

مدل سازی تبدیل گاز سنتز و بررسی درصد تبدیل هیدروژن و منوکسید کربن توسط شبکه عصبی براساس آزمایشات تجربی در راکتور بستر ثابت

افشین رزمجویی^۱، حسین آتشی^۱، فرهاد شهرکی^{۱*} و مهدی شیوا^۲
 دانشکده مهندسی شهید نیکبخت، دانشگاه سیستان و بلوچستان، زاهدان، ایران
 ۲- گروه مهندسی شیمی، دانشگاه صنعتی بیرجند، بیرجند، ایران

تاریخ دریافت: ۹۵/۱۱/۱۹ تاریخ پذیرش: ۹۶/۴/۲۶

چکیده

در این پژوهش، براساس داده‌ها و آزمایشات تجربی به بررسی درصد تبدیل هیدروژن و منوکسید کربن و طراحی مدل آنها براساس طراحی آزمایش و شبکه عصبی پرداخته شد. داده‌های آزمایشگاهی براساس پنج متغیر ورودی و براساس طراحی مکعب مرکزی تعیین گردید. این پنج متغیر موثر عبارتند از: دما، فشار راکتور، نسبت هیدروژن به منوکسید کربن در خوراک، فشار جزئی هیدروژن و منوکسید کربن در راکتور. شرایط عملیاتی راکتور، دما (۳۲۰-۳۴۰ °C)، فشار (bar gauge) ۲-۸، نسبت هیدروژن به منوکسید کربن (۲/۲-۰/۸)، فشار جزئی منوکسید کربن (۲/۷-۰/۳ bar gauge) و فشار جزئی هیدروژن (۲/۵-۰/۳ bar gauge) می‌باشد. برای بررسی و به‌دست آوردن مدل درصد تبدیل‌ها، از دو روش پاسخ سطح و شبکه عصبی استفاده گردید. برای بررسی توانمندی هر دو روش، دو پارامتر مهم خطای آماری شامل مجذور میانگین خطا و انحراف نسبی میانگین مطلق محاسبه شد. نتایج به‌دست آمده از هر دو مدل پاسخ سطح و شبکه عصبی با نتایج تجربی مقایسه شد. مشاهده گردید که هر دو مدل تطابق خوبی با داده‌های تجربی دارند. برای محاسبه بیشینه درصد تبدیل برای هر دو مدل، شبکه عصبی با الگوریتم ژنتیک مدل شده و نقاط بیشینه هر دو مدل غیرخطی به‌دست آمد. در پایان، مدل‌های حاصله تحلیل شده و نقاط بیشینه مورد بررسی قرار گرفت. همچنین این مدل می‌تواند برای به‌دست آوردن محصولات انتخابی با ارزش افزوده بالا نیز به‌کار گرفته شود.

کلمات کلیدی: سنتز فیشر - تروپش، تبدیل گاز سنتز، روش پاسخ سطح، شبکه عصبی، الگوریتم ژنتیک.

مقدمه

و [۱۱] اما بررسی هم‌زمان کاربرد شبکه عصبی مصنوعی و بهینه‌سازی با الگوریتم ژنتیک^۳ می‌تواند در یافتن مدل دقیق و بهینه‌سازی چند هدفه در به‌دست آوردن نقاط بهینه مدل، می‌تواند ما را در بررسی دقیق شرایط حاکم بر سنتز فیشر-تروپیش کمک شایانی نماید. شبکه عصبی مصنوعی به‌طور گسترده‌ای برای مدل‌سازی معادلات غیرخطی استفاده می‌شود [۳ و ۱۲-۱۴]. شبکه‌های عصبی روشی قدرتمند برای مدل‌سازی و برآورد داده‌های آزمایشگاهی است. طراحی آزمایش در مطالعات فیشر-تروپیش تا حدود زیادی گزارش داده شده است [۱۲ و ۱۴-۲۲] همچنین کاربرد شبکه عصبی مصنوعی در چندین مطالعه سینتیکی مشاهده می‌شود [۱۴، ۱۹ و ۲۳]. برای مثال، Adesina و Chen از طرح آزمایش به روش فاکتوریل جزئی برای طراحی و گزینش یکی سیستم کاتالیستی کبالت-مولیبدن ارتقاء یافته با پتاسیم برای تولید هیدروکربن استفاده نمودند. همچنین Eisenacher و Adesina تاثیر شرایط عملیاتی مانند pH، دمای کلسیناسیون و دمای احیاء را بر فعالیت احتمال رشد زنجیر هیدروکربنی در قالب طرح فاکتوریل کامل در دو سطح مورد مطالعه قرار دادند [۸]. Farias و همکاران به کمک طرح آزمایش و تحلیل آماری تاثیر پتاسیم به‌عنوان ارتقاءدهنده کاتالیست آهن و نیز تغییرات دما و فشار راکتور را بر شمار میانگین عدد کربن در هیدروکربن‌های تولید شده سنتز فیشر-تروپیش مطالعه کردند [۲۲] Sharma و همکاران مدل‌های شبکه عصبی مصنوعی بر روی کاتالیست کبالت و اکسید آلومینیم بر پایه اکسید سیلیس را توسعه داده و وابستگی درجه تبدیل و غلظت‌های حالت یکنواخت محصولات را مدل کردند [۱۱]. همچنین شیوا و همکاران بر روی مدل‌سازی معادلات سینتیکی بر روی کاتالیست‌های آهن و کبالت برای تولید اولفین‌های سبک براساس شبکه عصبی و مدل آماری تحقیق کردند [۹ و ۱۰].

سنتز فیشر-تروپیشاز جمله واکنش‌های کاتالیستی بسیار مهمی است که در آن گاز سنتز (مخلوط دو گاز هیدروژن و منوکسیدکربن) به زنجیره‌ای از هیدروکربن‌های ارزشمند تبدیل می‌گردد [۱-۳]. این فرآیند به این دلیل که منجر به تولید هیدروکربن‌هایی با کمترین میزان گوگرد و ترکیبات آروماتیک می‌گردد، بسیار مورد توجه بوده و تحقیقات و پژوهش‌های گسترده‌ای در این زمینه در جهان انجام گردیده است [۴-۶]. واکنش فیشر-تروپیش یک واکنش کاتالیستی است که در محدوده وسیعی از انواع کاتالیست‌ها و شرایط فیزیکی واکنش، می‌تواند محصولات گوناگونی تولید کند. پارامترهای گوناگون از جمله نوع کاتالیست، نیمه عمر کاتالیست، دما، فشار، نسبت هیدروژن به منوکسیدکربن، سرعت فضایی و غیره تاثیر مستقیمی بر تنوع محصولات دارد [۷]. با توجه به گستردگی این پارامترها مشاهده می‌شود که انجام آزمایشات سنتز فیشر-تروپیش در محدوده بسیار وسیعی انجام می‌گردد. امروزه برای انجام آزمایشات دقیق، استفاده از روش طراحی هوشمند آزمایشات^۱ پیشنهاد می‌گردد. طراحی آزمایشات از یک‌سو موجب کاهش هزینه‌ها و بالا رفتن دقت آزمایش شده و از سوی دیگر برای طراحی مدل و بهینه‌سازی آن استفاده می‌گردد. به‌طور کلی در فرآیند سنتز فیشر-تروپیش، مدل‌های رفتاری اغلب غیرخطی بوده و تحقیقات بر روی مدل‌سازی براساس طراحی هوشمند داده‌های آزمایشگاهی بسیار ضعیف است [۸ و ۹] به‌دلیل تاثیر پارامترهای گوناگون بر کیفیت واکنش سنتز فیشر-تروپیش، اغلب آزمایشات با تکرارهای زیاد انجام شده و مدل به‌دست آمده از رفتار پارامترها از دقت بالایی برخوردار نیست. کاربرد شبکه‌های عصبی مصنوعی^۲ در مدل‌سازی سنتز فیشر-تروپیش می‌تواند این مشکل را به‌سادگی برطرف نماید. در این زمینه تاکنون برخی از تحقیقات انجام شده به‌کاربرد این روش در سنتز فیشر-تروپیش پرداخته‌اند [۱۰]

