

تاریخ دریافت: ۸۸/۳/۹

تاریخ پذیرش: ۸۸/۵/۲۰

پیش‌بینی نرخ خوردگی با استفاده از شبکه‌های عصبی مطالعه موردی: سیستم‌های بالاسری تقطیر نفت خام

دکتر محمود البرزی*
سید امیر رضا ابطحی**

چکیده

هدف این تحقیق پیش‌بینی نرخ خوردگی با استفاده از شبکه‌های عصبی مصنوعی می‌باشد. خوردگی پدیده‌ای است که به علت تأثیر عوامل مختلف و متعدد شناخته‌شده و ناشناخته پیچیدگی بسیار زیادی دارد و به راحتی قابل مدلسازی نیست. جهت پیش‌بینی و مدلسازی خوردگی در رویکرد مکانیستیک^۱ به واکنش‌ها و فرایندهای فیزیکی، شیمیایی و الکتروشیمیایی آن توجه می‌شود و مدلسازی بر اساس آن‌ها انجام می‌پذیرد. با وجود موفقیت‌هایی که این مدل‌ها داشته‌اند، لیکن به علت تعدد عوامل تأثیرگذار که بعضاً ناشناخته نیز هستند، نیاز به مدل‌هایی که با دقت بیشتری این پدیده را مدلسازی و پیش‌بینی کنند احساس می‌شود.

در این تحقیق برای پیش‌بینی نرخ خوردگی از مدل شبکه عصبی مصنوعی با بهینه‌سازی ژنتیک^۲ استفاده گردیده است. از بین مدل‌های مختلف شبکه عصبی، شبکه عصبی چند لایه با الگوریتم یادگیری کاهش گرادیان انتخاب شده است. پس از ایجاد شبکه، فرایند آموزش شبکه با داده‌های موجود در یک پالایشگاه نفت مورد تحقیق انجام شد و سپس ارزیابی و آزمایش صورت گرفت. پس از آماده شدن شبکه، جهت استخراج دانش از روش تحلیل حساسیت و الگوریتم گارسن استفاده شد.

* استادیار، گروه مدیریت صنعتی دانشگاه آزاد اسلامی، واحد علوم و تحقیقات، تهران، ایران

** دانش آموخته کارشناسی ارشد مدیریت صنعتی از دانشگاه آزاد اسلامی واحد علوم و تحقیقات، تهران، ایران

1- Mechanistic approach

2- Genetic optimization

نتایج تحقیق نشان می‌دهد که روش شبکه عصبی توانایی پیش‌بینی نرخ خوردگی را با ضریب همبستگی و خطای MSE^1 قابل قبول دارد. بخش دیگری از نتایج که برگرفته از روش تحلیل حساسیت هستند، نشان‌دهنده میزان تأثیر هر کدام از پارامترهای نفت خام بر روی خوردگی می‌باشد. طبق این نتایج نمک و گوگرد تأثیرگذارترین عوامل بر روی خوردگی در پالایشگاه مورد تحقیق هستند.

واژگان کلیدی: پیش‌بینی، شبکه عصبی، تحلیل حساسیت، استخراج دانش^۲، الگوریتم گارسون^۳، خوردگی فلزات، سیستم‌های بالاسری تقطیر نفت خام

مقدمه

یکی از مباحث مهم علمی، فنی و اقتصادی که بیش از نیم قرن است توجه گروهی از دانشمندان، پژوهشگران، مهندسان و صاحبان صنایع را به خود جلب کرده و زمینه پژوهش‌های ارزشمندی شده است مسأله خوردگی فلزات و حفاظت وسایل و تأسیسات فلزی است. بررسی مبحث خوردگی چندان ساده نیست و با همه پژوهش‌های انجام شده، هنوز عوامل آن به درستی شناخته نشده است. به غیر از بکارگیری علوم شیمی برای مقابله با خوردگی، استفاده از سایر علوم در کنترل و پیش‌بینی خوردگی و استفاده از نتایج آن در تعمیرات تجهیزات فلزی از اهمیت ویژه‌ای برخوردار است. وجود نفت خام و آب که حاوی ترکیبات خورنده هستند در پالایشگاه‌ها باعث وجود مسأله خوردگی در این واحدهای صنعتی به شکلی بسیار جدی‌تر از صنایع دیگر شده است. عدم توانایی در پیش‌بینی نرخ خوردگی باعث می‌شود که زمان‌های خرابی ناشی از آن نیز چندان قابل پیش‌بینی نباشد که این موضوع تیم‌های نگهداری و تعمیرات پالایشگاه‌ها را دچار مشکل می‌نماید.

تا کنون روش‌های مختلفی در مواجهه با این پدیده استفاده شده‌است. مدل‌سازی خوردگی می‌تواند در شناخت بیشتر و پیش‌بینی مسائل برآمده از آن مؤثر باشد.

1- Mean Squared Error
2- Knowledge extraction
3- Garson's algorithm

روش‌های متفاوت استفاده شده در این مدل‌سازی‌ها، بیشتر روش‌های مکانیستیک با تکیه بر پیشینه تئوریک خوردگی و فرمول‌های ریاضی بوده است، اما به دلیل پیچیدگی ذاتی این پدیده، این روش‌ها موفقیت زیادی نداشته‌اند. به دلیل پیچیدگی ذکر شده و تعدد عوامل شناخته‌شده و بعضاً ناشناخته تأثیرگذار بر این پدیده و همین‌طور وجود داده‌های زیاد در مورد این پدیده که کمتر مورد استفاده قرار گرفته‌اند به نظر می‌رسد می‌توان در مدل‌سازی و پیش‌بینی این پدیده از روش‌های داده‌محور موجود در رایانش نرم همچون شبکه عصبی مصنوعی برای پیش‌بینی این پدیده استفاده کرد. در این تحقیق سعی شده است تا از روش‌های رایانش نرم از جمله شبکه عصبی در پیش‌بینی پدیده خوردگی استفاده شود.

