

Implementation of Neural Networks for Prediction of Location and Orientation of Pipe Defects in Guided Wave Ultrasonic Testing

Siavash Tayebi, Amin Yaghootian*, Laleh Fatahi

Department of Mechanical Engineering, Shahid Chamran University of Ahvaz, Ahvaz, Iran

*a.yaghootian@scu.ac.ir

Abstract

In this research, a method based on the classification and prediction of the neural network to determine the location and orientation of cracks in pipes is presented. For this purpose, first, the finite element method is used to model wave propagation and crack modeling in different locations and orientations. In this regard, two types of longitudinal and torsional guided excitation waves have been used. The obtained signals are processed to calculate the appropriate characteristics. In the present study, reflection echoes were measured, and five features were extracted at six levels from discrete wavelet decomposition of raw signals. Selected properties of the signals are processed to limit the size of the neural network model without losing information. For this purpose, the firefly algorithm method was used and fed to an artificial neural network that predicts the location and orientation of the crack. In this study, conventional multilayer perceptron diffusion networks have been used. According to the obtained results, it is observed that the proposed method shows good accuracy in predicting the location and orientation of the crack, and the percentage of neural network errors is less than 7%.

Keywords: Nondestructive test, Wavelet Transform, Feature Extraction, Firefly Algorithm, Artificial Neural Network.

به کارگیری شبکه عصبی برای پیش‌بینی موقعیت و راستای عیوب لوله در آزمون فراصوتی با امواج هدایت‌شده

سیاوش طیبی، امین یاقوتیان*، لاله فتاحی

دانشکده مهندسی مکانیک، دانشگاه شهید چمران اهواز، ایران

*a.yaghootian@scu.ac.ir

چکیده

در این تحقیق، روشی بر اساس طبقه‌بندی و پیش‌بینی شبکه عصبی برای تشخیص موقعیت و راستای ترک در لوله‌ها ارائه شده است. به این منظور، ابتدا از روش اجزاء محدود برای مدل‌سازی انتشار موج و مدل‌سازی ترک در موقعیت و راستاهای مختلف استفاده شده است. در این راستا از دو نوع موج تحریک هدایت‌شده طولی و پیچشی بهره گرفته شده است. سیگنال‌های به‌دست آمده به منظور فیلتر کردن نویز، کاهش ابعاد داده و برای محاسبه ویژگی‌های مناسب، پردازش شده‌اند. در پژوهش حاضر، اندازه‌گیری پژواک‌های بازتابیده انجام شده و پنج ویژگی در شش سطح از تجزیه موجک گسسته سیگنال‌های خام استخراج شده است. ویژگی‌های انتخاب شده از سیگنال‌ها، پردازش شده تا اندازه مدل شبکه عصبی بدون از دست دادن اطلاعات، محدود شود. به همین منظور، از روش الگوریتم کرم شب‌تاب استفاده شده و به یک شبکه عصبی مصنوعی که موقعیت و راستای ترک را پیش‌بینی می‌کند، تغذیه شده است. در این مطالعه، از شبکه‌های مرسوم پس انتشار چند لایه پرسپترون استفاده شده است. با توجه به نتایج به‌دست آمده مشاهده می‌شود که روش ارائه شده دقت خوبی را در پیش‌بینی موقعیت و راستای ترک، نشان می‌دهد. همچنین درصد خطاهای شبکه عصبی به کار رفته کمتر از ۷٪ است.

کلمات کلیدی: آزمون‌های غیرمخرب، تبدیل موجک، استخراج ویژگی، الگوریتم کرم شب‌تاب، شبکه‌های عصبی مصنوعی.

۱- مقدمه

بازرسی لوله‌ها یکی از مسائل بسیار مهم در صنعت است. در صنایع مهمی از قبیل صنایع نفت و گاز و همچنین در فرآیند نورد لوله‌ها بوجود آمدن عیوب مختلف در ماده یا قطعه در حین فرآیند ساخت، امری اجتناب‌ناپذیر بوده و شرایط کاربری آتی قطعه به ماهیت و اندازه دقیق عیب بستگی خواهد داشت [۱]. از جمله‌ی مهمترین این عیوب، امکان ایجاد انواع ترک‌ها در موقعیت و با راستاهای مختلف در حین فرآیند ساخت لوله‌ها است.

از میان روش‌های مختلف برای بازرسی لوله‌ها، می‌توان از آزمون فراصوتی، که یکی از پرکاربردترین و کم هزینه‌ترین روش برای بازرسی عیوب سطحی و داخلی لوله‌ها است، نام برد. در این روش از انواع و مودهای مختلف امواج فراصوتی برای تشخیص عیب و ترک استفاده می‌شود. یکی از مهمترین راه‌های بازرسی لوله‌ها استفاده از امواج هدایت‌شده پیچشی و طولی است. این امواج که زیر

مجموعه‌ی امواج هدایت‌شده هستند، میرایی نسبتاً کمی داشته و در طول لوله انتشار می‌یابند. از این رو می‌توانند عیوب مختلف در لوله را تشخیص دهند. این امواج دارای مودهای مختلفی هستند. اولین مود از امواج پیچشی یعنی $T(0,1)$ در تمامی فرکانس‌ها و مود دوم از امواج طولی که با $L(0,2)$ بیان می‌شود، در محدوده وسیعی از فرکانس‌ها ناپاشنده^۱ هستند، یعنی سرعت این امواج به فرکانس آن‌ها وابسته نیست. این امواج را می‌توان از یک محل در لوله منتشر کرد و پس از انتشار اگر در لوله عیوب یا ناپیوستگی‌هایی وجود داشته باشد به آن‌ها برخورد کرده و بازتاب می‌شوند. امواج بازتاب شده که حاوی اطلاعاتی در مورد موقعیت و راستای عیب هستند، به گیرنده‌هایی که در جاهای مشخصی تعبیه شده‌اند می‌رسند.

