



# Optimization of performance of artificial neural network for predicting the tensile properties of friction stir welded Al-5083

M. Mosallae\*, A.H. Morshedy

Departemnt of Mining and Metallurgy, Faculty of Engineering, Yazd University, Iran.

Received 20 September 2023 ; Accepted 21 November 2023

## Abstract

In this research, the optimization of the artificial neural network (ANN) capability for predecting the tensile strength and elongation of friction stir welded Al-5083 (FS-welded Al-5083) was carried out. The effective parameters of ANN, such as the number of layers, number of neurons in hidden layers, transfer function between layers, the learning algorithm and etc. were investigated and the efficient neural network was determined to predict the tensile properties of FS-welded Al-5083. The investigations revealed that the perceptron neural network with two hidden layers and 17 neurons numbers, Lunberg-Marquardt training algorithm and Logsig transfer function for the intermediate layers and Tansig transformation function for the output layer is the most optimized neural network for the prediction. The optimized network has an optimal structure based on the minimum value of the mean square error of 0.05, the maximum total correlation coefficient of 0.93 and the line regression with an angle of 45 degrees between the actual and estimated values. Therefore, this network has a good performance for training, generalizing and estimating of tensile strength and elongation of FS-welded Al-5083.

**Keywords:** Al-5083, FSW, Strength, Rotation speed, Traverse speed, artificial neural network.

Corresponding Author: [mosal@yazd.ac.ir](mailto:mosal@yazd.ac.ir)



## بهینه نمودن کارایی شبکه عصبی مصنوعی برای پیش‌بینی خواص کششی Al-5083 اتصال داده شده توسط فرایند FSW

مسعود مصلاهی<sup>ID\*</sup>، امین حسین مرشدی<sup>ID</sup>

دانشکده مهندسی معدن و متالورژی، دانشگاه یزد، ایران.

دریافت مقاله: 1402/06/29؛ پذیرش مقاله: 1402/08/30

### چکیده

در این تحقیق، بهینه‌سازی قابلیت شبکه عصبی مصنوعی (ANN) به منظور پیش‌بینی استحکام کششی و ازدیاد طول نسبی اتصالات ایجاد شده بر Al-5083 توسط فرایند جوشکاری همزنی اصطکاکی (FSW) مورد بررسی قرار گرفت. بدین منظور با تغییر پارامترهای موثر بر کارایی ANN از قبیل تعداد لایه‌ها و تعداد نوروهای لایه‌های مخفی، نوع تابع انتقال بین لایه‌ها، الگوریتم یادگیری و غیره، شبکه عصبی کارآمد برای پیش‌بینی خواص کششی اتصالات FSWed-Al-5083 تعیین گردید. بررسی‌های انجام شده آشکار نمود که شبکه عصبی پرسپترون با دو لایه پنهان و تعداد 17 نرون، الگوریتم آموزش لوبز-مارکوارت و تابع انتقال Logsig برای لایه‌های میانی و تابع تبدیل Tansig برای لایه خروجی، کارآمدترین شبکه عصبی برای پیش‌بینی مورد نظر است. شبکه مذکور دارای ساختار بهینه براساس کمینه مقدار خطای میانگین مربعات 0/05، بیشینه ضریب همبستگی کل 0/93 و رگرسیون خط با زاویه 45 درجه بین مقادیر واقعی و پیش‌بینی شده می‌باشد. در نتیجه این شبکه از کارایی مطلوبی برای آموزش، تعمیم و برآورد استحکام کششی و ازدیاد طول نسبی Al-5083 اتصال FSW داده شده برخوردار است.

**کلمات کلیدی:** Al-5083، FSW، استحکام، سرعت چرخش، سرعت پیش‌روی، شبکه عصبی مصنوعی.

\* نویسنده مسئول، پست الکترونیکی: mosal@yazd.ac.ir

### 1- مقدمه

به عنوان یک آلیاژ سازه‌ای بی‌نظیر برای ساخت سازه‌های دریایی مانند ساخت کشتی و زیردریایی مطرح نموده است [3و4].

جوشکاری همزنی اصطکاکی، در سال 1991 توسط موسسه جوشکاری انگلستان (TWI) ابداع شد. فرایند FSW یک فرایند اتصال حالت جامد که ترکیبی از دو فرایند اکستروژن و فورج می‌باشد. عدم تشکیل فاز مذاب حین اتصال‌دهی FSW موجب توجه گسترده‌ای به این فرایند برای اتصال‌دهی فلزات مختلف به‌خصوص آلیاژهای آلومینیوم شده است [5-9]. لازم به ذکر است برخی از آلیاژهای آلومینیوم بسیار به ترک داغ و تخلخل

آلیاژهای آلومینیوم به دلیل خصوصیات از قبیل استحکام ویژه بالا، قابلیت شکل‌پذیری عالی، رسانایی مطلوب، مقاومت به خوردگی مناسب، قابلیت بازیابی و غیره در صنایع مختلفی از قبیل بسته‌بندی، بدنه وسایل نقلیه زمینی، هوایی، ریلی و دریایی، تولید انرژی‌های خورشیدی/بادی و غیره مورد استفاده روزافزون واقع می‌شوند [1و2].

