

تشخیص نشتی در خط لوله نفت با استفاده از تبدیل موجک و ویژگی‌های آماری همراه با کاربرد شبکه عصبی مصنوعی

مرتضی زادکرمی¹، مهدی شهبازیان^{2*}، کریم سلحشور³

1- دانشجوی کارشناسی ارشد، مهندسی ابزار دقیق و اتوماسیون در صنایع نفت، دانشگاه صنعت نفت، اهواز

2- دانشیار، مهندسی ابزار دقیق و اتوماسیون در صنایع نفت، دانشگاه صنعت نفت، اهواز

3- استاد، مهندسی ابزار دقیق و اتوماسیون در صنایع نفت، دانشگاه صنعت نفت، اهواز

* اهواز، صندوق پستی 61991-71183، shahbazian@put.ac.ir

چکیده

نشتی‌های خط لوله نفت اگر مورد توجه واقع نشود می‌تواند منجر به خسارت‌های بزرگی گردد. اولین گام برای مقابله مؤثر با این نشتی‌ها، تشخیص محل وقوع آن‌ها است. در مقاله‌ی حاضر یک روش جدید آشکارسازی و جداسازی عیوب (FDI) مبتنی بر داده پیشنهاد می‌شود که نه تنها قادر است وقوع عیب نشتی و محل آن را آشکار سازد بلکه می‌تواند وخامت (اندازه) نشتی را نیز با دقت زیاد تخمین بزند. در مطالعه‌ی حاضر، خط لوله‌ی گلخاری-بینک که در جنوب ایران واقع شده، در نرم‌افزار الگا مدل‌سازی گردیده است که داده‌های مورد نیاز برای آموزش سیستم FDI را فراهم می‌نماید. سناریوهای مختلف نشتی بر مدل اعمال می‌گردد و نرخ دبی خروجی و فشار ورودی متناظر به عنوان داده‌های آموزش ثبت می‌شود. داده‌های بدست آمده در حوزه‌ی زمان به حوزه‌ی موجک انتقال داده می‌شوند. سپس ویژگی‌های آماری داده‌ها از دو حوزه‌ی موجک و زمان استخراج می‌شود. ویژگی‌های بدست آمده به یک شبکه‌ی عصبی چندلایه‌ی پرسپترون (MLPNN) به عنوان سیستم FDI اعمال می‌گردد. نتایج نشان می‌دهد که سیستم مبتنی بر ویژگی‌های آماری موجک عملکرد بهتری نسبت به سیستم مبتنی بر ویژگی‌های آماری حوزه‌ی زمان دارد. همچنین سیستم پیشنهادی می‌تواند محل و وخامت نشتی را با نرخ هشدار غلط (FAR) اندک و نرخ طبقه‌بندی صحیح (CCR) بسیار زیاد تشخیص دهد.

اطلاعات مقاله

مقاله پژوهشی کامل
دریافت: 12 تیر 1395
پذیرش: 06 مرداد 1395
ارائه در سایت: 21 شهریور 1395

کلید واژگان:

تشخیص نشتی

ویژگی آماری

تبدیل موجک

شبکه عصبی مصنوعی

Oil pipeline leak diagnosis using wavelet transform and statistical features with artificial neural network application

Morteza Zadkarami, Mehdi Shahbazian*, Karim Salahshoor

Department of Instrumentation and Automation Engineering, Petroleum University of Technology, Ahvaz, Iran.

* P.O.B. 61991-71183 Ahvaz, Iran, Shahbazian@put.ac.ir

ARTICLE INFORMATION

Original Research Paper
Received 02 July 2016
Accepted 27 July 2016
Available Online 11 September 2016

Keywords:

Leak diagnosis
Statistical feature
Wavelet transform
Artificial neural network

ABSTRACT

Oil pipeline leakages, if not properly treated, can result in huge losses. The first step in tackling these leakages is to diagnose their location. This paper employs a data-driven Fault Detection and Isolation (FDI) system, not only to detect the occurrence and location of a leakage fault, but also to estimate its severity (size) with extreme accuracy. In the present study, the Golkhari-Binak pipeline, located in southern Iran, is modeled in the OLGA software. The data used to train the data-driven FDI system is acquired by this model. Different leakage scenarios are applied to the pipeline model; then, the corresponding inlet pressure and outlet flow rates are recorded as the training data. The time-domain data are transformed into the wavelet domain; then, the statistical features of the data are extracted from both the wavelet and the time domains. Each of these features is then fed into a Multi-Layer Perceptron Neural Network (MLPNN) which functions as the FDI system. The results show that the system with the wavelet-based statistical features outperforms that of the time-domain based features. The proposed FDI system is also able to diagnose the leakage location and severity with a low False Alarm Rate (FAR) and a high Correct Classification Rate (CCR).

1-مقدمه

خط لوله از جمله عوامل اصلی ایجاد نشتی به شمار می‌آیند. سیستم‌های آشکارسازی و جداسازی عیوب نشتی (FDI)¹ را به دو دسته‌ی کلی مبتنی بر سخت‌افزار و نرم‌افزار تقسیم‌بندی می‌کنند [1]. سیستم‌های مبتنی بر سخت‌افزار از تجهیزات ویژه‌ای برای تشخیص مستقیم

خطوط لوله از جمله عوامل اصلی انتقال انرژی محسوب می‌شوند. اما نشتی این لوله‌ها می‌تواند محیط زیست را در معرض خطرات جدی قرار داده و موجب خسارت‌های مالی و حتی جانی فراوان گردد. طول عمر زیاد، نصب نادرست، عیوب مواد سازنده خط لوله و همچنین ساخت و سازهای نزدیک به

¹ Fault Detection and Isolation

Please cite this article using:

M. Zadkarami, M. Shahbazian, K. Salahshoor, Oil pipeline leak diagnosis using wavelet transform and statistical features with artificial neural network application, *Modares Mechanical Engineering*, Vol. 16, No. 9, pp. 107-112, 2016 (in Persian)

برای ارجاع به این مقاله از عبارت ذیل استفاده نمایید:

نشتی با نرخ هشدار غلط (FAR) ¹⁶ پایین، ناتوان از تعیین وخامت و مکان آن بود [11,10].

