

بهینه‌سازی هوشمند فرایند تولید صنعتی سدیم کوسیلیکات با استفاده از رویکرد ترکیبی ANN-GA

سید مهدی موسوی*

استادیار گروه شیمی کاربردی، دانشکده شیمی، دانشگاه کاشان، کاشان، ایران
mousavi.smahdi@kashanu.ac.ir

Intelligent Optimization of Industrial Sodium Co-silicate Production Process using a Hybrid Approach of ANN-GA

Seyed Mahdi Mousavi

Assistant Professor of Applied Chemistry, Department of Applied Chemistry, Faculty of Chemistry, University of Kashan, Kashan, Iran

Abstract

In this research, a hybrid model based on artificial neural network and genetic algorithm was developed for optimization of the industrial production process of sodium co-silicate. The required data were collected from the production line during the years 2023 and 2024, and a total of 245 valid operational records were used. The input parameters included caustic soda consumption and inlet silica density, while the outputs included modulus, viscosity, and final product density. A multilayer perceptron neural network with a 2-10-10-3 architecture and hyperbolic tangent activation functions in the hidden layers and linear activation function in the output layer was trained using the Levenberg-Marquardt algorithm. The model performance was evaluated on the test data with coefficients of determination (R^2) of 0.945 for modulus, 0.926 for viscosity, and 0.932 for output density, indicating the high accuracy of the model in predicting product quality indicators. The developed ANN model was then used as the objective function in the genetic algorithm with a multi-objective fitness function (including increasing modulus, increasing viscosity, and reducing caustic soda consumption). The optimization results led to the discovery of an optimal point in which, with a 2.7% increase in inlet density (from 1.480 to 1.520 g/cm³), caustic soda consumption decreased by 11.2% (from 242 to 215 kg/ton), while the product modulus increased by 8.7% (from 2.41 to 2.62) and viscosity increased by 10.4% (from 385 to 425 cP). Implementation of the results on the actual production line for 7 working days and analysis of 21 samples showed a relative error of less than 1% between model predictions and practical results, confirming the high validity of the model.

Keywords: Sodium Co-silicate, Process Optimization, Artificial neural network, Genetic algorithm, Modulus.

* mousavi.smahdi@kashanu.ac.ir: ایمیل: ۰۳۱-۵۵۹۱۳۰۵۵، ایران تلفن: ۰۳۱-۵۵۹۱۳۰۵۵، کاشان، دانشگاه کاشان، کاشان، ایران

چکیده

در این پژوهش، یک مدل ترکیبی مبتنی بر شبکه عصبی مصنوعی و الگوریتم ژنتیک برای بهینه‌سازی فرایند تولید صنعتی سدیم کوسیلیکات توسعه داده شد. داده‌های مورد نیاز از خط تولید شرکت صنعتی در بازه زمانی سال‌های ۱۴۰۲ و ۱۴۰۳ گردآوری و ۲۴۵ رکورد عملیاتی معتبر استفاده شد. پارامترهای ورودی شامل مصرف سود سوزآور و دانسیته چسب سیلیکات ورودی و خروجی‌ها شامل مدول، ویسکوزیته و دانسیته محصول نهایی بودند. شبکه عصبی پرسپترون چندلایه با معماری ۳-۱۰-۱۰-۲ و توابع فعال‌سازی تانژانت هیپربولیک در لایه‌های پنهان و خطی در لایه خروجی، با الگوریتم لونیگ-مارکواری آموزش داده شد. عملکرد مدل با ضریب تعیین ۰/۹۴۵، ۰/۹۲۶ و ۰/۹۳۲ به ترتیب برای مدول، ویسکوزیته و دانسیته خروجی ارزیابی شد. سپس مدل توسعه‌یافته شبکه عصبی مصنوعی به عنوان تابع هدف در الگوریتم ژنتیک با تابع تناسب چندهدفه (شامل افزایش مدول و ویسکوزیته و کاهش مصرف سود) مورد استفاده قرار گرفت. نتایج بهینه‌سازی نشان داد که با افزایش ۲/۷ درصدی دانسیته چسب ورودی، مصرف سود ۱۱/۲ درصد کاهش و مدول ۸/۷ درصد و ویسکوزیته ۱۰/۴ درصد بهبود یافت. پیاده‌سازی نتایج در خط تولید به مدت ۷ روز، خطای نسبی کمتر از ۱ درصد را تأیید کرد.

واژه کلیدی: سدیم کوسیلیکات، بهینه‌سازی فرایند، شبکه عصبی مصنوعی، الگوریتم ژنتیک، مدول،

۱- مقدمه

سدیم کوسیلیکات یک ماده شیمیایی صنعتی با فرمول شیمیایی $\text{Na}_4\text{SiO}_3\text{CO}_3$ یک ترکیب سیلیکاتی قلیایی است که به طور گسترده در صنایع مختلف پتروشیمی، تصفیه آب، کاشی و سرامیک، مواد شوینده، نساجی و صنایع کاغذسازی استفاده می‌شود. برای تهیه این محصول، به طور معمول از واکنش ماسه سیلیسی (SiO_2) با سود سوزآور (NaOH) در دما و فشار بالا در ابتدا سدیم متاسیلیکات آبدار ($\text{Na}_2\text{SiO}_3, \text{nH}_2\text{O}$) تولید می‌شود. در ادامه از واکنش سدیم متاسیلیکات با نسبت های جرمی مختلف با سدیم کربنات (Na_2CO_3) محصول نهایی یعنی سدیم کوسیلیکات تولید می‌شود. در محصول نهایی، نسبت وزنی یا مولی اکسید سیلیسیم به اکسید سدیم که مدول نامیده می‌شود، هویت یافته و خواص نهایی آن مانند چسبندگی، قلیائیت، ویسکوزیته و پایداری حرارتی مستقیماً تحت تأثیر این مدول قرار دارد [۱، ۲]. یکی از چالش‌های اساسی در تولید این محصول، تنظیم همزمان پارامترهای مؤثر بر مدول مانند میزان مصرف سود سوزآور، دانسیته و خلوص چسب سیلیکات ورودی، دما و زمان واکنش است. در بسیاری از واحدهای صنعتی، این تنظیمات هنوز به روش سنتی «آزمون و خطا» و بر اساس تجربه اپراتورها انجام می‌شود. این رویکرد نه تنها زمان‌بر است، بلکه معمولاً به مصرف بیش از حد سود سوزآور (به عنوان یکی از هزینه‌برترین مواد اولیه) و نوسانات کیفی قابل توجه در محصول نهایی منجر می‌شود. از سوی دیگر، افزایش کیفیت محصول (یعنی افزایش مدول و ویسکوزیته مطلوب) اغلب با افزایش مصرف مواد اولیه همراه تصور می‌شود، در حالی که ممکن است با یک تنظیم هوشمندانه بتوان هم کیفیت را ارتقا داد و هم هزینه را کاهش داد. در سال‌های اخیر، روش‌های محاسبات نرم و هوش مصنوعی به ویژه شبکه‌های عصبی مصنوعی (ANN) و الگوریتم‌های بهینه‌سازی فراکاوشی مانند الگوریتم ژنتیک (GA) و الگوریتم ژنتیک با مرتب‌سازی نامغلوب (NSGA-II)، به دلیل توانایی منحصربه‌فرد در مدل‌سازی سیستم‌های غیرخطی و یافتن نقاط بهینه سراسری، توجه بسیاری از پژوهشگران شیمی و مهندسی شیمی را به خود جلب کرده است [۳-۷]. مطالعات متعددی در زمینه کاربرد روش‌های ترکیبی هوشمند در

