

## تعیین سرعت رشد خستگی در اتصالات لوله‌ای به وسیله شبکه‌های عصبی مصنوعی

مهندس علی فتحی<sup>۱</sup>، دکتر علی اکبر آقا کوچک<sup>۲</sup>

۱- دانشجوی سازه‌های دریایی، مقطع کارشناسی ارشد، دانشگاه تربیت مدرس

۲- دانشیار سازه، دانشگاه تربیت مدرس

## چکیده

برای تخمین عمر باقیمانده سازه یک سکوی دریایی و تدوین برنامه زمان‌بندی بهینه جهت بازرسی و تعمیر در زیر آب، نیاز است تا آهنگ رشد ترک خستگی در اتصالات لوله‌ای به صورت مناسب پیش‌بینی شود. به دلیل کوچک بودن شعاع منطقه پلاستیک در نوک ترک خستگی، مکانیک شکست الاستیک خطی و ضریب شدت تنش، ابزار مناسبی برای تعیین سرعت رشد ترک خستگی بشمار می‌روند. راهکارهای متنوعی با استفاده از روشهای مختلف برای تعیین سرعت رشد ترک خستگی در اتصالات لوله‌ای بر اساس قانون رشد ترک پاریس معرفی شده‌اند که نتایج حل آنها منجر به ارائه معادلاتی برای تعیین ضریب اصلاح شدت تنش (Y) شده است. در این تحقیق قابلیت شبکه‌های عصبی مصنوعی در پیش‌بینی سرعت رشد ترک در اتصالات لوله‌ای T تحت بار محوری در حالتی که عمق ترک بیش از ۲۰٪ ضخامت جداره عضو اصلی است، مورد ارزیابی قرار گرفته است. در این مرحله از رشد ترک، فرآیند رشد بیشترین تأثیر را از هندسه اتصال و مد بارگذاری می‌پذیرد. دو نوع شبکه عصبی مصنوعی MLP و RBF برای تخمین ضریب اصلاح شدت تنش در عمق ترک خستگی طراحی شده و آموزش دیده است. اطلاعات ورودی برای این شبکه‌ها، نسبت عمق به عرض ترک و درصد رشد ترک در عمق جداره است. داده‌های استفاده شده برای آموزش و آزمون شبکه‌ها نتایج آزمایش روی شش اتصال T است که در مرکز NDE دانشگاه UCL انجام شده است. پس از طراحی، آموزش و آزمون شبکه‌ها و انتخاب شبکه بهینه، نتایج حل به کمک شبکه‌های عصبی با نتایج برخی روشهای موجود مقایسه شده است.

## واژگان کلیدی:

اتصالات لوله‌ای، سکوه‌های دریایی، ترک خستگی، مکانیک شکست الاستیک خطی، ضریب اصلاح شدت تنش، شبکه‌های عصبی مصنوعی

## EVALUATING THE FATIGUE CRACK GROWTH RATE IN OFFSHORE TUBULAR JOINTS USING ARTIFICIAL NEURAL NETWORKS

## Abstract:

In order to predict the residual life of offshore platforms and establish efficient schedule for underwater inspection and repair, it is necessary to estimate the fatigue crack growth rate in tubular joints properly. Linear Elastic Fracture Mechanics and Stress Intensity Factor are applicable tools for evaluating growth rate of existing fatigue cracks in offshore tubular joints. In the past several approaches based on Paris crack growth law, have been proposed in this regard. Each of these approaches use different methods for estimating the Stress Intensity Modification Factor (Y).

In this research the capability of Artificial Neural Networks for evaluating the fatigue crack growth rate in offshore tubular T-joints under axial loading is investigated, when the crack depth is more than 20% of chord wall thickness. For this condition the crack growth process is highly affected by joint geometry and loading mode. Two types of artificial neural network are developed for predicting the Y factor: Radial Basis Function (RBF) and Multi Layer Perceptron (MLP) networks. The required input data consist of the crack shape and the percentage of crack penetration through thickness. Experimental data from NDE center in University College London are used for training and testing the networks. The results of this research are compared with other existing theoretical and empirical solutions.

### Keywords:

Tubular joints, Offshore platforms, Fatigue cracks, Linear elastic fracture mechanics, Stress intensity factor, Artificial neural networks

### واژه‌نامه


<i>Batch K-mean</i>	میانگین <i>K</i> دسته‌ای
<i>Brace</i>	عضو فرعی
<i>Chord</i>	عضو اصلی
<i>Crown</i>	نقطه تاج
<i>Jacket Type Platform</i>	سکوی شابلونی
<i>Moment Release</i>	آزاد سازی لنگر
<i>Noisy Data</i>	داده‌های معشوش
<i>Saddle</i>	نقطه زین
<i>Spread Constant</i>	ضریب پخش
<i>Stress Intensity Modification Factor</i>	ضریب اصلاح شدت تنش

### مقدمه

سکوهای دریایی، سازه‌هایی هستند که با صرف هزینه‌های بسیار بالا برای بهره‌برداری از مخازن نفت و گاز در اعماق دریا مورد استفاده قرار می‌گیرند. این سکوها بسته به عمق آب محل بهره‌برداری، تکنولوژی ساخت و... انواع متفاوتی دارند که رایجترین آنها سکوهای نوع شابلونی هستند که با توجه به هزینه‌های تمام شده و روشهای ساخت و نصب، مناسبترین نوع سکو برای ناحیه فلات قاره بشمار می‌روند. این سکوها با توجه به محل قرارگیری، بارهای محیطی مخربی مثل