هدف اصلی از بازرسی فراصوتی لوله‌ها، شناسایی مکان‌یابی و اندازه‌گیری عیوب است. در کنار این اهداف به

¹ Non Dispersive

شناسایی اولیه عیب را با استفاده از سیگنال‌های تحلیل رفته‌ی مصنوعی امواج لمب بدست آمده از دو نمونه ماده‌ی، آلومینیوم و پلیمر تقویت شده با الیاف شیشه بررسی کردند. ایشان از یک سیستم تشخیص نوآورانه (ND)^۳ که با سیگنال‌های اندازه‌گیری تجربی آموزش داده شده، استفاده کردند. ایشان با نتایج بدست آمده نشان دادند که سیستم ND طراحی شده برای سیگنال‌های ساده و پیچیده به درستی کار می‌کند. در سال ۲۰۱۶^۴ محجوب و همکاران [۷] بر روی انتخاب ویژگی‌ها با استفاده از الگوریتم انتخاب ویژگی متوالی رو به جلو جهت انجام یک نظارت بر سلامت ساختاری خطوط لوله با استفاده از انتشار امواج هدایت شده و بدست آوردن سیگنال‌های بازتابی از عیوبی مانند خوردگی پژوهش کردند. نتایج به دست آمده توسط ایشان نشان داد، تمام مراحل رشد عیب، حتی کوچکترین مرحله نیز با موفقیت شناسایی شده است. در سال ۲۰۱۷^۵ منگ و همکاران [۸] یک چهارچوب مبتنی بر یادگیری عمیق را برای طبقه بندی سیگنال‌های فراصوتی ناشی از نمونه‌های پلیمری تقویت شده با الیاف کربن^۴ با فضای خالی و لایه لایه پیشنهاد کردند. در الگوریتم شبکه‌های عصبی کانولوشن^۵ پیشنهادی آن‌ها برای یادگیری فشرده و موثر برای هر سیگنال، از ضرایب موجک استفاده شد. نتایج تجربی، عملکرد عالی الگوریتم پیشنهادی ایشان را در برابر طبقه بندی کلاسیک با ویژگی‌های تولید شده‌ی دستی را نشان داد. در سال ۲۰۱۷^۶ کرووز و همکاران [۹] روش‌های استخراج و انتخاب ویژگی با استفاده از تبدیلات فوریه، موجک و کسینوس گسسته در یک سیستم پشتیبان تصمیم‌گیرنده، براساس شبکه‌های عصبی را مورد مطالعه قرار دادند. داده‌ها در این کار از آزمایش فراصوتی در اتصالات جوش شده فولاد به دست آمد. ایشان از طریق روش پیشنهادی تنها با استفاده از ۲۰ ویژگی برای تغذیه طبقه‌بندی کننده، به جای استفاده از ۲۵۰۰ نقطه نمونه اصلی آ-اسکن، به یک راندمان تمیز بالا دست یافتند. در سال ۲۰۱۸^۷ منجورال و همکاران [۱۰] یک روش شناسایی ترک قدرتمند برای مخازن تحت فشار با استفاده از

طبقه‌بندی عیوب در اسرع وقت و با دقت هرچه بیشتر را نیز می‌توان افزود. با وجود مزایای استفاده از روش آزمون فراصوت، مواردی از قبیل سرعت بالای بازرسی، احتمال بالای درستی تشخیص و لزوم تعداد کم نتایج اشتباه در طبقه‌بندی عیب براساس سیگنال‌های فراصوتی، هنوز هم اغلب مورد سوال است. زیرا تجزیه و تحلیل و شناسایی انواع عیب منحصرأ به تجربه و دانش اپراتور بستگی دارد [۲].

طبقه‌بندی خودکار سیگنال در بسیاری از سیستم‌های مکانیکی از جمله آزمون غیر مخرب، به طور فزاینده‌ای مورد توجه قرار گرفته است. انگیزه استفاده از چنین سیستم‌هایی ناشی از نیاز به تفسیر دقیق حجم زیادی از داده‌های بازرسی و به حداقل رساندن خطاهای ناشی از عوامل انسانی است. سیستم‌های طبقه‌بندی خودکار سیگنال، توانایی تشخیص عیب و تفسیر سیگنال‌های فراصوتی را به طور مداوم و دقیق دارند. چنین سیستم‌هایی این مزیت را دارند که می‌توانند اندازه‌گیری کمی احتمال تشخیص عیب را ارائه دهند. تعدادی از الگوریتم‌های طبقه‌بندی نظارت شده و نظارت نشده مانند الگوریتم خوشه‌بندی کی-میانگین^۱، فازی سی-میانگین^۲ و اخیراً شبکه‌های عصبی برای طبقه‌بندی سیگنال‌ها پیشنهاد شده است [۳].

