ISSN: 2476-6909; Modares. Mech. Eng. *2026;26(05):307-323.*

Modares Mechanical Engineering

DOI: 10.48311/mme.2026.118727.82926
journal homepage: mme.modares.ac.ir

Evaluation and Prediction of Surface Roughness and Microhardness in the Deep Ball Burnishing Process Using Machine Learning Approach

Javad Kazemi, Amir Rasti*, Alireza Zarhoon

Faculty of Mechanical Engineering, Tarbiat Modares University, Tehran, Iran.

ARTICLE INFO

Article Type
Original Research

Article History
Received: January 06, 2026
Revised: February 08, 2026
Accepted: February 09, 2026
ePublished: March 04, 2026

ABSTRACT

Surface quality of engineering components directly affects their performance and service life. Conventional machining processes, particularly under conditions that induce high surface roughness and tensile residual stresses, are often unable to ensure the desired final surface quality. Consequently, the application of surface enhancement techniques such as deep ball burnishing (DBB) is essential for improving surface integrity. In this study, the combined effects of key DBB process parameters, including ball diameter, penetration depth, and feed rate, on surface quality indices—R_a, R_z, and surface microhardness—were analyzed. Advanced machine learning models were employed for predictive modeling, with the SVR model demonstrating the best performance, achieving R^2 values of 0.925, 0.942, and 0.910 for R_a, R_z, and microhardness, respectively. Although the XGBoost model also produced acceptable predictions, its accuracy was lower than that of SVR. The use of partial dependence plots (PDPs) enabled a quantitative assessment of the relative influence of the input parameters, revealing that burnishing penetration depth was the dominant factor for all outputs, accounting for approximately 41–47% of the predicted variations in surface quality. Nevertheless, ball diameter and feed rate also exhibited substantial contributions, each ranging from approximately 23–30%, highlighting their non-negligible roles in DBB process control and optimization. Overall, this study presents a novel machine-learning-based framework for analyzing and optimizing the DBB process to enhance surface quality.

Keywords: Deep Ball Burnishing, Surface Quality, Microhardness, Machine Learning.

How to cite this article
Kazemi J., Rasti A., Zarhoon A., Evaluation and Prediction of Surface Roughness and Microhardness in the Deep Ball Burnishing Process Using Machine Learning Approach. Modares Mechanical Engineering; *2026;26(05):307-323.*

*Corresponding author's email: a.rasti@modares.ac.ir
*Corresponding ORCID ID: 0000-0002-0138-6764

شاپا: ۷۹۰۹-۲۴۷۶؛ مهندسی مکانیک مدرس. ۳۲۳-۳۰۷:(۰۵)۲۶;۱۴۰۵

مهندسی مکانیک مدرس

DOI: 10.48311/mme.2026.118727.82926

صفحه اصلی مجله: mme.modares.ac.ir

ارزیابی و پیش‌بینی زبری و میکروسختی سطح در فرایند بال‌برنیشینگ عمیق با رویکرد یادگیری ماشین

جواد کاظمی، امیر راستی*، علیرضا زرهون

گروه مهندسی مکانیک، دانشگاه تربیت مدرس، تهران، ایران

اطلاعات مقاله

نوع مقاله

مقاله پژوهشی

تاریخچه مقاله

دریافت: ۱۴۰۴/۱۰/۱۶

بازنگری: ۱۴۰۴/۱۱/۱۹

پذیرش: ۱۴۰۴/۱۱/۲۰

ارائه آنلاین: ۱۴۰۴/۱۲/۱۳

چکیده

کیفیت سطح قطعات مهندسی به‌طور مستقیم بر عملکرد و طول عمر آن‌ها تأثیر می‌گذارد. فرایندهای ماشین‌کاری متداول، به‌ویژه در شرایطی که زبری سطح بالا و تنش‌های کششی ایجاد می‌شود، قادر به تضمین کیفیت نهایی سطح نیستند. در نتیجه، استفاده از روش‌های اصلاح سطح مانند بال‌برنیشینگ عمیق (DBB) برای بهبود کیفیت سطح ضروری است. در این مطالعه، اثر هم‌زمان پارامترهای مؤثر در DBB شامل قطر گوی، عمق نفوذ و نرخ پیشروی بر شاخص‌های کیفیت سطح؛ R_a، R_z و میکروسختی سطح، مورد تحلیل قرار گرفت. با استفاده از مدل‌های پیشرفته یادگیری ماشین، به‌ویژه مدل SVR، پیش‌بینی دقیقی از این شاخص‌ها انجام شد. مدل SVR با R^2 برابر با ۰/۹۲۵، ۰/۹۴۲ و ۰/۹۱ به‌ترتیب برای R_a، R_z و میکروسختی، بهترین عملکرد را از خود نشان داد. همچنین مدل XGBoost نیز نتایج قابل قبولی داشت، اما دقت آن در مقایسه با مدل SVR پایین‌تر بود. به‌کارگیری نمودارهای وابستگی جزئی، امکان ارزیابی کمّی اثرات نسبی پارامترهای ورودی را فراهم کرد، به‌گونه‌ای که عمق نفوذ برنیشینگ به‌عنوان پارامتر غالب در تمامی خروجی‌ها شناسایی شد و در حدود ۴۱ تا ۴۷ درصد از تغییرات پیش‌بینی‌شده کیفیت سطح را به خود اختصاص داد. با این حال، قطر گوی و نرخ پیشروی نیز با سهم‌های قابل‌توجه، هر یک در بازه‌ای حدود ۲۳ تا ۳۰ درصد، تأثیر معناداری بر پارامترهای کیفیت سطح نشان دادند که بیانگر نقش غیرقابل‌چشم‌پوشی آن‌ها در تنظیم و بهینه‌سازی فرایند DBB است. در مجموع، این مطالعه یک رویکرد نوین با استفاده از مدل‌های یادگیری ماشین برای تحلیل و بهینه‌سازی فرایند DBB و بهبود کیفیت سطح ارائه می‌دهد.

کلیدواژه‌ها: بال‌برنیشینگ عمیق، کیفیت سطح، میکروسختی، یادگیری ماشین.

نحوه ارجاع به این مقاله

کاظمی جواد، راستی امیر، زرهون علیرضا، ارزیابی و پیش‌بینی زبری و میکروسختی سطح در فرایند بال‌برنیشینگ عمیق با رویکرد یادگیری ماشین، مهندسی مکانیک مدرس. ۳۲۳-۳۰۷:(۰۵)۲۶;۱۴۰۵

*پست الکترونیکی نویسنده عهده‌دار مکاتبات: a.rasti@modares.ac.ir

*شناسه ارکید نویسنده عهده‌دار مکاتبات: 0000-0002-0138-6764

۱- مقدمه

کیفیت سطح قطعات مهندسی عامل اصلی در تعیین قابلیت اطمینان، رفتار تریبولوژیکی و طول عمر آن‌ها به شمار می‌آید [۱]. فرایندهای متداول ماشین‌کاری، به دلیل ایجاد تنش‌های کششی و زبری زیاد سطح، قادر به تضمین کیفیت مطلوب سطح نیستند. از این رو، بهره‌گیری از فرایندهای اصلاح سطح مانند سنگ‌زنی، هونینگ و غیره به‌منظور بهبود کیفیت سطح اجتناب‌ناپذیر است [۲-۵]. در میان این روش‌ها، بال‌برنیشینگ (Ball Burnishing-BB) به دلیل مزایای فراوانی همچون زمان پردازش کوتاه، صیقلی کردن سطح، افزایش چگالی ناهمواری‌ها و بهبود سختی سطح، توجه زیادی را به خود جلب کرده است [۶]. با این حال، این فرایند با چالش‌هایی مواجه است؛ از جمله عمق نفوذ کم و توزیع محدود تنش فشاری که مانع از دستیابی به بهبودهای قابل توجه در خصوصیات سطح می‌شود. به‌منظور غلبه بر این محدودیت‌ها، بال‌برنیشینگ عمیق با گوی (Deep Ball Burnishing-DBB) به‌عنوان یک راه‌حل نوآورانه معرفی شده است. این روش به‌ویژه در مقایسه با BB توانایی القای تغییرشکل مومسان عمیق‌تر، ایجاد تنش‌های پسماند فشاری پایدارتر و افزایش قابل توجه سختی سطح را فراهم می‌آورد [۷-۱۱]. گزارش‌ها نشان می‌دهد که DBB می‌تواند زبری را تا حدود ۸۰ درصد کاهش و سختی سطح را ۱۵ تا ۳۰ درصد افزایش دهد [۱۲-۱۴]. با وجود مزایای زیاد، رفتار فرایند DBB پیچیده و به پارامترهایی همچون قطر گوی، عمق نفوذ و نرخ پیشروی وابسته است. انتخاب نامناسب این پارامترها می‌تواند منجر به پدیده‌هایی همچون آسیب داکتیل (Ductile)، لایه‌لایه شدن (پوسته‌پوسته شدن) و کاهش تنش‌های فشاری مفید گردد [۱۵-۱۷].

اکثر پژوهش‌های حاضر، بر راهبرد چندگذره با عمق ثابت و استفاده از ابزار لغزشی با نیروهای عمودی بالا تمرکز دارند تا تغییرشکل مومسان لایه‌به‌لایه و به طور کنترل‌شده، انباشته شود و هم‌زمان زبری، سختی و تنش پسماند بهبود یابند. مرورهای تطبیقی انجام‌شده توسط پریادارسینی و همکاران [۱۸] و ژانگ و همکاران [۱۹] این مشاهدات را با بررسی انواع مختلف برنیشینگ؛ شامل برنیشینگ با غلتک، با گوی و برنیشینگ با پلاستیسیته پایین (Low Plasticity Burnishing-LPB)، گسترش داده‌اند. پریادارسینی و همکاران [۱۸] اشاره کردند که در میان این روش‌ها، LPB اغلب تنش‌های پسماند فشاری عمیق‌تر و پایدارتر، زبری سطح کمتر و عملکرد خستگی بهتری به‌ویژه در آلیاژهای آلومینیوم و فولاد ایجاد می‌کند. ایشان تأکید کردند که تعداد گذرها، نیروی برنیشینگ و هندسه ابزار در بهینه‌سازی این بهبودها حیاتی هستند. ژانگ و همکاران [۱۹] به‌طور مشابه تأکید کردند که LPB منجر به افزایش میکروسختی و مقاومت به سایش می‌شود و پارامترهای یکپارچگی سطح (زبری، تنش پسماند، سختی) به‌شدت با یکدیگر همبستگی دارند و بر طول عمر خستگی تأثیر می‌گذارند.

روش‌های مدل‌سازی سنتی، مانند روابط تجربی، رگرسیون (Regression) و روش‌های سطح پاسخ، اغلب نمی‌توانند به‌طور کامل رفتارهای غیرخطی و تعاملات پیچیده بین پارامترها را مدل‌سازی کنند. در مقابل، یادگیری ماشین با قابلیت بالای خود در شناسایی و استخراج الگوهای پیچیده در ارتباطات میان ورودی‌ها و خروجی‌های فرایندهای ساخت، به ابزاری توانمند تبدیل شده است. روش‌های یادگیری ماشین به‌ویژه در فرایندهای ماشین‌کاری، سنگ‌زنی، ساخت افزایشی و غیره به‌طور گسترده‌ای مورد استفاده قرار گرفته‌اند [۲۰]. یادگیری ماشین می‌تواند به‌عنوان یک ابزار قدرتمند در تحلیل داده‌های فرایندهای ماشین‌کاری، زبری سطح را با دقت بالا پیش‌بینی کند و همچنین امکان تنظیمات بلادرنگ را فراهم آورد [۲۱]. در سال‌های اخیر، محققان بسیاری از این روش‌ها را برای پیش‌بینی پارامترهایی نظیر میکروسختی، تنش پسماند و غیره به‌کار برده‌اند. اوغور اسمه و همکاران [۲۲] یک مدل پیش‌بینی برای زبری سطح با استفاده از شبکه عصبی مصنوعی (Artificial Neural Network-ANN) طراحی کردند تا تأثیر شرایط مختلف برنیشینگ در ماشین‌کاری آلیاژ آلومینیوم AA7075 را تحلیل کنند. این مدل به‌منظور پیش‌بینی پارامتر زبری سطح (R_a) توسعه یافت و پارامترهایی چون نیروی برنیشینگ، تعداد پاس‌های ابزار، نرخ پیشروی و سرعت برنیشینگ به‌عنوان ورودی‌ها در نظر گرفته شدند. نتایج حاصل از مدل ANN تطابق بسیار خوبی با داده‌های تجربی داشت. در مطالعه دیگری، رافال کلوز و همکاران [۲۳] به تأثیر پارامترهای برنیشینگ لغزشی بر زبری سطح میله‌های ساخته‌شده از فولاد قابل‌عملیات حرارتی 42CrMo4 پرداخته‌اند. این بررسی‌ها با استفاده از طرح سه‌سطحی هارتلی (Hartley) مدل چندگزینشی انجام شد که امکان استخراج یک معادله رگرسیونی به‌صورت یک چندجمله‌ای مرتبه دوم را فراهم می‌آورد. علاوه بر این، برای پیش‌بینی زبری سطح میله‌ها پس از برنیشینگ لغزشی، از مدل‌های شبکه عصبی مصنوعی استفاده شد. ایشان نشان دادند که حتی با داده‌های محدود، ANN توانایی بالایی در پیش‌بینی زبری سطح دارد. همچنین، کانویک و همکاران [۲۴] به مدل‌سازی زبری سطح بر اساس نتایج تجربی حاصل از بال‌برنیشینگ فولاد آلیاژی AISI 4130 با استفاده از ابزار گوی سرامیکی پرداختند. آن‌ها از سه روش تحلیل رگرسیون، شبکه عصبی مصنوعی و رگرسیون بردار پشتیبان برای مدل‌سازی زبری سطح استفاده کردند.