1. Design of Experiment (DOE)

2. Artificial neural Network (ANN)

3. Genetic Algorithm (GA)

فولاد ضدزنگ ساخته شده که قطری معادل ۲ cm و طول ۸ cm دارد. خروجی این راکتور پس از عبور از یک بستر جاذب رطوبت سیلیکاژل وارد دستگاه کروماتوگراف جهت برآورد مقادیر ترکیب محصول سنتز می‌گردد. شماتیک این سامانه در شکل ۱ مشاهده می‌گردد.

کاتالیست مورد استفاده در این پژوهش، ۹۰٪ وزنی MgO، ۵٪ وزنی Fe و ۵٪ وزنی CO می‌باشد که به روش تلقیح مرطوب ساخته شده است. برای ساخت کاتالیست ابتدا یک محلول اشباع از اکسید منیزیم (پایه کاتالیست) و با مشخصات (مساحت سطح $118/93 \text{ (m}^2/\text{g)}$ ، میانگین اندازه ذرات 19 (Å) و میانگین حجم حفره $0/0041 \text{ (cm}^3/\text{g)}$) با محلول آبی نیترات کبالت ($\text{CO(NO}_3)_2 \cdot 6\text{H}_2\text{O}$) و نیترات آهن ($\text{Fe(NO}_3)_3 \cdot 6\text{H}_2\text{O}$) ساخته می‌شود. اکسید منیزیم پیش از تلقیح در دمای 600°C به مدت ۶ hr در جریان هوا کلسینه می‌شود. مشخصات پایه پس از کلسیناسیون به این شرح می‌باشد: (مساحت سطح $127/09 \text{ (m}^2/\text{g)}$ ، میانگین اندازه 15 (Å) و میانگین حجمی $0/0032 \text{ (cm}^3/\text{g)}$) سپس مقادیر مشخص از نیترات کبالت و نیترات آهن در آب مقطر حل شده و مستقیماً بر روی پایه اکسید منیزیم تلقیح می‌گردد. این سوسپانسیون فیلتر شده سپس در دمای 120°C به مدت ۱۶ hr خشک می‌شود. کاتالیست نهایی به دست آمده خرد شده و تا اندازه (مش کمتر از 120) غربال می‌گردد.

طراحی آزمایش

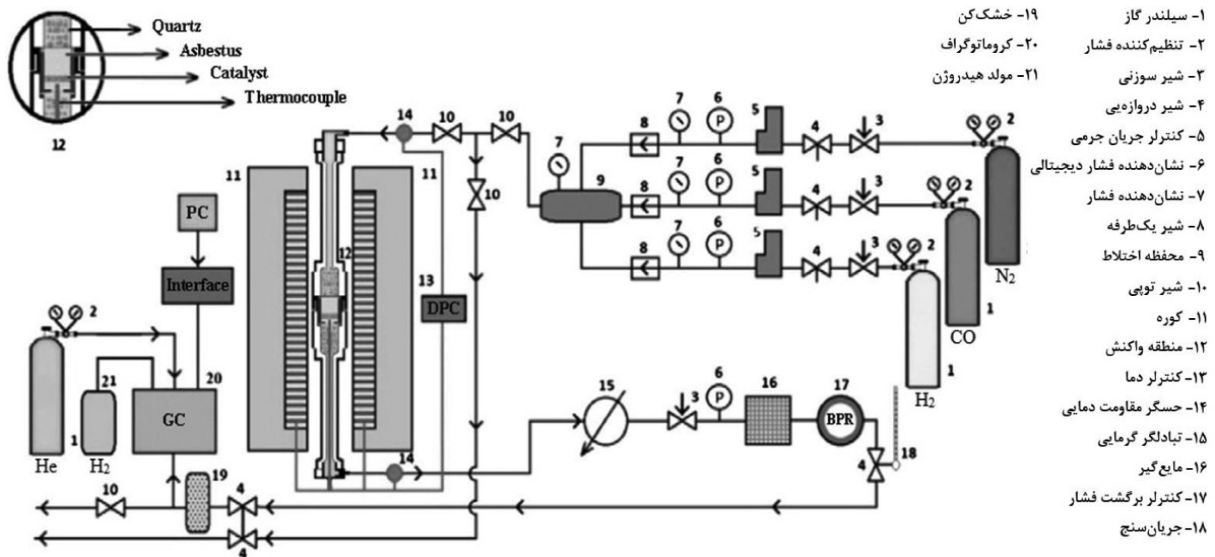
مشخصات پارامترهای منتخب موثر بر واکنش سنتز با طراحی مکعب مرکزی و انتخاب محدوده‌های فیزیکی فرآیند صورت می‌پذیرد. انتخاب سه محدوده حد پایین، میانه و بالا جهت دسته‌بندی سطوح آزمایش براساس طراحی مکعب مرکزی در روش پاسخ سطح طبق جدول ۱ صورت می‌گیرد.

1. Response Surface Methodology (RSM)
2. Central Composite Ddesign (CCD)
3. Fixed-bed Reactor

سعی ما بر این است که داده‌های آزمایشگاهی را که براساس روش طراحی هوشمند آزمایشات براساس روش پاسخ سطح^۱ انجام داده‌ایم را با داده‌هایی که از شبکه عصبی مصنوعی مدل کرده‌ایم، مقایسه نموده و نقاط بهینه مدل به دست آمده را با استفاده از الگوریتم ژنتیک تعمیم دهیم. این روش می‌تواند خطاهای ناشی از محدودیتی را که طراحی هوشمند آزمایشات بر مدل ما تحمیل می‌کند، رفع کرده و محدوده‌ای امن برای دقت داده‌های آزمایش فراهم آورد. در این پژوهش، تاثیر پنج پارامتر اصلی واکنش سنتز فیشتر- تروپیش بر روی درصد تبدیل گاز سنتز را با استفاده از روش‌های گفته شده بررسی می‌کنیم. این پارامترها عبارتند از: دما، فشار، نسبت هیدروژن به منوکسید کربن در ورودی راکتور و فشار جزیبی منوکسید کربن و هیدروژن. طراحی هوشمند آزمایش براساس روش پاسخ سطح و متد طراحی مکعب مرکزی^۲ انجام گرفته و سپس با استفاده از ترکیب شبکه مصنوعی و الگوریتم ژنتیک به بررسی و بهینه‌سازی دو مدل به دست آمده می‌پردازیم. این روش می‌تواند به همین ترتیب برای بیشینه نمودن مقدار محصول منتخب از خروجی راکتور فیشتر- تروپیش به کار گرفته شود.

