

علمی - ترویجی

ارائه الگوریتمی بر اساس یادگیری ماشین شدید،

به منظور نرخ انتقال مواد در فرآیند EDC

در مقاله حاضر از روش ماشین یادگیری شدید برای مدل‌سازی نرخ انتقال مواد در فرآیند EDC به عنوان پارامتر تأثیرگذار بر سرعت انجام فرآیند و کیفیت سطح بوجود آمده، استفاده شده است. میزان میانگین مربعات خطا (MSE) برای نرخ انتقال مواد در داده‌های آموزش ۰/۰۰۰،۳۸۷ و در داده‌های آزمون ۰/۰۰۱،۷ با استفاده از مدل شبکه عصبی ماشین یادگیری شدید بدست آمده است. همچنین، مقدار میانگین مربعات خطا برای متوسط ضخامت لایه بازنشانی شده در داده‌های آموزش ۰/۰۰۰،۲۱۴ و در داده‌های آزمون ۰/۰۰۱،۷ محاسبه شده است. الگوریتم ارائه شده ماشین یادگیری شدید با نتایج تجربی از دقت بالایی در پیش‌بینی پارامترهای خروجی فرآیند برخوردار است.

واژه‌های کلیدی: EDC، متوسط ضخامت لایه، نرخ انتقال مواد، ماشین یادگیری شدید

محمدرضا مرکی^۱، مربی، دانشکده مهندسی مکانیک و مواد، دانشگاه صنعتی بیرجند
هادی تقی ملک^{۲*}، دانشجوی دکتری، دانشکده فنی و مهندسی، دانشگاه سمنان
مجید آذرگمان^۳، دانشجوی دکتری، دانشکده فنی و مهندسی، دانشگاه سمنان
رامین کریمی^۴، دانشجوی کارشناسی ارشد، دانشکده فنی و مهندسی، دانشگاه ارومیه

* نویسنده مخاطب، آدرس: سمنان، کدپستی: ۳۵۱۳۱-۱۹۱۱۱

An Algorithm, Based on Extreme Machine Learning, for Modeling Rate of Material Transfer in EDC Process

In this paper, Extreme Learning Machine method is used to model the rate of material transfer as an effective parameter in process speed and surface quality. Using neural network model of Extreme Learning Machine, the mean squared error (MSE) for the material transfer rate in the learning data is 0.000,387 and in the test data is 0.001,7. While, the mean error squared for the average reset layer thickness, calculated in the learning data, was 0.000,214 and in the test data was 0.001,7. The proposed algorithm of Extreme Learning Machine with experimental results has high accuracy in predicting a process output parameters.

Keywords: Electro Discharge Coating, Average Layer Thickness, Material Transfer Rate, Extreme Learning Machine

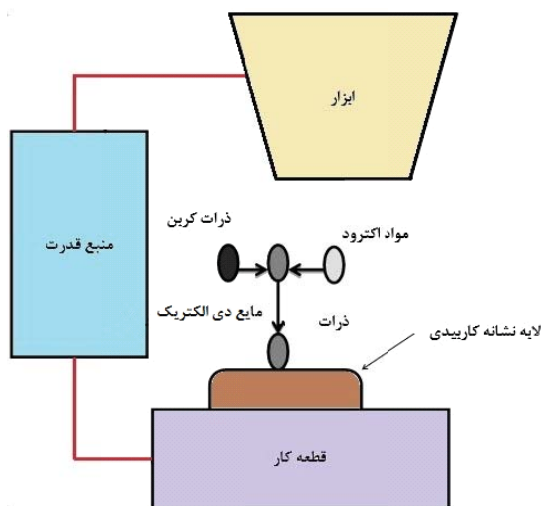
M.R. Marki¹, Instructor, Department of Mechanics and Materials Engineering, Birjand University of Technology, Birjand
H. Tagimalek^{2*}, PhD Student, Department of Engineering, Semnan University
M. Azargoman³, PhD Student, Department of Engineering, Semnan University
R. Karami⁴, M.Sc. Student, Department of Engineering, Urmia University

*Corresponding Author, Postal Code: 35131-19111, Semnan, IRAN
h_tagimalek@semnan.ac.ir

فهرست علائم و اختصارات

MC	لایه کاربیدی
M	واکنش شیمیایی بین مواد حاصل از فرسایش الکتروود
C	ذرات کربن
EDC	لایه‌نشانی با استفاده از تخلیه الکتریکی
H ⁺	معکوس ماتریس موور - پنروز
Cu-SiC	الکتروود کامپوزیتی
CP	فشار تراکم
ST	دمای سینترینگ
Ip	جریان الکتریکی
Ton	زمان روشنی پالس
Toff	زمان خاموشی پالس
MTR	نرخ انتقال مواد از الکتروود به قطعه کار
LT	متوسط ضخامت تشکیل مواد بر روی قطعه کار

لایه‌نشانی با استفاده از تخلیه الکتریکی (EDC)^۱ معرفی کرده‌اند. لایه‌نشانی با استفاده از تخلیه الکتریکی باعث بهبود سطح قطعه شد. ابزار مورد استفاده از جنس متالورژی پودر بوده است. به دلیل ارتباط مستقیم با مواد الکتروود و حضور مایع دی‌الکتریک یک سطح سخت کاربیدی بر روی قطعه کار تشکیل می‌شود. شماتیک فرآیند EDC در شکل ۱ نشان داده شده است. فرآیند EDC با سایش ابزار که به دنبال ایجاد کاربیده‌های سخت (MC) از طریق واکنش شیمیایی بین مواد حاصل از فرسایش الکتروود (M) و ذرات کربن (C) حاصل از تجزیه هیدروکربن در دمای بالا می‌باشد، شروع می‌شود و لایه کاربیدی (MC) در عرض چند دقیقه بر روی سطح قطعه کار ایجاد می‌شود. اساس کار فرآیند EDC انتقال مواد الکتروود به روی سطح قطعه کار می‌باشد که با کنترل فشار تراکم و دمای سینترینگ می‌توان ویژگی‌های ابزار متالورژی پودر را تعیین کرد [۱-۲].