بارهای ناشی از امواج، زلزله، ضربه احتمالی ناشی از برخورد شناورها یا قطعات یخ و... را تجربه می‌کنند. در کنار این عوامل، خستگی پدیده‌ای است که به مرور و در تمام طول عمر سکو باعث ضعف مقاومت سازه‌ای آن می‌شود. خستگی در یک سکوی دریایی و به ویژه در اتصالات آن ناشی از اعمال تعداد بسیار زیاد سیکل بارهای دینامیکی ناشی از امواج و جریان‌ها دریایی است که در طول عمر یک سکوی عادی ممکن است به بیش از ۱۵۰ میلیون سیکل برسد [۱]. یک سکو علاوه بر اینکه در مرحله طراحی برای کنترل مقاومت در برابر خستگی تحلیل می‌شود، در حین بهره‌برداری نیز باید تحت بازرسی و ترمیم‌های دوره‌ای قرار گیرد. این عملیات در هنگام برآورد مجدد مقاومت کلی سازه، شکل بارزتری به خود می‌گیرد؛ به خصوص برای حالتی که یا عمر تئوری خستگی سکو سپری شده ولی حوزه نفتی مربوط به آن هنوز قابل بهره‌برداری است که در این حالت ادامه بهره‌برداری با عملیات ترمیم و نگهداری دقیق و مناسب امکان‌پذیر خواهد بود؛ یا اینکه حوزه نفتی به هر علت دیگر قابل استفاده نیست؛ اما سکو قابلیت استفاده مجدد در یک منطقه دیگر را دارد. در این حالت قبل از انتقال سکو به محل

جوش بوجود می‌آید. علاوه بر این، تنشهای پسماند کششی ناشی از جوشکاری را نیز نباید نادیده گرفت. به دلیل وجود همین نواقص اولیه و همچنین تأثیر خوردگی محیط، عمر مرحله جوانه‌زنی ترک در اتصالات سکوه‌های دریایی در مقایسه با زمان رشد آن نسبتاً کوتاه است؛ به طوری که در محاسبات از آن صرف نظر می‌شود. در حالت بارگذاری محوری و خمشی برون صفحه‌ای، ترک در نقطه زین و در حالت خمشی درون صفحه‌ای ترک در نقطه تاج بوجود می‌آید. شکل (۱) موقعیت محتمل ترک را حول مقطع اتصال در سه حالت بارگذاری محوری، خمشی درون صفحه‌ای و خمشی برون صفحه‌ای در یک اتصال T نشان می‌دهد.



شکل ۱- موقعیت محتمل ترک حول مقطع اتصال

در حالت‌های واقعی که بارگذاری ترکیبی از حالت‌های بالاست، موقعیت ترک بین نقطه زین و تاج است. در اتصالات پیچیده و دارای سخت‌کننده‌های حلقوی، به علت پیچیدگی زیاد هندسی و همچنین تغییر زیاد خواص فلز مبنا در هنگام جوشکاری، ممکن است ترک خوردگی از نقاط دیگر مثل بدنه سخت‌کننده نیز آغاز شود [۳].

ترک خستگی در دو جهت عمق جداره و حول مقطع اتصال رشد می‌کند. در ضمن رشد ترک در عمق جداره، مسیر ترک به سمت زیر پنجه جوش خم می‌شود (شکل (۲)) و همین خمیدگی باعث کم شدن تأثیر مدهای دوم و سوم بازشدگی ترک می‌گردد [۴]. پایان عمر خستگی در یک اتصال لوله‌ای زمانی است که ترک به وجه دیگر جداره عضو اصلی برسد و اصطلاحاً آن را سوراخ کند. با وجود آنکه در شکل ترک‌های

جدید باید از کارایی آن جهت ادامه سرویس‌دهی اطمینان حاصل کرد.

به علت هزینه‌های بسیار بالای عملیات بازرسی و ترمیم در زیر آب، بهینه‌سازی این عملیات از نظر شناسایی اتصالات بحرانی و همچنین محاسبه آهنگ رشد ترک خستگی در آنها برای تعیین دوره بازرسی و ترمیم بعدی همیشه مطلوب بوده است. به ویژه اینکه بیش از یک چهارم سکوه‌های موجود عمری بیش از ۲۵ سال دارند [۲]. تحقیقات زیاد و متنوعی با صرف هزینه‌های قابل توجه برای پیش‌بینی آهنگ رشد ترک در سکوه‌های دریایی انجام شده است که هر یک به درجه‌ای از موفقیت دست یافته‌اند؛ اما هنوز لزوم تحقیقات بیشتر و استفاده از روشها و راه‌حلهای جدید در این زمینه به چشم می‌خورد.

با توجه به توانایی و توسعه چشمگیر کاربرد هوش محاسباتی و به خصوص شبکه‌های عصبی برای حل مسائل گوناگون مهندسی در دو دهه اخیر، در این تحقیق سعی بر آن بوده است تا قابلیت این روش برای پیش‌بینی آهنگ رشد ترک یک اتصال لوله‌ای مورد آزمون و بررسی قرار گیرد.