آلیاژ Al-5083 یک آلیاژ کارسخت شونده پایه Al-Mg می‌باشد که خصوصیات منحصربه‌فرد این آلیاژ از قبیل شکل‌پذیری بالا همراه با مقاومت به خوردگی عالی در محیط‌های دریایی، آن را

یادگیری لونیگ-مارکوارت کارایی بالاتری نسبت به ANN با الگوریتم یادگیری گرادیان نزولی در پیش‌بینی خواص کششی نمونه‌های اتصال داده شده برخوردار است.

N. P. Senapati [23] و همکاران تاثیر پارامترهای فرایند FSW از قبیل سرعت چرخش، سرعت پیش‌روی و میزان فرورفتگی ابزار در سطح اتصال، را بر اندازه دانه، استحکام کششی و ازدیاد طول نسبی نمونه‌های اتصال داده شده از AI-1100 را توسط شبکه‌های عصبی شبیه‌سازی نمودند. آن‌ها گزارش نمودند که شبکه عصبی با الگوریتم یادگیری لونیگ-مارکوارت از دقت و سرعت بالاتری برای پیش‌بینی خصوصیات اتصال ایجاد شده نسبت به شبکه‌های عصبی رایج برخوردار است. L. Fratini و همکاران [24] از شبکه‌های عصبی برای پیش‌بینی اندازه دانه در منطقه اغتشاشی آلیاژ AA-2139-T8 استفاده نمودند. مروری بر پیشینه تحقیقاتی انجام شده در زمینه فرایند FSW نشان داد که تا کنون تحقیق جامعی در خصوص بهینه نمودن کارایی شبکه عصبی برای ایجاد ارتباط بین خواص کششی اتصال ایجاد شده توسط فرایند FSW و پارامترهای اصلی فرایند اتصال‌دهی (سرعت پیش‌روی و چرخش ابزار) در آلیاژ AI5083 انجام نشده است بنابراین در پژوهش حاضر با تغییر پارامترها و توابع شبکه عصبی سعی شده تا کارآمدترین شبکه برای پیش‌بینی و تخمین خواص کششی AI-5083 اتصال FSW شده طراحی شود.

## 2- مواد و روش پژوهش

### 2-1- جوشکاری اصطکاکی همزنی نمونه‌ها

در این پژوهش، از صفحات AI-5083 با ضخامت 5 mm به‌عنوان فلزپایه استفاده شد. نمونه‌های مورد نظر برای جوشکاری در ابعاد 80×60 mm توسط وایرکات از صفحات دریافتی برش زده شد. ترکیب شیمیایی فلزپایه توسط روش اسپکتروسکوپی نشری تعیین و در مقایسه با ترکیب شیمیایی اسمی این آلیاژ [25] در جدول (1) ارائه شده است.

سطوح مورد نظر برای اتصال‌دهی تا سنباده 600 سنگ و پس از چربی‌زدایی در حمام آلتراسونیک حاوی استون، با استفاده از دستگاه فرز سنگین و ابزار چرخنده از جنس فولاد ابزار گرم‌کار

حین جوشکاری ذوبی حساس می‌باشند [10]. از قابلیت‌های کاربردی فرایند FSW می‌توان به کنترل میزان حرارت ورودی و تغییر فرم ایجاد شده در موضع اتصال توسط کنترل پارامترهای اصلی فرایند مثل سرعت چرخش و پیش‌روی ابزار، نیروهای اعمالی بر ابزار، شکل و ابعاد پین اشاره نمود [11-13].

چالش اصلی فرایند FSW، انتخاب صحیح پارامترهای جوشکاری برای رسیدن به یک اتصال مطلوب می‌باشد. روش‌های سنتی انتخاب پارامترهای جوشکاری برای تولید اتصال جوشکاری عمدتاً زمان‌بر و هزینه‌بر می‌باشد [14-16]. پارامترهای جوشکاری را می‌توان با تعداد محدودی آزمایش تجربی و با استفاده از روش‌هایی از قبیل تحلیل رگرسیون و روش سطح پاسخ و با استفاده از نرم‌افزارهای محاسباتی مانند سیستم‌های مبتنی بر منطق فازی و غیره، با دقت بالایی بهینه نمود. شبکه عصبی مصنوعی یک تکنیک قابل اطمینان برای ایجاد ارتباط بین پارامترهای یک فرایند و یادگیری تاثیر هر پارامتر بر نتایج حاصله و در نتیجه پیش‌بینی پاسخ‌های فرایند براساس آموزش شبکه با داده‌های تجربی است [17]. در دهه‌های اخیر، شبکه‌های عصبی مصنوعی به‌عنوان شاخه‌ای از داده‌کاوی در رایانش نرم و مدل‌سازی عددی در زمینه‌های مختلف علوم مهندسی و کاربردی توسعه و استفاده شده است. شبکه عصبی مصنوعی به‌عنوان یک رویکرد مبتنی بر الگوریتم یادگیری، از ساختار عصبی مغز انسان الهام گرفته است. فرایند آموزش شبکه‌های عصبی را می‌توان با تغییر مقادیر عوامل وزنی در میان نورون‌ها (به‌عنوان واحد اساسی شبکه) براساس داده‌های آزمایشی یا پاسخ به بازخوردهای خود نورون، بهینه کرد و قابلیت تعمیم‌یافتگی شبکه را ارتقا داد [18].