بیان مسأله

در پالایشگاه، نفت خام اصلی‌ترین عامل در خوردگی است. نفت خام که ترکیبی از هیدروکربورهای سبک، متوسط، سنگین و آسفالتین‌ها است، ابتدا در واحدهای تقطیر در فشار اتمسفر در اثر اختلاف در نقطه جوش تفکیک گردیده و محصولات از قبیل گازها، گاز مایع، بنزین، نفت سفید، گازوئیل و ته ماند برج تقطیر خارج می‌گردد. سیستم‌های بالا سری شامل دو مرحله فین تیوب‌های هوایی است که در آن بخارات نفت خام به وسیله جریان هوا خنک و مایع می‌گردد. وجود مواد غیرهیدروکربوری در نفت خام موجب ایجاد خوردگی در سیستم‌های بالاسری می‌گردد. سوراخ شدن و خرابی فین تیوب‌های بالاسری که در اثر همین خوردگی صورت می‌پذیرد، باعث توقف کار دستگاه تقطیر شده و خسارات زیادی را از قبیل هزینه‌های تعمیراتی و توقف تولید وارد می‌سازد. پیش‌بینی نرخ خوردگی می‌تواند مبنای محاسباتی برای تیم‌های بازرسی فنی و نگهداری و تعمیرات باشد تا بتوانند با کنترل آن از بروز توقف تولید جلوگیری نمایند. انواع مختلف نفت خام ورودی به برج‌های تقطیر از لحاظ گراویتی^۱، مقدار آب، نمک، ترکیبات گوگردی و فلزات، دارای نرخ خوردگی متفاوت می‌باشند. نرخ خوردگی در

پالایشگاه مورد تحقیق با شاخص مقدار آهن (Fe^{++}) موجود در آب ترش^۱ خروجی سیستم بالاسری اندازه‌گیری می‌شود. کارشناسان واحد خوردگی جهت کنترل مقدار خوردگی و کاهش آن با توجه به میزان شاخص ذکر شده، نسبت به تزریق خنثی کننده آلی، آمونیاک و ایجادکننده فیلم اقدام می‌کنند و نتیجه را با اندازه‌گیری آهن در خروجی آب سیستم بالاسری تحلیل می‌کنند. این موضوع اگرچه ظاهراً باعث کاهش خوردگی می‌گردد ولی در واقع این نحوه کنترل، بهینه نمی‌باشد و نتایج قابل انتظار حاصل نمی‌گردد. در صورتی که بتوان سیستمی جهت پیش‌بینی عملکرد خوردگی ایجاد کرد و بر مبنای آن نتایج شرایط عملیاتی را پیش‌بینی نمود، می‌توان از اعمال نظرات موردی احتراز و نتایج بهینه‌ای ایجاد نمود و تأثیر میزان تزریق مواد خنثی کننده و ایجاد کننده فیلم و حتی تأثیر میزان و درصد ترکیبات نفت خام ورودی را بر نرخ خوردگی پیش‌بینی نمود.

بنابراین پیش‌بینی نرخ خوردگی با شاخص میزان آهن موجود در آب بالاسری با توجه به ترکیبات نفت خام و میزان تزریق مواد خنثی کننده و ایجادکننده فیلم و میزان PH و یون کلر موجود در آب سیستم بالاسری، می‌تواند در کنترل خوردگی در سیستم بالاسری نقش قابل توجهی داشته باشد.

با توجه به ماهیت غیرخطی خوردگی و وجود مؤلفه‌های متعدد شناخته شده و عوامل تأثیرگذار ناشناخته، پیش‌بینی شرایط با پیچیدگی زیادی مواجه است، به نظر می‌رسد که شبکه عصبی مصنوعی که ماهیتاً داده محور و خود انطباق است و بدون نیاز به فرضیاتی که روش‌های مدل محور نیاز دارند وارد مقوله پیش‌بینی رفتار سیستم‌های غیرخطی می‌شوند، ابزار مناسبی باشد (البرزی، ۱۳۸۶، ص ۵۹).

این تحقیق بر مبنای استفاده از توانایی‌های شبکه‌های عصبی برای پیش‌بینی نرخ خوردگی بنا نهاده شده است و بدین منظور از اطلاعات جمع‌آوری شده و موجود در واحد خوردگی و بازرسی فنی و واحد مهندسی پالایش در پالایشگاه مورد تحقیق استفاده می‌نماید.

اهمیت و ضرورت تحقیق

با وجود این که کارشناسان واحد خوردگی و بازرسی فنی معتقد به تأثیر درصد ترکیبات موجود در نفت خام به عنوان عامل اصلی خوردگی در قسمت‌های مختلف تأسیسات پالایش هستند و مشخصات شیمیایی و فیزیکی نفت خام و آب ترش خروجی را به صورت روزانه اندازه‌گیری کرده و ثبت و تحلیل نموده و بر مبنای نتایج، تغییرات لازم را اعمال می‌نمایند، ولی عدم وجود یک سیستم که بتواند از داده‌های موجود، اطلاعات نهفته را استخراج و تحلیل نموده و در مقایسه با شرایط مطلوب، وضعیت جاری خوردگی را مشخص و پیش‌بینی نماید، عملاً داده‌های موجود را فاقد ارزش افزوده کرده است.

استفاده از داده‌های موجود جهت پیش‌بینی نرخ خوردگی، کارشناسان و کارکنان واحد خوردگی و بازرسی فنی را در دریافت نحوه و میزان تأثیر هر یک از ترکیبات نفت خام ورودی بر روی میزان آهن موجود در آب ترش (شاخص نرخ خوردگی) و سیستم بالاسری یاری می‌دهد. کارشناسان با کمک شناخت به وجود آمده، می‌توانند نسبت به انجام تغییرات لازم برای کاهش نرخ خوردگی در خوراک (نفت خام) و میزان تزریق خنثی‌کننده‌ها تصمیم‌گیری نمایند.

عدم وجود پیش‌بینی مناسبی از نرخ خوردگی در تأسیسات پالایش با توجه به ترکیبات نفت خام، موجب شده تا ترکیب نفت خام ورودی به برج تقطیر که حاصل ترکیب چند نوع مختلف نفت خام می‌باشد فقط با استفاده از تجربیات کارشناسان صورت گیرد، هم‌چنین میزان تزریق مواد خنثی‌کننده و ایجاد کننده فیلم نیز با توجه به میزان لحظه‌ای آهن موجود در آب بالاسری طبق تجربه قبلی کارشناسان انجام می‌پذیرد و سیستم خاصی برای این کار وجود ندارد.

همچنین همواره اندازه‌گیری‌ها، تحلیل‌ها و آزمایشات، پس از رخ دادن خوردگی در سیستم صورت می‌پذیرد در حالیکه وجود مدل شبکه عصبی برای پیش‌بینی نرخ خوردگی می‌تواند به انتخاب ترکیب مناسب نفت خام ورودی کمک کند و پیدا کردن میزان مناسب تزریق مواد خنثی‌کننده را قبل از اعمال به سیستم امکان‌پذیر نماید.

