



تشخیص سایز و موقعیت نسبی ترک در لوله‌های حاوی سیال با استفاده از شبکه عصبی مصنوعی

مصطفی رستاقی^۱، مهرداد نوری خاجوی طهرانی^{۲*}

۱- دانشجوی کارشناسی ارشد دانشکده مکانیک، دانشگاه تربیت دبیر شهید رجایی، تهران

۲- استادیار دانشکده مکانیک، دانشگاه تربیت دبیر شهید رجایی، تهران

* تهران، صندوق پستی 1678815811

mnouri@srttu.edu

اطلاعات مقاله

چکیده
در این تحقیق، سایز و موقعیت نسبی ترک، با استفاده از فرکانس‌های طبیعی لوله محتوی مایع تحت فشار به کمک شبکه عصبی تشخیص داده می‌شود. شبکه عصبی به کار رفته از نوع پرسپترون چندلایه (MLP) می‌باشد. با مقایسه بین ورودی‌های مختلف، ورودی‌های مطلوب انتخاب شدند. سیال داخل لوله آب می‌باشد. لوله‌های مورد استفاده از دو جنس آلومینیوم و فولاد هستند. لوله در چهار وضعیت: خالی از سیال، حاوی سیال با فشار صفر، با فشار ۰/۴۹۸ MPa و با فشار ۰/۹۸۱ MPa می‌باشد. محدوده سایز ترک از ۰/۱۹۰۴۳ تا ۰/۶۳۴۶ و محدوده موقعیت از ۰/۱۹۹ تا ۰/۴۰۳ می‌باشد. در زمینه تشخیص ترک سازه‌ها بر مبنای خصوصیت تغییرات فرکانس طبیعی با کمک شبکه عصبی تحقیقات زیادی انجام شده است؛ اما تا آنجا که مولفان آگاهی دارند، برای شناسایی ترک در لوله‌های حاوی سیال از روش فوق الذکر استفاده نشده است. همچنان استفاده همزمان از سازه‌های با دو جنس مختلف برای آموزش و تست شبکه عصبی از دیگر نوادری‌های این تحقیق است. مقایسه روش پیشنهادی در این تحقیق با روش‌های تحلیلی انجام شده، نشان می‌دهد که روش پیشنهادی همواره در تخمین سایز دقیق‌تر می‌باشد ولی در تخمین موقعیت با توجه به تعداد کم نمونه‌ها همواره دقیق‌تر نیست.

مقاله پژوهشی کامل

دربافت: ۲۵ شهریور ۱۳۹۲

پذیرش: ۰۳ آذر ۱۳۹۲

ارائه در سایت: ۲۲ تیر ۱۳۹۳

کلید واژگان:

تشخیص ترک

شبکه عصبی مصنوعی

لوله‌ها

فرکانس‌های طبیعی

Detection of size and location of crack in pipes under fluid pressure by neural networks

Mostafa Rostaghi, Mehrdad Nouri Khajavi*

Department of Mechanical Engineering, Shahid Rajaee Teacher Training University, Tehran, Iran
*P.O.B. 1678815811 Tehran, Iran, mnouri@srttu.edu

ARTICLE INFORMATION

Original Research Paper

Received 16 September 2013

Accepted 24 November 2013

Available Online 13 July 2014

Keywords:

Crack Detection
Artificial Neural Network
Pipes
Natural Frequencies

ABSTRACT

In this research crack size and location in pipes under fluid pressure will be detected using pipe's natural frequencies by neural network. Neural network used in this research is multi-layer perception. Comparing different inputs, appropriate inputs are selected. Pipes contain water. Steel and aluminum pipes were used in this research. Pressure condition of the pipes is: 1) without water 2) water with zero pressure 3) water with 0.498 MPa 4) water with 0.981 MPa. Crack size range from 0.19043 to 0.6346. Crack location range from 0.199 to 0.403. Many researches have been done about crack detection based on natural frequencies of structures by neural network. However, as far as authors know, no work has been done for crack detection in pipes containing pressurized water. Also in this paper two structures with different materials have been used for neural network training and testing which is another innovation of this research. Comparison of the results of this method with analytic methods shows that the proposed method is always more accurate in detecting crack size but is not always better in estimating crack location.

برای تشخیص ترک به کار می‌روند. اما برای لوله‌های طولانی که کاربردهای زیادی در تأسیسات نیروگاه‌ها، صنایع شیمیایی و انتقال آب و گاز و نفت دارند، در هر یک از این روش‌ها برای تشخیص ترک باید کل لوله مرحله به مرحله مورد بررسی قرار گیرد، و در نتیجه گران و زمان بر هستند [۱] و این انگیزه‌ای برای استفاده از روش‌های جایگزین شده است. استفاده از روش‌هایی بر اساس ارتعاشات برای تشخیص ترک، یکی از روش‌های جایگزین است. استفاده از ارتعاشات برای عیوب‌یابی ترک لوله حاوی سیال دو مزیت دارد: ۱) در روش استفاده از ارتعاشات، در مسافت‌های معینی، از یک نقطه داده‌برداری انجام می‌شود. بنابراین از روش‌های فوق الذکر که کل لوله باید مورد بررسی قرار بگیرند

امروزه استفاده از روش‌های آزمون غیرمخرب^۱ به منظور شناسایی وضعيت خارجی موضوعی مهم می‌باشد. تکنیک‌های غیرمخرب زیادی برای شناسایی ترک وجود دارد. آزمون‌های غیرمخرب از قبیل مایع نفوذپذیر^۲، تست ذرات^۳ مغناطیسی^۴، روش مشاهده مستقیم^۵، بازرسی فراصوتی^۶ و روش اشعه ایکس^۶

1- Non-Destructive Testing (NDT)

2- Liquid (or Dye) Penetrant Method (PT)

3- Magnetic Particle Test (MPI)

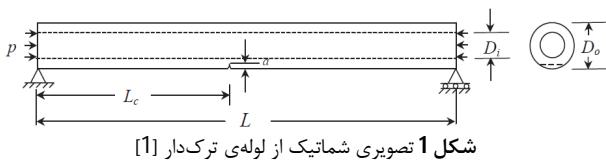
4- Direct Vision Method (VT)

5- Ultrasonic Inspections (UT)

6- X-ray Testing (RT)

برای ارجاع به این مقاله از عبارت ذیل استفاده نمایید:

M. Rostaghi, M. Nouri Khajavi, Detection of size and location of crack in pipes under fluid pressure by neural networks, *Modares Mechanical Engineering*, Vol. 14, No. 7, pp. 35-42, 2014 (In Persian)



شکل ۱ تصویری شماتیک از لوله‌ی ترک‌دار [۱]

دامنه سیگنال و شکل مود هم می تواند برای تشخیص ترک استفاده شود، اما چون در یک سازه، فرکانس های طبیعی به آسانی اندازه گیری می شوند و مستقل از محل اندازه گیری می باشند و همچنین عموماً صحت اندازه گیری فرکانس های طبیعی بالاتر از شکل مودها یا میرایی مودال است [2]، تاکنون در تحقیقات زیادی، از فرکانس های طبیعی برای تشخیص ترک در سازه ها استفاده شده است.

3-دادهای مورد نیاز

به طور کلی روش‌های تشخیص به دو طبقه اصلی تقسیم شده‌اند: روش‌های بر اساس مدل که مدل‌هایی مبتنی بر فیزیک دستگاه را برای طبقه‌بندی عیوب استفاده می‌کنند و روش‌های داده محور³ که اصولاً بر داده‌ها تکیه می‌کنند و الگوریتم‌ها یا ابزارهای داده محور را به کار می‌گیرند [17]. ابزارهای تشخیص داده‌های گذشته⁴، طبقه‌بندی داده‌های آماری⁵، الگوریتم‌های خوشه‌بندی بر پایه منطق فازی و ساختارهای شبکه عصبی، از ابزارها و الگوریتم‌های داده محور می‌باشند [17].

