

عیب یابی و رفع عیب برج جذب گاز ترش

بوسیله شبکه های عصبی

سعید حاج میرزایی - رضا مسیبهی بهبهانی* - هوشنگ جزایری راد

اهواز، دانشکده نفت، گروه مهندسی فرآوری و انتقال گاز

r_behbahani@yahoo.com

چکیده:

عیب یابی و رفع عیب فرآیند^۱ یکی از مسائل بسیار مهم در کنترل فرآیند می باشد. این موضوع قسمت اصلی مدیریت حوادث غیر عادی^۲ در فرآیندهای صنعتی می باشد که امروزه بسیار مورد توجه قرار گرفته است. در این تحقیق، از شبکه های عصبی به منظور ابزاری برای شناسایی عامل اختلال (خطا) در فرآیند جذب دی اکسید کربن توسط محلول مونو اتانول آمین^۳ در یک برج پر شده استفاده شده است. ورودی شبکه پارامتر اندازه گیری شده فرآیند توسط حسگر و ابزار اندازه گیری و خروجی شبکه عامل اختلال یا عیب شناسایی شده می باشد. به منظور شناسایی عوامل اختلال، تغییر در پارامترهای فرآیند از جمله: نرخ خوراک، ترکیب درصد خوراک، نرخ مایع جاذب و ترکیب درصد آن مورد بررسی قرار گرفت. تغییر در این پارامترها منجر به تغییر کیفیت محصول، افت فشار در برج و تغییر دمای برج می شود. این در حالی است که مقدار دی اکسید کربن در محصول نباید از مقدار معینی تجاوز کند. هدف از استفاده از شبکه های عصبی، شناسایی عاملی است که منجر به این افزایش شده است. با انتخاب یک شبکه مناسب پرسپترون چند لایه^۴ با آرایش ۸-۹-۵ این امکان فراهم آمد تا شبکه بتواند با دقت، عامل اختلال را در فرآیندی که داده های آن قبلاً توسط شبکه مشاهده نشده بود شناسایی کند.

کلمات کلیدی: برج پر شده، جذب دی اکسید کربن، شبکه عصبی مصنوعی، عیب یابی فرآیند

۱-مقدمه

مکانیکی مانند شیرهای کنترل، اختلال در حس گرها مانند دماسنج ها و اختلال در پارامترهای فرآیندی مانند پدیده جرم گرفتگی در لوله های یک مبدل حرارتی. گرچه امروزه بسیاری از واحدهای عملیاتی به سیستمهای کنترل اتوماتیک مجهز گردیده اند، اما همچنان عملکرد کامپیوتر محدود است و بسیار وابسته به عملکرد اپراتوری است که مسوولیت نظارت و کنترل واحد را بر عهده دارد. در بعضی از واحدهای عملیاتی پیشرفته، در هر ثانیه، بیش از ۱۰۰ متغیر فرآیندی نظارت و بررسی می شود [۱]. پس در چنین شرایطی دور از انتظار نیست که یک اپراتور تصمیم نادرستی اتخاذ کند و یا عکس العمل اشتباهی را انجام دهد.

اهمیت بهبود در کیفیت محصول، تولید بیشتر، ایمنی فرآیند و مسائل زیست محیطی منجر به پیچیدگی طراحی واحدهای عملیاتی و سیستم های کنترل آنها می شود و بدلیل این پیچیدگی زیاد در واحد لازم است که اپراتور را در امر کنترل واحد یاری نمود. منظور از کنترل واحد، شناسایی سریع عیب، ریشه یابی عامل اختلال، تصمیم گیری صحیح و عکس العمل سریع اپراتور در هنگام مواجه شدن با هرگونه اختلالی در واحد می باشد به طوریکه واحد به شرایط نرمال اولیه باز گردد. به طور کلی اختلالات موجود در یک واحد فرآیندی را می توان به سه دسته تقسیم نمود: اختلال در کنترل کننده های

1 Process Fault Detection & Diagnosis
2 Abnormal Event Management
3 MEA
4 Multilayer Perceptron





پیچیده و غیر قابل پیش بینی، توانایی شناسایی عامل اختلال بوسیله یادگیری، مقاومت در برابر اطلاعات اندازه گیری شده ناواضح^۹ و همچنین تطابق دادن خود با شرایط جدید در هنگام استفاده.