اهداف تحقیق

هدف اصلی این تحقیق «پیش‌بینی نرخ خوردگی با استفاده از شبکه‌های عصبی مصنوعی» بوده است، که در راستای تحقق این هدف، اهداف فرعی همچون شناسایی، بررسی و دسته‌بندی شبکه‌های عصبی و مدل‌های مختلف آن، شناسایی، بررسی و دسته‌بندی روش‌های معمول پیش‌بینی نرخ خوردگی در تحقیقات مشابه در ایران و سایر کشورهای جهان، شناسایی عوامل مؤثر بر نرخ خوردگی در سیستم‌های بالاسری تقطیر نفت خام در پالایشگاه مورد تحقیق، پیش‌بینی خوردگی قبل از ایجاد آن در سیستم و همچنین ارائه پیشنهادهایی در جهت تقلیل نرخ خوردگی در سیستم با توجه به نتایج بدست آمده از تحقیق، محقق شده‌اند.

پیشینه تحقیق

روش‌های مختلفی برای مدل‌سازی مسائل خوردگی^۱ وجود دارند. این روش‌ها را می‌توان در سه دسته زیر براساس میزانی که آنها به مباحث تئوری خوردگی می‌پردازند، طبقه‌بندی نمود:

- مدل‌های مکانیستیک^۲
- مدل‌های شبه تجربی^۳
- مدل‌های تجربی^۴

مدل‌های مکانیستیک معمولاً مکانیزم واکنش‌های پایه‌ای که موجب خوردگی می‌شوند را توضیح می‌دهند و دارای زمینه تئوریک قوی هستند. تمامی یا بیشتر ثوابت و متغیرهایی که در این نوع مدل‌ها دیده می‌شوند، دارای معنای فیزیکی و شیمیایی دقیق و خاصی هستند. تعداد زیادی از مقادیر عددی که وابسته به دیدگاه‌های تئوری هستند را می‌توان در سوابق و ادبیات موجود در مورد خوردگی پیدا کرد. زمانی که فرمول‌ها و مدل‌های مکانیستیک با پایگاه داده‌های تجربی و قابل اعتماد ترکیب و پالایش شوند،

1- Corrosion Problems
 2- Mechanistic Models
 3- Semi- Empirical Models
 4- Empirical Models

این مدل‌ها می‌توانند جهت انجام پیش‌بینی‌های دقیق در بازه مورد نظر جهت حل مسأله، مورد استفاده قرار گیرند. افزودن موارد جدید و دانش جدید به این نوع از مدل‌ها ساده است و با کمترین میزان تغییر در ساختار مدل موجود و متغیرهای مدل امکان‌پذیر می‌باشد.

مدل‌های شبه تجربی فقط در بخش‌هایی براساس فرضیات تئوریک بنا شده‌اند. عموماً این مدل‌ها در عمل در مواردی استفاده می‌شوند که دانش تئوریک کافی در مورد یک پدیده موجود نیست و مطالب جدید به صورت توابع تجربی به مباحث تئوریک اضافه می‌شوند. برخی از ثوابت و متغیرهایی که در این مدل‌ها مشاهده می‌شوند، دارای معنای دقیق فیزیکی و شیمیایی بوده، در حالی که بقیه متغیرها، متغیرهایی هستند که تجربه نشان داده است در مسأله دخیل می‌باشند. با سنجش و پالایش این مدل‌ها به وسیله پایگاه داده تجربی مورد اطمینان، می‌توان انتظار داشت که این مدل‌ها با دقت خوبی پیش‌بینی را انجام دهند. افزودن دانش جدید به این مدل‌ها با اضافه کردن فاکتورهای سنجش صحت و تغییر برخی از ثوابت و متغیرهای مدل موجود، صورت می‌پذیرد.

مدل‌های تجربی دارای پیشینه تئوریک بسیار کمی هستند. متغیرها و ثوابت موجود در این مدل‌ها دارای معنای دقیقی در معادلات فیزیکی و شیمیایی پدیده‌ها نیستند و با توجه به تجربیات و داده‌های تاریخی موجود، به عنوان پارامترهای تأثیرگذار بر رفتار سیستم یا پدیده، شناسایی شده‌اند. زمانی که این مدل‌ها از پایگاه داده بزرگ و قابل اطمینانی از داده‌های تجربی تغذیه شوند، می‌توانند برای پیش‌بینی رفتار پدیده‌هایی که فرایندهای داخلی آنها ناشناخته و یا پیچیده است، مناسب باشند. افزودن دانش جدید به این مدل‌ها به نسبت مشکل است و نیاز به تنظیم دوباره کل مدل دارد.

اهمیت در نظر گرفتن تأثیر نفت خام در خوردگی و ضرورت توجه به آن در آزمایش و پیش‌بینی نرخ خوردگی توسط افرد^۱ مورد توجه قرار گرفته است. (Efrird, 1991:5) او هم‌چنین معیاری برای میزان آب موجود در نفت خام که خوردگی را افزایش می‌دهد و آن را به یک مشکل تبدیل می‌کند، تعیین نموده است.

اسمارت نشان داده است که نفت خام ترکیبات فعال سطحی (ترکیبات قطبی همچون اکسیژن، نیتروژن و سولفور) دارد که روی خوردگی تأثیرگذار هستند. (Smart, 1993:10) در تحقیقاتی، میزان خوردگی به صورت عددی مدل شده و مشخص شده که ترکیبات شیمیایی نفت از جمله اشباع‌ها^۱، آروماتیک‌ها^۲، رزین‌ها^۳، آسفالتین‌ها^۴، نیتروژن و سولفور^۵ در خوردگی نقش به‌سزایی دارند. (Hernandez et al, 2003:12)

دیدگاهی هم در مورد متغیرهایی در ترکیب نفت خام که می‌توانند بر میزان خوردگی یا بازدارندگی نفت خام تأثیرگذار باشند ارائه شده است. در این کار یک تحلیل آماری روی چند نوع نفت خام ونزوئلایی به صورت تجربی در شرایط یکسان انجام شد، نفت خام‌ها به دو دسته پارافینیک^۶ و آسفالتینیک^۷ براساس اشباع‌ها، آروماتیک‌ها، رزین‌ها و آسفالتین‌ها تقسیم‌بندی شدند. تأثیر مشخصه‌های فیزیکی و شیمیایی نفت خام با استفاده از رگرسیون خطی چند متغیره محاسبه شده است. (Hernandez et al, 2002:6)

در سال‌های اخیر استفاده از هوش مصنوعی در زمینه مدل‌سازی فرایندهای خوردگی مورد توجه قرار گرفته است. شبکه‌های عصبی مصنوعی یکی از روش‌های بسیار پر استفاده در زمینه مدل‌سازی فرایند خوردگی شده‌اند. در ادامه برخی از تحقیقات در مورد خوردگی که در آنها از شبکه عصبی برای مدل‌سازی استفاده شده، معرفی می‌گردد.

