



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

مصطفی رستاقی¹، مهرداد نوری خاجوی طهرانی^{2*}

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

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

* تهران، صندوق پستی 1678815811، mnouri@srttu.edu

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 0/498 MPa و با فشار 0/981 MPa می‌باشد. محدوده سایز ترک از 0/19043 تا 0/6346 و محدوده موقعیت از 0/199 تا 0/403 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. همچنین استفاده همزمان از سازه‌های با دو جنس مختلف برای آموزش و تست شبکه عصبی از دیگر نوآوری‌های 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.

اطلاعات مقاله

مقاله پژوهشی کامل
دریافت: 25 شهریور 1392
پذیرش: 03 آذر 1392
ارائه در سایت: 22 تیر 1393
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, Mehرداد 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.

1- مقدمه

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 زمان‌بر هستند [1] 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 عیب‌یابی ترک لوله حاوی سیال دو مزیت دارد: 1) 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 غیرمخرب¹ به منظور شناسایی وضعیت خرابی موضوعی مهم می‌باشد. تکنیک‌های غیرمخرب زیادی برای شناسایی ترک وجود دارد. آزمون‌های غیرمخرب از قبیل مایع نفوذپذیر²، تست ذرات مغناطیسی³، روش مشاهده مستقیم⁴، بازرسی فراصوتی⁵ و روش اشعه ایکس⁶


- 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)

Please cite this article using:

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)

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 1 تصویری شماتیک از لوله‌ی ترک‌دار [1]

دامنه سیگنال و شکل مود هم می‌تواند برای تشخیص ترک استفاده شود، اما چون در یک سازه، فرکانس‌های طبیعی به آسانی اندازه‌گیری می‌شوند و مستقل از محل اندازه‌گیری می‌باشند و همچنین عموماً صحت اندازه‌گیری فرکانس‌های طبیعی بالاتر از شکل مودها یا میرایی مودال است [2]، تاکنون در تحقیقات زیادی، از فرکانس‌های طبیعی برای تشخیص ترک در سازه‌ها استفاده شده است.

3- داده‌های 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 موریندراپا و همکارانش در مرجع [1] به دست آورده‌اند، استفاده شده است. موریندراپا 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 گنج لوله‌ها، موقعیت و سایز نسبی 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 0/87 و 0/8 متر می‌باشد. فشار گنج لوله‌های حاوی سیال از 0MPa تا 0/981MPa و سایز نسبی ترک $(\alpha = 2a/D_o - D_i)$ از 0/19043 تا 0/6346 و موقعیت نسبی ترک $(\beta = L_c/L)$ از 0/199 تا 0/403 بوده است. ترک‌ها به وسیله دستگاه وایرکات ایجاد شده بودند که قطر وایر آن 0/15 میلی متر است [1].

4- شبکه عصبی مصنوعی

4-1- طراحی شبکه عصبی

متداول‌ترین 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 غیرمخرب بر اساس ارتعاشات سال‌ها است که مورد توجه قرار گرفته‌اند، [2-4]. برای تشخیص ترک‌ها نیز به طور خاص کارهای زیادی از قبیل مرور خوبی توسط دیماروگونس [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 روششان 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 آوردند [7]. پرترفدارترین 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 متخصصان واقع شود. در سال 2004، موریندراپا 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 آوردند 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 نمودارهایی رابطه بین سایز و مکان نسبی ترک با سختی پیچشی فنر معادل را به دست آوردند [1]. عملکرد این روش در تشخیص موقعیت نسبی ترک لوله خیلی خوب بود ولی سایز نسبی ترک را با خطای بالا تشخیص می‌داد. موریندراپا 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]. نانویودکار 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 خرابی در سازه‌های مختلف تشخیص داده شده است [12-14]. فرانسسکا ساو و همکارانش برای تشخیص عیب در لوله‌ها از شبکه عصبی پرسپترون چندلایه فیدفوراد و امواج صوتی هدایت شده استفاده کردند. آن‌ها از PCA¹ و 2FFT² به عنوان پیش پردازش داده‌ها برای استفاده در شبکه عصبی استفاده کردند [15].

2- تشخیص ترک بر اساس فرکانس طبیعی

اغلب کاهش در سختی محلی به دلیل ترک یا عیبی شبیه 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 متداول است.