بهینه‌سازی فرایندهای شیمیایی گزارش شده است [۸-۱۲]. کاتوج و همکاران (۲۰۲۱)، مروری جامع بر الگوریتم ژنتیک، سیر تکاملی، انواع، کاربردها در بهینه‌سازی و زمینه‌های نوظهور مانند محاسبات تکاملی و یادگیری ماشین ارائه دادند [۱۴]. در همین راستا، تای و همکاران (۲۰۲۳) یک استراتژی یادگیری ماشین ترکیبی را برای بهینه‌سازی چندهدفه فرایندهای کاتالیستی پیچیده مانند هیدروکراکینگ ارائه دادند. آنها با درهم‌تنیدن فیزیک‌محور (مدل سینتیک پیوسته) در یک شبکه عصبی مصنوعی کم‌عمق و تلفیق آن با الگوریتم NSGA-II، توانستند با میانگین مربعات خطای کمتر از ۰/۰۱، به طور همزمان گزینش‌پذیری و بازده محصول را بهینه کنند [۱۵]. همچنین آلانی و همکاران (۲۰۲۳) در مقاله مروری خود بر کاربرد الگوریتم‌های تکاملی چندهدفه در راکتورهای تولید مواد شیمیایی، نشان دادند که این الگوریتم‌ها به طور گسترده برای بهینه‌سازی اهداف متضاد مانند اقتصاد، محیط زیست، ایمنی و مصرف انرژی مورد استفاده قرار گرفته‌اند [۱۶]. حسینی و همکاران (۱۳۹۵) با استفاده از شبکه عصبی مصنوعی، خواص فیزیکی سدیم کوسیلیکات را پیش‌بینی کردند و نشان دادند که این روش دقت بالایی در تخمین ویسکوزیته و دانسیته دارد [۴].

با وجود پیشرفت‌های قابل توجه در روش‌های ترکیبی ANN-GA در زمینه فرایندهای پالایشگاهی، پیل‌های سوختی و الکتروشیمیایی [۲۶-۱۷]، کاربرد این رویکرد برای بهینه‌سازی فرایند تولید سدیم کوسیلیکات (به ویژه با هدف کاهش مصرف سود سوزآور) کمتر مورد توجه قرار گرفته است. به عبارت دیگر، شکاف پژوهشی مشخصی در عدم استفاده از مدل‌های هوشمند ترکیبی برای این صنعت خاص وجود دارد که این پژوهش در صدد پر کردن آن برآمده است. اگرچه مدل‌سازی پدیده‌محور می‌تواند درک عمیق‌تری از فیزیک فرایند ارائه دهد، اما در فرایندهای صنعتی مانند تولید سدیم کوسیلیکات، به دلیل ناشناخته بودن سینتیک دقیق واکنش‌های چندفازی، عدم قطعیت در ضرایب ترمودینامیکی و دشواری تعیین شرایط مرزی در مقیاس صنعتی، با چالش‌های جدی مواجه است. در مقابل، مدل‌سازی داده‌محور مبتنی بر شبکه عصبی مصنوعی، بدون نیاز به پیش‌فرض‌های فیزیکی پیچیده، قادر است روابط غیرخطی و پنهان بین متغیرها را مستقیماً از داده‌های واقعی خط تولید استخراج کند. این رویکرد علاوه بر سرعت بالا در پیش‌بینی، امکان به‌روزرسانی مدل با داده‌های جدید و تلفیق با الگوریتم‌های بهینه‌سازی مانند GA را فراهم می‌آورد تا نقاط بهینه‌ای کشف شوند که با روش‌های سنتی قابل دستیابی نیستند.

هدف اصلی این پژوهش، توسعه یک مدل ترکیبی شبکه عصبی مصنوعی و الگوریتم ژنتیک برای بهینه‌سازی فرایند تولید صنعتی سدیم کوسیلیکات در شرکت صنعتی پردیس سبک‌سازان اردکان است. نوآوری پژوهش در آن است که برای اولین بار در صنعت تولید سدیم کوسیلیکات ایران، یک مدل هوشمند ترکیبی با هدف کاهش همزمان مصرف سود سوزآور و افزایش مدول و ویسکوزیته محصول (که به طور سنتی اهداف متضاد تلقی می‌شوند) به کار گرفته شده و بر خلاف پژوهش‌های پیشین که عمدتاً مدل‌سازی تک‌هدفه یا با داده‌های آزمایشگاهی انجام شده است، این پژوهش یک تابع هدف چندمعیاره را در مقیاس صنعتی و با داده‌های واقعی خط تولید پیاده‌سازی می‌کند. همچنین برجستگی این کار در آن است که یافته‌های پژوهش صرفاً در سطح نظری باقی نمی‌ماند، بلکه در خط تولید واقعی پیاده‌سازی و اعتبارسنجی عملی می‌شود و نشان می‌دهد که چگونه با یک رویکرد کم‌هزینه و مبتنی بر داده، بدون نیاز به تغییرات اساسی در تجهیزات، می‌توان هم کیفیت محصول را ارتقا داد و هم هزینه‌های مواد اولیه را کاهش داد.

۲- روش شناسی

۲-۱- فرایند جمع آوری داده‌ها

داده‌های مورد نیاز این پژوهش از خط تولید سدیم کوسیلیکات شرکت صنعتی پردیس سبک‌سازان اردکان در بازه زمانی سال‌های ۱۴۰۲ و ۱۴۰۳ جمع آوری شد. در مجموع ۲۴۵ رکورد عملیاتی معتبر (پس از حذف داده‌های پرت و ناقص) مورد استفاده قرار گرفت. پیش‌پردازش داده‌ها شامل شناسایی و حذف رکوردهای ناقص (داده‌هایی که حداقل یکی از پارامترهای ورودی یا خروجی اصلی در آن‌ها ثبت نشده بود) و حذف داده‌های پرت با استفاده از روش چارک‌ها (به گونه‌ای که رکوردهایی با مقادیر خارج از بازه $[Q_1 - 1.5 \times IQR, Q_3 + 1.5 \times IQR]$ از مجموعه داده حذف شوند) انجام شد. همچنین نرمالایزاسیون تمامی متغیرهای ورودی و خروجی در محدوده $[-1, +1]$ به منظور جلوگیری از غلبه متغیرها با مقیاس بزرگتر بر فرایند یادگیری شبکه عصبی انجام شد. پارامترهای ورودی و خروجی در جدول ۱ ارائه شده است. تمامی اندازه‌گیری‌ها مطابق با استانداردهای داخلی شرکت و با استفاده از دستگاه‌های کالیبره شده (ویسکوزیومتر دیجیتال بروکفیلد مدل DV II Pro، دانسیته‌سنج دیجیتال مدل DA130N، دستگاه تیتراسیون خودکار مدل Metrohm 848) انجام شده است.

جدول ۱: پارامترهای ورودی و خروجی در مدلسازی


Table 1: Input and output parameters in modeling

Variable	Parameter	Description
Input	X_1	Caustic soda consumption (range: 200 to 260 kg/ton of final product)
	X_2	Inlet silica density at 20 °C (range: 1.40 to 1.56 g/cm ³)
Output	Y_1	Product modulus: (wt% SiO ₂)/(wt% Na ₂ O) × 1.032 (target range: 2.3 to 2.8)
	Y_2	Viscosity at 25 °C (unit: cP, range: 350 to 450)
	Y_3	Final product density at 20 °C (unit: g/cm ³ , range: 1.45 to 1.55)

۲-۲- شبکه عصبی مصنوعی

شبکه‌های عصبی مصنوعی یکی از قدرتمندترین ابزارهای محاسبات نرم در مدل‌سازی سیستم‌های غیرخطی، پیچیده و با دانش اندک از فیزیک داخلی فرایند هستند. این روش با الهام از ساختار شبکه عصبی زیستی، از لایه‌هایی از نرون‌های مصنوعی تشکیل شده است که هر نرون با دریافت ورودی‌های وزنی، اعمال تابع فعال‌سازی و تولید خروجی، قادر به یادگیری الگوهای پنهان در داده‌ها می‌باشد. در این پژوهش، از یک شبکه پرسپترون چندلایه (MLP) استفاده شده است که متداول‌ترین معماری در مسائل پیش‌بینی و مدل‌سازی فرایندهای شیمیایی است.