در سال ۲۰۱۳^۸ لیو و همکاران [۴] رویکردی را برای شناسایی و توصیف ترک‌های ساختاری ناشی از ردیف سوراخ‌های پرچ در صفحات فلزی نازک با استفاده از موج لمب، تبدیل موجک و شبکه‌های عصبی ارائه دادند. ایشان نشان دادند که این روش می‌تواند ترک‌ها را به طور موثر شناسایی کرده و مکان آن‌ها را در هر دو روش شبیه‌سازی و آزمایشگاهی شناسایی کند. در سال ۲۰۱۵^۹ پیروینچنزو و همکاران [۵] بازرسی لوله توسط امواج هدایت شده فراصوتی در یک استخراج ویژگی با استفاده از تبدیلات تجزیه موجک گسسته، هیلبرت و فوریه و چهار چوب طبقه‌بندی خودکار در یک شبکه‌ی عصبی مصنوعی را انجام دادند. روش ایشان عملکرد طبقه‌بندی خوب و مقاومت در برابر نویز و تغییر در برخی پارامترهای عملیاتی را نشان داد. در سال ۲۰۱۶^{۱۰} نازارکو و همکاران [۶]

³ Novelty Detection (ND)


⁴ Carbon Fiber Reinforced Polymer (CFRP)

⁵ Convolutional Neural Networks (CNNs)

¹ K-Mean Clustering Algorithm

² Fuzzy C-Means

طولی و پیچشی در لوله حاوی عیب ترک در راستاهای مختلف بدست می‌آیند. شکل ۱ تصویر شماتیک از لوله شبیه‌سازی شده و موقعیت عیوب و محل قرارگیری گیرنده‌ها را نشان می‌دهد. برای شبیه‌سازی از خصوصیات مکانیکی و هندسی ارائه شده در جدول ۱ استفاده شده است. همچنین طول لوله ۰/۸ متر در نظر گرفته شده است. تحریک موج برای موج هدایت شده پیچشی در سطح بیرونی ابتدای لوله به طول ۲۰ میلی‌متر و به وسیله نیروی محیطی و برای موج هدایت شده طولی نیرو بصورت متقارن در سمت چپ لوله و در راستای محور آن اعمال شده است.



شکل ۱- شماتیک لوله و عیب آن و محل قرارگیری گیرنده‌ها

جدول ۱- مشخصات هندسی و خواص الاستیک لوله

مقدار	واحد	نماد	خاصیت
۲۰۷	GPa	E	مدول یانگ
۰/۳	-	ν	ضریب پواسون
۷۸۰۰	($\frac{kg}{m^3}$)	ρ	چگالی
۸۰۰	mm	l	طول
۷۷/۹	mm	d_{in}	قطر داخلی
۵/۵	mm	h	ضخامت دیواره

برای شبیه‌سازی پالس تحریک از رابطه ۱ استفاده شده است [۱۲].

$$A(t) = \begin{cases} [1 - \cos(\frac{2\pi f}{N}t)] \cos(2\pi ft) & 0 < t < \frac{N}{f} \\ 0 & t > \frac{N}{f} \end{cases} \quad (1)$$

که در آن N تعداد سیکل‌های پالس اعمالی و برابر ۲ در نظر گرفته می‌شود. f فرکانس پالس تحریک است و t پهنای زمانی پالس را بیان می‌کند.

برای انتخاب مود و فرکانس مناسب انتشار امواج به شکل ۲ و ۳ که به ترتیب سرعت فاز و گروه لوله متناظر با مشخصات ذکر شده در جدول ۱ هستند، رجوع می‌شود

الگوریتم ژنتیک و یک شبکه عصبی عمیق^۱ در یک آزمایش انتشار موج آکوستیک را ارائه دادند. در سال ۲۰۱۸ منیر و همکاران [۱۱] از روش‌های هدایت داده برای آموزش شبکه عصبی استفاده کردند که طبقه‌بندی عیوب بدون هیچگونه استخراج ویژگی از سیگنال‌های فراصوتی، انجام شود.

در پژوهش حاضر، سیستم تشخیصی مبتنی بر شبکه‌های عصبی مصنوعی^۲، با هدف تشخیص موقعیت و راستای ترک ارائه شده است. در این سیستم به طور خاص، تشخیص عیب به عنوان یک فرآیند الگوی تشخیصی که در آن طبقه‌بندی و پیش‌بینی کننده یک شبکه عصبی است، مدل شده است. به طور کلاسیک، یک سیستم تشخیص الگو از سه مازول تشکیل شده است: گیرنده‌هایی که سیگنال‌های بازگشتی را دریافت می‌کنند. یک استخراج کننده ویژگی^۳ که هدف آن کاهش ابعاد داده‌های دریافتی به منظور فیلتر کردن نویز و محاسبه ویژگی‌ها یا خصوصیات قابل توجه است. سپس یک طبقه‌بندی و پیش‌بینی کننده‌ای که در مورد کلاسی که عیب متعلق به آن است، تصمیم می‌گیرد.