پژوهش‌های مختلفی در علم مهندسی مواد در زمینه پیش‌بینی خصوصیات فیزیکی و مکانیکی در زمینه‌های مختلف جوشکاری، ریخته‌گری و غیره انجام شده است [19-24]. برای مثال Y.K. Yousif و همکاران [22] کارایی ANN برای ایجاد ارتباط بین خواص مکانیکی صفحات آلومینیومی اتصال FSW داده شده و پارامترهای FSW از شبکه‌های عصبی استفاده نمودند. آن‌ها گزارش نمودند که شبکه عصبی با الگوریتم

جدول 1- ترکیب شیمیایی اسمی و اندازه گیری شده Al5083 (%wt).

Others Total	Others Each	Cu	Ti	Zn	Si	Mn	Cr	Fe	Mn	Mg	Al	ترکیب شیمیایی
Max. ۰/۱۵	Max. ۰/۰۵	Max. ۰/۱	Max. ۰/۱۵	Max. ۰/۲۵	Max. ۰/۰۴	۰/۴ ۰/۱	۰/۰۵ ۰/۲۵	Max. ۰/۴	۰/۴ ۱/۰	۴/۰ ۴/۹	Bal.	اسمی
۰/۰۴	۰/۰۱	۰/۰۵	۰/۰۱	۰/۱۲	۰/۱۳	۰/۴۵	۰/۲۱	۰/۲۳	۰/۵۵	۴/۴۰	Bal.	اندازه گیری


جدول 2- ویژگی های آماری متغیرهای ورودی و خروجی شبکه عصبی.

متغیر	میانگین	انحراف استاندارد	کمینه	چارک اول	میانه	چارک سوم	بیشینه	چولگی*	کشیدگی**
سرعت چرخش	۱۰۴۸/۳	۵۱۱/۶	۴۵	۵۸۰	۹۰۰	۱۴۰۰	۲۵۰۰	۰/۸۲	۰/۰۶
سرعت پیشروی	۱۱۱/۴	۹۶/۴	۵	۳۵	۸۶	۱۵۰	۳۴۲	۱/۲۶	۰/۶۳
استحکام کششی	۲۴۶	۶۹/۸	۱۰۹	۱۷۹/۵	۲۷۰	۳۰۱	۳۳۴	-۰/۵۸	-۰/۹۹
ازدیاد طول	۱۳/۶۱	۹/۰۴	۱/۶	۲/۹۵	۱۵	۲۲/۲۵	۲۷	-۰/۰۵	-۱/۵۷

\* شاخص آماری از میزان تقارن تابع توزیع می باشد که بیانگر میزان انحراف از حالت نرمال است.

\*\* شاخص آماری از توصیف کننده میزان قله ای بودن یا مسطح بودن یک تابع توزیع احتمال است.

کشش در مورد هر نمونه، سه بار تکرار و میانگین نتایج برای آن نمونه گزارش شد.



شکل 1- شماتیک الف- موقعیت برش نمونه های کشش.

ب- ابعاد نمونه های کشش مورد استفاده در پژوهش حاضر.

H13 در وضعیت تخت اتصال دهی شدند. هندسه پین به صورت مخروطی رزوه دار، قطر شانه و پین به ترتیب 15 mm و 5 mm و ارتفاع ابزار 4/8 mm انتخاب شد.

## 2-2- شبکه عصبی و داده های مورد استفاده

در این پژوهش از شبکه عصبی پرسپترون چند لایه و تعداد 41 داده برای آموزش و ارزیابی کارایی شبکه عصبی استفاده شد. لازم به ذکر است این داده ها عمدتاً توسط آزمون های آزمایشگاهی به دست آورده شد و مابقی داده ها از مقالات موجود برداشت شد. مهمترین پارامترهای موثر در فرایند FSW یعنی سرعت چرخش (W) و سرعت پیشروی (V) ابزار به عنوان ورودی های شبکه عصبی و متغیرهای پاسخ (خروجی شبکه) استحکام کششی ( $S_{UTS}$ ) و ازدیاد طول نسبی (%L) نمونه های جوشکاری شده انتخاب شد. شاخص های آماری در خصوص ویژگی های داده های استفاده شده برای آموزش، ارزیابی و تحلیل نتایج شبکه عصبی در جدول (2) ارائه شده است.