با توجه به چالش‌های موجود در فرایند برنیشینگ عمیق با گوی، بسیاری از مطالعات پیشین تنها به ارزیابی یک شاخص از یکپارچگی سطح (مانند زبری یا سختی) پرداخته‌اند و بررسی جامع‌تری از توپوگرافی سطح و تغییرات میکروسختی ارائه نشده است [۱۵-۱۷, ۲۵, ۲۶]. علاوه بر این، اکثر پژوهش‌ها تنها به استراتژی‌های تک‌گذره با عمق نفوذ محدود پرداخته‌اند که این موضوع باعث می‌شود تنش‌های فشاری القاشده در سطح، عمق کافی برای کاربردهای سنگین نداشته باشند. در این مطالعه،

جدول ۱ خواص مکانیکی آلیاژ Al 2024-T4.

Table 1 Mechanical Properties of Al 2024-T4 Alloy.

E (GPa)	υ	Sy (MPa)	SUT (MPa)	H (Hv)
73	0.33	317	454	**130±3**

برخلاف پژوهش‌های پیشین که تنها به ارزیابی یک شاخص از یکپارچگی سطح پرداخته‌اند، اثر هم‌زمان پارامترهای کلیدی فرایند DBB شامل قطر گوی، عمق نفوذ و نرخ پیشروی بر شاخص‌های کیفیت سطح، شامل R_a، R_z و میکروسختی سطح را به‌طور جامع بررسی شد. یکی از نوآوری‌های این مطالعه، استفاده از مدل‌های یادگیری ماشین رگرسیون خطی (Linear Regression-LR)، درخت تصمیم (Decision Tree-DT)، جنگل تصادفی (Random Forest-RF)، گرادیان بوستینگ شدید (XGBoost) و رگرسیون بردار پشتیبان (Support Vector Regression-SVR) برای پیش‌بینی شاخص‌های کیفیت سطح است. در نهایت، این مطالعه رویکردی نوین برای مدل‌سازی و پیش‌بینی رفتار سطح در فرایند DBB ارائه می‌دهد و کاربرد مدل‌های یادگیری ماشین را برای تحلیل و بهینه‌سازی این فرایند معرفی می‌کند.

۲- مواد و روش‌ها

۲-۱- تجهیزات و روش انجام آزمایش

آلیاژ آلومینیوم Al2024-T4 به‌منظور بررسی تأثیر فرایند DBB بر یکپارچگی سطح انتخاب شد. این آلیاژ به‌دلیل خواص مکانیکی برجسته‌ای چون استحکام کششی بالا و مقاومت در برابر خوردگی در محیط‌های سخت، به‌طور گسترده در صنایع هوافضا و خودروسازی کاربرد دارد. خواص مکانیکی آلیاژ Al 2024-T4 در جدول ۱ به صورت خلاصه و منحنی تنش–کرنش حاصل از آزمون تجربی کشش، در شکل ۱ ارائه شده است.

با توجه به وجود نیروهای عمودی بسیار بالا در فرایند DBB، از ابزار برنیشینگ لغزشی بهره گرفته شد تا تماس پایدار و توزیع بار یکنواخت و مؤثر در سراسر فرایند تضمین گردد. گوی کروی از جنس فولاد 100cr6 با سختی ۲۵۰ ویکرز استفاده شد. این آلیاژ به دلیل سختی و مقاومت بالا در برابر سایش و آسیب‌دیدگی‌های ناشی از تماس‌های مستقیم، انتخاب شده است. گوی فولادی توسط میله یک‌تکه مقاوم، پشتیبانی می‌شود تا انتقال یکنواخت نیرو در حین فرایند را تضمین کند. همچنین برای روانکاری مؤثر میان ابزار برنیشینگ و سطح قطعه‌کار، از روانکار نیمه‌سنتتیک SAE 40 استفاده شد که از طریق نازل با فشار مناسب به سطح قطعه اعمال می‌شود. این روانکار، علاوه بر کاهش سایش، به کاهش دما و جلوگیری از تغییرات حرارتی در سطح قطعه کمک می‌کند.

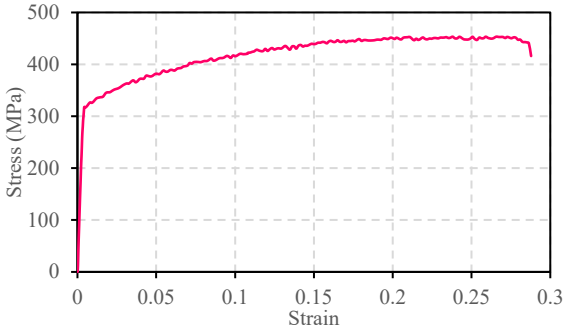

شکل ۱ منحنی تنش–کرنش حاصل از آزمون کشش آلیاژ Al 2024-T4.

Fig. 1 Stress–strain curve obtained from the tensile test of the Al2024-T4.

جدول ۲ پارامترهای ماشین‌کاری کف تراشی.

Table 2 Machining Parameters for Face Milling.

میزان پیشروی (mm/min)	عمق بار (mm)	سرعت دورانی (rpm)	قطر ابزار (mm)
200	**0.2**	**2000**	**22**

شکل ۲ چیدمان تجربی مورد استفاده را نشان می‌دهد. قبل از آغاز عملیات برنیشینگ، به‌منظور آماده‌سازی و یکنواخت کردن سطح اولیه قطعه‌کار، یک مرحله عملیات کف‌تراشی نیمه‌پرداخت توسط دستگاه فرز با کنترل عددی کامپیوتری مدل جانفورد و کنترلر فانوک انجام شد. این مرحله برای حذف ناهمواری‌ها و سطح‌سازی اولیه در قطعه‌کار ضروری است. پارامترهای ماشین‌کاری اولیه در جدول ۲ آورده شده است.

در ابتدا، یک سری آزمایش‌های تجربی اولیه انجام شد تا تأثیر پارامترهای مختلف فرایند برنیشینگ بر خواص سطحی قطعه‌کار بررسی شود. پارامترهایی که مورد بررسی قرار گرفتند شامل عمق بار عمودی، سرعت پیشروی، قطر نوک ابزار، تعداد عبور ابزار و نوع روانکار بودند. نتایج این آزمایش‌های اولیه، نشان داد که عمق بار عمودی از جمله مهم‌ترین پارامترها برای افزایش سختی سطح است. همچنین، سرعت پیشروی و نیروی برنیشینگ تأثیر زیادی بر زبری سطح دارند. در این راستا، برای بهینه‌سازی فرایند و کاهش زبری سطح و افزایش سختی، پارامترهای قطر نوک ابزار، سرعت پیشروی و عمق نهایی نفوذ به‌عنوان متغیرهای اصلی در نظر گرفته شدند و سایر پارامترها ثابت باقی ماندند. تنظیم نیروی عمودی ابزار یا عمق بار در سطوح بالاتر، موجب افزایش سختی سطح می‌شود، چرا که این تغییرات باعث افزایش تنش‌های پسماند فشاری و کرنش مومسان سطح می‌گردد. از سوی دیگر، برای کمینه‌سازی زبری سطح، نیروی برنیشینگ و سرعت پیشروی، باید در سطوح پایین‌تر تنظیم شوند. این ناسازگاری بین تأثیر نیروی برنیشینگ و سختی سطح موجب می‌شود که نتوان هم‌زمان به بالاترین سختی و کمترین زبری سطح دست یافت.

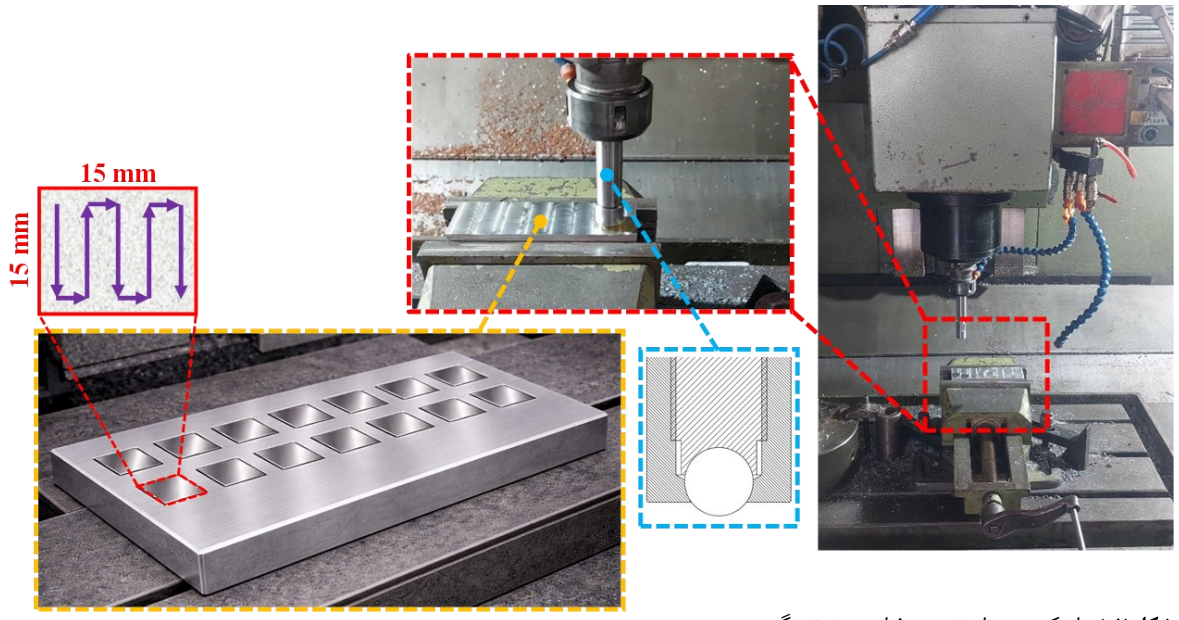

شکل ۲ شماتیک چیدمان تجربی فرایند برنیشینگ عمیق.

Fig. 2 Schematic of the Experimental Setup for Deep Burnishing Process.

بر اساس مشاهدات اولیه، افزایش بیش از حد کرنش مومسان، ممکن است منجر به آسیب‌های نرم در سطح قطعه و کاهش تنش‌های پسماند فشاری شود که در نهایت باعث پوسته‌پوسته شدن سطح می‌گردد. این آسیب‌ها به خرابی قطعه و افزایش هزینه‌های عملیاتی منجر خواهد شد. علاوه بر این، طبق نتایج پژوهش‌های پیشین [۱۵–۱۷, ۲۵]، شرایطی که بیشترین چقرمگی را ایجاد می‌کند الزاما باعث بهبود کیفیت سطح نمی‌شود، زیرا نیروی عمودی یا عمق بار، مؤثرترین پارامتر بر چقرمگی محسوب می‌شود، در حالی که تأثیر آن بر زبری سطح کمتر است.