در این تحقیق، از شبکه های عصبی مصنوعی به عنوان ابزاری جهت شناسایی و رفع عامل اختلال در یک برج پرشده جذب گاز دی اکسیدکربن استفاده می شود. علاوه بر این، عوامل اختلال فقط منجر به تغییر کیفیت و بازدهی محصول می شود. این اختلالات منجر به آلودگی زیست محیطی و یا خسارت تجهیزات و یا بسته شدن واحد نمی شود.

۲- الگوریتم شبکه های عصبی مصنوعی

یک شبکه عصبی، ابزاری قدرتمند جهت مدل کردن اطلاعات یک فرآیند می باشد به این صورت که می تواند رابطه غیر خطی و پیچیده بین ورودی ها و خروجی های یک سیستم را بدست آورد. تاکنون الگوریتم های مختلفی برای شبکه های عصبی مصنوعی ابداع گردیده است. از جمله می توان شبکه های عصبی احتمالی^{۱۰}، پرسپترون چند لایه^{۱۱}، برگشتی^{۱۲}، هوفیلد، کوهنون و شعاعی^{۱۳} اشاره نمود. در بعضی از مقالات تا بیش از ۵۰ نوع شبکه عصبی مصنوعی که کاربرد مستقیم در علوم مهندسی دارند، معرفی شده است [۱۳] که از بین آنها شبکه های عصبی پرسپترون چند لایه که با الگوریتم پس انتشار خطا^{۱۴} آموزش دیده اند، پرکاربردترین نوع در حوضه مهندسی شیمی دارند. الگوریتم پس انتشار خطا بر این اساس عمل می کند که ابتدا مقادیر اولیه ای به توابع وزن تخصیص داده می شود، سپس داده های ورودی به شبکه وارد می شود و نتایج بدست آمده از شبکه (خروجی شبکه) با مقادیر مورد انتظار مقایسه می شود و اختلاف بین این دو مقدار محاسبه می شود، سپس با استفاده از روش های ریاضی مقادیر جدید برای توابع وزن محاسبه می شود. دوباره ورودی ها به شبکه وارد می شوند و با توجه به تابع وزن جدید، خروجی های جدید دیگری بدست می آید و بار دیگر مقایسه انجام می گیرد. این کار آنقدر ادامه پیدا می کند تا تابع وزن طوری بدست آید که جواب خروجی از شبکه، بسیار به جواب مورد انتظار نزدیک باشد.

آمار صنعتی نشان می دهد که بیش از ۷۰٪ از حوادث صنعتی ناشی از خطا های انسانی است [۲] تا آنجاییکه با پیشرفت های زیادی که امروزه در زمینه سیستم های کنترل وجود دارد همچنان شاهد حوادث ناگواری هستیم که خسارات جبران ناپذیری را بدنبال دارد. یکی از آنها حادثه در کارخانه بوپال^۱ وابسته به شرکت UC^۲ در هند و دیگری حادثه پایپر آلفا^۳ وابسته به شرکت OP^۴ می باشد. همچنین می توان به انفجار مهیبی که در سال ۲۰۰۰ میلادی در پالایشگاه مینا الاحمدی در کویت رخ داد اشاره نمود که خسارتی بیش از ۱۰۰ میلیون دلار در پی داشت. گرچه حوادثی بدین صورت نادر است و به ندرت رخ می دهد، ولی آمار موجود حاکی از حوادث کوچکتر است که روزانه در اقصی نقاط دنیا رخ می دهد و خسارات جانی و مالی زیادی را تا سقف بیلیون ها دلار به بار می آورد [۳]. اولین قدم در مدیریت حوادث غیر مترقبه^۵ استفاده از سیستمهای خودکار عیب یابی و رفع عیب فرآیند^۶ می باشد.

مسائل و مشکلات موجود در چنین سیستم هایی منجر شده که طی سالیان گذشته روش ها و بسته های کامپیوتری مختلفی عرضه گردد. در این سیستم ها از تکنیک های مختلفی مانند درخت های عیب^۷، روش های تحلیلی و سیستم های خبره بر پایه اطلاعات^۸ در گذشته و شبکه های عصبی در سال های اخیر استفاده شده است [۴-۵]. شبکه های عصبی مصنوعی کاربردهای زیادی در حوضه های مختلف مهندسی شیمی دارند [۶]. در ابتدا تلاش ها و تحقیقات زیادی به منظور استفاده از شبکه های عصبی مصنوعی به عنوان سیستم های عیب یابی و رفع عیب فرآیند انجام شد [۷-۱۱].