## فرآیند تشکیل و رشد ترک خستگی در اتصالات لوله‌ای

محل پیدایش ترک خستگی در یک سازه به طور کلی در جایی است که تحت بارگذاری متناوب، دچار کرنشهای پلاستیک متناوب شود. در اتصالات لوله‌ای نیز محل ترک خوردگی حول مقطع، جایی است که از لحاظ تمرکز تنش بحرانی‌ترین حالت را دارا باشد. بنابراین محل ترک را هندسه اتصال و نحوه بارگذاری تعیین می‌کند.

با توجه به نحوه توزیع تنش حول مقطع اتصال، طول عضو منتهی به اتصال و ضخامت جداره عضو اصلی، ترک خستگی همیشه از محل پنجه جوش و از سطح رویه آغاز می‌شود؛ زیرا در این نقطه نه تنها اثر توأم افزایش تنش ناشی از هندسه اتصال و هندسه جوش وجود دارد؛ بلکه در اثر جوشکاری، هم فولاد دچار تردشدگی می‌شود و هم نواقص و معایبی در پنجه

(LEFM) از قانون رشد ترک پاریس برای تعیین آهنگ رشد ترک استفاده می‌شود که در آن سرعت رشد ترک، علاوه بر جنس ماده حاوی ترک و شرایط پیرامونی آن، تابعی از ضریب شدت تنش در محدوده مجاور نوک ترک است:

$$\frac{da}{dN} = C(\Delta K)^m \quad (1)$$

با مشخص شدن ضریب شدت تنش  $K$ ، حوزه تنش رأس ترک مشخص می‌گردد. اگر شعاع پلاستیک رأس ترک بزرگ شود، استفاده از معیار  $K$  و مکانیک شکست خطی امتیاز خود را از دست می‌دهد؛ ولی در مسایل خستگی،  $K$  یک معیار مناسب تشخیص داده شده است؛ چرا که خستگی اغلب در تکرار زیاد و دامنه تنش‌های پایین رخ می‌دهد و شعاع پلاستیک رأس ترک بزرگ نیست. ضریب شدت تنش با رابطه زیر به تنش دوردست و ابعاد ترک مربوط می‌شود:


$$K = Y\sigma\sqrt{\pi a} \quad (2)$$

که در آن  $a$  بسته به نقطه مورد بررسی، یک پارامتر اندازه ترک و  $Y$  ضریب اصلاح شدت تنش است که برای هندسه‌های واقعی با توجه به هندسه جسم حاوی ترک، شرایط گیرداری و نحوه بارگذاری دارای مقادیر مختلفی است و این مقادیر به صورت تحلیلی تنها برای حالت‌های بسیار ساده قابل محاسبه است. در اتصالات لوله‌ای با توجه به پیچیدگی اتصال و نحوه بارگذاری و توزیع تنش در آن، حل تحلیلی برای  $Y$  ممکن نیست. از این رو محققان روش‌های مختلف دیگری را برای محاسبه آن مورد استفاده قرار داده‌اند. از میان این روش‌ها می‌توان به روش‌های اندازه‌گیری آزمایشگاهی، روش‌های تجربی، روش‌های عددی، روش‌های اجزاء محدود و حل‌های اصلاح شده ورق تخت اشاره کرد [۱۰ و ۱۱].

### شبکه‌های عصبی مصنوعی

شبکه‌های عصبی مصنوعی یکی از زیرشاخه‌های دانش «هوش محاسباتی» است که با هدف شبیه‌سازی شبکه‌های عصبی زیستی ابداع شده است. این شبکه‌ها از تعداد نسبتاً زیادی عنصر پردازشگر ساده با نام نرون تشکیل شده‌اند که در لایه‌های مختلف شبکه (لایه

خستگی در اتصالات لوله‌ای پراکندگی بسیاری دیده می‌شود؛ اما تمام این ترک‌ها با نام ترک‌های سطحی نیمه بیضوی شناخته می‌شوند (شکل ۳). در این ترک‌ها برای بیان هندسه ترک از دو پارامتر  $a$  و  $c$  که به ترتیب بیانگر عمق و نصف طول ترک هستند، استفاده می‌شود.



شکل ۲- نیمرخ ترک خستگی در اتصالات لوله‌ای




شکل ۳- ترک سطحی نیمه بیضوی پس از گسیختگی اتصال

### تعیین سرعت رشد ترک در اتصالات لوله‌ای با استفاده از مکانیک شکست

در طراحی سکوها دریایی برای خستگی، منحنی‌های S-N و روش‌های مبتنی بر آن به طور گسترده مورد استفاده قرار می‌گیرند که به وسیله آنها عمر اتصال محاسبه می‌شود؛ اما در حالتی که لازم باشد مقاومت سازه‌های موجود حاوی ترک‌های خستگی، مورد ارزیابی قرار گیرند، از روش‌های مکانیک شکست برای تعیین آهنگ رشد ترک و عمر باقیمانده خستگی اتصال استفاده می‌شود. در مکانیک شکست الاستیک خطی

MLP را با دو لایه نهان نشان می‌دهد که در لایه نهان دارای تابع انتقال تانژانت هیپربولیک و در لایه خروجی دارای تابع انتقال خطی است.



