

پیش بینی پیوستگی فرآیند جوشکاری زیر پودری در ساخت لوله های اسپیرال نفت و گاز با استفاده از شبکه های عصبی مصنوعی

خلاصه

دو نوع شبکه عصبی مصنوعی و هوشمند برای پیش بینی زمان توقف ماشین جوشکاری زیر پودری در خط تولید لوله های انتقال انرژی در یکی از سازندگان بزرگ لوله های قطور طراحی گردیده است. شبکه اول قادر به پیش بینی زمان توقف بطور مستقل و شبکه دوم قادر به پیش بینی زمان توقف براساس زمان کارکرد می باشد. هر دو شبکه از نوع Cascade-forward backprop می باشند که تابع آموزش آنها trainLM و adoption learning function: learnGDM می باشند که performance function =MSE در نظر گرفته شده است. ساختار شبکه اول ساختار {۱و۱۵و۲۵و۲۰و۱} و ساختار شبکه دوم {۱و۳۳و۲۲و۱} طرح گردیده است. نتایج داده های تست حاکی از قدرت مناسب پیش بینی توسط روش بکار رفته است.

کلید واژه ها:

لوله اسپیرال، نفت و گاز، جوشکاری زیر پودری، شبکه های عصبی مصنوعی

۱- مقدمه

فرایند جوشکاری از مهمترین فرایندهای ساخت لوله های نفت و گاز می باشد. خط جوش ناشی از این فرایند از جهات مختلف حائز اهمیت است و یکی از این جهات، پیوستگی جوش می باشد. بدین معنی که ماشین جوشکاری بطور دائم جوشکاری نموده و هیچگونه توقف و قطعی در فرایند تولید ایجاد نگردد. ایجاد ریز ترک و حفره، تغییر در درصد عناصر ناحیه مذاب، تغییر در نسبت رقت و ... از جمله عیوب قطع عملیات جوشکاری می باشد. بدیهی است اهمیت موضوع فوق برای لوله های نفت و گاز که هر گونه عیب در ساختار آنها می تواند عواقب جبران ناپذیری را به دنبال داشته باشد بسیار زیاد است.

پیش بینی پیوستگی فرایند جوشکاری توسط پیش بینی کارکرد و توقف ماشین جوشکاری انجام می شود. با مدل سازی ماشین جوشکاری می توان زمانهای کارکرد یا عمر ماشین و تعمیر یا خوابیدگی آن را پیش بینی نموده و با راهبری صحیح از شکل گیری توقفات ناخواسته ماشین در حین عملیات جلوگیری نموده و نتیجتاً به پیوستگی بیشتر خط جوش در لوله دست یافت. انجام این پیش بینی نیازمند داشتن اطلاعات کامل از ماشین جوشکاری و رفتار آن در زمان گذشته بوده که با ساخت شبکه عصبی متناسب با این رفتار می توان به یک مدل ریاضی از رفتار ماشین دست یافت. مقاله حاضر

تلاشی برای رسیدن به این یک مدل ریاضی از دستگاه جوش زیرپودری خط تولید لوله نفت و گاز در شرکت لوله و تجهیزات سدید می باشد.

۲- معرفی شبکه های عصبی مصنوعی

شبکه های عصبی مصنوعی جزء آن دسته از سیستم ها قرار دارند که با پردازش داده ها، دانش یا قانون نهفته در ورای داده ها را به ساختار شبکه منتقل می کنند. شبکه های عصبی مصنوعی با الگوبرداری از شبکه های عصبی بیولوژیکی و نحوه عملکرد آن ایجاد شده اند. شبکه های عصبی مصنوعی در دسته سیستم های دینامیکی هوشمند قرار دارند به همین خاطر به این سیستم ها هوشمند میگویند، چراکه بر اساس محاسبات روی داده های عددی یا مثال ها ، قوانین کلی را فرا میگیرند. این سیستم ها در مدل سازی ساختار نرو-سیناپتیکی مغز میکوشند.