3- Data Driven
4- Historical Data Diagnostic Tools
5- Statistical Legacy Data Classification
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 t_i و a_i به ترتیب خروجی‌های واقعی و هدف برای i امین خروجی می‌باشند و N تعداد نرون 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 نرون در لایه مخفی (به صورت پیش‌فرض که در مراحل بعد، ساختار بهینه شبکه به دست آورده می‌شود) و دو نرون 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 دارا بود.

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 c ترک‌دار بودن و اندیس پائین nc سالم بودن لوله را نشان می‌دهد. به عنوان مثال f_{nc}^3 نشان دهنده فرکانس طبیعی سوم لوله 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 الاستیسیته، 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 الاستیسیته 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 الاستیسیته 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.

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 خطا 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 بیش‌برازش می‌کند، خطای مجموعه اعتبارسنجی نوعاً شروع به افزایش می‌کند، در این 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 شدند. 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 شدند و خروجی‌های شبکه عصبی به صورت همزمان سایز و موقعیت ترک لوله‌ها می‌باشند. این شبکه عصبی بر اساس جدول 3، شبکه $\alpha\beta 11$ نامیده شد.

در طراحی شبکه‌های عصبی، در ابتدا به صورت پیش‌فرض، از تابع تبدیل تانژانت هیپربولیک سیگموئید 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 خطا (MSE) مشخص شد که از طریق جمع مربعات خطای هر نرون در لایه خروجی، تقسیم بر تعداد نرون‌های لایه خروجی، به دست می‌آید. رابطه (1) نحوه محاسبه میانگین مربعات خطا (MSE) را نشان می‌دهد.

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

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

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


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

تصادفی مختلف، وزن‌هایی که شبکه عصبی با آنها یادگیری بهتری داشت، انتخاب شدند. شکل 7، روند تغییرات خطا حین یادگیری را برای شبکه‌ای که انتخاب شده بود، نشان می‌دهد. بعد از 15 دوره که خطای داده‌های اعتبارسنجی کاهش نمی‌یابد، آموزش شبکه متوقف می‌شود. در این شکل، زمانی که شبکه بیش‌ترین تعمیم‌پذیری 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 $\alpha\beta11$ با وزن‌های بهینه، همبستگی بین داده‌های خروجی با داده‌های هدف برای داده‌های آموزش و اعتبارسنجی به ترتیب 0/9999 و 0/9979 به دست آمد (شکل 8).

2-4- بررسی نتایج شبکه عصبی


برای داده‌های آزمون شبکه عصبی $\alpha\beta11$ ، میانگین مربعات خطا (MSE) $8/7488e-5$ است.




شکل 2 میانگین MSE 100 بار آموزش شبکه عصبی برای هر مجموعه داده ورودی متفاوت با وزن‌های تصادفی



شکل 3 میانگین رگرسیون 100 بار آموزش شبکه عصبی برای هر مجموعه داده ورودی متفاوت با وزن‌های تصادفی



شکل 4 بزرگ‌نمایی شکل 2، برای مجموعه داده‌های Bd تا Df.



شکل 5 بزرگ‌نمایی شکل 3، برای مجموعه داده‌های Bd تا Df

نام شبکه عصبی	تخمین	تعداد داده‌های تقسیم داده‌ها
$\alpha\beta11$	سائز و موقعیت (α, β)	11
بر اساس	آزمون	جدول 1

در این مقاله برای انتخاب الگوریتم یادگیری پس‌انتشار، 10 الگوریتم یادگیری بر اساس معیار کارایی و سرعت یادگیری مقایسه شدند. الگوریتم‌های یادگیری بررسی شده شامل، لونیگ-مارکواریت پس‌انتشار¹، شیب مزدوج پس‌انتشار با به روز رسانی پولاک-ریبیر²، کاهش شیب با نرخ یادگیری تطبیقی پس‌انتشار³، کاهش شیب با مومنتم و نرخ یادگیری تطبیقی پس‌انتشار⁴، پس‌انتشار ارتجاعی⁵، شیب مزدوج مقیاس شده پس‌انتشار⁶، پس‌انتشار یک مرحله‌ای قاطع⁷، شیب مزدوج پس‌انتشار با بروز رسانی فلچرریوز⁸، پس‌انتشار شبه نیوتنی BFGS⁹ و شیب مزدوج پس‌انتشار با شروع های مجدد پاول-بیل¹⁰ می‌باشد. توضیحات در خصوص این توابع یادگیری در مرجع [19] دیده می‌شود.