شرح آزمایش

سامانه آزمایشگاهی مورد استفاده در این پژوهش شامل یک راکتور بستر ثابت^۳ است که دارای سه سیلندر هیدروژن، منوکسید کربن و نیتروژن با خلوص بالای ۹۹/۵٪ می‌باشد. شیرآلات این سامانه شامل شیرهای سوزنی، شیرهای توپی و شیرهای یک طرفه است که به ترتیب برای کنترل جریان، قطع و وصل آن و جلوگیری از برگشت گاز استفاده می‌شود. هر مخزن گاز شامل یک دستگاه کنترل کننده جرمی برای تنظیم دقیق جریان گاز می‌باشد. کوره گرمایی که وظیفه ایجاد دمای واکنش سنتز را بر عهده دارد از نوع استوانه‌ای است که دارای ترموکوپل و سیستم کنترل دما می‌باشد. راکتور بستر ثابت از




شکل ۱ میکروراکتور بستر ثابت با متعلقات آن

جدول ۱ محدوده‌های پارامترهای مستقل ورودی در طراحی مکعب مرکزی

متغیرهای مستقل	سطوح فاکتورها		
دما (x_1) (°C)	۳۲۰ (-)	۳۳۰ (۰)	۳۴۰ (+)
فشار برحسب بار (x_2)	۲	۵	۸
نسبت H_2/CO (x_3)	۰/۸	۱/۵	۲/۲
برحسب بار P_{CO} فشار (x_4)	۰/۳	۱/۵	۲/۷
برحسب بار P_{H_2} فشار (x_5)	۰/۳	۱/۵۵	۲/۸

که شدت افزایش درصد تبدیل منوکسیدکربن به شدت به نسبت هیدروژن به منوکسید کربن وابسته است. از سوی دیگر درصد تبدیل هیدروژن در راکتور به شدت به فشار راکتور بستگی دارد. بنابر شکل ۲ از میان تمام پارامترها، فشار راکتور و نسبت هیدروژن به منوکسیدکربن به ترتیب بیشترین و کمترین میزان تاثیر را بر درصد تبدیل هیدروژن در راکتور دارند. از سوی دیگر، نسبت هیدروژن به منوکسیدکربن و فشار جزئی منوکسیدکربن در راکتور، به ترتیب بیشترین و کمترین میزان تاثیر را بر درصد تبدیل منوکسیدکربن دارند. براساس روش طراحی مکعب مرکزی تعداد ۳۲ آزمایش براساس طراحی تصادفی آماری انجام می‌گیرد.

طی آزمایشات تجربی مشخص گردید که تمام پارامترهای جدول ۱ بر درصد تبدیل دو جزء گاز سنتز موثر می‌باشند اما میزان تاثیر این پارامترها در مقایسه با یکدیگر متفاوت است. شکل ۲ میزان تاثیر هر کدام از این پارامترها بر درصد تبدیل منوکسیدکربن و هیدروژن در محدوده‌های گفته شده را نشان می‌دهد. این مقایسه با طرح آزمایش به روش فاکتوریل و بررسی میزان تاثیر پارامترها بر درصد تبدیل مورد نظر به‌عنوان تابع هدف انجام گرفته است. با توجه به شکل ۲ مشاهده می‌شود که افزایش میزان هیدروژن در خوراک ورودی به راکتور موجب کاهش درصد تبدیل هیدروژن و افزایش درصد تبدیل منوکسیدکربن می‌گردد. به گونه‌ای



شکل ۲ میزان و شدت تاثیر پارامترهای موثر بر درصد تبدیل گاز سنتز در حد پایین و بالای هر پارامتر موثر

زیر می‌باشد:

$$f = a_0 + \sum_{i=1}^n a_i x_i + \sum_{i=1}^n a_{ii} x_i^2 + \sum_{i < j} a_{ij} x_i x_j \pm \varepsilon \quad (2)$$

این تابع مجموع ضرایب خطی، توان دو و برهم‌کنش متغیرهای ورودی را در بر می‌گیرد.

شبکه عصبی

یک روش ریاضی قدرتمند برای تحلیل معادلات غیرخطی و پیچیده است [۲۵]. یک شبکه عصبی از مجموع چند نورون^۱ تشکیل شده که به‌صورت لایه‌های ورودی، مخفی و خروجی به یکدیگر متصل می‌گردند. تعداد نورون‌ها در لایه ورودی برابر با تعداد متغیرهای ورودی و تعداد لایه‌های خروجی برابر با تعداد خروجی (هدف) است [۱۰ و ۱۱]. به‌طور کلی یک نورون با تابع زیر تعریف می‌شود:

$$Y_i = \sum_{i=1}^n x_i \omega_i + \theta_i \quad (3)$$

در این تابع، Y_i خروجی شبکه (هدف)، x_i متغیر ورودی، ω_i تابع وزن و θ_i مولفه بایاس^۲ است. پارامترهای گوناگونی وجود دارند که به‌صورت مستقیم بر توانمندی یک شبکه عصبی تاثیر دارند از جمله تعداد نورون‌ها، نوع تابع انتقال، الگوریتم تابع آموزش و تعداد متغیرهای ورودی مساله [۲۶ و ۲۷].

1. Neuron
2. Bias

بر این اساس، تعداد آزمایشات انجام شده با توجه به شرایط آزمایش، تعداد پارامترها و به‌منظور یافتن نقاط بهینه فرآیند و مطالعه تاثیر پارامترها بر تابع هدف انجام می‌پذیرد جدول ۲. داده‌های تجربی، مدل پاسخ سطح و شبکه عصبی برای هر دو درصد تبدیل تعداد آزمایشات انجام شده را به‌همراه داده‌های پیش‌بینی توسط روش پاسخ سطح و شبکه عصبی نشان می‌دهد.

روش پاسخ سطح

روش پاسخ سطح، روشی کارآمد براساس داده‌های آماری و ریاضی است که به‌منظور مدل‌سازی و بهینه‌سازی یک فرآیند انجام می‌گیرد. کاربرد اصلی این روش هنگامی است که بخواهیم تاثیرات دو یا چند متغیر مستقل را بر بعضی مشخصه‌ها و ویژگی‌های یک فرآیند یا یک محصول که در اینجا به‌عنوان پاسخ از آن یاد می‌شود را بررسی کنیم [۲۴]. ارتباط بین متغیرهای مستقل با پاسخ طبق رابطه زیر بیان می‌گردد:

$$y = f(x_1, x_2, x_3, \dots, x_n) \pm \varepsilon \quad (1)$$

در این رابطه y پاسخ، f تابع پاسخ، $x_1, x_2, x_3, \dots, x_n$ متغیرهای ورودی تابع پاسخ و ε خطای ناشی از برآزش تابع پاسخ است. تابع رگرسیون درجه دو ناشی از برآزش داده‌های تجربی به‌صورت

جدول ۲ داده‌های تجربی، مدل پاسخ سطح و شبکه عصبی برای هر دو تابع درصد تبدیل هیدروژن و مونوکسیدکربن

