

مدل سازی و مقایسه مدل های برتر فرآیند جوشکاری رباتیک قوسی جهت پیش بینی کیفیت مطلوب جوش و انتخاب پارامترهای مناسب

علی رضا اکبرزاده توتونچی
استادیار گروه مهندسی مکانیک
دانشگاه فردوسی مشهد
ali_akbarzadeh_t@yahoo.com

علی اکبر اکبری
استادیار گروه مهندسی مکانیک
دانشگاه فردوسی مشهد
akbari@um.ac.ir

جعفر ثنائی مقدم سبزواری
دانشجوی کارشناسی ارشد مکانیک
دانشگاه فردوسی مشهد
jafarsanaei@yahoo.com

چکیده

جوشکاری (Gas Metal Arc (GMA، یکی از پرکاربردترین فرآیندهای تولید به شمار می آید که برای ایجاد اتصالات با کیفیت بالا بکار گرفته می شود. همچنین، این روش قابلیت استفاده در سیستم های اتومات جهت افزایش قابلیت تولید را دارد. در حال حاضر، گرایش به سمت فرآیند جوشکاری اتومات در صنعت رو به افزایش است. اما با وجود استفاده زیاد آن در صنایع مختلف، جوشکاری تمام اتومات GMA هنوز با مشکلاتی مواجه است. یکی از اساسی ترین مشکلات فقدان الگوریتم مناسب برای استخراج رابطه موجود بین متغیرهای جوشکاری و هندسه جوش است. زیرا با کنترل هندسه جوش می توان خواص مکانیکی را نیز کنترل نمود. در این بررسی چند مدل بهینه شده ریاضی برای پیش بینی عمق نفوذ جوش با استفاده از روش رگرسیون چند گانه، شبکه عصبی^۱ MLP و^۲ SANN ارائه شد. نتایج نشان داد که مدل های پیشنهادی میتوانند عمق نفوذ جوش را با دقت قابل قبولی، پیش بینی نمایند. در بین ۵ مدل ارائه شده، مدل شبکه عصبی MLP با دقت بالاتری عمق نفوذ را پیش بینی می کند. در ادامه با کمک الگوریتم تبرید تدریجی مقادیر بهینه پارامترهای ورودی مدل MLP که کیفیت مطلوب را ایجاد می کند، تخمین زده شد. این مقادیر با مقادیر حاصل از نتایج Karadeniz و همکاران [۱۲] مقایسه گردید.

واژه های کلیدی: جوشکاری رباتیک، مدل سازی، شبکه عصبی، بهینه سازی، الگوریتم تبرید تدریجی.

مقدمه

جوشکاری GMA، از پر کاربردترین روش های جوشکاری در زمینه های صنعتی به شمار می رود [۱]. در دوره های قبل که جوشکاری قوسی به صورت دستی انجام می شد، کنترل کیفیت جوش توسط مهارت و تجربه شخص جوشکار صورت می گرفت. بدین صورت که جوشکار در حین انجام جوشکاری، میزان جوش ایجاد شده در محل مورد نظر مشاهده کرده و با تنظیم سریع پارامترها، نسبت به ایجاد جوش با کیفیت مطلوب اقدام می نمود. در نتیجه دست یابی به جوشی با کیفیت بالا، مستلزم به کارگیری پرسنلی مجرب بود. تحقیقات محققان نشان می دهد که با انتخاب درست پارامترهای جوشکاری می توان به ریزساختار مناسب، کیفیت مطلوب و هندسه جوش مورد نظر دست یافت. از سویی با کنترل مناسب پارامترها،