ابتدا 10 الگوریتم یادگیری متفاوت برای آموزش شبکه عصبی MLP با 5 نرون در لایه میانی (به صورت پیش‌فرض) به کار گرفته شد. برای هر الگوریتم، 100 بار به صورت تصادفی وزن‌های اولیه انتخاب شدند و شبکه آموزش دید. میانگین عملکرد شبکه‌های عصبی در 100 بار آموزش با هر الگوریتم، در جدول 6 مقایسه شده‌اند که بهترین و سریع‌ترین یادگیری را الگوریتم trainlm، داشت. در نتیجه 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 خطی¹¹، تانژانت هیپربولیک سیگموئید¹² و لگاریتم سیگموئید¹³ داشتند و تعداد نرون‌های لایه میانی زمانی که شبکه تنها یک لایه میانی داشت از 1 تا 10 تغییر می‌کرد و همچنین هنگامی که شبکه عصبی دو لایه میانی داشت، تعداد نرون‌های هر لایه میانی از 1 تا 7 تغییر می‌یافت. بر این اساس 1413 ساختار مختلف مورد ارزیابی قرار گرفت. هر کدام از ساختارهای شبکه با وزن‌های تصادفی بیست بار آموزش دیدند، و کارایی هر کدام از ساختارهای مختلف 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 $\alpha\beta11$ ، شبکه با ساختار 5:6:4:2، 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 0/9946 و $1/9700e-4$ بود. شکل 6، 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 (trainrnp)
- 6- Scaled Conjugate Gradient Back-Propagation (trainscg)
- 7- One-Step Secant Back-Propagation (trainoss)
- 8- Conjugate Gradient Back-Propagation with Fletcher-Reeves Updates (traingcf)
- 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 ورودی شبکه عصبی	مدول الاستیسیته فلز لوله	فرکانس طبیعی دوم لوله سالم	فرکانس طبیعی سوم لوله سالم	فرکانس طبیعی چهارم لوله سالم	فشار وارد بر سطوح داخلی لوله	لوله حاوی سیال =1 لوله خالی =0
a	✓	✓			✓	✓
b	✓	✓			✓	
c	✓	✓			✓	
d	✓	✓			✓	
e	✓		✓			
f	✓			✓		

این شبکه‌های عصبی از نوع MLP با تابع یادگیری trainlm می‌باشند. پنج ورودی شبکه‌های عصبی (1) فرکانس چهارم لوله سالم، (2) مدول الاستیسیته فلز لوله، (3) فرکانس دوم لوله ترک‌دار تقسیم بر فرکانس دوم لوله سالم (f_c^2/f_{nc}^2) ، (4) فرکانس سوم لوله ترک‌دار تقسیم بر فرکانس سوم لوله سالم (f_c^3/f_{nc}^3) و (5) 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، 20 بار با وزن‌های تصادفی مختلف شبکه آموزش داده شدند و کارایی هر کدام از ساختارهای مختلف با میانگین گرفتن از MSE داده‌های اعتبارسنجی در 20 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 9 نشان داده شده است. در نهایت شبکه‌های عصبی که بهتر آموزش دیده بودند (یعنی وزن‌های بهینه‌ای داشتند) انتخاب و تست شدند. در جدول 10 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 موريجندراپا 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 11 ارائه شده است. از جدول 11 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 $\beta 11$ از روش تحلیلی موفقیت‌آمیزتر بود. شبکه‌های عصبی زمانی که به صورت جداگانه سایز و موقعیت ترک را تخمین می‌زدند، عملکرد نسبتاً بهتری داشتند، به نحوی که همان طور که در جدول 11 نشان داده شده است، حداکثر درصد خطای نسبی شبکه‌های $\alpha 11$ و $\beta 11$ از شبکه $\alpha \beta 11$ و شبکه‌های $\alpha 15$ و $\beta 15$ از شبکه $\alpha \beta 15$ 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 $\alpha 11$ ، $\beta 11$ و $\alpha \beta 11$ از شبکه‌های $\alpha 15$ ، $\beta 15$ و $\alpha \beta 15$ عملکرد بهتری داشتند. در نتیجه 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	f_c^3	f_c^2
B	$f_c^4 - f_{nc}^4$	$f_c^3 - f_{nc}^3$	$f_c^2 - f_{nc}^2$
C	$f_c^4 - f_{nc}^4$	$f_c^3 - f_{nc}^3$	$f_c^2 - f_{nc}^2$
D	f_{nc}^4	f_{nc}^3	f_{nc}^2
	f_c^4	f_c^3	f_c^2
	f_{nc}^4	f_{nc}^3	f_{nc}^2