شکل ۴- یک نمونه از شبکه‌های MLP

الگوریتم معمول برای آموزش شبکه‌های MLP الگوریتم پس‌انتشار خطا (BP) است. در این روش که یک روش آموزش با نظارت است، در هر چرخه یادگیری مقادیر خطا در مسیر رفت محاسبه و سیگنالهای تصحیح مقادیر وزن در یک مسیر برگشتی در شبکه توزیع می‌شوند [۶].

### شبکه‌های نوع RBF

شبکه‌های RBF دارای ساختاری پیشخور هستند که از یک لایه نهان و یک لایه خروجی تشکیل شده‌اند. لایه نهان از نرونهای با توابع انتقال شعاعی تشکیل شده است که تماماً به نرونهای لایه خروجی متصل هستند. در اغلب موارد از توابع گوسی در این لایه استفاده می‌شود. لایه خروجی این شبکه دارای نرونهای خطی است.

الگوریتم آموزش در این شبکه از دو قسمت مجزا برای لایه خروجی و لایه نهان تشکیل شده است. لایه نهان یک لایه خودسامانده است به این معنی که پارامترهای آن با توجه به توزیع مقادیر در فضای ورودی به‌هنگام می‌شوند. اما در لایه خروجی RBF برای آموزش، از روشهای با نظارت استفاده می‌شود، یعنی پارامترهای این لایه با توجه به نگاشت بین فضای ورودی و خروجی به‌هنگام می‌شوند. شکل (۵) معماری معمول این شبکه را نشان می‌دهد.

ورودی، لایه خروجی و یک یا چند لایه میانی یا نهان قرار دارند و به هم متصل هستند. هر نرون دارای تابع انتقال و ماتریس وزن است. هر سیگنال ورودی به نرون ابتدا به وسیله ماتریس وزن که در تک تک مؤلفه‌های آن ضرب می‌شود و سپس به وسیله تأثیر تابع انتقال تغییر می‌کند. سپس سیگنال خروجی، به نرون یا نرونهای لایه بعدی منتقل می‌شود. تغییر در توابع وزن نرونها باعث تغییر در جوابهای شبکه می‌شود. شبکه‌های عصبی ساخته شده از این نرونها قابلیت انجام نگاشتهای پیچیده و غیرخطی را از فضای  $n$  بعدی به فضای  $m$  بعدی دارا هستند؛ ضمن اینکه با استفاده از تکنیکهای آموزش، این شبکه‌ها فرآیند رسیدن به جواب را با حداقل خطا یاد می‌گیرند.


از بین تمام خواص شبکه‌های عصبی، خاصیت یادگیری به عنوان بارزترین ویژگی مطرح بوده و از اهمیت بالایی برخوردار است. در شبکه‌های عصبی قانون یادگیری با روابط بازگشتی و عموماً به صورت معادلات دیفرانسیلی بیان می‌شود. قانون یادگیری روندی با نظارت و یا بدون نظارت است که توسط آن ماتریسهای وزن شبکه عصبی طوری تنظیم می‌شوند که نزدیکترین جواب را به جواب دلخواه بدست دهند [۶].

### شبکه‌های نوع MLP

شبکه‌های پرسپترون چند لایه (MLP) شبکه‌هایی پیشخور با یک یا چند لایه نهان هستند که در آنها هر نرون در هر لایه به تمام نرونهای لایه بعدی خروجی می‌دهد و از تمام نرونهای لایه قبل، ورودی می‌گیرد (شبکه‌های کاملاً متصل). این شبکه‌ها پر استفاده‌ترین شبکه‌های عصبی مصنوعی در مسائل مهندسی هستند. عنصر اصلی در این شبکه‌ها نرون پرسپترون است. این نرون ترکیبی خطی از بردار ورودی را با استفاده از مقادیر وزن به صورت ورودی خالص محاسبه می‌کند، پس از تأثیر تابع انتقال خروجی را بدست می‌آورد و به عنوان ورودی به نرونهای لایه بعد منتقل می‌کند. مرسوم‌ترین توابع انتقال در شبکه‌های MLP توابع زیگموئیدی، تانژانت هیپربولیک و خطی هستند. شکل (۴) یک نمونه شبکه

جدول ۱- دامنه تغییرات تنش و محیط آزمایش برای هر اتصال


Test No.	HS Stress	environment
T1	400MPa	(Air)
T2	300MPa	(Air)
T3	225MPa	(-1000mV)
T4	225MPa	(-800mV)
T5	300MPa	(-1000mV)
T6	300MPa	(-800mV)




شکل ۵- یک نمونه از شبکه‌های RBF

اندازه‌گیری ابعاد ترک ضمن آزمایش به وسیله روش ACPD انجام گرفته است.

در مراحل مختلف رشد ترک در هر اتصال مقادیر Y بر حسب a/c و a/T با استفاده از داده‌های خام ACPD محاسبه شده و مقادیر مربوط به قسمت  $0.1 < a/T < 0.2$  از بین داده‌ها انتخاب شده‌اند. علت این امر تأثیر بسیار زیاد هندسه جوش در فرآیند رشد ترک در محدوده  $a/T < 0.2$  است. در شکل‌های (۷) و (۸) به ترتیب مقادیر Y بر حسب a/T و a/c نشان داده شده است.