بیشتر خطاها و مشکلاتی که در حین فرآیند ممکن است توسط جوشکار و یا بر اثر تغییر پارامترها رخ دهد را، تا حد زیادی رفع نمود. روش جوشکاری قوسی رباتیک (اتومات) تا حد زیادی از مشکلات بالا مصون است. البته مشکلی که در تحقیقات جهانی به آن اشاره می شود مربوط به بخش مدل سازی فرآیند است. زیرا با بکارگیری مدلی دقیق در ربات جوشکار می توان تخمین پارامترها را با توجه به ابعاد قطعه کار و هندسه مطلوب جوش، انتخاب نمود. تا کنون تحقیقات زیادی برای ارائه مدل های ریاضی که بیان کننده ارتباط صحیح بین پارامترهای موثر انتخاب شده و هندسه جوش باشد، انجام شده است. [۲] Chandle برای اولین بار روش مدل سازی ریاضی را برای فرآیند جوشکاری GMA بکار برد و روابط بین برخی متغیرهای فرآیند و هندسه جوش را بررسی کرد. نتایج این بررسی نشان داد که مدل های ریاضی استخراج شده از نتایج آزمایشات برای پیش بینی هندسه جوش قابل استفاده است. Kim و همکاران [۳ و ۴] در فرآیند GMAW آنالیز حساسیت را برای دو مدل ریاضی انجام دادند. این مدل ها که از تحلیل رگرسیون بدست آمدند شامل یک مدل خطی و یک مدل غیرخطی بود. برای آنالیز حساسیت از مدل غیرخطی استفاده گردید. در ادامه، آنها نشان دادند که در پیش بینی کیفیت مطلوب جوش، ولتاژ و شدت جریان تاثیر بیشتری دارند. در کار دیگری kim و همکاران [۵] معادلات رگرسیون چندگانه خطی را به خوبی معادلات غیرخطی به کار بردند. این معادلات برای بیان رابطه پارامترهای فرآیند جوشکاری با پارامترهای هندسی جوش در جوشکاری قوسی CO₂ ارائه گردید. Murugan و همکاران در سال 2005 [۶]، ارتباط بین پارامترهای جوشکاری قوسی زیرپودری را با هندسه جوش بررسی نمودند. آنها در این تحقیق از معادله رگرسیون مرتبه دوم برای بیان این رابطه استفاده کردند. در سال 2006، Ganjigatti و همکاران [۷] 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 مدل منحنی الخط از دقت بالاتری در پیش بینی برخوردار می باشد.

از سوی دیگر، Nagesh و همکاران [۸] در سال 2002، شبکه عصبی را برای پیش بینی هندسه جوش و عمق نفوذ در جوشکاری SMAW بدون در نظر گرفتن ساختار شبکه عصبی بکار بردند. آنها بیان کردند که شبکه عصبی یک مدل با قابلیت کار مناسب برای پیش بینی هندسه جوش و عمق نفوذ تحت یک مجموعه شرایط جوشکاری مشخص می باشد. در سال

¹ Multi Layer Perceptron (MLP)

² Simulated Annealing Neural Network

³ Shield Metal Arc Welding

kim, 2004 و همکاران [۹] از شبکه عصبی برای بیان رابطه بین پارامترهای فرآیند جوشکاری GMA با پهنای جوش استفاده کردند. آنها آزمایشات را برای سه تعداد پاس جوش مختلف انجام دادند. سپس از دو الگوریتم لوبنرگ مارکوات و برگشت انتشار خطا برای آموزش شبکه استفاده نمودند. نتایج بررسی ها نشان داد که الگوریتم لوبنرگ تاثیر بیشتری در کاهش مجذور میانگین مربعات خطا دارد. Wu و همکاران [۱۰] 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. Ates، در سال 2007 [۱۱]، شبکه عصبی را برای تخمین پارامترهای جوشکاری قوسی بکار برد. وی رابطه موجود بین پارامترهای فرآیند جوشکاری و خصوصیات مکانیکی جوش ایجاد شده را با کمک شبکه عصبی چند لایه تعیین نمود. نتایج بررسی ها نشان داد که مدل شبکه با دقت خوبی خواص مکانیکی جوش را پیش بینی نمود. در تحقیق دیگری در همان سال، karadeniz و همکاران [۱۲] پس از انجام یک سری آزمایشات نشان دادند که تاثیر شدت جریان بر عمق نفوذ جوش نسبت به سایر پارامترها از قبیل سرعت و ولتاژ جوشکاری بیشتر است. این نتیجه از مقایسه نمودارهای مربوط به دادهای آزمایشی و بدون انجام عملیات های تحلیلی و ارایه مدل اتخاذ شد. امروزه از هوش مصنوعی، شبکه های عصبی مصنوعی، منطق فازی و الگوریتم های تکاملی منظر جدیدی برای تحقیق در زمینه کنترل و مونیتورینگ فرآیند جوشکاری رباتیک برای محققین ارایه می دهد. در تحقیق حاضر، (با استفاده از اطلاعات مربوط به آزمایشات karadeniz) ابتدا به ارایه مدل های مناسبی جهت کنترل فرآیند جوشکاری رباتیک GMA با کمک روش رگرسیون، شبکه عصبی، روش ترکیبی پرداخته می شود. سپس در ادامه پارامترهای بهینه جوشکاری برای ایجاد جوش با کیفیت مطلوب توسط الگوریتم تبرید تدریجی استخراج می گردد. به عبارت دیگر، در این بررسی سعی شده است تا روش های موجود برای مدل سازی در قالب یک مجموعه و برای یک مجموعه مشخص از آزمایشات ارایه و سپس با یکدیگر مقایسه شوند.