اما تحقیقات بعدی بیشتر در مورد تحلیل روش های یادگیری، فراخوانی و تعمیم شبکه های عصبی در عیب یابی و رفع عیب فرآیند های پایا بود [۱۲]. شاید مهمترین عامل موفقیت شبکه های عصبی مصنوعی در صنعت، توانایی آن در استخراج اطلاعات از داده های خام موجود در واحد باشد، علاوه بر این، آنها خصوصیات منحصر بفردی برای چنین مقصودی دارا می باشند. این خصوصیات عبارتند از: توانایی در شناسایی و استفاده در فرآیندهای غیر خطی

- 1 Bhopal
- 2 Union Carbide
- 3 Piper Alpha
- 4 Occidental Petroleum
- 5 Abnormal Event Management (AEM)
- 6 Process Fault Detection & Diagnosis (PFD&D)
- 7 Fault Trees
- 8 Knowledge-Based Expert System (KBES)

- 9 Noisy Measured Data
- 10 Probabilistic Neural Network (PNN)
- 11 Multi-Layer Perceptron (MLP)
- 12 Recurrent Network (RN)
- 13 Radial Basis Function (RBF)
- 14 Back Propagation Algorithm (BPA)


در این حالت اصطلاحاً می‌گوییم شبکه آموزش یافته است. در این تحقیق از شبکه‌های عصبی مصنوعی پرسپترون چند لایه با الگوریتم پس انتشار خطا به منظور یادگیری، استفاده شده است.

۳- شرح فرآیند

در این تحقیق، به عنوان یک مورد آزمایشگاهی، جذب گاز دی‌اکسید کربن توسط محلول مونو اتانول آمین^۱ در یک برج پر شده مورد بررسی قرار گرفت. شکل (۱) فلودیاگرام این واحد را در مقیاس آزمایشگاهی نشان می‌دهد. پایلوت استفاده شده جهت جمع‌آوری اطلاعات مورد نیاز در این تحقیق، یک برج جذب و دفع اتوماتیک ساخت شرکت EV^۲ ایتالیا می‌باشد که در مرکز تحقیقات گاز دانشکده نفت اهواز نصب گردیده است.

فرآیند بدین ترتیب می‌باشد که ابتدا گاز دی‌اکسید کربن درون یک میکسر با هوا مخلوط می‌شود و از پایین وارد برج جذب می‌شود. محلول جاذب رقیق توسط پمپ از درون تانک حلال به بالای برج پمپ می‌شود. برج جذب توسط حلقه‌های راشیگ با مشخصات ذکر شده در جدول (۱) پر شده است. تمام کنترل‌کننده‌ها شامل کنترل‌کننده شدت جریان گاز، شدت جریان هوا و شدت جریان حلال، همچنین سیستم‌های جمع‌آوری اطلاعات مانند دمای نقاط مختلف برج و افت فشار در برج توسط یک میکروکنترلری که به یک کامپیوتر متصل گردیده و با استفاده از بسته نرم‌افزاری موجود قابل ثبت و اندازه‌گیری است. همچنین پارامترهای شیرهای کنترل توسط نرم‌افزار قابل تغییر است. به منظور اندازه‌گیری گاز دی‌اکسید کربن در محصول خروجی از یک آنالیزر گازی قابل حمل و به صورت آنلاین استفاده شده است. مشخصات فیزیکی این برج در جدول (۲) ذکر شده است.

- 1 MEA
- 2 Elettronica Veneta



شکل ۱ - فلودیاگرام واحد جذب در مقیاس آزمایشگاهی


	ارتفاع (mm)	قطر داخلی (mm)	قطر خارجی (mm)	درصد پر شوئندگی	سطح ویژه (m^2/m^3)
مشخصات حلقه‌های راشیگ	۸	۶	۸	۷۲٪	۶۰۰

جدول ۱ - مشخصات پرکننده (آکنه) ها

حجم (Liters)	سطح مقطع (m^2)	قطر داخلی (cm)	ارتفاع (cm)	مشخصات برج
۵/۵	۰/۰۰۵۰۲۴	۸	۱۱۰	

جدول ۲ - مشخصات برج جذب پرشده

در این تحقیق، عوامل اختلال در فرآیند تنها در برج جذب اکسید کربن در خوراک برابر ۲۰/۸ درصد مولی می باشد و ایجاد می شود. درصد گاز دی اکسید کربن در گاز شیرین خروجی از بالای برج بسیار حائز اهمیت می باشد و این درصد نباید از مقدار مشخصی فراتر رود. مقدار گاز دی اکسید کربن در خوراک برابر ۲۰ درصد وزنی MEA در حلال ورودی از بالای برج برابر ۲۰ درصد وزنی می باشد. تعداد دیگری از پارامترهای عملیاتی در شکل (۲) مشخص گردیده است.