همچنین رگرسیون بین داده‌های خروجی شبکه عصبی با داده‌های هدف، برای داده‌های آزمون، 0/9980 به دست آمد، که در شکل 9 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 حداکثر 8/039% و 6/777% خطا داشت. این شبکه عصبی برای داده‌های آزمون، در هنگام تشخیص سایز و موقعیت نسبی ترک، به ترتیب 7/730% و 6/962% خطا داشت. در جدول 7 مقادیر خطا برای تمام نمونه‌های آزمون آمده است. میانگین مطلق درصد خطا (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.

4-3- 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 2 ساخته و استفاده شد، تا قوام این روش را نشان دهد. مرور تحقیقات انجام شده روی سازه‌های مختلف نظیر 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 جداگانه مکان و یا سایز ترک لوله را تشخیص می‌دادند، طراحی شد. پنج شبکه عصبی که در این بخش طراحی شدند، در جدول 8 معرفی شده‌اند. روند طراحی هر پنج شبکه عصبی این قسمت، کاملاً شبیه شبکه عصبی‌ای که در ابتدای این مقاله بود ($\alpha \beta 11$) می‌باشد.



شکل 7 روند تغییرات خطا حین یادگیری نشان داده شده است. دایره نشان‌دهنده زمانی است که شبکه بیش‌ترین تعمیم‌پذیری را دارد.

جدول 6 مقایسه توابع مختلف یادگیری پس انتشار

تابع یادگیری	بهترین رگرسیون داده‌های آموزش	بهترین MSE داده‌های آموزش ($\times 10^{-4}$)	میانگین رگرسیون داده‌های آموزش ($\times 10^{-4}$)	MSE میانگین رگرسیون داده‌های اعتبارسنجی ($\times 10^{-4}$)	میانگین تعداد دوره در هر بار آموزش
trainlm	0/99991	0/3006	0/9952	2/9760	38/86
traincgp	0/9990	0/3244	0/9946	3/1331	39/86
traingda	0/9868	4/4749	0/9497	15/4053	45/4
traingdx	0/9700	10/2071	0/9187	24/5485	176/53
trainrp	0/9929	2/3895	0/9805	6/6657	202/76
trainscg	0/9953	1/5934	0/9830	5/7363	108/14
trainoss	0/9941	1/9895	0/9822	5/9464	112/85
traincgf	0/9944	1/8877	0/9805	6/0036	102/45
trainbfg	0/9945	1/8711	0/9810	6/2374	114/3
traincgb	0/9955	1/5135	0/9858	5/4973	104/3

جدول 7 مقدار واقعی و پیش بینی شده با شبکه عصبی $\alpha\beta 11$ و درصد خطای سایز و موقعیت ترک برای مجموعه داده‌های تست

نمونه	موقعیت واقعی ترک	مقدار واقعی عمق به ضخامت ترک	موقعیت نسبی ترک تعیین شده به وسیله شبکه عصبی	سایز نسبی ترک تعیین شده به وسیله شبکه عصبی	درصد خطای نسبی موقعیت	درصد خطای نسبی سایز
1	0/207	0/19043	0/220360514915918	0/188060441855783	6/4543	-1/2443
2	0/207	0/25385	0/221412023003993	0/257352419951649	6/9623	1/3797
3	0/207	0/38077	0/205149504059502	0/387458799901226	-0/8939	1/7566
4	0/207	0/63460	0/206592986195275	0/626105351098444	0/1966	-1/3386
5	0/284	0/19043	0/303702060753571	0/192638241461969	6/9373	1/1596
6	0/284	0/25385	0/297291034448530	0/234227631838631	4/6799	7/7299
7	0/284	0/38077	0/284949708784434	0/378483593620296	0/3344	-0/6005
8	0/284	0/63460	0/284739410301626	0/626057229631539	0/2606	1/3462
9	0/397	0/25385	0/408517464304801	0/267921876980977	2/9011	5/5434
10	0/397	0/38077	0/398565393318921	0/375146809327916	0/3943	-1/4768
11	0/397	0/63460	0/396947239659264	0/633588053084976	-0/0133	-0/1595