شهبازیان و همکاران، محل وقوع نشتی و اندازه آن را توسط شبکه عصبی مصنوعی (ANN) ¹⁷ در خط لوله‌ی گلخاری- بینک تعیین کردند. در کار مذکور فرض شده بود که فشار انتهایی خط لوله ثابت است. نرم‌افزار الگا سیگنال‌های فشار ورودی را در سناریوهای ¹⁸ مختلفی از نشتی با محل و اندازه‌های متفاوت ایجاد می‌کند. ویژگی‌های آماری و موجک از سیگنال‌ها استخراج و سپس ویژگی‌های مذکور به عنوان ورودی به یک شبکه‌ی عصبی تابع پایه‌ی شعاعی (RBFNN) ¹⁹ داده شد. نتایج مطالعه‌ی مذکور نشان می‌داد که سیستم FDI مبتنی بر ویژگی‌های موجک عملکرد بهتری نسبت به سیستم FDI مبتنی بر ویژگی‌های آماری دارد [12].

هدف مطالعه‌ی حاضر تعیین وقوع، محل و اندازه‌ی نشتی و در عین حال کاهش FAR است. در روش به کار گرفته شده از دو حسگر استفاده می‌شود که فشار ورودی و دبی خروجی را در سناریوهای مختلف نشتی اندازه‌گیری می‌کنند. داده‌های نشتی در حوزه‌ی زمان به حوزه‌ی موجک نگاشته می‌شوند. سپس ویژگی‌های آماری از حوزه‌های زمان و موجک استخراج گشته و هر کدام به عنوان بردار ورودی به یک سیستم طبقه‌بندی شبکه‌ی عصبی چندلایه‌ی پرسپترون (MLPNN) ²⁰ داده می‌شود. مطابق نتایج شبیه‌سازی، سیستمی که با ویژگی‌های آماری حاصل از حوزه‌ی موجک تغذیه شده عملکرد بهتری نسبت به سیستمی دارد که با ویژگی‌های حاصل از حوزه‌ی زمان تغذیه می‌شود.

ساختار مقاله در ادامه به شرح ذیل است. بخش 2 به پیش‌زمینه‌های نظری تکنیک موجک و طبقه‌بندی توسط ANN به عنوان دو عنصر اصلی سیستم FDI می‌پردازد. روش استخراج داده و معیار عملکرد سیستم نیز در این بخش شرح داده می‌شود. خط لوله‌ی مورد مطالعه گلخاری- بینک در بخش 3 توضیح داده می‌شود. بخش 4 به جزئیات سناریوهای مختلف نشتی پرداخته و روش‌های تشخیص این نشتی‌ها را ارائه می‌دهد. نتایج شبیه‌سازی در بخش 5 گنجانده شده است. در نهایت، بخش 6 به نتیجه‌گیری از کار حاضر می‌پردازد.

2- پیش‌زمینه‌های نظری

2-1- تبدیل موجک

همان‌طور که پیش‌تر اشاره شد، روش‌های پیش‌پردازش سیگنال در سیستم‌های آشکارسازی نشتی معمولاً مورد استفاده قرار می‌گیرند. تبدیل فوری به دلیل قابلیت ویژه‌اش در استخراج ویژگی‌های فرکانسی سیگنال‌ها یکی از پرکاربردترین پیش‌پردازنده‌ها به حساب می‌آید. علیرغم قابلیت تبدیل فوری در استخراج مشخصه‌های فرکانسی سیگنال، این تبدیل قادر به بیان مشخصه‌های حوزه‌ی زمان سیگنال نیست. اطلاعات حوزه‌ی زمان نیز به همراه مشخصه‌های حوزه‌ی فرکانس برای بیانی جامع و کامل از سیگنال‌ها لازم به است. لذا برای استخراج این اطلاعات زمانی از تبدیل فوری‌ی زمان- کوتاه (STFT) ²¹ استفاده می‌شود. STFT ابتدا سیگنال را به بلوک‌های زمانی کوچکی تجزیه می‌نماید و در ادامه تبدیل فوری را بر هر بلوک اعمال می‌کند. تبدیل فوری‌ی سیگنال زمانی $f(t)$ مطابق معادله (1) خواهد بود.