شکل (۱): شما تیک فرآیند EDC

مطالعه به منظور بهبود عملکرد و افزایش مقاومت مس خالص (به عنوان الکتروود ابزار) در برابر سایش الکتریکی طی فرآیند تخلیه الکتریکی با استفاده از ساختار بسیار ریز انجام شده است [۳]. برای این منظور از روش اکستروژن در کانال‌های هم مقطع زاویه‌دار^۲ استفاده شده که به طور کلی با ریز شدن ساختار کریستالی الکتروودهای مسی سایش الکتریکی آن‌ها کاهش می‌یابد. از طرفی، مقاومت در برابر سایش الکتریکی الکتروود مسی با شکل‌گیری دانه‌هایی در حد نانو به میزان قابل ملاحظه‌ای افزایش یافته است [۳]. خسروزاده و شبرگرد، تأثیر هم زمان افزودن نانو ذرات SiO₂

مقدمه

فرآیند تخلیه الکتریکی یک فرآیند ماشینکاری الکتریکی-حرارتی غیرسستی است که با کنترل دقیق جرقه بین الکتروود و قطعه کار در حضور یک مایع دی‌الکتریک ماشینکاری انجام شده و الکتروود به عنوان ابزار برش در نظر گرفته می‌شود. این فرآیند به طور گسترده برای ماشینکاری مواد سخت استفاده می‌شود. برخلاف سایر روش‌های ماشینکاری، فرآیند تخلیه الکتریکی برای برداشت مواد از سطح قطعه کار از تماس فیزیکی ابزار و قطعه کار استفاده نمی‌کند. از آنجا که در فرآیند تخلیه الکتریکی هیچ تماسی بین الکتروود و قطعه کار نیست، بنابراین هیچ نیروی ابزاری در این فرآیند وجود ندارد. به همین منظور از این فرآیند برای صنعت قالب‌سازی در چند دهه اخیر استفاده شده است. سایش ابزار، تشکیل لایه نازک و ترد در سطح ماشینکاری شده که متأثر از لایه دوباره منجمد شده‌ای (لایه سفید) تشکیل می‌شود. لایه سفید پس از ذوب شدن سطح از حوضچه مذاب خارج نشده و مجدداً در سطح قطعه انجماد یافته است. حبس شدن و انجماد لایه سفید از معایب این فرآیند محسوب می‌شود. سایش ابزار در این فرآیند تا حدی قابل کنترل بوده و دستیابی به شرایط بدون سایش ابزار غیر ممکن به نظر می‌رسد. محققان که به کمک فرآیند تخلیه الکتریکی و سیال دی‌الکتریک هیدروکربن، روش

1 Electro Discharge Coating
2. ECAP

فرآیند EDC، توسط الکتروود متالورژی پودر از جنس مس- تنگستن می‌باشد. در این بررسی، پارامترهای ورودی از جمله، فشار تراکم (CP)، دمای سینترینگ (ST)، جریان الکتریکی (Ip)، زمان روشنی پالس (Ton)، زمان خاموشی پالس (Toff) و پارامترهای خروجی از جمله نرخ انتقال مواد از الکتروود به قطعه کار (MTR) و متوسط ضخامت تشکیل مواد بر روی قطعه کار (LT) در نظر گرفته شده است. در ادامه، به توضیح نحوه مدل‌سازی با شبکه عصبی ماشین یادگیری شدید پرداخته می‌شود. سپس، توضیح داده‌های آزمایش مورد استفاده در این مقاله عنوان شده و نتایج بدست آمده مورد بحث قرار می‌گیرد و به منظور ارزیابی مدل ارائه شده نتایج حاصل با نتایج سایر پژوهشگران مورد مقایسه قرار خواهد گرفت.

ماشین یادگیری شدید

یادگیری در لغت به معنای بدست آوردن دانش و فهم آن از طریق مطالعه، آموزش و تجربه برای بهبود عملکرد تعریف شده است. اما یادگیری ماشین عبارت است از این که چگونه می‌توان برنامه‌ای نوشت که از طریق تجربه یادگیری قبلی، عملکرد خود را بهتر کند. یادگیری ممکن است باعث تغییر در ساختار برنامه و یا داده‌ها شود [۹].

ماشین‌های یادگیری شدید^۷ ELM یکی از روش‌های موفق اخیر در یادگیری ماشین، به خصوص برای انجام الگوی طبقه‌بندی است [۱۰]. این روش در واقع یک الگوریتم جدید برای تک لایه‌های پنهان شبکه عصبی پیش‌خور^۸ می‌باشد که دارای سرعت یادگیری بسیار بالا و عملکرد کلی خوبی بوده است [۱۱]. در تفاوت بین یادگیری انسان و ماشین می‌توان گفت انسان از طریق تعامل با محیط بیرونی یاد می‌گیرد اما از طریق نوشتن برنامه می‌توان به ماشین گفت که چه باید بکند. همچنین، از طریق نمایش مثال‌های متعدد می‌توان ماشین را وادار به یادگیری نمود. ماشین می‌تواند از طریق تجربه محیط واقعی یاد بگیرد. هدف از یادگیری ماشین ساخت سیستم‌های کامپیوتری است که می‌تواند از تجربه خود عمل انطباق و یادگیری را اجرا کند. در مقایسه با الگوریتم‌های یادگیری معمولی برای شبکه‌های عصبی که در شبکه‌های تکرار شونده نیاز به تنظیم پارامترها دارند، روش ELM یک الگوریتم یادگیری در جهت SLFNS بوده که بصورت تصادفی گره‌های پنهان را انتخاب کرده و وزن خروجی SLFNS را بصورت آنالیز تحلیلی تعیین می‌کند [۱۰].