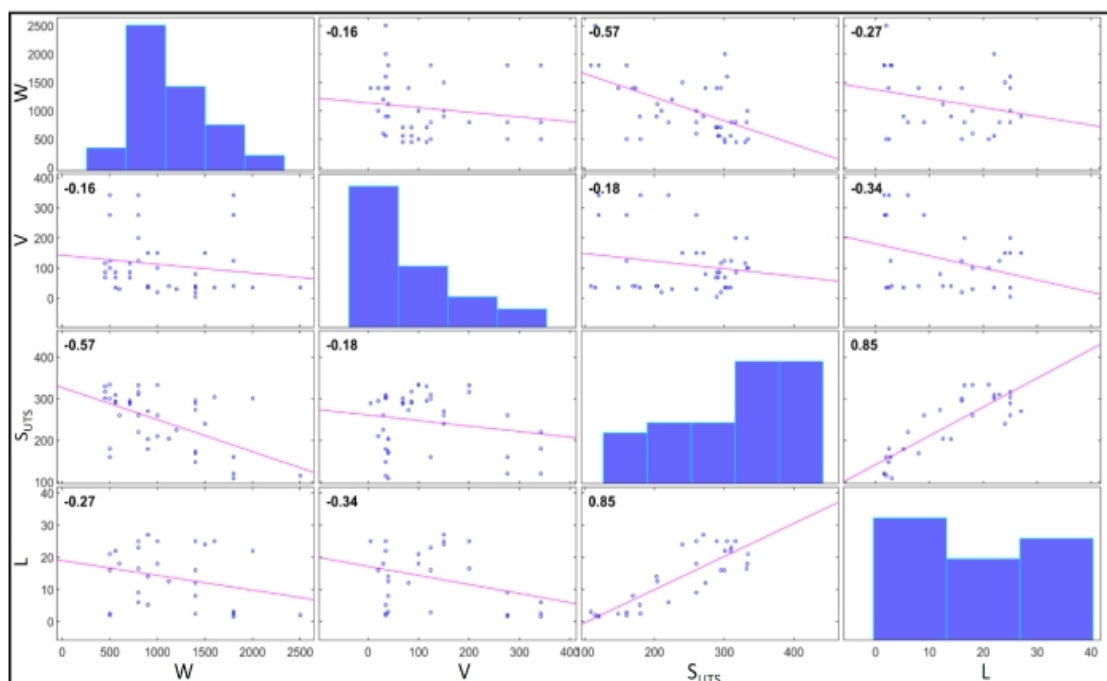
## 3- نتایج و بحث

### 3-1- تحلیل داده ها و آموزش شبکه عصبی

یکی از مراحل کلیدی در مطالعات عددی، تحلیل داده ها توسط نمودارهای آماری تک و چند متغیره است. در شکل (2)، نتایج حاصل از این بررسی آماری به صورت نمودار ماتریسی ارائه شده است. در این نمودار قطر اصلی، هیستوگرام (فراوانی نما) و دیگر قسمت ها، نمودار متقاطع دو به دو متغیرها و ضریب همبستگی آنها می باشد.


### 3-2- ارزیابی مکانیکی نمونه های اتصال داده شده

نمونه های آزمون کشش مطابق شکل (1) از مقطع عرضی موضع اتصال برش و براساس استاندارد ASTM E8 [26] توسط دستگاه کشش Instron 5586 و نرخ کرنش 3 mm/min در دمای اتاق کشیده شدند. برای اطمینان از نتایج حاصله، آزمون



شکل 2- نمودار ماتریسی براساس هیستوگرام و نمودار مقاطع متغیرهای مورد مطالعه.

خروجی، بیشترین کاربرد را دارد (شکل 4).



شکل 3- مدل درونیابی متغیرهای خروجی الف - SUTS

ب -  $L$  برحسب متغیرهای ورودی  $W$  و  $V$ .

به عبارت دیگر در این شبکه می توان از توابع مختلف انتقال براساس توزیع متغیرها استفاده نمود. دو ویژگی مهم شبکه عصبی پرسپترون چندلایه عبارت است از [18]:


الف - اجزاء پردازنده غیرخطی (مانند توابع لگاریتمی، تانژانت - هایپربولیک و غیره)

همانگونه که از قسمت های مختلف این شکل برداشت می شود، ضریب همبستگی متغیرها، در اغلب موارد معکوس و ضعیف می باشد که دلالت بر عدم تاثیر متقابل محسوس بین متغیرها است. تنها ارتباط  $SUTS$  و  $L$  دارای همبستگی قوی - مستقیم (0/85) و همبستگی بین  $W$  و  $SUTS$  متوسط - معکوس (-0/57) است. بنابراین می توان برداشت نمود که روش های رگرسیون های معمولی برای پیش بینی خواص کششی نمونه های AI-5083 اتصال داده شده توسط FSW، چندان کارآمد نمی باشد و ضرورت استفاده از شبکه عصبی برای پیش بینی مذکور را آشکار می نماید. در شکل (3)، رفتار متغیرهای پاسخ  $SUTS$  و  $L$  برحسب کمیت های ورودی ( $W$  و  $V$ ) به صورت یک مدل درونیابی سه بعدی نشان داده شده است. همانگونه که در شکل (3-الف) دیده می شود بیشینه  $SUTS$  در مناطقی با  $W$  و  $V$  کم تا متوسط، می باشد. مدل درونیابی  $L$  برحسب  $W$  و  $V$ ، نمایانگر مقادیر بیشینه  $L$  در مقادیر متوسط  $W$  است (شکل 3-ب).