یکی از جدی‌ترین کارهایی که برای استفاده از شبکه‌های عصبی در مسائل خوردگی صورت گرفت و جزو اولین‌ها در این زمینه بوده است، پیش‌بینی نرخ خوردگی با استفاده از شبکه عصبی توسط اسمتس و بوگارتس بوده است. آنها در کار خود یک شبکه عصبی

-
- 1- Saturates
 - 2- Aromatics
 - 3- Resins
 - 4- Asphaltenes
 - 5- Sulphur
 - 6- Paraffinic
 - 7- Asphaltenic

تولید کردند و با استفاده از آن به پیش‌بینی SCC^1 بر روی فولاد زنگ نزن نوع ۳۰۴ در حضور ترکیبات کلراید و اکسیژن‌دار و دمای مشخص پرداختند. آنها دریافتند که روش شبکه‌های عصبی در این امر نسبت به روش رگرسیون سنتی برتری دارد. (*Smets*)
(*H.M. and G.Bogaerts, 1992:16*)

در تحقیق دیگری یک مدل شبکه عصبی جهت پیش‌بینی تعداد و عمق حفره‌های ناشی از خوردگی حفره‌ای^۲ تولید شد. البته اطلاعاتی در مورد توپولوژی و اندازه شبکه و نحوه آموزش آن داده نشده است. پیشرفت در عمق حفره‌ها و تعداد آنها به صورت مؤثر مدل‌سازی شد و نتایج خوبی را در مقایسه با داده‌های تجربی نشان داد. (*Urquidi-Macdonald e al, 1993:326*)

از شبکه عصبی برای پیش‌بینی نوع خوردگی از منحنی پلاریزاسیون^۳ استفاده شده است. ورودی‌های شبکه چگالی و پتانسیل خوردگی حفره‌ای بوده و خروجی‌های آن ریسک به وجود آمدن هر کدام از خوردگی‌های عمومی، حفره‌ای و شکننده بوده است. (*Silverman, D.C. and E.M. Rosen, 1992:14*)

نسیک و دیگران در مقاله‌ای به دو مشکل مهم که باعث می‌شود از شبکه‌های عصبی کمتر در مباحث خوردگی استفاده شود اشاره کرده‌اند. اولین دلیل را عدم آشنایی مهندسان خوردگی با مقوله هوش مصنوعی و شبکه عصبی و کاربرد آن در پیش‌بینی خوردگی دانسته‌اند و دلیل دوم آن را عدم وجود داده‌های کافی و وجود داده‌های گم‌شده در این امر دانسته‌اند. البته در این مقاله در بخش اول توضیحاتی در مورد شبکه عصبی برای آشنایی اولیه مهندسان خوردگی آمده است و در بخش دوم روش مونت کارلو^۴ معرفی شده و در حین آن یک کار عملی انجام شده است. (*Nesic et al, 2001:10*)

تراساتی و گابتا در تحقیقی یک شبکه عصبی تولید کردند که از نفت خام، عدد اسید^۵ و درصد سولفور، از ترکیبات شیمیایی مواد، درصد کرومیوم و درصد مولیبدینم، از شرایط

1- Stress Corrosion Cracking
2- Pitting Corrosion
3- Polarization Curve
4- Monte Carlo approach
5- Total Acid Number

عملیاتی فرایند (دما، فشار و نرخ جریان^۱) را به عنوان ورودی و از نرخ خوردگی با واحد میلیمتر در سال (*mpy*) به عنوان خروجی استفاده کردند و نرخ خوردگی را با موفقیت از طریق شبکه عصبی تولید شده پیش‌بینی نمودند. (*S.P. Trassati and G. Gabbeta, 2006: 5*)

روش تحقیق

این تحقیق در زمینه استفاده از شبکه‌های عصبی جهت پیش‌بینی نرخ خوردگی سیستم‌های بالاسری یک پالایشگاه بوده است. بنابراین تحقیق، کاربردی و روش انجام آن مورد کاوی می‌باشد.

۱- شیوه‌های گردآوری اطلاعات در این تحقیق از طرق بررسی‌های نظری، مشاهده و مصاحبه با افراد خبره بوده است. همچنین پیش‌بینی صورت گرفته در این تحقیق براساس داده‌های واقعی و گردآوری شده از پایگاه داده‌های موجود در پالایشگاه مورد تحقیق می‌باشد. برای گردآوری اطلاعات از پایگاه داده موجود در پالایشگاه مورد تحقیق که شامل همه داده‌های اندازه‌گیری شده بصورت روزانه می‌باشد، استفاده شده است. پس از تهیه پایگاه داده ذکر شده و در جلسه‌ای که ۱۸ نفر از مهندسان و کارشناسان واحد خوردگی و بازرسی فنی پالایشگاه در آن شرکت داشتند، عامل خوردگی در تجهیزات و سیستم‌های بالاسری واحدهای تقطیر نفت خام در پالایشگاه مورد تحقیق رفتار نفت خام و مواد شیمیایی موجود در آن در شرایط عملیاتی ذکر گردید.

مشخصه‌هایی از نفت خام که به صورت روزانه و یا دوره‌ای اندازه‌گیری می‌شوند عبارت بودند از ترکیبات اشباع^۲، آروماتیک‌ها^۳، رزین‌ها^۴، آسفالتین‌ها^۵، گراویتی^۶، عدد اسید^۷،

-
- 1- Flowrate
 - 2- Saturated components
 - 3- Aromatics
 - 4- Resins
 - 5- Asphaltines
 - 6- Gravity
 - 7- Total Acid Number (TAN)

گوگرد، نیتروژن، نمک، فشار بخار^۱، آب و املاح^۲ و میزان آهن موجود در آب ترش بالاسری که در پالایشگاه مورد تحقیق به عنوان شاخصی از میزان خوردگی تجهیزات بالاسری به شمار می‌رود.