مدل سازی فرآیند جوشکاری

در قسمت نخست این تحقیق هدف مدل سازی فرآیند جوشکاری قوسی است. مدل، نشان دهنده رابطه موجود بین پارامترهای جوشکاری و هندسه جوش می باشد. پارامترهای فرآیند از قبیل: ولتاژ جوشکاری، سرعت، شدت جریان جوشکاری می باشد. عمق نفوذ جوش نیز به عنوان عامل مهم تر در بیان هندسه جوش در نظر گرفته شد. اطلاعات برای انجام تحلیل ها از نتایج آزمایشات استخراج شد.



شکل ۱- پارامترهای ورودی و خروجی فرآیند جوشکاری GMA

مدل های ریاضی

تحلیل رگرسیون یکی از روش های آماری است که برای مدل سازی از آن استفاده قرار می گیرد. به طور کلی، تحلیل رگرسیونی شامل روش هایی است که با استفاده از آنها می توان روابط بین گروهی از متغیرها را بررسی نمود. برای مدل سازی ریاضی از نرم افزار SAS [۱۳] استفاده شد.

مدل خطی مرتبه اول


تابع پاسخ، بیان کننده عمق نفوذ جوش است که بر حسب پارامترهای فرآیند ارایه می شود. شکل کلی مدل به صورت زیر است:

$$Y = b_0 + b_1C + b_2V + b_3S \quad (۱)$$


که V ولتاژ، S سرعت و C شدت جریان جوشکاری می باشد. برای محاسبه ضرایب معادله فوق از روش حداقل مربعات خطا استفاده می شود. بعد از انجام عملیات مشتق گیری و حل معادلات ضرایب به صورت زیر محاسبه می گردد:

$$Y = -0.86380 + 0.02672C + 0.04194V - 0.00153S \quad (۲)$$

قبل از انجام هر گونه تحلیل رگرسیونی برای مدل های ریاضی، باید ابتدا برقراری فرض های رگرسیون بررسی شود. از جمله این فرض ها شرط نرمال بودن باقیمانده ها و ثابت بودن واریانس باقیمانده ها است. نمودارهای زیر برقرار بودن این فرض ها را بیان می کنند.




شکل ۲- نمودار باقیمانده ها در مقابل مقادیر تخمین زده شده برای عمق نفوذ




شکل ۳- نمودار احتمال نرمال بودن باقیمانده ها

شایستگی مدل های ریاضی و اهمیت ضرایب پارامترهای جوشکاری روی هندسه جوش، به ترتیب با اعمال آنالیز واریانس^۱ و آزمون t بررسی شد. هر کدام از این آزمونها در سطح اطمینان 95% انجام می شود. یکی از فاکتورهای مهم آنالیز واریانس ضریب تبیین تنظیم شده است. جداول زیر نشان دهنده این آزمون ها است:

¹ Analysis OF Variance(ANOVA)




شکل ۴- نمودار باقیمانده ها در مقابل مقادیر تخمین زده شده (مدل غیرخطی)



شکل ۵- نمودار احتمال نرمال بودن باقیمانده ها (مدل غیرخطی)

مدل شبکه عصبی MLP

شبکه عصبی مصنوعی، 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 دارند، بلکه بر روی دقت پیش بینی و تخمین نیز موثرند [۱۴].



شکل ۶- ساختار کلی شبکه عصبی برای پیش بینی عمق نفوذ جوش

جدول ۱- سطح اهمیت ضرایب مدل مرتبه اول

P_value			
C	V	S	b ₀
0.061	0.0701	0.042	0.002

جدول ۲- آنالیز واریانس مدل مرتبه اول

Source	Sum of Squares	Mean Square	F Value	Pr > F
Model	1.07477	0.35826	77.02	<.0001
Error	0.08372	0.00465		
R-Square = 0.9277			R-Sq(Adj) = 0.9157	

مدل مرتبه دوم با حذف پارامترهای کم اثر

مدل مرتبه دوم به طور کلی به صورت زیر ارائه می شود:

$$Y = b_0 + b_1C + b_2V + b_3S + b_{11}C^2 + b_{22}V^2 + b_{33}S^2 + b_{12}CV + b_{13}CS + b_{23}VS \quad (3)$$

در این مدل تمام حالات ترکیب پارامترها و تاثیر آنها در متغیر پاسخ در نظر گرفته شده است. اما از آنجایی که وجود برخی عوامل کم اثر باعث کاهش دقت مدل می شود، با استفاده از روش پس رو مدل بهینه گردید. در انتها متغیر پاسخ، براساس ترکیب مناسب درجه دوم متغیرهای مستقل، به صورت زیر حاصل شد:

$$Y = -9.52884 + 0.17956C + 0.04194V + 0.02331S - 0.00072778C^2 - 0.00020694S^2 \quad (4)$$