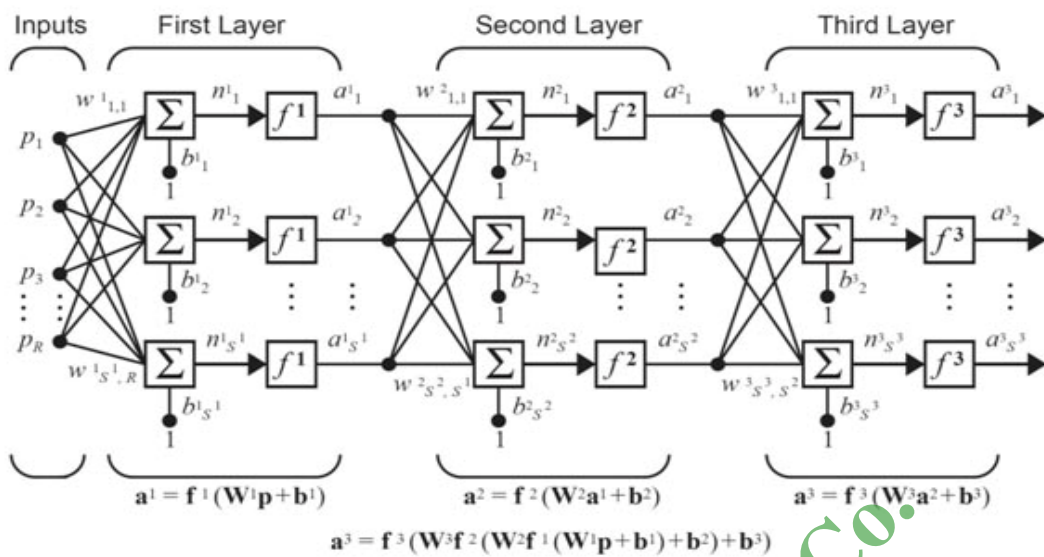
در شبکه های عصبی مصنوعی روشهای مختلف یادگیری وجود دارد که مهمترین آنها عبارتند از: الف) یادگیری با سرپرستی ب) یادگیری بدون سرپرستی ج) یادگیری تقویتی. در یادگیری با سرپرستی که در این تحقیق استفاده شده پارامترهای شبکه (وزنها و بایاسها) باید به نحوی تنظیم شوند که عملکرد شبکه بهینه شود، یعنی خطای بین خروجی شبکه و خروجی مطلوب حداقل گردد.

۳- لایه های شبکه

شبکه عصبی BP، معمولاً یک شبکه پیشخور چند لایه پرسپترون همراه با تعدادی لایه مخفی، با آموزش وابسته به هم، همراه با تکنیک کاهش گرادیان که بر پایه قانون یادگیری صحیح و غلط است، می باشد.

لایه اول که لایه ورودی نامیده میشود، داده ها را از جهان خارج دریافت میکند. لایه آخر که لایه خروجی است، اطلاعات را به بیرون برای کاربران می فرستد. لایه هایی که بین لایه های ورودی و خروجی قرار میگیرند را لایه های مخفی می نامند که هیچ ارتباط مستقیمی با محیط ندارند. حضور آنها به این علت لازم است که در شبکه ساختار پیچیده ای برای مدلسازی ارتباط بین توابع غیرخطی تهیه کنیم. تعداد لایه های مخفی مترادف با پیچیدگی دامنه مسأله ای که باید حل شود، می باشد. مثالی از شبکه چند لایه در شکل ۱ آمده است.

Kowsar San'at Espadana Co.



شکل ۱: ساختار یک شبکه چند لایه با تعداد R ورودی

اغلب پارامترهای مورد استفاده را به دو گروه تقسیم می کنند. یکی داده های آموزشی و دیگری داده های مربوط به بررسی صحت.

