

پیش بینی و کنترل فرآیند جوشکاری رباتیک قوسی با استفاده از شبکه عصبی مصنوعی

جعفر ثنائی مقدم سبزواری^۱، علی اکبر اکبری^۲، علیرضا اکبرزاده توتونچی^۳

مشهد، دانشگاه فردوسی، دانشکده مهندسی، گروه مکانیک

jafarsanaei@yahoo.com

چکیده :

فرآیند جوشکاری قوسی (Gas Metal Arc Welding) به عنوان یک تکنیک اتصال فلزات با کیفیت بالا شناخته شده است که کاربردهای وسیع به ویژه در لوله گذاری های نفت و گاز دارد. این روش جوشکاری (بر اساس تحقیقات American Petroleum Institute) به عنوان یکی از دو روش جوشکاری مناسب در لوله گذاری های طولانی مورد استفاده قرار می گیرد. برای دستیابی به کیفیت مطلوب جوش، نیاز است که رابطه پارامترهای مؤثر جوشکاری روی هندسه جوش مدل سازی شود. اهمیت این مطلب بدان خاطر است که خصوصیات مکانیکی جوش نیز تحت تاثیر هندسه جوش قرار دارد. علی‌رغم زمینه گسترده استفاده جوشکاری قوسی در صنایع مختلف، هنوز جوشکاری قوسی رباتیک تمام اتومات با مشکلاتی مواجه است. یکی از این مشکلات، مدل‌سازی فرآیند جوشکاری قوسی است. لذا در این بررسی یک مدل ریاضی بهینه شده و یک مدل بهینه شبکه عصبی برای پیش بینی عمق نفوذ جوش ارائه می شود. (اطلاعات مربوط به آزمایشات از مقاله تحقیقاتی Karadeniz و همکاران استخراج گردیده است). نتایج نشان داد که اگر چه مدل ریاضی می تواند عمق نفوذ جوش را با دقت قابل قبول پیش بینی و کیفیت مطلوب جوش را تضمین نماید، اما مدل شبکه عصبی بهتر از مدل ریاضی عمل کنترل و پیش‌بینی را انجام می‌دهد.

کلمات کلیدی : جوشکاری رباتیک- شبکه عصبی مصنوعی- مدل سازی -رگرسیون چندگانه-GMAW.

۱- مقدمه :

ایجاد مدل هایی که بتواند پیش بینی پارامترهای جوشکاری قوسی را - با در نظر گرفتن شرایط قطعه کار و هندسه سطح جوش مطلوب - انجام دهد، برای توسعه سیستم جوشکاری رباتیک اهمیت ویژه ای دارد. زیرا علاوه بر زیبایی ظاهری، خصوصیات مکانیکی جوش نیز تحت تاثیر هندسه آن می‌باشد. از این رو برای دست یابی به جوش با کیفیت مطلوب باید بر روی پارامترهای مؤثر فرآیند کنترل کامل داشت. جوشکاری اتومات GMA با هدف کاهش هزینه های تولید و یکنواختی و ثابت ماندن کیفیت محصولات، در حال پیشرفت سریع است. اما از طرفی هنوز جوشکاری قوسی رباتیک تمام اتومات با مشکلاتی مواجه است. یکی از مشکلات قابل توجه، مدل‌سازی فرآیند جوشکاری قوسی است [۱].

مدل سازی فرآیند جوشکاری که بیان کننده ارتباط صحیح بین پارامترهای مؤثر انتخاب شده و هندسه جوش باشد، مورد توجه محققان بوده است [۲]. Chandle [۳] برای اولین بار روش مدل سازی ریاضی را برای فرآیند جوشکاری GMA بکار برد و روابط بین متغیرهای فرآیند و هندسه جوش را بررسی

^۱ دانشجوی کارشناسی ارشد مکانیک-ساخت و تولید

^۲ استادیار گروه مکانیک

^۳ استادیار گروه مکانیک

کرد. نتایج این بررسی نشان داد که جریان قوس بیشترین تاثیر را روی هندسه جوش دارد و مدل‌های ریاضی برای پیش بینی هندسه جوش قابل استفاده است. در سال 2003، Kim و همکاران [۴] آنالیز حساسیت را برای دو مدل ریاضی در فرآیند GMAW انجام دادند. آنها نشان دادند که در پیش بینی کیفیت مطلوب جوش، ولتاژ و شدت جریان تاثیر بیشتری دارند. در سال 2006، Ganjigatti و همکاران [۵] فرآیند جوشکاری (Metal Inert Gas) را با استفاده از روش های آماری مدل سازی کردند. در این بررسی آنها نشان دادند که مدل های خطی نسبت به برخی مدل های غیرخطی مانند منحنی الخط از دقت بالاتری در پیش بینی برخوردار می باشد.