به دی‌الکتریک پایه نفتی و اعمال ارتعاشات آلتراسونیک به ابزار در فرآیند ماشینکاری تخلیه الکتریکی آلیاژ تیتانیوم-Ti-6Al-4V را بررسی کردند. نتایج نشان می‌دهد که در ماشین کاری تخلیه الکتریکی با افزودن نانو ذرات پودری به دی‌الکتریک به همراه ارتعاشات آلتراسونیک ابزار بهینه‌ترین شرایط برای نرخ براده برداری و بالا بردن صافی سطح را به همراه دارد [۴]. آقای تورس^۳ و همکارانش بر روی قابلیت ماشینکاری قطعه کار از جنس TiB_2 با الکتروود از جنس مس در فرآیند تخلیه الکتریکی را مطالعه کردند. آن‌ها سه پارامتر، نرخ براده برداری، سایش ابزار و صافی سطح را در این فرآیند مورد بررسی قرار دادند. نتایج نشان داد که مهم‌ترین عامل در نرخ براده برداری و صافی سطح، شدت جریان است. در حالی که در مورد سایش ابزار، زمان پالس مهم‌ترین عامل می‌باشد [۵]. لی^۴ و همکارانش، مطالعه و بررسی ویژگی‌های ماشین کاری آلیاژ تیتانیوم Ti-6Al-4V با الکتروود کامپوزیتی Cu-SiC و تجزیه و تحلیل توپوگرافی سطح، میکروساختار زیرسطحی و طیف‌سنجی پراکندگی انرژی در ماشین کاری تخلیه الکتریکی انجام شد [۶]. دیوودی^۵ و همکارانش به بهبود یکپارچگی سطح فولاد ابزار AISI D3 با استفاده از چرخش ابزار در فرآیند تخلیه الکتریکی با مطالعه و بررسی بر روی پارامترهای خروجی از جمله صافی سطح، میکرو ترک و لایه‌های تحت تأثیر پرداخته‌اند [۷]. همچنین، پژوهش و بررسی پوشش سرامیک (Ti+B4C+AL) بر روی سطح آلومینیومی با استفاده از روش لایه‌نشانی با استفاده از تخلیه الکتریکی انجام شده است. در این تحقیق ابزار به وسیله متالورژی پودر از جنس تیتانیوم، برم کارباید و آلومینیوم ساخته شده که توسط فرآیند EDC باعث ایجاد روکش بر روی قطعه کار از جنس آلومینیوم می‌شود. پارامترهای ابزار شامل ترکیب مواد الکتروود و فشار تراکم و پارامترهای تنظیمی مختلف دیگر از جمله شدت جریان و زمان روشنی پالس و پارامترهای خروجی از جمله نرخ رسوب مواد، نرخ سایش ابزار و متوسط ضخامت لایه ایجاد شده بر روی قطعه کار می‌باشد که با طراحی آزمایش به روش تاگوچی^۶ به منظور رسیدن به بهترین مقادیر ورودی به منظور حصول مقادیر بهتر MDR، TWR و LT انجام شده است [۸].

هدف از این پژوهش، بهینه‌سازی به کمک ماشین یادگیری شدید به منظور پیش‌بینی مقادیر MTR و LT در

3. Torres
4. Li
5. Dwivedi
6. Taguchi

7. Extreme Machine Learning
8. SLFNS

ماشین یادگیری سریع

در یادگیری ماشین جهت تخمین توابع وابسته به ورودی‌های زیاد و پیچیده، از شبکه‌های عصبی استفاده می‌شود. یکی از انواع شبکه‌های عصبی، شبکه عصبی پیشرو است. کاربرد این شبکه‌ها تخمین نگاشت‌های غیرخطی پیچیده از رویدادهای ورودی است. علاوه بر این، در مسائلی که حل آن‌ها با روش‌های قدیمی پارامتریک دشوار است، از این شبکه‌ها استفاده می‌شود. پس انتشار الگوریتم، که به یادگیری معروفی بوده که در شبکه عصبی پیشرو استفاده می‌شود. در این روش، گرادینان‌ها با انتشار از خروجی محاسبه می‌شود. از مشکلاتی که در این شبکه‌ها وجود دارد می‌توان به مینیمم محلی، زمان آموزش طولانی و کند بودن اشاره کرد. هدف از ماشین یادگیری سریع، حل این مسائل و مشکلات می‌باشد [۱۲].