Multi-layer Neural Network Architecture



شکل ۱: معماری شبکه عصبی چند لایه توسعه داده شده برای مدل سازی

Figure 1: Architecture of the developed multi-layer neural network for modeling

در شبکه عصبی طراحی شده در این پژوهش (شکل ۱)، لایه ورودی شامل ۲ نرون است که به ترتیب، مقادیر نرمالایز شده مصرف سود سوزآور و دانسیته چسب سیلیکات ورودی را دریافت می‌کنند. نرمالایزاسیون داده‌ها در محدوده $[-1, +1]$ انجام شد تا از غلبه متغیرهای با مقیاس بزرگتر بر فرایند یادگیری جلوگیری شود. لایه‌های پنهان شامل دو لایه پنهان که هر یک دارای ۱۰ نرون می‌باشند. برای تعیین معماری بهینه شبکه، روش آزمون و خطای سیستماتیک با ارزیابی عملکرد شبکه بر روی داده‌های اعتبارسنجی بر اساس معیار میانگین مربعات خطا به کار گرفته شد. معماری‌های مختلف با تعداد لایه‌های پنهان یک و دو و تعداد نرون‌های متغیر (۸، ۱۰، ۱۲) مورد بررسی قرار گرفتند. نتایج نشان داد که شبکه‌های تک‌لایه علی‌رغم سادگی، به دلیل غیرخطی بودن روابط، قادر به پیش‌بینی دقیق خروجی‌ها نبودند. انتخاب دو لایه پنهان به دلیل پیچیدگی نسبتاً بالای روابط غیرخطی بین ورودی و خروجی و همچنین مشاهده عملکرد بهتر در مرحله آزمون و خطا صورت گرفت. شبکه‌های دو لایه پنهان با ۱۰ نرون در هر لایه، بهترین عملکرد را با کمترین خطای اعتبارسنجی و بدون وقوع بیش‌برازش ارائه دادند. افزایش تعداد نرون‌ها از ۱۰ به ۱۲ منجر به بیش‌برازش (افزایش خطای اعتبارسنجی) شد، در حالی که کاهش آن به ۸ نرون، دقت مدل را به طور محسوسی کاهش داد. بنابراین، معماری ۲-۱۰-۱۰-۳ به عنوان معماری بهینه انتخاب شد.

تابع فعالسازی در لایه‌های پنهان از تابع تانژانت هیپربولیک (Tanh) با دامنه خروجی $(-1, +1)$ استفاده شد. دلیل انتخاب این تابع، توانایی آن در مدل‌سازی روابط غیرخطی متقارن و عملکرد بهتر آن نسبت به تابع سیگموئید لوجستیک (Log-Sigmoid) در داده‌هایی با میانگین نزدیک به صفر بود. لایه خروجی شامل ۳ نرون است که به ترتیب مقادیر پیش‌بینی شده مدول، ویسکوزیته و دانسیته خروجی را تولید می‌کنند. تابع فعالسازی در لایه خروجی، از نوع خطی انتخاب شد. این

انتخاب به دلیل ماهیت مسئله رگرسیون (پیش‌بینی مقادیر پیوسته) است. در مسائل رگرسیون، محدود کردن خروجی با توابعی مانند سیگموئید یا تانژانت هیپربولیک، دامنه پاسخ را محدود کرده و خطا را افزایش می‌دهد. برای آموزش شبکه، از الگوریتم لوبز-مارکوارت استفاده شد. این الگوریتم یکی از سریع‌ترین و کارآمدترین روش‌های آموزش شبکه‌های عصبی با اندازه کوچک تا متوسط (کمتر از چندصد وزن) است که ترکیبی از مزایای روش گرادیان نزولیو روش گلو-نیوتن را داراست [۱۰]. تابع هزینه در این الگوریتم، میانگین مربعات خطا تعریف شد که مطابق معادله (۱) محاسبه می‌شود. در این معادله، n تعداد کل نمونه‌های آموزش، Y_i مقدار واقعی و Y_i^o مقدار پیش‌بینی شده توسط شبکه است.

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - Y_i^o)^2 \quad (\text{معادله ۱})$$

مجموعه داده‌های گردآوری شده به سه زیرمجموعه مستقل با نسبت‌های زیر تقسیم شدند. ۱۷۲ رکورد (۷۰٪ از کل داده‌ها) به عنوان داده‌های آموزش برای به‌روزرسانی وزن‌ها و بایاس‌های شبکه استفاده شد. ۳۷ رکورد (۱۵٪ از کل داده‌ها) به عنوان داده‌های اعتبارسنجی برای نظارت بر عملکرد شبکه در حین آموزش و جلوگیری از بیش‌برازش به کاربرده شد. ۳۶ رکورد (۱۵٪ از کل داده‌ها) به عنوان داده‌های آزمون برای ارزیابی نهایی و مستقل مدل آموزش دیده استفاده شد. برای جلوگیری از پدیده بیش‌برازش، از روش توقف زودهنگام استفاده شد. در این روش، به ازای هر دوره آموزش، خطای داده‌های اعتبارسنجی محاسبه می‌شود. اگر خطای اعتبارسنجی به مدت ۱۵ دوره متوالی بهبود نیابد (افزایش یابد یا ثابت بماند)، فرایند آموزش متوقف می‌گردد و وزن‌های مربوط به دوره با کمترین خطای اعتبارسنجی به عنوان وزن‌های نهایی مدل ذخیره می‌شوند. شایان ذکر است که با وجود نسبت تقریباً ۱ به ۱ بین تعداد پارامترهای قابل آموزش شبکه و تعداد داده‌های آموزش، چندین شاخص معتبر حاکی از عدم وقوع پدیده بیش‌برازش در مدل توسعه‌یافته است. روش توقف زودهنگام با معیار ۱۵ دوره عدم بهبود در خطای اعتبارسنجی، مانع از همگرایی کامل شبکه بر روی داده‌های آموزش شد و منحنی‌های خطای آموزش و اعتبارسنجی که در ادامه ارایه شده است، فاصله معناداری با یکدیگر ندارند.

عملکرد مدل نهایی بر روی داده‌های آزمون با استفاده از سه معیار ضریب تعیین (R^2)، میانگین مربعات خطا و میانگین خطای مطلق درصدی مورد ارزیابی قرار گرفت. تمامی مراحل مدل‌سازی شامل نرم‌لایزاسیون داده‌ها، طراحی معماری شبکه، آموزش، توقف زودهنگام و محاسبه معیارهای ارزیابی در محیط نرم‌افزاری MATLAB نسخه 2024a و با استفاده از جعبه ابزار شبکه عصبی انجام شد.

۲-۳- الگوریتم ژنتیک

در این پژوهش، از الگوریتم ژنتیک به عنوان یک روش بهینه‌سازی فراکاوشی برای یافتن شرایط بهینه عملیاتی استفاده شده است. مدل شبکه عصبی مصنوعی آموزش‌دیده بخش قبل به عنوان تابع هدف در الگوریتم ژنتیک به کار گرفته شد. به عبارت دیگر، به جای آنکه یک تابع ریاضی صریح و تحلیلی از فرایند داشته باشیم، از مدل جعبه سیاه ANN به عنوان شبیه‌ساز فرایند استفاده می‌شود. الگوریتم ژنتیک با ارسال مقادیر مختلف از پارامترهای ورودی (X_1 و X_2)، به مدل ANN، خروجی‌های مربوطه (Y_1, Y_2, Y_3) را دریافت کرده و سپس بر اساس یک تابع ترکیبی که هم کیفیت و هم هزینه را در

نظر می‌گیرد، به هر جواب یک امتیاز اختصاص می‌دهد. سپس با تکرار این فرایند در طول نسل‌های متوالی، جمعیت جواب‌ها را به سمت شرایط بهینه هدایت می‌کند.