برای این مدل نیز قبل از انجام عملیات تحلیل رگرسیون، از برقراری فرضیات اصلی اطمینان حاصل شد. در ادامه به تحلیل مدل پرداخته شد. نتایج تحلیل ها در جداول زیر آورده شده است:

جدول ۳ - سطح اهمیت ضرایب مدل رگرسیون چندگانه مرتبه دوم

P_value					
C	V	S	C ²	S ²	b ₀
0.001	0.000	0.002	0.004	0.001	0.001

جدول ۴ - آنالیز واریانس مدل رگرسیون چندگانه مرتبه دوم

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	

مدل غیرخطی

در بخش مدل های ریاضی، از مدل غیر خطی نیز برای بیان رابطه بین متغیرهای مستقل و متغیر پاسخ استفاده می شود. عمق نفوذ جوش به عنوان تابعی از پارامترهای ورودی فرآیند، به شکل زیر بیان می شود:

$$Y = b_0 \times C^{b_1} \times V^{b_2} \times S^{b_3} \quad (5)$$

بعد از استفاده از تابع تبدیل لگاریتم طبیعی، رابطه بالا به شکل زیر در می آید:

$$Y = 2.7183^{-4.4011} C^{0.97067} V^{0.30499} S^{-0.00815} \quad (6)$$

که b_0, b_1, b_2, b_3 ضرایب مدل غیر خطی می باشند. در این بخش دیگر نمی توان از آزمون های قبلی برای بررسی میزان شایستگی مدل استفاده نمود و بدین صورت آن را با دو مدل قبل مقایسه کرد. زیرا داده ها توسط تابع لگاریتمی به فضای دیگر انتقال یافته اند. بنابراین برای این مدل فقط باید از برقراری مفروضات اصلی رگرسیون اطمینان حاصل نمود. نمودار های زیر این مطلب را بیان می کنند:

¹ Artificial Intelligence

برای نرمالیز کردن داده ها از فرمول زیر استفاده شد:

$$T = \frac{(T_{max} - T_{min}) \times (P - P_{min})}{(P_{max} - P_{min})} + T_{min} \quad (7)$$

که T_{min} , T_{max} به ترتیب ۱ و ۱- و P_{min} , P_{max} نیز به ترتیب بیشترین و کمترین مقدار پارامتر P است. همچنین T ، مقدار نرمال شده P در بازه $[T_{min}, T_{max}]$ است.

تعداد لایه های میانی مناسب از بین دو لایه و تعداد نرون های مناسب در لایه های میانی از بین ۱۶ نرون انتخاب گردید. 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 [۱۵]. در جدول (۵) جهت آشنایی با نحوه انتخاب ساختار، فقط نتایج مربوط به یک لایه آورده شد. در نهایت یک ساختار شبکه بهینه $1 \times 4 \times 3$ برای انجام مدل سازی استفاده شد.

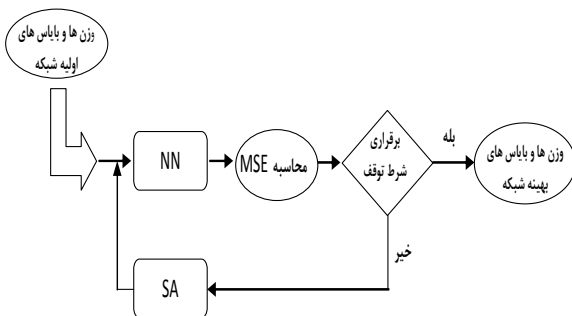
جدول ۵- نتایج ساختارهای مختلف شبکه با الگوریتم لونیبرگ مارکوات

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	0.054803	0.054803
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

مشاهده شده است. برای محاسبه میزان تغییرات بایاس ها در هر مرحله نسبت به مرحله قبل نیز از فرمول ذکر شده استفاده می گردد. در اینجا اگر نسبت خطای جدید به خطای قبلی از یک نسبت ثابت تعریف شده ای (معمولا 1.04) بیشتر شود، وزن ها و بایاس های جدید حذف و نرخ یادگیری کاهش می یابد در غیر اینصورت وزن ها و بایاس های جدید لحاظ شده و نرخ یادگیری افزایش می یابد.