در این مقاله، با توجه به استفاده از روش داده محور به وسیله شبکه عصبی برای تشخیص ترک از داده‌هایی که موریجندرایا و همکارانش در مرجع [1] به دست آورده‌اند، استفاده شده است. موریجندرایا و همکارانش [1] با تست ضربه، چهار فرکانس طبیعی اول را در لوله‌های حاوی سیال دارای ترک‌های با موقعیت و سایز متفاوت اندازه‌گیری کردند. به این دلیل که فرکانس طبیعی اول لوله، با تغییرات سایز و موقعیت ترک، نسبت به فرکانس‌های بعدی از حساسیت کمتری برخوردار بود، آن‌ها تنها از فرکانس‌های دوم و سوم و چهارم در مقاله خود استفاده کردند. 60 جفت داده در مقاله استفاده شد، که شامل فرکانس‌های طبیعی دوم، سوم و چهارم لوله‌ها، جنس و فشار گیج لوله‌ها، موقعیت و سایز سبی ترک می‌باشد. در شکل 1 تصویری شماتیک از لوله‌ای ترکدار و پارامترهای آن نشان داده شده است. لوله‌ها از دو جنس، آلومینیوم و فولاد هستند. طول لوله‌های آلومینیوم و فولادی به ترتیب ۰/۸ و ۰/۸۷ متر می‌باشد. فشار گیج لوله‌های حاوی سیال از 0 MPa تا $0/981\text{ MPa}$ و سایز ترک ($\beta = Lc/L$) از $0/199$ تا $0/403$ بوده است. ترک‌ها به وسیله دستگاه‌ایرکات بحد شده بودند که فقط ابار آن، $0/15$ میل.^۳ مت است [1].

4- شکه عصہ مصنوع

۱-۴ طاح شکه عص

متداول ترین نوع شبکه عصبی، پرسپترون چند لایه⁶ (MLP) است، که در مانیتورینگ وضعیت، در بیشتر از 90 درصد موارد از این نوع شبکه عصبی استفاده می‌شود [18]، از این‌رو در این تحقیق نیز از شبکه عصبی پرسپترون چند لایه استفاده شد.

قبل از شروع کردن به طراحی شبکه عصبی، و قبل از استفاده از داده‌ها برای یادگیری شبکه، دو گام باید برداشته شود. داده‌ها نیاز به پیش‌پردازش

ارزان‌تر و سریع‌تر است. (2) ممکن است دسترسی به قسمت‌هایی از لوله امکان‌پذیر نباشد، در این صورت روش‌های فوق‌الذکر امکان استفاده ندارند. با این حال تنها با دسترسی به یک نقطه از لوله حاوی سیال، فرکانس طبیعی آن مشخص شده و با کمک آن مشخصات ترک تشخیص داده می‌شود.

آزمون‌های غیرمختلط بر اساس ارتعاشات سال‌ها است که مورد توجه قرار گرفته‌اند، [4-2]. برای تشخیص ترک‌ها نیز به طور خاص کارهای زیادی از قبیل مرور خوبی توسط دیماروگوناس [5] انجام شده است. کارهای زیادی برای تشخیص ترک در سازه‌ها بر اساس روش‌های تحلیلی، متدهای اجزا محدود و روش‌های هوشمند از قبیل الگوریتم ژنتیک و شبکه عصبی انجام شده‌اند. به عنوان نمونه، نحوی و جباری موقعیت و عمق ترک تیر را با روش المان محدود به دست آورده و با آزمایش مودال روشنگران را تایید کردند [6]. طالبی و همکارانش، با استفاده از الگوریتم ژنتیک و فرکانس‌های طبیعی، عمق و موقعیت ترک تیر دورانی با سطح مقطع متغیر را به دست آورده‌اند [7]. پرطوفدارترین روش برای تشخیص ترک در تیرها استفاده از روش کشیدن کانتوری از فرکانس‌ها، با حداقل سه فرکانس طبیعی است [8].

با این حال برای تشخیص ترک به طور خاص در لوله‌های حاوی سیال، کارهای محدودی انجام شده است. با توجه به کاربرد زیاد لوله‌ها انتظار می‌رود، روش‌های مبتنی بر ارتعاشات در آینده مورد توجه بیشتر مختصان واقع شود. در سال 2004، موریجندرابا و همکارانش، مطالعه‌ای تئوری و تجربی برای تشخیص ترک بر روی لوله‌های حاوی سیال انجام دادند [1]. آنها ابتدا روابط تحلیلی ارتعاشات آزاد لوله ترک‌دار با مایع تحت فشار را به دست آورده‌اند و سختی ترک را با سختی یک فنر پیچشی مدل کردند. سپس با دو روش (براساس فرکانس‌ها و بر اساس تغییر مکان لوله ترک‌دار تحت بار)، سختی پیچشی فنر را محاسبه کردند و سپس با رسم نمودارهای رابطه بین سایز و مکان نسبی ترک با سختی پیچشی فنر معادل را به دست آورده‌اند [1]. عملکرد این روش در تشخیص موقعیت نسبی ترک لوله خیلی خوب بود ولی سایز نسبی ترک را با خطای بالا تشخیص می‌داد. موریجندرابا و همکارانش همچنین در سال 2004، در مطالعه‌ای تحلیلی و تجربی، چندین ترک را روی لوله‌های حاوی سیال بر اساس اندازه‌گیری فرکانس‌های طبیعی تشخیص دادند [9]. نانیوکار و همکارانش در سال 2008 موقعیت زاویه‌ای ترک را در لوله‌های حاوی سیال تشخیص دادند [10]. دیلنا و همکارانش در سال 2011 نشان دادند که با تنها دو فرکانس طبیعی اول هم می‌توان موقعیت ترک‌ها را در لوله‌های حاوی سیال به دست آورد [11].

شبکه عصبی مصنوعی در آزمون‌های غیر مخرب کاربرد زیادی دارد. در مقالات زیادی براساس خصوصیات ارتعاشی و با استفاده از شبکه عصبی خواری در سازه‌های مختلف تشخیص داده شده است [14-12]. فرانسیسکا ساو و همکارانش برای تشخیص عیب در لوله‌ها از شبکه عصبی پرسپیترون چندلایهٔ فیدفوروارد و امواج صوتی هدایت شده استفاده کردند. آن‌ها از PCA و FFT² به عنوان پیش‌پردازش داده‌ها برای استفاده در شبکه عصبی استفاده کردند [15].

2- تشخیص تک داساں فی کانس طبع

غلب کاهش در سختی محلی به دلیل ترک یا عیوب شبهه ترک است [16].
کاهش سختی نیز موجب کاهش فرکانس‌های طبیعی قطعه ترکدار می‌شود.
بنابراین در تشخیص ترک بر اساس ارتعاشات، استفاده از تغییرات
فرکانس‌های طبیعی متداوول است.

3 Data Driven

4-Historical Data Diagnostic Tools

4- Historical Data Diagnostic Tools 5- Statistical Legacy Data Classification

5- Statistical Legacy Data 6- Multi-Layer Perceptron

1- Principal Component Analysis
2- Fast Fourier Transform

$$MSE = \frac{1}{N} \sum_{i=1}^N (e_i)^2 = \frac{1}{N} \sum_{i=1}^N (t_i - a_i)^2 \quad (1)$$

که a_i و t_i به ترتیب خروجی‌های واقعی و هدف برای آمین خروجی می‌باشد و N تعداد نمون در لایه خروجی است.