بنابراین، در این مطالعه به‌منظور دستیابی به کمترین مقدار زبری سطح و بیشترین سختی سطح، بهینه‌سازی دقیق پارامترهای ورودی انجام گردید. برای تعیین حداقل عمق بار عمودی، مشخص شد که این مقدار باید بیشتر از مقدار Rz سطح اولیه باشد. به‌طور خاص در آزمایش‌های اولیه، زبری اولیه سطح پس از کف تراشی برابر با ۱۷/۲ میکرومتر بود، بنابراین حداقل عمق بار عمودی با توجه به آزمایش برنیشینگ عمیق ۵۰ میکرون (۰/۰۵ میلی‌متر) انتخاب گردید تا از آسیب‌های ناشی از کرنش مومسان بیش از حد جلوگیری شود. علاوه بر این، عمق هر پاس در فرایند برنیشینگ به‌طور ثابت و به اندازه ۰/۰۵ میلی‌متر تنظیم شد تا از آسیب‌های ناشی از عمق بار زیاد جلوگیری گردد. همچنین، عمق نهایی نفوذ به‌صورت مضربی از اندازه پاس تنظیم شد. به‌عنوان مثال، برای عمق نهایی ۰/۱۵ میلی‌متر، سه مرحله جاروب کامل عملیات برنیشینگ با پاس ثابت ۰/۰۵ میلی‌متر انجام گردید. این روش علاوه بر کاهش آسیب‌های نرم ناشی از فرایند برنیشینگ عمیق، باعث افزایش کارایی و دقت فرایند می‌شود. در شکل ۳ پروفیل نفوذ نوک کروی ابزار برنیشینگ به‌طور واضح نشان داده شده است. با توجه به این شکل و رابطه (۱) [۲۷]، پارامترهای عمق بار عمودی،

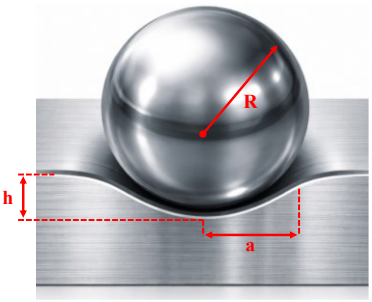

شکل ۳ پروفیل نفوذ نوک کروی ابزار در فرایند برنیشینگ.

Fig. 3 Profile of the Spherical Tool Tip Penetration in the Burnishing Process.

شعاع نوک ابزار و شعاع نفوذ مؤثر بر سطح قطعه به‌هم وابسته هستند.

برای اطمینان از اینکه تمام نقاط سطح قطعه پوشش داده شوند، گام عرضی در برنیشینگ باید کوچکتر از شعاع نفوذ مؤثر باشد. انتخاب گام جانبی کمتر، باعث افزایش تغییر شکل مومسان و تنش‌های پسماند فشاری می‌شود که نتیجه‌ای مطلوب برای بهبود خواص سطح قطعه به همراه می‌آورد.

$$a = \sqrt{2Rh - h^2} \qquad (۱)$$

در رابطه (۱)، شعاع نفوذ موثر (a) بر حسب پارامتر های عمق بار عمودی (h) و شعاع نوک ابزار (R) بدست می آید. با استفاده از این رابطه و در نظر گرفتن قطر گوی و عمق بار، شعاع نفوذ مؤثر برابر با ۰/۵۴ میلی‌متر بدست می‌آید و با توجه به کارایی و دقت دستگاه ماشین ابزار و همچنین مقدار شعاع نفوذ، مقدار گام عرضی ثابت با اندازه ۰/۱۲ میلی متر در نظر گرفته شده است.

به جهت حصول نتایج قابل اطمینان و کاهش حجم آزمایش‌های تجربی با در نظر گرفتن بهترین دقت در طراحی آزمایش، از روش عاملی کامل (Full Factorial Design)، شامل دو پارامتر با سه سطح

جدول ۳ پارامترهای مؤثر و سطوح مورد بررسی آن‌ها در فرایند برنشینگ عمیق با گوی.

Table 3 Effective Parameters and Their Levels Considered in the Deep Ball Burnishing Process.

پارامترها	سطح ۱	سطح ۲	سطح ۳
قطر گوی (میلی‌متر)	6	-----	10
عمق نهایی نفوذ (میلی‌متر)	0.05	0.10	0.15
نرخ پیشروی (میلی‌متر بر دقیقه)	800	1600	2400

و یک پارامتر با دو سطح، با ۱۸ آزمایش تجربی انتخاب شده است (جدول ۳). به‌وسیله این طراحی آزمایش، تأثیرات مستقل و متقابل پارامترهای مختلف به‌طور دقیق بررسی و ارتباط میان این پارامترها و خواص سطحی قطعه‌کار مشخص شدند. ابعاد طراحی‌شده برای آزمایش تجربی، ۱۵ در ۱۵ میلی‌متر و فاصله بین آن‌ها ۸ میلی‌متر در نظر گرفته شد. در شکل ۲، مسیر حرکت جاروب‌شده‌ی ابزار برنیشینگ نشان داده شده است. در هر قسمت از بلوک آلومینیومی، یک آزمایش تجربی انجام و نتایج آن به‌طور جامع ثبت شد.

برای اندازه‌گیری زبری سطح (پارامترهای R_a و R_z)، از زبری‌سنج قابل‌حمل ماهر (Mahr) مدل PS1 استفاده شد. پارامتر R_a به‌عنوان میانگین قدر مطلق انحرافات پروفیل زبری نسبت به خط میانی در طول اندازه‌گیری تعریف می‌شود و بیانگر زبری کلی و متوسط سطح است. در مقابل، پارامتر R_z میانگین اختلاف ارتفاع بین بلندترین قله‌ها و عمیق‌ترین دره‌های پروفیل زبری در طول نمونه‌برداری را نشان می‌دهد و نسبت به ناهمواری‌های موضعی و قله–دره‌های برجسته، حساسیت بیشتری دارد. ازاین‌رو، در حالی که R_a تصویری کلی از کیفیت سطح ارائه می‌دهد، R_z قادر است عیوب موضعی و ناپیوستگی‌های شدید سطح را با دقت بیشتری منعکس کند.

اندازه‌گیری پارامترهای زبری سطح R_a و R_z در دو راستا (موازی و عمود بر جهت پیشروی ابزار) و در سه ناحیه مختلف انجام شد. طول ارزیابی برابر با ۵/٦ میلی‌متر بر اساس استاندارد ISO 4288 انتخاب گردید؛ به‌گونه‌ای که این طول شامل پنج طول نمونه‌برداری (cut-off length) متوالی بوده و شرایط لازم برای محاسبه معتبر پارامترهای زبری سطح را مطابق الزامات استاندارد فراهم می‌کند [۲٦]. مقدار نهایی پارامترهای R_a و R_z به‌صورت میانگین مقادیر ثبت‌شده در نواحی و راستاهای مختلف محاسبه شد.

میکروسختی سطح با استفاده از دستگاه سختی‌سنج ویکرز بوهلر (Buehler Micromet) تحت بار ۰/۵ کیلوگرم و زمان ماند ۱۰ ثانیه (شکل ٤) اندازه‌گیری شد. این اندازه‌گیری‌ها مطابق با استاندارد ISO 6507-1 انجام گرفت و در سه ناحیه مجزا روی سطح نمونه صورت گرفت. نقاط اندازه‌گیری به‌ترتیب در فواصل ٤، ۸ و ۱۲ میلی‌متر از لبه نمونه انتخاب شدند تا از اثرات لبه‌ای اجتناب شده و نماینده مناسبی از شرایط واقعی سطح باشند. مقدار نهایی میکروسختی هر نمونه به‌صورت میانگین مقادیر اندازه‌گیری‌شده محاسبه شد.

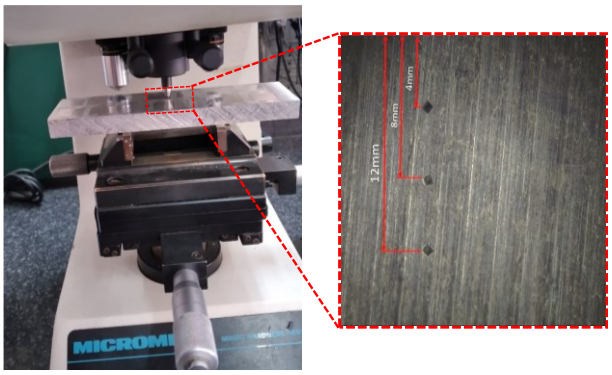

شکل ۴ نقاط اندازه‌گیری میکروسختی با استفاده از دستگاه سختی‌سنج بوهلر.

Fig. 4 Microhardness Measurement Points Using the Buehler Micromet Device.

۲-۲- مدل‌های یادگیری ماشین

برای پیش‌بینی کیفیت سطح در فرایند DBB، از مدل‌های یادگیری ماشین استفاده شد تا تعاملات پیچیده و غیرخطی پارامترهای فرایند مانند قطر گوی، عمق نفوذ و نرخ پیشروی که مدل‌سازی آن‌ها با روش‌های تحلیلی سنتی دشوار است، به‌طور دقیق پیش‌بینی شوند. در این مطالعه، پنج مدل شامل رگرسیون خطی، درخت تصمیم، جنگل تصادفی، گرادیان بوستینگ شدید و رگرسیون بردار پشتیبان بررسی و مقایسه شدند. ورودی‌ها شامل پارامترهای قطر گوی، عمق نفوذ و نرخ پیشروی و خروجی‌ها شامل زبری سطح (Ra و Rz) و میکروسختی ویکرز بودند. داده‌ها به‌طور تصادفی به دو بخش ۷۰٪ برای آموزش (Train) و ۳۰٪ برای آزمایش (Test) تقسیم شدند. در ادامه، ویژگی‌ها و خصوصیات مهم هر یک از مدل‌های به‌کاررفته، توضیح داده شده است:

۱) رگرسیون خطی: یکی از ساده‌ترین و سریع‌ترین مدل‌ها است که رابطه‌ای خطی بین ورودی‌ها و خروجی‌ها مدل‌سازی می‌کند. این روش با استفاده از روش کوچک‌ترین مربعات معمولی (Ordinary Least Squares)، ضرایب معادله را طوری محاسبه می‌کند که خطاها به حداقل برسند. در حالی که رگرسیون خطی قادر به مدل‌سازی روابط پیچیده و غیرخطی نیست، سرعت بالای محاسبات و قابلیت تفسیر آسان ضرایب باعث شده که در بسیاری از مدل‌های پیش‌بینی اولیه و برای بررسی روابط ساده میان داده‌ها استفاده شود.

۲) درخت تصمیم: یک مدل یادگیری ماشین ساده، بصری و تفسیرپذیر است که داده‌ها را با استفاده از تقسیم بازگشتی بر اساس ویژگی‌ها به گروه‌های همگن تقسیم می‌کند. این مدل قادر به مدل‌سازی تعاملات غیرخطی و پیچیده بین ویژگی‌ها است و نیازی به پیش‌پردازش داده‌ها ندارد. ویژگی مهم درخت تصمیم، قابلیت بیان قوانینی ساده به صورتی است که برای کاربردهای صنعتی مانند تحلیل تأثیر پارامترها در فرایندهای تولید بسیار مفید است.

۳) جنگل تصادفی: یک مدل مجموعه‌ای است که با ترکیب تعدادی درخت تصمیم ساخته می‌شود. این مدل از روش بگینگ (Bagging) برای کاهش بیش‌برازش (Overfitting) و بهبود دقت پیش‌بینی استفاده می‌کند. جنگل تصادفی، به‌ویژه برای داده‌های پیچیده و نویزی مناسب است و توانایی مدل‌سازی روابط غیرخطی و تعاملات پیچیده بین ویژگی‌ها را دارد. علاوه بر این، جنگل تصادفی در مقایسه با درخت تصمیم منفرد، تعمیم‌پذیری بهتری دارد و به همین دلیل یکی از مدل‌های پرکاربرد در پیش‌بینی و طبقه‌بندی داده‌ها است.

٤) گرادیان بوستینگ شدید: یکی از مدل‌های پیشرفته است که از روش‌های منظم‌سازی برای جلوگیری از بیش‌برازش استفاده می‌کند. این روش با بهره‌گیری از پردازش موازی، هرس پیش‌گیرانه درخت‌ها و وزن‌دهی هوشمند نمونه‌ها، سرعت آموزش و دقت پیش‌بینی را به سطح بالایی می‌رساند. گرادیان بوستینگ شدید به‌ویژه برای مجموعه‌داده‌های بزرگ و پیچیده کاربرد دارد و در بسیاری از مسائل پیش‌بینی و مهندسی نتایج شگفت‌انگیزی ارائه می‌دهد.

۵) رگرسیون بردار پشتیبان: یک مدل قدرتمند برای مسائل رگرسیون پیچیده و غیرخطی است که با استفاده از توابع کرنل (Kernel) داده‌ها را به فضایی با ابعادی بالاتر منتقل می‌کند تا روابط غیرخطی پیچیده را مدل‌سازی کند. این مدل قادر به تعادل دقیق بین دقت پیش‌بینی و پیچیدگی مدل است و برای داده‌هایی با ویژگی‌های پیچیده و تغییرات زیاد، بسیار موثر خواهد بود.