مدل ترکیبی SANN

در سال 1953، Metropolis و همکاران با استفاده از معیاری، فرآیند سرد شدن یک جسم را برای رسیدن به سطح انرژی جدید را شبیه سازی نمود. تبرید تدریجی روشی مبتنی بر محاسبات است که سعی در حل مسایل پیچیده و یافتن جواب های خوب از طریق تکنیک انتخاب تصادفی کنترل شده دارد. الگوریتم این روش که بر اساس معیار Metropolis است، برای نخستین بار در سال 1983 توسط Kirkpatrick و همکاران ارائه شد. از آن زمان به بعد از این الگوریتم به طور گسترده برای بسیاری از مسایل بهینه سازی استفاده شده است. یکی از موارد استفاده آن در بخش آموزش شبکه عصبی است. لذا در این اینجا سعی شد با استفاده از ساختار به دست آمده در مرحله قبل، با کمک الگوریتم SA عملیات آموزش شبکه عصبی انجام گردد.




شکل ۷- طرح کلی فرآیند آموزش شبکه با کمک الگوریتم SA، MSE میانگین مربعات خطا است.

برای این منظور ابتدا شبکه تشکیل گردید. برای آموزش شبکه داده های آموزشی نرمالیز شدند. زیرا این کار از بروز مشکلات بعدی در شبکه جلوگیری می کند. برای نرمال کردن داده ها نیز مانند قسمت قبل از فرمول (۷) استفاده گردید.

از تابع فعال سازی تانژانت هیپربولیک به عنوان تابع انتقال در لایه های میانی و خروجی استفاده شد. صورت کلی تابع به شکل زیر است [۱۶]:

$$g(x) = \frac{2}{(1 + \exp(-2 \times x))} - 1 \quad (9)$$

در شکل (۸)، یک نرون از هر لایه و وزن ها و بایاس های اعمالی نشان داده شده است.



شکل ۸- طرح کلی شبکه شامل یک نرون از هر لایه و عوامل موثر در محاسبات


با افزایش تعداد لایه ها و گره ها، تشکیل پدیده یادگیری مبالغه ای^۱ در فرآیند آموزش شبکه مشاهده گردید.

برای انتخاب پارامترهای مناسب شبکه از الگوریتم های مختلف مانند: روش لونیبرگ - مارکوات، کاهش شیب با مومنتوم، کاهش شیب با مومنتوم و 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 کمک نرم افزار MATLAB 2006 انجام شد. الگوریتم مناسب از بین روش های ذکر شده، که کمترین میزان خطا در تست را ارائه می داد، الگوریتم کاهش شیب با مومنتوم و با نرخ یادگیری متغیر بود که در حالت بهینه (کمترین میزان خطای تست) دارای ثابت یادگیری 0.05، مومنتوم 0.9، سرعت افزایش گام 1.05 و سرعت کاهش گام 0.7 بود و برای 10000 تکرار، آموزش دیده شد. از تابع فعال سازی تانژانت هیپربولیک برای لایه میانی و خروجی استفاده گردید. در روش آموزش کاهش شیب با مومنتوم و با نرخ یادگیری متغیر، تغییرات وزن ها بر طبق فرمول زیر محاسبه می گردد [۱۴]:

$$dW_{ji}(k) = \alpha(k) \times \eta \times \frac{dE}{dw_{ji}(k)} + \eta \times dW_{ji}(k-1) \quad (8)$$

که α نرخ یادگیری و η ضریب مومنتوم و W_{ji} وزن اتصالی بین نرون i ام و j ام می باشد. E، مجموع مربعات تفاضل بین مقادیر تخمین زده و

¹ Over training



شکل ۹- مقدار مجموع مربعات خطا در مرحله آموزش شبکه توسط SA

مقایسه مدل ها

در این قسمت به مقایسه دقت مدل ها برای پیش بینی عمق نفوذ جوش پرداخته می شود. برای این منظور از نتایج ۵ آزمایش که در مراحل مدل سازی استفاده نشده است، کمک گرفته می شود. جدول مقادیر مربوط به پارامترها را نشان می دهد.

جدول ۶- پارامترها و نتایج آزمایشات اضافی در فرآیند جوشکاری GMA

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

همان گونه که از نتایج مربوط به مدل های ریاضی برداشت شد و جداول آنالیز واریانس و ضرایب تبیین مدل ها نشان داد، مدل مرتبه دوم از دقت بالاتری برخوردار است.

شبکه عصبی با ساختار مناسب نیز بعد از طی مراحل بهینه سازی برای پیش بینی کیفیت مطلوب جوشکاری انتخاب گردید. رسیدن به کمترین میزان خطا برای داده های تست به عنوان عامل اصلی در تعیین شبکه مناسب بود. در مدل ترکیبی نیز سعی شد با انتخاب پارامترهای بهینه میزان میانگین مربعات خطا به کمترین مقدار خود برسد.