با توجه به ماهیت چندهدف مسئله بهینه‌سازی در این پژوهش، تابع تناسب (fitness) به گونه‌ای تعریف شد که سه هدف را به طور همزمان پوشش دهد. هدف اول، بهبود کیفیت اول که افزایش مدول محصول (Y_1) با بالاترین اهمیت بود. هدف دوم، بهبود کیفیت دوم که افزایش ویسکوزیته محصول (Y_2) با اهمیت متوسط بود. هدف سوم، کاهش هزینه که از طریق کاهش مصرف سود سوزآور (X_1) اهمیت اقتصادی مسئله را توجیه می‌کرد. برای تبدیل این سه هدف به یک تابع عددی، از روش مجموع وزنی استفاده شد. ابتدا هر یک از متغیرهای هدف (Z) با استفاده از روش نرمال‌سازی کمینه-بیشینه مطابق معادله (۲) نرمالایزاسیون شدند تا اثر اختلاف مقیاس حذف گردد. سپس تابع تناسب مطابق معادله (۳) محاسبه شد.

$$Z_{norm} = \frac{Z_{actual} - Z_{min}}{Z_{max} - Z_{min}} \quad (\text{معادله ۲})$$

$$Fitness = w_1 \times Y_{1,norm} + w_2 \times Y_{2,norm} - w_3 \times X_{1,norm} \quad (\text{معادله ۳})$$

ضرایب وزنی (w_1, w_2, w_3) بر اساس نظرسنجی از متخصصان فرایند و کارشناسان کنترل کیفیت شرکت و با توجه به اولویت‌های استراتژیک واحد صنعتی، به صورت تجربی و پس از چندین اجرای آزمایشی، به ترتیب مقادیر $0/4$ ، $0/3$ و $0/3$ تعیین شدند. علامت منفی در جمله سوم معادله (۳)، به این دلیل است که کاهش مصرف سود (یعنی مقدار نرمالایز شده کوچک‌تر) مطلوب ماست، در حالی که در دو جمله اول، افزایش کیفیت (مقدار نرمالایز شده بزرگتر) مورد نظر است. در این تابع تناسب، قیود مسئله نیز لحاظ شده است. بدین معنا که مقادیر X_1 و X_2 تنها در محدوده مجاز عملیاتی (مشخص شده در جدول ۱) مجاز به جستجو هستند. هر جوابی که خارج از این محدوده باشد، به طور خودکار مقدار تابع تناسب بسیار پایینی (معمولاً صفر یا منفی) دریافت می‌کند. همچنین یک قید سختگیرانه در مورد ویسکوزیته محصول (Y_2) نیز اعمال شد که مقدار آن نباید از 450 سانتی پواز بیشتر شود، زیرا محصول بیش از حد غلیظ برای کاربردهای بعدی نامناسب خواهد بود. پارامترهای الگوریتم ژنتیک تأثیر مستقیمی بر سرعت همگرایی و کیفیت جواب نهایی دارند. در این پژوهش، پس از انجام آزمون‌های متعدد (حدود 30 اجرای آزمایشی با ترکیب پارامترهای مختلف)، مقادیر بهینه پارامترها مطابق جدول ۲ انتخاب شدند. فرایند بهینه‌سازی با الگوریتم ژنتیک به صورت گام به گام زیر انجام شد.

گام ۱- مقداردهی اولیه: جمعیتی به اندازه 100 کروموزوم به صورت تصادفی در فضای جواب تولید شد. هر کروموزوم شامل دو ژن بود. ژن اول مربوط به مصرف سود سوزآور (X_1) و ژن دوم مربوط به دانسیته چسب ورودی (X_2).

گام ۲- ارزیابی: هر کروموزوم به مدل ANN داده شد و مقادیر Y_1, Y_2, Y_3 توسط شبکه پیش‌بینی شد. سپس مقدار تابع تناسب برای هر کروموزوم بر اساس تابع هدف محاسبه شد.

گام ۳- انتخاب: با استفاده از روش چرخ رولت، کروموزوم‌هایی که تابع تناسب بالاتری داشتند، شانس بیشتری برای انتخاب به عنوان والد جهت تولید نسل بعد دریافت کردند.

گام ۴- ترکیب: با احتمال $0/8$ ، جفت والدین انتخاب شده، با روش یک نقطه‌ای با یکدیگر ترکیب شده و دو کروموزوم فرزند تولید کردند. نقطه برش به صورت تصادفی بین دو ژن انتخاب شد.

گام ۵- جهش: با احتمال ۰/۰۵ هر ژن از کروموزوم‌های فرزند تحت تأثیر جهش گاوسی قرار گرفت که به آن یک مقدار تصادفی کوچک از توزیع نرمال با میانگین صفر و انحراف معیار ۰/۰۵ اضافه می‌شد.

گام ۶- جایگزینی: نسل جدید (۱۰۰ کروموزوم) از ترکیب بهترین کروموزوم‌های نسل قبل و کروموزوم‌های فرزند جدید تشکیل شد.

گام ۷- تکرار مراحل ۲ تا ۶ تا رسیدن به معیار توقف (عدم بهبود تابع تناسب در ۳۰ نسل متوالی یا رسیدن به ۲۰۰ نسل) تکرار شد.

جدول ۲: پارامترهای تنظیم شده الگوریتم ژنتیک

Table 2: Tuned parameters of the genetic algorithm

Parameter	Selected value	Reason for selection
Population size	100	Balance between solution diversity and computational speed
Number of generations	200	Ensuring complete convergence
Crossover rate	0.8	High probability of producing offspring from superior parents
Mutation rate	0.05	Preventing entrapment in local optima
Selection method	Roulette wheel	Selection chance proportional to fitness value
Crossover method	Single-point	Simplicity and suitable efficiency for the two-variable problem
Mutation method	Gaussian mutation	Creating diversity with small, natural changes around the current value
Stopping criterion	No fitness improvement for 30 consecutive generations	Preventing unnecessary computations after convergence

برای اطمینان از تکرارپذیری نتایج، الگوریتم ژنتیک ۳ بار مجزا با دانه‌های تصادفی متفاوت اجرا شد. در هر سه اجرا، نتایج نهایی (مقادیر بهینه) حداکثر ۲٪ با یکدیگر اختلاف داشتند که نشان‌دهنده پایداری و تکرارپذیری مناسب الگوریتم است. منحنی همگرایی میانگین تابع تناسب در طول نسل‌ها نشان داد که حدود ۸۵ نسل اول، کاهش سریع تابع هزینه (میانگین مربعات خطا) اتفاق می‌افتد و پس از نسل ۱۲۰، میانگین تابع تناسب به یک مقدار سیرشده می‌رسد که بیانگر همگرایی الگوریتم است. الگوریتم ژنتیک در محیط MATLAB نسخه 2024a و با استفاده از جعبه ابزار بهینه‌سازی جهانی و تابع GA پیاده‌سازی شد. برای تلفیق با مدل ANN، مدل آموزش‌دیده شبکه عصبی به عنوان یک تابع به الگوریتم ژنتیک معرفی شد تا در هر مرحله ارزیابی، خروجی‌های مورد نیاز را محاسبه نماید.

۲-۴- پیاده‌سازی عملی نتایج بهینه سازی

پس از تعیین نقاط بهینه توسط GA، شرایط پیشنهادی شامل مصرف سود سوزآور ۲۱۵ کیلوگرم بر تن و دانسیته چسب ورودی ۱/۱۵۲ گرم بر سانتی‌متر مکعب، به مدت ۷ روز کاری متوالی در خط تولید شرکت اجرا شد. این بازه زمانی به گونه‌ای انتخاب شد تا اثرات نوسانات روزانه خوراک و شرایط عملیاتی بر نتایج لحاظ شود. در طول این دوره، در هر روز کاری ۳ نمونه از محصول نهایی (در ساعات ابتدا، میانه و انتهای روز کاری) برداشته شد که مجموعاً ۲۱ نمونه حاصل شد.

تمامی نمونه‌ها تحت آزمایش‌های استاندارد کنترل کیفیت شامل تعیین مدول (با تیتراسیون)، ویسکوزیته (با ویسکومتر بروکفیلد) و دانسیته (با دانسیته‌سنج دیجیتال) قرار گرفتند.