از طرفی در سالهای اخیر، شبکه های عصبی مصنوعی (ANN^1) به عنوان ابزار بسیار مناسبی برای ایجاد مدل‌هایی که رابطه داخلی بین ورودی و خروجی سیستم های پیچیده را بیان می کند، مطرح شده است. مزیت اصلی ANN در زمینه طراحی مهندسی و تکنولوژی گروهی، توانایی ذخیره کردن یک مجموعه بزرگ از الگوها که به عنوان حافظه ای برای سیستم است، که قابلیت فراخوانی در زمان دیگر را دارد [۶]. این خصوصیت، شبکه عصبی را بعنوان یک ابزار مفید برای کاربردهای مختلف در صنعت تولید معرفی می کند.

درمورد استفاده از شبکه عصبی برای کاربردهای متنوع در زمینه جوشکاری، پژوهش هایی انجام گرفته است. Datta و Nagesh [۷] شبکه عصبی پس انتشار خطا را برای پیش بینی هندسه جوش و عمق نفوذ در جوشکاری SMAW² بدون توجه به ساختار شبکه عصبی بکار بردند. آنها بیان کردند که شبکه عصبی یک مدل با قابلیت کار مناسب برای پیش بینی هندسه گرده جوش و عمق نفوذ تحت یک مجموعه شرایط جوشکاری مشخص می باشد. Kim و همکارانش [۸] از شبکه عصبی برگشت انتشار خطا برای پیش بینی گرده جوش برای فرآیند جوشکاری GMA استفاده کردند. آنها نشان دادند که مدل شبکه انتخاب شده قادر به پیش بینی هندسه گرده جوش با دقتی مطلوب می باشد. Wu و همکاران [۸] در سال 2006، از یک مدل شبکه عصبی برای نشان دادن ارتباط پارامترهای هندسی روی جوش با عمق نفوذ جوش ارایه دادند و در ادامه از این شبکه جهت کنترل عمق نفوذ جوش بهره بردند.

امروزه استفاده از سیستم های هوشمند، هوش مصنوعی، شبکه های عصبی مصنوعی، منطق فازی و الگوریتم های تکاملی، منطقی جدید برای تحقیق در زمینه کنترل و مونیتورینگ فرآیند جوشکاری رباتیک، ارایه می دهد. در مقاله حاضر مدل های بهینه ای جهت کنترل فرآیند جوشکاری رباتیک GMAW توسط شبکه عصبی و مدل های ریاضی ارائه شده و مورد مقایسه قرار می گیرد. اطلاعات مربوط به آزمایشات (جهت مدل سازی فرآیند جوشکاری) از تحقیق Karadeniz و همکاران [۹] که در سال 2007 انجام نمودند، استخراج گردید. در تحقیق این گروه تاثیر پارامترهای جوشکاری (شدت جریان، سرعت و ولتاژ جوشکاری) بر عمق نفوذ جوش، بدون انجام مدل سازی فرآیند و با ارایه یک سری نمودار تغییرات، بررسی شده است.

¹ Artificial Neural Network

² Shield Metal Arc Welding

۲- شرایط آزمایش :


در این قسمت فرآیند انجام آزمایشات Karadeniz و همکاران به صورت اجمالی، مورد بررسی قرار می‌گیرد. آزمایشات طراحی شده آماری که بر اساس طرح فاکتوریل می باشد، هزینه ها را کاهش داده و در عین حال اطلاعات مورد نیاز درباره تاثیرات پارامترهای اصلی روی فاکتورهای جواب را بیان می‌کند [۹].