شکل ۷- مقادیر Y بر حسب a/T برای شش اتصال



شکل ۸- مقادیر Y بر حسب a/c برای شش اتصال


### روند حل به کمک شبکه‌های عصبی

روند طی شده برای حل این مسأله مطابق با الگوریتم شکل (۹) است. با توجه به داده‌های موجود،

از الگوریتم‌های متداول برای آموزش شبکه RBF می‌توان به روش میانگین K برای آموزش لایه نهان و روش‌های حل دقیق و رگرسیون خطی برای لایه خروجی اشاره کرد [۷].

### معرفی داده‌های مورد استفاده

داده‌های استفاده شده در این تحقیق برای آموزش و آزمون شبکه‌ها، نتایج آزمایش روی شش اتصال لوله‌ای T شکل مشابه و در ابعاد واقعی است که در مرکز NDE در دانشگاه UCL<sup>۱</sup> انجام شده است. در این سری آزمایش‌ها هر یک از اتصالات تا گسیختگی کامل و جدا شدن شاخه از پایه، تحت تنش‌های هارمونیک متفاوت قرار گرفته‌اند. آزمایش روی دو اتصال در شرایط هوای خشک و روی چهار اتصال در شرایط مشابه آب دریا با حفاظت کاتودیک انجام شده است. در شکل (۶) مشخصات هندسی و در جدول (۱) شرایط تنش و محیط آزمایش برای نمونه‌ها ارائه شده‌اند.<sup>۲</sup>



شکل ۶- پارامترهای هندسی اتصالات مورد آزمایش

<sup>۱</sup>University College London

<sup>۲</sup>اطلاعات دقیقتر از مشخصات نمونه‌ها و نحوه آزمایش در مرجع [۸] موجود است.


در مرحله بعد باید از بین داده‌های موجود دسته‌ای برای آموزش و دسته‌ای برای آزمون اختصاص داده شوند. در جداسازی دسته‌های آموزش و آزمون از بین داده‌ها باید دانست که به علت اینکه شبکه‌های عصبی قابلیت برونیابی ندارند، باید داده‌های آموزش شامل تمام الگوهای حاوی مقادیر بیشینه و کمینه هر یک از متغیرها، اعم از ورودی و خروجی باشد تا ابتدا و انتهای بازه حل را به شبکه اطلاع دهد؛ چرا که شبکه قدرت پیش‌بینی خارج از این محدوده را نخواهد داشت. تقسیم‌بندی الگوها در این تحقیق به این صورت انجام شده است که درصد داده‌های انتخاب شده برای آموزش و آزمون برای تمام اتصالات یکسان بوده است و همچنین الگوهای شامل  $a/c$ ،  $a/T$  و  $Y$  بیشینه و کمینه در دسته آموزش قرار گرفتند. به این ترتیب از ۱۷۷ الگوی موجود، ۱۱۸ الگو برای آموزش و ۵۹ الگو برای آزمون انتخاب شدند که هر دو دسته از توزیع یکنواختی در طول گسترش ترک در اتصالها برخوردار بودند.

انتخاب نوع شبکه بیش از هر چیز تابع مسأله است. در این تحقیق از شبکه‌های  $MLP$  و  $RBF$  که اولی توانایی بالایی در نگاشتهای پیچیده و غیرخطی با تعداد نرون نسبتاً کم و دومی توانایی بالایی در خوشه‌بندی الگوها در فضای ورودی با تعداد نسبتاً بیشتر نرون (نسبت به  $MLP$ ) دارد، مورد استفاده قرار گرفته‌اند. در شبکه‌های نوع  $MLP$  در نرونهای تمام لایه‌ها از تابع انتقال لگاریتمی زیگموئیدی و در شبکه‌های  $RBF$  در لایه اول از تابع گوسی و در لایه دوم از تابع انتقال خطی استفاده شده است.

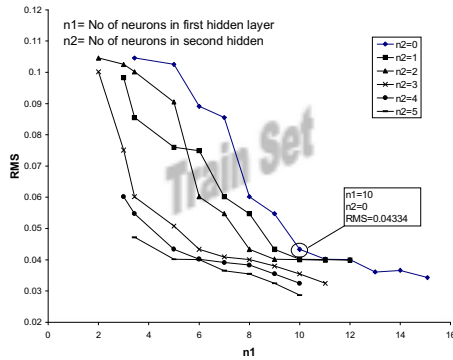
روش آموزش برای شبکه  $MLP$  روش الگوریتم پس‌انتشار خطا ( $BP$ ) بوده است. پارامترهای یادگیری الگوریتم  $BP$  به صورت سعی و خطا تا رسیدن به جواب بهینه تغییر داده شده است. برای شبکه  $RBF$  روش میانگین  $K$  دسته‌ای برای آموزش لایه اول استفاده شده و حل دقیق نیز برای آموزش لایه دوم شبکه انتخاب شده است. قبل از شروع آموزش باید داده‌های هدف (مقادیر  $Y$ ) برای شبکه  $MLP$  بین صفر و یک نرمال سازی شوند؛ چون خروجی تابع لگاریتمی

تعریف مسأله به این صورت قابل بیان است: «ساخت و آموزش شبکه‌هایی برای اتصالات  $T$  تحت بار محوری که با دانستن مقادیر  $a/c$  و  $a/T$ ، بتواند مقدار ضریب اصلاح شدت تنش را پیش‌بینی کند». با تعیین  $Y$  و معلوم بودن مقدار دامنه تغییرات تنش و ثوابت پاریس، سرعت رشد ترک در هر مرحله از رشد (برای  $1/0 < a/T < 0/2$ ) قابل محاسبه خواهد بود.