این مدل‌های یادگیری ماشین، از روش‌های مختلف مانند جستجوی شبکه‌ای، جستجوی تصادفی و بهینه‌سازی بیزی (Bayesian optimization) برای تنظیم دقیق ابرپارامترها (Hyperparameters) استفاده می‌کنند تا دقت پیش‌بینی را به حداکثر برسانند. در جدول ٤ ابرپارامترهای به‌کاررفته برای هر یک از این مدل‌ها، به‌طور جامع ذکر شده است [۲۸-۳۱].

جدول ۴ ابرپارامترهای به‌کاررفته برای هر یک از مدل‌های یادگیری ماشین.
Table 4 Hyperparameters Used for Each of the Machine Learning Models.

Model	Hyperparameters
Linear Regression	**Fit Method='OLS', Solver=QR Decomposition, Regularization=None, Fitting Algorithm=Direct matrix inversion using OLS, Data Standardization=Yes.**
Decision Tree	**Criterion='squared_error', max_depth=None, min_samples_split=2, min_samples_leaf=1, max_features='auto'.**
Random Forest	**Method='Bag', NumLearningCycles=100, MinLeafSize=1, MaxNumSplits=Inf.**
XGBoost	**n_estimators = 100, learning_rate = 0.1, max_depth = 6, objective = 'reg:squarederror', booster = 'gbtree', NumLearningCycles = 100, Method = 'LSBoost'.**
Support Vector Regression (SVR)	**KernelFunction = 'rbf', BoxConstraint = 1.0, Epsilon = 0.1, KernelScale = 'auto', Standardize = true.**

جدول ۵ نتایج اندازه‌گیری پارامترهای زبری و میکروسنجی پس از فرایند برنیشینگ عمیق.
Table 5 Measurement Results of Roughness and Microhardness Parameters After Deep Burnishing Process.

No.	Inputs			Outputs		
	Ball dia. (Db) (mm)	Total depth (htot) (mm)	Feed rate (f) (mm/min)	Ra (µm) Avg.	Rz (µm) Avg.	H (HV)
1	6	0.05	800	0.67	2.795	135
2	6	0.05	1600	0.795	3.685	140
3	6	0.05	2400	0.97	4.385	146
4	6	0.1	800	0.785	3.715	146
5	6	0.1	1600	0.995	4.72	153
6	6	0.1	2400	1.245	6.14	162
7	6	0.15	800	1.545	7.115	155
8	6	0.15	1600	1.82	8.26	164
9	6	0.15	2400	2.11	9.315	175
10	10	0.05	800	0.37	1.57	145
11	10	0.05	1600	0.495	1.975	152
12	10	0.05	2400	0.63	2.395	160
13	10	0.1	800	0.605	2.455	162
14	10	0.1	1600	0.77	3.3	170
15	10	0.1	2400	0.89	4.235	184
16	10	0.15	800	0.95	5.035	176
17	10	0.15	1600	1.08	5.51	188
18	10	0.15	2400	1.38	6.135	197

۳- نتایج و بحث

طبق توضیحات ارائه‌شده، آزمایش‌های تجربی شامل دو پارامتر با سه سطح و یک پارامتر با دو سطح، با تعداد ۱۸ آزمایش، انجام شد. نتایج اندازه‌گیری پارامترهای R_a و R_z (میانگین اندازه‌گیری در راستاهای موازی و عمود بر جهت پیشروی ابزار)، به همراه میکروسختی پس از فرایند برنیشینگ، در جدول ۵ آورده شده است. در ادامه، نتایج به‌دست‌آمده از روش‌های مختلف یادگیری ماشین برای هر یک از پارامترهای خروجی، به‌طور جداگانه بررسی می‌شوند و سپس مورد تجزیه و تحلیل قرار خواهند گرفت.

۳-۱- پارامتر زبری R_a

با توجه به شکل ۵ که نتایج پیش‌بینی پارامتر R_a را توسط مدل‌های مختلف یادگیری ماشین در مراحل آموزش و آزمون نشان می‌دهد، می‌توان به تحلیل دقیق عملکرد هر مدل پرداخت. در این شکل، داده‌های آموزشی برای یادگیری مدل‌های یادگیری ماشین و داده‌های آزمایشی برای ارزیابی قابلیت تعمیم آن‌ها به‌کار رفته‌اند و خط مورب خاکستری با شیب واحد ($y = x$) بیانگر حالت برازش ایده‌آل است که میزان نزدیکی پیش‌بینی‌ها به مقادیر واقعی را نشان می‌دهد.

رگرسیون خطی در مرحله آموزش عملکرد خوبی دارد، اما در آزمون پیش‌بینی‌ها به‌طور قابل توجهی از خط ایده‌آل فاصله دارند، که نشان‌دهنده ضعف مدل در تعمیم به داده‌های جدید است. درخت تصمیم در هر دو مرحله آموزش و آزمون پیش‌بینی‌های دقیقی ارائه داده و توانسته است تعاملات غیرخطی پیچیده را به‌خوبی مدل‌سازی کند. جنگل تصادفی در آموزش عملکرد خوبی دارد، اما در آزمون کاهش دقت نشان می‌دهد که احتمالا به دلیل بیش‌برازش است و نیاز به بهینه‌سازی بیشتر دارد. XGBoost

عملکرد عالی در هر دو مرحله داشته و پیش‌بینی‌ها به‌طور دقیق به خط ایده‌آل نزدیک است، که نشان‌دهنده تعادل مناسب بین یادگیری و تعمیم‌پذیری مدل است. در نهایت، رگرسیون بردار پشتیبان بهترین عملکرد را در داده‌های آزمون از خود نشان داده و پیش‌بینی‌های دقیقی ارائه داده است، که نشان‌دهنده تعمیم مؤثر به داده‌های جدید است. به‌طور کلی، رگرسیون بردار پشتیبان بهترین عملکرد را در پیش‌بینی پارامتر R_a در هر دو مرحله آموزش و آزمون داشته است. در شکل ٦، نمودارهای باقیمانده (Residuals) مدل‌های مختلف یادگیری ماشین برای پیش‌بینی پارامتر R_a در دو مرحله آموزش و آزمون نشان داده شده است. این نمودارها به‌وضوح عملکرد هر مدل را در پیش‌بینی داده‌ها ارزیابی می‌کنند. تمرکز تصادفی باقیمانده‌ها در اطراف خط صفر، که با خط خاکستری خط‌چین مشخص شده است، نشان‌دهنده عدم وجود خطای سیستماتیک و مناسب بودن برازش مدل بوده، در حالی که پراکندگی نامتقارن یا الگوهای منظم در باقیمانده‌ها می‌تواند بیانگر ضعف مدل در پیش‌بینی برخی بازه‌های داده باشد.

در مدل رگرسیون خطی، باقیمانده‌ها در داده‌های آزمون پراکندگی بیشتری دارند که نشان‌دهنده کاهش دقت مدل در تعمیم به داده‌های جدید است. این مدل نتواسته است به‌خوبی تعاملات غیرخطی و پیچیده موجود در داده‌ها را مدل‌سازی کند. در مقابل، درخت تصمیم، باقیمانده‌های کمتری در هر دو مرحله آموزش و آزمون نشان می‌دهد که نشان‌دهنده عملکرد مناسب این مدل در یادگیری و تعمیم داده‌ها است. مدل جنگل تصادفی در مرحله آموزش به‌خوبی عمل کرده، اما در داده‌های آزمون باقیمانده‌ها پراکندگی بیشتری دارند. روش XGBoost عملکرد بسیار خوبی در هر دو مرحله از خود نشان داده و باقیمانده‌ها به‌طور قابل توجهی کوچک و نزدیک به صفر هستند، که نشان‌دهنده تعادل مؤثر بین یادگیری و تعمیم‌پذیری این مدل است. SVR نیز عملکرد بسیار دقیقی در مرحله آزمون دارد، باقیمانده‌ها در داده‌های آزمون به‌طور نزدیک به صفر باقی می‌مانند که نشان‌دهنده تعمیم‌پذیری عالی و دقت بالای مدل در پیش‌بینی داده‌های جدید است. در مجموع، SVR بهترین عملکرد را در پیش‌بینی پارامتر Ra دارد.

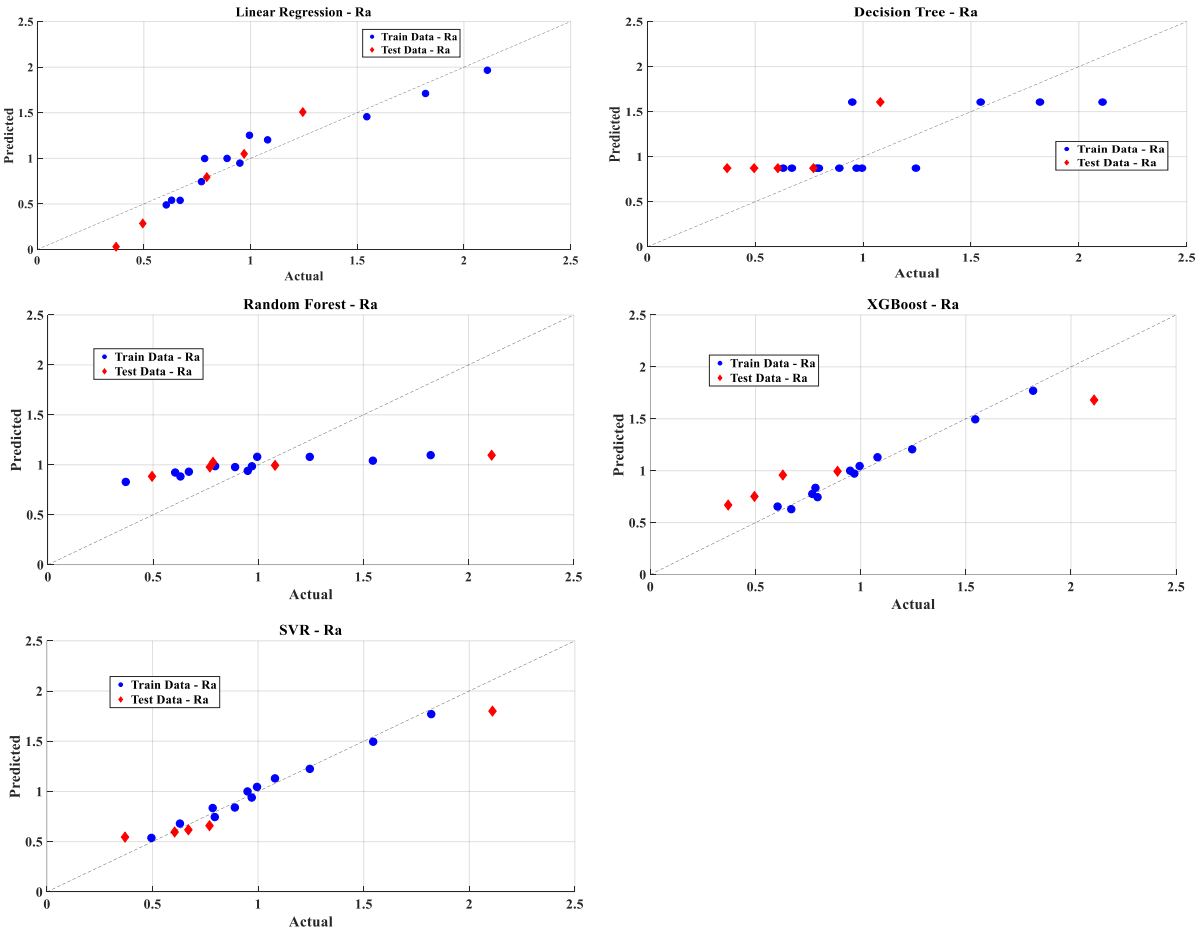

شکل ۵ نمودار پراکندگی مقادیر پیش‌بینی‌شده در مقابل مقادیر واقعی R_a، برای مجموعه داده‌های آموزشی (دایره‌های آبی ●) و آزمایشی (مربع‌های قرمز ♦) در تمام مدل‌های یادگیری ماشین، با خط خاکستری مورب که نشان‌دهنده برازش ایده‌آل است.

Fig. 5 Scatter Plot of Predicted vs. Actual R_a Values for the Training (Blue Circles ●) and Testing (Red Squares ♦) Datasets in All Machine Learning Models, with a Diagonal Gray Line Representing Ideal Fit.