در شبکه عصبی پیشرو تک لایه پنهان برای N نمونه دل‌خواه (x, i, t) که در آن SLFN استاندارد با \tilde{N} نود پنهان تابع فعالیت $g(x)$ به صورت روابط (۱-۲) مدل می‌شود.

$$Xi = \{Xi1, Xi2, \dots, Xin\}tRn \in \quad (1)$$

$$\{ti1, ti2, \dots, tin\}T \in RM, ti \quad (2)$$

$\sum_{i=1}^{\tilde{N}} \beta_{ig}(w_i x_i + b_i) = t_i$
در روابط (۱-۲)، W_i بردار وزن است که ورودی‌ها و i امین نود پنهان را به هم وصل کرده و β_i بردار وزن است که i امین نود پنهان را به نود خروجی متصل می‌کند.
روابط (۱-۲) را می‌توان به صورت زیر نوشت:

$$HB = T(Y), \quad (3)$$

که برای H و B در رابطه (۳) داریم:

$$H = \begin{bmatrix} g(w_1 x_1 + b_1) & \dots & g(w_{\tilde{N}} x_1 + b_1) \\ \vdots & \ddots & \vdots \\ g(w_1 x_N + b_1) & \dots & g(w_{\tilde{N}} x_n + b_{\tilde{N}}) \end{bmatrix} N \times \tilde{N} \quad (4)$$

$$B = \begin{bmatrix} B_1^T & T_1^T \\ \vdots & \vdots \\ B_{\tilde{N}}^T & T_{\tilde{N}}^T \end{bmatrix} N \times \tilde{N} \quad (5)$$

الگوریتم ماشین یادگیری سریع بیان می‌کند که در صورتیکه تابع فعالیت مشتق‌پذیر نامتناهی باشد می‌توان W_i و b_i را به طور تصادفی انتخاب کرد. در این صورت شبکه عصبی تبدیل به یک سیستم خطی خواهد شد. در این سیستم خطی راه حل با کمترین میزان مربعات خطا به صورت رابطه ذیل خواهد بود:

$$\hat{B} = H^+ T, \quad (6)$$

که در آن، H^+ معکوس ماتریس موور-پنروز^{۱۰} است. روش‌های

زیادی برای یافتن معکوس ماتریس موور-پنروز وجود دارد. از این روش‌ها می‌توان به روش‌های مبتنی بر تکرار، ضرب متعامد، متعامدسازی و تجزیه مقدار منفرد^{۱۱} اشاره کرد. روش متعامدسازی و مبتنی بر تکرار دارای محدودیت‌هایی هستند. زیرا، در این روش‌ها از جستجو و تکرار استفاده می‌شود که در ELM از آن پرهیز می‌کنیم. روش ضرب متعامد، زمانی استفاده می‌شود که $H^T \times H$ ماتریس تکین نباشد و $H^+ = (H^T \times H)^{-1} H^T$ برقرار باشد. به دلیل این محدودیت، این روش در همه کاربردها استفاده نمی‌شود. به همین دلیل در ELM از روش SVD استفاده می‌شود. تاکنون توسعه‌های متعددی برای ELM ارائه شده است [۱۳]. در این مقاله از چهار توسعه جهت مدل‌سازی محل خطای نرم‌افزار استفاده شده است.

پارامترهای فرآیند

در پژوهش حاضر، روشی جدید برای مدل‌سازی نرخ انتقال مواد از ابزار به قطعه و متوسط ضخامت لایه تشکیل شده بر روی قطعه با استفاده از شبکه عصبی ماشین یادگیری شدید در فرآیند لایه‌نشانی به وسیله تخلیه الکتریکی ارائه شده است. همچنین، به منظور ارزیابی مدل ارائه شده و صحت آن از نتایج آزمایش‌های تجربی پاتواری^{۱۱} و همکاران [۲] استفاده شده است که نحوه انجام آزمایش‌ها و پارامترهای آن در این بخش توضیح داده شده است. آزمایش توسط یک دستگاه EDM مدل Victor-I، ساخت شرکت Ltd., Pune Id انجام شده است. ابزار متالورژی پودر شامل ۷۵ درصد تنگستن و ۲۵ درصد مس بوده که برای انتقال مواد روی سطح قطعه‌کار در نظر گرفته شده است. برای اندازه‌گیری MTR تفاوت وزن قطعه کار قبل و بعد از فرآیند توسط ترازوی الکترونیکی اندازه‌گیری شده است. همچنین جهت تعیین مقدار LT، قطعه کار توسط وایرکات برش خورده و پس از آماده‌سازی سطح برش، ضخامت لایه توسط میکرومتر نوری به فاصله مشخص ۲۰۰ میکرومتر از یکدیگر اندازه‌گیری شده و سپس بین مقادیر حاصل، میانگین گرفته شده است. پارامترهای فرآیند و خروجی‌های اندازه‌گیری شده در جداول ۱-۲ نشان داده شده است. نمونه قطعه‌کار به همراه مواد رسوبی بر روی آن و تصویر میکروگرافی از ساختار لایه رسوبی در شکل‌های ۳-۲ نشان داده شده است. مقدار صافی سطح قطعه‌کار بین ۳ تا ۱۵ میکرومتر و مقادیر منفی

10. SVD
11. Patowari

9. Moore - Penrose


جدول (۲): نتایج آزمایش [۲].