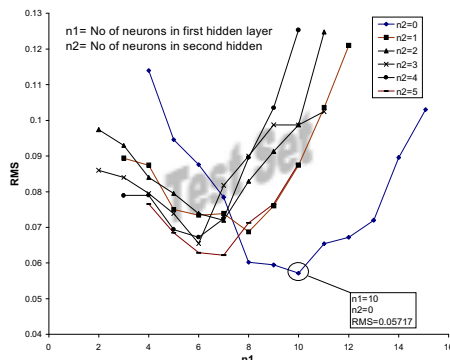
با تعریف مسأله، پارامتر هدف خود به خود مشخص می‌شود. تعداد پارامترهای هدف، مستقل از نوع شبکه، برابر با تعداد نرونهای لایه خروجی است که برای این مسأله برابر با یک است.



شکل ۹- الگوریتم حل مسأله به کمک شبکه‌های عصبی




شکل ۱۰- مقادیر RMS برای شبکه‌های MLP با معماری مختلف در دسته داده‌های آموزش



شکل ۱۱- مقادیر RMS برای شبکه‌های MLP با معماری مختلف در دسته داده‌های آموزش

در شکل‌های (۱۲) و (۱۳) داده‌های واقعی به ترتیب در برابر مقادیر آزمون و آموزش شبکه و خط راست برازش شده به آنها نمایش داده شده است.



شکل ۱۲- مقادیر Y پیش‌بینی شده توسط شبکه MLP بهینه در برابر مقادیر واقعی در دسته داده‌های آموزش

زیگموئیدی، جوابهایی بین صفر و یک می‌دهد. معادله نرمال‌سازی بکار رفته به صورت زیر است:


$$Y_{i(normal)} = \frac{Y_i - Y_{min}}{Y_{max} - Y_{min}} \quad (3)$$

برای تعیین کفایت یک شبکه باید پارامترهای مناسبی مربوط به خطا برای دسته داده‌های آموزش و آزمون، محاسبه و با هم مقایسه شوند. برای این تحقیق از پنج پارامتر بیشینه درصد خطا، کمینه درصد خطا، جذر متوسط مربعات خطا (RMS)، ضریب همبستگی (R) و متوسط قدر مطلق خطاها (MAE) استفاده شده است که برای دسته داده‌های آموزش و آزمون محاسبه شده‌اند.


پس از انتخاب نوع شبکه، الگوریتم آموزش و توابع محرک نرونهای هر لایه، باید تعداد لایه‌های نهان و تعداد نرونهای هر لایه تعیین شوند تا معماری شبکه تکمیل گردد. تعداد پارامترهای ورودی و خروجی، تعداد الگوهای آموزش و ماهیت و فیزیک مسأله مورد بررسی، عوامل مؤثر بر میزان پیچیدگی معماری شبکه و تعدد نرونهای لایه نهان آن هستند. تا کنون روش سیستماتیک کاملی برای رسیدن به معماری بهینه ارائه نشده و شبکه نهایی عموماً با آزمون و خطا بدست می‌آید. برای تعیین تعداد لایه‌های میانی و تعداد نرونهای هر یک در شبکه، باید استراتژی مناسبی برای مدل‌سازی و آزمون شبکه‌های مختلف اتخاذ نمود.

در شکل‌های (۱۰) و (۱۱) مقادیر جذر میانگین مربعات خطا (RMS) برای شبکه‌های مختلف MLP ساخته شده به ترتیب برای دسته داده‌های آزمون و آموزش نشان داده شده است و شبکه بهینه همان طور که در شکل مشخص است، عبارت است از شبکه‌ای با یک لایه نهان که ۱۰ نرون در آن لایه وجود دارد.

در شکل‌های (۱۶) و (۱۷) مقادیر واقعی در برابر مقادیر خروجی شبکه و خط برازش مربوط بر آنها به ترتیب برای داده‌های آزمون و آموزش نشان داده شده است.



شکل ۱۶- مقادیر  $Y$  پیش‌بینی شده توسط شبکه RBF بهینه در برابر مقادیر واقعی در دسته داده‌های آموزش




شکل ۱۷- مقادیر  $Y$  پیش‌بینی شده توسط شبکه RBF بهینه در برابر مقادیر واقعی در دسته داده‌های آزمون

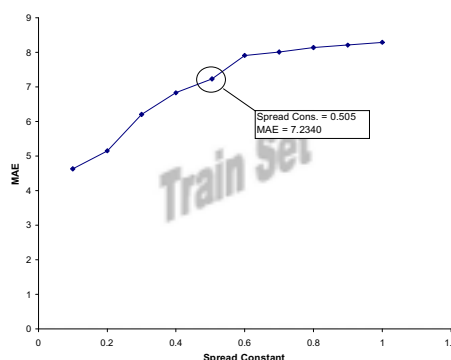
همان‌طور که در جدول (۲) آمده است، شبکه RBF برای هر دو دسته داده‌های آموزش و آزمون پیش‌بینی‌هایی با درصد خطای کمتر و ضریب همبستگی بیشتر انجام داده است.