از این سری آزمایشات برای ارائه مدل جوش و بیان ارتباط بین پارامترهای مستقل قابل کنترل فرآیند استفاده گردید. پارامترهای ثابت در طول فرآیند جوشکاری عبارتند از: ضخامت فلز پایه (2.5 mm)، قطر سیم جوش (1 mm)، گاز محافظ، سرعت تغذیه سیم جوش (12 m/min) و زاویه تورچ جوشکاری (5°). پارامترهای متغیر فرآیند بکار رفته در این بررسی شامل سه سطح جریان جوشکاری (95,105,115 A)، سه سطح ولتاژ جوشکاری (22,24,26 V) و همچنین سرعت های جوشکاری (40,60,80 cm/min) است. سیم جوش مورد استفاده در انجام آزمایشات از سری G3Si و به شماره استاندارد DIN EN 440 می‌باشد. جنس قطعه استفاده شده برای جوشکاری لب به لب در این بررسی، فولاد DIN EN 10120 است. این نوع فولاد برای لوله های تحت فشار استفاده می شود. ترکیب شیمیایی این فولاد در جدول ۱ نشان داده شده است. صفحه فولادی در ابعاد 60×30 mm² بریده می شود و عملیات سندبلاست روی هر دو سطح بریده شده قطعات برای برطرف کردن کثیفی و اکسیدها انجام می شود. ترکیبات گاز محافظ 18%CO₂ + 82%Ar بوده و جوشکاری توسط ربات ARK ROBO 1100 مدل DAIHEN از سری ربات های DR انجام شده است.

جدول ۱. ترکیب شیمیایی قطعه کار فولادی و

سیم جوش	C	Mn	Si	S	P
قطعه کار	0.16	0.72	0.07	0.004	0.013
سیم	0.077	1.11	0.86	0.012	0.014

برای اندازه گیری عمق نفوذ جوش ایجاد شده، برش های عرضی با استفاده از یک اره لنگ در موقعیت میانی خط جوش ایجاد شده روی نمونه بریده شد، سپس این سطوح ابتدا توسط کاغذهای سمباده با شماره ۶۰۰-۸۰۰-۱۲۰۰ پرداخت و سپس با استفاده از محلول 10% HNO₃ برای نشان دادن عمق نفوذ جوش اچ می شود. تصویر شماتیکی از هندسه جوش در شکل ۱ نشان داده شده است. (P عمق نفوذ، W پهنای جوش و H ارتفاع جوش می باشد). تصاویر مربوط به سطوح پرداخت شده جهت اندازه گیری عمق نفوذ توسط یک میکروسکوپ نوری با بزرگنمایی 10× و با یک سیستم آنالیز تصویر گرفته شده است [۹].



شکل ۱. تصویر شماتیک هندسه جوش

۳- مدل سازی :

۳-۱- مدل ریاضی :

رگرسیون چندگانه برای برقراری رابطه بین شدت جریان و ولتاژ و سرعت جوشکاری با عمق نفوذ جوش ایجاد شده مورد بررسی قرار گرفت. برای استخراج رابطه بین پارامترهای ورودی و پارامتر خروجی (عمق نفوذ جوش) از نرم افزار SAS استفاده شده است [۱۰]. به طور کلی، دقت مدل های ریاضی و اهمیت ضرایب برای ارزیابی کمی تاثیر پارامتر روی متغیر پاسخ، به ترتیب با انجام تکنیک آنالیز واریانس و آزمون t (student t-test) آزمایش می شود. در آنالیز واریانس مدل های برازش شده، فاکتور ضریب تبیین یکی از عوامل اصلی بیان کننده دقت مدل است.

۳-۱-۱- مدل چند جمله ای مرتبه دوم :

در این بخش مناسب ترین مدل رگرسیونی ارائه می شود. این مدل، متغیر پاسخ را بر اساس ترکیب درجه دوم متغیرهای مستقل برازش می دهد. به عبارتی، تابع پاسخ به ازای هر سری از پارامترها به صورت، $Y = F(C, V, S)$ است که رابطه کلی سطح پاسخ درجه دوم به صورت زیر ارائه می گردد :

$$Y = b_0 + b_1C + b_2V + b_3S + b_{11}C^2 + b_{22}V^2 + b_{33}S^2 + b_{12}CV + b_{13}CS + b_{23}VS \quad (۱)$$

که C جریان جوشکاری، V ولتاژ و S سرعت جوشکاری است.