برای انتخاب ورودی‌های مطلوب مورد استفاده در شبکه عصبی، با نوشتن کدهای اسکریپت در نرم‌افزار متلب، شبکه عصبی پرسپترون چندلایه (MLP) با 5 نمون در لایه مخفی (به صورت پیش‌فرض که در مراحل بعد، ساختار بهینه شبکه به دست آورده می‌شود) و دو نمون به تعداد خروجی‌ها (سایز و موقعیت نسبی ترک) در لایه خروجی ایجاد شد. برای هر سری داده، 100 بار شبکه با وزن‌های اولیه اتفاقی، آموزش داده شد. میانگین MSE و میانگین رگرسیون برای داده‌های آموزش و اعتبارسنجی به دست آمد. سری داده‌ای برای ورودی شبکه انتخاب شد که کمترین میانگین MSE و بیشترین میانگین رگرسیون را دارد.

برای ورودی شبکه عصبی در هر حالت، همزمان از یک نوع ورودی جدول 4 و یک نوع ورودی از جدول 5، استفاده شد. در جدول 4، هر کدام از خانه‌های جدول که انتخاب شده باشند، مجموعه داده ورودی شبکه، شامل آن ورودی نیز خواهد بود. در جدول 5 نیز اندیس بالا نشان دهنده شماره فرکانس طبیعی و اندیس پائین f_{nc}^2 ترک‌دار بودن و اندیس پائین f_{nc}^2 سالم بودن لوله را نشان می‌دهد. به عنوان مثال f_{nc}^2 نشان دهنده فرکانس طبیعی سوم لوله را ترک‌دار و f_{nc}^2 نشان دهنده فرکانس طبیعی دوم لوله سالم می‌باشد. هر مجموعه از داده‌های ورودی با یک اندیس مشخصه از جدول 4 و یک اندیس مشخصه از جدول 5 نمایش داده می‌شود. به عنوان مثال مجموعه داده Ab شامل شش ورودی: مدول الاستیستیته، فرکانس دوم لوله سالم، فشار وارد بر سطوح داخلی لوله و فرکانس دوم تا چهارم لوله ترک‌دار می‌باشد.

همان‌طور که در شکل‌های 2 و 3 دیده می‌شود، زمانی که ورودی شبکه عصبی یکی از فرکانس‌های طبیعی لوله سالم و مدول الاستیستیته فلز لوله و مجموعه داده B یا C یا D باشد، شبکه‌های عصبی به خوبی آموزش می‌بینند و تفاوت چندانی با هم ندارند. با این حال همان‌طور که در شکل‌های 4 و 5 نشان داده شده، بهترین حالت مربوط به سری داده Df می‌باشد که شامل فرکانس چهارم لوله سالم و مدول الاستیستیته فلز لوله و فرکانس دوم تا چهارم لوله ترک‌دار تقسیم بر فرکانس دوم تا چهارم لوله سالم می‌باشد، بنابراین به عنوان ورودی‌های شبکه عصبی انتخاب شدند.

جدول 1 مجموعه داده‌های آموزش، اعتبارسنجی و آزمون. داده‌های مربوط به خانه‌ای از جدول که مشخص شده‌اند، برای مجموعه داده‌ای آموزش یا اعتبارسنجی و یا آزمون انتخاب شده‌اند

آلومینیوم				فولاد				جنس			
فشار (MPa)	تعداد داده‌ها	داده آموزش	داده اعتبارسنجی	فشار (MPa)	تعداد داده‌ها	داده آموزش	داده آزمون	فشار (MPa)	تعداد داده‌ها	داده آموزش	داده اعتبارسنجی
0/981	0/4905	0	خالی	0/981	0/4905	0	خالی	فشار (MPa)	تعداد داده‌ها	داده آموزش	داده آزمون
11	11	11	11	4	4	4	4				
		✓	✓			✓	✓				
			✓				✓				

جدول 2 مجموعه داده‌های آموزش، اعتبارسنجی و آزمون. داده‌ای مربوط به خانه‌ای از جدول که مشخص شده‌اند، برای هر کدام از مجموعه داده‌ها استفاده شده‌اند

آلومینیوم				فولاد				جنس			
فشار (MPa)	تعداد داده‌ها	داده آموزش	داده اعتبارسنجی	فشار (MPa)	تعداد داده‌ها	داده آموزش	داده آزمون	فشار (MPa)	تعداد داده‌ها	داده آموزش	داده اعتبارسنجی
0/981	0/4905	0	خالی	0/981	0/4905	0	خالی	فشار (MPa)	تعداد داده‌ها	داده آموزش	داده آزمون
11	11	11	11	4	4	4	4				
		✓	✓			✓	✓				
			✓				✓				

دارند و همچنین نیاز است به چند دسته تقسیم شوند. اگر مراحل پیش‌پردازش روی داده‌های هدف و ورودی انجام شود، کارایی یادگیری شبکه عصبی بیش‌تر خواهد شد. عموماً در مجموعه داده‌ها، مرحله نرمال‌سازی هم برای بردارهای ورودی و هم بردارهای هدف به کار می‌رود [19]. در گام دوم داده‌ها به سه زیر دسته: یادگیری، اعتبارسنجی و آزمون تقسیم می‌شوند. زیردسته یادگیری برای محاسبه گرادیان خطأ و به روز شدن وزن‌ها و بایاس استفاده می‌شود. زیردسته اعتبارسنجی در فرایند آموزش استفاده می‌شود. خطای مجموعه داده‌های اعتبارسنجی به صورت عادی، در ابتدا کاهش می‌یابد، اما وقتی شبکه آغاز به بیش‌پردازش می‌کند، درین زمان آموزش متوقف می‌شود. وزن‌ها و بایاس شبکه در زمانی که خطای داده‌های اعتبارسنجی کمترین مقدار است ذخیره می‌شوند. داده‌های آزمون تأثیری در آموزش شبکه عصبی ندارند و به منظور اندازه‌گیری مستقلی از کارایی شبکه عصبی پس از آموزش استفاده می‌شوند.

در این مقاله داده‌های شبکه عصبی به دو صورت، بر اساس فشار سیال و جنس لوله، مطابق جدول 1 و تنها بر اساس فشار سیال مطابق جدول 2 به سه زیردسته تقسیم شدن. علت تقسیم‌بندی داده‌ها به دو صورت، بررسی اثر تفاوت تعداد و نوع داده‌های مربوط به آموزش و آزمون در این دو حالت، در ساختار و نتایج شبکه عصبی بود تا قوام این روش مورد ارزیابی قرار گیرد.

برای بار اول، داده‌های شبکه عصبی مطابق جدول 1 به سه زیردسته تقسیم شدن و خروجی‌های شبکه عصبی به صورت همزمان سایز و موقعیت ترک لوله‌ها می‌باشند. این شبکه عصبی بر اساس جدول 3، شبکه ۱۱ به نامیده شد.

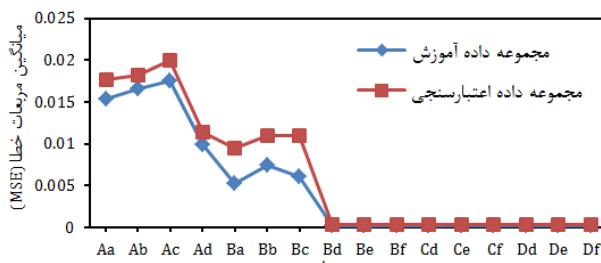
در طراحی شبکه‌های عصبی، در ابتدا به صورت پیش‌فرض، از تابع تبدیل تائزات هیپربولیک سیگموید در لایه مخفی و تابع تبدیل خطی در لایه خروجی استفاده شد؛ چرا که معمولاً این ساختار برای تخمین تابع پیشنهاد می‌شود [19].

مقدار کارایی شبکه عصبی با میانگین مربعات خطأ (MSE) مشخص شد که از طریق جمع مربعات خطای هر نمون در لایه خروجی، تقسیم بر تعداد نمون‌های لایه خروجی، به دست می‌آید. رابطه (1) نحوه محاسبه میانگین مربعات خطأ (MSE) را نشان می‌دهد.

