma Chem Plasma P, 33, 453-466, 2013.
- [4] Ha, K.S.; Bae, J.W.; Woo, K.J.; Jun, K.W.; Environ Sci Technol, 44, 1412-1417, 2010.
- [5] Tao, X.M.; Bai, M.J.; Li, X.; Long, H.L.; Shang, S.Y.; Yin, Y.X.; Dai, X.Y.; Prog Energy Combust Sci, 37, 113-124, 2011.
- [6] Aleknaviciute, I.; Karayiannis, T.G.; Collins, M.W.; Xanthos, C.; Energy, 59, 432-439, 2013.
- [7] Wang, Q.; Spasova, B.; Hessel, V.; Kolb, G.; Chemical Engineering Journal, 262, 766-774, 2015.
- [8] Ozkan, A.; Dufour, T.; Arnoult, G.; De Keyzer, P.; Bogaerts, A.; Reniers, F.; Journal of CO2 Utilization, 9, 74-81, 2015.
- [9] وافری، بهزاد؛ کرمی، حمیدرضا؛ کریمی، غلامرضا؛ نشریه شیمی و مهندسی شیمی ایران، ۳۰(۳)، ۳۷-۲۵، ۱۳۹۰.
- [10] Yan, B.; Wang, Q.; Jin, Y.; Cheng, Y.; Plasma Chem Plasma Process, 30(2):257-266, 2010.
- [11] Aerts, R.; Tu, X.; Van Gaens, W.; Whitehead, J.C.; Bogaerts, A.; Environ Sci Technol, 47, 6478-6485, 2013.
- [12] De Bie, C.; Verheyde, B.; Marten, T.; van Dijk, J.; Paulussen, S.; Bogaerts, A.; Plasma Processes Polym, 8, 1033-1058, 2011.
- [13] De Bie, C.; Marten, T.; van Dijk, J.; Paulussen, S.; Verheyde, B.; Corthals, S.; Bogaerts, A.; Plasma Source Sci Technol, 20, 024008, 2011.
- [14] Snoecks, R.; Aerts, R.; Tu, X.; Bogaerts, A.; J. Phys. Chem. C, 117, 4957-4970, 2013.
- [15] Sadeghzadeh Ahari, J.; Sadeghi, M.T.; Zarrin Pashne, S.; J Taiwan Ind of Chem Eng, 42, 751-759, 2011.
- [16] Nasr, N.; Hafez, H.; El, M.H.; Nakhla, G.; Int J Hydrogen Energy, 38, 3189-3195, 2013.
- [17] Hossain, M.A.; Ayodele, B.V.; Cheng, C.K.; Khan, M.R.; Int J of Hydrogen Energy, 1-12, 2016.
- [18] Ayodele, B.V.; Cheng, C.K.; J Ind Eng Chem, 32, 246-258, 2015.
- [19] Zamaniyan, A.; Joda, F.; Behroozsarand, A.; Int J of Hydrogen Energy, 38, 6289-6297, 2013.
- [20] Istadi, I.; Amin, N.A.S.; Chem Eng Sci, 62, 6568-6581, 2007.
- [21] Liu, S.Y.; Mei, D.H.; Shen, Z.; Tu, X.; J Phys Chem C 118, 10686-10693, 2014.
- [22] Peng, Z.; Min, Z.J.; Hong, Y.T.; Hui, Z.P.; Chinese Sci Bull, 56(20), 2162-2166, 2011.
- [23] de Bie, C.; Martens, T.; Van Dijk, J.; Plasma Sources Sci and Technol, 20(2), 1-11, 2011.
- [24] Lee, D.H.; Kim, K.T.; Cha, M.S.; Song, Y.H.; Int J of Hydrogen Energy, 35(20), 10967-10976, 2010.
- [25] Amin, N.A.S.; Istadi, I.; In book: Real-World