برای تحلیل دقیق عملکرد مدل‌های یادگیری ماشین در پیش‌بینی پارامتر R_a، مقادیر R^2، RMSE و MAE در مراحل آموزش و آزمون برای هر مدل در جدول ٦ ارائه شده است. شاخص R^2 میزان توان تبیین مدل نسبت به تغییرات داده‌های واقعی را نشان می‌دهد، در حالی که RMSE و MAE به‌ترتیب بیانگر بزرگی خطا با تأکید بر خطاهای بزرگ و میانگین قدر مطلق خطاها هستند؛ مقایسه این شاخص‌ها در مراحل آموزش و آزمون امکان ارزیابی هم‌زمان دقت و قابلیت تعمیم مدل‌ها را فراهم می‌کند.

مدل رگرسیون خطی در مرحله آموزش عملکرد نسبتاً خوبی با $R^2 =$ 0.918 داشته که نشان‌دهنده تطابق مناسب با داده‌های آموزشی است. با این حال، در مرحله آزمون، عملکرد آن کاهش قابل توجهی داشت و R^2 به ۰/۵۳۳ کاهش یافت. این کاهش دقت همراه با افزایش قابل توجه RMSE به ۰/۲۱٦ و MAE به ۰/۱۷۸ است که نشان‌دهنده ناتوانی مدل در تعمیم به داده‌های جدید و کاهش کارایی آن در پیش‌بینی داده‌های آزمون است. مدل درخت تصمیم عملکرد ضعیفی در هر دو مرحله آموزش و آزمون نشان می‌دهد. در حالی که R^2 در مرحله آموزش برابر ۰/۵۸٦ است، در مرحله آزمون این مقدار به ۱/٤۹- کاهش یافت که نشان‌دهنده ناکارآمدی شدید این روش در پیش‌بینی داده‌های آزمون است.

مدل جنگل تصادفی در مرحله آموزش عملکرد نسبتاً ضعیفی دارد و R^2 آن تنها ۰/۳۰۲ است که در مرحله آزمون به ۰/۱۸٦ کاهش یافت. این روش نتواست به‌طور مؤثر بر تعاملات پیچیده داده‌ها مسلط شود و دقت آن در پیش‌بینی داده‌های آزمون با افزایش RMSE به ۰/۵۰۷ و MAE به ۰/۳۸۷ کاهش یافته است. مدل XGBoost عملکرد بسیار خوبی نشان داد و در مرحله آموزش با R^2 برابر ۰/۹۸۳ و در آزمون با R^2 تقریباً ۰/۷۷ پیش‌بینی‌های دقیقی ارائه داد. همچنین، RMSE و MAE آن در آزمون به ترتیب ۰/۳۰۳ و ۰/۲۸٤ بودند که نشان‌دهنده تعمیم مؤثر مدل است.

SVR عملکرد برجسته‌ای داشت و در مرحله آموزش با R^2 برابر ۰/۹۸۳ مشابه XGBoost بود و در آزمون R^2 آن به ۰/۹۲۵ رسید. این مدل با کمترین مقادیر RMSE و MAE بهترین عملکرد را داشت.

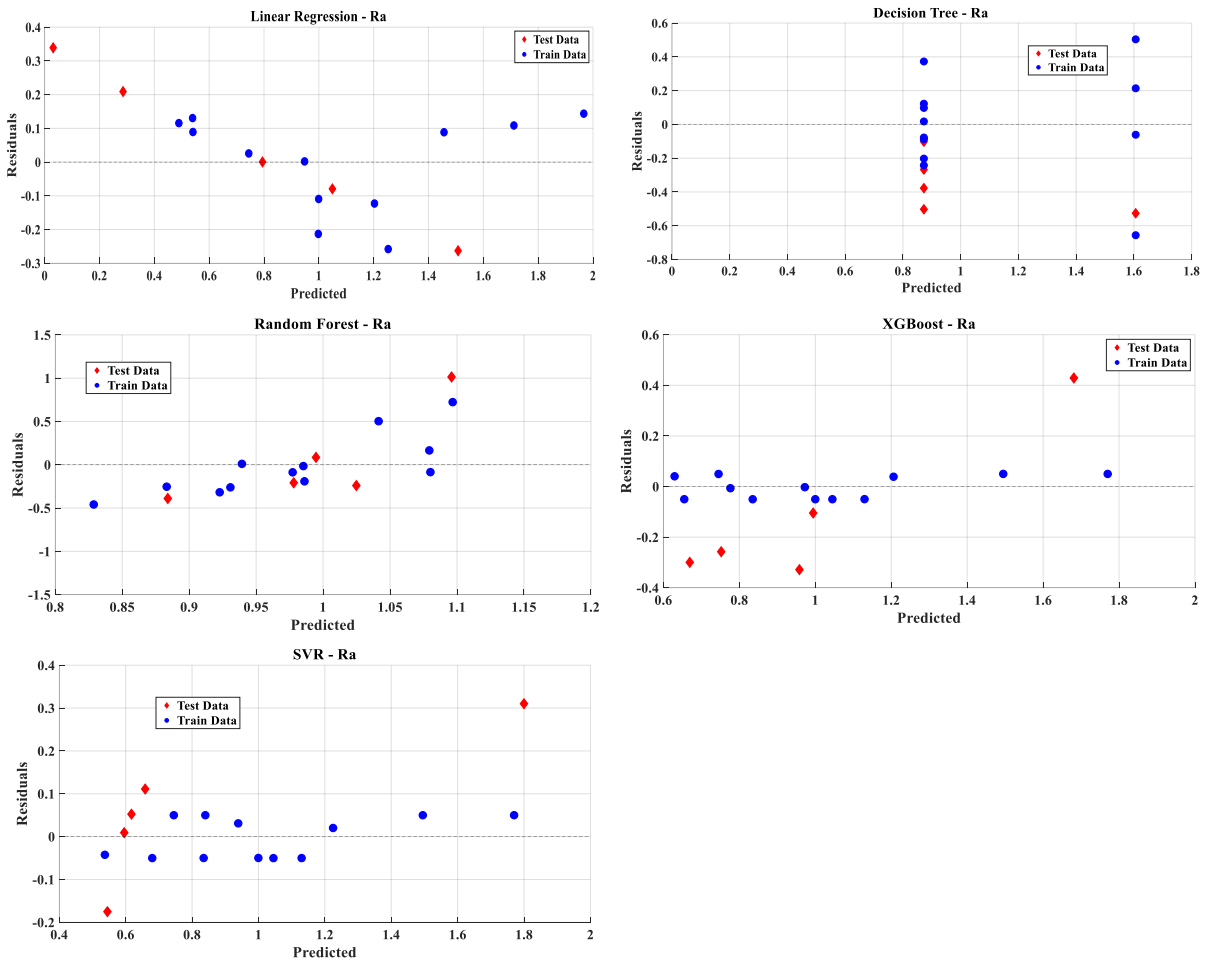

شکل ۶ نمودارهای باقیمانده (مقادیر باقیمانده در مقابل مقادیر برازش شده) R_a برای هر مدل، که داده‌های آموزشی را با دایره‌های آبی (●) و داده‌های آزمایشی را با مربع‌های قرمز (♦) نشان می‌دهد، با یک خط خاکستری خط‌چین در نقطه صفر که نشان‌دهنده عدم خطا است.

Fig. 6 Residual Plots (Residuals vs. Fitted Values) for R_a in Each Model, with Training Data Represented by Blue Circles (●) and Testing Data by Red Squares (♦), and a Gray Dashed Line at Zero Indicating No Error.

جدول ۶ مقادیر R^2، RMSE و MAE برای پارامتر R_a مربوط به هر مدل یادگیری ماشین در مراحل آموزش و آزمون.

Table 6 R^2, RMSE, and MAE Values for the R_a Parameter Corresponding to Each Machine Learning Model in the Training and Testing Stages.

Model	Train			Test		
	R^2	RMSE	MAE	R^2	RMSE	MAE
Linear Regression	0.9181	0.13484	0.11721	0.53347	0.21637	0.17819
Decision Tree	0.5868	0.29025	0.22125	-1.4904	0.38833	0.35525
Random Forest	0.3027	0.32907	0.25604	0.18551	0.50751	0.38727
XGBoost	0.9839	0.043925	0.040649	0.86867	0.30282	0.28367
Support Vector Regression	0.9832	0.046228	0.04528	0.92528	0.16858	0.13164

در نتیجه، SVR و XGBoost بهترین مدل‌ها در پیش‌بینی پارامتر R_a بودند. در مقابل، رگرسیون خطی، درخت تصمیم و جنگل تصادفی عملکرد ضعیف‌تری داشتند.

۲-۳- پارامتر زبری R_z

شکل ۷ پیش‌بینی‌های مدل‌های مختلف یادگیری ماشین برای پارامتر R_z را در مراحل آموزش و آزمون نشان می‌دهد. مدل رگرسیون خطی در مرحله آموزش عملکرد خوبی دارد، اما در آزمون پیش‌بینی‌ها از خط ایده‌آل فاصله می‌گیرد که نشان‌دهنده ضعف در تعمیم به داده‌های جدید است. درخت تصمیم در آموزش به‌خوبی عمل می‌کند، اما در آزمون دچار بیش‌برازش می‌شود و دقت آن کاهش می‌یابد. جنگل تصادفی عملکردی مشابه با درخت تصمیم دارد، اما توانست بهتر داده‌های جدید را تعمیم دهد، هرچند که نیاز به بهینه‌سازی دارد. XGBoost در هر دو مرحله آموزش و آزمون پیش‌بینی‌های دقیقی ارائه داده و تعادل خوبی بین یادگیری و تعمیم‌پذیری برقرار کرده است. SVR نیز عملکرد خوبی در هر دو مرحله و پیش‌بینی‌هایی نزدیک به خط ایده‌آل دارد. XGBoost و SVR بهترین عملکرد را در پیش‌بینی پارامتر Rz داشته‌اند، در حالی که مدل‌های جنگل تصادفی و رگرسیون خطی در آزمون عملکرد ضعیف‌تری از خود نشان داده‌اند و درخت تصمیم به‌دلیل بیش‌برازش نتوانسته است عملکرد مناسبی داشته باشد.

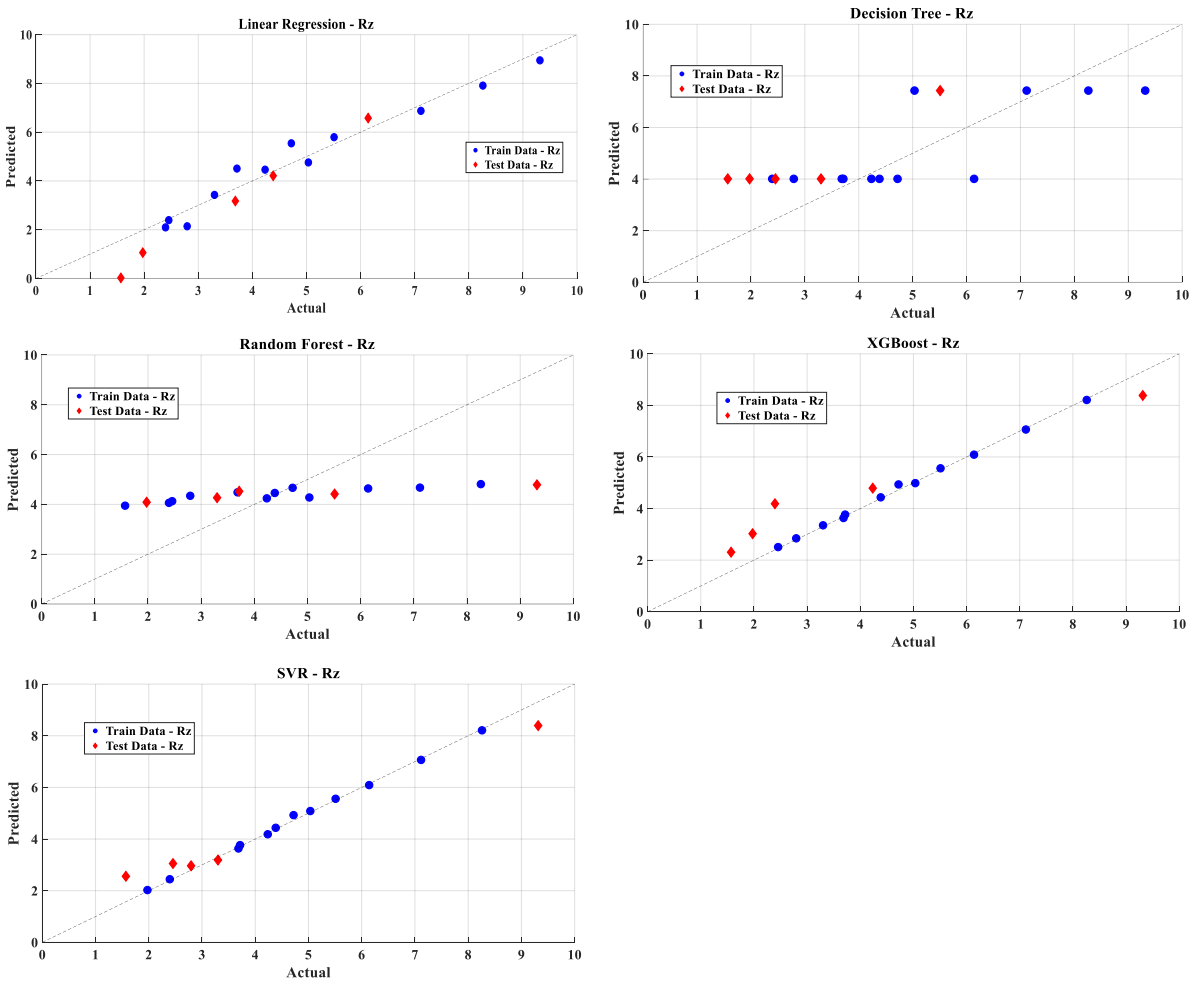

شکل ۷ نمودار پراکندگی مقادیر پیش‌بینی‌شده در مقابل مقادیر واقعی R_z برای مجموعه داده‌های آموزشی (دایره‌های آبی ●) و آزمایشی (مربع‌های قرمز ♦) در تمام مدل‌های یادگیری ماشین، با خط خاکستری مورب که نشان‌دهنده برازش ایده‌آل است.