نتایج مقایسه مدل ها به ازای داده های تست در شکل (۱۰) نشان داده شده است.

همان گونه که در این نمودار مشاهده می شود، مدل MLP از دقت بالاتری برخوردار است. مدل مرتبه دوم، مدل SANN، مدل غیرخطی و مدل خطی مرتبه اول، به ترتیب در جایگاههای بعدی از نظر دقت در پیش بینی قرار گرفتند.

خروجی از هر لایه در شکل (۸) به صورت زیر می باشد. بدین صورت که برای لایه ورودی:

$$O_{Ij} = I_j \quad (10)$$

و برای لایه میانی:

$$O_{Hk} = \frac{2}{1 + e^{-2 \times [\sum_j (O_{Ij} V_{jk}) + c_k]}} - 1 \quad (11)$$

و برای لایه خروجی:

$$O_{Om} = \frac{2}{1 + e^{-2 \times [\sum_k (O_{Hk} W_{km}) + d_m]}} - 1 \quad (12)$$

روابط به صورت بیان شده است. همان گونه که ذکر شد از SA برای آموزش شبکه استفاده می شود. در ادامه نحوه استفاده از این الگوریتم شرح داده می شود.

مکانیزم تولید همسایگی در اطراف یک جواب

رشته جواب در این مساله همه وزن ها و بایاس های مربوط به شبکه می باشد. این رشته شامل ۱۶ وزن و ۵ بایاس است و به هر وزن یک جایگاه داده می شود. برای ایجاد همسایگی در اطراف یک جواب ۴ جایگاه مربوط به وزن و ۲ جایگاه مربوط به بایاس با حفظ مقدار انتخاب می گردد. سپس بقیه مقادیر به صورت تصادفی در سایر جایگاهها قرار می گیرند.

معیار قبول همسایگی ایجاد شده

همسایگی یک جواب هنگامی مورد قبول واقع می گردد که یکی از دو شرط زیر را برآورده کند:

$$\Delta f = f(k) - f(k-1) \quad (13)$$

$k, k-1$ به ترتیب بیان کننده جواب کنونی و همسایگی است که از جواب فعلی حاصل شده است. تابع f ، که همان تابع هدف می باشد، میانگین مربعات خطا برای داده های آموزش را نشان می دهد.

شرط دیگر بدین صورت است که تابع بولتزن از یک مقدار تصادفی بین (۱ و ۰) که دارای توزیع یکنواخت است، بزرگتر باشد.

$$\exp\left(-\frac{\Delta f}{t_i}\right) \geq \text{rand} \quad (14)$$

T_i بیانگر دمای فعلی است.

نحوه به روز رسانی دما

برای به روز رسانی دما در انتهای هر مرحله از فرمول زیر استفاده گردید:

$$t_{i+1} = \beta \times t_i \quad i=0,1,2,\dots \quad (15)$$

که مقدار بهینه β از بازه $0.9 < \beta < 1.0$ بدست می آید.

معیار توقف

برای توقف الگوریتم از دو معیار، رسیدن به دمای $1 * e^{-50}$ و یا تعداد تکرار ۴۰۰۰ استفاده گردید.

شکل (۹) میزان (Sum Square Error) را برای یک مرحله اجرای الگوریتم و برای ۴۰۰۰ تکرار نشان می دهد. برای این مساله شرایط اولیه پس از چندین بار اجرای برنامه، به صورت زیر تعریف گردید:

$$\beta = 0.9678, 700^\circ C$$

جدول ۷- مقایسه مقادیر بهینه جوشکاری حاصل از انجام آزمایش با نتایج

تحلیلی

شدت جریان A	سرعت cm/min	ولتاژ V	عمق نفوذ mm	مقادیر حاصل از آزمایش
105	80	24	2.84	مقادیر حاصل از آزمایش
104	80	24	2.835	مقادیر حاصل از SA

جدول بالا حاکی از آن است که الگوریتم استفاده شده برای حل این مساله قابل اطمینان است و با دقت خوبی قادر به پیش بینی کیفیت مطلوب جوش می باشد.

نتیجه گیری

در این تحقیق سعی شد تا اکثر روش هایی که در مقالات بین المللی استفاده شده را در یک مجموعه و تحت یک سری شرایط آزمایشی مشخص مورد بررسی و مقایسه قرار داده و در ادامه ضمن انتخاب بهترین روش مدل سازی فرآیند پارامترهای بهینه را کمک الگوریتم تکاملی SA استخراج نمود. در این صورت می توان هم از مدل سازی فرآیند اطمینان حاصل نمود و هم پارامترهایی که منجر به ایجاد کیفیت جوش مطلوب می شود را بدست آورد.