جدول ۳: نتایج پیاده‌سازی عملی شرایط بهینه در خط تولید در مقایسه با شرایط پایه (میانگین سالانه ۱۴۰۲-۱۴۰۳)

Table 3: Results of implementing optimal conditions in the production line compared to baseline conditions

Parameter	Baseline	Min (optimal)	Max (optimal)	Mean (optimal)	Standard deviation	Absolute improvement	Improvement (%)
Caustic soda consumption (kg/ton)	242	210	225	217.3	3.8	-24.7	-10.2
Inlet density (g/cm ³)	1.48	1.51	1.53	1.518	0.006	+0.038	+2.6
Product modulus (ratio)	2.41	2.54	2.68	2.60	0.04	+0.19	+7.9
Product viscosity (cP)	385	408	435	421.5	7.2	+36.5	+9.5
Output density (g/cm ³)	1.495	1.500	1.512	1.506	0.003	+0.011	+0.7


نتایج حاصل از این ۲۱ نمونه به همراه میانگین حسابی ۲۴۵ رکورد معتبر تولیدی شرکت در سال‌های ۱۴۰۲ و ۱۴۰۳ (شرایط پایه) در جدول ۳ گزارش شده است. همان‌طور که مشاهده می‌شود، میانگین مدول محصول از ۲/۴۱ در شرایط پایه به ۲/۶۰ در شرایط بهینه رسیده است (افزایش ۷/۷۹ درصدی). ویسکوزیته نیز با ۹/۵ درصد افزایش، از ۳۸۵ به ۴۲۱/۵ سانتی‌پواز ارتقا یافته است. در مقابل، مصرف سود سوزآور با کاهش ۱۰/۲ درصدی از ۲۴۲ به ۲۱۷/۳ کیلوگرم بر تن رسیده است. نتایج آزمون‌های آماری، معناداری آماری تمامی بهبودها را با p-value کمتر از ۰/۰۰۱ تأیید می‌کند. انحراف معیار پایین متغیرهای خروجی (مدول با ۰/۰۴ و ویسکوزیته با ۷/۲) نشان‌دهنده پایداری مطلوب فرایند در شرایط بهینه است.

۳- نتایج و بحث

۳-۱- نتایج مدل‌سازی شبکه عصبی مصنوعی

پس از انجام مراحل آموزش، اعتبارسنجی و آزمون شبکه عصبی طراحی شده با معماری ۲-۱۰-۱۰-۳، عملکرد مدل بر روی داده‌های آزمون (۳۶ رکورد که هرگز در فرایند آموزش استفاده نشده‌اند) مورد ارزیابی قرار گرفت. شبکه عصبی پس از ۱۲۸ دوره آموزش به همگرایی رسید، به گونه‌ای که خطای داده‌های اعتبارسنجی در این دوره به حداقل مقدار خود یعنی ۰/۰۰۳۴ دست یافت و روش توقف زودهنگام در دوره ۱۴۳ فرایند آموزش را متوقف کرد. نمودار کاهش خطای آموزش و اعتبارسنجی در طی دوره‌های مختلف (شکل ۲) نشان می‌دهد که هیچ پدیده بیش‌برازش رخ نداده است، زیرا خطای اعتبارسنجی همواره روندی مشابه با خطای آموزش داشته و فاصله معناداری بین این دو منحنی مشاهده نمی‌شود. نتایج ارائه شده در جدول ۴ نشان می‌دهد که مدل شبکه عصبی توسعه‌یافته، دقت بسیار خوبی در پیش‌بینی هر سه شاخص کیفی محصول دارد. ضریب تعیین برای مدول برابر ۰/۹۴۵ که بیانگر آن است که مدل قادر به توضیح ۹۴/۵ درصد از تغییرات این پارامتر مهم کیفی می‌باشد. بالاترین مقدار میانگین خطای مطلق درصدی مربوط به ویسکوزیته با ۳/۸ درصد

است که همچنان در محدوده قابل قبول برای کاربردهای صنعتی قرار دارد. این خطای نسبتاً بالاتر برای ویسکوزیته می‌تواند به دو دلیل اصلی نسبت داده شود: اول، حساسیت بالای ویسکوزیته به نوسانات جزئی دما در حین نمونه‌برداری و اندازه‌گیری، و دوم، تأثیرپذیری بیشتر این پارامتر از عواملی مانند توزیع اندازه ذرات سیلیس که در مدل به عنوان ورودی لحاظ نشده است. با این وجود، مقدار میانگین خطای مطلق درصدی کمتر از ۴ درصد برای یک مدل صنعتی با داده‌های واقعی خط تولید، عملکردی بسیار رضایت‌بخش محسوب می‌شود. مقدار میانگین مربعات خطا پایین برای مدول (۰/۰۰۲۸) و دانسیته خروجی (۰/۰۰۰۹) نیز نشان‌دهنده دقت بالای مدل در پیش‌بینی این پارامترهاست. به طور کلی، نتایج جدول ۴ تأیید می‌کند که شبکه عصبی طراحی شده با موفقیت روابط غیرخطی پیچیده بین خوراک (مصرف سود و دانسیته چسب ورودی) و خروجی‌های کیفی محصول را یاد گرفته و می‌تواند به عنوان یک شبیه‌ساز فرایند معتبر در مرحله بهینه‌سازی مورد استفاده قرار گیرد.




شکل ۲- نمودار عملکرد شبکه عصبی توسعه داده شده، کاهش میانگین مربعات خطا بر حسب دوره‌های آموزش
Figure 2: Performance diagram of the developed neural network — reduction MSE versus training epochs

جدول ۴ - شاخص‌های عملکرد مدل ANN برای پیش‌بینی هر یک از خروجی‌ها (داده‌های آزمون)

Table 4: Performance metrics of the ANN model for predicting each of the outputs (test data)

Output	R ²	MSE	MAPE (%)
Modulus	0.945	0.0028	2.1
Viscosity	0.926	14.2	3.8
Output density	0.932	0.0009	0.7



شکل ۳- نمودارهای رگرسیون نتایج پیش‌بینی شبکه عصبی


Figure 3: Regression plots of neural network prediction results

شکل ۳ نمودارهای رگرسیون مقادیر پیش‌بینی شده در مقابل مقادیر واقعی را برای داده‌های آزمون نشان می‌دهد. انطباق بالای نقاط بر خط ۴۵ درجه در هر سه پارامتر مدول، ویسکوزیته و دانسیته، بیانگر دقت بالای شبکه عصبی در بازه عملیاتی هدف است. انتخاب ترکیب توابع فعال‌سازی Tanh و Linear نقشی کلیدی در دقت مدل ایفا کرد. تابع تانژانت هیپربولیک در لایه‌های پنهان، با نگاشت متقارن داده‌ها حول صفر، توانست روابط غیرخطی و پیچیده حاکم بر پارامتر ویسکوزیته را که رفتاری حساس و غیرخطی دارد، به‌خوبی استخراج کند. در مقابل، استفاده از تابع خطی در لایه خروجی، بدون محدود کردن دامنه پاسخ، اجازه پیش‌بینی دقیق مقادیر پیوسته مدول و دانسیته را فراهم ساخت و از بروز خطای اشباع در تخمین مقادیر حداکثری جلوگیری نمود. عملکرد مدل حاضر در پیش‌بینی مدول با میانگین خطای مطلق درصدی برابر با ۲/۱٪ در مقایسه با نتایج خسروی و همکاران [۳] که برای پیش‌بینی ویسکوزیته محلول‌های سدیم کوسیلیکات به میانگین خطای مطلق درصدی حدود ۴/۵٪ دست یافتند، بهبود قابل توجهی را نشان می‌دهد. این بهبود را می‌توان به استفاده از معماری دو لایه پنهان و همچنین استفاده از داده‌های واقعی خط تولید (به جای داده‌های آزمایشگاهی) نسبت داد که تنوع بیشتری از شرایط عملیاتی را پوشش می‌دهد. دقت بالای مدل در مرحله آزمون (R^2 بالاتر از ۰/۹۴) و خطای میانگین مطلق درصدی پایین، اطمینان لازم را جهت استفاده از این شبکه عصبی به عنوان تابع هدف در الگوریتم ژنتیک فراهم می‌آورد تا شرایط بهینه عملیاتی استخراج گردد.