نحوه نگهداری داده‌های ذکر شده در پالایشگاه مورد تحقیق به این صورت است که برای هر روز در هر ماه و در هر سال یک فایل *Excel* جداگانه حاوی تمام اطلاعات اندازه‌گیری شده آن روز وجود دارد. داده‌های ذکر شده برای سه سال متوالی ۱۳۸۵، ۱۳۸۶ و ۱۳۸۷ از فایل‌های *Excel* موجود جمع‌آوری و در یک فایل ذخیره گردید.

۲- بعد از جمع‌آوری داده‌ها، یک سری عملیات آماده‌سازی روی آنها انجام گردید، ابتدا کنترل شد که اعداد کامل باشند و احتمالاً عددی از قلم نیفتاده باشد که به علت دقت ثبت اعداد اندازه‌گیری شده در پالایشگاه مورد تحقیق این موضوع وجود نداشت. همچنین نقاط اخلاص که در فرایند پیش‌بینی ممکن است تأثیر نامطلوب داشته باشد نیز در صورت وجود حذف شد. پس از انجام این تغییرات، مجموعاً تعداد ۸۳۷ رکورد داده جهت ورود به شبکه عصبی آماده گردید.

۳- برای ایجاد شبکه عصبی مرحله اول، تولید ساختار شبکه‌ای است، که در پیش‌بینی خوردگی کارا تر می‌باشد. چهار مرحله اصلی برای تولید شبکه عصبی به این صورت است:

- انتخاب داده‌ها و تقسیم آنها به سه بخش آموزش، ارزیابی و آزمون: ابتدا داده‌های تحقیق متناسب با الگوی ورودی ساختارهای مورد نظر که در این تحقیق الگوی ثابتی است به صورت آرایه‌های ورودی خروجی تبدیل شد. این عمل با *Export* کردن فایل *Excel* به فرمت *CSV*^۳ که فرمتی قابل قبول برای نرم‌افزار *Neurosolutions* به عنوان ورودی می‌باشد صورت گرفت.

1- Vapor Pressure

2- Water and Base sediment (W&BS)

3- Comma Separated Values

بعد از تبدیل داده‌ها به صورت فوق، کل داده‌ها به سه قسمت تقسیم شدند: مجموعه آموزش^۱ یا یادگیری شبکه شامل ۷۰ درصد کل داده‌ها، مجموعه ارزیابی شامل ۱۵ درصد کل داده‌ها و مجموعه آزمون شامل ۱۵ درصد کل داده‌ها.

فرایند یادگیری شبکه به این صورت است که ابتدا داده‌ها مربوط به یادگیری که در این تحقیق به صورت ۱۱ ورودی و یک خروجی مطلوب می‌باشد به شبکه وارد می‌گردند. وزن‌های اولیه اتصالات بین نرون‌ها به صورت تصادفی توسط شبکه تنظیم می‌گردند. پس از بارگذاری^۲ داده‌های مجموعه یادگیری و تنظیم وزن‌های شبکه، اولین داده داده به عنوان ورودی به شبکه اعمال شده و خروجی شبکه با استفاده از توابع تبدیل الگوریتم یادگیری محاسبه شده و با خروجی مطلوب مقایسه می‌گردد. در اینجا شبکه با استفاده از خطای حاصله وزن‌های شبکه را تغییر می‌دهد. این عملیات برای کل داده‌های آموزش تکرار می‌گردد. بنابراین پس از اعمال هر ورودی، وزن‌های شبکه به هنگام می‌شوند. هر بار تکرار فرایند فوق برای کل داده‌های آموزش یک *Epoch* نام دارد. بعد از هر *Epoch* میانگین مربعات خطا^۳ محاسبه شده و با *MSE* هدف (که قبلاً تعیین می‌گردد) مقایسه می‌شود. در صورتی که خطا بزرگتر از خطای هدف باشد، دوباره یک *Epoch* دیگر شروع می‌گردد. (البرزی، ۱۳۸۶، ص ۶۳)

بنابراین در اینجا شرط توقف یادگیری، رسیدن به خطای هدف است. برای جلوگیری از طولانی شدن زمان یادگیری عدد ۱۰۰۰۰ به عنوان شرط حداکثر تکرار *Epoch* جهت توقف مرحله یادگیری نیز تعیین گردید.

از طرف دیگر چون ممکن بود قبل از رسیدن به شروط توقف، فرایند یادگیری بر روی داده‌های آموزش بیش از حد باشد (یادگیری بیش از حد^۴) و در نتیجه علی‌رغم کاهش خطا در مجموعه آموزش، کارایی شبکه در پیش‌بینی داده‌های مجموعه آزمون کاهش یابد، لذا از مجموعه داده‌های ارزیابی جهت کنترل خطای شبکه استفاده گردید. به این ترتیب بعد از هر *Epoch*، کارایی شبکه بر روی مجموعه داده ارزیابی توسط شبکه

1- Training Set

2- Loading

3- Mean Square Error-MSE

4- Overtraining

بررسی می‌گردد. در صورتی که خطای مجموعه داده‌های ارزیابی نیز رو به کاهش باشد، فرایند یادگیری ادامه می‌یابد. در غیر این صورت یادگیری شبکه متوقف گردیده و مجموعه داده‌های آزمون پیش‌بینی می‌گردد. توضیحات بیشتر در قسمت شرط توقف آمده است.

• انتخاب معماری درست شبکه و الگوریتم مناسب جهت آموزش آن: تعدادی از شبکه‌های عصبی با ساختارهای متفاوت از جمله پرسپترون چند لایه^۱، شبکه عصبی ماژولار^۲، RBF ^۳ جهت انجام پیش‌بینی مورد استفاده قرار گرفت تا با در نظر گرفتن MSE ، ساختاری که دقیق‌تر می‌باشد، انتخاب شود. توضیحات مربوط به هر کدام از معماری‌های شبکه‌های ذکر شده که در این تحقیق و با داده‌های موجود آزمایش شدند در جدول ۱ آورده شده است.