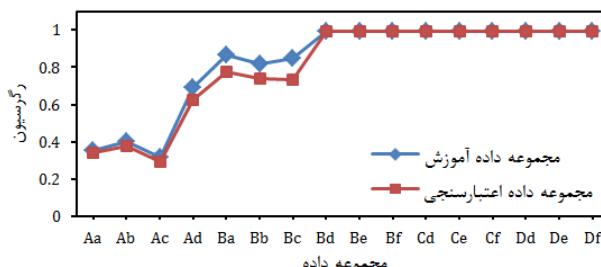
تصادفی مختلف، وزن‌هایی که شبکه عصبی با آنها یادگیری بهتری داشت، انتخاب شدند. شکل ۷، روند تغییرات خطای حین یادگیری را برای شبکه‌ای که انتخاب شده بود، نشان می‌دهد. بعد از ۱۵ دوره که خطای داده‌های اعتبارسنجی کاهش نمی‌یابد، آموزش شبکه متوقف می‌شود. در این شکل، زمانی که شبکه بیشترین تغییر را دارد با دایره نشان داده شده و مقادیر وزن‌ها و بایاس در این هنگام ذخیره شده و برای شبکه استفاده می‌شود. در شبکه عصبی طراحی شده آزمون $\alpha\beta_{11}$ با وزن‌های بهینه، همبستگی بین داده‌های خروجی با داده‌های هدف برای داده‌های آموزش و اعتبارسنجی به ترتیب ۰/۹۹۷۹ و ۰/۹۹۹۹ به دست آمد (شکل ۸).

۴-۲- بررسی نتایج شبکه عصبی

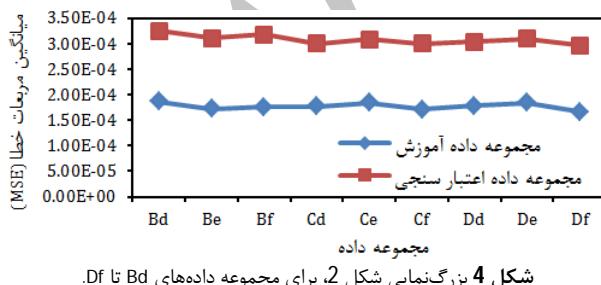
برای داده‌های آزمون شبکه عصبی $\alpha\beta_{11}$ ، میانگین مربعات خطای (MSE) ۸/۷۴۸۸e-۵ است.



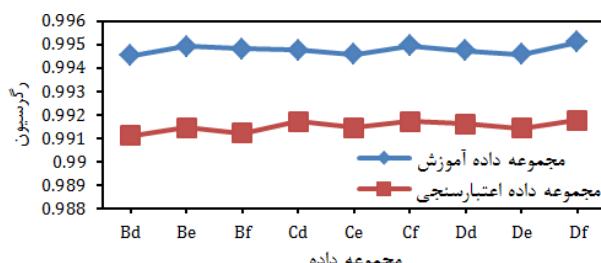
شکل ۲ میانگین ۱۰۰ بار آموزش شبکه عصبی برای هر مجموعه داده ورودی متفاوت با وزن‌های تصادفی



شکل ۳ میانگین رگرسیون ۱۰۰ بار آموزش شبکه عصبی برای هر مجموعه داده ورودی متفاوت با وزن‌های تصادفی



شکل ۴ بزرگنمایی شکل ۲ برای مجموعه داده‌های Bd تا Df.



شکل ۵ بزرگنمایی شکل ۳ برای مجموعه داده‌های Bd تا Df

جدول ۳ خصوصیات شبکه عصبی $\alpha\beta_{11}$

نام شبکه	تخمین	تعداد داده‌های	تقسیم داده‌ها
عصبی	زنده	آزمون	بر اساس
$\alpha\beta_{11}$	11	1	جدول ۱ سایز و موقعیت (α, β)

در این مقاله برای انتخاب الگوریتم یادگیری پس انتشار، ۱۰ الگوریتم یادگیری بر اساس معیار کارایی و سرعت یادگیری مقایسه شدند. الگوریتم‌های یادگیری بررسی شده شامل، لونبرگ-مارکوارت پس انتشار^۱، شبیب مزدوج پس انتشار با به روز رسانی پولاک-ریبیر^۲، کاهش شبیب با نرخ یادگیری تطبیقی پس انتشار^۳، کاهش شبیب با مومنتوم و نرخ یادگیری تطبیقی پس انتشار^۴، پس انتشار ارجاعی^۵، شبیب مزدوج مقیاس شده پس انتشار^۶، پس انتشار یک مرحله‌ای قاطع^۷، شبیب مزدوج پس انتشار با بروز رسانی فلچربریوز^۸، پس انتشار شبیه نیوتونی BFGS^۹ و شبیب مزدوج پس انتشار با شروع مجدد پاول-بیل^{۱۰} می‌باشد. توضیحات در خصوص این توابع یادگیری در مرجع [۱۹] دیده می‌شود.

ابتدا ۱۰ الگوریتم یادگیری متفاوت برای آموزش شبکه عصبی MLP با ۵ نرون در لایه میانی (به صورت پیش‌فرض) به کار گرفته شد. برای هر الگوریتم، ۱۰۰ بار به صورت تصادفی وزن‌های اولیه انتخاب شدند و شبکه آموزش دید. میانگین عملکرد شبکه‌های عصبی در ۱۰۰ بار آموزش با هر الگوریتم، در جدول ۶ مقایسه شده‌اند که بهترین و سریع‌ترین یادگیری را الگوریتم trainlm داشت. درنتیجه این الگوریتم برای آموزش انتخاب شد.

پس از انتخاب ورودی‌ها و الگوریتم آموزش، به منظور طراحی ساختار شبکه عصبی، با نوشتن یک کد اسکریپت در نرم‌افزار متلب، در ابتدا ساختارهای مختلف شبکه عصبی طراحی شدند، به صورتی که یک یا دو لایه میانی و توابع تبدیل مختلف شامل تابع انتقال خطی^{۱۱}، تائزات هیپربولیک سیگموئید^{۱۲} و لگاریتم سیگموئید^{۱۳} داشتند و تعداد نرون‌های لایه میانی زمانی که شبکه تنها یک لایه میانی داشت از ۱ تا ۱۰ تغییر می‌کرد و همچنین هنگامی که شبکه عصبی دو لایه میانی داشت، تعداد نرون‌های هر لایه میانی از ۱ تا ۷ تغییر می‌یافت. بر این اساس ۱۴۱۳ ساختار مختلف مورد ارزیابی قرار گرفت. هر کدام از ساختارهای شبکه با میانگین گرفتن از MSE داده‌های اعتبارسنجی در بیست بار آموزش مشخص شد. در نهایت ساختاری که کمترین میانگین MSE را داشت، انتخاب شد.

در طراحی شبکه عصبی $\alpha\beta_{11}$ ، شبکه با ساختار ۵:۶:۴:۲ داشت. که در لایه‌های میانی از تابع انتقال لگاریتم سیگموئید و در لایه خروجی از تابع انتقال خطی استفاده شده بود، کمترین میانگین MSE را برای داده‌های اعتبارسنجی داشت و برگزیده شد. میانگین رگرسیون و MSE داده‌های اعتبارسنجی آن به ترتیب ۰/۹۹۴۶ و ۱/۹۷۰۰e-۵ بود. شکل ۶، شماتیک شبکه عصبی استفاده شده را نشان می‌دهد.