مقادیر ضرایب با استفاده از آنالیز رگرسیون و با کمک معادلات زیر محاسبه می شود [۱۱] :

$$b_0 = 0.142857 \sum Y - 0.035714 \sum \sum (X_{ii}Y) \quad (۲)$$

$$b_i = 0.041778 \sum (X_iY) \quad (۳)$$

$$b_{ii} = 0.03125 \sum (X_{ii}Y) - 0.035714 \sum \sum (X_{ii}Y) - 0.035714 \sum Y \quad (۴)$$

$$b_{ij} = 0.0625 \sum (X_{ij}Y) \quad (۵)$$

با توجه به داده های آزمایشگاهی برای این حالت رابطه عمق نفوذ جوش با پارامترهای متغیر به صورت زیر است :

$$Y = -9.52884 + 0.17956 C + 0.04194 V + 0.02331 S - 0.00072778 C^2 - 0.00020694 S^2 \quad (۶)$$

در مدل های برازش شده همان گونه که ذکر شد، به طور معمول آنالیز واریانس ANOVA، تاثیر پارامترهای جوشکاری بر روی عمق نفوذ جوش را مشخص کرده و برای تشخیص وجود عکس العمل بین خود فاکتورها و اهمیت هر کدام از فاکتورها در رابطه به دست آمده، استفاده می شود. با کمک نرم افزار SAS آزمون های بالا انجام شد. شایستگی مدل های ریاضی و اهمیت ضرایب پارامترهای جوشکاری روی هندسه جوش، به ترتیب با اعمال آنالیز واریانس و آزمون t بررسی شد.

به طور کلی برای بیان آنالیز واریانس معمولاً از مقادیر مربوط به خطای استاندارد، ضریب همبستگی و ضریب تبیین استفاده می‌شود. در مدل‌های ارائه شده از ضریب تبیین برای بیان آنالیز واریانس استفاده شد.

جدول ۲. سطح اهمیت ضرایب

P value					
C	V	S	C ²	S ²	b ₀
0.001	0.000	0.002	0.004	0.001	0.001

معادله رگرسیون

جدول ۳. آنالیز واریانس مدل رگرسیون چندگانه

Source	Sum of Squares	Mean Square	F Value	Pr > F
Model	1.13190	0.22638	136.20	<.0001
Error	0.02659	0.00166		
R-Square = 0.9770		R-Sq(Adj) = 0.9699		

۲-۳- مدل شبکه عصبی :

شبکه‌های عصبی به طور موفقیت آمیز در زمینه‌های مختلف ریاضیات، مهندسی، پزشکی، روانشناسی، هواشناسی^۱ و موارد دیگر به کار گرفته شده است. شبکه عصبی ترکیبی از نرون‌های مختلف است و هر نرون یک فاکتور وزن قابل تنظیم مرتبط با خود دارد. ورودی به واحدهای پنهان میانی O_i و خروجی نرون‌ها، V_j می‌باشد که مجموع همه خروجی‌های متصل شده به صورت حاصلضرب با وزن اتصال W_{ji} است و بصورت زیر نشان داده می‌شود :

$$V_j = \sum W_{ji}I_i + \theta_j \quad (7)$$


که W_{ji} بیانگر وزن‌های بین نرون i ام و نرون j ام و I_i سیگنال‌های ورودی به گره مورد نظر است. این شبکه (مجموع) با تابع فعال سازی (تابع سیگموئید) زیر انتقال می‌یابد :

$$f(z) = \frac{1}{1 + e^{-z}} \quad (8)$$

خروجی یک گره با تابع انتقال و شبکه ورودی به گره بصورت زیر قابل محاسبه است :

$$output(j) = y_j = f(V_j) = \frac{1}{1 + \exp[-(V_j)]} = \frac{1}{1 + \exp(-(\sum W_{ji}I_i + \theta_j))} \quad (9)$$

که θ_j بایاس یا آستانه تحریک داخلی گره j ام برای جبران کننده‌های غیرصفر مناسب در داده‌ها است.



شکل ۲. یک نرون شبکه عصبی

¹ meteorology

² offset

ANN به طور گسترده در تحقیقات هوش مصنوعی^۱ و در جایی که یک تابع تقریبی برای نگاشت غیرخطی بین پارامترهای ورودی و خروجی نیاز است، کاربرد دارد. در شبکه های عصبی وزن های اولیه، انتخاب تابع فعال سازی و انتخاب تعداد نرون های استفاده شده در لایه میانی (پنهان) به عنوان فاکتورهای یادگیری در نظر گرفته می شوند. شناخت و انتخاب صحیح این فاکتورها مهم است. زیرا آنها نه تنها بر روی همگرایی شبکه تاثیر دارد، بلکه بر روی دقت پیش بینی و تخمین نیز موثرند [۱۲]. همگرایی و سودمندی شبکه عصبی انتشار برگشتی به طور مؤثری به مقدار ثابت یادگیری بستگی دارد. بطور کلی مقدار بهینه ثابت یادگیری باعث حل شدن مساله خواهد شد و مقدار مناسب واحدی برای ثابت یادگیری برای حالت های مختلف آموزش وجود ندارد. بنابراین مقدار ثابت یادگیری به طور آزمایشی و با سعی و خطا برای این مساله باید انتخاب شود.