شبکه عصبی هوشمند نیازمند آموزش است. برای آموزش شبکه لازم است کتابخانه‌ای از سیگنال‌های دریافتی عیوب مختلف در آزمون فراصوتی فراهم شود. یک روش تهیه چنین سیگنال‌هایی، استفاده از نمونه‌های آزمایشگاهی است. از طرفی تهیه نمونه‌های آزمایشگاهی بسیار گران، پیچیده و زمان‌بر است. بنابراین، روش جایگزین، به دست آوردن سیگنال‌های مورد نیاز با استفاده از روش‌های عددی، از جمله روش اجزای محدود است. مدل‌سازی مناسب شرایط آزمایشگاهی با استفاده از روش اجزای محدود این امکان را ایجاد می‌کند که سیگنال‌هایی که تا حد ممکن به داده‌های واقعی نزدیک هستند فراهم شود.

۲- شبیه‌سازی اجزای محدود


در این پژوهش برای بدست آوردن نمونه‌هایی برای آموزش شبکه عصبی از روش اجزای محدود استفاده شده است. این سیگنال‌ها از شبیه‌سازی امواج هدایت شده

¹ Deep Neural Network (DNN)

² Artificial Neural Networks (ANN)

³ Feature Extractor


درجات آزادی در جهت‌های شعاع و محور لوله بر روی یک نقطه از انتهای لوله ثابت شده است. مطابق شکل ۱ دو گیرنده به ترتیب در فاصله‌های ۲۰۰ و ۶۰۰ میلیمتری از ابتدای لوله برای دریافت سیگنال بازگشتی از عیوب، در نظر گرفته شده است. برای شبکه‌بندی مدل از المان سه‌بعدی C3D8R استفاده شده و اندازه المان در هر دو مدلسازی انتشار امواج پیچشی و طولی نیز ۰/۰۴ (کمتر از یک بیستم طول موج) انتخاب شده است [۱۲]. نمونه‌ای از مش‌بندی لوله به همراه عیب در شکل ۴ نشان داده شده است.




شکل ۴- مش‌بندی لوله به همراه عیب مورب

بخش اول مطالعه‌ی عددی، مربوط به شبیه‌سازی لوله‌ای با ترک در موقعیت‌ها و راستاهای متفاوت در تمام طول لوله است. به این منظور، چندین مدل‌سازی با استفاده از نرم‌افزار آباکوس برای ترک‌های با هندسه‌ی یکسان، که ابعاد ترک در جدول ۲ آمده است، در موقعیت‌ها و راستای راستاهای مختلف انجام شده است. موقعیت و راستای ترک با حرکت در هر سانتی‌متر طول لوله تغییر کرده است. در ادامه امواج هدایت شده پیچشی و طولی در لوله برای هر ترک منتشر شده و سیگنال‌های بازگشتی از ترک‌ها به صورت اندازه‌ی جابجایی، در هر دو گیرنده‌ی تعبیه شده روی لوله ذخیره شده است. مجموع حالات در نظر گرفته شده برای ترک ۸۴ حالت مختلف می‌باشد که در نهایت مجموعه داده‌ها را توسط ۳۳۶ سیگنال تشکیل می‌دهد. محدود بودن تعداد شبیه‌سازی‌ها به دلیل لزوم زمان پردازش (CPU) زیاد برای مدل‌سازی در هر یک از شبیه‌سازی‌ها است.

[۱۲]. همان‌طور که در منحنی‌های پاشندگی^۱ شکل‌های ۲ و ۳ مشاهده می‌شود، موده‌های مختلفی از امواج هدایت شده قادر به پدیدار شدن در محیط انتشار می‌باشند که مود متقارن مرتبه اول پیچشی یعنی $T(0,1)$ در تمامی فرکانس‌ها و مود دوم طولی $L(0,2)$ در یک محدوده مشخص ناپاشنده هستند. شایان ذکر است که از مود اول طولی $L(0,1)$ نیز می‌توان استفاده کرد ولی با توجه به سرعت بالاتر مود دوم طولی نسبت به مود اول، $L(0,2)$ انتخاب شده است. فرکانس تحریک برای موج پیچشی ۳۰ کیلوهرتز و برای موج طولی ۶۰ کیلوهرتز است.



شکل ۲- نمودار پاشندگی سرعت فاز برحسب فرکانس لوله شبیه‌سازی شده



شکل ۳- نمودار پاشندگی سرعت گروه برحسب فرکانس لوله شبیه‌سازی شده

¹ Dispersion Curves

$$E_x = \sum_{n=-\infty}^{\infty} |x(n)|^2 \quad \text{۱. انرژی موج}$$

$$v = \left(\frac{1}{n-1}\right) \sum_{i=1}^n (m_i - m)^2 \quad \text{۲. واریانس ضرایب}$$