Fig. 7 Scatter Plot of Predicted vs. Actual R_z Values for the Training (Blue Circles ●) and Testing (Red Squares ♦) Datasets in All Machine Learning Models, with a Diagonal Gray Line Representing Ideal Fit.

شکل ۸، نمودارهای باقیمانده مدل‌های مختلف یادگیری ماشین را برای پیش‌بینی پارامتر R_z در مراحل آموزش و آزمون نشان می‌دهد. رگرسیون خطی در داده‌های آموزش پیش‌بینی‌های دقیقی دارد، اما در آزمون با پراکندگی زیاد باقیمانده‌ها مواجه است. درخت تصمیم نیز در آموزش عملکرد خوبی دارد، اما در آزمون با باقیمانده‌های بزرگ مواجه و نشان‌دهنده بیش‌برازش است. جنگل تصادفی نیز عملکردی مشابه درخت تصمیم دارد. مدل‌های XGBoost و SVR با انحرافات بسیار کوچک و نزدیک به صفر در هر دو مرحله عملکرد برجسته‌ای داشته‌اند، که نشان‌دهنده توانایی بالای این مدل‌ها در تعمیم به داده‌های جدید است. این دو مدل توانسته‌اند پیش‌بینی‌های دقیقی ارائه دهند و بهترین عملکرد را در پیش‌بینی پارامتر R_z نشان داده‌اند. در مقابل، رگرسیون خطی و درخت تصمیم نتوانسته‌اند به‌طور مؤثر داده‌های آزمون را پیش‌بینی کنند.

نتایج مدل‌های مختلف یادگیری ماشین برای پیش‌بینی پارامتر R_z در جدول ۷ نشان‌دهنده تفاوت‌های قابل توجه در عملکرد آن‌ها در مراحل آموزش و آزمون است.

رگرسیون خطی با R^2 تقریباً ۰/۹۵۹ در آموزش عملکرد خوبی دارد، اما در آزمون این مقدار به ۰/۷۳۲ کاهش می‌یابد که نشان‌دهنده ضعف در تعمیم به داده‌های جدید است.

درخت تصمیم با R^2 حدود ۰/۶۱ در آموزش و ۰/۷۱- در آزمون، به‌طور قابل‌توجهی دچار بیش‌برازش شده است. جنگل تصادفی نیز در آموزش و آزمون، به ترتیب با R^2 تقریباً ۰/۲۲ و ۰/۱۴ عملکرد ضعیفی دارد و نیاز به بهینه‌سازی دارد. روش XGBoost با R^2 در آموزش ۰/۹۹۸ و در آزمون ۰/۸۵۲، پیش‌بینی‌های خوبی ارائه می‌دهد و توانسته تعادل مناسبی بین یادگیری و تعمیم‌پذیری برقرار کند. SVR نیز با R^2 حدود ۰/۹۴ در آزمون، بهترین عملکرد را نشان داده و کمترین خطا را دارد. بنابراین، XGBoost و SVR بهترین مدل‌ها در پیش‌بینی پارامتر R_z هستند، در حالی که درخت تصمیم و جنگل تصادفی به دلیل بیش‌برازش نتواسته‌اند در داده‌های آزمون عملکرد خوبی داشته باشند.

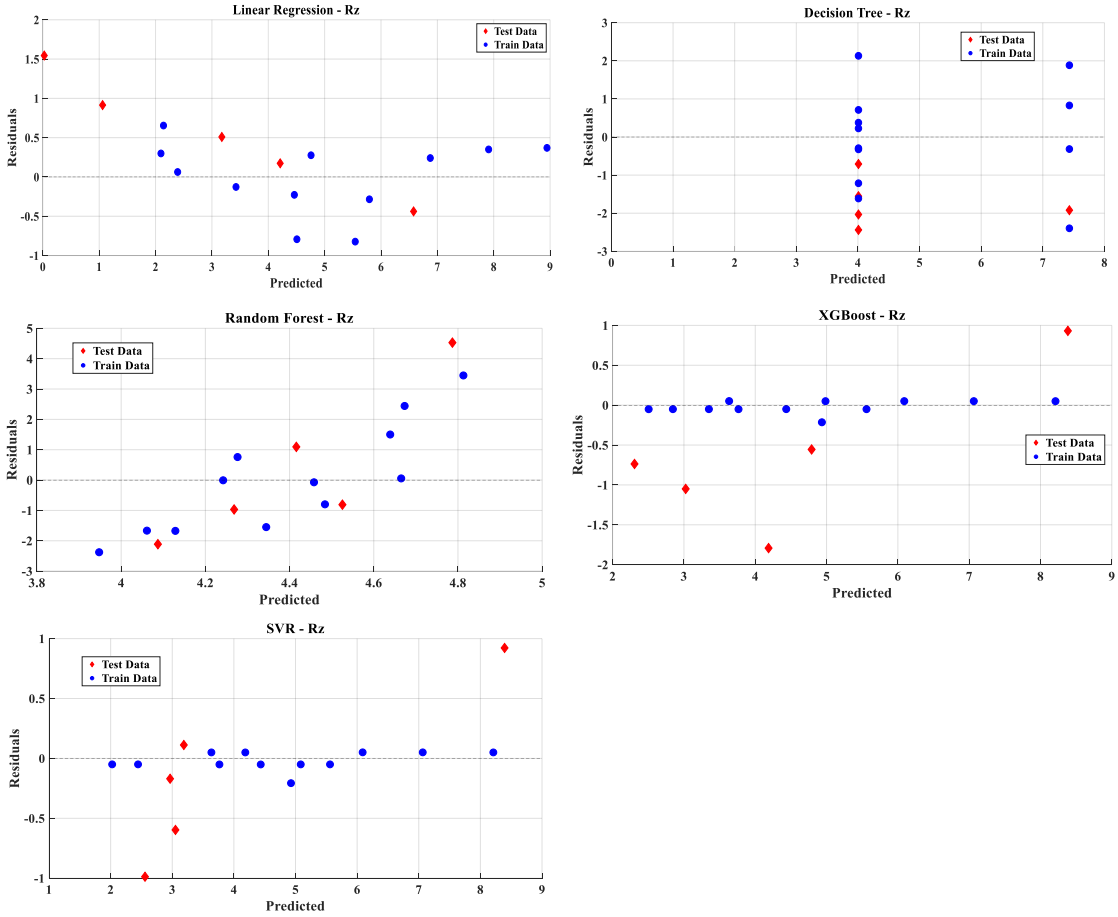

شکل ۸ نمودارهای باقیمانده (مقادیر باقیمانده در مقابل مقادیر برازش شده) R_z برای هر مدل، که داده‌های آموزشی را با دایره‌های آبی (●) و داده‌های آزمایشی را با مربع‌های قرمز (♦) نشان می‌دهد، با یک خط خاکستری خط‌چین در نقطه صفر که نشان‌دهنده عدم خطا است.

Fig. 8 Residual Plots (Residuals vs. Fitted Values) for R_z in Each Model, with Training Data Represented by Blue Circles (●) and Testing Data by Red Squares (♦), and a Gray Dashed Line at Zero Indicating No Error.

جدول ۷ مقادیر R^2، RMSE و MAE برای پارامتر R_z مربوط به هر مدل یادگیری ماشین در مراحل آموزش و آزمون.

Table 7 R^2, RMSE, and MAE Values for the R_z Parameter Corresponding to Each Machine Learning Model in the Training and Testing Stages.

Model	Train			Test		
	R^2	RMSE	MAE	R^2	RMSE	MAE
Linear Regression	0.9586	0.4443	0.3757	0.7321	0.8607	0.7160
Decision Tree	0.6146	1.278	1.0262	-0.7075	1.8271	1.7312
Random Forest	0.2186	1.707	1.3625	0.1404	2.3562	1.9027
XGBoost	0.9978	0.0784	0.0639	0.8523	1.0984	1.0131
Support Vector Regression	0.9981	0.0766	0.0632	0.9421	0.667	0.5578

۳-۳- میکروسختی

در شکل ۹ که نمودارهای پیش‌بینی میکروسختی (پارامتر H) را برای مدل‌های مختلف در مراحل آموزش و آزمون نشان می‌دهد، عملکرد هر مدل به‌وضوح قابل ارزیابی است. مدل رگرسیون خطی در مرحله آموزش عملکرد خوبی داشت، اما در داده‌های آزمون پیش‌بینی‌ها به‌شدت از خط ایده‌آل فاصله دارد که نشان‌دهنده ضعف در تعمیم به داده‌های جدید است. این مشکل ناشی از سادگی مدل و ناتوانی آن در مدل‌سازی روابط پیچیده و غیرخطی است. درخت تصمیم در آموزش عملکرد نسبی داشت، اما در آزمون به دلیل بیش‌برازش، پیش‌بینی‌ها به‌طور قابل‌توجهی از خط ایده‌آل منحرف شدند. این امر نشان‌دهنده ناتوانی مدل در تعمیم به داده‌های جدید است. جنگل تصادفی به نسبت درخت تصمیم عملکرد بهتری داشته و پیش‌بینی‌های آن در داده‌های آزمون به‌طور نسبی به خط ایده‌آل، نزدیک‌تر است، هرچند که برای دقت بالاتر، نیاز به بهینه‌سازی دارد. XGBoost و SVR در هر دو مرحله آموزش و آزمون بهترین عملکرد را داشتند. پیش‌بینی‌های این مدل‌ها به‌طور دقیق به خط ایده‌آل نزدیک است که نشان‌دهنده توانایی بالای آن‌ها در تعمیم به داده‌های جدید و جلوگیری از بیش‌برازش است.