۱-۲-۳- فرآیند یادگیری شبکه عصبی:

در این بخش به برخی فرآیندهای یادگیری استفاده شده در این بررسی، شامل کاهش شیب با مونتوم، لوبنرگ_مارکوات اشاره می شود.

۲-۲-۳- فرآیند یادگیری کاهش شیب با مونتوم:

در این بخش یکی از روش های یادگیری (کاهش شیب با مونتوم) استفاده شده در آموزش شبکه عصبی به اختصار و به ترتیب مراحل زیر بیان می گردد. یک بردار ورودی در شبکه وارد شده و اجزای آن در نرون های موجود در لایه ورودی وارد می شوند. این اطلاعات به طور روبه جلو در شبکه منتشر می شوند که به موجب این عمل بردار خروجی O تولید می شود. مقایسه بین مقادیر خروجی این شبکه با خروجی مطلوب، یک مقدار خطا برای خروجی هر نرون ایجاد می کند. هدف فرآیند آموزش کمینه کردن خطای کلی شبکه است که در رابطه ۱۱ آورده شده است.

$$E = \frac{1}{2} \sum_j (Z_j - V_j)^2 \quad (10)$$

که مقادیر Z_j خروجی مطلوب می باشند.

اعمال تغییرات برای تطبیق وزن ها برگرفته از فرمول زیر است :

$$\Delta W_{ji} = W_{ji}(k+1) - W_{ji}(k) = -\alpha \frac{\partial E}{\partial W_{ji}} \quad (11)$$

که α سرعت یادگیری و W_{ji} وزن های اتصالی بین نرون j و نرون i می باشند. به عبارتی :

¹ Artificial Intelligence

$$\Delta W_{ji} = \alpha \delta_j O_i \quad (12)$$

و خطای نرون لایه پنهان به صورت زیر محاسبه می شود :

$$\delta_j = f'(v_j) \sum \delta_j W_{ji} \quad (13)$$

اعضای δ_j خطاهای عضوهای لایه مورد نظر را بیان میکند، در حالی که W_{ji} وزن های اتصالی برای این اعضا را بیان می نماید. مشاهده می شود که به منظور محاسبه خطای یک نرون در لایه k ام، خطاهای همه نرون ها در لایه $K+1$ ام (لایه بعدی) نیاز می شود. خطای لایه خروجی یک نرون به صورت زیر محاسبه می شود :

$$\delta_j = f'(v_j)(Z_j - y_j) \quad (14)$$

این خطا جزء ابتدایی ترین محاسبات است و سپس انتشار برگشتی در لایه پنهان قرار گرفته شده قبلی از لایه خروجی محاسبه می شود. این فرآیند تا هنگامی که لایه ورودی حاصل می شود، ادامه می یابد. زمانی که لایه ورودی محاسبه شد، یک خطا برای هر عضو محاسبه شده است. این وزن های اتصالی می توانند بعداً بر طبق ΔW_{ji} محاسبه شده در آخرین مرحله این فرآیند تغییر یابند. به منظور غلبه بر همگرایی پایین و گریز از بهینه های محلی، یک جزء مومنتوم و یک نرخ یادگیری در روش یادگیری استفاده می شود. الگوریتم مورد نظر به صورت زیر است :

$$\Delta W_{ji}(k) = \alpha(k) \delta_j O_i + \eta \Delta W_{ji}(k-1) \quad (15)$$

که $\Delta W_{ji}(k)$ تغییرات K امین وزن اتصالی در الگوریتم است. $W_{ji}(k-1)$ تغییرات $(K-1)$ امین وزن اتصال است. η مومنتوم ($0 \leq \eta < 1$) است. و $\alpha(k) = \alpha(0) \times 0.999999^k$ سرعت یادگیری می باشد [8].