نشتی بهره می‌گیرند. روش‌های تشخیص نشتی فراصوت و صوتی، پایش خاک ¹ و تصویربرداری مادون قرمز حرارتی ² از جمله روش‌های FDI مبتنی بر سخت‌افزار هستند [2]. روش‌های مبتنی بر نرم‌افزار که از حسگرهای معمولی سامانه‌ی سرپرستی و گردآوری داده (SCADA) ³ بهره می‌گیرند، خود به روش‌های مبتنی بر مدل و مبتنی بر داده دسته‌بندی می‌شوند. از جمله روش‌های نرم‌افزاری عبارتند از مدل‌سازی بلادرنگ حالت گذر (RTTM) ⁴، روش موانه‌ی جرم و روش موج فشار منفی (NPW) ⁵ [3]. از جمله عیوب روش‌های FDI سخت‌افزاری هزینه بالا و نیروی انسانی زیاد است. بنابراین روش‌های شبیه‌سازی عددی جایگزین مناسبی می‌باشند [4]. سیستم‌های FDI مذکور در پیشینه‌ی تحقیقات معمولاً بر حسب سرعت تشخیص، سادگی در پیاده‌سازی، مقرون به صرفه بودن و توانایی در جداسازی دقیق عیوب و تعیین میزان وخامت آن‌ها مقایسه می‌شوند [5]. یک سیستم FDI مناسب نتیجه‌ی مصالحه‌ای میان این ویژگی‌ها است.

داده‌ها پیش از آن که به سیستم FDI داده شوند مورد پیش‌پردازش قرار می‌گیرند. به عنوان مثال در روش صوتی، نویزهایی ⁶ از سیگنال صوتی توسط تبدیل موجک ⁷ به عنوان یک عملیات پیش‌پردازش صورت گیرد. سپس در مرحله‌ی استخراج ویژگی از تحلیل‌های حوزه‌ی زمان برای دریافت خواصی از سیگنال همچون مقدار میانگین ⁸، چولگی ⁹ و میزان کشیدگی ¹⁰ سیگنال ورودی استفاده می‌شود [6].

هرگاه نشتی رخ دهد، یک شکل موج فشار منفی به سوی پایانه‌های خط لوله منتشر می‌شود. مدل‌های فشاری که در دو سر خط لوله نصب شده‌اند می‌توانند این تغییرات فشار را ثبت کنند و اطلاعات مورد نیاز برای روش NPW را فراهم آورند. این روش می‌تواند محل وقوع نشتی را نیز مشخص سازد. روش تلفیق موجک و NPW با موفقیت در خط لوله‌ی تیانجین ¹¹ در چین پیاده‌سازی شده است [7]. باوجود این مزیت‌ها، زمانی که فشار انتها خط لوله توسط کنترل‌کننده ثابت باقی بماند، روش NPW ناتوان از تشخیص نشتی‌های کوچک خواهد بود. از این رو سیگنال دبی جریان نیز اخذ می‌شود تا اطلاعات لازم برای تصمیم‌گیری در مورد نشتی در اختیار باشد [8]. یک شبکه‌ی عصبی احتمالاتی (PNN) ¹² که با داده‌هایی از سیگنال‌های فشار ورودی - خروجی و سیگنال دبی عبوری تغذیه می‌شود برای آشکارسازی نشتی پیشنهاد شده است [9].

ولی‌زاده و همکاران، مسئله‌ی آشکارسازی نشتی را همچون یک مسئله‌ی طبقه‌بندی ¹³ در نظر می‌گیرند و عیوب خط لوله‌ی سراج در قم را معلوم می‌سازند. این مولفان از نرم‌افزار الگا ¹⁴ برای کسب سیگنال‌های فشار، دما و دبی عبوری و خروجی استفاده کرده‌اند. آن‌ها ویژگی‌های آماری داده را استخراج کرده و سیستم‌های طبقه‌بندی متنوعی را مطالعه کرده‌اند. سپس این سیستم‌ها را از نظر نرخ طبقه‌بندی صحیح (CCR) ¹⁵ مورد مقایسه قرار داده‌اند. با این حال سیستم پیشنهادی آن‌ها با وجود توانایی تشخیص وقوع

¹ Soil monitoring

² Thermal infrared imaging

³ Supervisory Control And Data Acquisition

⁴ Real Time Transient Modeling

⁵ Negative Pressure Wave

⁶ denosing

⁷ Wavelet

⁸ Mean

⁹ Skewness

¹⁰ Kurtosis

¹¹ Tianjin

¹² Probabilistic Neural Network

¹³ Classification

¹⁴ OLGA

¹⁵ Correct Classification Rate

¹⁶ False Alarm Rate

¹⁷ Artificial Neural Network

¹⁸ Scenarios

¹⁹ Radial Basis Function Neural Network

²⁰ Multi-Layer Perceptron Neural Network

²¹ Short-Time Fourier Transform

$$\bar{x} = \frac{1}{N} \sum_{o=1}^N x_o \quad (4)$$

• انحراف معیار¹⁰

$$\sigma = \sqrt{\frac{1}{N} \sum_{o=1}^N (x_o - \bar{x})^2} \quad (5)$$

• چولگی

$$\gamma_1 = \frac{1}{N\sigma^3} \sum_{o=1}^N (x_o - \bar{x})^3 \quad (6)$$

• کشیدگی

$$\gamma_2 = \frac{1}{N\sigma^4} \sum_{o=1}^N (x_o - \bar{x})^4 - 3 \quad (7)$$

2-3-سیستم طبقه‌بندی شبکه‌ی عصبی مصنوعی

یافتن مدل ریاضی بر اساس قوانین فیزیکی برای استفاده در مسئله تشخیص نشتی خط لوله دشوار است، لذا از سیستم‌های FDI مبتنی بر داده برای پرهیز از مدل‌سازی مستقیم استفاده می‌شود [15]. در میان انواع مختلف سیستم‌های FDI مبتنی بر مدل، ANN قادر است اثرات نویز را کاهش دهد و تحلیلی سریع را برای تعداد زیادی داده فراهم آورد [16].