### 2-3- شبکه عصبی و الگوریتم یادگیری آن

به طور کلی، در مورد تشخیص الگوهای ایستا، شبکه پرسپترون چندلایه متشکل از لایه ورودی، لایه (های) پنهان یا میانی و لایه

آموزش (یادگیری) شبکه عصبی، چهار الگوریتم لونبرگ-مارکوارت، گرادیان نزولی، گرادیان مزدوج و شبه نیوتنی بررسی شد [27 و 28]. همچنین به منظور انتخاب بهترین ساختار شبکه عصبی پرسپترون چندلایه جهت پیش بینی استحکام کششی و ازدیاد طول نسبی نمونه های اتصال داده شده، تحلیل حساسیت روی شبکه های عصبی مختلف (تعداد لایه های میانی مختلف، توابع مختلف و غیره) انجام شد. توضیح آنکه عملکرد شبکه های عصبی متعدد شامل یک یا دو لایه میانی، تعداد نورون ها مختلف در هر لایه میانی، توابع انتقال و الگوریتم آموزش متفاوت بررسی شد. کارایی شبکه های مذکور براساس، خروجی های به دست آمده برای داده های آموزش، اعتبار سنجی و آزمون مورد ارزیابی واقع شد.




شکل 5- نمودار کارایی شاخص میانگین مربعات خطا در حالت شبکه عصبی با یک لایه میانی.

#### الف- شبکه های عصبی طراحی شده با یک لایه میانی

شبکه های عصبی مختلف با یک لایه میانی، تعداد نورون های متغیر 2 تا 20 عدد و توابع مختلف آموزش و انتقال طراحی و اجرا شد. در نهایت از بین تعداد 304 شبکه ممکن، براساس کمینه تابع خطا و بهترین انطباق رگرسیون، شبکه بهینه با تعداد 4 نورون، الگوریتم آموزش لونبرگ-مارکوارت و تابع انتقال Tansig تعیین شد. لازم به ذکر است که در این مقاله، معیار میانگین مربعات خطا (MSE) به عنوان شاخص ارزیابی

ب- ارتباط های داخلی متعدد بین واحدهای مختلف شبکه.



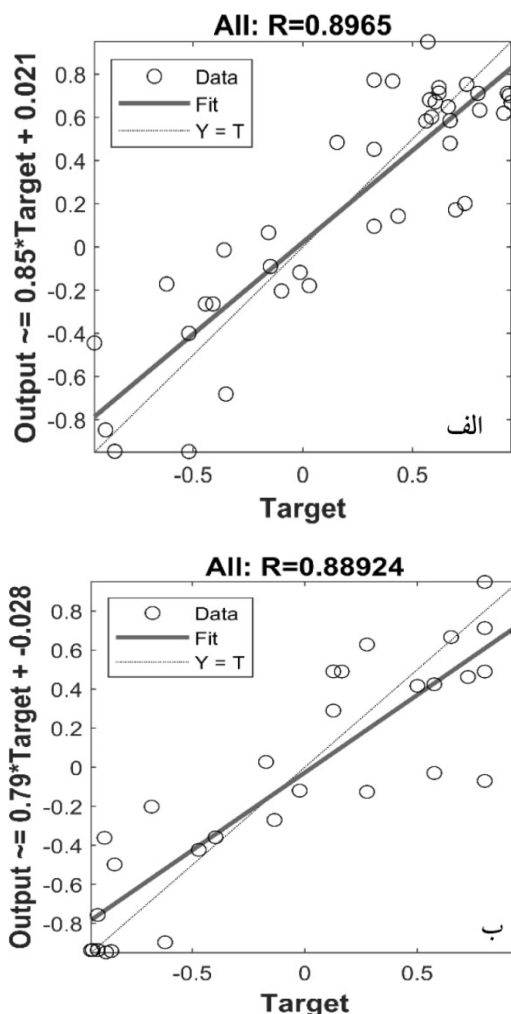
شکل 4- ساختار شبکه عصبی پرسپترون چندلایه به منظور پیش بینی متغیرهای استحکام کششی و ازدیاد طول.

نظر به اینکه داده های ورودی و خروجی مورد مطالعه در دامنه ها و گستره های عددی متفاوت تشکیل شده اند، برای اطمینان از عملکرد یکسان تمام پارامترها در مدل، داده ها براساس فرایند استانداردسازی در بازه عددی  $[-0/95, 0/95]$  استاندارد (نرمال) شدند. به منظور اجرای صحیح، ارزیابی و بررسی قابلیت تعمیم شبکه، داده ها به صورت تصادفی به سه بخش آموزش (70%)، اعتبارسنجی (15%) و آزمون (15%) تقسیم شدند.

به منظور بهینه سازی ساختار شبکه عصبی مصنوعی در تخمین متغیرهای استحکام کششی و ازدیاد طول، چهار عامل مهم در ساختار شبکه های عصبی مصنوعی شامل، تعداد و نورون های لایه های پنهان، الگوریتم آموزش و تابع انتقال مورد بررسی قرار گرفت.

براساس تعداد متغیرهای ورودی و خروجی و همچنین تعداد نمونه ها، لایه های میانی در دو حالت (الف) یک لایه و (ب) دو لایه و تعداد نورون های هر لایه، 2 تا 20 عدد انتخاب شد. لازم به ذکر است تعداد نورون های کم باعث کم برازشی و در مقابل، افزایش بیش از حد نورون ها موجب بیش برازشی می شود.