۳-۲- نتایج بهینه‌سازی با الگوریتم ژنتیک

پس از تلفیق مدل معتبر ANN به عنوان تابع هدف با الگوریتم ژنتیک، فرایند بهینه‌سازی با پارامترهای تنظیم شده در جدول ۲ اجرا شد. الگوریتم پس از حدود ۸۵ نسل کاهش سریع تابع هزینه (میانگین مربعات خطا) را تجربه کرد و تا نسل ۱۲۰ به همگرایی کامل رسید، به طوری که مقدار میانگین تابع تناسب در جمعیت، به مقدار سیرشده ۰/۸۶ تثبیت شد. منحنی همگرایی (شکل ۴) نشان می‌دهد که در ۳۰ نسل اول، بهبود تابع تناسب بسیار سریع بوده و سپس شیب منحنی

کاهش یافته و پس از نسل ۱۲۰ تقریباً افقی می‌شود. این رفتار همگرایی سه مرحله‌ای (کاهش سریع، کاهش تدریجی و سیرشدگی) مشخصه الگوریتم‌های فراکاوشی موفق است. کاهش سریع در ۳۰ نسل اول نشان‌دهنده اکتشاف کارآمد فضای جواب توسط ترکیب و جهش است. فلات شدن پس از نسل ۱۲۰ بیانگر آن است که الگوریتم به ناحیه بهینه سراسری رسیده و نوسانات ناشی از بهینه‌های محلی را پشت سر گذاشته است. مقدار نهایی تابع تناسب برابر ۰/۸۶ با توجه به حداکثر نظری ۱/۰، بیانگر دستیابی به راه‌حلی با تطابق ۸۶ درصدی با اهداف مطلوب کیفی-اقتصادی است.



شکل ۴- منحنی همگرایی در بهینه سازی ANN-GA

Figure 4: Convergence curve in ANN-GA optimization

نتایج ارائه شده در جدول ۵ حاوی یک یافته بسیار مهم و غیربدیهی است. بر خلاف تصور رایج در صنعت که افزایش کیفیت محصول (مدول بالاتر و ویسکوزیته بیشتر) تنها با افزایش مصرف مواد اولیه (به ویژه سود سوزآور) امکان‌پذیر است، مدل ترکیبی ANN-GA موفق به کشف منطقه بهینه‌ای در فضای پارامترها شد که در آن همزمان با کاهش ۱۱/۲ درصدی مصرف سود سوزآور، مدول محصول ۸/۷ درصد و ویسکوزیته ۱۰/۴ درصد افزایش می‌یابد. کلید این موفقیت، افزایش جزئی دانسیته چسب سیلیکات ورودی به میزان ۲/۷ درصد (از ۱/۴۸۰ به ۱/۵۲۰ گرم بر سانتی‌متر مکعب) است.

جدول ۵: مقایسه شرایط عملیاتی قبل و بعد از بهینه‌سازی (مقادیر پیشنهادی مدل ANN-GA)

Table 5: Comparison of operating conditions before and after optimization


Parameter	Baseline (mean 2023-2024)	Optimal condition proposed (ANN-GA)	Absolute change	Change (%)
Caustic soda consumption (kg/ton)	242.0	215.0	-27.0	-11.2
Inlet glue density (g/cm ³)	1.480	1.520	+0.040	+2.7
Product modulus (ratio)	2.41	2.62	+0.21	+8.7
Product viscosity (cP)	385	425	+40	+10.4
Output density (g/cm ³)	1.495	1.505	+0.010	+0.7

افزایش دانسیته چسب ورودی به معنای افزایش غلظت ماده جامد فعال ($\text{SiO}_2 + \text{Na}_2\text{O}$) در خوراک اولیه است که باعث می‌شود واکنش بین سیلیس و سود سوزآور با بازده بالاتری انجام شود. به عبارت دیگر، مدل موفق به شناسایی یک

جایگزینی هوشمند بین دو ورودی شده است: با افزایش جزئی و کم‌هزینه دانسیته چسب ورودی، می‌توان مصرف سود سوزآور (که هزینه بالاتری دارد) را به میزان قابل توجهی کاهش داد و همزمان کیفیت محصول را نیز بهبود بخشید. شکل ۵ (الف) بررسی سطح پاسخ حاصل از مدل را نشان می‌دهد که تأثیر دانسیته چسب ورودی بر مدول محصول، غیرخطی و با یک آستانه مشخص در حدود $1/50$ گرم بر سانتی‌متر مکعب است. در دانسیته‌های کمتر از این آستانه، افزایش مصرف سود تأثیر غالب بر مدول دارد، اما در دانسیته‌های بالاتر از آستانه، اثر متقابل مثبتی بین دو پارامتر مشاهده می‌شود که منجر به نقطه بهینه کشف شده می‌گردد. این تغییر رفتار در نمودار کانتور با تغییر جهت خطوط تراز و همگرایی آن‌ها به سمت ناحیه بهینه کاملاً مشهود است؛ جایی که مدل با بهره‌گیری از هم‌افزایی متغیرها، موفق شده است بر محدودیت‌های عملیاتی غلبه کرده و علی‌رغم کاهش معنی‌دار در مصرف مواد اولیه، پایداری و ارتقای شاخص‌های کیفی محصول را در یک ساختار غیرخطی و پیچیده تضمین نماید.

بررسی سطح پاسخ ویسکوزیته (شکل ۵ (ب)) رفتار غیرخطی و حساس این پارامتر را نسبت به تغییرات دانسیته چسب ورودی نشان می‌دهد. برخلاف مدول که آستانه مشخصی در $1/50$ گرم بر سانتی‌متر مکعب داشت، ویسکوزیته در کل محدوده مورد بررسی (دانسیته چسب $1/40$ تا $1/56$ گرم بر سانتی‌متر مکعب)، افزایشی تقریباً نمایی با افزایش دانسیته چسب ورودی از خود نشان می‌دهد. در دانسیته‌های کمتر از $1/48$ گرم بر سانتی‌متر مکعب، تأثیر مصرف سود بر ویسکوزیته ناچیز است (شیب کمتر از ۵)، اما در دانسیته‌های بالاتر (نزدیک به $1/52$ گرم بر سانتی‌متر مکعب)، افزایش مصرف سود از 220 به 260 کیلوگرم بر تن، ویسکوزیته را حدود 15 سانتی‌پواز افزایش می‌دهد. در نقطه بهینه کشف شده (دانسیته چسب $1/52$ و مصرف سود 215)، ویسکوزیته به 425 سانتی‌پواز رسیده که در محدوده مطلوب ($350-450$) قرار دارد و نسبت به شرایط پایه (385 سانتی‌پواز) افزایش $10/4$ درصدی را نشان می‌دهد. شیب تند منحنی‌های تراز در این ناحیه (تغییرات حدود 30 سانتی‌پواز به ازای هر $0/01$ افزایش دانسیته چسب)، نشان‌دهنده حساسیت بالای ویسکوزیته به تغییرات جزئی این پارامتر است که لزوم کنترل دقیق آن را در خط تولید تأیید می‌کند. نمودار سطح پاسخ دانسیته خروجی که در شکل ۵ (ج) ارایه شده، الگوی متفاوتی نسبت به دو پارامتر قبلی نشان می‌دهد.