$$\text{۳. انحراف معیار استاندارد از ضرایب}$$

$$SD = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (m_i - m)^2}$$

$$WL = \sum_{n=1}^{N-1} |x_{n+1} - x_n| \quad \text{۴. طول شکل موج}$$

$$E = -\sum_{i=1}^n P(x_i) \log_b P(x_i) \quad \text{۵. آنتروپی}$$

در این تحقیق ۸۴ حالت مدل‌سازی انجام شد. در هر حالت از دو گیرنده سیگنال بازگشتی از عیوب دریافت و با در نظر گرفتن بررسی عیب توسط انتشار هر دو موج پیچشی و طولی در لوله، برای هر حالت ۴ سیگنال به دست آمد. با اعمال پیش پردازش و استخراج ویژگی بر روی سیگنال‌ها، به ازای هر سیگنال ۳۰ ویژگی حاصل شد. در نهایت برای هر حالت در نظر گرفته شده ۱۲۰ ویژگی استخراج و ماتریس با ابعاد ۸۴ × ۱۲۰ تشکیل شد. در ادامه عمل کاهش ویژگی‌های ورودی شبکه عصبی بر روی این ماتریس انجام شده و ماتریس حاصل برای آموزش یک شبکه عصبی چند لایه پرسپترون^۶ استفاده شده است.

۵- کاهش ویژگی‌ها

تعداد ویژگی‌های استخراجی، در مقایسه با تعداد محدود شبیه‌سازی‌های موجود بسیار زیاد است. بنابراین، روش‌های مختلف کاهش داده‌ها آزمایش شده است. بهترین نتایج با استفاده از روش الگوریتم کرم شب‌تاب بدست آمد. این الگوریتم از زندگی گروهی کرم‌های شب‌تاب الهام گرفته شده است. در این الگوریتم هر کرم شب‌تاب بیانگر جوابی از مسئله است. روش به‌کار رفته بر روی ضرایب تبدیل موجک گسسته اعمال می‌شود و طول بردار ویژگی‌های استخراجی به عنوان تابع ارزیابی برای الگوریتم در نظر گرفته شده‌اند. برای این کار ابتدا یک زیر مجموعه با ۷ ویژگی از بین ۱۲۰ ویژگی مجموعه داده‌ها انتخاب شده است. این انتخاب به صورت باینری می‌باشد.

¹ Energy Per Waveform

² Variance of coefficients

³ Standard deviation of coefficients

⁴ Waveform Length (WL)

⁵ Entropy

⁶ Multi-Layer Perceptron

جدول ۲- ابعاد ترک در مدل‌سازی‌ها

مشخصه هندسی ترک	اندازه (mm)
طول	۵۰
عرض	۱
عمق	۵/۵

۳- پیش پردازش سیگنال‌ها

در پژوهش حاضر وجود ترک در لوله باعث تغییر سیگنال‌های خروجی از سیستم می‌شود. از طرفی سیگنال‌های فراصوتی حاوی بسیاری از ویژگی‌های غیرثابت یا گذرا هستند. این ویژگی‌ها اغلب مهمترین قسمت سیگنال هستند و تجزیه و تحلیل فوری برای شناسایی ویژگی‌های ذکر شده مناسب نیست، زیرا فقط در حوزه فرکانس قابل پردازش است. تبدیل موجک بخصوص برای رفع این نواقص ایجاد شده است. تجزیه و تحلیل سیگنال با استفاده از تبدیل موجک سریعتر از تجزیه و تحلیل تبدیل فوری است. تبدیل موجک یکی از جدیدترین تکنیک‌ها برای پردازش سیگنال‌های غیر ثابت (گذرا) است که به طور همزمان در حوزه‌های زمان و فرکانس عمل می‌کند [۱۳]. در تحقیق حاضر، از روش پردازش سیگنال مبتنی بر تبدیل موجک گسسته به منظور افزایش حساسیت تشخیص و توصیف عیب برای پیش پردازش امواج منعکس شده از ترک‌های استفاده شده است. با استفاده از تبدیل موجک گسسته می‌توان ویژگی‌های قابل توجه را استخراج کرد و سیگنال را با تجزیه آن به اطلاعات دقیق، تحلیل کرد. در این پژوهش، هر سیگنال بازگشتی از عیب حاصل از شبیه‌سازی اجزای محدود با استفاده از روش تبدیل موجک گسسته و نوع موجک مادر سیملت ۸ (sym8) در ۶ سطح تجزیه شده است.

۴- استخراج ویژگی‌ها

روش پیش پردازش به‌کار رفته، مبتنی بر تجزیه و تحلیل در هر دو حوزه‌ی زمان و فرکانس بوده است. به منظور کاهش ابعاد سیگنال پردازش شده از هر سیگنال ۵ ویژگی در ۶ سطح استخراج شده است. در نهایت برای هر سیگنال ۳۰ ویژگی استخراج شده است. ویژگی‌های به‌کار رفته به شرح زیر است:

(یعنی تعداد وزن‌های اتصال) محدود شود. این امر می‌تواند با محدود کردن تعداد لایه‌های پنهان یا تعداد نورون‌های موجود در لایه‌های پنهان یا کاهش تعداد نورون‌های ورودی انجام شود [۱۴]. در این تحقیق، کاهش نورون‌های ورودی انجام شد.