ANNها با یادگیری از طریق مثال، سعی در تقلید از عملکرد مغز انسان را دارند. این شبکه‌ها تا آنجا آموزش داده می‌شوند که برای مثال‌های آموزش داده شده خطایی کم داشته باشند. با استفاده از ANN بدون نیاز به مدل‌سازی مستقیم مسئله می‌توان روابط اصلی میان داده‌ها را استخراج کرد. ANNها را بر اساس الگوی ارتباطیشان به دو دسته‌ی اصلی تقسیم‌بندی می‌کنند: شبکه‌های پیش‌خور¹¹ که دارای حلقه نیستند و شبکه‌های پس‌خور¹²، MLPNN که در کار حاضر مورد استفاده قرار گرفته از شبکه‌های پیش‌خور محسوب می‌شود. در MLPNN ارتباطات وزن‌دار نوروها از طریق لایه‌های پیش‌خور برقرار می‌شود. در این مقاله از MLPNN با دو لایه پنهان میانی استفاده شده است.

نورون h ام از دومین لایه‌ی پنهان $(h+1)$ ، ورودی x_j^{h+1} را به صورت معادله (9) دریافت می‌کند.

$$x_j^{h+1} = \sum_i y_i^h w_{ij}^h - \theta_j^{h+1} \quad (8)$$

که در آن y_i^h خروجی لامین نورون از اولین لایه‌ی پنهان (h) است، w_{ij}^h وزن ارتباطی میان لامین نورون از لایه‌ی اول و لامین نورون از لایه‌ی دوم است. θ_j^{h+1} نیز حد آستانه را معلوم می‌کند.

$$x_j^h = \begin{cases} \frac{1}{1 + \exp(-x_j^h)} & \text{به ازای نورونی در هر لایه} \\ x_j^0 & \text{به ازای نورونی در لایه‌ی ورودی} \end{cases} \quad (9)$$

که در آن x_j^0 نمایانگر بردار ورودی است.

یادگیری زمانی کامل می‌شود که بتوان خطا را از طریق به‌روزرسانی وزن‌ها کمینه کرد. به ازای بردار وزن w ، میانگین مربعات خطا (MSE)¹³ به صورت معادله (10) تعریف می‌شود.

$$E(w) = \frac{1}{2} \sum_{j,p} (y_{j,p}^h(w) - d_{j,p})^2 \quad (10)$$

$$F(\omega) = \int_{-\infty}^{+\infty} f(t) \exp(-i\omega t) dt \quad (1)$$

که در آن $i = \sqrt{-1}$.

رابطه‌ی STFT به ازای سیگنال زمانی $f(t)$ به صورت معادله (2) است.

$$F_{STFT}(\tau, \omega) = \int_{-\infty}^{+\infty} f(t) g^*(t - \tau) \exp(-i\omega t) dt \quad (2)$$

که در آن τ پارامتر شیفت¹ زمانی است، سیگنال $g(t)$ پنجره‌ای با طول ثابت بوده و نماد (*) بیانگر مزدوج مختلط می‌باشد.

افراز² زمان - فرکانس STFT بر کل صفحه‌ی زمان - فرکانس، ثابت است. افراز زمان (Δt) و افراز فرکانس $(\Delta \omega)$ نمی‌توانند به طور همزمان مقادیری کوچک داشته باشند زیرا که مطابق اصل عدم قطعیت³ یا نامساوی هایزنبرگ⁴ $(\Delta t \Delta \omega \geq 0.5)$ ، یک حد پایین مجاز برای حاصل ضرب افرازهای زمان و فرکانس وجود دارد. اما تبدیل موجک با تغییر افرازهای Δt و $\Delta \omega$ در صفحه‌ی زمان - فرکانس دارای قابلیت تحلیل چنددقته⁵ است.

موجک‌ها یک خانواده را تشکیل می‌دهند که در آن موجک پایه، «موجک مادر، $\Psi(t)$ » نامیده می‌شود و تمامی دیگر موجک‌ها که با شیفت یا مقیاس‌بندی موجک مادر مطابق معادله (3) بدست می‌آیند [13].

$$\Psi_{a,b}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-\tau}{a}\right) \quad a \in \mathbb{R}^+, \tau \in \mathbb{R} \quad (3)$$

که در آن a ضریب مقیاس‌بندی و τ شیفت زمانی است.

به منظور استخراج اطلاعات مؤثر سیگنال، از تبدیل موجک گسسته (DWT)⁶ استفاده می‌شود. DWT سیگنال اصلی به اجزایی به نام کلیات⁷ (بخش‌های فرکانس پایین) و جزئیات⁸ (بخش‌های فرکانس بالا) تجزیه می‌کند. در ادامه کلیات سیگنال، دوباره به اجزا دیگری شکسته می‌شود. به عبارت دیگر، ابتدا سیگنال به زیرباندهای فرکانس بالا و فرکانس پایین تجزیه می‌گردد. در هر سطح، کانال فرکانس پایین از سطح قبلی به ترتیب توسط فیلترهای بالاگذر و پایین‌گذر به زیرباندهایی مجاور با فرکانس بالا و پایین تجزیه می‌شود.