مطابق شکل ۵ (ج)، دانسیته خروجی رفتاری تقریباً خطی و افزایشی با هر دو پارامتر ورودی دارد، اما شدت تأثیر دانسیته چسب ورودی به مراتب بیشتر از مصرف سود است. بر اساس مشتق جزئی تخمینی از سطح پاسخ، ضریب حساسیت برای دانسیته چسب ورودی حدود $0/75$ و برای مصرف سود حدود $0/25$ محاسبه شده است. در محدوده عملیاتی، دانسیته خروجی از $1/495$ (شرایط پایه، با مصرف سود 242 و دانسیته چسب $1/48$) به $1/506$ (نقطه بهینه، با مصرف سود 215 و دانسیته چسب $1/52$) رسیده است که افزایشی $0/7$ درصدی (معادل $0/011$ گرم بر سانتی‌متر مکعب) را نشان می‌دهد. خطوط تراز در این نمودار تقریباً موازی و با فاصله نسبتاً یکنواخت (هر خط تراز معادل تغییر $0/005$ واحد دانسیته خروجی) هستند که تأییدکننده رفتار خطی و قابل پیش‌بینی این پارامتر است. این ویژگی، کنترل دانسیته خروجی را نسبت به دو پارامتر دیگر ساده‌تر می‌سازد.



شکل ۵- منحنی سطح پاسخ و نمودار کانتور اثر متقابل مصرف سود سوزآور و دانسیته چسب بر: (الف) مدول، (ب) ویسکوزیته و (ج) دانسیته محصول

Figure 5: Response surface and contour plots of the interaction effect of caustic soda consumption and adhesive density on: (a) modulus, (b) viscosity, and (c) product density

۳-۳- پیاده‌سازی عملی و اعتبارسنجی مدل‌سازی

به منظور تأیید قابلیت اطمینان مدل ترکیبی ANN-GA در شرایط واقعی تولید، شرایط بهینه پیشنهادی شامل مصرف سود سوزآور ۲۱۵ کیلوگرم بر تن و دانسیته چسب ورودی ۱/۵۲ گرم بر سانتی‌متر مکعب، به مدت ۷ روز کاری متوالی (۳ نوبت کاری در هر روز) در خط تولید شرکت اجرا شد. در طول این دوره، از هر شیفت کاری ۳ نمونه از محصول نهایی (در ساعات ابتدا، میانه و انتهای شیفت) برداشت شد که مجموعاً ۲۱ نمونه حاصل شد. تمامی نمونه‌ها تحت آزمایش‌های استاندارد کنترل کیفیت شامل تعیین مدول (با تیتراسیون)، ویسکوزیته (با ویسکومتر بروکفیلد) و دانسیته (با دانسیته‌سنج دیجیتال) قرار گرفتند.

نتایج ارائه شده در جدول ۶ نشان می‌دهد که مدل ترکیبی ANN-GA از دقت پیش‌بینی بسیار خوبی برخوردار است. خطای نسبی پیش‌بینی برای تمامی پارامترهای اصلی کمتر از ۱ درصد است که در یک مسئله صنعتی با داده‌های واقعی خط تولید، عملکردی عالی محسوب می‌شود. کمترین خطای نسبی مربوط به دانسیته خروجی (۰/۱ درصد) و بیشترین آن مربوط به مصرف سود (۱/۱- درصد) است. هرچند نتایج عملی بسیار نزدیک به پیش‌بینی‌های مدل است، اما اختلافات جزئی مشاهده شده را می‌توان به عوامل مانند نوسانات دمایی راکتور، خطای انسانی در تنظیم خوراک و تغییرات کیفی بین محموله‌ها نسبت داد.

جدول ۶: مقایسه نتایج پیش‌بینی مدل ANN-GA با نتایج پیاده‌سازی عملی

Table 6: Comparison of the ANN-GA model prediction results with the practical implementation results

Parameter	ANN-GA prediction	Practical results (mean of 21 samples)	Absolute deviation	Relative error (%)	Practical standard deviation
Caustic soda consumption (kg/ton)	215.0	217.3	2.3	-1.1	3.8
Inlet density (g/cm ³)	1.520	1.518	-0.002	-0.1	0.006
Product modulus (ratio)	2.62	2.60	-0.02	-0.8	0.04
Product viscosity (cP)	425	421.5	-3.5	-0.8	7.2
Output density (g/cm ³)	1.505	1.506	0.001	+0.1	0.003

دمای واکنش در طول شیفت‌های مختلف کاری (به ویژه شیفت شب) ممکن است بین ۲ تا ۵ درجه سانتی‌گراد نوسان داشته باشد، در حالی که مدل ANN دمای ثابت را فرض کرده است. ویسکوزیته به شدت به دما حساس است و این عامل می‌تواند توجیه‌کننده بخشی از خطای ۰/۸ درصدی این پارامتر باشد. تنظیم دقیق دانسیته چسب ورودی روی مقدار ۱/۵۲ گرم بر سانتی‌متر مکعب در تمام شیفت‌ها با چالش مواجه بود.

انحراف معیار ۰/۰۰۶ برای این پارامتر (مطابق جدول ۶) نشان‌دهنده نوسانات جزئی در مقدار واقعی اعمال شده است. سود سوزآور و چسب سیلیکات مصرفی در طول ۷ روز اجرای طرح، از محموله‌های مختلف تأمین شده‌اند. تفاوت در خلوص و توزیع اندازه ذرات این مواد اولیه می‌تواند تأثیر جزئی بر نتایج نهایی داشته باشد. ضمناً مدل ANN تنها بر اساس دو ورودی اصلی (مصرف سود و دانسیته چسب) ساخته شده است. عواملی مانند دما، زمان واکنش و درصد رطوبت که در عمل

می‌توانند نوساناتی داشته باشند، در مدل لحاظ نشده‌اند. با توجه به خطای نسبی کمتر از ۱ درصد بین پیش‌بینی مدل و نتایج عملی، همچنین معناداری آماری تمام بهبودها، می‌توان نتیجه گرفت که مدل ترکیبی ANN-GA توسعه‌یافته از اعتبار و قابلیت اطمینان بالایی برای کاربرد در مقیاس صنعتی برخوردار است. این مدل می‌تواند به عنوان یک ابزار کمکی تصمیم‌گیری در تنظیم پارامترهای تولید و همچنین در مواجهه با تغییرات کیفی مواد اولیه مورد استفاده قرار گیرد.

۴- نتیجه‌گیری

در این پژوهش، یک مدل ترکیبی مبتنی بر شبکه عصبی مصنوعی و الگوریتم ژنتیک برای بهینه‌سازی فرایند تولید صنعتی سدیم کوسیلیکات در شرکت پردیس سبک‌سازان اردکان توسعه داده شد. شبکه عصبی پرسپترون چندلایه با معماری ۲-۱۰-۳ و توابع فعالسازی تانژانت هیپربولیک در لایه‌های پنهان و خطی در لایه خروجی، با استفاده از الگوریتم لونیگ-مارکوارت بر روی ۲۴۵ رکورد داده واقعی آموزش دید و عملکرد بسیار مطلوبی با ضریب تعیین ۰/۹۴۵ برای مدول، ۰/۹۲۶ برای ویسکوزیته و ۰/۹۳۲ برای دانسیته خروجی در مرحله آزمون از خود نشان داد. تلفیق این مدل معتبر با الگوریتم ژنتیک با تابع تناسب چندهدفه (شامل افزایش مدول، افزایش ویسکوزیته و کاهش مصرف سود) منجر به کشف نقطه بهینه‌ای شد که در آن با افزایش ۲/۷ درصدی دانسیته چسب ورودی (از ۱/۴۸۰ به ۱/۵۲۰ گرم بر سانتی‌متر مکعب)، مصرف سود سوزآور ۱۱/۲ درصد کاهش (از ۲۴۲ به ۲۱۵ کیلوگرم بر تن) یافته و در مقابل، مدول محصول ۸/۷ درصد (از ۲/۴۱ به ۲/۶۲) و ویسکوزیته ۱۰/۴ درصد (از ۳۸۵ به ۴۲۵ سانتی‌پواز) بهبود یافته است. پیاده‌سازی نتایج در خط تولید واقعی به مدت ۷ روز کاری و آنالیز ۲۱ نمونه، خطای نسبی کمتر از ۱ درصد بین پیش‌بینی مدل و نتایج عملی را نشان داد که اعتبار بالای مدل را تأیید می‌کند. این پژوهش نشان می‌دهد که رویکرد ترکیبی ANN-GA می‌تواند به عنوان یک ابزار کم‌هزینه، غیرتخریبی و قابل اطمینان برای بهینه‌سازی فرایندهای شیمیایی پیچیده بدون نیاز به تغییرات اساسی در تجهیزات، مورد استفاده قرار گیرد.