شماره آزمایش	فشار تراکم (CP) و MPa	دمای سینترینگ (ST) و °C	شدت جریان (Ip) و A	زمان روشنی (Ton) و Hs	زمان خاموشی (Toff) و Hs	نرخ انتقال مواد mg/min و MTR
۱	۱۲۰	۷۰۰	۸	۱۹	۱۹	۴/۹۱
۲	۱۸۰	۷۰۰	۸	۱۹	۱۹	۵/۰۵
۳	۲۴۰	۷۰۰	۸	۱۹	۱۹	۳/۰۴
۴	۳۰۰	۷۰۰	۸	۱۹	۱۹	-/۹۳
۵	۱۲۰	۷۰۰	۸	۲۹	۲۸	۶/۳
۶	۱۸۰	۷۰۰	۸	۲۹	۲۸	۸/۵۲
۷	۲۴۰	۷۰۰	۸	۲۹	۲۸	۷/۱۳
۸	۳۰۰	۷۰۰	۸	۲۹	۲۸	۳/۱۲
۹	۱۲۰	۷۰۰	۸	۳۹	۳۸	۵/۴۳
۱۰	۱۸۰	۷۰۰	۸	۳۹	۳۸	۹/۴۶
۱۱	۲۴۰	۷۰۰	۸	۳۹	۳۸	۶/۸۶
۱۲	۳۰۰	۷۰۰	۸	۳۹	۳۸	۱/۱۱
۱۳	۱۲۰	۷۰۰	۸	۵۹	۵۸	۸/۱۴
۱۴	۱۸۰	۷۰۰	۸	۵۹	۵۸	۱۰/۸۶
۱۵	۲۴۰	۷۰۰	۸	۵۹	۵۸	۴/۹۲
۱۶	۳۰۰	۷۰۰	۸	۵۹	۵۸	۶/۰۲
۱۷	۱۲۰	۷۰۰	۸	۱۲۶	۱۲۶	۵۶/۳۷
۱۸	۱۸۰	۷۰۰	۸	۱۲۶	۱۲۶	۲۸/۲۷
۱۹	۲۴۰	۷۰۰	۸	۱۲۶	۱۲۶	۲۲/۵۴
۲۰	۳۰۰	۷۰۰	۸	۱۲۶	۱۲۶	۱۳/۶۱
۲۱	۱۲۰	۷۰۰	۸	۲۵۶	۲۵۶	۱۲۷/۷۳
۲۲	۱۸۰	۷۰۰	۸	۲۵۶	۲۵۶	۸۷/۷۴
۲۳	۲۴۰	۷۰۰	۸	۲۵۶	۲۵۶	۶۰/۴
۲۴	۳۰۰	۷۰۰	۸	۲۵۶	۲۵۶	۲۷/۹۴
۲۵	۱۲۰	۷۰۰	۸	۳۸۶	۳۸۶	۱۷۲/۵۶
۲۶	۱۸۰	۷۰۰	۸	۳۸۶	۳۸۶	۱۰۷/۴۶
۲۷	۲۴۰	۷۰۰	۸	۳۸۶	۳۸۶	۱۰۴/۵۹
۲۸	۳۰۰	۷۰۰	۸	۳۸۶	۳۸۶	۶۸/۵۷
۲۹	۱۲۰	۷۰۰	۴	۱۲۶	۱۲۶	۷/۹۵
۳۰	۱۸۰	۷۰۰	۴	۱۲۶	۱۲۶	۶/۰۸
۳۱	۲۴۰	۷۰۰	۴	۱۲۶	۱۲۶	۶/۱۷
۳۲	۳۰۰	۷۰۰	۴	۱۲۶	۱۲۶	۶/۱۴
۳۳	۱۲۰	۷۰۰	۴	۲۵۶	۲۵۶	۱۱/۴۶
۳۴	۱۸۰	۷۰۰	۴	۲۵۶	۲۵۶	۷/۴
۳۵	۲۴۰	۷۰۰	۴	۲۵۶	۲۵۶	۶/۶
۳۶	۳۰۰	۷۰۰	۴	۲۵۶	۲۵۶	۲/۴۵
۳۷	۱۲۰	۷۰۰	۴	۳۸۶	۳۸۶	۵۸/۵۴
۳۸	۱۸۰	۷۰۰	۴	۳۸۶	۳۸۶	۳۴/۱۸
۳۹	۲۴۰	۷۰۰	۴	۳۸۶	۳۸۶	۳۷/۷۲
۴۰	۳۰۰	۷۰۰	۴	۳۸۶	۳۸۶	۲۰/۴۱
۴۱	۱۲۰	۷۰۰	۱۲	۱۹	۱۹	۳/۹۴
۴۲	۱۸۰	۷۰۰	۱۲	۱۹	۱۹	۳/۲
۴۳	۲۴۰	۷۰۰	۱۲	۱۹	۱۹	۱/۴۷
۴۴	۳۰۰	۷۰۰	۱۲	۱۹	۱۹	-/۴
۴۵	۱۲۰	۷۰۰	۱۲	۲۹	۲۸	۷/۶۱
۴۶	۱۸۰	۷۰۰	۱۲	۲۹	۲۸	۵/۴۱
۴۷	۲۴۰	۷۰۰	۱۲	۲۹	۲۸	-/۲۴
۴۸	۳۰۰	۷۰۰	۱۲	۲۹	۲۸	-/۴۷
۴۹	۱۲۰	۷۰۰	۱۲	۳۹	۳۸	۵/۳۹
۵۰	۱۸۰	۷۰۰	۱۲	۳۹	۳۸	۶/۳۴
۵۱	۲۴۰	۷۰۰	۱۲	۳۹	۳۸	۱/۷۷
۵۲	۳۰۰	۷۰۰	۱۲	۳۹	۳۸	-/۱

MTR نشان دهنده بیشتر بودن مقدار MRR از نرخ انتقال مواد می باشد [۲].



شکل (۲): قطعه نمونه به همراه لایه رسوبی تشکیل شده بر روی سطح [۲].



شکل (۳): میکروساختار لایه رسوبی [۲].

جدول (۱): شرایط فرآیند [۲].