2-2- استخراج ویژگی

استخراج ویژگی داده به طرز چشمگیری باعث افزایش اعتمادپذیری و دقت سیستم‌های FDI مبتنی بر داده می‌شود. ویژگی‌های مؤثر داده دارای خواصی هستند از جمله آن که اندازه‌گیری آن‌ها آسان است؛ از نظر ریاضی قابل تعریف هستند؛ تعبیر فیزیکی دارند؛ فاصله‌ی میانگینشان بین کلاس‌های⁹ مختلف بزرگ بوده و تغییراتشان در یک کلاس، کوچک است؛ حساسیت آن‌ها نسبت به متغیرهای مزاحم قابل صرف نظر است و با دیگر ویژگی‌ها همبستگی ندارند [14]. ویژگی‌های حوزه‌ی زمان، فرکانس و موجک را می‌توان از سیگنال‌های زمانی استخراج کرد. تکنیک‌های آماری از جمله ابزارهای ممکن برای استخراج ویژگی‌های مؤثر یک سیگنال هستند. این ابزارها می‌توانند از مشخصه‌های آماری که در معادله‌های (4) تا (7) آمده، استفاده کنند.

• میانگین

¹ Shift

² Partitioning

³ Uncertainty principle

⁴ Heisenberg inequality

⁵ Multi-resolution

⁶ Discrete Wavelet Transform

⁷ Approximate

⁸ Detail

⁹ Classes

¹⁰ Standard deviation

¹¹ Feed forward

¹² Feedback

¹³ Mean Square Error

جمله قطر، ضخامت، طول، مواد سازنده و پروفایل خط لوله به مدل الگا داده شد. مشخصه‌های دینامیکی جریان خط لوله در حالت بدون نشتی شامل دبی عبوری و فشار خروجی به عنوان حالات اولیه‌ی مدل الگا مورد استفاده قرار گرفتند و سپس سناریوهای مختلف نشتی بر مدل خط لوله اعمال شد.

4- روش بررسی

الگوریتم پیشنهادی در تشخیص نشتی شامل چندین مرحله است. ابتدا داده‌ها در نرم‌افزار الگا ایجاد می‌شود. سپس داده‌های نشتی در حوزه‌ی زمان به حوزه‌ی موجک نگاشته می‌شود. در نهایت ویژگی‌های آماری از هر دو حوزه‌ی زمان و موجک استخراج شده و به عنوان دو بردار ورودی جداگانه به دو سیستم طبقه‌بندی MLPNN داده می‌شود.

4-1-گردآوری داده‌ها و سناریوهای نشتی

فشار ورودی و دبی خروجی خط لوله‌ی مدل‌سازی شده به مدت 36000 ثانیه (10 ساعت) پایش می‌شود. همان‌گونه که در شکل‌های 2 و 3 دیده می‌شود، حدود 19437 ثانیه (حدود 5 ساعت و 40 دقیقه) طول می‌کشد که سیال به پایان خط لوله برسد و 23283 ثانیه (حدود 6 ساعت و 50 دقیقه) نیز طول می‌کشد که کاملاً به شرایط پایدار برسد.

همان‌گونه که در جداول 1 و 2 دیده می‌شود، سناریوهای نشتی در زمان 28800 ثانیه (پایان ساعت هشتم) در محل‌ها و اندازه‌های مختلف اعمال می‌گردند.




Fig. 2 Outlet flow signal at leak-free condition ($1 \text{ ft}^3/\text{sec} = 0.028 \text{ m}^3/\text{sec}$)
شکل 2 سیگنال دبی خروجی در شرایط بدون نشتی




Fig. 3 Inlet Pressure signal at leak-free condition ($1 \text{ psi} = 6.89 \text{ kPa}$)
شکل 3 سیگنال فشار ورودی در شرایط بدون نشتی

جدول 1 مکان‌های مختلف نشتی

| مکان نشتی (کیلومتر) | برجسب مکان نشتی |
|---------------------|-----------------|
| 2, 4, 5, 6 | ابتدای خط لوله |
| 8, 10, 12 | وسط خط لوله |
| 14, 15, 16, 18 | انتهای خط لوله |

که در آن $y_{j,p}^H(w)$ نمایانگر خروجی زامین گره در لایه‌ی خروجی (H) است؛ p نشانگر الگوی ورودی است و $d_{j,p}$ خروجی مطلوب است. روش لوبنبرگ-مارکوارت¹ و گرادیان نزولی² برای کمینه کردن $E(w)$ با وزن‌های اولیه‌ی تصادفی مورد استفاده قرار می‌گیرند. معادلات کمینه‌سازی نسبی برای به‌روز-رسانی پی‌درپی وزن‌ها استفاده می‌شوند. هرگاه خطای $E(w)$ کوچک‌تر از یک مقدار از پیش تعیین شده گردد یا تکرارهای مجاز برای به‌روز رسانی به پایان برسد، مرحله‌ی آموزش متوقف می‌شود. در این حالت انتظار می‌رود که شبکه عصبی، روابط ورودی-خروجی را استنتاج کرده باشد. سپس ساختار ANN حاصل، با استفاده از بردار ورودی آزمون مورد آزمایش قرار می‌گیرد. مرحله‌ی آزمون بدین دلیل افزوده می‌شود که توانایی تعمیم‌دهی شبکه سنجیده شود [17].

4-2-ارزیابی عملکرد سیستم طبقه‌بندی

عملکرد سیستم طبقه‌بندی را می‌توان با ماتریس درهم‌ریختگی³ مورد ارزیابی قرار داد. تعداد سطرها و ستون‌های این ماتریس متناظر تعداد کلاس‌ها می‌باشد. هر سطر نمایانگر کلاس حقیقی الگوها است و هر ستون نشان‌دهنده‌ی کلاسی است که توسط سیستم طبقه‌بندی برای الگوی ورودی در نظر گرفته شده است. از این رو یک سیستم طبقه‌بندی کامل برای یک دسته داده‌ی مشخص باید منجر به یک ماتریس درهم‌ریختگی قطری شود. عملکرد کلی سیستم طبقه‌بندی را می‌توان توسط معیار CCR که مطابق معادله (11) تعریف می‌شود، ارزیابی نمود.

$$CCR(\%) = \frac{\text{جمع درایه‌های قطری ماتریس در هم ریختگی}}{\text{جمع تمامی درایه‌های ماتریس در هم ریختگی}} \times 100 \quad (11)$$

لذا یک سیستم طبقه‌بندی ایده‌آل دارای نرخ طبقه‌بندی صحیح 100% است.