همانطور که در بیشتر کاربردهای شبکه عصبی پرسپترون در پژوهش‌های مشابه مشاهده شده است، اندازه لایه پنهان باید به صورت اکتشافی مشخص شود [۱۴]. در پژوهش حاضر، یک شبکه پرسپترون با یک لایه پنهان انتخاب شده است. برای یافتن تعداد نورون‌های مناسب جهت رسیدن به نتیجه مطلوب به طور خاص روش رشد^۴ اتخاذ شده است. این امر شامل آموزش شبکه‌ای است که دارای تعداد کمی نورون و سپس ارزیابی عملکرد آن‌ها است. اگر چنین عملکردی رضایت‌بخش باشد، روش به پایان می‌رسد، در غیر این صورت یک شبکه جدید که دارای نورون پنهان‌تری است آموزش داده می‌شود و این کار تا زمانی که شبکه به عملکرد مطلوب برسد، ادامه می‌یابد. این روش آموزش، از بیش‌برازش که ناشی از تعداد بیش از حد درجه آزادی است اجتناب می‌کند. همچنین بیش‌برازش می‌تواند ناشی از بیش‌آموزش^۵ باشد [۱۴]. در طول مرحله آموزش، جمع خطای مربع ارزیابی شده روی مجموعه آزمون و آموزش، اطلاعاتی را در مورد بیش‌برازش به ما می‌دهد. با شروع خطا در مجموعه آزمون و آموزش، روند آموزش خاتمه می‌یابد (روش متوقف شدن زود هنگام^۶). داده‌ها به دو مجموعه تقسیم شد، ۹۰ درصد داده‌ها برای آموزش و ۱۰ درصد برای آزمون به کار رفته است. برای افزایش قدرت تفکیک مدل شبکه و به طور هم‌زمان محدود کردن تعداد نورون‌های ورودی، استخراج ویژگی‌ها و استراتژی‌های کاهش داده‌ها اتخاذ شده است. ساختار شبکه عصبی به تعداد ویژگی‌های ورودی یا به عبارتی به روش کاهش داده بستگی دارد. تعداد نورون‌های ورودی با روش انتخاب ویژگی‌ها تعیین می‌شود. تعداد نورون‌های خروجی توسط کدگذاری مقادیر پیش‌بینی مورد نظر طراح تعیین می‌شود، در حالی که باید تعداد نورون‌های پنهان به صورت تجربی مشخص شود.

به این شکل که یک مجموعه داده به صورت ۰ و ۱ انتخاب می‌شود. ۰ به معنی حذف ویژگی و ۱ به معنی انتخاب ویژگی می‌باشد. در ادامه عمل ارزیابی براساس میانگین و انحراف معیار داده‌های انتخاب‌شده صورت می‌گیرد. در نهایت، زیر مجموعه‌ای که دارای اختلاف بیشتری از مقدار میانگین است به عنوان داده‌های پرت در نظر گرفته و از تحلیل خارج می‌شوند. سرانجام داده‌ها پس از نرمال‌سازی^۱ کردن توسط رابطه ۲، به منظور مدل‌سازی به یک شبکه عصبی چند لایه پرسپترون داده می‌شود.

$$X_{norm} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (2)$$

که در آن X عددی است که قرار است نرمال شود و X_{max} و X_{min} به ترتیب کمترین و بیشترین عدد در مجموعه داده‌ی مورد نظر است.

۶- معماری شبکه عصبی به کار رفته

یافتن راه‌حل مناسب برای مساله آزمون‌های غیر مخرب از طریق روش‌های استاندارد و معمول به کار رفته دشوار است [۱۴]. از این رو استفاده از رویکردهای غیر متعارف، مانند شبکه‌های عصبی برای آزمون‌های غیر مخرب قابل توجه است. یکی از پرکاربردترین شبکه‌های عصبی طبقه‌بندی کننده، شبکه عصبی چند لایه‌ی پرسپترون است. یک شبکه عصبی پرسپترون توسط یک لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی از نورون‌های^۲ عصبی تشکیل شده است. نورون‌های هر لایه با تمام نورون‌های لایه قبلی مرتبط هستند. هر کدام از نورون‌های ورودی در یک وزن ضرب می‌شود. مقادیر وزن‌ها پارامترهای اختیاری یک فرآیند یادگیری است. آن‌ها با ارائه مجموعه نورون‌های (ویژگی‌های) ورودی به شبکه تعیین می‌شوند. در طی فرآیند یادگیری، خروجی شبکه و خروجی مورد نظر از طریق تابع خطا مقایسه می‌شوند. شبکه آموزش دیده برای ارزیابی عملکرد شبکه، به مجموعه‌ای از نمونه‌های جدید (مجموعه آزمون) اعمال می‌شود. می‌توان خاطرنشان کرد که اگر تعداد نمونه‌ها در مجموعه آموزش محدود باشد، همانطور که در مسئله حاضر وجود دارد، برای جلوگیری از بیش‌برازش^۳ شبکه، باید اندازه‌ی شبکه

⁴ Growing Method

⁵ Overtraining


⁶ Early Stopping

¹ Normalization


² Neurons

³ Overfitting

پیش‌بینی خوبی را ارائه می‌دهد. به طور خاص، درصد خطاهای شبکه برای پیش‌بینی موقعیت ترک با خطای میانگین از ۶/۹۲٪ و برای پیش‌بینی راستای ترک با میانگین خطای ۶/۵۵٪ است.