در تحقیق جاری آموزش شبکه عصبی مورد نظر در نرم افزار MATLAB با استفاده از تابع TRAIN LM انجام شده است.

الگوریتم LM یک روش بسیار مؤثر برای حل مسایل بهینه سازی غیر خطی است. که در آن وزن نرونها به صورت تکرار شونده به وسیله فرمول زیر تنظیم می شود.

$$w(n_0 + 1) = w(n_0) - (J^T J + \lambda I)^{-1} g_h$$

g برداریان تابع خطا E وابسته به وزن و بایاس (w) است. J ماتریس ژاکوبین مشتق اول از تابع خطای E که مرتبط با وزنهایست. I ماتریس همانی، λ یک ضریب ثابت قابل تنظیم است. هنگامی که لاندا بزرگ است، این یک الگوریتم شدیداً نزولی با اندازه گامهای کوچک است. لذا هدف اینست که هر چه سریعتر و دقیقتر به سمت لاندا برابر با صفر شیفت یابیم.

با توجه به وجود چندین ماشین جوشکاری زیر پودری که در خط تولید کارخانه لوله و تجهیزات سدید وجود دارند مدل را می توان برای تک تک آنها استفاده نمود. بعنوان نمونه جدول زیر که مطابق اعداد واقعی هستند برای کارکرد ماشین جوش زیر پودری ۱ در طی دو ماه اول سال ۸۶ اختصاص داده شده است بطوریکه ماشین پس از طی مدت زمان کارکرد برحسب ساعت بدلایلی دچار خرابی شده و پس از رفع نقص این سیکل ادامه می یابد این اعداد در جدول ۱ آمده است.

جدول ۱: زمانهای کارکرد و توقف


زمان کارکرد	زمان توقف	زمان کارکرد	زمان توقف	زمان کارکرد	زمان توقف
0.17	1.17	12.58	0.42	1.92	0.5

0.5	0.25	11.42	0.33	15.75	0.33
52.42	0.67	9.67	1.25	6.75	0.33
20.83	9.83	16.42	2.42	20.75	0.25
1.83	2.17	7	0.67	1.92	0.5
55	1.17	4.83	1	2.33	2.5
31.58	0.17	4	0.67	4.33	0.67
5.92	8.33	1.83	0.83	4	0.33
15	0.33	3.33	0.33	1.25	0.33
21.58	1.83	10.17	0.33	1.08	0.83
13.58	0.17	0.67	0.67	2.83	1.5
10.5	0.17	2.83	0.17	1.17	0.33
3.33	0.33	10.5	1.83	4.33	0.33
9.92	1.33	34.83	1.33	10.83	0.17
15.08	0.58	8.25	0.42	0.5	0.5

برای مدلسازی شبکه عصبی به منظور پیش بینی پیوستگی عملیات جوشکاری و متعاقب آن برنامه ریزی برای تولید ممتد می بایست زمان کارکرد و توقف ماشین جوشکاری را پیش بینی نمود که این کار توسط دو شبکه عصبی با شماره های ۱ و ۲ انجام می شود. شبکه شماره ۱ پیش بینی زمان کارکرد ماشین است. نتایج این شبکه قابل استحصال از روشهای شناخته شده مانند رگرسیون، روش باکس جنکینز، هموار سازی نمایی و شبیه سازی مونت کارلو نیز می باشد اما ثابت شده این روشها در کوتاه مدت خوب پیش بینی می کنند اما در بلند مدت روشهای پیش بینی غیر خطی بهتر است و استفاده از شبکه های عصبی دارای خطای پیش بینی کمتری می باشد. تیم تحقیق در حال کار بر روی این شبکه است و این در حالیهست که دو شبکه دیگر برای تکمیل این مرحله از تحقیقات ایجاد شد شبکه ۲ جهت پیش بینی زمان توقف بطور مستقل و شبکه ۳ جهت پیش بینی زمان توقف براساس زمان کارکرد ایجاد گردید که ذیلا شبکه های ۲ و ۳ و مقایسه آنها توضیح داده می شود.