Run. order	دما (x ₁) (°C)	فشار (x ₂) (bar)	نسبت H ₂ /CO (x ₃) (-)	P _{CO} (x ₄) (bar)	P _{H₂} (x ₅) (bar)	درصد تبدیل مونوکسید کربن			درصد تبدیل هیدروژن		
						تجربی	پاسخ سطح	شبکه عصبی	تجربی	پاسخ سطح	شبکه عصبی
۱	۳۳۰	۵	۱/۵	۲/۷	۱/۵۵	۷/۸۰	۸/۵۷	۷/۷۷	۲۵/۷۰	۲۶/۴۳	۲۵/۷۳
۲	۳۴۰	۵	۱/۵	۱/۵	۱/۵۵	۸/۵۰	۸/۲۵	۸/۴۷	۱۷/۳۰	۱۷/۹۷	۱۷/۳۴
۳	۳۲۰	۲	۰/۸	۲/۷	۰/۳	۳/۳۵	۳/۱۸	۳/۳۸	۱۵/۴۰	۱۵/۳۴	۱۵/۴۲
۴	۳۲۰	۵	۱/۵	۱/۵	۱/۵۵	۵/۷۳	۶/۵۰	۵/۷۷	۱۱/۴۲	۱۰/۹۵	۱۱/۳۸
۵	۳۳۰	۵	۰/۸	۱/۵	۱/۵۵	۶/۳۵	۶/۱۵	۶/۳۰	۲۰/۵۵	۲۰/۰۳	۲۰/۴۱
۶	۳۳۰	۲	۱/۵	۱/۵	۱/۵۵	۵/۷۰	۶/۰۳	۵/۴۳	۱۲/۳۴	۱۱/۸۵	۱۲/۳۹
۷	۳۲۰	۸	۲/۲	۰/۳	۲/۸	۸/۳۰	۸/۳۰	۸/۳۳	۱۲/۶۷	۱۲/۶۶	۱۲/۶۱
۸	۳۲۰	۲	۲/۲	۲/۷	۲/۸	۱۱/۶۵	۱۱/۲۸	۱۱/۵۹	۴/۲۱	۴/۰۷	۴/۳۳
۹	۳۴۰	۸	۲/۲	۰/۳	۰/۳	۷/۵۵	۷/۴۰	۷/۴۸	۱۶/۳۳	۱۶/۲۸	۱۶/۲۱
۱۰	۳۴۰	۲	۲/۲	۲/۷	۰/۳	۸/۴۵	۸/۳۷	۸/۴۶	۲۵/۴۳	۲۵/۴۹	۲۵/۳۲
۱۱	۳۴۰	۸	۰/۸	۰/۳	۲/۸	۹/۴۵	۹/۶۲	۹/۴۴	۱۵/۴۵	۱۵/۶۳	۱۵/۴۹
۱۲	۳۳۰	۸	۱/۵	۱/۵	۱/۵۵	۸/۶۴	۸/۷۱	۸/۶۹	۱۹/۵۶	۲۰/۲۴	۱۹/۵۱
۱۳	۳۲۰	۸	۰/۸	۲/۷	۲/۸	۷/۳۴	۷/۱۱	۷/۳۱	۱۸/۳۳	۱۸/۴۹	۱۸/۴۲
۱۴	۳۴۰	۲	۰/۸	۲/۷	۲/۸	۶/۹۳	۷/۰۶	۶/۸۸	۱۶/۴۵	۱۶/۴۹	۱۶/۵۳
۱۵	۳۲۰	۸	۰/۸	۰/۳	۰/۳	۵/۶۷	۵/۷۶	۵/۶۳	۱۳/۹۰	۱۳/۷۳	۱۳/۸۳
۱۶	۳۴۰	۸	۰/۸	۲/۷	۰/۳	۸/۵۶	۷/۸/۵۱	۸/۵۵	۳۶/۳۱	۳۵/۸۴	۳۶/۲۶
۱۷	۳۳۰	۵	۱/۵	۱/۵	۱/۵۵	۷/۳۴	۷/۳۷	۷/۵۶	۱۹/۴۰	۱۹/۲۱	۱۹/۲۷
۱۸	۳۴۰	۸	۱/۵	۲/۷	۲/۸	۱۳/۶۵	۱۳/۸۱	۱۳/۶۶	۲۲/۰۰	۲۱/۶۹	۲۱/۸۸
۱۹	۳۳۰	۵	۱/۵	۱/۵	۱/۵۵	۷/۸۵	۷/۳۷	۷/۵۶	۱۹/۲۰	۱۹/۲۱	۱۹/۲۷
۲۰	۳۳۰	۵	۱/۵	۰/۳	۱/۵۵	۶/۳۴	۶/۱۸	۶/۳۹	۱۷/۸۰	۱۷/۲۶	۱۷/۸۴
۲۱	۳۳۰	۵	۱/۵	۱/۵	۱/۵۵	۷/۸۶	۷/۳۷	۷/۵۶	۱۹/۲۳	۱۹/۲۱	۱۹/۲۷
۲۲	۳۳۰	۵	۱/۵	۱/۵	۱/۵۵	۷/۵۴	۷/۳۷	۷/۵۶	۱۸/۸۵	۱۹/۲۱	۱۹/۲۷
۲۳	۳۳۰	۵	۱/۵	۱/۵	۲/۸	۸/۴۵	۸/۳۷	۸/۴۹	۱۸/۴۰	۱۸/۲۲	۱۸/۴۴
۲۴	۳۲۰	۸	۲/۲	۲/۷	۰/۳	۹/۴۵	۹/۲۰	۹/۵۱	۲۲/۸۰	۲۲/۷۴	۲۲/۸۴
۲۵	۳۴۰	۲	۰/۸	۰/۳	۰/۳	۴/۷۸	۴/۷۱	۴/۷۱	۱۰/۲۰	۱۰/۱۶	۱۰/۱۳
۲۶	۳۳۰	۵	۲/۲	۱/۵	۱/۵۵	۸/۳۵	۸/۵۹	۸/۴۲	۱۸/۶۵	۱۸/۴۰	۱۸/۵۹
۲۷	۳۳۰	۵	۱/۵	۱/۵	۱/۵۵	۷/۴۵	۷/۳۷	۷/۵۶	۱۹/۲۳	۱۹/۲۱	۱۹/۲۷
۲۸	۳۴۰	۲	۲/۲	۰/۳	۲/۸	۶/۴۵	۶/۴۷	۶/۵۱	۱۰/۱۰	۹/۹۸	۹/۹۸
۲۹	۳۳۰	۵	۱/۵	۱/۵	۱/۵۵	۷/۴۱	۷/۳۷	۷/۵۶	۱۹/۲۵	۱۹/۲۱	۱۹/۲۷
۳۰	۳۲۰	۲	۰/۸	۰/۳	۲/۸	۳/۳۳	۳/۲۹	۳/۳۶	۴/۰۰	۴/۳۴	۳/۹۹
۳۱	۳۲۰	۲	۲/۲	۰/۳	۰/۳	۳/۸۰	۳/۸۶	۳/۸۱	۳/۶۵	۴/۰۱	۳/۶۶
۳۲	۳۳۰	۵	۱/۵	۱/۵	۰/۳	۶/۰۰	۶/۳۷	۵/۹۶	۲۲/۸۷	۲۳/۲۵	۲۲/۸۱
						MSE	۰/۰۷	۰/۰۰۴		۰/۱۱	۰/۰۰۵
						AARD	۲/۹۱	۰/۷۵		۱/۹۳	۰/۴۶

بحث و نتایج

گامی مهم در آنالیزهای آماری هستند. برای آنالیز خطای^۱ مدل به‌دست آمده، ابتدا به معرفی دو پارامتر مهم می‌پردازیم. پارامتر اول دقت و صحت برآزش و مدل به‌دست آمده را ارزیابی می‌کند. این پارامتر به‌صورت زیر تعریف می‌گردد:



$$R^2 = 1 - \frac{SS_{res}}{SS_{tot}} \quad (۴)$$

پارامتر بعدی که در حقیقت مدل اصلاح شده پارامتر اول بوده و صحت پارامتر اول را می‌سنجد به‌صورت زیر بیان می‌شود:

$$R_{adj}^2 = 1 - \frac{MS_{res}}{MS_{tot}} \quad (۵)$$

جدول ۳ تحلیل و آنالیز خطای مدل به‌دست آمده توسط روش پاسخ سطح می‌باشد.