در این پژوهش، از توابع انتقال (فعال سازی) تانژانت سیگموئید و لاگ سیگموئید برای لایه (های) میانی و توابع Tansig و تابع خطی برای لایه خروجی استفاده و تاثیر آنها بر عملکرد شبکه عصبی مورد بررسی قرار گرفت. به منظور بررسی تاثیر الگوریتم



شکل 6- نمودار متقاطع به همراه رگرسیون خروجی شبکه عصبی بهینه با یک لایه میانی. الف - SUTS و ب - L%.

در شکل (8-الف) نمودار متقاطع مقادیر واقعی در مقابل مقادیر پیش‌بینی شده SUTS (در حالت نرمال‌سازی شده)، نشان داده شده است. براساس این شکل، ضریب همبستگی حدود 0/93 و رابطه خطی بین مقادیر واقعی و تخمینی با شیب خط رگرسیون 0/86 و عرض از مبدا صفر، حاصل شد که دلالت بر عملکرد مطلوب شبکه عصبی انتخاب شده در تخمین متغیر SUTS دارد.

در شکل (8-ب)، نمودار متقاطع مقادیر واقعی و تخمینی متغیر L% برای کل داده‌ها نمایش داده شده است که مقادیر تخمینی نسبت به مقادیر واقعی دارای ضریب همبستگی تقریباً 0/93 و رابطه خطی رگرسیون با شیب تقریبی 0/9 و عرض از مبدا 0/04 (نزدیک به خط 45 درجه) است.



عملکرد و کارایی شبکه عصبی انتخاب شد. بهترین شرایط شبکه در دور یا تکرار (Epoch) 24 با مقدار میانگین مربع خطا 0/078 برای مجموعه داده‌های اعتبارسنجی حاصل شد (شکل 5). همانگونه که در این شکل دیده می‌شود با افزایش دفعات تکرار تا دور 24 خطا کاهش و پس از آن علی‌رغم تداوم بهبود روند آموزش، میزان خطا در مجموعه‌های اعتبارسنجی و به‌ویژه آزمون، افزایش می‌یابد.

در شکل (6-الف)، نمودار متقاطع به همراه خط برازش شده مقادیر واقعی و تخمینی در کل داده‌های متغیر SUTS نمایش داده شده است که بیانگر عملکرد قابل قبول شبکه عصبی در تخمین متغیر SUTS براساس ضریب همبستگی تقریبی 0/9 و رابطه خطی بین مقادیر واقعی و تخمینی با شیب خط رگرسیون 0/85 و عرض از مبدا تقریبی 0/02 (نزدیک به خط 45 درجه) است. در شکل (6-ب)، نمودار رگرسیون تخمین متغیر L% برای کل داده‌ها نمایش داده شده است که مقادیر تخمینی نسبت به مقادیر واقعی دارای ضریب همبستگی تقریبی 0/9 و رابطه خطی رگرسیون با شیب تقریبی 0/8 و عرض از مبدا 0/03 است. لازم به ذکر است این مقادیر در حالت نرمال‌سازی شده نمایش داده شده است.


### ب- شبکه‌های عصبی طراحی شده با دو لایه میانی

6080 شبکه عصبی با دو لایه میانی و تعداد نورون‌های هر لایه در گستره 2-20 (تعداد نورون‌ها در لایه اول بزرگتر مساوی لایه دوم انتخاب شد) و توابع مختلف آموزش و انتقال اجرا شد. در نهایت، شبکه بهینه براساس معیارهای ذکر شده در قسمت قبل، با 17 نورون در لایه میانی اول و 7 نورون در لایه میانی دوم، الگوریتم آموزش لونبرگ-مارکوارت و تابع انتقال Logsig برای لایه‌های میانی و تابع Tansig برای لایه خروجی انتخاب شد. همانگونه که در نمودار کارایی (شکل 7) دیده می‌شود، بهترین شرایط این شبکه در دور 12 با مقدار میانگین مربعات خطا 0/1 برای داده اعتبارسنجی حاصل شد و پس از آن، علی‌رغم تداوم روند بهبود آموزش، میزان خطا در مجموعه‌های اعتبارسنجی و به‌ویژه آزمون، افزایش می‌یابد. این رفتار بیانگر پدیده بیش‌برازشی است.






شکل 8- نمودار مقاطع به همراه رگرسیون خروجی شبکه عصبی بهینه با دولاایه میانی متغیرهای الف - SUTS و ب - %L.



شکل 9- نمودار مقایسه‌ای مقادیر واقعی و تخمینی داده‌های مربوط به متغیرهای الف - استحکام کششی (الف) و ازدیاد طول (ب).



شکل 7- نمودار کارایی شاخص میانگین مربعات خطا در حالت شبکه عصبی با دو لایه میانی.

به منظور بررسی دقیق‌تر کارایی و قابلیت تعمیم‌پذیری شبکه عصبی، مقادیر تخمینی شبکه عصبی به بازه اولیه بازگردانده شده و با داده‌های واقعی مقایسه شدند، همانطور که در شکل (9) نمایش داده شده است خروجی‌های شبکه‌های عصبی در حالت یک و دو لایه پنهان توانسته به خوبی روند کلی داده، حدود بالا و پایین متغیرها را پیش‌بینی و پوشش بدهد.