(الف)



(ب)

شکل ۶-الف) درصد خطای شبکه‌ی عصبی برای راستای عیب در ۸ مورد مجموعه آزمون ب) درصد خطای شبکه‌ی عصبی برای موقعیت عیب در ۸ مورد مجموعه آزمون

جدول ۳- مجموعه‌ی آزمون

شماره‌ی آزمون	۱	۲	۳	۴	۵	۶	۷	۸
موقعیت ترک (cm)	۵۰	۱۵	۲۶	۲۷	۶۲	۵۱	۵۹	۳۹
راستای زاویه (درجه)	۹۰	۱۲	۳۸	۲۵	۱۵۸	۱۴۳	۱۴۸	۷۴


در صورت به‌کاربردن روش الگوریتم کرم شب‌تاب از ساختار چند لایه پرسپترون زیر استفاده شده است:

• ۷ گره ورودی مربوط به ۷ مؤلفه‌ی اصلی انتخاب شده است.

• یک لایه پنهان با ۲۳ گره و تانزانت هایپربولیک (تانسیگ در نرم‌افزار متلب) به عنوان تابع فعال‌سازی انتخاب شده است.

• دو گره خروجی با تابع فعال‌سازی خطی، متناسب با موقعیت و راستای عیب کدگذاری شده است.

در شکل ۵ معماری شبکه پرسپترون به‌کار رفته در پژوهش حاضر، ارائه شده است.



شکل ۵- توپولوژی شبکه عصبی پس انتشار سه لایه پرسپترون

۷- بحث بر روی نتایج

۷-۱- نتایج پیش‌بینی شبکه

بعد از مرحله آموزش، عملکرد شبکه پرسپترون با یک مجموعه آزمون متشکل از ۸ مورد ترک که مطابق با مشخصات موقعیت و راستای ذکر شده در جدول ۳ است، آزمایش شد. استفاده از روش الگوریتم کرم شب‌تاب دقت پیش‌بینی خوبی را فراهم می‌کند. در شکل ۶-الف و ۶-ب به ترتیب درصد خطاها برای موقعیت و راستای ترک‌ها، در حالت نرمالیزه شده را نشان داده شده است. درصد خطاهای شبکه عصبی پرسپترون آموزش دیده برای پیش‌بینی موقعیت و راستای ترک همیشه کمتر از میانگین ۷٪ است. در هر دو مورد، عملکرد مدل‌های شبکه عصبی سه لایه‌ی پس انتشار پرسپترون برای تخمین موقعیت و راستای ترک بسیار دلگرم کننده است و دقت

بانک اطلاعاتی شامل داده سیگنال برای مجموعه آموزش، اعتبارسنجی و آزمون با استفاده از روش اجزاء محدود بدست آمد. سیگنال‌ها با تکنیک‌های تبدیل موجک گسسته و روش ضریب همبستگی پیرسون پردازش شدند تا داده‌های ورودی مناسب برای تغذیه شبکه عصبی سه لایه پس انتشار پرسپترون را بدست آید.

داده‌های مربوط به عیب از طریق انتشار امواج فراصوتی هدایت شده در مود اول پیچشی و مود دوم طولی بدست آمدند. این دو مود در محدوده فرکانس انتخابی ناپاشنده بوده و به همین دلیل برای بازرسی مناسب هستند.

درصد خطاهای شبکه عصبی پرسپترون آموزش دیده برای پیش‌بینی موقعیت و راستای ترک همیشه کمتر از ۷٪ است. در هر دو مورد، عملکرد مدل‌های شبکه عصبی سه لایه پس انتشار پرسپترون برای تخمین موقعیت و راستای ترک بسیار دلگرم کننده است و دقت پیش‌بینی خوبی را ارائه می‌دهد. به طور خاص، درصد خطاهای شبکه برای پیش‌بینی موقعیت ترک با خطای میانگین ۶٪/۹۲ و برای پیش‌بینی راستای ترک با میانگین خطای ۶٪/۵۵ است.

۹- تشکر و قدردانی

بدینوسیله از حمایت مالی معاونت پژوهش و فناوری دانشگاه شهید چمران اهواز در قالب پژوهانه (GN98/3/02/14909) در انجام این تحقیق تشکر و قدردانی می‌گردد.

۱۰- منابع

- [1] S. Wang, S. Huang, W. Zhao, and Z. Wei, "3D modeling of circumferential SH guided waves in pipeline for axial cracking detection in ILI tools," *Ultrasonics*, vol. 56, pp. 325–331, 2015.
- [2] M. J. S. Lowe, D. N. Alleyne, and P. Cawley, "10.1016_S0041-624X(97)00038-3-Defect-detection-in-pipes-using-guided-waves.pdf," vol. 36, pp. 147–154, 1998.
- [3] R. Polikar, L. Udpa, S. S. Udpa, and T. Taylor, "Frequency invariant classification of ultrasonic weld inspection signals," *IEEE Trans. Ultrason. Ferroelectr. Freq. Control*, vol. 45, no. 3, pp. 614–625, 1998.
- [4] S. Liu, C. Du, J. Mou, L. Martua, J. Zhang, and F. L. Lewis, "Diagnosis of structural cracks using wavelet transform and neural networks," *NDT E Int.*, vol. 54, pp. 9–18, 2013.
- [5] P. Rizzo, I. Bartoli, A. Marzani, and F. Lanza Di Scalea, "Defect classification in pipes by neural networks using multiple guided ultrasonic wave