جهت برآورد صحت مدلی که توسط روش پاسخ سطح به‌دست آورده‌ایم از منحنی توزیع نرمال داده‌ها استفاده می‌کنیم. در حقیقت این منحنی ابزاری است برای تشخیص صحت روش و اطمینان از توزیع نرمال داده‌های آماری به این‌صورت که اگر داده‌ها به‌صورت نرمال توزیع شده باشند این منحنی تقریباً خطی راست را تشکیل می‌دهد. شکل ۳ دو منحنی توزیع نرمال برای هر دو تابع هدف (درصد تبدیل منوکسیدکربن و هیدروژن) را نشان می‌دهد. اصولاً صحت روش‌های آماری وابستگی زیادی به توزیع نرمال داده‌ها دارد، از این‌رو این منحنی‌ها



شکل ۳ منحنی‌های توزیع نرمال درصد تبدیل، هیدروژن (بالا)، منوکسید کربن (پائین). (باقیمانده در محور افقی، پارامتری بدون بعد بوده و برابر با اختلاف میان پاسخ داده تجربی و پاسخ پیش‌بینی شده توسط معادله رگرسیون می‌باشد)

جدول ۳ آنالیز خطای مدل پاسخ سطح برای هر دو درصد تبدیل هیدروژن و منوکسیدکربن

X _{H₂}						X _{CO}					
Source	Degree of freedom	Sum of square	Mean square	F-Value	P-Value	Degree of freedom	Sum of square	Mean square	F-Value	P-Value	
Model	۱۷	۱۳۵۵/۸۲	۷۹/۷۵	۳۱۱/۷۳	۰/۰۰۰	۱۲	۱۳۸/۳۸	۱۱/۵۳	۸۶/۵۴	۰/۰۰۰	
Linear	۵	۱۰۴۳/۴۹	۲۰۸/۶۹	۸۱۵/۷۳	۰/۰۰۰	۵	۱۱۶/۳۵	۲۳/۲۷	۱۷۴/۶۲	۰/۰۰۰	
Square	۴	۱۶۷/۷۷	۴۱/۹۳	۱۶۳/۹۴	۰/۰۰۰						
Interaction	۸	۱۴۴/۵۵	۱۸/۰۶	۷۰/۶۳	۰/۰۰۰	۷	۲۲/۰۳	۳/۱۴	۲۳/۶۲	۰/۰۰۰	
Error	۱۴	۳/۵۸	۰/۲۵			۱۹	۲/۵۳	۰/۱۳			
Lack-of-fit	۹	۳/۴۲	۰/۳۸	۱۱/۳۹	۰/۵۴	۱۴	۲/۲۷	۰/۱۶	۳/۱۷	۰/۱۱	
Pure error	۵	.۱۷	۰/۰۳			۵	۰/۲۵	۰/۰۵			
Total	۳۱	۱۳۵۹/۴۰				۳۱	۱۴۰/۹۲				
					%. ۹۹/۷۴					۹۸/۲۰ %	
				adj	%. ۹۹/۴۲				adj	%. ۹۷/۰۷	

می‌دهد. در مورد درصد تبدیل هیدروژن مشاهده می‌شود که با افزایش دما و افزایش همزمان فشار، میزان درصد تبدیل ابتدا افزایش و سپس کاهش می‌یابد. افزایش فشار جزئی منوکسیدکربن موجب افزایش درصد تبدیل شده و این روند در فشارهای بالاتر دارای شدت بیشتری است. افزایش فشار جزئی هیدروژن ابتدا موجب کاهش و سپس افزایش درصد تبدیل هیدروژن می‌گردد. تغییرات درصد تبدیل منوکسیدکربن با پارامترهای مستقل تقریباً خطی است. با افزایش دما و فشار زیاد می‌شود. افزایش فشار جزئی هیدروژن و منوکسیدکربن موجب افزایش درصد تبدیل شده و شدت افزایش درصد تبدیل با نسبت هیدروژن به منوکسیدکربن در ورودی، رابطه‌ای مستقیم دارد.

مدل شبکه عصبی

در این بخش به بررسی و تحلیل نتایج به‌دست آمده با استفاده از شبکه عصبی و مقایسه آن با روش پاسخ سطح می‌پردازیم.

مقادیر پارامترهای T و P و همچنین ضرایب معادله رگرسیون هر دو تابع هدف را در جدول ۴ مشاهده می‌کنید. جدول ۴، در برگیرنده تمام ضرایب موثر در مدل حاصل شده برای هر دو درصد تبدیل منوکسیدکربن و هیدروژن است. بر این اساس معادله درجه دو به‌دست آمده برای این دو به صورت زیر است:


$$X_{H_2} = -0.352x_2^2 + 1.827x_4^2 + 0.97x_5^2 - 0.026x_1x_2 + 0.033x_1x_3 + 0.112x_1x_4 - 0.038x_1x_5 - 0.224x_2x_3 + 0.131x_2x_4 - 0.837x_3x_4 - 1.545x_4x_5 - 5286 \quad (۶)$$

$$X_{CO} = -0.008x_1x_2 - 0.063x_1x_3 - 0.12x_2x_3 - 0.07x_2x_4 + 1.05x_3x_4 + 0.43x_3x_5 + 0.16x_4x_5 + 0.14x_1 - 2x_2 + 21.09x_3 - 0.49x_4 - 0.1x_5 - 44.5 \quad (۷)$$

دو مدل محاسبه شده، نحوه تاثیر پارامترهای مستقل را بر هر دو متغیر وابسته نشان می‌دهد. برای درک بهتر چگونگی تاثیر این پارامترها بر درصد تبدیل هیدروژن و منوکسیدکربن، شکل ۴ تغییرات پارامترهای دیگر با دما را نشان می‌دهد. شکل ۴ روند تغییرات دما بر سایر متغیرها را نشان