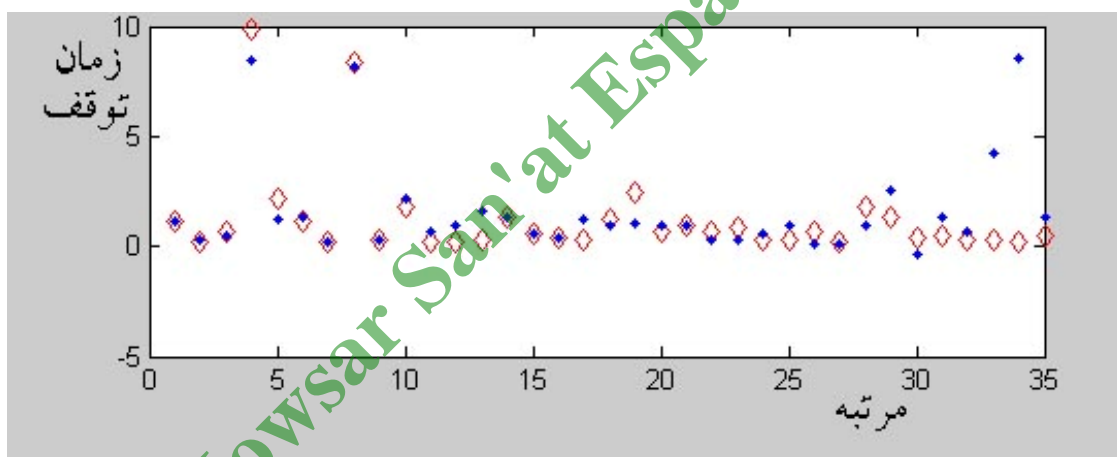
۴- شبکه پیش بینی زمانهای خوابیدگی بطور مستقل

این شبکه برای پیش بینی طول زمان از کارافتادگی ماشین بطور مستقل طراحی شد. بعد از تعدادی آموزش برای لایه های مخفی مختلف و تعداد نرونهای متفاوت با دو لایه مخفی انتخاب شد. این شبکه از نوع adoption learning و trainLM است که تابع آموزش آن Cascade-forward backprop است و function: learnGDM و performance function =MSE می باشد. ساختار شبکه عصبی با سعی و خطا و بر اساس مهارت طراحی می گردد. در این خصوص شبکه ای با ساختار {۱۵و۲۵و۲۰و۱} طراحی گردیده یعنی ۱ لایه ورودی با ۱ واحد(نرون)، ۱ لایه مخفی با ۲۰ واحد(نرون)، ۱ لایه مخفی با ۲۵ واحد(نرون)، ۱ لایه مخفی با ۱۵ واحد(نرون)، ۱ لایه خروجی با ۱ واحد(نرون). تغییرات درصد خطای شبکه در حین آموزش مطابق شکل می باشد. میانگین مربع خطا(MSE) با استفاده از این شبکه کمتر از 0.2 می باشد که مقدار بسیار مناسبی است. تغییرات درصد خطای شبکه در حین آموزش در شکل ۲ منعکس شده است.



شکل ۲: درصد خطای شبکه در حین آموزش

جهت اعتبار سنجی شبکه ۲ برای داده های آموزش مقادیر واقعی و پیش بینی مطابق شکل ۳ و جدول ۲ می باشد.