جدول ۲- مقادیر مشخصه خطا برای دو شبکه MLP و RBF


	(MLP)Network		(RBF)Network	
	Train	Test	Train	Test
Min. Error(%)	23.0577	32.7939	25.3770	31.3851
Max. Error(%)	-42.6161	-51.6138	-44.3974	-47.7918
RMS	0.0434	0.0572	0.0415	0.0566
R	0.9221	0.8657	0.9290	0.8710
MAE(%)	7.5146	9.4147	7.2341	8.9599



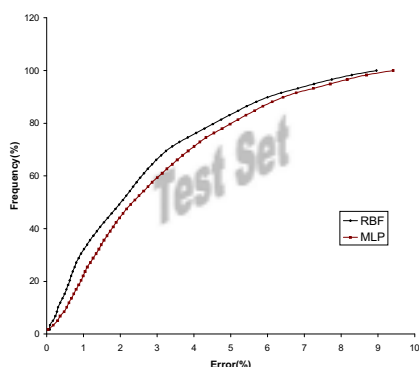
شکل ۱۳- مقادیر  $Y$  پیش‌بینی شده توسط شبکه MLP بهینه در برابر مقادیر واقعی در دسته داده‌های آزمون در مورد شبکه‌های RBF با روش حل دقیق در لایه خروجی تنها پارامتر در اختیار طراح، ضریب پخش است که در این تحقیق مقادیر مختلف برای آن تا رسیدن به جواب بهینه امتحان شده است. شکل‌های (۱۴) و (۱۵) میانگین قدرمطلقهای خطا (MAE) برای مقادیر مختلف ضریب پخش را به ترتیب برای داده‌های آموزش و آزمون نشان می‌دهد که بهترین شبکه به ازای ضریب پخش برابر با ۰/۵۰۵ بدست آمده است.



شکل ۱۴- مقادیر MAE برای شبکه‌های RBF با ضرایب پخش مختلف در دسته داده‌های آموزش



شکل ۱۵- مقادیر MAE برای شبکه‌های RBF با ضرایب پخش مختلف در دسته داده‌های آزمون



شکل ۱۹- مقایسه فرکانس خطا در پیش‌بینی Y توسط شبکه‌های MLP و RBF بهینه در داده‌های آزمون

### مقایسه با روشهای پیشین

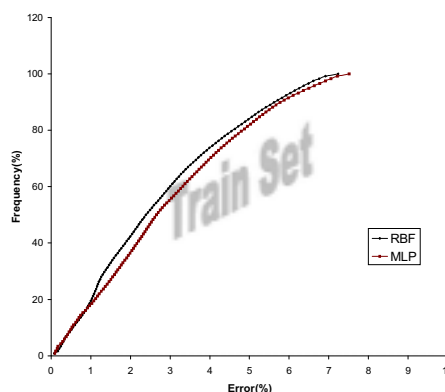
برای شش اتصال در مرحله رشد  $0.2 < a/T < 1.0$  مقادیر Y به ازای  $a/T$  و  $a/c$  مختلف از برخی روشهای تجربی و نیمه تجربی پیشین محاسبه و جوابها با نتایج بدست آمده از شبکه‌ها مقایسه شده است. این روشها شامل موارد زیر است:

- روش تنش متوسط (AVS) [۹].
- روش تنش متوسط اصلاح شده (MAVS) [۹].
- مدل دوفازی (TPM) [۹].
- مدل نیمه تجربی Etube و همکاران<sup>۳</sup> [۱۰].
- مدل Newman-Raju [۱۱] به همراه روش آزاد سازی خطی لنگر<sup>۴</sup> [۱۲].

مقایسه نتایج حاصل از شبکه و روشهای قبلی با نتایج واقعی به صورت مقادیر R، RMS و MAE به ترتیب در شکل‌های (۲۰)، (۲۱) و (۲۲) نشان داده است که خود گویای قابلیت مناسب شبکه برای تخمین مقدار Y است.


از نقاط ضعف MAE این است که نسبت به خطاهای بیشینه بسیار حساس است؛ به این معنی که وجود چند مورد خطای بالا مقدار آن را به شدت بالا می‌برد؛ حال آنکه ممکن است در درصد بالایی از داده‌ها خطاها کم باشد. RMS از این لحاظ خصوصیات بهتری نشان می‌دهد و به همین دلیل در بیشتر مقالات از آن استفاده شده است.

برای استفاده از MAE بدون نقیصه فوق، از بیان فرکانس خطا استفاده می‌شود که بیانگر این است که برای درصدی مشخص از داده‌ها، مقدار خطا چقدر است. در این تحقیق نیز در انتخاب مدل نهایی از بین مدل‌های با عملکرد مناسب، از فرکانس خطا استفاده شده است. در شکل‌های (۱۸) و (۱۹) نمودارهای فرکانس خطا برای هر دو شبکه به ترتیب برای داده‌های آموزش و آزمون نشان داده شده است که مشاهده می‌شود خطای MAE برای ۸۰٪ از داده‌ها در دو مرحله آموزش و آزمون برای شبکه RBF برابر ۴/۵ و برای MLP برابر با ۵ درصد است. قرار گرفتن نمودار شبکه RBF در سمت چپ MLP حاکی از قابلیت نسبتاً بهتر این شبکه برای حل این مسأله است.