جدول ۴ ضرایب رگرسیون مدل‌های درصد تبدیل به‌دست آمده

X_{H_2}					X_{CO}				
Term	Coeff.	SE coefficient	T-value	P-value	Term	Coeff.	SE coefficient	T-value	P-value
Constant	۱۹/۲۱	۰/۱۴	۱۳۳/۶۱	۰/۰۰۰	Constant	۷/۳۷	۰/۰۶۴	۱۱۴/۲۹	۰/۰۰۰
دما (x_1) (°C)	۳/۵۱	۰/۱۲	۲۹/۴۵	۰/۰۰۰	دما (x_1) (°C)	۰/۸۷	۰/۰۸۶	۱۰/۱۴	۰/۰۰۰
فشار (x_2) (bar)	۴/۱۹	۰/۱۲	۳۵/۲۱	۰/۰۰۰	فشار (x_2) (bar)	۱/۳۴۲	۰/۰۸۶	۱۵/۶۱	۰/۰۰۰
نسبت H_2/CO (x_3)	-۰/۸۲	۰/۱۲	-۶/۸۷	۰/۰۰۰	نسبت H_2/CO (x_3)	۱/۲۱۶	۰/۰۸۶	۱۴/۱۳	۰/۰۰۰
P_{CO} (x_4)	۴/۵۸	۰/۱۲	۳۸/۴۶	۰/۰۰۰	P_{CO} (x_4)	۱/۱۹۵	۰/۰۸۶	۱۳/۸۹	۰/۰۰۰
P_{H_2} (x_5)	-۲/۵۱	۰/۱۲	-۲۱/۱۰	۰/۰۰۰	P_{H_2} (x_5)	۰/۹۹۶	۰/۰۸۶	۱۱/۵۸	۰/۰۰۰
$x_1 * x_1$	-۴/۷۵	۰/۳۱	-۱۵/۱۷	۰/۰۰۰	$x_1 * x_2$	۰/۲۴۸	۰/۰۹۱	۲/۷۲	۰/۰۱۴
$x_2 * x_2$	-۳/۱۶	۰/۳۱	-۱۰/۱۰	۰/۰۰۰	$x_1 * x_3$	۰/۴۴۵-	۰/۰۹۱	۴/۸۸-	۰/۰۰۰
$x_4 * x_4$	۲/۶۳	۰/۳۱	۸/۳۹	۰/۰۰۰	$x_2 * x_3$	۰/۲۵۱-	۰/۰۹۱	۲/۷۶-	۰/۰۱۲
$x_5 * x_5$	۱/۵۱	۰/۳۱	۴/۸۳	۰/۰۰۰	$x_2 * x_4$	۰/۲۴۹-	۰/۰۹۱	۲/۷۳-	۰/۰۱۳
$x_1 * x_2$	-۰/۷۸	۰/۱۲	-۶/۱۹	۰/۰۰۰	$x_3 * x_4$	۰/۸۸۴	۰/۰۹۱	۹/۶۹	۰/۰۰۰
$x_1 * x_3$	۰/۲۳	۰/۱۲	۱/۸۵	۰/۰۸۵	$x_3 * x_5$	۰/۳۸۱	۰/۰۹۱	۴/۱۸	۰/۰۰۱
$x_1 * x_4$	۱/۳۵	۰/۱۲	۱۰/۶۷	۰/۰۰۰	$x_4 * x_5$	۰/۲۵۱	۰/۰۹۱	۲/۷۶	۰/۰۱۲
$x_1 * x_5$	-۰/۴۸	۰/۱۲	-۳/۸۲	۰/۰۰۲					
$x_2 * x_3$	-۰/۴۷	۰/۱۲	-۳/۷۲	۰/۰۰۲					
$x_2 * x_4$	۰/۴۷	۰/۱۲	۳/۷۳	۰/۰۰۲					
$x_3 * x_4$	-۰/۷۰	۰/۱۲	-۵/۵۶	۰/۰۰۰					
$x_4 * x_5$	-۲/۳۱	۰/۱۲	-۱۸/۳۳	۰/۰۰۰					



شکل ۴ چگونگی تغییرات پارامترهای مستقل ورودی با دما برای درصد تبدیل. هیدروژن (بالا) و منوکسیدکربن (پایین)

پیش بینی شده و تجربی توسط مدل است و n تعداد داده های تجربی است. شکل ۶ خروجی شبکه عصبی و مقادیر خطا و بهترین نقاط بازدهی و عملکرد شبکه را نشان می دهد. مشاهده می شود که کمترین میزان مجذور میانگین خطا (بهترین عملکرد) برای هیدروژن برابر ۰/۳۲۹ و برای منوکسید کربن برابر ۰/۴۰ می باشد. با توجه به مقادیر خطای میانگین مشاهده می شود که هر دو مدل نتایج قابل قبولی را ارائه می دهند اما مدل شبکه عصبی دقیق تر و دارای خطای کمتری است. شکل ۷ مقایسه بین خطای هر دو مدل پاسخ سطح و شبکه عصبی را نشان می دهد. نمودارها قدر مطلق تفریق داده های تجربی و هر یک از مدل ها را نشان می دهد.

طرح هم زمان شبکه عصبی و الگوریتم ژنتیک^۳

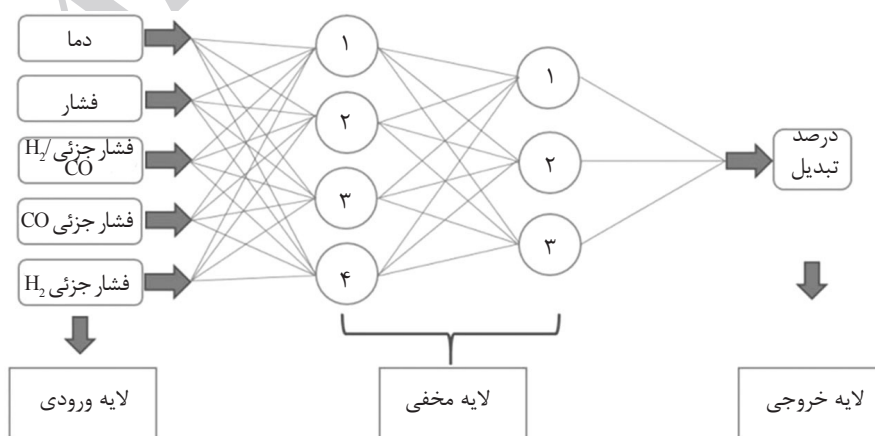
الگوریتم ژنتیک ابزاری توانمند برای به دست آوردن نقاط اکسترمم توابع غیر خطی است. استفاده از شبکه عصبی و الگوریتم ژنتیک به صورت هم زمان می تواند میزان خطای ناشی از عملکرد بهینه یابی را کم کند. شکل ۸ شماتیک الگوریتم هم زمان شبکه عصبی و ژنتیک را نشان می دهد. با استفاده از محدوده تغییرات متغیرهای مستقل که گفته شد و همچنین توابع درجه دو که در مورد هر دو درصد تبدیل به دست آمد، مقادیر بیشینه درصد تبدیل هیدروژن و منوکسید کربن مشخص می گردد.

شبکه عصبی بر مبنای ۴ گام طراحی می شود:
 ۱. تعیین ورودی های شبکه مصنوعی و لایه های ورودی،
 ۲. انتخاب و تعیین الگوریتم مناسب جهت آموزش نورون ها،
 ۳. تعیین تعداد لایه های مخفی^۱ و نورون های آموزش،
 ۴. آموزش و ارزیابی مدل. شبکه مورد نظر ما دارای پنج لایه ورودی (تعداد متغیرهای مستقل ورودی)، هفت لایه مخفی (دو لایه سری شامل چهار و سه نورون)، و یک خروجی (درصد تبدیل) تشکیل می شود. شکل ۵ شماتیک این شبکه عصبی را نشان می دهد. الگوریتم لوبنبرگ- مارکواردت^۲ برای اغلب مدل سازی های شبکه عصبی الگوریتمی کارآمد و توانا است. این الگوریتم برای استفاده از روش آموزش سریع و استفاده از توابع انتقال تانژانت در لایه های مخفی و توابع خطی در لایه خروجی توصیه می گردد [۲۸] و [۲۹] به منظور ارزیابی مقدار خطای داده های مدل با نتایج تجربی و تشخیص صحت مدل، دو پارامتر تعریف می گردد. پارامتر اول، میانگین مجذور خطا پارامتر دوم میانگین مطلق انحراف نسبی است که به صورت زیر تعریف می شوند:

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y^{i,mod.} - Y^{i,exp.})^2 \quad (8)$$





$$AARD = \frac{1}{n} \sum_{i=1}^n \left(\left| \frac{Y^{i,mod.} - Y^{i,exp.}}{Y^{i,exp.}} \right| \right) \times 100 \quad (9)$$