شکل ۳: مقایسه زمان پیش بینی و واقعی شبکه ۲-نقاط توخالی زمان واقعی و نقاط توپر زمان پیش بینی

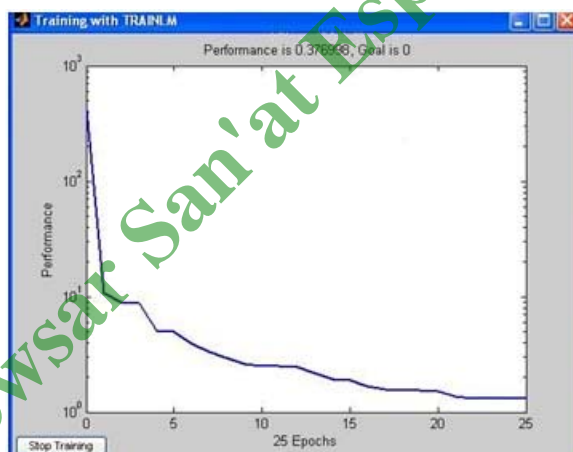
جدول ۲: مقایسه زمان پیش بینی و واقعی شبکه ۲

زمان خوابیدگی	پیش بینی زمان خوابیدگی بطور مستقل	خطاها	درصد خطاها
1.17	1.1496	-0.0204	-2.04
0.25	0.1647	-0.0853	-8.53
0.67	0.8368	0.1668	16.68
9.83	9.74	-0.09	-9
2.17	2.2129	0.0429	4.29
1.17	0.685	-0.485	-48.5
0.17	1.8956	1.7256	172.56
8.33	6.8709	-1.4591	-145.91

0.33	0.5461	0.2161	21.61
1.83	1.794	-0.036	-3.6
0.17	0.1815	0.0115	1.15
0.17	0.1451	-0.0249	-2.49
0.33	0.4668	0.1368	13.68
1.33	1.1747	-0.1553	-15.53
0.58	0.6275	0.0475	4.75
0.42	0.4132	-0.0068	-0.68
0.33	0.4156	0.0856	8.56
1.25	1.3895	0.1395	13.95
2.42	2.1888	-0.2312	-23.12


۵- شبکه پیش بینی زمانهای خوابیدگی بصورت وابسته

این شبکه برای پیش بینی طول زمانهای خوابیدگی بر حسب زمانهای کارکرد ماشین تهیه شده است. این مدل بعد از تعدادی آموزش برای لایه های مخفی مختلف و تعداد نرونهای متفاوت شبکه عصبی با سه لایه مخفی انتخاب شد. این شبکه از نوع Cascade-forward backprop است که تابع آموزش آن trainLM و adoption learning function: learnGDM و performance function =MSE می باشد. در مورد اخیر به کمک ساختار شبکه عصبی {۱و۵و۳و۲و۱} به میانگین مربعات خطای 0.3 دست یافته شد. تغییرات درصد خطای شبکه در حین آموزش مطابق شکل ۴ می باشد.



شکل ۴: درصد خطای شبکه در حین آموزش

جهت اعتبار سنجی شبکه ۳ برای داده های آموزش مقادیر واقعی و پیش بینی مطابق شکل ۵ و جدول ۳ می باشد.



شکل ۵: مقایسه زمان پیش بینی و واقعی شبکه ۲- نقاط توخالی زمان واقعی و نقاط توپر زمان پیش بینی

جدول ۳: مقایسه زمان پیش بینی و واقعی شبکه ۳

زمان کارکرد	زمان خوابیدگی	پیش بینی زمان خوابیدگی با استفاده از زمان کارکرد	خطاها	درصد خطاها
0.17	1.17	1.1508	0.0192	1.92
0.5	0.25	0.2815	-0.0315	-3.15
52.42	0.67	0.5283	0.1417	14.17
20.83	9.83	8.4123	1.4177	141.77
1.83	2.17	1.2449	0.9251	92.51
55	1.17	1.3179	-0.1479	-14.79
31.58	0.17	0.17	0	0
5.92	8.33	8.1789	0.1511	15.11
15	0.33	0.3227	0.0073	0.73
21.58	1.83	2.1648	-0.3348	-33.48
13.58	0.17	0.6305	-0.4605	-46.05
10.5	0.17	0.9748	-0.8048	-80.48
3.33	0.33	1.6475	-1.3175	-131.75
9.92	1.33	1.3433	-0.0133	-1.33
15.08	0.58	0.617	-0.037	-3.7
12.58	0.42	0.4183	0.0017	0.17
11.42	0.33	1.2449	-0.9149	-91.49
9.67	1.25	0.9567	0.2933	29.33
16.42	2.42	1.0098	1.4102	141.02

و در جدول ۳ مقادیر پیش بینی دو روش بایکدیگر مقایسه شده اند.