شکل ۲ - نمای شماتیک از برج جذب پرشده در شرایط نرمال

۴- طراحی الگوی عیب یابی بوسیله شبکه عصبی
در واحد مورد بررسی قرار گرفت. این عوامل عبارتند از: تغییر درصد حجمی دی اکسید کربن در محصول خروجی به عوامل متعددی از جمله: غلظت دی اکسید کربن در خوراک، شدت جریان خوراک، دما و شدت جریان مایع جاذب، افت فشار در برج، طول برج و ... بستگی دارد اما در این تحقیق، تغییرات فقط در چهار عامل زیر به عنوان منابع ایجادکننده اختلال ذکر شده است.

در واحد مورد بررسی قرار گرفت. این عوامل عبارتند از: تغییر غلظت دی اکسید کربن در خوراک، شدت جریان خوراک، شدت جریان مایع جاذب و غلظت MEA در مایع حلال. هر یک از این موارد به عنوان عاملی در تغییر درصد حجمی دی اکسید کربن در محصول می شود. این عوامل در جدول (۳) ذکر شده است.

نشانه	عامل ایجاد کننده اختلال
F _۱	شدت جریان کم خوراک
F _۲	شدت جریان زیاد خوراک
F _۳	غلظت کم دی اکسید کربن در خوراک
F _۴	غلظت زیاد دی اکسید کربن در خوراک
F _۵	شدت جریان کم مایع جاذب
F _۶	شدت جریان زیاد مایع جاذب
F _۷	غلظت کم MEA در مایع جاذب
F _۸	غلظت زیاد MEA در مایع جاذب

جدول ۳ - عوامل ایجادکننده اختلال در واحد



به عنوان مثال هر گاه شدت جریان خوراک به میزان ۲۵٪ افزایش یابد، آنرا با (+۲۵%) F2 نشان می دهیم و عدد متناسب با چنین خطایی ۵۵/۰ است. چنین عاملی را یک عامل اختلال جزئی^۴ گویند.

سپس، اطلاعات بدست آمده از این واحد توسط ابزاری^۱ در نرم افزار Aspen Plus مورد پردازش قرار گرفت. این ابزار توانایی بالایی جهت تطابق دادن داده های آزمایشگاهی یا داده های یک واحد صنعتی بر روی یک مدل را دارد [۱۴]. داده های آزمایشگاهی با موفقیت توسط این ابزار بر روی سیستم جذب CO_۲/MEA تطبیق داده شد.

به منظور شبیه سازی از برج RADFRAC^۲ استفاده شد و متقابلاً از این مدل به منظور بدست آوردن داده های جدید استفاده شد و نهایتاً به منظور آموزش و تست شبکه، از اطلاعات بدست آمده توسط مدل شبیه سازی شده استفاده گردید.

۵- آموزش شبکه

همانگونه که ذکر گردید، در این تحقیق، تغییرات در غلظت دی اکسید کربن موجود در خوراک، شدت جریان خوراک، شدت جریان مایع جاذب و غلظت MEA در مایع حلال به عنوان منابع ایجادکننده اختلال در واحد مورد بررسی قرار گرفت. جدول (۴) تعدادی از داده های بدست آمده از نرم افزار را که به منظور آموزش شبکه مورد استفاده قرار گرفت، نشان می دهد. بطور کلی تعداد ۲۶۰ سری از اطلاعات توسط نرم افزار جمع آوری گردید که تعداد ۲۰۰ عدد از آن در آموزش شبکه مورد استفاده قرار گرفت و تعداد ۶۰ عدد هم به عنوان تست کردن شبکه مورد استفاده قرار گرفت.

هرگاه تغییر در عوامل ذکر شده منجر به آن شود که درصد مولی دی اکسید کربن در محصول نهایی (گاز شیرین) از ۱ درصد بیشتر شود، به آن عامل ایجاد اختلال (عیب) در فرآیند گویند و چنین عاملی را یک عامل اختلال کامل^۳ گویند.

برای چنین حالتی در الگوی آموزش عدد ۱ در نظر گرفته می شود. با توجه به جدول (۴)، در شرایط نرمال، غلظت دی اکسید کربن در گاز شیرین برابر ۰/۴ درصد مولی می باشد، در چنین حالتی عدد متناسب با عامل اختلال در الگوی آموزش صفر در نظر گرفته می شود.