۳-۲-۳- فرآیند یادگیری لونبرگ_مارکوات :

این روش یادگیری مشابه روش نیوتن است با این تفاوت که نیاز به محاسبه ماتریس هسین (Hessian) نیست:

$$x_{k+1} = x_k - H^{-1} \times g_k \quad (16)$$

که ماتریس به صورت زیر تخمین زده می شود:

$$H = J^T J \quad (17)$$

و گرادیان (g) نیز بدین طریق محاسبه می شود:

$$g = J^T e \quad (18)$$

در محاسبات بالا J ماتریس ژاکوبین است که شامل مشتق اول خطاهای شبکه نسبت به وزن ها و بایاس ها می باشد. e نیز بردار مربوط به خطاهای شبکه می باشد. ماتریس ژاکوبین با استفاده از روش پس انتشار استاندارد قابل محاسبه است که از محاسبات پیچیده ماتریس هسین ساده تر است. در نتیجه در الگوریتم لوبنبرگ با توجه به تخمین بالا داریم:

$$x_{k+1} = x_k - [J^T J + \mu I]^{-1} J^T e \quad (19)$$

بدین ترتیب تنظیم وزن ها و بایاس ها بر طبق تابع تبدیل انجام می شود [۱۳]:


$$\Delta x = [J^T J + \mu I]^{-1} J^T e \quad (20)$$

هنگامی که ضریب μ صفر باشد، روش فوق، روش نیوتن با تقریب ماتریس هسین است. هنگامی که μ بزرگ است، روش تبدیل به روش کاهش شیب با اندازه گام کوچک می شود. روش نیوتن سریعتر و با دقت بیشتری، به خطای می نیم نزدیک است. بنابراین هدف حرکت به سمت روش نیوتن است. بدین گونه μ بعد از هر گام موفقیت آمیز (کاهش در تابع عملکرد) کاهش می یابد و فقط هنگامی افزایش داده می شود که یک گام آزمایشی بتواند تابع عملکرد را افزایش دهد. بدین ترتیب تابع عملکرد همیشه در هر تکرار الگوریتم کاهش داده می شود [۱۴].


۴- بحث و نتیجه گیری:

در این تحقیق، پارامترهای ورودی شامل جریان، سرعت و ولتاژ جوشکاری است و عمق نفوذ جوش پارامتر خروجی می باشد.

مدل سازی رگرسیونی بر پایه یک سری فرضیات انجام می شود که باید در حین فرآیند مدل سازی از برقراری این مفروضات اطمینان حاصل نمود. یکی از مهم ترین فرضیه ها، نرمال بودن توزیع باقیمانده ها می باشد. زیرا تحلیل رگرسیون بر این اساس است. با کمک شکل های می توان از این موضوع اطمینان حاصل نمود که واریانس خطاها ثابت و توزیع باقیمانده ها نرمال است.



شکل ۴. نمودار باقیمانده ها نسبت به مقادیر تخمین زده شده



شکل ۳. نمودار نرمال بودن باقیمانده ها


در قسمت مدل سازی شبکه عصبی تعداد سه نرون در لایه ورودی و یک نرون در لایه خروجی انتخاب می شود. به منظور بدست آوردن مدل فرآیند جوشکاری، تصمیم گیری در مورد اینکه چه تعداد لایه و چه تعداد نرون برای هر لایه شبکه انتخاب شود، خیلی مهم است.

در ادامه وضعیت لایه های پنهان بررسی گردید. سپس با تعداد لایه های میانی مختلف این نتیجه حاصل شد که تقریباً در بیشتر برنامه های اجرا شده داشتن یک لایه میانی با تعداد چهار گره، خطای قابل قبولی را ارائه می دهد و در برخی مراحل تعداد لایه های زیاد فقط باعث کاهش سرعت و همچنین کاهش دقت شبکه می گردد. برای رسیدن به این نتیجه که تعداد لایه میانی و همچنین تعداد گره مناسب چه تعداد است، از روش یادگیری لونیبرگ - مارکوات استفاده شد. زیرا جزء سریعترین روش های یادگیری است. در نهایت یک ساختار شبکه بهینه $3 \times 4 \times 1$ برای انجام مدل سازی استفاده گردید.