3-خط لوله مورد مطالعه

خط لوله مورد مطالعه در کار حاضر بخشی از خط لوله‌ی نفتی گلخاری به بینک است. طول خط لوله 20 کیلومتر بوده و قطر آن 12 اینچ (30.48 سانتی‌متر) است. دبی ورودی به خط لوله $0.0567 \text{ m}^3/\text{sec}$ با فشار ورودی 450 psi (3.1026 MPa) است. فشار خروجی توسط یک کنترل‌کننده روی 200 psi (1.3789 MPa) ثابت شده است. پروفایل خط لوله در شکل 1 نشان داده شده است.

از آن‌جا که اندازه‌گیری داده‌های نشتی به ازای محل‌ها و اندازه‌های مختلف این نشتی‌ها برای خط لوله‌ی گلخاری-بینک ممکن نبود، این خط لوله در نرم‌افزار الگا مدل‌سازی گردید. مشخصه‌های مکانیکی خط لوله از




Fig. 1 First 20 kilometers of Golkhari to Binak pipeline profile
شکل 1 20 کیلومتر اول از پروفایل خط لوله گلخاری به بینک

¹ Levenberg-Marquardt

² Gradient descent

³ Confusion matrix

جدول 2 مکان‌های مختلف نشتی

| برچسب قطر نشتی | اندازه قطر نشتی (اینچ) |
|----------------|------------------------|
| قطر کوچک | 0.5, 1 |
| قطر متوسط | 1.5, 2 |
| قطر بزرگ | 2.5, 3 |

جدول 3 وضعیت‌های مختلف نشتی

| شماره کلاس | وضعیت نشتی در خط لوله |
|------------|----------------------------|
| کلاس 1 | بدون نشتی |
| کلاس 2 | قطر کوچک و ابتدای خط لوله |
| کلاس 3 | قطر کوچک و وسط خط لوله |
| کلاس 4 | قطر کوچک و انتهای خط لوله |
| کلاس 5 | قطر متوسط و ابتدای خط لوله |
| کلاس 6 | قطر متوسط و وسط خط لوله |
| کلاس 7 | قطر متوسط و انتهای خط لوله |
| کلاس 8 | قطر بزرگ و ابتدای خط لوله |
| کلاس 9 | قطر بزرگ و وسط خط لوله |
| کلاس 10 | قطر بزرگ و انتهای خط لوله |

شکل‌های 4 و 5 دبی خروجی و فشار ورودی را در محل‌های مختلف نشتی با اندازه‌ی 0.5 اینچ (1.27 سانتی‌متر) پیش از وقوع نشتی و پس از رسیدن به حالت مانا نشان می‌دهند. به عبارت دیگر این شکل‌ها، سیگنال‌های مذکور را در زمان 26000 تا 36000 ثانیه نشان می‌دهند.

داده‌های ایجاد شده در نرم‌افزار الگا برای عملیات‌های بعدی به نرم‌افزار متلب¹ برده می‌شود. همان‌گونه که در جدول 3 دیده می‌شود، داده‌های تولید شده در نرم‌افزار الگا به ده کلاس طبقه‌بندی شده‌اند.

داده‌های الگا بدون نویز هستند اما در شرایط واقعی نویزهایی همچون نویز اندازه‌گیری و نویزهای محیطی وجود دارند. از این رو نویزی با توزیع نرمال² و مشخصه سیگنال به نویز (SNR)³ 5% به داده‌ها اعمال می‌شود. سپس داده‌های نویزدار در حوزه‌ی زمان به منظور تحلیل ویژگی‌ها به حوزه‌ی موجک نگاشته می‌شود.

2-4- تحلیل ویژگی

همان‌گونه که در معادله‌های (4) تا (7) توضیح داده شد، در کار حاضر از

ویژگی‌های آماری استفاده می‌شود. این ویژگی‌ها از داده‌هایی در حوزه‌ی زمان و موجک بدست می‌آیند. توجه داشته باشید که مطابق جدول 3 در تمامی حالات، فشار ورودی و دبی خروجی به صورت همزمان اندازه‌گیری می‌شوند. ویژگی‌های مربوط به سناریوی k ام، Y^k ، به صورت معادله (12) خواهد بود.

$$(Y^k, X^k), X^k = (X_{F1}^k, X_{F2}^k, \dots, X_{Fn}^k, X_{P1}^k, X_{P2}^k, \dots, X_{Pn}^k) \quad (12)$$

که در آن X^k ویژگی‌های سناریوی متناظر می‌باشد و $X_{F1}^k, X_{F2}^k, \dots, X_{Fn}^k$ و ویژگی‌های آماری سیگنال دبی خروجی و $X_{P1}^k, X_{P2}^k, \dots, X_{Pn}^k$ ویژگی‌های آماری سیگنال فشار ورودی برای سناریوی مذکور می‌باشد.