از نتایج این بررسی می توان برای برخی روش های دیگر تولید که امکان کنترل مناسب فرآیند وجود ندارد، استفاده نمود. این عدم کنترل مناسب به دلیل کمبود آگاهی از نحوه ارتباط میان پارامترها می باشد.

همان گونه که در این تحقیق بیان شد، در رنج کاری مورد بررسی می توان هرگونه رخدادی را پیش بینی و برای مواجه با آن در حین فرآیند جوشکاری اتومات تصمیحات لازم را اتخاذ کرد. از طرفی، می توان مقادیر بهینه که منجر به تولید جوش با کیفیت مطلوب می شود را نیز پیش بینی نمود.



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 سه معادله رگرسیون (مدل خطی و منحنی الخط و 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 های 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- با توجه به داده های کم آزمایشی، شبکه عصبی ارائه شده دارای دقت بهتری می باشد که این مستلزم انجام عملیات بهینه سازی برای شبکه ارائه شده است.

۵- در پایان پارامترهای جوشکاری بهینه با در نظر گرفتن تابع هدف (سرعت جوشکاری بیشینه) توسط روش تبرید تدریجی تعیین گردید که مقایسه مقادیر تخمین زده شده با مقادیر



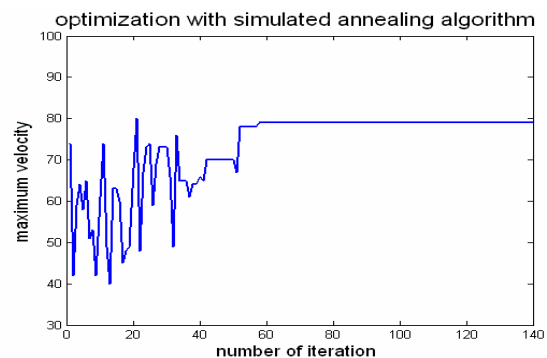
شکل ۱۰- مقایسه نتایج اندازه گیری و محاسبه شده عمق نفوذ جوش با استفاده از ۵ مدل ارایه شده

انتخاب پارامترهای بهینه فرآیند

در این مرحله با استفاده از الگوریتم تکاملی SA، پارامترهای بهینه جوشکاری انتخاب می شود. البته برای این کار از مدل MLP که در گام قبل به عنوان روش دقیق تر ارایه شد، نیز استفاده می گردد. انتظار می رود که انتخاب این پارامترها منجر به تولید جوش با کیفیت مطلوب شود. در این صورت هم تغییرات فرآیند پیش بینی شده و هم مقادیر مناسب پارامترها استخراج گردیده است.

در این برنامه نیز دستیابی به حداکثر سرعت جوشکاری و در عین حال تضمین جوش مطلوب به عنوان تابع هدف و محدودیت های انتخاب پارامترها لحاظ گردید.

شکل (۱۱) بیان کننده نحوه رسیدن به سرعت بیشینه همراه با عمق جوش مطلوب است.



شکل ۱۱- بهینه سازی پارامترهای جوش با هدف حداکثر سرعت جوشکاری به روش تبرید تدریجی

در مقاله مربوط به تحقیقات Karadeniz [۱۲] مقادیر مناسب پارامترها با انجام آزمایشات بدست آمد. در جدول زیر این مقادیر با مقادیری که توسط مدل شبکه عصبی و الگوریتم SA بدست آمد، ارایه شده است.

International Journal of Materials Processing Technology, Vol. 159, pp.113–118.

2- R.S. Chandel, 1988, Mathematical modeling of gas metal arc weld features, Proceedings of the Fourth International Conference on Modeling of Casting and Welding Processes, pp. 109–120.

3- I.S. Kim, K.J. Son, Y.S. Yang, P.K.D.V. Yaragada, 2003, Sensitivity analysis for process parameters in GMA welding processes using a factorial design method, International Journal of Machine Tools & Manufacture, 43, pp. 763–769.

4- Kim IS, Jeong YJ, Son IJ, Kim IJ, Kim JY, Kim IK, Yarlagadda PKDV, 2003, Sensitivity analysis for process parameters influencing weld quality in robotic GMA welding process, International Journal of Material Process Technology, vol. 140, pp. 676–681.

5- Kim IS, Son JS, Kim IG, Kim JY, Kim OS, 2003, A study on relationship between process variables and bead penetration for robotic CO2 arc welding, International Journal of Materials Processing Technology, vol. 136, pp. 139–145.