پس از طراحی ساختار شبکه عصبی، با چندین بار استفاده از وزن‌های

- 1- Levenberg-Marquardt Back-Propagation (trainlm)
- 2- Conjugate Gradient Back-Propagation with Polak-Ribière Updates (traincgp)
- 3- Gradient Descent with Adaptive Learning Rate Back-Propagation (traingda)
- 4- Gradient Descent with Momentum and Adaptive Learning Rate Back-Propagation (traingdx)
- 5- Resilient Back-Propagation (trainrp)
- 6- Scaled Conjugate Gradient Back-Propagation (trainscg)
- 7- One-Step Secant Back-Propagation (trainoss)
- 8- Conjugate Gradient Back-Propagation with Fletcher-Reeves Updates (traincgf)
- 9- BFGS Quasi-Newton Back-Propagation (trainbfg)
- 10- Conjugate Gradient Back-Propagation with Powell-Beale Restarts (traincgb)
- 11- Linear Transfer Function (purelin)
- 12- Hyperbolic Tangent Sigmoid (tansig)
- 13- Log-Sigmoid Transfer Function (logsig)

جدول 4 تعدادی از مجموعه داده‌های استفاده شده به عنوان ورودی شبکه عصبی							نوع مجموعه داده	
لوله حاوی سیال = 1 لوله خالی = 0	فشار وارد بر سطوح داخلی لوله	فرکانس طبیعی چهارم لوله سالم	فرکانس طبیعی سوم لوله سالم	فرکانس طبیعی دوم لوله سالم	مدول الاستیسیته فلز لوله	ورودی شبکه عصبی	و	
✓	✓	✓	✓	✓	✓	a		
				✓	✓	b		
					✓	c		
					✓	d		
					✓	e		
					✓	f		

این شبکه‌های عصبی از نوع MLP باتابع یادگیری trainlm می‌باشند. پنج ورودی شبکه‌های عصبی (۱) فرکانس چهارم لوله سالم، (۲) مدول الاستیسیته فلز لوله، (۳) فرکانس دوم لوله ترکدار تقسیم بر فرکانس دوم لوله سالم (f_c^2/f_{nc}^2)، (۴) فرکانس سوم لوله ترکدار تقسیم بر فرکانس سوم لوله سالم (f_c^3/f_{nc}^3) و (۵) فرکانس چهارم لوله ترکدار تقسیم بر فرکانس چهارم لوله سالم (f_c^4/f_{nc}^4) می‌باشد. ساختارهای مختلف شبکه عصبی با یک یا دو لایه میانی و توابع تبدیل مختلف (تابع تبدیل خطی، تانژانت هیپربولیک سیگموئید و لگاریتم سیگموئید) و تعداد نرون‌های لایه میانی مختلف، ۲۰ بار با وزن‌های تصادفی مختلف شبکه آموزش داده شدند و کارایی هر کدام از ساختارهای مختلف با میانگین گرفتن از MSE داده‌های اعتبارسنجی در ۲۰ بار آموزش مشخص شد. ساختاری از شبکه که در داده‌های اعتبارسنجی بهترین کارایی (کمترین میانگین MSE) را داشت، برای شبکه عصبی انتخاب شد. ساختار انتخاب شده و میانگین MSE و رگرسیون هر شبکه عصبی در داده‌های اعتبارسنجی در جدول ۹ نشان داده شده است. در نهایت شبکه‌های عصبی که بهتر آموزش دیده بودند (یعنی وزن‌های بهینه‌ای داشتند) انتخاب و تست شدند. در جدول ۱۰ نیز کارایی شبکه‌های عصبی با وزن‌های بهینه در کل داده‌ها و داده‌های آزمون ارائه شده است.

5- بحث و مقایسه روش‌ها

مقایسه شبکه‌های عصبی MLP استفاده شده در این مقاله با روش موریجندراپا و همکارانش [1] که با استفاده از فرکانس‌های طبیعی و خیز تیر، سختی فنر پیچشی معادل ترک را محاسبه کرده و سپس رابطه بین این سختی معادل را با سایز و موقعیت نسبی ترک به دست آورده بودند، در جدول ۱۱ ارائه شده است. از جدول ۱۱ واضح است که شبکه‌های عصبی در مقایسه با روش تحلیلی مرجع [1]، در تشخیص سایز نسبی عملکرد بهتری داشتند و در یافتن موقعیت نسبی ترک، تنها شبکه عصبی β_{11} از روش تحلیلی موقیت‌آمیزتر بود. شبکه‌های عصبی زمانی که به صورت جدآگاه سایز و موقعیت ترک را تخمین می‌زنند، عملکرد نسبتاً بهتری داشتند، به نحوی که همان طور که در جدول ۱۱ نشان داده شده است، حداکثر درصد خطای نسبی شبکه‌های α_{11} و β_{11} از شبکه α_{15} و β_{15} و شبکه‌های α_{15} و β_{15} از شبکه α_{15} کمتر می‌باشد.

زمانی که داده‌های مربوط به آموزش بیشتر و داده‌های آزمون کمتر و از یک جنس بودند، عملکرد شبکه عصبی بهتر بود یعنی شبکه‌های α_{11} ، α_{15} و β_{11} از شبکه‌های α_{15} ، α_{15} و β_{15} و α_{15} عملکرد بهتری داشتند. درنتیجه انتظار می‌رود، این شبکه‌های عصبی با آموزش توسط نمونه‌های بیشتر، سایز و موقعیت نسبی ترک را دقیق‌تر تخمین بزنند.

با توجه به ساختارهای متفاوت انتخاب شده به عنوان بهترین ساختار برای شبکه‌های عصبی با تعداد ورودی‌های مختلف و خروجی مجزا یا همزمان تشخیص سایز و موقعیت ترک لوله حاوی سیال، بررسی ساختارهای مختلف شبکه عصبی در هر حالت ضروری است.

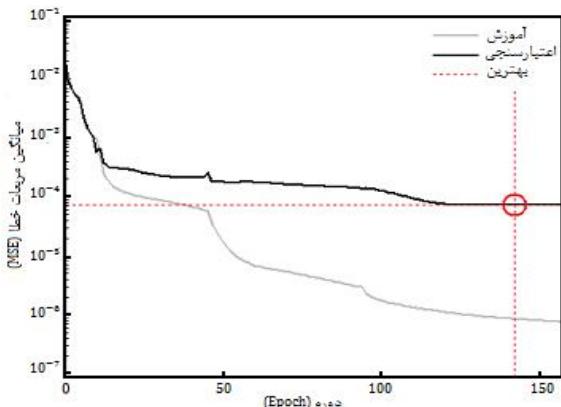
جدول 5 تعدادی از مجموعه داده‌های استفاده شده به عنوان ورودی شبکه عصبی

نوع مجموعه داده ورودی	ورودی‌ها
A	f_c^4
B	$f_c^4 - f_{nc}^4$
C	$f_c^4 - f_{nc}^4$
D	f_{nc}^4

همچنین رگرسیون بین داده‌های خروجی شبکه عصبی با داده‌های هدف، برای داده‌های آزمون، $0/9980$ بدست آمد، که در شکل ۹ نشان داده شده است. شبکه عصبی $\alpha_{\beta 11}$ در مجموعه داده‌های آموزش و اعتبارسنجی، در هنگام تشخیص سایز و موقعیت نسبی ترک، به ترتیب حداقل $8/039$ و $6/777$ خطای داشت. این شبکه عصبی برای داده‌های آزمون، در هنگام تشخیص سایز و موقعیت نسبی ترک، به ترتیب $7/730$ و $6/962$ خطای داشت. در جدول ۷ مقادیر خطای برای تمام نمونه‌های آزمون آمده است. میانگین مطلق درصد خطای (MAPE) برای داده‌های آزمون، به منظور تشخیص سایز و موقعیت به ترتیب برابر $2/158$ و $2/730$ است و MAPE کل داده‌ها برای تشخیص سایز و موقعیت به ترتیب برابر $1/010$ و $1/109$ است.