3-4- سیستم طبقه‌بندی ANN

ویژگی‌های بدست آمده در بخش 2-4 به بازه‌ی [-1, +1] نرمالیزه شده و به سیستم طبقه‌بندی MLPNN داده می‌شود. این شبکه عصبی دارای دو لایه‌ی پنهان و یک لایه‌ی خروجی است که به ترتیب دارای 20، 15 و 10 نورون هستند. 2220 داده‌ی ورودی به ازای تمامی سناریوهای جدول 3 در نظر گرفته شده است. در لایه‌های پنهان و لایه‌ی خروجی به ترتیب از توابع فعال‌سازی تانژانت هایپربولیک⁴ و خطی استفاده شده است. 70% از کل داده‌ها به شکل تصادفی برای آموزش شبکه انتخاب شده است. جدول 4 معیارهای پایان مرحله‌ی آموزش را بیان می‌کند.

5- بحث و نتایج شبیه‌سازی

نویسندگان در مقاله قبلی خود، یک سیستم تشخیص نشتی را برای خط لوله‌ی گلخاری- بینک پیشنهاد کردند. سیستم مطرح شده در سناریوهای مختلف نشتی از سیگنال فشار ورودی استفاده می‌کرد. آن‌ها بیان کردند که با استفاده از سیستم طبقه‌بندی RBFNN و ویژگی‌های موجک می‌توان به عملکرد مطلوبی در تشخیص نشتی‌های متوسط و بزرگ با CCR حدود 85% دست یافت.

جدول 4 معیار توقف آموزش شبکه عصبی مصنوعی

| مقدار | معیار توقف |
|-------|----------------|
| 0.001 | مینیمم گرادیان |
| 0.01 | مینیمم خطا |
| 200 | تعداد تکرار |




Fig. 4 Outlet flow signals for different leak locations while leak size is 0.5 inch (1 inch = 2.54 cm; 1 ft³/sec = 0.028 m³/sec)

شکل 4 سیگنال دبی خروجی در شرایط نشتی با قطر 0.5 اینچ و مکان‌های متفاوت رخ دادن آن




Fig. 5 Inlet pressure signals for different leak locations while leak size is 0.5 inch (1 inch = 2.54 cm; 1 psi = 6.89 kPa)

شکل 5 سیگنال فشار ورودی در شرایط نشتی با قطر 0.5 اینچ و مکان‌های متفاوت رخ دادن آن

¹ Matlab

² Normal distribution

³ Signal to Noise Ratio

⁴ Hyperbolic tangent

پیشنهادی، یک MLPNN است که با ویژگی‌های آماری حاصل از حوزه‌های زمان و موجک کار می‌کند. به علاوه از دو حسگر فشار ورودی و دبی خروجی در تشکیل بردار ورودی استفاده شده است. مقایسه نتایج نشان می‌دهد که استخراج ویژگی‌های آماری از حوزه‌ی موجک، MLPNN را دقیق‌تر می‌سازد. شبیه‌سازی‌ها در حالت مذکور، CCR معادل 93.5% را گزارش می‌دهد.

7- تقدیر و تشکر

نویسندگان مقاله از حمایت شرکت خطوط لوله و مخابرات نفت ایران که سبب پیشبرد این پژوهش شد کمال تشکر و قدردانی را دارند.

8- مراجع

- [1] T. M. El-Shiekh, Leak detection methods in transmission pipelines, *Energy Sources, Part A: Recovery, Utilization, and Environmental Effects*, Vol. 32, No. 8, pp.715-726, 2010.
- [2] L. Boaz, S. Kaijage, R. Sinde, An overview of pipeline leak detection and location systems, *The Pan African Conference on Science, Computing and Telecommunications*, Arusha, Tanzania, July 14-18, 2014.
- [3] Y. Bai, Q. Bai, *Subsea pipeline integrity and risk management*, pp. 125-143, Boston: Gulf Professional Publishing, 2014.
- [4] A. Azimi, F. Khaliji, M. Shabani, Simultaneous estimation of flow rate and location of leakage in natural gas pipeline using Levenberg-Marquardt method, *Modares Mechanical Engineering*, Vol. 13, No. 4, pp.13-24, 2013. (in Persian فارسی)
- [5] P. Murvay, I. Silea, A survey on gas leak detection and localization techniques, *Journal of Loss Prevention in the Process Industries*, Vol. 25, No. 6, pp. 966-973, 2012.
- [6] L. Meng, L. Yuxing, W. Wuchang, F. Juntao, Experimental study on leak detection and location for gas pipeline based on acoustic method, *Journal of Loss Prevention in the Process Industries*, Vol. 25, No. 1, pp. 90-102, 2012.
- [7] Z. Yang, Z. Xiong, M. Shao, A new method of leak location for the natural gas pipeline based on wavelet analysis, *Energy*, Vol. 35, No. 9, pp. 3814-3820, 2010.
- [8] L. Sun, N. Chang, Integrated-signal-based leak location method for liquid pipelines, *Journal of Loss Prevention in the Process Industries*, Vol 32, No. 1, pp. 311-318, 2014.
- [9] M. B. Abdulla, R. Herzallah, Probabilistic multiple model neural network based leak detection system: Experimental study, *Journal of Loss Prevention in the Process Industries*, Vol. 36, No. 1, pp.30-38, 2015.
- [10] S. Valizadeh, B. Moshiri, K. Salahshoor, Multiphase pipeline leak detection based on fuzzy classification, *The Second Global Conference on Power Control and Optimization*, Bali, Indonesia, June 1-3, 2009.
- [11] S. Valizadeh, B. Moshiri, K. Salahshoor, Leak detection in transportation pipelines using feature extraction and KNN classification, *Pipelines Specialty Conference*, San Diego, California, United States, August 15-19, 2009.
- [12] M. Shahbazian, M. Zadkarami, K. Salahshoor, Pipeline leak diagnosis using wavelet feature extraction and radial basis function neural network, *The 5th International Conference on Emerging Trends in Energy Conservation*, Tehran, Iran, February 22-23, 2016.
- [13] J. C. Goswami, A. K. Chan, *Fundamentals of Wavelets: Theory, Algorithms, and Applications*, Second edition, pp. 207-273, Hoboken, New Jersey, USA: John Wiley & Sons, 2011.
- [14] A. R. Webb, *Statistical Pattern Recognition*, Second edition, pp. 305-361, Chichester, UK: John Wiley & Sons, 2002.
- [15] K. O. Afebu, A. J. Abbas, G. G. Nasr, A. Kadir, Integrated leak detection in gas pipelines using OLGA simulator and artificial neural networks, *International Petroleum Exhibition and Conference*, Abu Dhabi, UAE, November 9-12, 2015.
- [16] I. N. Ferraz, A. C. B. Garcia, F. C. Bernardini, Artificial neural networks ensemble used for pipeline leak detection systems, *The 7th International Pipeline Conference*, Alberta, Canada, September 29- October 3, 2008.
- [17] S. Mitra, T. Acharya, *Data Mining: Multimedia, Soft Computing, and Bioinformatics*, pp. 1-78, Hoboken, New Jersey, USA: John Wiley & Sons, 2003.