6- N. Murugan, V. Gunaraj, 2005, Prediction and control of weld bead geometry and shape relationships in submerged arc welding of pipes, International Journal of Materials Processing Technology, Vol. 168, pp.478–487.

7- J. P. Ganjigatti & D. K. Pratihari & A.RoyChoudhury, 2006, Modeling of the MIG welding process using statistical approaches, International Journal of Advance Manufacturing Technology, pp. 798-809.

8- Nagesh DS, Datta GL., 2002, Prediction of weld bead geometry and prediction in shielded metal-arc welding using artificial neural networks, International Journal of Materials Processing Technology, Vol. 79, pp.1–10.

9- Ill-Soo Kim, Joon-Sik Son, Sang-Heon Lee, Prasad K.D.V. Yarlagadda, 2004, Optimal design of neural networks for control in robotic arc welding, International Journal of Robotics and Computer-Integrated Manufacturing Vol. 20, pp. 57–63.

10- C.S. Wu, J.Q. Gao and Y.H. Zhao, 2006, Neural network for weld penetration control in gas tungsten arc welding, Journal of Acta Metall. Sin. (Engl. Lett.), Vol. 19, No. 1 pp. 27-33.

11- Hakan Ates, 2007, Prediction of gas metal arc welding parameters based on artificial neural networks, International Journal of Materials and Design, Vol. 28, pp.2015-2023.

12- Erdal Karadeniz, Ugur Ozsarac, Ceyhan Yildiz, 2007, The effect of process parameters on penetration in gas metal arc welding processes, International Journal of Materials and Design, vol. 28(2), pp. 649-656.

13- SAS Institute, Inc., SAS/STAT User's Guide, 2003 Edition, SAS Institute Inc., Cary, NC, 2003.

14- Burke L, Ignizio JP., 1997, Apractical overview of neural networks, International Journal of Intelligent Manufacturing, Vol. 8, pp. 157–65.

15- Demuth H., Beale M., Hagan M., 2006, Neural network toolbox for use with MATLAB, Copyright 1992 - 2006 by The MathWorks, Inc.

16- Vogl, T.P., J.K. Mangis, A.K. Rigler, W.T. Zink, and D.L. Alkon, 1988, Accelerating the convergence of the backpropagation method, Biological Cybernetics, Vol. 59, pp. 257-263.

حاصل از آزمایش حاکی از دقت بالای روش استفاده شده در این تحقیق 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 لونیگ - مارکوات، کاهش شیب با مومنتوم، کاهش شیب با مومنتوم و با نرخ یادگیری متغیر بررسی شد و در نهایت ساختار یک لایه میانی و با چهار گره به عنوان ساختار بهینه ای که حداقل خطای تست را دارد، انتخاب شد.

تشکر و قدر دانی

نویسنده اول، بدین وسیله از راهنمایی ها و رهنمود های دکتر فرهاد کلاهان (استادیار گروه مکانیک دانشگاه فردوسی) تشکر و قدر دانی می نماید.

فهرست علائم

C	شدت جریان جوشکاری
c_k	بایاس نرون k ام لایه میانی
d_m	بایاس نرون m ام لایه خروجی
$dW_{ji}(k)$	دیفرانسیل وزن در مرحله (k) ام
$dW_{ji}(k-1)$	دیفرانسیل وزن در مرحله $(k-1)$ ام
E	مجموع مربعات خطا در شبکه
f	میانگین مربعات خطا (تابع هدف)
g	تابع فعال سازی تانژانت هیپربولیک
I_j	ورودی به نرون j ام لایه ورودی
MSE	میانگین مربعات خطا
O_{Hk}	خروجی نرون k ام لایه میانی
O_{Ij}	خروجی نرون j ام لایه ورودی
O_{Om}	خروجی نرون m ام لایه خروجی
P	مقادیر نرمال نشده
S	سرعت جوشکاری
SSE	مجموع مربعات خطا
T	مقادیر نرمال شده
t_i	دما در مرحله i ام ($^{\circ}C$)
V	ولتاژ جوشکاری
V_{jk}	وزن بین نرون j ام و k ام
W_{ji}	وزن بین نرون j ام و i ام
W_{km}	وزن بین نرون k ام و m ام
Y	عمق نفوذ جوش

فهرست علائم یونانی

α	نرخ یادگیری
β	ضریب ثابت دمایی
Δf	تغییرات تابع هدف
η	ضریب مومنتوم

مراجع

1- I.S. Kim, J.S. Son, C.E. Park, I.J. Kim, H.H. Kim, 2005, An investigation into an intelligent system for predicting bead geometry in Arc welding process,