با ایجاد عوامل اختلال، هرگاه غلظت دی اکسید کربن بین ۰/۴ تا ۱ تغییر کرد، عدد متناسب با این اختلال هم به صورت خطی (و بروش درونیابی) بین صفر تا ۱ تغییر می یابد.

1. Data-Fit Analysis Tool
2. Rigorous RADFRAC method
3. Full Fault




عامل اختلال	شدت جریان گاز (kg/h) شیرین	دمای گاز شیرین (°C)	شدت جریان مایع جاذب (kg/h)	دمای مایع جاذب غنی (°C)	افت فشار در برج (Pa)	غلظت دی اکسید کربن در گاز شیرین (%mol)
Normal	۱۰/۵	۲۰/۸	۵۵	۲۰	۰/۴	۰/۴
F1 (-۵٪)	۷/۲۳۳	۲۶/۸	۵۷/۷۷	۴۸/۴۵	۶۶/۳	۰/۳۵
F2 (+۵٪)	۷/۹۶۷	۲۷/۳۴	۵۸/۰۳	۵۰/۱۸	۷۴/۴	۰/۴۳۸
F3 (-۵٪)	۷/۷۱۱	۲۶/۹۴	۵۷/۷۹	۴۸/۵۸	۷۰/۶	۰/۳۷۴
F4 (+۵٪)	۷/۴۵۶	۲۷/۲۲	۵۸/۰۴	۵۰/۲۷	۶۹/۸	۵۰/۴۳
F5 (-۵٪)	۷/۶۰۳	۲۷/۳۳	۵۴/۹	۵۰/۳۸	۶۹/۳۵	۰/۴۲
F6 (+۵٪)	۷/۵۹۷	۲۶/۸۴	۶۰/۹	۴۸/۳۵	۷۱/۲۵	۰/۳۹
F7 (-۵٪)	۷/۶۰۳	۲۷/۱۶	۵۷/۹	۴۸/۹۷	۷۰/۳	۰/۵۵
F8 (+۵٪)	۷/۵۹۶	۲۶/۹۷	۵۷/۹	۴۹/۶۶	۷۰/۳	۰/۴۹
F1 (-۱۰٪)	۶/۵۰۲	۲۶/۴	۵۷/۵	۴۶/۵۶	۵۸/۴	۰/۳۲
F2 (+۱۰٪)	۸/۷۱	۲۸/۱۱	۵۸/۲۹	۵۱/۷۹	۸۲/۸	۰/۵۴۵
F3 (-۱۰٪)	۷/۸۴۱	۲۶/۸۳	۵۷/۶۶	۴۷/۶۸	۷۱/۱	۰/۳۴۹
F4 (+۱۰٪)	۷/۳۳۱	۲۷/۴	۵۸/۱۷	۵۱/۱	۶۹/۴	۰/۴۷۳
F5 (-۱۰٪)	۷/۶۰۸	۲۷/۷۵	۵۱/۸۹	۵۱/۵۴	۶۸/۴۴	۰/۴۵
F6 (+۱۰٪)	۷/۵۹۶	۲۶/۷۳	۶۲/۹	۴۷/۷۲	۷۱/۹	۰/۳۸
F7 (-۱۰٪)	۷/۶۰۹	۲۷/۳۲	۵۷/۸۹	۴۸/۶۲	۷۰/۳	۰/۶
F8 (+۱۰٪)	۷/۵۹۴	۲۶/۹۱	۵۷/۹۱	۴۹/۹۵	۷۰/۳	۰/۴۶
F1 (-۲۵٪)	۵/۷۷۳	۲۶/۰۶	۵۷/۲۳	۴۴/۵۴	۵۰/۹	۰/۲۵
F2 (+۲۵٪)	۹/۴۶۸	۲۹/۴۲	۵۸/۵۳	۵۳/۱۷	۹۱/۵	۰/۷۳
F3 (-۲۵٪)	۸/۲۳۹	۲۶/۵۱	۵۷/۲۶	۴۴/۷۲	۷۲/۳۵	۰/۲۸۴
F4 (+۲۵٪)	۶/۹۷۴	۲۸/۳۲	۵۸/۵۳	۵۳/۳۲	۶۸/۲	۰/۶۷۶
F5 (-۲۵٪)	۷/۶۷۷	۳۲/۱	۴۳/۸۲	۵۴/۴۵	۶۶/۱۳	۰/۸۹
F6 (+۲۵٪)	۷/۵۹۳	۲۶/۳۷	۷۱/۹۱	۴۵/۲۱	۷۵	۰/۳۷
F7 (-۲۵٪)	۷/۶۶۱	۲۸/۹۳	۵۷/۸۴	۴۷/۰۵	۷۰/۳	۰/۸۹
F8 (+۲۵٪)	۷/۵۸۹	۲۶/۷۹	۵۷/۹۱	۵۰/۶۷	۷۰/۳	۰/۴۲
F1 (-۵۰٪)	۳/۶	۲۵/۳۵	۵۶/۴	۳۷/۷۴	۲۹/۷	۰/۱۱۳
F2 (+۵۰٪)	۱۲/۰۶	۳۸/۴۴	۵۸/۹۴	۵۵/۴	۱۱۹/۴	۲/۲۷
F3 (-۵۰٪)	۹/۰۷	۲۵/۹۶	۵۶/۴۳	۳۷/۸۷	۷۵	۰/۱۷۶
F4 (+۵۰٪)	۶/۵۱۷	۳۴/۰۸	۵۸/۹۸	۵۵/۷۷	۶۶/۳	۲/۰۶۷
F5 (-۵۰٪)	۷/۷۷۶	۳۷/۱۱	۴۰/۷۲	۵۴/۸۶	۶۵/۳	۲/۵۱
F6 (+۵۰٪)	۷/۵۹۱	۲۶/۱	۸۲/۹۱	۴۲/۷۴	۷۹/۱۵	۰/۳۶
F7 (-۵۰٪)	۷/۹۲۵	۳۴/۲۳	۵۷/۵۷	۴۳/۸۸	۷۰/۳	۲/۴۸
F8 (+۵۰٪)	۷/۵۸۳	۲۶/۷	۵۷/۹۲	۵۱/۶	۷۰/۳	۰/۳۹