در این معادلات، $Y^{i,mod.}$ ، $Y^{i,exp.}$ به ترتیب داده





شکل ۵ مدل طراحی شده شبکه عصبی مصنوعی

1. Hidden Layer
2. Levenberg-Marquardt Algorithm
3. Hybrid ANN/GA

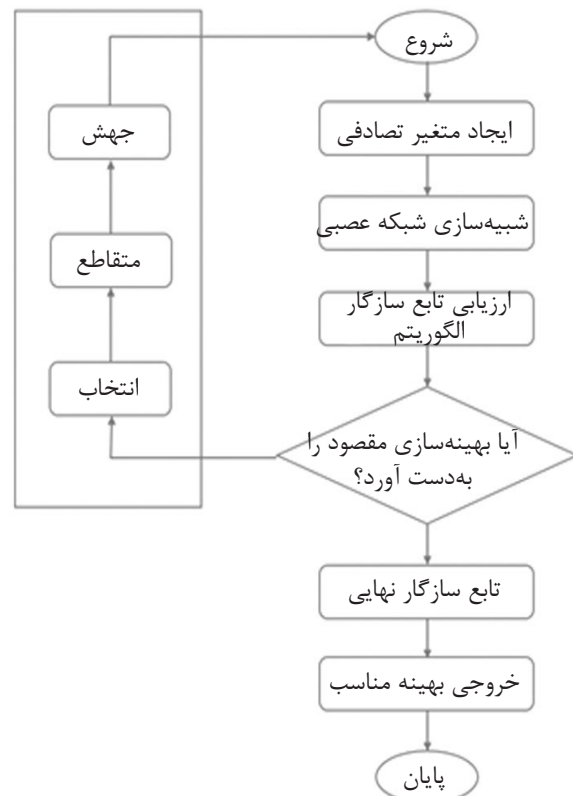


شکل ۶ میانگین مجذور خطا و نمودار خروجی شبکه عصبی برای هر دو مدل درصد تبدیل هیدروژن (بالا)، درصد تبدیل منوکسیدکربن (پایین)



شکل ۷ قدر مطلق اختلاف داده‌های تجربی با هر دو مدل پاسخ سطح و شبکه مصنوعی هیدروژن و منوکسیدکربن

و پارامترهای با تاثیر بیشتر برای هر کدام از درصد تبدیل‌ها مشخص گردید. مشاهده گردید که فشار و نسبت هیدروژن به منوکسیدکربن در خوراک بیشترین تاثیر را به ترتیب بر درصد تبدیل هیدروژن و منوکسیدکربن دارند. در ادامه با استفاده از مدل پاسخ سطح به تخمین مقادیر هر یک از درصد تبدیل‌ها پرداخته شد. سپس با استفاده از شبکه عصبی و ایجاد لایه‌های نورون مصنوعی درصد تبدیل‌ها برآورد و تخمین زده شد. با استفاده از پارامترهای آماری میانگین مجذور خطا و میانگین مطلق انحراف نسبی مشاهده گردید که هر دو مدل به دست آمده از توانایی بالایی در تخمین داده‌ها برخوردار بوده و شبکه عصبی مدل دقیق‌تری نسبت به پاسخ سطح ارائه می‌کند. در محدوده پارامترهای مستقل ورودی، مدل‌های حاصله با استفاده از الگوریتم ژنتیک بهینه گردید و نقاط بیشینه معادلات غیرخطی به دست آمد. این روش به همین ترتیب می‌تواند برای هر یک از محصولات سنتز فیشر-تروپش به کار گرفته شود. با این روش می‌توان یک یا چند محصول منتخب و مورد نظر را با توجه به شرایط و پارامترهای ورودی بهینه کرد. نتایج این پژوهش در عمل می‌تواند به بررسی دقیق تاثیر هر پارامتر بر فرآیند سنتز فیشر-تروپش منجر شود. پارامترهای گوناگونی می‌تواند بر یک فرآیند موثر باشد و کیفیت و کمیت محصول را تغییر دهد. در این روش میزان تاثیر هر پارامتر با آنالیز حساسیت آماری مشخص شده و با استفاده از بهینه‌سازی و تحلیل داده‌ها در شبکه عصبی و الگوریتم ژنتیک می‌توان نقاط بهینه را در محدوده‌های عملیاتی پیش‌بینی نمود. انتخاب گزینشی محصول در راکتور فیشر-تروپش و مطالعات دقیق تاثیر پارامترهای موثر بر این محصول در این پژوهش به کار گرفته شده و با استفاده از الگوریتم‌های هوشمند امکان کار در بهترین شرایط عملیاتی میسر می‌شود.




شکل ۸ الگوریتم هم‌زمان شبکه عصبی و ژنتیک


شکل ۹ نمودار اکستریم (بیشینه) دو تابع به دست آمده توسط الگوریتم ژنتیک است. مقدار بیشینه درصد تبدیل هیدروژن برابر با $37/45$ و مقدار بیشینه منوکسیدکربن برابر با $13/82$ می‌باشد. این مقادیر متغیرهای ورودی در این شرایط را در جدول ۵ مشاهده می‌کنید.

نتیجه‌گیری

این پژوهش به بررسی چگونگی مصرف گاز سنتز در یک راکتور بستر ثابت با کاتالیت آهن-کبالت بر پایه اکسید منیزیم می‌پردازد. درصد تبدیل و چگونگی مصرف گاز سنتز در راکتور فیشر-تروپش از اهمیت بالایی برخوردار است. در این پژوهش، داده‌های تجربی با استفاده از روش پاسخ سطح و طراحی مکعب مرکزی از طریق ۳۲ آزمایش به دست آمد. در ابتدا با توجه به محدودیت متغیرهای موثر بر واکنش، یک آنالیز حساسیت انجام گرفت



تکرار محاسبات الگوریتم برای حصول مقدار بیشینه



تکرار محاسبات الگوریتم برای حصول مقدار بیشینه

شکل ۹ خروجی الگوریتم ژنتیک و محاسبه بیشینه هر دو تابع (درصد تبدیل هیدروژن و درصد تبدیل منوکسید کربن)

جدول ۵ مقادیر متغیرهای ورودی مستقل در شرایط بیشینه توابع تبدیل

	دما بر حسب کلوین	فشار بر حسب بار	نسبت H_2/CO	P_{CO} (bar)	P_{H_2} (bar)
$H_2\%$	۳۳۴/۷	۷/۳	.۸	۲/۷	.۳
$\% CO$	۳۴۰	۸	۲/۲	۲/۷	۲/۸

مراجع

- [1]. Fu T., Lv J. and Li Z. , "Effect of carbon porosity and cobalt particle size on the catalytic performance of carbon supported cobalt fischer-tropsch catalysts," Industrial & Engineering Chemistry Research, Vol. 53(4): pp. 1342-1350, 2014.
- [2]. Adib, H., Haghbakhsh R., Saidi M., Ali Takassi M., Sharifi F., Koolivand M., Rahimpour M. R. and Keshtkari S., "Modeling and optimization of fischer-tropsch synthesis in the presence of co (iii)/al 2 o 3 catalyst using artificial neural networks and genetic algorithm," Journal of Natural Gas Science and Engineering, Vol. 10, pp. 14-24, 2013..
- [3]. Bayat, M., Hamidi M., Dehghani Z., Rahimpour M. R. and A. Shariati, "Sorption-enhanced reaction process in fischer-tropsch synthesis for production of gasoline and hydrogen: mathematical modeling," Journal of Natural Gas Science and Engineering, Vol. 14, pp. 225-237, 2013.
- [4]. Chiang S. W., Chang Ch. Ch., Shie J. L., Chang Ch. Y., Ji D. R. and Tseng J. Y., "Synthesis of alcohols and alkanes over potassium and vanadium promoted molybdenum carbides," Journal of the Taiwan Institute of Chemical Engineers, Vol. 43(6), pp. 918-925, 2012.
- [5]. Hemmati, M.R., Hemmati M. R., Kazemeini M., Khorasheh F. and Zarkesh J., "Investigating the effect of cal