۲-۷- اثر تغییر تعداد نورون‌ها بر عملکرد شبکه

در جدول ۴ بهترین عملکرد شبکه عصبی در ۵ حالت بهینه با تعداد نورون‌های مختلف در اجراهای زیادی با تعداد ویژگی ورودی به عدد ۷ برای شبکه‌ی عصبی سه لایه‌ی پرسپترون، آمده است. بنابراین با توجه به نتایج حاصل شده، مشاهده می‌شود که در میان این ۵ حالت که شبکه عملکرد خوبی را نشان می‌دهد، بهترین عملکرد با تعداد نورون لایه پنهان به عدد ۲۳ حاصل شد، که عملکرد پیش‌بینی و تخمین خوبی را نشان می‌دهد.

جدول ۴- انتخاب معماری بهینه چند لایه پرسپترون برای

بهترین عملکرد شبکه سه لایه

پارامترها	۱	۲	۳	۴	۵
تعداد ویژگی‌ها	۷	۷	۷	۷	۷
تابع فعالسازی لایه پنهان	tansig	tansig	tansig	tansig	tansig
تابع فعالسازی لایه خروجی	linear	linear	linear	linear	linear
الگوریتم آموزش	trainbr	trainbr	trainbr	trainbr	trainbr
تعداد نورون‌های لایه پنهان	۸	۱۵	۱۸	۲۳	۲۸
عملکرد آزمون‌های موقعیت	۰/۰۱۵	۰/۰۱۸	۰/۰۱	۰/۰۰۵۵	۰/۰۰۸۸
عملکرد آزمون‌های راستا	۰/۰۱۵	۰/۰۱۳	۰/۰۱۲	۰/۰۱	۰/۰۱۷
ساختار شبکه عصبی پرسپترون	۲-۸-۷	۲-۱۵-۷	۲-۱۸-۷	۲-۲۳-۷	۲-۲۵-۷

۸- نتیجه‌گیری

در این پژوهش، یک سیستم تشخیص موقعیت و راستای عیب، مبتنی بر شبکه‌های عصبی برای آزمون‌های غیرمخرب با استفاده از امواج فراصوتی در لوله‌ها اجرا شد.

- [10] M. Islam, M. Sohaib, J. Kim, and J. M. Kim, "Crack classification of a pressure vessel using feature selection and deep learning methods," *Sensors (Switzerland)*, vol. 18, no. 12, 2018.
- [11] N. Munir, H. J. Kim, S. J. Song, and S. S. Kang, "Investigation of deep neural network with drop out for ultrasonic flaw classification in weldments," *J. Mech. Sci. Technol.*, vol. 32, no. 7, pp. 3073–3080, 2018.
- [12] A. Mokhtarizadeh, A. Yaghootian, A. Valipour, "Detection of dimensions of axisymmetric surface defects located on the pipe using the first order symmetric torsional guided waves. NDT Technology, 2(7), 51-59, 2021.
- [13] G. Acciani, G. Brunetti, G. Fornarelli, and A. Giaquinto, "Angular and axial evaluation of superficial defects on non-accessible pipes by wavelet transform and neural network-based classification," *Ultrasonics*, vol. 50, no. 1, pp. 13–25, 2010.
- [14] B. Cannas, F. Cau, A. Fanni, A. Montisci, P. Testoni, and M. Usai, "Neural NDT by means of reflected longitudinal and torsional waves modes in long and inaccessible pipes," *WSEAS Trans. Syst.*, vol. 4, no. 11, pp. 2129–2137, 2005.
- features extracted after wavelet processing," *J. Press. Vessel Technol. Trans. ASME*, vol. 127, no. 3, pp. 294–303, 2005.
- [6] P. Nazarko and L. Ziemianski, "Damage detection in aluminum and composite elements using neural networks for Lamb waves signal processing," *Eng. Fail. Anal.*, vol. 69, pp. 97–107, 2016.
- [7] M. El Mountassir, S. Yaacoubi, J. Ragot, G. Mourot, and D. Maquin, "Feature selection techniques for identifying the most relevant damage indices in SHM using guided waves," *8th Eur. Work. Struct. Heal. Monit. EWSHM 2016*, vol. 2, no. September, pp. 1228–1235, 2016.
- [8] M. Meng, Y. J. Chua, E. Wouterson, and C. P. K. Ong, "Ultrasonic signal classification and imaging system for composite materials via deep convolutional neural networks," *Neurocomputing*, vol. 257, no. 2017, pp. 128–135, 2017.
- [9] F. C. Cruz, E. F. Simas Filho, M. C. S. Albuquerque, I. C. Silva, C. T. T. Farias, and L. L. Gouvêa, "Efficient feature selection for neural network based detection of flaws in steel welded joints using ultrasound testing," *Ultrasonics*, vol. 73, pp. 1–8, 2017.