جدول ۴. نتایج ساختارهای مختلف شبکه با الگوریتم لونیبرگ مارکوات

ساختار شبکه	خطای تست MSE	خطای آموزش MSE
3-1-1	0.263874	0.220948
3-2-1	0.202721	0.108909
3-3-1	0.244035	0.066799
3-4-1	0.031959	0.05480E-4
3-5-1	0.192738	0.025904
3-6-1	0.425116	5.16E-13
3-7-1	0.463331	0.019631
3-8-1	0.282911	1E-15
3-12-1	0.314216	4E-15
3-14-1	0.210478	5.83E-11
3-16-1	0.447749	1E-15

برای انتخاب شبکه مناسب از الگوریتم های مختلف (همان گونه که در توضیحات بالا آورده شد) مانند: روش لونیبرگ - مارکوات، کاهش شیب با مونتوم، پس انتشار خطا با نرخ یادگیری متغیر استفاده شد. از داده های آزمایشگاهی به عنوان الگوهای یادگیری استفاده گردید. ۲۲ داده برای آموزش شبکه عصبی و ۵ داده برای تست استفاده شد. در این بررسی ساخت شبکه و آموزش آن با استفاده از یک کامپیوتر PC 2.0 GHz و RAM 1GB، با کمک نرم افزار MATLAB 2006 اجرا شد. الگوریتم مناسب از بین سایر روش های ذکر شده، که کمترین میزان خطا در تست را ارائه می داد، الگوریتم کاهش شیب با نرخ یادگیری متغیر بود که در حالت بهینه (کمترین میزان خطای تست) دارای ثابت یادگیری 0.05، مونتوم 0.9، سرعت افزایش گام 1.05 و سرعت کاهش گام 0.7 بود و برای 10000 تکرار، آموزش دیده شد.



شکل ۵. شبکه عصبی طراحی شده برای پیش بینی عمق نفوذ جوش

۵- مقایسه مدل ها :

برای حصول اطمینان از مدل های حاصل از رگرسیون و شبکه عصبی ارائه شده برای پیش بینی عمق نفوذ جوش، نتایج آزمایشگاهی و تئوری برای چندین شرایط جوشکاری جدید با هم مقایسه شدند. همان گونه که در بخش مدل سازی ریاضی اشاره شد و جدول مربوط به آنالیز واریانس نیز گویای این مطلب می باشد، دقت مدل ریاضی رضایت بخش است. در این مرحله از روش حذفی پس رو استفاده گردید تا مدل مناسب درجه دوم، حاصل گردد.


برای طراحی بهینه شبکه عصبی که دارای کمترین میزان خطا در مقادیر تست باشد، شبکه با یک و دو لایه میانی و با تعداد گره های گوناگون استفاده شد و در انتها شبکه مطلوب با یک لایه میانی و با تعداد چهار گره در این لایه انتخاب شد. برای انتخاب دقیق ترین الگوریتم نتایج پیش بینی شده از مدل های

بدست آمده در نمودار ۱ با هم و با نتایج آزمایشات مقایسه شدند.

جدول ۵- پارامترهای جوشکاری آزمایشات اضافی برای

Trial No.	Arc current (A)	Welding speed (cm/min)	Welding voltage (V)	Penetration (mm)
1	95	80	22	2.36
2	95	60	26	2.69
3	105	40	24	2.89
4	105	80	26	2.91
5	115	60	24	3.14

معادله مرتبه دوم ارائه شده دارای دقت مناسبی است. اما با توجه به نمودار ۱ مدل شبکه های عصبی بیشترین نزدیکی را به مقادیر آزمایشگاهی داشته و پیش بینی بهتری را برای عمق نفوذ جوش نسبت به مدل ریاضی بهینه شده، ارائه می دهد.



شکل ۶. مقایسه نتایج اندازه گیری و محاسبه شده با استفاده از شبکه عصبی با ساختار بهینه و مدل ریاضی بهینه شده

۶- نتیجه گیری :

در این تحقیق تاثیر پارامترهای فرآیند جوشکاری بر عمق نفوذ جوش ایجاد شده با استفاده از فرآیند جوشکاری رباتیک GMA بررسی شده و نتیجه های زیر حاصل شد:

۱- پارامترهای موثر فرآیند جوشکاری قوسی توسط ربات جوشکار بر عمق نفوذ جوش عبارتند از: سرعت، ولتاژ و جریان جوشکاری.

۲- یک مدل شبکه عصبی و یک مدل رگرسیون چند جمله ای مرتبه دوم برای کنترل پارامترهای فرآیند به منظور دستیابی به عمق نفوذ جوش مطلوب ارائه شد. با استفاده از این مدل ها می توان با توجه به شرایط موجود، عمق نفوذ جوش را محاسبه کرد (با دقت مطلوب) که بدین ترتیب این فرآیند تحت کنترل قرار می گیرد.