جدول ۴ - تعدادی از داده های مورد استفاده به عنوان ورودی شبکه

الگویی که به منظور آموزش شبکه مورد استفاده قرار گرفت شامل ۵ گره ورودی^۱ می باشد که مستقیماً از واحد بدست می آید که عبارتند از: شدت جریان گاز شیرین (G)، دمای گاز شیرین (T_p)، شدت جریان مایع جاذب در خروجی برج (L_{Rich})، دمای مایع جاذب غنی (T_s) و افت فشار در برج (ΔP)، همچنین خروجی های شبکه شامل ۸ گره خروجی^۲ می باشد که متناسب با هشت عامل ایجاد کننده اختلال می باشد و با علائم $F_1, F_2, F_3, F_4, F_5, F_6, F_7, F_8$ نشان داده می شود. نمایی از شبکه طراحی شده در شکل (۳) نشان داده شده است.

2. Output Nodes

1. Input Nodes



شکل ۳ - شبکه طراحی شده با معماری ۵-۹-۸

بیانگر تعداد المانهای خروجی می باشد. جدول (۵) مقادیر بدست آمده برای این دو پارامتر را برای تعداد گره های مختلف در لایه مخفی، پس از ۱۰۰۰۰ بار تکرار نشان می دهد. با توجه به اطلاعات موجود در جدول واضح است که وجود ۹ گره در لایه مخفی کمترین خطا را دارد و بنابراین یک شبکه با معماری ۵-۹-۸ بهترین جواب را بدست می آورد. همچنین در این شبکه پارامتر نرخ یادگیری برابر ۰/۷ و پارامتر مومنتم برابر ۰/۸ در نظر گرفته شد. علاوه بر این مقادیر ثابت بایاس به گره های داخلی اضافه شد تا عملکرد شبکه بهبود یابد. نهایتاً تعداد بیشتر از ۱۲ گره در لایه مخفی (حتی با تعداد تکرارهای بیشتر) با عدم موفقیت در یادگیری بعضی از الگوها گردید و مشاهده گردید که تعداد بیشتر از ۱۲ گره تاثیر کمی بر روی فرآیند یادگیری دارد. این بدین دلیل است که افزایش زیاد تعداد گره ها در لایه مخفی، منجر به افزایش تعداد پارامترهای آزاد شبکه (وزن ها) می شود.