شکل ۱۸- مقایسه فرکانس خطا در پیش‌بینی Y توسط شبکه‌های MLP و RBF بهینه در داده‌های آموزش


<sup>۳</sup> Etube و همکاران [۱۰] روش خود را با استفاده از داده‌های مربوط به آزمایش روی سه اتصال Y معرفی کرده‌اند ولی استفاده از آن را برای سایر اتصالات با رعایت احتیاط مجاز دانسته‌اند.  
<sup>۴</sup> نتایج این روش در اشکال مربوطه با NR(WLMR) نشان داده شده است.




شکل ۲۲- مقایسه MAE در پیش‌بینی Y توسط شبکه‌های MLP و RBF بهینه و روشهای دیگر

### نتیجه‌گیری

با توجه به نتایجی که از این تحقیق حاصل شد، می‌توان عنوان کرد که شبکه‌های عصبی مصنوعی قابل کاربرد در تعیین آهنگ رشد ترک در اتصالات لوله‌ای هستند. استفاده از شبکه‌های عصبی مصنوعی امکان استفاده از داده‌های پر ارزش آزمایشگاهی را که عموماً از فرآیندهای پر هزینه بدست می‌آیند، فراهم می‌کند؛ همچنین با توجه به انعطاف‌پذیری و توانایی بالای شبکه‌های عصبی مصنوعی در ردیابی الگوهای واقعی و مقاوم بودن آن در برابر داده‌های توأم با اغتشاش، جوابهایی با خطاهای کمتر از این روش انتظار می‌رود. همراه با توسعه چشمگیر شبکه‌های عصبی مصنوعی از نظر تکامل ساختاری شبکه‌ها و الگوریتمهای یادگیری و توسعه روزافزون کاربردهای موفقیت‌آمیز آن در حل مسائل مهندسی و به خصوص علم مواد، استفاده از این روش در تعیین آهنگ رشد ترک خستگی در اتصالات لوله‌ای مفید و امیدوارکننده به نظر می‌آید.



شکل ۲۰- مقایسه ضریب همبستگی (R) در پیش‌بینی Y توسط شبکه‌های MLP و RBF بهینه و روشهای دیگر



شکل ۲۱- مقایسه RMS در پیش‌بینی Y توسط شبکه‌های MLP و RBF بهینه و روشهای دیگر

## مراجع

- 1- J. C. P. Kam, W. D. Dover, C. N. Ma, "The Prediction of Crack Shape Development for In-service Cracks in Offshore Welded Tubular Joints", J. Marine Structures (1995), pp.37-67
- 2- P. E. O. Connor, B. P. Amoco, "Case Studies of Platform Re-use in the Gulf of Mexico", International Conference of the Re-use of Offshore Production Facilities, 13-14 October, Netherlands, (2001)
- 3- A. A. Aaghakouchak, "Fatigue Fracture Mechanics Analysis of Ring-Stiffened and Simple Tubular Joints for Offshore Structures", Ph.D. Thesis, University College of London, (1989)
- 4- M. J. Cheaitant, H. M. Bolt, "Evaluation of Stress Intensity Factor Solutions for Offshore Tubular Joints", Offshore Mechanics and Arctic Engineering Conference, (1996)
- 5- L. S. Etube, "Fatigue and Fracture Mechanics of Offshore Structures", Professional Engineering Publishing, London, (2001)
- 6- Laurene Fausett, "Fundamentals of Neural Networks, Architectures, Algorithms and Applications", Prentice Hall International Inc, New Jersey, (1994)
- 7- S. Chen, C. F. N. Cowon and P. M. Grant "Orthogonal Least Square Learning Algorithm for Radial Basis Function Networks", IEEE Transaction on Neural Network, Vol. 2, No. 2, March 1991
- 8- B. Talie-Faz, W. D. Dover, F. P. Brennan, "Static Strength of Cracked High Strength Steel Tubular Joints", Health and Safety Executive, London, (2002)
- 9- L. S. Etube, F. P. Brennan, W. D. Dover, "Review of Empirical and Semi-empirical Y Factor Solutions for Cracked Welded Tubular Joints", J. Marine Structures, 12 (1999), pp. 565-583
- 10- L. S. Etube, F. P. Brennan, W. D. Dover, "A New Method for Predicting Stress Intensity Factor in Cracked Welded Tubular Joints", Int. J. Fatigue, 22 (2000), pp. 447-456
- 11- J. C. Newman, I. S. Raju, "An Empirical Stress Intensity Factor Equation for the Surface Cracks", Engineering Fracture Mechanics, Vol.12, No2, 1981, pp. 185-192.
- 12- A. Aaghakouchak, G. Glinka, S. Daramavasan, "A Load Shedding Model for Fracture Mechanics Analysis of Fatigue Cracks in Tubular Joints" Offshore Mechanics and Arctic Engineering (OMAE), 1989, PP. 159-165