3-4- طراحی تعدادی شبکه عصبی دیگر

در این قسمت، ابتدا شبکه عصبی با استفاده از داده‌های آزمون بیشتر و همزمان از دو جنس متفاوت، بر اساس جدول ۲ ساخته و استفاده شد، تا قوام این روش را شناس دهد. مرور تحقیقات انجام شده روی سازه‌های مختلف نظری تیر و روتور نشان می‌دهد که تاکنون از جنس‌های مختلف به منظور تشخیص ترک با شبکه عصبی استفاده نشده است. همچنین چهار شبکه عصبی که به صورت جدآگاه مکان و یا سایز ترک لوله را تشخیص می‌دادند، طراحی شد. پنج شبکه عصبی که در این بخش طراحی شدند، در جدول ۸ معرفی شدند. روند طراحی هر پنج شبکه عصبی این قسمت، کاملاً شبیه شبکه عصبی ای که در ابتدای این مقاله بود ($\alpha_{\beta 11}$) می‌باشد.



شکل 7 روند تغییرات خطای حین یادگیری نشان داده شده است. دایره نشان دهنده زمانی است که شبکه بیشترین تعمیم پذیری را دارد.

جدول 6 مقایسه توابع مختلف یادگیری پس انتشار

تابع یادگیری داده‌های آموزش	بهترین رگرسیون داده‌های آموزش ($\times 10^{-4}$)	میانگین داده‌های اعتبارسنجی در هر بار آموزش	MSE میانگین تعداد دوره	میانگین رگرسیون داده‌های اعتبارسنجی ($\times 10^{-4}$)	میانگین رگرسیون داده‌های آموزش ($\times 10^{-4}$)	میانگین رگرسیون داده‌های آموزش	MSE میانگین داده‌های آموزش ($\times 10^{-4}$)	بهترین رگرسیون داده‌های آموزش
trainlm	0 / ۹۹۹۱	0/3006	0/9952	1/6237	0 / ۹۹۱۸	2/9760	38/86	0 / ۹۹۹۱
traincgp	0 / ۹۹۹۰	0/3244	0/9946	1/8516	0 / ۹۹۱۳	3/1331	39/86	0 / ۹۹۹۰
traingda	0 / ۹۸۶۸	4/4749	0/9497	16/3617	0 / ۹۵۵۰	15/4053	454/4	0 / ۹۸۶۸
traingdx	0 / ۹۷۰۰	10/2071	0/9187	26/6048	0 / ۹۲۸۸	24/5485	176/53	0 / ۹۷۰۰
trainrp	0 / ۹۹۲۹	2/3895	0/9805	6/5041	0 / ۹۸۱۵	6/6657	202/76	0 / ۹۹۲۹
trainscg	0 / ۹۹۵۳	1/5934	0/9830	5/6796	0 / ۹۸۴۰	5/7363	108/14	0 / ۹۹۵۳
trainoss	0 / ۹۹۴۱	1/9895	0/9822	5/9498	0 / ۹۸۳۶	5/9464	112/85	0 / ۹۹۴۱
traincfgf	0 / ۹۹۴۴	1/8877	0/9805	6/5306	0 / ۹۸۳۳	6/0036	102/45	0 / ۹۹۴۴
trainbfg	0 / ۹۹۴۵	1/8711	0/9810	6/3504	0 / ۹۸۲۶	6/2374	114/3	0 / ۹۹۴۵
traincgb	0 / ۹۹۵۵	1/5135	0/9858	4/7753	0 / ۹۸۶۴	5/4973	104/3	0 / ۹۹۵۵

جدول 7 مقدار واقعی و پیش‌بینی شده با شبکه عصبی $\alpha\beta11$ و درصد خطای سایز و موقعیت ترک برای مجموعه داده‌های تست

نمونه	موقعیت واقعی ترک	به ضخامت ترک	به وسیله شبکه عصبی	به وسیله شکلکه عصبی	موقعیت نسبی ترک تعیین شده	درصد خطای سایز	درصد خطای نسبی سایز	درصد خطای
1	0/207	0/19043	0/220360514915918	0/188060441855783	6/4543	-1/2443	6/9623	1/3797
2	0/207	0/25385	0/221412023003993	0/257352419951649	-0/8939	1/7566	0/1966	1/1596
3	0/207	0/38077	0/205149504059502	0/387458799901226	4/6799	-1/3386	0/234227631838631	7/7299
4	0/207	0/63460	0/206592986195275	0/626105351098444	0/3344	1/3462	0/2606	5/5434
5	0/284	0/19043	0/303702060753571	0/192638241461969	0/3943	-1/4768	0/375146809327916	-1/4768
6	0/284	0/25385	0/297291034448530	0/234227631838631	-0/0133	-0/1595	0/633588053084976	-0/1595
7	0/284	0/38077	0/284949708784434	0/378483593620296	0/2606	0/2606	0/2606	1/3462
8	0/284	0/63460	0/284739410301626	0/626057229631539	0/3943	0/3943	0/3943	1/3462
9	0/397	0/25385	0/408517464304801	0/267921876980977	0/3943	0/3943	0/3943	1/3462
10	0/397	0/38077	0/398565393318921	0/375146809327916	-0/0133	-0/1595	0/633588053084976	-0/1595
11	0/397	0/63460	0/396947239659264	0/633588053084976	0/3943	0/3943	0/3943	1/3462

جدول 8 خصوصیات شبکه‌های عصبی طراحی شده در این بخش

شبکه عصبی	تخمین زننده	تعداد داده آزمون	تقسیم داده‌ها بر اساس
سایز	11	(a)	جدول 1
سایز	15	(a)	جدول 2
موقعیت	11	(β)	جدول 1
موقعیت	15	(β)	جدول 2
سایز و موقعیت	15	(α,β)	جدول 2

جدول 9 ساختارهای انتخاب شده برای شبکه‌های عصبی و عملکرد هر شبکه در 20 بار آموزش شبکه

شبکه عصبی	توابع تبدیل به کار رفته (به ترتیب از راست به چپ)	ساختار	میانگین رگرسیون	میانگین MSE
α_{11}	لگاریتم سیگموئید - لگاریتم سیگموئید - تابع انتقال خطی	0/000167	0/9980	5:7:7:1
α_{15}	لگاریتم سیگموئید - تابع انتقال خطی	0/000455	0/9829	5:8:1
β_{11}	تازه‌انت هیپربولیک سیگموئید - لگاریتم سیگموئید - تازه‌انت هیپربولیک سیگموئید	0/000086	0/9948	5:7:6:1
β_{15}	تازه‌انت هیپربولیک سیگموئید - تابع انتقال خطی	0/001633	0/7645	5:3:1
$\alpha\beta_{15}$	لگاریتم سیگموئید - تازه‌انت هیپربولیک سیگموئید	0/000803	0/9293	5:4:2

تنها با دانستن جنس لوله و یکی از فرکانس‌های لوله سالم، به همراه سه فرکانس از لوله معیوب (دوم، سوم و چهارم) به راحتی مشخصات ترک لوله مشخص می‌شود. در مجموع بدون در نظر گرفتن سادگی شبکه عصبی نسبت به روش تحلیلی برای رسیدن به دقیق ترین مشخصات ترک لوله، در تشخیص سایز نسبی، همواره شبکه عصبی موفقیت آمیزتر عمل کرد و این روش پیشنهاد می‌شود.