پارامترها	وضعیت
درصد ترکیب مواد الکتروود	۷۵ درصد تنگستن و ۲۵ درصد مس
فشار تراکم (CP)	۱۲۰ - ۱۸۰ - ۲۴۰ و ۳۰۰ مگاپاسکال
دمای سینترینگ (ST)	۷۰۰ و ۹۰۰ درجه سانتیگراد
شدت جریان Ip	۴-۸-۱۰ و ۱۲ آمپر
زمان پالس	۱۹ تا ۳۸۶ میکروثانیه
پلاریته ابزار	منفی
نسبت زمان ماشینکاری به کل بازه زمانی	حداقل ۵۰ درصد زمان روشنی پالس و حداکثر ۷۰ درصد زمان روشنی پالس
ولتاژ گپ	برای کنترل گپ، ولتاژ گپ بین ۴۰ تا ۴۵ ولت تنظیم شده است.
زمان فرآیند	۵ دقیقه

جدول (۲): ادامه.

شماره آزمایش	فشار تراکم (CP) و MPa	دهای سیتترینگ (ST) و OC	شدت جریان (Ip) و A	زمان روشنی (Ton) و μs	زمان خاموشی (Toff) و μs	نرخ انتقال مواد mg/min و MTR
۵۳	۱۲۰	۷۰۰	۱۲	۵۸	۵۹	۹/۸۷
۵۴	۱۸۰	۷۰۰	۱۲	۵۸	۵۹	۳/۷۳
۵۵	۲۴۰	۷۰۰	۱۲	۵۸	۵۹	۱/۲۵
۵۶	۳۰۰	۷۰۰	۱۲	۵۸	۵۹	۰/۳۷
۵۷	۱۲۰	۷۰۰	۶	۱۲۶	۵۴	۵۱/۷۶
۵۸	۱۲۰	۷۰۰	۶	۲۵۶	۱۰۸	۸۹/۹۵
۵۹	۱۲۰	۷۰۰	۱۰	۱۲۶	۵۴	۱۰۲/۹۱
۶۰	۱۲۰	۷۰۰	۱۰	۲۵۶	۱۰۸	۱۹۰/۸۴
۶۱	۱۲۰	۹۰۰	۸	۱۹	۱۹	۴/۹۸
۶۲	۱۸۰	۹۰۰	۸	۱۹	۱۹	۱/۷۷
۶۳	۲۴۰	۹۰۰	۸	۱۹	۱۹	۱/۴
۶۴	۳۰۰	۹۰۰	۸	۱۹	۱۹	۱/۰۸
۶۵	۱۲۰	۹۰۰	۸	۲۸	۲۹	۴/۸۵
۶۶	۱۸۰	۹۰۰	۸	۲۸	۲۹	۱/۳۸
۶۷	۲۴۰	۹۰۰	۸	۲۸	۲۹	۰/۲۷
۶۸	۳۰۰	۹۰۰	۸	۲۸	۲۹	-۰/۵
۶۹	۱۲۰	۹۰۰	۸	۳۸	۳۹	۶/۶۵
۷۰	۱۸۰	۹۰۰	۸	۳۸	۳۹	۰/۷۸
۷۱	۲۴۰	۹۰۰	۸	۳۸	۳۹	-۰/۷۶
۷۲	۳۰۰	۹۰۰	۸	۳۸	۳۹	-۱/۵۲
۷۳	۱۲۰	۹۰۰	۸	۵۸	۵۹	۵/۷۷
۷۴	۱۸۰	۹۰۰	۸	۵۸	۵۹	۰/۸۹
۷۵	۲۴۰	۹۰۰	۸	۵۸	۵۹	-۱/۵۲
۷۶	۳۰۰	۹۰۰	۸	۵۸	۵۹	-۵/۰۸
۷۷	۱۲۰	۹۰۰	۸	۱۲۶	۵۴	۶/۱۷
۷۸	۱۸۰	۹۰۰	۸	۱۲۶	۵۴	-۱/۱۱
۷۹	۲۴۰	۹۰۰	۸	۱۲۶	۵۴	-۵/۰۷
۸۰	۳۰۰	۹۰۰	۸	۱۲۶	۵۴	-۵/۷۷
۸۱	۱۲۰	۹۰۰	۱۲	۱۹	۱۹	۱۳/۱۶
۸۲	۱۸۰	۹۰۰	۱۲	۱۹	۱۹	۶/۱۴
۸۳	۲۴۰	۹۰۰	۱۲	۱۹	۱۹	۱/۲۳
۸۴	۳۰۰	۹۰۰	۱۲	۱۹	۱۹	۰/۳۷
۸۵	۱۲۰	۹۰۰	۱۲	۲۸	۲۹	۱۶/۹۴
۸۶	۱۸۰	۹۰۰	۱۲	۲۸	۲۹	۲/۵۷
۸۷	۲۴۰	۹۰۰	۱۲	۲۸	۲۹	-۳/۱۳
۸۸	۳۰۰	۹۰۰	۱۲	۲۸	۲۹	-۱/۶۵
۸۹	۱۲۰	۹۰۰	۱۲	۳۸	۳۹	۱۶/۹۸
۹۰	۱۸۰	۹۰۰	۱۲	۳۸	۳۹	۵/۳۶
۹۱	۲۴۰	۹۰۰	۱۲	۳۸	۳۹	-۴/۲۹
۹۲	۳۰۰	۹۰۰	۱۲	۳۸	۳۹	-۳/۰۹
۹۳	۱۲۰	۹۰۰	۱۲	۵۸	۵۹	۱۲/۵۱
۹۴	۱۸۰	۹۰۰	۱۲	۵۸	۵۹	۲/۰۱
۹۵	۲۴۰	۹۰۰	۱۲	۵۸	۵۹	-۳/۱۴
۹۶	۳۰۰	۹۰۰	۱۲	۵۸	۵۹	-۰/۵۲
۹۷	۱۲۰	۹۰۰	۱۲	۱۲۶	۵۴	۱۵/۰۹
۹۸	۱۸۰	۹۰۰	۱۲	۱۲۶	۵۴	-۵/۶۷
۹۹	۲۴۰	۹۰۰	۱۲	۱۲۶	۵۴	-۱۳/۸۴
۱۰۰	۳۰۰	۹۰۰	۱۲	۱۲۶	۵۴	-۱۱/۸۹