به طور کلی از قیاس خروجی‌های شبکه عصبی با مقادیر واقعی، می‌توان برداشت نمود که عملکرد شبکه عصبی با دو لایه پنهان مطلوب‌تر است، هرچند به پیچیدگی این شبکه باید توجه شود.

### 3-3- صحت‌سنجی شبکه عصبی انتخابی

به منظور راستی‌آزمایی و بررسی نتایج به دست آمده از شبکه‌های عصبی مختلف در پیش‌بینی متغیرهای استحکام کششی و ازدیاد طول نسبی، مقادیر ضریب همبستگی ( $r$ )، شیب خط ( $m$ ) و عرض از مبدا ( $b$ )، رگرسیون و خطای میانگین مربعات خطا داده‌ها در حالت خام ( $MSE$ ) و نرمال ( $MSE_N$ ) بررسی شد. شبکه بهینه دارای ضریب همبستگی و شیب خط نزدیک به یک، عرض از مبدا نزدیک به صفر و کمینه مقدار خطا را داشته باشد. براساس جمیع شاخص ارائه شده در جدول (3)، عملکرد شبکه عصبی با دو لایه پنهان مناسب‌تر و از دقت بالاتری برخوردار است.



2-R. L. F. J.R. Kissell, Working with aluminium, Aluminium structures: A guide to their specification and design. New York, USA: John Wiley & Sons Inc., 2002.

3- D. Singh, P. N. Rao, C. S. Rajoria, J. Bhamu, S. Goel, S. J. Raykar, K. K. Saxena and R. Jayaganthan, "Influence of processing and microstructure on the corrosion behavior of ultrafine grained Al 5083 alloy", Journal of Process Mechanical Engineering, 2022, v.3, pp.1-11.

4-S. A. Anil Kumar Bodukuri, K. Eswaraiah, Katla Rajendar, "Comparison of Aluminum Alloy 5083 properties on TIGW and FSW Processes," Mater. Today Proc., 2017, v. 4 pp. 10179–10201.

5- R.S. Mishra and Z.Y. Mab, "Friction stir welding and processing", Materials science and engineering: R, 2005, v.50, pp1-78, 2005.

6-M. Safari, H. Mostaan and A. Bakhtiari, "Optimization of variables of friction stir welding process with the aim of achieving the maximum fracture strength", JWSTI, 2016; n. 1, pp. 32-48.

7-N. Taheri Moghaddam, A. Rabiezhadeh, A. Khosravifard and L. Ghalandari, "Joining of the 5083-aluminum alloy using the bobbin tool friction stir welding technique", JWSTI, 2022; n. 2, pp. 25-37.

8- M. S. Shtrikman, "Current state and development of friction stir welding (review). Part 2. Improvement of tools and welding method," Welding International, 2008, v. 22, pp. 712–719.

9- K. Aybar and F. H. Çakir, "An experimental study of the friction stir welding of Al 5083 H321 plates by using different process parameters", Canadian Metallurgical Quarterly, 2023, 15 May, pp.1-13.

10- R. D. Ardika, T. Triyono and N. Muhayat, "A review porosity in aluminum welding", Procedia Structural Integrity, 2021, v. pp. 171–180.

11-K. Kavathia and V. Badheka, "Application of Friction Stir Welding (FSW) in Automotive and Electric Vehicle", Recent Advances in Mechanical Infrastructure, 2022, pp 289–304.

12-C. Chanakyan, S. Sivasankar, M. Meignanamoorthy and S. V. Alagarsamy, "Parametric Optimization of Mechanical Properties via FSW on AA5052 Using Taguchi Based Grey Relational Analysis", INCAS Bulletin, 2021, v. 13, pp. 21-30.

13-M. N. J. H. Lombard, D.G. Hattingh, A. Steuwer, "Effect of process parameters on the residual stresses in AA5083-H321 friction stir welds," Materials Science and Engineering: A, 2009, v. 501, pp. 119–124.

14-K. A. Prabha, P. K. Putha and B.S. Prasad, "Effect of Tool Rotational Speed on Mechanical Properties Of Aluminium Alloy 5083 Weldments in Friction Stir Welding," Materials Today Proceedings, 2018, v.5, pp. 18535-18543.

15-P. J. W. M. Peel, A. Steuwer and M. Preuss, "Microstructure, mechanical properties and residual stresses as a function of welding speed in aluminium AA5083 friction stir welds," Acta Materialia, 2003, v. 51, pp. 4790–4801.

جدول 3- شاخص‌های عملکرد شبکه عصبی در پیش‌بینی متغیرهای استحکام کششی ( $S_{UTS}$ ) و ازدیاد طول نسبی (%L).