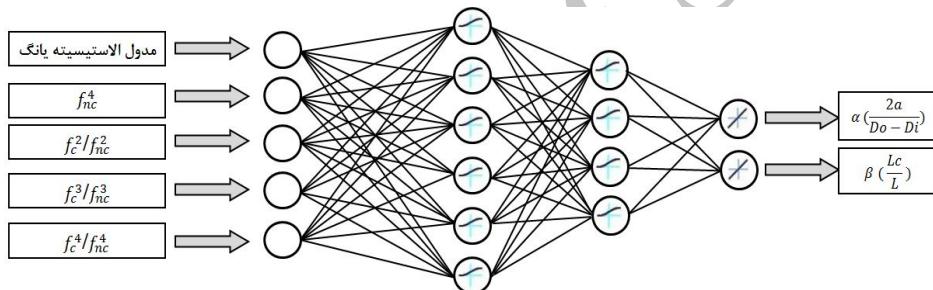
تحقيق حاضر ویژگی معمول روش‌های داده محور، یعنی اجرای ساده‌تر و در عمل ارزان تر از روش‌های بر اساس مدل را دارد و محدوده اجرای آن برای قطعات مختلف، گستره‌تر از روش‌های بر اساس مدل می‌باشد. به عنوان نمونه، در روش بر اساس مدل [1] داده‌های ورودی برای مدل سازی بیش‌تر است از جمله مدول الاستیسیتی لوله همراه با سیال در فشارهای مختلف و همچنین محاسبات طولانی‌تر و پیچیده‌تری دارد. اما در این روش

جدول 10 کارایی شبکه‌های عصبی طراحی شده با وزن‌های بهینه در کل داده‌ها و داده‌های آزمون

MSE کل داده‌ها	رگرسیون کل داده‌ها	MSE داده‌های تست	رگرسیون داده‌های تست	شبکه عصبی
2/8284 e-5	0/9994	6/4422 e-5	0/9991	α_{11}
4/4655 e-5	0/9992	9/6434 e-5	0/9985	α_{15}
2/8924 e-7	0/9999	9/9976 e-7	0/9999	β_{11}
1/0199 e-5	0/9993	1/7613 e-5	0/9989	β_{15}
7/5492 e-5	0/9978	1/7577 e-4	0/9952	$\alpha\beta_{15}$

جدول 11 مقایسه عملکرد شبکه‌های عصبی و روش تحلیلی مقاله [1]

روش‌های تشخیص	در تشخیص موقعیت نسبی ترک	MAPE حداکثر درصد	MAPE حداکثر درصد	MAPE حداکثر درصد	روش موریجندرپا و همکارانش ^(*) [1].
	دراحتی که برای آلومینیوم $0/2284 = \beta$ و برای فولاد $0/199 = \beta$ است.	خطا کل داده‌ها خطای آزمون کل داده‌ها داده‌های آزمون خطای کل داده‌ها خطای داده‌های آزمون	خطای کل داده‌ها خطای آزمون کل داده‌ها داده‌های آزمون خطای کل داده‌ها خطای داده‌های آزمون	خطای کل داده‌ها خطای آزمون کل داده‌ها داده‌های آزمون خطای کل داده‌ها خطای داده‌های آزمون	
		-	-	-	
		8/8179 ^(**)	2/6	0/8983	-
		-	-	-	α_{11}
		6/0348	1/1715	-	
		-6/3665	1/4991	-	α_{15}
		-	1/1507	1/1507	β_{11}
		-	5/9592	5/9592	β_{15}
		-8/0387	1/0102	6/9623	$\alpha\beta_{11}$
		-8/8162	2/3267	11/5340	$\alpha\beta_{15}$

^(*) با استفاده از فنر پیچشی معادل به جای ترک.^(**) فقط در حالتی که برای آلومینیوم $0/2284 = \beta$ و برای فولاد $0/199 = \beta$ است.

شکل 6 تصویر شماتیک از شبکه عصبی پرسپترون چند لایه (MLP) طراحی شده

سایز و موقعیت نسبی ترک تشخیص داده شد؛ برای آموزش شبکه عصبی، نسبت فرکانس‌های طبیعی لوله ترکدار به لوله بدون ترک برگزیده و استفاده شد؛ همچنین از دیگر نوآوری این مقاله، استفاده از جنس‌های مختلف، همزمان برای آموزش و تست شبکه عصبی می‌باشد.

در انتخاب ساختار شبکه‌های عصبی، تعداد لایه‌ها، توابع تبدیل و تعداد نرون‌های لایه میانی مختلف مورد بررسی قرار گرفتند. ساختارهای شبکه‌های عصبی انتخاب شده در هر حالت در جدول 9 آمده است. نتایج شبکه‌های عصبی استفاده شده در این پژوهش در جدول 11 آمده است، که عملکرد قبل قبول استفاده از شبکه عصبی را در تشخیص سایز و موقعیت نسبی ترک لوله حاوی سیال را نشان می‌دهد. به عنوان نمونه شبکه عصبی α_{11} که سایز و شبکه β_{11} که موقعیت نسبی ترک لوله حاوی سیال را تشخیص می‌داند، به ترتیب دارای حداقل درصد خطای $6/0348$ و $1/1507$ بودند، در حالی که در روش تحلیلی حداقل درصد خطای سایز و موقعیت نسبی ترک به ترتیب $16/44$ و $2/6$ می‌باشد. شبکه‌های عصبی که به صورت مجزا سایز و موقعیت نسبی ترک را تشخیص می‌دانند، عملکرد نسبتاً بهتری در تشخیص سایز و موقعیت نسبی ترک داشتند به طوری که به عنوان نمونه حداقل درصد خطای شبکه $\alpha\beta_{15}$ در تشخیص سایز و موقعیت نسبی به ترتیب $11/5340$ و $9/0293$ می‌باشد که از حداقل خطای شبکه عصبی 15% در تشخیص سایز (%-6/3665) و شبکه β_{15} ، در تشخیص موقعیت ترک (%5/9592) بیشتر می‌باشد.

باید توجه داشت که در کاربرد عملی روشهای تشخیص بر اساس فرکانس طبیعی، تغییرات ناشی از ترک روی فرکانس طبیعی مقدار کمی بوده و در نتیجه ممکن است تغییرات فرکانسی لوله به سبب شرایط کاری و محیطی، اثر کاهش فرکانسی به سبب ترک را نشان ندهد [20]. بنابراین پیشنهاد می‌شود حتماً در صورت استفاده از این روش در شرایط کاری مختلف، پارامترهای مؤثر بر فرکانس طبیعی سازه ترکدار مثل دما شناسایی شده و به عنوان یکی از ورودی‌های شبکه عصبی لحاظ شود.

در این مقاله تنها لوله‌های مستقیم حاوی سیال ترکدار مورد بررسی قرار گرفتند، دلیل این امر عدم دسترسی به داده‌های مورد نیاز برای لوله‌های غیرمستقیم بود. با این حال، هر چند روش حاضر به سهولت با استفاده از تغییرات فرکانس‌های طبیعی و شبکه عصبی قابلیت اجرا دارد، و نتایج این تحقیق در لوله‌های مستقیم بسیار خوب بود ولی دقت استفاده از شبکه عصبی برای تشخیص ترک در لوله‌های غیر مستقیم و همراه با تغییرات ناگهانی در جنس و سطح مقطع، خود موضوع تحقیق دیگری می‌تواند باشد و در این شرایط واضح است که تغییرات ناگهانی سطح مقطع، راستا و مدول الاستیسیته لوله به دلیل تاثیر گذاری بر فرکانس‌های طبیعی باید به عنوان ورودی شبکه مورد استفاده قرار بگیرند.