خطا (MSE)	الگوریتم آموزش	تابع انتقال	ساختار	تعداد لایه‌های میانی	نوع شبکه
۰,۰۰۴۹	BP	تانژانت هیپربولیک	۱۱-۸-۱	۱	MLP
۰,۰۰۳۶	BP	لجستیک	۱۱-۶-۱	۱	MLP
۰,۰۰۲۲	BP	تانژانت هیپربولیک	۱۱-۱۰-۸-۱	۲	MLP
۰,۰۰۳۵	BP	تانژانت هیپربولیک	۱۱-۱۰-۸-۱	۲	MLP
۰,۰۰۲۴	BP	تانژانت هیپربولیک	۱۱-۶-۶-۱	۲	MLP با بهینه‌سازی ژنتیک

جدول ۱: ارزیابی معماری‌های مختلف شبکه عصبی مورد استفاده در این تحقیق

• استفاده از الگوریتم ژنتیک برای بهینه‌سازی پارامترهای شبکه: با توجه به موارد مطرح در پیشینه تحقیق و ادبیات موضوع به نظر می‌رسد که استفاده از پرسپترون چند لایه می‌تواند مناسب باشد، حال از امکان نرم‌افزاری الگوریتم ژنتیک که در نرم‌افزار وجود دارد برای به دست آوردن پارامترهای بهینه برای شبکه استفاده

می‌شود. در این روش فقط، بدترین عضو جامعه در هر تکرار تعویض خواهد شد. این روش پیشروی در مقایسه با روش پیشروی مولد زودتر به نتیجه می‌رسد. عملگر ژنتیک که در این الگوریتم مورد استفاده قرار می‌گیرد، عملگر انتخاب^۱ نام دارد. این عملگر کروموزومی که باید در جامعه نسل بعدی شرکت بکند را انتخاب می‌نماید. با استفاده از عملگرهای ترکیب و یا جهش این کروموزوم بهینه شده و به جمعیت نسل بعدی اضافه می‌شود. فرایند ترکیب^۲ ساختن کروموزوم جدید با اتصال دو والد می‌باشد، بنابراین کروموزوم جدید مشخصات هر دو کروموزوم والد را خواهد داشت. شاخص احتمال ترکیب^۳ فرایند ترکیب را کنترل می‌نماید.

عملگر دیگر ژنتیکی به نام جهش^۴ برای تغییر یک یا چند ژن در یک کروموزوم خاص مورد استفاده قرار می‌گیرد و مقدار جدیدی را برای ژن ایجاد می‌کند. با استفاده از این مقدار جدید ژن الگوریتم ژنتیک می‌تواند نتایج بهتری را در قیاس با ژن قبلی به دست آورد.

براساس تجربه و با توجه به جدول ۱ یک شبکه عصبی پرسپترون چند لایه با دو لایه پنهان به صورت ۱-۶-۱۱ با شش عدد المان پردازشگر^۵ و تابع انتقال تانژانت هایپربولیک انتخاب شد. از الگوریتم پس انتشار خطا^۶ جهت آموزش استفاده شد. برای سرعت بخشیدن به فرایند آموزش شبکه و اطمینان از این که همگرایی شبکه به می‌نیمم مطلق بیشتر می‌شود، نرخ مومنتوم^۷ و *Step-Size* ها در طول آموزش متغیر بود.

• در نظر گرفتن تمهیداتی جهت پایان آموزش: الگوریتم آموزش به کار رفته در این تحقیق بردارهای وزن که پارامترهای ورودی شبکه را به خروجی مورد انتظار

-
- 1- Selection
 - 2- Crossover
 - 3- Crossover Probability
 - 4- Mutation
 - 5- Processing Elements
 - 6- Back propagation-BP
 - 7- Momentum

منطبق می‌کنند را تولید می‌کند. این بردارهای وزن در ابتدا به صورت تصادفی مقداردهی می‌شوند و در طول فرایند آموزش تنظیم می‌شوند. سه معیار زیر برای تشخیص نقطه پایان آموزش مدنظر قرار گرفت: حداکثر تعداد *Epoch*ها، عدم بهبود نتایج ارزیابی با آموزش بیشتر و بهبود نتایج ارزیابی با آموزش بیشتر. پارامترهای آموزش مورد استفاده برای شبکه *MLP*، ۱-۶-۶-۱۱ مورد استفاده در این تحقیق در جدول ۲ آورده شده است.

مقدار	پارامترهای شبکه
۰/۰۱	<i>Step Size</i>
۰/۷	مومنتم
۱۰۰۰۰	تعداد <i>Epoch</i> ها
۱۰۰	تعداد <i>Epoch</i> ها بدون بهبود در نتایج ارزیابی

جدول ۲: پارامترهای آموزش و شرط توقف شبکه

- ۴- در مرحله بعدی تحلیل حساسیت صورت گرفت. تحلیل حساسیت در حقیقت تأثیرات متقابل بین متغیرهای ورودی و شناخت میزان تأثیر هر یک از آنها بر روی خروجی شبکه می‌باشد. تحلیل حساسیت براساس میزان تغییر خروجی با تغییر هر یک از ورودی‌ها صورت گرفت و نمودار آن از سیستم به عنوان خروجی دریافت شد.
- ۵- برای کشف میزان اهمیت نسبی هر کدام از متغیرهای ورودی و میزان تأثیرگذاری آن‌ها بر روی خروجی از الگوریتم گارسن استفاده شد. الگوریتم گارسن نشان می‌دهد که هر کدام از ورودی‌ها چه میزان بر خروجی تأثیرگذار هستند و مشخص می‌کند که کدام یک از متغیرهای ورودی تأثیر کمی بر خروجی دارند و می‌توان آنها را در تحقیقات بعدی حذف کرد.


یافته‌های تحقیق

۱- با توجه به نتایج جدول ۳ یک شبکه پرسپترون چند لایه به صورت ۱-۶-۶-۱۱، بالاترین دقت را در میان داده های مجموعه آموزش داشته است. کم بودن خطای آزمایش نیز که اختلاف میان خروجی شبکه و خروجی مورد انتظار می باشد، یک شاخص دیگر در ارزیابی عملکرد مدل می باشد. جدول ۱ خطای MSE و دقت مدل شبکه عصبی انتخاب شده را نمایش می دهد.

خطای MSE	ضریب همبستگی	معماری شبکه
0.0026	$R = 96.7\%$	۱۱-۶-۶-۱ MLP

جدول ۳: خطای آموزش و خطای آزمون شبکه عصبی انتخاب شد.

در شکل ۱ عملکرد شبکه با توجه به دقت مدل و خطای MSE مقایسه می شود. پارامتر مهم دیگر، زمانی است که مدل برای رسیدن به کمترین MSE صرف کرده است. در این مدل، در سریع ترین حالت شبکه پس از ۳۵۰۰ epoch به پائین ترین MSE دست پیدا کرد.