عملکرد مدل‌های مختلف یادگیری ماشین در پیش‌بینی پارامتر H در دو مرحله آموزش و آزمون به‌طور دقیق در شکل ۱۰ نمایش داده شده است. مدل رگرسیون خطی به‌طور نسبی در داده‌های آموزش پیش‌بینی‌هایی دقیق داشته، اما در داده‌های آزمون با انحرافات

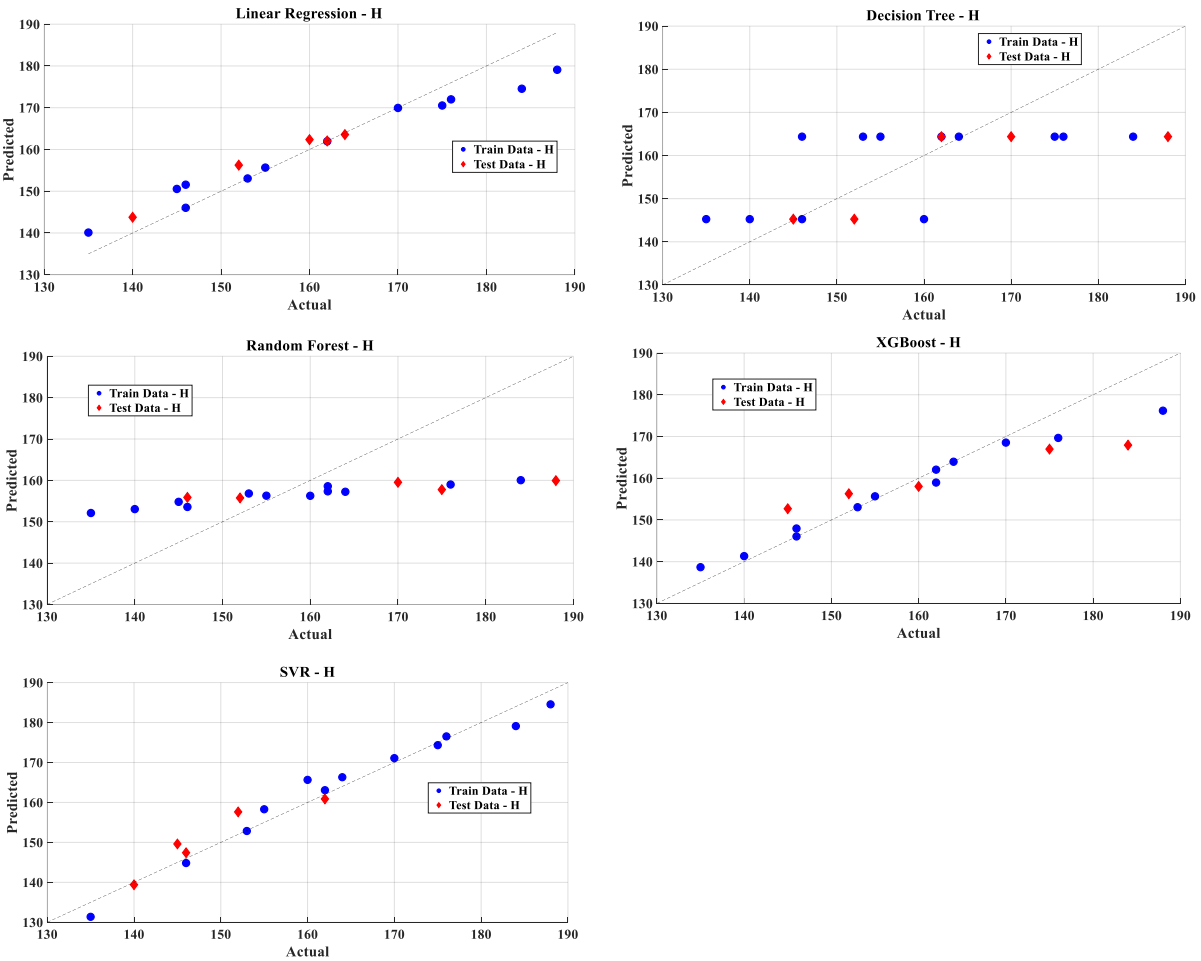

شکل ۹ نمودار پراکندگی مقادیر پیش‌بینی‌شده در مقابل مقادیر واقعی H برای مجموعه داده‌های آموزشی (دایره‌های آبی ●) و آزمایشی (مربع‌های قرمز ♦) در تمام مدل‌های یادگیری ماشین، با خط خاکستری مورب که نشان‌دهنده برازش ایده‌آل است.

Fig. 9 Scatter Plot of Predicted vs. Actual H Values for the Training (Blue Circles ●) and Testing (Red Squares ♦) Datasets in All Machine Learning Models, with a Diagonal Gray Line Representing Ideal Fit.

زیادی مواجه است. این کاهش دقت در آزمون به وضوح بیانگر ناتوانی مدل در مدل‌سازی روابط پیچیده داده‌ها است. مدل درخت تصمیم نیز در داده‌های آموزش عملکرد مناسبی دارد، اما در آزمون با انحرافات گسترده‌ای از خط ایده‌آل روبه‌رو است. این وضعیت به‌وضوح نشان می‌دهد که مدل به‌خوبی ویژگی‌های خاص داده‌های آموزش را یاد گرفته، ولی نتواسته است این یادگیری را به‌طور مؤثر به داده‌های جدید تعمیم دهد. جنگل تصادفی نیز در مرحله آموزش پیش‌بینی‌های دقیقی ارائه می‌دهد، اما در داده‌های آزمون با باقیمانده‌های بزرگ‌تر مواجه است که به‌طور مستقیم نشان‌دهنده مشکلات بیش‌برازش و کاهش دقت پیش‌بینی‌ها در آزمون است. در مقابل، XGBoost و SVR پیش‌بینی‌هایی دقیق در هر دو مرحله آموزش و آزمون ارائه داده‌اند. پیش‌بینی‌ها در داده‌های آزمون به‌طور نزدیک به خط ایده‌آل قرار دارند و باقیمانده‌ها در این مرحله بسیار کوچک و نزدیک به صفر هستند، که نشان‌دهنده تعمیم مؤثر و دقت بالا در پیش‌بینی پارامتر H است. به‌طور کلی، XGBoost و SVR بهترین عملکرد را در پیش‌بینی پارامتر H داشته‌اند.

بر اساس جدول ۸، عملکرد مدل‌های مختلف در پیش‌بینی پارامتر H در مراحل آموزش و آزمون متفاوت است. مدل رگرسیون خطی در مرحله آموزش عملکرد خوبی داشت، اما در آزمون R^2 آن به ۰/۸۰۱ کاهش می‌یابد که نشان‌دهنده ضعف مدل در تعمیم به داده‌های جدید است. این کاهش دقت با افزایش RMSE و MAE همراه بود. درخت تصمیم و جنگل تصادفی در هر دو مرحله آموزش و آزمون عملکرد ضعیفی دارند. درخت تصمیم و جنگل تصادفی اصلاً نتواسته‌اند داده‌های آزمون را پیش‌بینی کنند که نشان‌دهنده بیش‌برازش است و این مدل‌ها دارای باقیمانده‌های بزرگی در داده‌های آزمون هستند. XGBoost در مرحله آموزش عملکرد خوبی با R^2 حدود ۰/۹۲ دارد، اما در آزمون این مقدار به ۰/۶۱۱ کاهش می‌یابد. باوجوداین، پیش‌بینی‌های آن هنوز بهتر از برخی مدل‌های دیگر است. RMSE و MAE در داده‌های آزمون به ترتیب ۸/۹۸۹ و ۷/۶۰۷ هستند که نشان می‌دهد روش XGBoost نیاز به بهینه‌سازی بیشتر دارد.

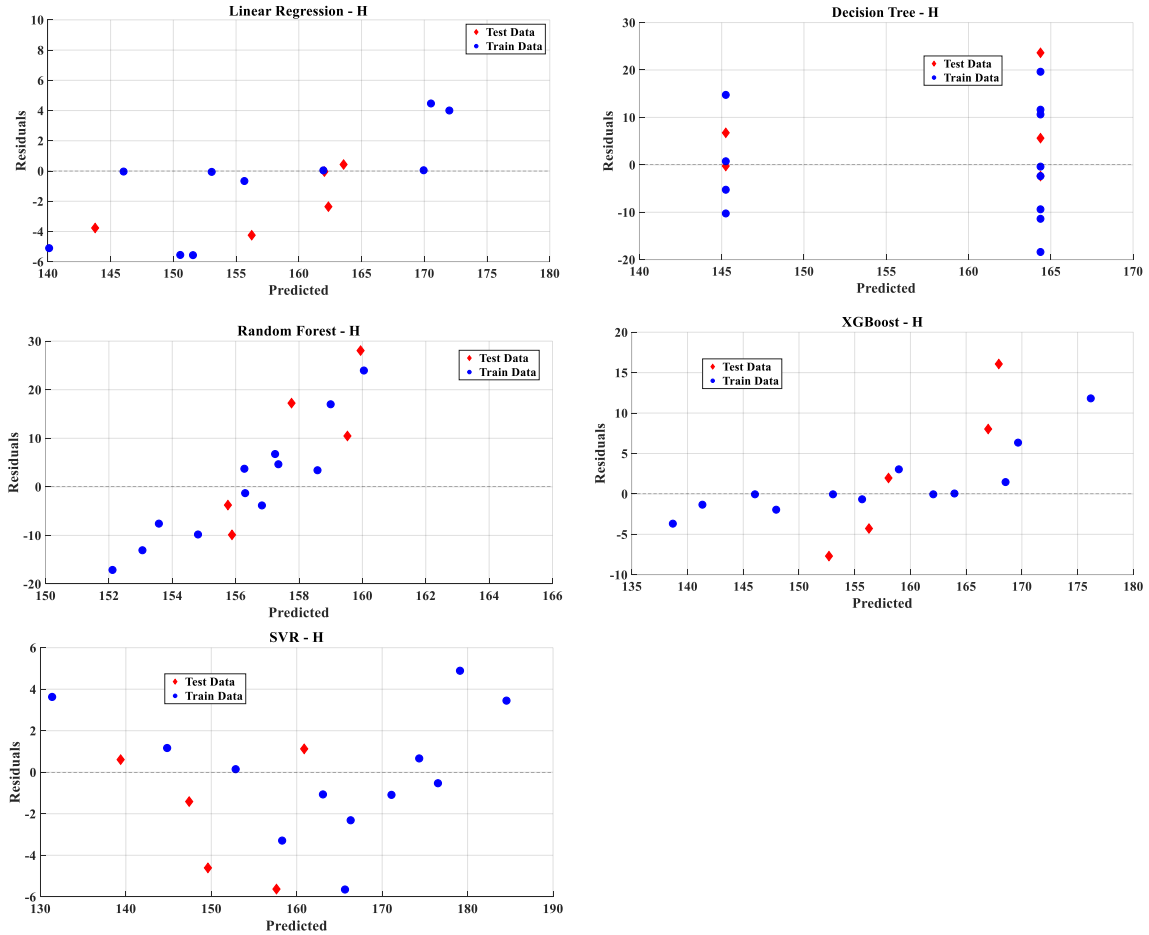

شکل ۱۰ نمودارهای باقیمانده (مقادیر باقیمانده در مقابل مقادیر برازش شده) H برای هر مدل، که داده‌های آموزشی را با دایره‌های آبی (●) و داده‌های آزمایشی را با مربع‌های قرمز (♦) نشان می‌دهد، با یک خط خاکستری خط‌چین در نقطه صفر که نشان‌دهنده عدم خطا است.

Fig. 10 Residual Plots (Residuals vs. Fitted Values) for H in Each Model, with Training Data Represented by Blue Circles (●) and Testing Data by Red Squares (♦), and a Gray Dashed Line at Zero Indicating No Error.

جدول ۸ مقادیر R^2، RMSE و MAE برای پارامتر H مربوط به هر مدل یادگیری ماشین در مراحل آموزش و آزمون.

Table 8 R^2, RMSE, and MAE Values for the H Parameter Corresponding to Each Machine Learning Model in the Training and Testing Stages.

Model	Train			Test		
	R^2	RMSE	MAE	R^2	RMSE	MAE
Linear Regression	0.9096	4.9416	3.6586	0.80084	3.3634	2.6768
Decision Tree	0.3871	11.3454	9.5625	0.42723	11.323	7.725
Random Forest	0.2955	11.5074	9.3494	-0.10957	16.1601	13.8813
XGBoost	0.9192	4.1919	2.5414	0.7111	8.9887	7.6068
Support Vector Regression	0.9619	2.9087	2.3243	0.9119	2.7562	2.1689

روش SVR در هر دو مرحله آموزش و آزمون بهترین عملکرد را از خود نشان داد. این مدل با R^2 معادل ۰/۹۶۲ در آموزش و ۰/۹۰۲ در آزمون، توانست پیش‌بینی‌های دقیقی ارائه دهد. همچنین، باقیمانده‌های کوچک (RMSE و MAE) نشان‌دهنده توانایی بالای این مدل در تعمیم به داده‌های جدید و دقت بالای پیش‌بینی‌ها است.