در این تحقیق، از یک شبکه عصبی با یک لایه مخفی استفاده گردید زیرا چنین شبکه ای توانایی نگاشت هر گونه سیستمی را داراست [۱۵]. برای طراحی یک شبکه عصبی که بتواند بهترین جواب را بدست آورد از دو پارامتر مینیموم مجموع مربعات (MSE)^۱ و ماکزیمم متوسط درصد خطا (MAPE/%)^۲ استفاده شد، بدین صورت که با تغییر در تعداد گره ها در لایه مخفی، این دو پارامتر کمترین مقدار ممکن بدست آیند [۱۶]:

$$\%MAPE = \frac{100}{(N)(P)} \sum_{j=0}^P \sum_{i=0}^N \frac{|d_{ij} - y_{ij}|}{y_{ij}}$$

$$MSE = \frac{\sum_{j=0}^P \sum_{i=0}^N (d_{ij} - y_{ij})^2}{(N)(P)}$$

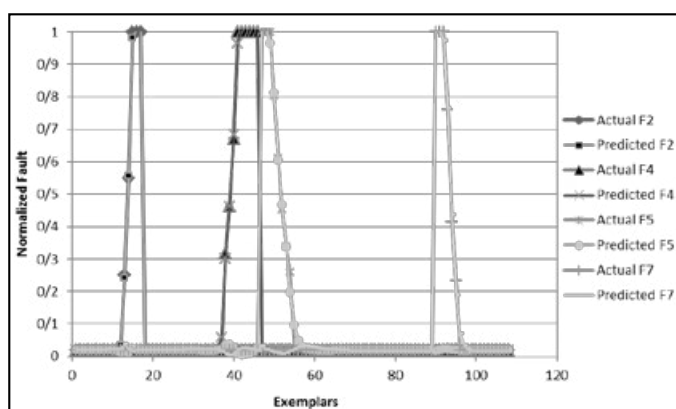
که در آن y_{ij} خروجی از شبکه و d_{ij} خروجی مطلوب (مورد نظر) می باشد. در این فرمول، N بیانگر تعداد نمونه ها و P

1. Mean Square Error
2. Maximum Average Percentage Error

تعداد گره ها در لایه مخفی	MSE	%MAPE
۳	۰/۰۰۱	۳۰/۱۲
۴	۰/۰۰۰۶	۱۹/۸۹
۵	۰/۰۰۰۵۵	۱۷/۷۲
۶	۰/۰۰۰۴۶	۱۵/۱۷
۷	۰/۰۰۰۴۸	۱۶/۱۸
۸	۰/۰۰۰۴۶	۱۵/۴۱
۹	۰/۰۰۰۳۷	۱۴/۷
۱۰	۰/۰۰۰۴۶	۱۵/۱
۱۱	۰/۰۰۰۵۲	۱۸/۴۸
۱۲	۰/۰۰۰۴۴	۱۶/۹۷


جدول ۵ - مقادیر MSE و %MAPE با تغییر تعداد گره ها در لایه مخفی

۶- استفاده از شبکه عصبی برای عیب یابی می دهد. با توجه به شکل مشخص است که شبکه توانسته شکل (۴) نحوه عملکرد شبکه را در حین آموزش نشان است به خوبی جواب مطلوب و مورد نظر را بدست آورد.



شکل ۴ - عملکرد شبکه عصبی در حین یادگیری (تغییرات با دامنه ۵، ۱۰، ۲۵ و ۵۰٪)

همچنین، شبکه با اطلاعات ورودی که قبلاً مشاهده نکرده مشخص شده است در این حالت شبکه توانست به خوبی بود نیز مورد آزمایش قرار گرفت. همانگونه که در شکل (۵) عوامل اختلال را پیشگویی کند.



شکل ۵ - عملکرد شبکه عصبی بعد از یادگیری (تغییرات با دامنه ۱۵، ۲۰ و ۳۰٪)





عملکرد شبکه در برابر دو و سه عامل ایجاد کننده اختلال (به طور همزمان) نیز مورد بررسی قرار گرفت. جدول (۶) توانایی شبکه را در برابر دو و سه عامل اختلال نشان می دهد، با توجه به جدول مشاهده می شود که شبکه به خوبی

می تواند دو عامل اختلال را به خوبی شناسایی کند ولی در شناسایی سه عامل اختلال به طور همزمان ضعیف عمل می کند و علت این است که شبکه برای شناسایی یک عامل ایجاد کننده اختلال آموزش داده شده بود.