شکل ۱: عملکرد شبکه، داده‌های آموزش در مقابل داده‌های آزمایش

۲- نتایج بدست آمده در تحلیل حساسیت در شکل‌های ۲ تا ۱۴ آورده شده است. شکل ۲ که تحلیل حساسیت کلی مدل را نمایش می‌دهد، نشان‌دهنده تأثیر کلی هرکدام از پارامترها در مقایسه با سایر پارامترها بر روی خروجی می‌باشد. در شکل ۴، مقدار درصد گوگرد در نفت خام در محور افقی و مقدار خوردگی در محور عمودی نشان داده شده است. همانطور که در نمودار دیده می‌شود، افزایش مقدار گوگرد در نفت خام باعث افزایش خوردگی با ضریب حدوداً ۱۰ درصد گردیده است و این نشان از تأثیر چشمگیر گوگرد موجود در نفت خام بر روی خوردگی دارد.

مقدار نمک موجود در نفت خام بر حسب پوند در هر هزار بشکه اندازه‌گیری می‌شود. نمک‌های موجود در نفت خام بصورت کلرورهای سدیم، منیزیم و کلسیم می‌باشد که یون کلر آن‌ها اندازه‌گیری می‌شود. از زمان استخراج نفت خام از چاه‌های تولیدی در چندین مرحله نمک‌زدایی مقدار نمک کاهش داده می‌شود. در هنگام ورود نفت خام به واحدهای تقطیر پالایشگاه مورد تحقیق نیز یک دستگاه نمک‌زدا وجود دارد که مقدار نمک را کاهش می‌دهد. منحنی شکل ۵ نشان‌دهنده آن است که افزایش مقدار نمک از ۳ الی ۴ *PTB* بطور زیادی (با ضریب حدوداً ۱۰ درصد) خوردگی را افزایش می‌دهد. بنابراین کنترل مقدار نمک از اهمیت فوق العاده‌ای برخوردار است.

در منحنی‌های مربوط به رزین‌ها، اشباع‌ها، آسفالتین‌ها، فشار بخار و آروماتیک‌ها در شکل‌های ۶، ۷، ۸، ۹، ۱۰ مشاهده می‌شود که افزایش آن‌ها تغییرات کمی (با ضریب حدود ۱ درصد) بر روی خوردگی دارد و به نظر می‌رسد در مقابل سایر عوامل قابل چشم‌پوشی هستند.


منحنی شکل ۱۲ میزان تأثیر مقدار آب و املاح نفت خام را بر روی خوردگی نشان می‌دهد. مشاهده می‌شود که افزایش آب و املاح باعث افزایش خوردگی با ضریب حدود ۱۰ درصد شده است. بنابراین کنترل آن با استفاده از دستگاه‌های نمک‌زدا و شستشوی نفت خام با آب کاهش خوردگی را امکان‌پذیر می‌نماید.

همانطور که در منحنی شکل ۱۴ دیده می‌شود عدد اسید نفت خام، در این مرحله تأثیر قابل ملاحظه‌ای بر روی خوردگی در سیستم بالاسری تقطیر نفت خام نداشته است.

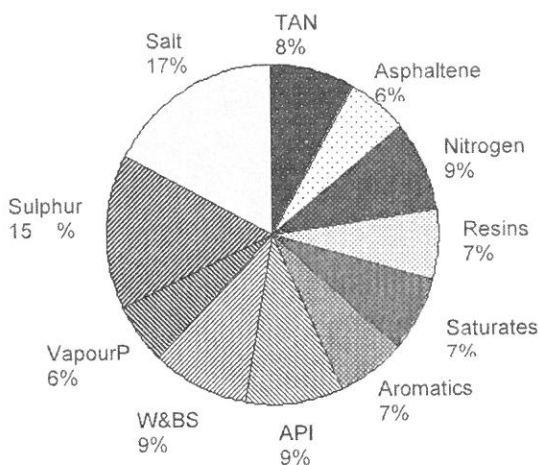
منحنی شکل ۱۳ ارتباط بین *API* نفت خام و مقدار خوردگی سیستم بالاسری را نشان می‌دهد. با توجه به تأثیر قابل توجه *API* بر روی خوردگی، مشخص می‌شود که هر چه نفت خام سنگین‌تر شود، میزان تأثیر آن بر خوردگی سیستم بالاسری بیشتر خواهد شد. ۳- برای کشف میزان اهمیت نسبی هر کدام از متغیرهای ورودی و میزان تأثیرگذاری آن‌ها بر روی خروجی از الگوریتم گارسن استفاده شده است. در شکل ۳، نتایج این الگوریتم در قالب نمودار دایره‌ای، آورده شده است.

الگوریتم گارسن نشان می‌دهد که هر کدام از ورودی‌ها چه میزان بر خروجی تأثیرگذار هستند و مشخص می‌کند که کدام یک از متغیرهای ورودی تأثیر کمی بر خروجی دارند


و می‌توان آنها را در تحقیقات بعدی حذف کرد. از شکل ۳ می‌توان فهمید که نمک، آب و املاح و گوگرد بیشترین تأثیر را بر روی خروجی دارند، در حالی که بقیه عوامل تأثیر تقریباً یکسانی بر روی خروجی دارند.




شکل ۲: نتیجه تحلیل حساسیت کلی




شکل ۳: نتایج الگوریتم گارسن



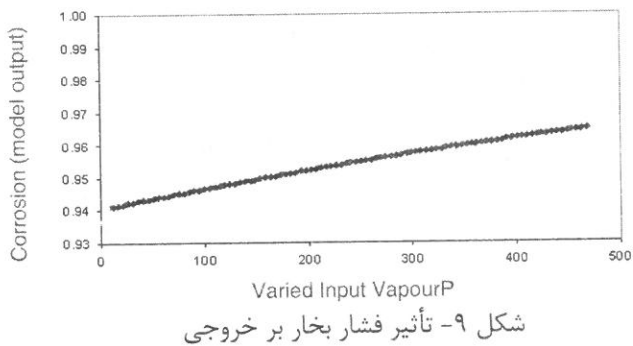


شکل ۴- تأثیر گوگرد بر خروجی




شکل ۵- تأثیر نمک بر خروجی




شکل ۶- تأثیر ترکیبات اشباع بر خروجی







شکل ۱۰- تأثیر آروماتیک‌ها بر خروجی




شکل ۱۱- تأثیر نیتروژن بر خروجی



شکل ۱۲- تأثیر آب و املاح بر خروجی



شکل ۱۳- تأثیر API بر خروجی



شکل ۱۴- تأثیر عدد اسید بر خروجی

نتیجه‌گیری و پیشنهادات

انواع مختلف نفت خام ورودی به برج‌های تقطیر، باعث تغییر در نرخ خوردگی و شدت و ضعف آن می‌شوند. پیچیدگی ذاتی پدیده خوردگی باعث می‌شود که نتوان صرفاً با استفاده از روش‌های مکانیستیک و توجه به فرایندهای شیمیایی و الکتروشیمیایی به مدل‌سازی و پیش‌بینی آن پرداخت. با توجه به وجود پایگاه داده‌ای از انواع نفت خام ورودی به برج تقطیر و میزان خوردگی در پالایشگاه مورد تحقیق، می‌توان با استفاده از شبکه عصبی به مدل‌سازی و پیش‌بینی خوردگی پرداخت.