بحث و نتایج


در پژوهش حاضر به منظور مدل کردن متوسط ضخامت لایه بازنشانی شده و نرخ انتقال مواد از ابزار به قطعه کار در فرآیند لایه‌نشانی به کمک فرآیند تخلیه الکتریکی از شبکه عصبی ماشین یادگیری شدید استفاده شد. بدین منظور از جعبه ابزار ماشین یادگیری شدید در نرم‌افزار متلب استفاده شده است [۱۴]. در مدل ارائه شده پارامترهای زمان روشنی پالس، زمان خاموشی پالس، فشار تراکم، شدت جریان و دمای سیتترینگ به عنوان پارامترهای ورودی شبکه عصبی و متوسط ضخامت لایه بازنشانی شده و نرخ انتقال مواد از ابزار به قطعه کار به عنوان پارامترهای خروجی شبکه عصبی در نظر گرفته شده‌اند. در شبکه به کار رفته از تابع پایه شعاعی به عنوان تابع کرنل ماشین یادگیری شدید استفاده شد. پارامترهای ماشین یادگیری شدید مورد استفاده جهت مدل‌سازی هر یک از خروجی‌ها مطابق با داده‌های جدول ۳ می‌باشد.

جدول (۳): پارامترهای ماشین بردار یادگیری شدید.


پارامتر	نرخ انتقال مواد	متوسط ضخامت لایه
پارامتر کرنل (σ2)	۲/۹۸۴۴	۸۳/۷۸۶۹
ثابت تنظیم (C)	۱۷۱۴۷	۸/۳۰۱۵ × ۱۰۸

داده‌های آزمایش به دو بخش جداگانه آموزش و آزمون تقسیم شده‌اند. از میان ۱۰۰ داده حاصل از آزمایش‌ها تجربی، ۶۷ داده برای آموزش شبکه عصبی و ۳۳ داده برای آزمون آن بکار رفتند. نتایج بدست آمده از مدل ماشین یادگیری شدید برای مدل‌سازی نرخ انتقال مواد و متوسط ضخامت لایه در داده‌های آموزش در شکل‌های ۴ و ۵ نشان داده شده است. مقادیر مدل‌سازی شده توسط مدل پیشنهادی برای داده‌های آزمون در شکل‌های ۶ و ۷ نشان داده شده است. مقدار میانگین مربعات خطا (MSE) برای نرخ انتقال مواد در داده‌های آموزش ۰/۰۰۰۳۸۷ و در داده‌های آزمون ۰/۰۰۱۰۷ با استفاده از مدل شبکه عصبی ماشین یادگیری شدید بدست آمد. مقدار میانگین مربعات خطا برای متوسط ضخامت لایه بازنشانی شده در داده‌های آموزش ۰/۰۰۰۲۱۴ و در داده‌های آزمون ۰/۰۰۱۰۷ محاسبه شد. مقدار خطای بدست آمده با استفاده از شبکه عصبی پیشخور به همراه باز انتشار خطا برای نرخ انتقال مواد و متوسط ضخامت لایه بازنشانی شده از مقادیر بیشتری برخوردار بوده است که در جدول ۴ مقادیر مدل‌سازی شده شبکه عصبی باز انتشار خطا نشان داده شده است. بررسی نتایج نشان می‌دهد مدل پیشنهاد شده در این پژوهش در مقایسه با پژوهش‌های پیشین به دقت‌های بالاتری دست یافته است و به عبارت دیگر ماشین یادگیری شدید قابلیت‌های بالاتری در مدل‌سازی فرآیند لایه‌نشانی به کمک تخلیه الکتریکی دارد.


ارائه الگوریتمی براساس یادگیری ماشین شدید به منظور نرخ انتقال مواد در فرآیند EDC (علمی-ترویجی)




شکل (۴): مقادیر مدل سازی نرخ انتقال مواد برای داده های آموزش.



شکل (۵): مقادیر مدل سازی متوسط ضخامت لایه برای داده های آموزش.



شکل (۶): مقادیر مدل سازی نرخ انتقال مواد برای داده های آزمون.



شکل (۷): مقادیر مدل سازی متوسط ضخامت لایه برای داده های آزمون.

جدول (۴): مقایسه نتایج بدست آمده توسط ماشین یادگیری شدید با نتایج پاتواری و همکاران [۲].

میانگین مربعات خطا در متوسط ضخامت لایه		میانگین مربعات خطا در نرخ انتقال مواد		مدل
آزمون	آموزش	آزمون	آموزش	
۰/۰۰۱۷	۰/۰۰۰۲۱۴	۰/۰۰۱۷	۰/۰۰۰۳۸۷	ماشین بردار یادگیری شدید
۰/۰۰۲	۰/۰۰۱۶	۰/۰۰۳۸	۰/۰۰۱۴	شبکه پیشخور با باز انتشار خطا [۲]

Electrical Discharge Machining", *Modarres Mech. Engineering*, Vol. 14, No. 1, pp. 97-105, 2014.