نوع شبکه	متغیر	r	m	b	MSE	MSE <sub>N</sub>
یک لایه	$\sigma_{UTS}$	۰/۹	۰/۸۵	۰/۰۲	۹۴۶/۷	۰/۰۷
میانی	%L	۰/۸۹	۰/۷۹	۰/۰۳	۱۶/۶	۰/۰۹
دو لایه	$\sigma_{UTS}$	۰/۹۳	۰/۸۶	۰	۷۰۲/۰۲	۰/۰۵
میانی	%L	۰/۹۳	۰/۹	۰/۰۴	۱۱/۲۸	۰/۰۶

#### 4- نتیجه‌گیری

در این پژوهش، کاربرد شبکه عصبی پرسپترون چند لایه به‌عنوان یک ساختار کارآمد و پرکاربرد هوش مصنوعی در پیش‌بینی پاسخ‌های استحکام کششی و ازدیاد طول نسبی اتصالات ایجاد شده بر Al-5083 توسط فرایند همزنی اصطکاکی براساس متغیرهای ورودی سرعت چرخش و پیش‌روی مورد بررسی قرار گرفت. به‌منظور تعیین ساختار بهینه شبکه عصبی، تحلیل حساسیت بر پایه سناریوهای تعداد یک و دو لایه پنهان (با توجه به تعداد نمونه‌ها)، تعداد 2-20 نورون در لایه پنهان و توابع فعال‌سازی و آموزش اجرا شد.

در رویکرد تک لایه میانی با توجه به ضریب همبستگی 0/9 و میانگین مربعات خطا 0/08، شبکه بهینه با تعداد 4 نورون، الگوریتم آموزش لونیگ-مارکوارت و تابع انتقال Tansig تعیین شد. در رویکرد دو لایه میانی با توجه به ضریب همبستگی 0/93 و میانگین مربعات خطا 0/06، شبکه بهینه براساس معیارهای ذکر شده، با تعداد نورون 17 (لایه اول پنهان) - 7 (لایه دوم پنهان)، الگوریتم آموزش لونیگ-مارکوارت و تابع انتقال Logsig برای لایه‌های میانی و تابع Tansig لایه خروجی انتخاب شد.

با بررسی حالت‌های مختلف شبکه مشخص شد سناریوی شبکه عصبی پرسپترون چند لایه با دو لایه پنهان دارای عملکرد مناسب‌تری به‌منظور تخمین متغیرهای استحکام کششی و ازدیاد طول نسبی اتصالات با توجه به آموزش و تعمیم‌پذیری برخوردار است.

#### منابع

1- E. L. Rooy, Introduction to aluminium and aluminium alloys, ASM Handbook. ASM International, 1990.

Neural Network”, Jordan Journal of Mechanical and Industrial Engineering, 2008, v. 2, pp. 151-155.

23-N. P. Senapati, D.K. Panda, R. K. Bhoi, “Prediction of multiple characteristics of Friction-Stir welded joints by Levenberg Marquardt algorithm based artificial neural network”, Materials Today: Proceedings, 2021, v. 41 pp.391–396.

24-L. Fratini, G. Buffa and D. Palmeri, “Using a neural network for predicting the average grain size in friction stir welding processes”, Computers and Structures, 2009, v. 87, pp.1166–1174

25-“Aluminium 5083-H116, 5083-H321” <http://asm.matweb.com> in ASM Aerospace Specification Metals Inc.

26-“ASTM E8/E8M-22 Standard Test Methods for Tension Testing of Metallic Materials,” PA, USA: ASTM International: West Conshohocken, 2022.

27-M.H. Beale, M.T. Hagan, H.B. Demuth, “Neural network toolbox User’s Guide”, MathWorks, (2018), 136 pp.

28-I. Mukherjee, S. Routroy, “Comparing the performance of neural networks developed by using Levenberg–Marquardt and Quasi-Newton with the gradient descent algorithm for modelling a multiple response grinding process. Expert Systems with Applications”, 2012, v. 39, pp. 2397-2407.

16-R. Beygi, M. Z. Mehrizi, A. A. Safar, S. Mohammadi and L. F. Silva, “A Parametric Study on the Effect of FSW Parameters and the Tool Geometry on the Tensile Strength of AA2024–AA7075 Joints: Microstructure and Fracture”, Lubricants, 2023, v. 11, pp. 2-18.

17-J. . Zurada, Introduction to artificial neural systems. West Publishing Company, 1992.

18-C. C. Aggarwal, “Neural networks and deep learning”, Springer, 2018.

19-H.K. Bhadeshia, , R.C. Dimitriu, S. Forsik, J.H. Pak and J. H. Ryu, “Performance of neural networks in materials science”, Materials Science and Technology, 2009, v. 4, pp 504-510.

20- T. P. Nguyen, S. Choi, S. Park, J. Yoon, “Inspecting Method for Defective Casting Products with Convolutional Neural Network (CNN)”, International Journal of Precision Engineering and Manufacturing-Green Technology, 2021, v. 8, pp583-594.

21- J. Lin, Y. Yao, L. Ma and Y. Wang, “Detection of a casting defect tracked by deep convolution neural network”, International Journal of Precision Engineering and Manufacturing-Green Technology, 2018, v. 97, pp. 573-581.

22-Y. K. Yousif, K. M. Daws and B. I. Kazem, “Prediction of Friction Stir Welding Characteristic Using