نتایج حاصل از تحلیل حساسیت نشان می‌دهد که نمک، گوگرد، گراوتینی و آب و املاح بیشترین تأثیر را بر روی خوردگی تجهیزات دارند و نتایج الگوریتم گارسن بر روی این موضوع تأکید می‌کند.

بنابراین پیشنهاد می‌گردد:

- ۱- استفاده از شبکه‌های عصبی برای پیش‌بینی نرخ خوردگی در پالایشگاه‌ها و به خصوص پالایشگاه مورد تحقیق می‌تواند اطلاعات ارزشمندی را برای شناخت پارامترهایی از نفت خام که تأثیرات زیادی بر روی خوردگی دارند، فراهم آورد. بنابراین پیشنهاد می‌شود که از شبکه‌های عصبی مصنوعی برای مواجهه با مسأله خوردگی در پالایشگاه استفاده شود.

- ۲- کارشناسان واحدهای خوردگی و بازرسی فنی پالایشگاه‌ها و به خصوص پالایشگاه مورد تحقیق، می‌توانند با استفاده از اطلاعات به دست آمده از تحلیل حساسیت صورت گرفته بر روی مدل، پارامترهایی از نفت خام که بیشترین تأثیر را بر خوردگی دارند مشخص نموده و در مرحله قبل از ورود نفت خام به برج‌های تقطیر که نفت خام ورودی به صورت ترکیبی از چند نفت خام مختلف موجود در پالایشگاه تولید می‌شود، با تنظیم آن پارامترها در کاهش نرخ خوردگی تجهیزات مؤثر باشند.
- ۳- وجود گروهی برای اندازه‌گیری و ثبت پارامترهای نفت خام و دیگر پارامترهای مهم در پالایشگاه مورد تحقیق باعث به وجود آمدن یک پایگاه داده قوی شده‌است. اما بکار نرفتن این داده‌ها نشان‌دهنده عدم وجود واحد و گروهی برای تحلیل این آن‌ها می‌باشد. به وجود آمدن این گروه و استفاده از شبکه عصبی جهت کشف روابط پنهان و دانش موجود در داده‌های ذکر شده می‌تواند منجر به کاهش صدمات و هزینه‌های ناشی از خوردگی شود.

پیشنهاد برای تحقیقات آتی:

- ۱- همانطور که گفته شد، انتخاب توپولوژی و نوع شبکه عصبی بصورت تجربی صورت می‌پذیرد. به نظر می‌رسد استفاده از الگوریتم ژنتیک برای انتخاب توپولوژی و نوع شبکه عصبی علاوه بر استفاده از آن در بهینه‌سازی پارامترهای شبکه می‌تواند در انتخاب بهتر توپولوژی و نوع شبکه عصبی مؤثر باشد. بنابراین پیشنهاد می‌شود در تحقیقات آتی به امکان‌پذیری و نحوه استفاده از الگوریتم ژنتیک در انتخاب نوع و ساختار شبکه عصبی پرداخته شود.
- ۲- همانطور که از نتایج تحقیق مشخص است، شبکه عصبی توانسته است به خوبی خوردگی را مدلسازی و نرخ آنرا پیش‌بینی کند. با توجه به موفقیت در این زمینه پیشنهاد می‌شود که از این روش در پیش‌بینی نرخ خوردگی در تجهیزات دیگر موجود در سیستم‌های پالایش استفاده گردد.

منابع و مأخذ

- ۱- آر. بیل و تی. جکسون (۱۳۸۶)، آشنایی با شبکه‌های عصبی، ترجمه: محمود البرزی، چاپ دوم، تهران: مؤسسه انتشارات علمی دانشگاه صنعتی شریف
- 2- Efirid و K. D. (1991). *Preventive Corrosion Engineering in Crude Oil Production*. Offshore Technology Conference (OTC), Paper no. 6599.
- 3- Hernandez S., S. Duplat, J. R. Vera, E. Barón. (2002). *A statistical approach for analyzing the inhibiting effects of different types of crude oil in CO₂ corrosion of carbon steel*. Corrosion/2002, Paper no. 02293. National Association of Corrosion Engineers.
- 4- Hernandez S., J. Bruzual, F. Lopez-Linares, J. Luzon. (2003). *Isolation Of Potential Corrosion Inhibiting Compounds in Crude Oils*. NACE International, Corrosion/2003, Houston, TX, Paper No. 03330.
- 5- Nesic, S. , Nordsveen, M., Maxwell N., Vrhovac, M. (2001). *Probabilistic modeling of CO₂ corrosion laboratory data using neural networks*. Corrosion Science, VOL. 43.
- 6- Smart, J. S. (1993). *Wettability – a Major Factor in Oils and Gas System Corrosion*. NACE Corrosion/93, Paper no. 70.
- 7- Smets, H. M. G., Bogaerts, W. F. L. (1992). *Neural network prediction of stresscorrosion Cracking*. Mater Perform, Vol. 31.
- 8- Silverman D. C, Rosen E. M. (1992). *Corrosion prediction from polarization scans*
- 9- *using an artificial neural network integrated with an expert system*. Corrosion/92, Vol. 48.
- 10- Trassati, S. P. , Gabbetta G. (2006), *Study of naphtenic acid corrosion by neural network*. Corrosion Engineering, Science, and Technology, Vol 41.

- 11- *Urquidi-Macdonald, M., Eiden, M. N., Macdonald D. D. (1993). Development of a neural network model for predicting damage functions for pitting corrosion in condensing heat exchangers. Modifications of Passive Films, Paris.*