جدول 8 خصوصیات شبکه‌های عصبی طراحی شده در این بخش

شبکه عصبی	تخمین زنده‌ی	تعداد داده آزمون	تقسیم داده‌ها بر اساس
$\alpha 11$	سایز (α)	11	جدول 1
$\alpha 15$	سایز (α)	15	جدول 2
$\beta 11$	موقعیت (β)	11	جدول 1
$\beta 15$	موقعیت (β)	15	جدول 2
$\alpha\beta 15$	سایز و موقعیت (α, β)	15	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	MSE میانگین
$\alpha 11$	لگاریتم سیگموئید - لگاریتم سیگموئید - تابع انتقال خطی	5:7:7:1	0/000167
$\alpha 15$	لگاریتم سیگموئید - تابع انتقال خطی	5:8:1	0/000455
$\beta 11$	تانزانته هیپربولیک سیگموئید - لگاریتم سیگموئید - تانزانته هیپربولیک سیگموئید	5:7:6:1	0/000086
$\beta 15$	تانزانته هیپربولیک سیگموئید - تابع انتقال خطی	5:3:1	0/001633
$\alpha\beta 15$	لگاریتم سیگموئید - تانزانته هیپربولیک سیگموئید	5:4:2	0/000803

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 دقیق‌ترین مشخصات ترک لوله، در تشخیص سایز نسبی، همواره شبکه عصبی موفقیت آمیزتر عمل کرد و این روش پیشنهاد می‌شود.

تحقیق حاضر ویژگی معمول روش‌های داده محور، یعنی اجرای ساده‌تر و در عمل ارزان‌تر از روش‌های بر اساس مدل را دارد و محدودۀ اجرای آن برای قطعات مختلف، گسترده‌تر از روش‌های بر اساس مدل می‌باشد. به عنوان نمونه، در روش بر اساس مدل مرجع [1] داده‌های ورودی برای مدل‌سازی بیش‌تر است از جمله مدول الاستیسیته 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


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

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

روش‌های تشخیص		در تشخیص موقعیت نسبی ترک		در تشخیص سایز (عمق ترک به ضخامت) ترک	
MAPE کل داده‌ها	MAPE داده‌های آزمون	حداکثر درصد خطا کل داده‌ها	حداکثر درصد خطا داده‌های آزمون	MAPE کل داده‌ها	MAPE داده‌های آزمون
-	0/8983	-	2/6	8/8179(**)	16/44(**)
-	-	-	-	2/3721	5/9686
-	-	-	-	1/4991	-6/1136
0/0409	0/1250	1/1507	1/1507	-	-
0/9708	1/2795	5/9592	5/9592	-	-
1/1088	2/7298	6/9623	6/9623	2/1577	-7/7299
1/5488	2/6701	11/5340	11/5340	2/3267	-8/8162

(*) با استفاده از فنر پیچشی معادل به جای ترک.

(**) فقط در حالتی که برای آلومینیوم $\beta = 0/2284$ و برای فولاد $\beta = 0/199$ است.

شکل 6 تصویر شماتیک از شبکه عصبی پرسپترون چند لایه (MLP) طراحی شده α_{11}

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 متفاوت، 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 قابل 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 می‌دادند، به ترتیب دارای حداکثر درصد خطای 6/0348% و 1/1507% بودند، در حالی که در روش تحلیلی حداکثر 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 می‌دادند، عملکرد نسبتاً بهتری در تشخیص سایز و موقعیت نسبی ترک داشتند به طوری که به عنوان نمونه حداکثر درصد خطای شبکه $\alpha\beta_{15}$ ، در تشخیص سایز و موقعیت نسبی به ترتیب برابر 9/0293%- و 11/5340% می‌باشد که از حداکثر خطای شبکه عصبی α_{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 متفاوت، 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 $\alpha\beta 15$ ، که ضعیف‌ترین نتایج را در تشخیص سایز ترک داشت، حداکثر درصد خطا و MAPE، به ترتیب 9/0293% و 3/5384 می‌باشد که از روش موجیندراپا و همکارانش که دارای حداکثر درصد خطا 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. 1013-1032, 2004.
- [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. Huanga, 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.



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