۵- تشکر و قدردانی

نگارنده بر خود لازم می‌داند از مدیران و پرسنل محترم شرکت صنعتی پردیس سبک‌سازان اردکان، به ویژه تیم تولید و کنترل کیفیت، به دلیل همکاری صمیمانه در اجرای این طرح پژوهشی، صمیمانه تشکر نماید.

۶- منابع

- [1] Rahimipour, M. R., Karimi, H. (2019), Chemistry and Technology of Silicates. Amirkabir University of Technology (Tehran Polytechnic) Press, Tehran, In Persian.
- [2] Iler, R. K. (1979), The Chemistry of Silica. John Wiley & Sons, New York.
- [3] Hashemi, S. M., Masoumi, H., Abbasi Souraki, B., & Ghanadzadeh Gilani, H. (2021), Experimental investigation and drying modeling of parsley using artificial neural network. *Journal of Iranian Chemical Engineering*, 20(117), 23-35, In Persian.
- [4] Yousefi, M., Yasin, M. H. (2015), Optimization of industrial water pretreatment operational processes using artificial neural network and genetic algorithm. *Journal of Iranian Chemical Engineering*, 14(79), 13-22, In Persian.
- [5] Zahedi Abghari, S., Imani, A. (2018), Determination of suitable operating conditions of fluid catalytic cracking process by application of artificial neural network and firefly algorithm. *Iranian Journal of Chemistry and Chemical Engineering*, 37(6), 157-168.

- [6] Abedini, H., Pishvaie, M. R., Boozarjomehry, R. B. (2007), Kinetic mechanism reduction using genetic algorithms, case study on H₂/O₂ reaction. *Iranian Journal of Chemistry and Chemical Engineering*, 26(3), 1-9.
- [7] Gholami, V., Sahour, H., Khaleghi, M.R. et al. (2024), Combining artificial neural networks and genetic algorithms to model nitrate contamination in groundwater. *Natural Hazards* 120, 4789–4809.
- [8] Zhang, T., Chen, L., & Wang, J. (2023), Multi-objective optimization of elliptical tube fin heat exchangers based on neural networks and genetic algorithm. *Energy*, 269, 126729.
- [9] Liu, X., Qin, J., Zhao, K., Featherston, C. A., Kennedy, D., Jing, Y., & Yang, G. (2023), Design optimization of laminated composite structures using artificial neural network and genetic algorithm. *Composite Structures*, 305, 116500.
- [10] Shang, Q., et al. (2022), Photocatalytic degradation of ofloxacin antibiotic wastewater using TS-1/C₃N₄ composite photocatalyst: Reaction performance optimization and estimation of wastewater component synergistic effect by artificial neural network and genetic algorithm. *Chemical Engineering Journal*, 443, 136354.
- [11] K. Atashkari, N. Nariman-Zadeh, M. Gölcü, A. Khalkhali, A. Jamali, (2007), Modelling and multi-objective optimization of a variable valve-timing spark-ignition engine using polynomial neural networks and evolutionary algorithms, *Energy Conversion and Management*, 48(3), 1029-1041.
- [12] Tatar A., Naseri S., Bahadori M., Zeinolabedini Hezave A., Kashiwao T., Bahadori A., Darvish H., (2016), Prediction of carbon dioxide solubility in ionic liquids using MLP and radial basis function (RBF) neural networks, *Journal of the Taiwan Institute of Chemical Engineers*, 60, 151-164,
- [13] Safarpour, O., Jahanfarnia, G. and Zarifi, E. (2026), Steam Valve Coefficient Effects on Pressurized Water Reactor Dynamic Performance: A Whale Optimization Algorithm-Optimized Artificial Neural Network Predictive Framework. *Iranian Journal of Chemistry and Chemical Engineering*, 45(2), 336-359.
- [14] Katoch, S., Chauhan, S.S. & Kumar, V., (2021), A review on genetic algorithm: past, present, and future. *Multimedia Tools and Applications*, 80, 8091–8126.
- [15] Tai, X.Y., Ocone, R., Christie, S., Xuan, J., (2022), Multi-objective optimisation with hybrid machine learning strategy for complex catalytic processes, *Energy and AI*, 7, 100134.
- [16] Al Ani, Z., Gujarathi, A.M. & Al-Muhtaseb, A.H. (2023), A state of art review on applications of multi-objective evolutionary algorithms in chemicals production reactors. *Artif Intell Rev* 56, 2435–2496.
- [17] Izadi, A., Shahafve, M., Ahmadi, P., (2022), Neural network genetic algorithm optimization of a transient hybrid renewable energy system with solar/wind and hydrogen storage system for zero energy buildings at various climate conditions, *Energy Conversion and Management*, 260, 115593.
- [18] Lira, J., Riella, H., Soares, N., (2022), Computational fluid dynamics (CFD), artificial neural network (ANN) and genetic algorithm (GA) as a hybrid method for the analysis and optimization of micro-photocatalytic reactors: NO_x abatement as a case study, *Chemical Engineering Journal*, 431(1), 133771.
- [19] Ebrahimi Saryazdi S.M., Etemad, A., Shafaat, A., Bahman, A.M., (2022), Data-driven performance analysis of a residential building applying artificial neural network (ANN) and multi-objective genetic algorithm (GA), *Building and Environment*, 225, 109633.
- [20] Jamali, A., Ahmadi, P., Nazri, M., Jaafar, M. (2014), Optimization of a novel carbon dioxide cogeneration system using artificial neural network and multi-objective genetic algorithm, *Applied Thermal Engineering*, 64, 293-306.

- [21] Goyal, D., Sharma, M., Singh, D. et al. (2025), Modelling and Optimization of Silica Extraction from Perlite Using RSM, ANN, and NSGA-II Techniques. *Silicon*,17, 4653–4673.
- [22] Jesus, R.A., Nascimento, V.R.S., Costa, J.A.S. et al. (2024), Empirical modeling, experimental optimization, and artificial intelligence (ANN-GA) as a tool for the efficient dye remediation by the biosilica extracted from sugarcane bagasse ash. *Biomass Conversion and Biorefinery*, 14, 31475–31489.
- [23] Mousa, J., Negny, S., Ouaret, R., (2025), Hybrid neural networks for improved chemical process modeling: Bridging data-driven insights with physical consistency, *Digital Chemical Engineering*, 16, 100256.
- [24] Nourizadeh, M., Khosravi, R., Simjoo, M. et al. (2026), A hybrid AI-genetic algorithm framework for the optimization of polymer flooding strategies: a numerical simulation-based approach. *Scientific Reports*, 16, 3934.
- [25] Zhou, J., Shi, T., Ren, J., He, C., (2024), Accelerating operation optimization of complex chemical processes: A novel framework integrating artificial neural network and mixed-integer linear programming, *Chemical Engineering Journal*, 481, 148421.
- [26] Nandi, S., Badhe, Y., Lonari, J., et al, (2004), Hybrid process modeling and optimization strategies integrating neural networks/support vector regression and genetic algorithms: study of benzene isopropylation on Hbeta catalyst, *Chemical Engineering Journal*,97, 115-129.
- [27] Samad, a., Ahmad, i., Kano, m., Caliskan, h., (2023), Prediction and optimization of exergetic efficiency of reactive units of a petroleum refinery under uncertainty through artificial neural network-based surrogate modeling, *Process Safety and Environmental Protection*,177, 1403-1414.