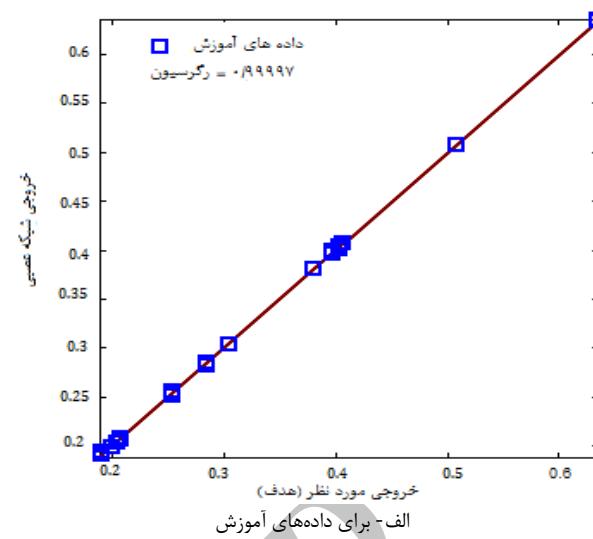
6- نتایج

در این مقاله برای اولین بار در لوله‌های حاوی سیال با استفاده از شبکه عصبی،

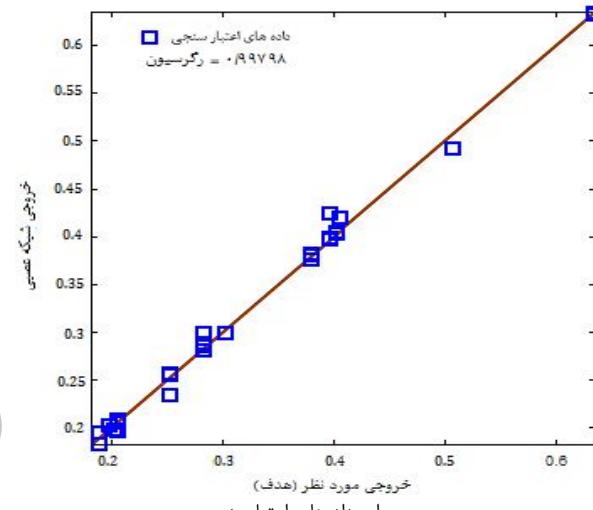
روش تحلیلی همواره دقیق‌تر است. به صورتی که در شبکه عصبی $\alpha\beta15$ ، $\alpha\beta15$ ضعیفترین نتایج را در تشخیص سایز ترک داشت، حداکثر درصد خطأ و MAPE، به ترتیب $9\% / 0293$ و $3/5384$ می‌باشد که از روش موجیندرپا و همکارانش که دارای حداکثر درصد خطأ و MAPE، به ترتیب $16\% / 44$ و $8/8179$ می‌باشد، خطای کمتری دارد.

7- مراجع

- [1] S. M. Murigendrappa, S. K. Maiti, H. R. Srirangarajan, Experimental and theoretical study on crack detection in pipes filled with fluid, *Journal of Sound and Vibration*, Vol. 270, No. 4-5, pp. 1013-10322004.,
- [2] Y. J. Yan, L. Chengb, Z. Y. Wu, L. H. Yam, Development in vibration-based structural damage detection technique, *Mechanical Systems and Signal Processing*, Vol. 21, No. 5, pp. 2198-2211, 2007.
- [3] J. T. Kim, Y. S. Ryu, H. M. Cho, N. Stubbs, Damage identification in beam-type structures: frequency-based method vs mode-shape-based method, *Engineering Structures*, Vol. 25, No. 1, pp. 57-67, 2003.
- [4] R. B. Randall, *Vibration-based condition monitoring (industrial, aerospace, automotive and applications)*, United Kingdom: John Wiley & Sons, 2011.
- [5] A. D. Dimarogonas, Vibration of cracked structures: state of the art review, *Engng Fract Mech*, Vol. 55, No. 5, pp. 831-857, 1996.
- [6] H. Nahvi, M. Jabbari, Crack detection in beams using experimental modal data and finite element model, *International Journal of Mechanical Sciences*, Vol. 47, No. 10, pp. 1477-1497, 2005.
- [7] S. Talebi, A. Ariaei, Vibration analysis of rotating tapered cantilever beams and their crack detection using genetic algorithm, *Modares Mechanical Engineering*, Vol. 13, No. 8, pp. 1-13, 2013. (In Persian)
- [8] J. Lee, Identification of multiple cracks in a beam using vibration amplitudes, *Journal of Sound and Vibration*, Vol. 326, No. 1-2, pp. 205-212, 2009.
- [9] S.M. Murigendrappa, S. K. Maiti , H. R. Srirangarajan, Frequency-based experimental and theoretical identification of multiple cracks in straight pipes filled with fluid, *NDT&E International*, Vol. 37, No. 6, pp. 431-438, 2004.
- [10] M. R. Naniwadekar, S. S. Naik, S. K. Maiti, On prediction of crack in different orientations in pipe using frequency based approach, *Mechanical Systems and Signal Processing*, Vol. 22, No. 3, pp. 693-708, 2008.
- [11] M. Dilena, M. F. Dell'oste, A. Morassi, Detecting cracks in pipes filled with fluid from changes in natural frequencies, *Mechanical Systems and Signal Processing*, Vol. 25, No. 8, pp. 3186-3197, 2011.
- [12] S. W. Liua, J. H. Huang, J. C. Sungb, C. C. Lee, Detection of cracks using neural networks and computational mechanics, *Comput. Methods Appl. Mechanical Engineering*, Vol. 191, No. 25-26, pp. 2831-2845, 2002.
- [13] L. Huijian, H. Changjun, J. Jialin, H. Wang, C. Hao, Crack damage detection in beam-like structures using RBF neural networks with experimental validation, *International Journal of Innovative Computing Information and Control*, Vol. 1, No. 4, pp. 625-634, 2005.
- [14] J. L. Zapico, K. Worden, F. J. Molina, Vibration-based damage assessment in steel frames using neural networks, *J. Smart Mater. Struct.*, Vol. 10, No. 3, pp. 553-559, 2001.
- [15] F. Cau, A. Fanni, A. Montisci, P. Testoni, M. Usai, A signal-processing tool for non-destructive testing of inaccessible pipes, *Engineering Applications of Artificial Intelligence*, Vol. 19, No. 7 pp. 753-760, 2006.
- [16] D. P. Patil, S. K. Maiti, Experimental verification of a method of detection of multiple Cracks in beams based on frequency measurements, *Journal of Sound and Vibration*, Vol. 281, No. 1-2, pp. 439-451, 2005.
- [17] G. Vachtsevanos, F. Lewis, M. Roemer, A. Hess, B. Wu, *Intelligent fault diagnosis and prognosis for engineering systems*, pp. 8-10, New Jersey: John Wiley & Sons, 2006.
- [18] J. Rafiee, F. Arvani, A. Harifi, M.H. Sadeghi, Intelligent condition monitoring of a gearbox using artificial neural network, *Mechanical Systems and Signal Processing*, Vol. 21, No.4, pp. 1746-1754, 2007.
- [19] M. H. Beale, M. T. Hagan, H. B. Demuth, *Neural Network Toolbox™7 User's Guide*, 2010.
- [20] W. Fan, P. Qiao, Vibration-based Damage Identification Methods: A Review and Comparative Study, *Structural Health Monitoring*, Vol. 10, No. 1, pp. 83-111, 2011.

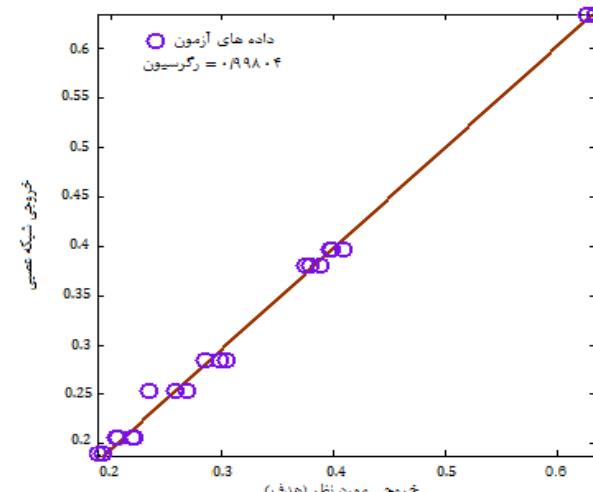


الف - برای داده‌های آموزش



ب - برای داده‌های اعتبارسنجی

شکل 8 همبستگی بین داده‌های خروجی از شبکه عصبی با داده‌های هدف



شکل 9 همبستگی بین داده‌های خروجی از شبکه عصبی با داده‌های هدف، برای داده‌های آزمون.

همچنین نتایج نشان داد در تشخیص سایز ترک، استفاده از شبکه عصبی از