۳- مدل ارائه شده مرتبه دوم و شبکه عصبی قادر به پیش بینی پارامترهای فرآیند جوشکاری با دقت مناسب، جهت دستیابی به عمق نفوذ جوش مطلوب می باشند.

۴- مدل درجه دوم با حذف پارامترهای کم اثر، بهینه گردید.

۵- با توجه به داده های کم آزمایشی، شبکه عصبی ارائه شده دارای دقت بهتری می باشد که این مسئله مستلزم انجام عملیات بهینه سازی برای شبکه ارائه شده است.

در این تحقیق روش های مختلف آموزش شبکه برای رسیدن به ساختار مناسب و با دقت مطلوب بررسی شد و با توجه به داده های آزمایشی روش مناسب انتخاب گردید. برای رسیدن به ساختار مناسب، حالت های مختلف ساختار یک و دو لایه پنهان و با تعداد گره حداکثر ۱۶ نود توسط چند روش لونبرگ - مارکوات، کاهش شیب با مومنتوم، پس انتشار خطا با نرخ یادگیری متغیر بررسی شد و در نهایت یک شبکه با ساختار یک لایه میانی، چهار نرون و با استفاده از الگوریتم پس انتشار خطا با نرخ یادگیری متغیر به عنوان ساختار بهینه که حداقل خطای تست را دارد، انتخاب شد.

References :

- [1] Ill-Soo Kim, Joon-Sik Son, Sang-Heon Lee, Prasad K.D.V. Yarlagadda, "Optimal design of neural networks for control in robotic arc welding," International Journal of Robotics and Computer-Integrated Manufacturing Vol. 20, pp. 57-63, 2004.
- [2] Welding Handbook, vol. 2, second ed., American Welding Society.
- [3] R.S. Chandel, "Mathematical modeling of gas metal arc weld features," Fourth International Conference on Modeling of Casting and Welding Processes, , pp. 109-120, 1988.
- [4] I.S. Kim, K.J. Son, Y.S. Yang, P.K.D.V. Yaragada, "Sensitivity analysis for process parameters in GMA welding processes using a factorial design method," Int. J. Machine Tools & Manufacture, Vol. 43, pp. 763-769, 2003.
- [5] J. P. Ganjigatti & D. K. Pratihar & A. RoyChoudhury, "Modeling of the MIG welding process using statistical approaches," Int. J. Adv. Manuf. Technol., pp. 798-809, 2006.
- [6] I.S. Kim, J.S. Son, C.E. Park, I.J. Kim, H.H. Kim, "An investigation into an intelligent system for predicting bead geometry in Arc welding process" Int. J. Materials Processing Technology, Vol. 159, 113-118, 2005.
- [7] Nagesh DS, Datta GL."Prediction of weld bead geometry and prediction in shielded metal-arc welding using artificial neural networks". Int. J. Mater Process Technology, Vol. 79, pp.1-10, 2002.
- [8] C.S. Wu, J.Q. Gao and Y.H. Zhao, "NEURAL NETWORK FOR WELD PENETRATION CONTROL IN GAS TUNGSTEN ARC WELDING," Int. J. Acta Metall. Sin. (Engl. Lett.), Vol. 19, No. 1, pp. 27-33, 2006.
- [9] Erdal Karadeniz, Ugur Ozsarac, Ceyhan Yildiz, , "The effect of process parameters on penetration in gas metal arc welding processes," J. Materials and Design, vol. 28(2), pp. 649-656, 2007.
- [10] SAS Institute, Inc., SAS/STAT User's Guide, 2003 Edition, SAS Institute Inc., Cary, NC, 2003

- [11] N. Murugan , V. Gunaraj, “Prediction and control of weld bead geometry and shape relationships in submerged arc welding of pipes,” Int. J. Materials Processing Technology, Vol. 168, pp.478–487, 2005.
- [12] Burke L, Ignizio JP. “A practical overview of neural networks,” Int. J. Intelligent Manufacturing, Vol. 8, pp. 157–65, 1997.
- [13] Hagan, M.T., and M. Menhaj, “Training feed-forward networks with the Marquardt algorithm,” IEEE Transactions on Neural Networks, Vol. 5, No. 6, 1999, pp. 989-993, 1994.
- [14] Demuth H., Beale M., Hagan M., Neural network toolbox for use with MATLAB, Copyright 1992 - 2006 by The MathWorks, Inc. ,2006.