- ination repetitions on the lifetime of $\text{Co}/\gamma\text{-Al}_2\text{O}_3$ catalysts in fischer-tropsch synthesis utilising the precursor's solution affinities," *Journal of the Taiwan Institute of Chemical Engineers*, Vol. 44(2): pp. 205-213, 2013.
- [6]. Feyzi M., Khodaei M. M. and Shahmoradi J., "Effect of sulfur on the catalytic performance of $\text{Fe-Ni}/\text{Al}_2\text{O}_3$ catalysts for light olefins production," *Journal of the Taiwan Institute of Chemical Engineers*, Vol. 45(2): pp. 452-460, 2014.
- [7]. Schulz H., "Short history and present trends of fischer-tropsch synthesis," *Applied Catalysis A: General*, Vol. 186(1): pp. 3-12, 1999.
- [8]. Calemma V., Corraera S., Perego C., Pollesel P. and Pellegrini P. L., "Hydroconversion of fischer-tropsch waxes: assessment of the operating conditions effect by factorial design experiments," *Catalysis today*, Vol. 106(1): pp. 282-287, 2005.
- [9]. Shiva M., Atashi H., Mirzaei A. A., Arsalanfar M. and Zare A., "Study of syngas conversion to light olefins by statistical models," *Fuel*, Vol. 123: pp. 205-210, 2014.
- [10]. Shiva M., Atashi H., Tabrizi F. F., Mirzaei A. A. and Zare A., "The application of hybrid doe/ann methodology in lumped kinetic modeling of fischer-tropsch reaction," *Fuel Processing Technology*, Vol. 106, pp. 631-640, 2013.
- [11]. Sharma B. K., Sharma M. P., Kumar Roy S., Tendulkar Sh. B., Tambe S. S. and Kulkarni B. D., "Fischer-tropsch synthesis with $\text{Co}/\text{SiO}_2\text{-Al}_2\text{O}_3$ catalyst and steady-state modeling using artificial neural networks," *Fuel*, Vol. 77(15): pp. 1763-1768, 1998.
- [12]. Zahedi G., Lohi A. and Mahdi K., "Hybrid modeling of ethylene to ethylene oxide heterogeneous reactor," *Fuel Processing Technology*, Vol. 92(9), pp. 1725-1732, 2011.
- [13]. Zarenezhad B. and Aminian A., "Predicting the vapor-liquid equilibrium of carbon dioxide+ alkanol systems by using an artificial neural network," *Korean Journal of Chemical Engineering*, Vol. 28(5): pp. 1286-1292, 2011.
- [14]. Baş D., Dudak F. C. and Boyacı I. H., "Modeling and optimization iv: investigation of reaction kinetics and kinetic constants using a program in which artificial neural network (ann) was integrated," *Journal of Food Engineering*, Vol. 79(4), pp. 1152-1158, 2007.
- [15]. Souza M. J., Fernandes F., Pedrosa A. and Araujo A. S., "Selective cracking of natural gasoline over hzsm-5 zeolite," *Fuel Processing Technology*, Vol. 89(9), pp. 819-827, 2008.
- [16]. Elavarasan P., Kondamudi K. and Upadhyayula S., "Statistical optimization of process variables in batch alkylation of p-cresol with tert-butyl alcohol using ionic liquid catalyst by response surface methodology," *Chemical Engineering Journal*, Vol. 155(1): pp. 355-360, 2009.
- [17]. Rao T. M., Vico-Ruiz E., Bañares M. A. and Deo G., "Obtaining the best composition of supported $\text{V}_2\text{O}_5\text{-moo}_3/\text{Tio}_2$ catalyst for propane odh reaction," *Journal of Catalysis*, Vol. 258(2), pp. 324-333, 2008.
- [18]. Jafarzadeh N. K., Sharifnia Sh., Hosseini S. N. and Rahimpour F., "Statistical optimization of process conditions for photocatalytic degradation of phenol with immobilization of nano Tio_2 on perlite granules," *Korean Journal of Chemical Engineering*, Vol. 28(2), pp. 531-538, 2011.
- [19]. Baş D., Dudak F. C. and Boyacı I. H., "Modeling and optimization iii: reaction rate estimation using artificial neural network (ann) without a kinetic model," *Journal of Food Engineering*, Vol. 79(2), pp. 622-628, 2007.

- [20]. Chen, H. and A.A. Adesina, "Design of a multimetallic catalyst system for hydrocarbon synthesis: a statistical optimisation procedure," Applied Catalysis A: General, Vol. 162(1-2), pp. 47-56, 1997.
- [21]. Eisenacher, K. and A.A. Adesina, "A statistical evaluation of preparation conditions on the performance of ce-promoted co-mo fischer-tropsch catalyst," Korean Journal of Chemical Engineering, 17(1), pp. 71-75, 2000.
- [22]. Farias F. E., Sales F. G. and Fernandes F. A., "Effect of operating conditions and potassium content on fischer-tropsch liquid products produced by potassium-promoted iron catalysts," Journal of Natural Gas Chemistry, Vol. 17(2), pp. 175-178, 2008.
- [23]. Serra J. M., Corma A., Chica A., Argente E. and Botti V., "Can artificial neural networks help the experimentation in catalysis?" Catalysis Today, Vol. 81(3), pp. 393-403, 2003.
- [24]. Gunst R.F., "Response surface methodology: process and product optimization using designed experiments," Technometrics, Vol. 38(3), pp. 284-286, 1996.
- [25]. Samarasinghe S., "Neural networks for applied sciences and engineering: from fundamentals to complex pattern recognition," CRC Press, 2006.
- [26]. Aghaeinejad-Meybodi, A., Ebadi A., Shafiei S., Khataee A. R. and Rostampour M., "Modeling and optimization of antidepressant drug fluoxetine removal in aqueous media by ozone/H₂O₂ process: comparison of central composite design and artificial neural network approaches," Journal of the Taiwan Institute of Chemical Engineers, Vol. 48, pp. 40-48, 2015.
- [27]. Karimi F., Rafiee S., Taheri-Garavand A. and Karimi M., "Optimization of an air drying process for artemisia absinthium leaves using response surface and artificial neural network models," Journal of the Taiwan Institute of Chemical Engineers, Vol. 43(1), pp. 29-39, 2012.
- [28]. Sodeifian G., Sajadian S. A. and Ardestani N. S., "Evaluation of the response surface and hybrid artificial neural network-genetic algorithm methodologies to determine extraction yield of ferulago angulata through supercritical fluid," Journal of the Taiwan Institute of Chemical Engineers, Vol. 60, pp. 165-173, 2016.
- [29]. Shen C., L. Wang and Li Q., "Optimization of injection molding process parameters using combination of artificial neural network and genetic algorithm method," Journal of Materials Processing Technology, Vol. 183(2), pp. 412-418, 2007.