- Applications of Genetic Algorithms, 2007.
- [26] Amin, N.A.S.; Yusof, K.M.; Isha, R.; Jurnal Teknologi, 43, 15–30, 2005.
- [۲۷] اکبری، ایمان؛ قریشی، سید محمد؛ رضوی، نرجس السادات؛ قریشی سید مهرداد؛ وفایی جهان مجید؛ نشریه پژوهش‌های کاربردی در شیمی، (۴)۷، ۵، ۱۳۹۲.
- [28] Aziznia, A.; Bozorgzadeh, H.R.; Seyed-Mat-in, N.; Baghalha, M.; Mohamadalizadeh, A.; J Nat Gas Chem, 21, 466-475, 2012.
- [۲۹] حسن‌آبادی، مرتضی؛ نشریه شیمی و مهندسی شیمی ایران، (۲)۳۱، ۵۵، ۱۳۹۱.
- [30] Istadi, I.; Amin, N.A.S.; Fuel Processing Technology, 87, 449–459, 2006b.
- [31] Holland, J.; "Adaptation in Natural and Artificial Systems," University of Michigan Press, 1975.
- [32] Hossain M.A.; Ayodele, B.V.; Cheng, C.K.; Khan, M.R.; Int J Hydrogen Energy, 1-12, 2016.
- [33] Huang, K.; Zhan, X.L.; Chen, F.Q.; Lu, D.W.; Chem. Eng. Sci, 58, 81-85, 2003.
- [34] Nazari, H.; Kazemi, A.; Hashemi, M.H.; Sadat, M.M.; Nazari, M.; Int J Energy Environ Eng, 6, 345–355, 2015.
- [35] Tu, X.; Whitehead, J.C.; App Catal B: Environ, 125, 439–448, 2012.
- [36] Eliasson, B.; Liu, C.J.; Kogelschatz, U.; Ind. Eng. Chem. Res, 39, 1221-1227, 2000.

## Plasma-assistance dry reforming of methane process by using artificial neural network and genetic algorithm

M. Fazeli<sup>1</sup>, F. Ravari<sup>2</sup>, H.R. Bozorgzadeh<sup>3,\*</sup> and J. Sadeghzadeh-Ahari<sup>4</sup>

1. PhD student in physical chemistry, Department of Chemistry, Payame Noor University, Tehran, Iran
2. Assistant Prof. of physical chemistry, Department of Chemistry, Payame Noor University, Tehran, Iran
3. Associate Prof. of physical chemistry, Plasma Research Laboratory, Research Institute of Petroleum Industry (RIPI), Tehran, Iran
4. Assistant Prof. of Chemical Engineering, Research Institute of Petroleum Industry (RIPI), Gas Research Division, Tehran, Iran

Received: January 2017, Revised: February 2017, Accepted: May 2017

**Abstract:** The plasma-assistance dry reforming of methane products (hydrogen and carbon monoxide) predicted at atmospheric pressure were simulated using artificial neural network. The experimental data required for modeling artificial neural networks was collected in a corona discharge plasma reactor. Effect of process parameters (plasma discharge power and feed flow rate) on the performance of the reaction, for example, methane conversion, and selectivity of the products were studied. A network with feed forward back-propagation algorithm, and Levenberg-Marquardt training function, tangent sigmoid activation function and linear activation function for hidden and output layer, respectively were used in this project. For example, artificial neural network model predicted methane conversion 25.12%, selectivity of hydrogen and carbon monoxide 71.15%, 74.85% in 4 w plasma discharge power. The model error values for the conversion of methane, hydrogen and carbon monoxide selectivity were 0.47%, 1.2% and 0.2%, respectively. A combination of genetic algorithms and artificial neural network to achieve optimum operating conditions were used in the reforming process. The results showed that the optimal feed flow rate and plasma discharge power were 175 ml.min<sup>-1</sup> and 6 watt, respectively. Also, the conversion of methane and hydrogen selectivity were 25.85% and 65.15%, respectively. The very small differences between predicted and experimental values confirm that combined neural network with genetic algorithm model is suitable tools for modeling and optimization of plasma-assistance methane dry reforming process.

**Keywords:** Artificial neural network, Methane dry reforming, Plasma, Modeling, Optimization