- [4] Khosrozadeh, B. and Shabgard, M.R., "Investigating the Effect of Simultaneous Ultrasonic Vibration of Tool and Addition of SiO₂ Nanoparticles into the Dielectronic Machining Characteristics of Titanium Alloy Ti-6Al-4V in EDM Process", *Modarres Mech. Engineering*, Vol. 15, No. 13, pp. 311-317, 2015.
- [5] Torres, A., Luis, C.J., and Puertas, I., "EDM Machinability and Surface Roughness Analysis of TiB₂, Using Copper Electrodes", *J. Alloys and Compounds*, Vol. 69, pp. 337-347, 2017.
- [6] Li, L., Feng, L., Bai, X., and Li, Z.Y., "Surface Characteristics of Ti-6Al-4V Alloy by EDM with Cu-SiC Composite Electrode", *Applied Surface Sci.*, Vol. 388, pp. 546-550, 2016.
- [7] Dwivedi, A.P. and Choudhury, S.K., "Improvement in the Surface Integrity of AISI D3 Tool Steel Using Rotary Tool Electric Discharge Machining Process", *Procedia Tech.*, Vol. 23, pp. 280-287, 2016.
- [8] Ahmed, A., "Deposition and Analysis of Composite Coating on Aluminum Using Ti-B₄C Powder Metallurgy Tools in EDM", *Materials and Manufacturing Processes*, Vol. 31, No. 4, pp. 467-474, 2016.
- [9] Bagheri Golzar, C., Karami Sorkhe Chaghiaie, F., Eftekhari Moghadam, A., and Boroumandnia, A., "Machine Learning and Explaining Its Significant Algorithms", *The 4th Iranian Conference on Electrical and Electronic Engineering, Islamic Azad University, Gonabad*, 2012.
- [10] Rong, H.J., Ong, Y.S., Tan, A.H., and Zhu, Z., "A Fast Pruned-Extreme Learning Machine for Classification Problem", *Neurocomputing*, Vol. 72, No. 1-3, pp. 359-366, 2008.
- [11] Xu, Z., Yao, M., Wu, Z., and Dai, W., "Incremental Regularized Extreme Learning Machine and Its Enhancement", *Neurocomputing*, Vol. 174, Part. A, pp. 134-142, 2016.
- [12] Huang, G.B., Zhu, Q.Y., and Siew, C.K., "Extreme Learning Machine: Theory and Applications", *Neurocomputing*, Vol. 70, No. 1-3, pp. 489-501, 2006.
- [13] Huang, G., Huang, G.B., Song, S., and You, K., "Trends in Extreme Learning Machines: a Review", *Neural Networks*, Vol. 70, pp. 32-48, 2015.
- [14] Alaba, P.A., Popoola, S.I., Olatomiwa, L., Akanle, M.B., Ohunakin, O., Adetiba, E., Alex, O.D., Atayero, A.A.A., and Wan Daud, W.M.A., "Towards a More Efficient and Cost-Sensitive Extreme Learning Machine: a State-of-the-art Review of Recent Trend", *Neurocomputing*, Vol. 350, pp. 70-90, 2019.

نتیجه گیری

یکی از روش‌های نوین بهبود کیفیت سطح مواد، لایه‌نشانی با کمک فرآیند تخلیه الکتریکی می‌باشد. در این مقاله از روش ماشین یادگیری شدید برای مدل‌سازی این فرآیند استفاده شده است. پارامترهای متوسط ضخامت لایه و نرخ انتقال مواد به عنوان پارامترهای خروجی فرآیند مدل شدند. پارامترهای مؤثر بر روی پارامترهای خروجی، زمان روشنی پالس، زمان خاموشی پالس، شدت جریان، فشار تراکم و دمای سیترینگ در نظر گرفته شدند. بررسی خطاهای مدل پیشنهادی نشان داد که روش ارائه شده به طور قابل قبولی قادر به مدل‌سازی پارامترهای خروجی فرآیند بوده و در مقایسه با مدل پیشنهاد شده توسط پاتواری و همکاران از دقت بالاتری برخوردار است. از نتایج بدست آمده می‌توان دریافت که:

- میانگین مربعات خطا (MSE) برای نرخ انتقال مواد در داده‌های آموزش ۰/۰۰۰,۳۸۷ و در داده‌های آزمون ۰/۰۰۱,۷ با استفاده از مدل شبکه عصبی ماشین یادگیری شدید بدست آمد.
- میانگین مربعات خطا برای متوسط ضخامت لایه‌بازنشانی شده در داده‌های آموزش ۰/۰۰۰,۲۱۴ و در داده‌های آزمون ۰/۰۰۱,۷ محاسبه شد.
- مقدار میانگین خطای مربعات در نرخ انتقال مواد و متوسط ضخامت لایه برای داده‌های آزمون ۰/۰۰۱,۷ بدست آمد که نشان از کاربردی بودن مدل پیشنهادی در بحث مدل‌سازی می‌باشد.

مراجع

- [1] Jameson E.C., *Description and Development of Electrical Discharge Machining (EDM)*, in *Electrical Discharge Machining*, Society of Manufacturing Engineers, Dearborn, Michigan, 2001.
- [2] Patowari, P.K., Saha, P., and Mishra, P.K., "Artificial Neural Network Model in Surface Modification by EDM, Using Tungsten-Copper Powder Metallurgy Sintered Electrodes", *The Int. J. Advanced Manufacturing Tech.*, Vol. 51, No. 5, pp. 627-638, 2010.
- [3] Ranaei, M.A., Afsari, A., Ahmadi Brooghani, S.Y., and Moshksar, M.M., "Investigation on Performance of Ultra Fine Grained Pure Copper as Electrode During