جدول 5 تاثیر حوزه‌های مختلف استخراج ویژگی در تشخیص نشتی

Table 5 The effect of different feature extraction domains on leak diagnosis

| حوزه استخراج ویژگی | درصد نرخ طبقه‌بندی صحیح |
|--------------------|-------------------------|
| زمان | 74.9249 |
| موجک | 93.5435 |

در مقاله‌ی حاضر از دو حسگر فشار ورودی و دبی خروجی در خط لوله‌ی گلخاری- بینک استفاده شده است. به علاوه ویژگی‌های آماری، معادله‌های (4) تا (7)، از هر دو حوزه‌ی زمان و موجک استخراج شده است. CCR مربوط به این دو سیستم FDI مبتنی بر ویژگی‌های آماری، مقایسه شده و دقت آن‌ها در جدول 5 اعلام شده است. هر دو سیستم FDI از سیستم طبقه‌بندی MLPNN استفاده می‌کنند و تنها تفاوت آن‌ها در این است که ویژگی‌های آماری از کدام حوزه (زمان یا موجک) استخراج شده باشند.

در حالتی که ویژگی‌های آماری از داده‌های حوزه‌ی زمان استخراج می‌شود، مقدار CCR برابر 75% خواهد بود. عناصر قطر اصلی ماتریس درهم-ریختگی احتمالی، که نمایانگر میزان دقت هر کلاس توسط سیستم طبقه‌بندی می‌باشد، حالت مذکور در جدول 6 نشان داده شده است.

در مرحله‌ی بعد، داده‌های نشتی با استفاده از موجک مادر هر¹ در سه سطح به حوزه‌ی موجک نگاشته می‌شوند. سپس ویژگی‌های آماری داده‌های حوزه‌ی موجک استخراج شده و به MLPNN تزریق خواهد شد. در این حالت میزان CCR به 93.5% می‌رسد. جدول 6 عناصر قطر اصلی ماتریس درهم-ریختگی احتمالی حالت مذکور را نمایش می‌دهد.

از آن‌جا که تبدیل موجک در هر سطح، سیگنال نویزدار را به سیگنال‌های جزئیات و کلیات تجزیه می‌کند، سیگنال‌های تقریبی در سطح سوم عاری از مشخصه‌های فرکانس بالا هستند. آن‌گونه که در جدول 6 دیده می‌شود، سیستم FDI مبتنی بر ویژگی‌های آماری حاصل از حوزه‌ی موجک، FAR بسیار کوچکی دارند.

6- جمع بندی

در مقاله‌ی حاضر، تشخیص نشتی خط لوله‌ها به عنوان واسطه اصلی انتقال هیدروکربن‌ها مورد بررسی قرار گرفت تا خطرات زیست محیطی و اقتصادی حاصل از نشتی این خط لوله‌ها کاهش یابد. با استفاده از سیستم تشخیص نشتی پیشنهادی، نه تنها وقوع نشتی، بلکه محل و میزان وخامت آن نیز می‌تواند با FAR بسیار اندکی تعیین شود. هسته‌ی اصلی سیستم FDI

جدول 6 عناصر قطر اصلی ماتریس‌های درهم‌ریختگی احتمالی

Table 6 Main diagonal elements of probability confusion matrices

| شماره کلاس | استخراج ویژگی از حوزه زمان | استخراج ویژگی از حوزه موجک |
|------------|----------------------------|----------------------------|
| کلاس 1 | 1 | 1 |
| کلاس 2 | 0.551 | 0.782 |
| کلاس 3 | 0.72 | 0.79 |
| کلاس 4 | 0.884 | 0.885 |
| کلاس 5 | 0.769 | 1 |
| کلاس 6 | 0.86 | 0.994 |
| کلاس 7 | 0.675 | 0.974 |
| کلاس 8 | 0.28 | 1 |
| کلاس 9 | 0.854 | 0.953 |
| کلاس 10 | 1 | 1 |

¹ Haar