دو عامل ایجاد کننده اختلال	عامل شناسایی شده توسط شبکه
F2, F4	F2, F4
F4, F5	F4, F5
F5, F7	F5, F7
F2, F7	F2, F7
F2, F5	F2, F5
F4, F7	F4, F7
سه عامل ایجاد کننده اختلال	
F2, F4, F5	F2, F4
F4, F5, F7	F4, F7

جدول ۶ - توانایی شبکه در شناسایی دو و سه عامل اختلال

۷- نتیجه گیری

را باید در نظر گرفت که به منظور طراحی یک سیستم عیب یابی و رفع عیب واحد، تمام اختلالاتی که امکان وقوع آنها است، مانند اختلال در فرآیند، اختلال در سنسورها و وسایل اندازه گیری، اختلال در شیرهای کنترل و حتی اختلال ناشی از تغییرات پارامترهای فرآیند باید در نظر گرفته شود. بدین منظور در تحقیقات آینده می توان از ترکیب چند شبکه عصبی^۱ استفاده نمود تا توانایی شناسایی همزمان انواع عامل اختلال را داشته باشد.

توانایی استفاده از شبکه عصبی به منظور شناسایی عامل اختلال در یک برج جذب گاز دی اکسید کربن مورد بررسی قرار گرفت. داده های یک واحد برج جذب و دفع آزمایشگاهی در مدل کردن این واحد در نرم افزار Aspen Plus توسط ابزار موجود در آن نرم افزار مورد استفاده قرار گرفت. سپس اطلاعات مورد نیاز جهت آموزش و تست شبکه از نرم افزار استخراج گردید. تغییرات در غلظت دی اکسید کربن موجود در خوراک، شدت جریان خوراک، شدت جریان مایع جاذب و غلظت MEA در مایع حلال به عنوان منابع ایجادکننده اختلال در واحد انتخاب گردید. شبکه طراحی شده شامل ۵ ورودی می باشد که مستقیماً از واحد بدست می آید و همچنین شامل ۸ خروجی می باشد که متناسب با عوامل اختلال معرفی شده می باشد. شبکه با تغییرات ۵، ۱۰، ۲۵، ۵۰ در عوامل ایجاد کننده اختلال مورد آموزش قرار گرفت و نهایتاً شبکه ای با معماری ۸-۹-۵ با نرخ یادگیری ۰/۷ و مومنتوم ۰/۸ طراحی گردید که شبکه با موفقیت در تمام حالت ها توانست عامل ایجاد کننده اختلال در واحد را شناسایی کند. البته این نکته

1. Hybrid Networks

۸- منابع

- [1] S. J. Bailey, Control Eng. 1984, 31 (6), 86-90
- [2] F. P. Lees, London: Butterworth-Heinemann. 1996
- [3] Bureau of Labor Statistics, Washington, DC: Government Printing Office, 1998
- [4] V. Venkatasubramanian, R. Rengaswamy, S.N. Kavuri, K. Yin, Computers and Chemical Engineering 2003, 27
- [5] T. Sorsa, H.N. Koivo, 1993, Automatica, 29(4), 843-849
- [6] D. M. Himmelblau, Korean J. Chem. Eng. 2000, 17(4), 373-392
- [7] V. Venkatasubramanian, Journal of Loss prevention in the Process Industries 1988, (2), 84-91
- [8] K. Watanabe, I. Matsura, A. M. Kubota, D.M. Himmelblau, American Inst. of Chem. Eng. Journal 1989, 35(11)
- [9] V. Venkatasubramanian, K. Chan, American Inst. of Chem. Eng. Journal 1989, 35 (12), 1993-2002
- [10] L. H. Ungar, B. A. Powell, S. N. Kamens, Comp. and Chem. Eng. 1990, 14 (4-5), 561-572
- [11] J. C. Hoskins, K. M. Kaliyur, D. M. Himmelblau, American Inst. of Chem. Eng. Journal 1991, 37 (1), 137-141
- [12] V. Venkatasubramanian, R. Vaidyanathan, Y. Yamamoto, Comp. and Chem. Eng. 1990, 14 (7), 699-712
- [13] R.P. Lippmann, IEEE ASSP Magazine 1987, April, 4-21
- [14] A. Khan, M. Simioni, V. Zijll, D. Jong, S. Kentish, G. Stevens, 35th Australasian Chem. Eng. Conf. 2007, Melbourne, Australia, 23-26 Sep., 778-785
- [15] S.C. Huang, Y.F. Huang, IEEE Trans. Neural Networks 1991, vol. 2, 47-55, Springer-Verlag