جدول ۳: مقایسه خروجی های دو شبکه

پیش بینی زمان خوابیدگی بطور مستقل	پیش بینی زمان خوابیدگی با استفاده از زمان کارکرد	تفاوت
1.1496	1.1508	0.0012
0.1647	0.2815	0.1168
0.8368	0.5283	-0.3085
9.74	8.4123	-1.3277
2.2129	1.2449	-0.968
0.685	1.3179	0.6329
1.8956	0.17	-1.7256
6.8709	8.1789	1.308
0.5461	0.3227	-0.2234
1.794	2.1648	0.3708
0.1815	0.6305	0.449
0.1451	0.9748	0.8297
0.4668	1.6475	1.1807
1.1747	1.3433	0.1686
0.6275	0.617	-0.0105
0.4132	0.4183	0.0051
0.4156	1.2449	0.8293
1.3895	0.9567	-0.4328
2.1888	1.0098	-1.179

۶- نتیجه گیری و پیشنهاد:

با تشکیل شبکه های عصبی مصنوعی مناسب با شرایط ماشین جوشکاری رفتار این ماشین مدل شد. این امر برنامه ریزان را در جهت کاهش عیوب محصول و افزایش بهره کمک می نماید.

در این خصوص دو شبکه تشکیل شده است بطوریکه که شبکه اول قادر به پیش بینی زمان توقف بطور مستقل و شبکه دوم قادر به پیش بینی زمان توقف براساس زمان کارکرد می باشد. هر دو شبکه از نوع Cascade-forward backprop می باشند که تابع آموزش آنها trainLM و adoption learning function: learnGDM می باشند که performance function =MSE در نظر گرفته شده است. ساختار شبکه اول ساختار {۱و۱۵و۲۵و۲۰و۱} و ساختار شبکه دوم {۱و۵و۳۳و۲۲و۱} طرح گردیده که به ترتیب دارای Performance 0.2 و 0.3 می باشند که بسیار مناسب است.

۷- مراجع:

۱ - "استفاده از روشهای شبکه عصبی و الگوریتم ژنتیک برای کاهش تنش های پسماند ناشی از جوشکاری زیر پودری"، پانزدهمین کنفرانس سالانه بین المللی مهندسی مکانیک، دانشگاه صنعتی امیرکبیر، اردیبهشت ۱۳۸۶

2- Hagan, Martin, H.B.Demuth, M.Beale, "Neural Network Design", Intonation Thomson Publishing Company, prentice Hall, Englewood Cliffs,1995.

3 Juan-hua Su, He-jun Li, Qi-ming Dong, Ping Liu, Bao-hong Tian, Modeling of rapidly solidified aging process of Cu-Cr-Sn-Zn alloy by an artificial neural network, Computational Materials Science 34 (2005) 151-156

۴- فقیه نظام الدین، عاطفت دوست علیرضا، "هوش مصنوعی در پیش بینی ایست خط تولید"، انتشارات زر، ۱۳۸۴

۵- منهاج، محمد باقر، "هوش محاسباتی مبانی شبکه عصبی"، انتشارات دانشگاه صنعتی امیرکبیر، جلد اول ۱۳۷۹

داور محترم از آنجایی که مرجع ۱ اشاره به نام برخی نویسندگان مقاله دارد، نامها در مرحله داوری حذف شده است.

Kowsar San'at Espadana Co.