۴-۳- تحلیل اثر پارامترهای ورودی بر شاخص‌های کیفیت سطح

با توجه به نتایج به‌دست‌آمده از مقایسه مدل‌های مختلف یادگیری ماشین، مدل SVR به‌عنوان دقیق‌ترین و پایدارترین مدل برای پیش‌بینی شاخص‌های کیفیت سطح انتخاب شد. ازاین‌رو، در این بخش به بررسی اثر پارامترهای ورودی شامل قطر گوی، عمق نفوذ کل و نرخ پیشروی بر خروجی‌های موردنظر یعنی R_a، R_z و میکروسختی سطح (H) پرداخته می‌شود. از آنجا که مدل‌های یادگیری ماشین، به‌ویژه مدل‌های غیرخطی مانند SVR، روابط بین ورودی‌ها و خروجی‌ها را به‌صورت ضمنی و در قالب یک ساختار غیرشفاف جعبه سیاه (Black Box) مدل‌سازی می‌کنند، تحلیل مستقیم اثر هر پارامتر ورودی امکان‌پذیر نیست. در این راستا، از نمودارهای وابستگی جزئی (Partial Dependence Plots – PDP) به‌عنوان یک ابزار تفسیرپذیر استفاده شده است. PDP با میانگین‌گیری اثر یک متغیر ورودی بر خروجی مدل، در حالی که سایر متغیرها ثابت در نظر گرفته می‌شوند، امکان بررسی اثر کلی و غیرخطی هر پارامتر فرایندی بر پاسخ مدل را فراهم می‌کند. به همین دلیل، این روش به‌طور گسترده برای تفسیر مدل‌های جعبه‌سیاه در مسائل مهندسی و داده‌محور به‌کار گرفته می‌شود [۳۲].

بر اساس نمودارهای وابستگی جزئی در شکل ۱۱، افزایش پارامترهای فرایندی به‌طور کلی موجب افزایش میکروسختی سطح می‌شود که می‌توان آن را به افزایش میزان تغییرشکل پلاستیک و چگالی نابجایی‌ها در لایه سطحی و در نتیجه تقویت کارسختی نسبت داد. از سوی دیگر، افزایش عمق نفوذ و نرخ پیشروی برنیشینگ با افزایش R_a همراه است؛ زیرا عمق نفوذ بیشتر شدت تماس و تغییرشکل موضعی را افزایش داده و نرخ پیشروی بالاتر نیز زمان مؤثر هموارسازی و فرصت جریان پلاستیک یکنواخت را

جدول ۹ اهمیت نسبی پارامترهای ورودی بر خروجی‌های مدل SVR براساس نمودارهای وابستگی جزئی میانگین.

Table 9 Relative importance of input parameters on different output responses based on mean partial dependence plots of the SVR model.

Output	Input Parameter	Relative Importance (%)
R_a	Ball diameter	30.4
	Burnishing depth	43.5
	Burnishing feed rate	23.1
R_z	Ball diameter	29.8
	Burnishing depth	47.1
	Burnishing feed rate	23.1
Micro Hardness (H)	Ball diameter	28.7
	Burnishing depth	41.6
	Burnishing feed rate	29.7

کاهش می‌دهد، که مجموعاً می‌تواند به باقی‌ماندن ناهمواری‌های ریز و افزایش زبری منجر شود. در مقابل، افزایش قطر گوی باعث کاهش R_a می‌گردد؛ چراکه با بزرگ‌تر شدن شعاع تماس، فشار تماس موضعی و گرادیان تغییرشکل کاهش یافته و اثر هموارسازی سطح یکنواخت‌تر می‌شود. همین الگوی رفتاری مشاهده‌شده برای R_a، به‌طور مشابه برای R_z نیز برقرار است، زیرا هر دو شاخص از مورفولوژی پروفیل سطح تأثیر پذیرفته و نسبت به تغییرات شرایط تماس و مکانیزم هموارسازی حساس هستند.

به‌منظور ارزیابی اهمیت نسبی پارامترهای ورودی، از PDP استفاده شد. در این چارچوب، اثر هر پارامتر بر خروجی مدل SVR، از طریق میانگین‌گیری پاسخ مدل نسبت به تغییرات آن پارامتر، استخراج گردید. دامنه تغییرات پاسخ مدل در منحنی‌های PDP به‌عنوان شاخصی برای سنجش میزان تأثیر هر پارامتر در نظر گرفته شد. نتایج کمّی حاصل از این تحلیل به‌صورت خلاصه در جدول X ارائه شده است.

بر اساس نتایج ارائه‌شده در جدول ۹، عمق نفوذ در هر سه خروجی مورد بررسی بیشترین اهمیت نسبی را به خود اختصاص داده است، به‌طوری‌که سهم آن در پیش‌بینی R_a، R_z و میکروسختی سطح به‌ترتیب ٤٣/٥٪، ٤٧/١٪ و ٤١/٦٪ بدست آمد. این مقادیر به‌روشنی بیانگر نقش غالب عمق نفوذ، در کنترل شدت تغییرشکل پلاستیک و شرایط تماس گوی–سطح است؛ به‌گونه‌ای که افزایش عمق نفوذ موجب افزایش تنش‌های تماسی و کرنش پلاستیک مؤثر در لایه سطحی شده و در نتیجه هم بر تکامل مورفولوژی پروفیل سطح (R_a و R_z) و افزایش میکروسختی سطح اثر مستقیم می‌گذارد.

هم‌چنین، قطر گوی سهم قابل‌توجهی در زبری سطح نشان می‌دهد، به‌ویژه برای R_a با اهمیت نسبی حدود ٣٠/٤٪ و برای R_z با مقدار ٢٩/٨٪، که این موضوع به افزایش شعاع تماس و توزیع یکنواخت‌تر تنش‌های تماسی نسبت داده می‌شود؛ مکانیزمی که منجر به هموارسازی مؤثرتر سطح و کاهش مؤلفه‌های R_a و R_z می‌گردد. نرخ پیشروی نیز اگرچه در مقایسه با عمق نفوذ اهمیت کمتری دارد، اما همچنان سهم قابل‌توجهی در پاسخ مدل ایفا می‌کند. در مجموع، تحلیل مبتنی بر PDP مدل SVR امکان تفکیک سهم اثر نسبی هر پارامتر فرایندی را فراهم کرد.

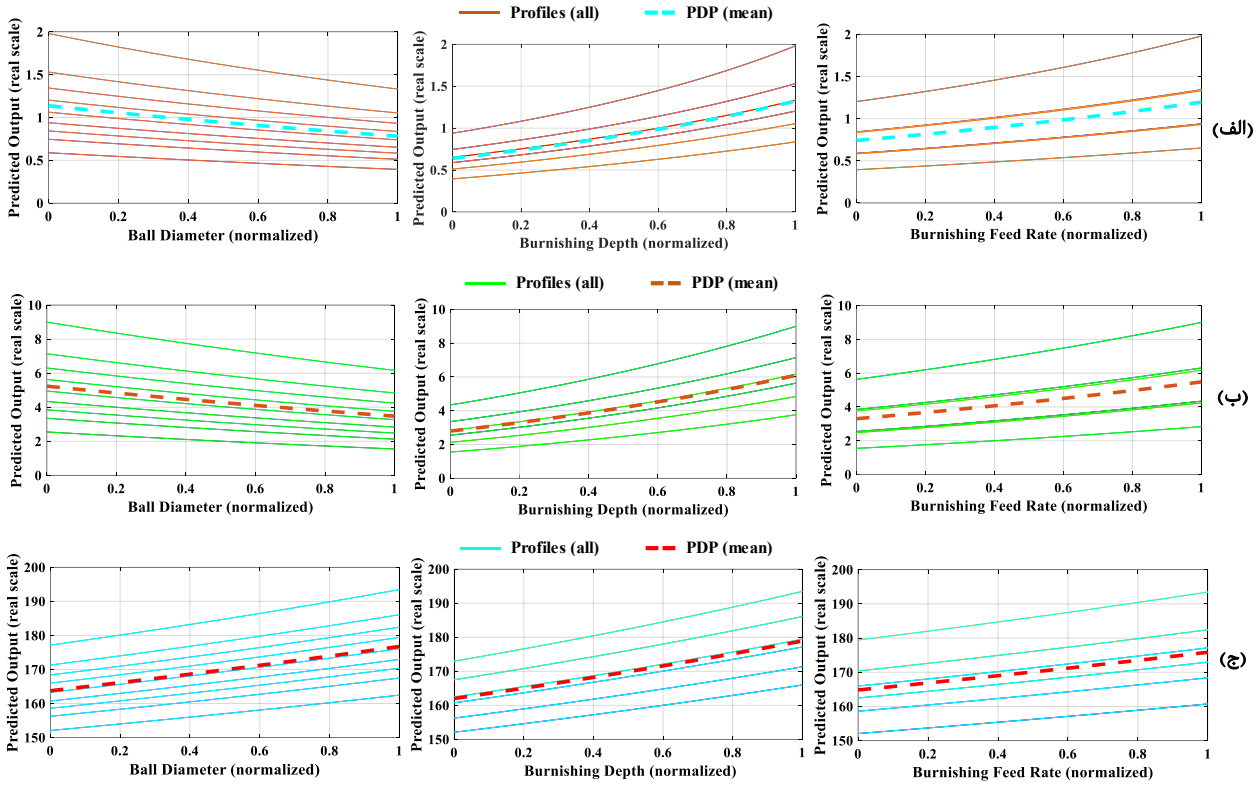

شکل ۱۱ نمودارهای وابستگی جزئی که اثر میانگین هر یک از پارامترهای ورودی (قطر گوی، عمق نفوذ و نرخ پیشروی برنیشینگ) را بر پیش‌بینی پارامترهای زبری سطح به‌ترتیب برای (الف) R_a، (ب) R_z و (ج) میکروسختی سطح (H) نشان می‌دهند.

Fig. 11 Partial dependence plots illustrating the mean effect of each input parameter (ball diameter, burnishing depth, and burnishing feed rate) on the predicted surface roughness parameters for (a) R_a, (b) R_z, and (c) surface microhardness (H).

۴- نتیجه‌گیری

در این مطالعه، برخلاف بسیاری از پژوهش‌های پیشین که عمدتاً به راهبردهای تک‌گذره یا مدل‌های کلاسیک برای پیش‌بینی ویژگی‌های سطح محدود بوده‌اند، یک چارچوب داده‌محور مبتنی بر مدل‌های یادگیری ماشین برای پیش‌بینی هم‌زمان چند شاخص اصلی کیفیت سطح شامل زبری سطح (پارامترهای R_a و R_z) و میکروسختی سطح ارائه شد. این رویکرد امکان مدل‌سازی رفتارهای غیرخطی و برهم‌کنش‌های پیچیده میان پارامترهای فرایند را فراهم ساخت. نتایج نشان داد که مدل SVR در مقایسه با سایر مدل‌ها عملکرد برجسته‌تری در پیش‌بینی پارامترهای کیفیت سطح دارد؛ به‌طوری‌که مقادیر R^2 برابر با ۰/۹۲۵ برای R_a، ۰/۹۴۲ برای R_z و ۰/۹۱۰ برای میکروسختی به‌دست آمد که بیانگر دقت بالای این مدل است. این سطح از دقت با مقادیر پایین RMSE و MAE همراه بود که توانایی مدل SVR در تعمیم به داده‌های جدید را تأیید می‌کند. در مقابل، مدل XGBoost اگرچه نتایج قابل قبولی ارائه داد، اما دقت آن به‌ویژه در پیش‌بینی میکروسختی کمتر از SVR بود. تحلیل تفسیرپذیر مبتنی بر نمودارهای وابستگی جزئی امکان ارزیابی کمّی اثر نسبی پارامترهای فرایندی را فراهم کرد؛ به‌طوری‌که عمق نفوذ فرایند با سهمی حدود ۴۱ الی ۴۷ درصد در تمامی خروجی‌ها بیشترین اثرگذاری را نشان داد، در حالی که قطر گوی و نرخ پیشروی به‌طور متوسط سهمی در بازه ۲۳ الی ۳۰ درصد داشتند. بنابراین، نتایج این مطالعه تأیید می‌کند که به‌کارگیری مدل‌های پیشرفته یادگیری ماشین، نه‌تنها چارچوبی کارآمد و قابل‌اعتماد برای پیش‌بینی شاخص‌های کیفیت سطح در فرایندهای صنعتی فراهم می‌آورد، بلکه امکان شناسایی و تفکیک کمّی اهمیت نسبی پارامترهای ورودی را نیز فراهم می‌سازد. علاوه بر این، مشخص شد که کیفیت سطح نهایی در فرایند برنیشینگ عمیق، حاصل برهم‌کنش هم‌زمان مکانیزم‌های تماس، تغییرشکل پلاستیک و شرایط سینماتیکی فرایند است.

تأییدیه اخلاقی: محتویات علمی این مقاله حاصل پژوهش نویسندگان است و در هیچ نشریه ایرانی و غیرایرانی منتشر نشده است.

تعارض منافع: در این مقاله از برخی نتایج حاصل از رساله دکتری نویسنده اول استفاده شده است. هیچ تعارض منافع دیگری برای اظهار وجود ندارد.

منابع

[1] A. Rasti, M. H. Sadeghi, and S. S. Farshi, "An investigation into the effect of surface integrity on the fatigue failure of AISI 4340 steel in different drilling strategies," *Engineering Failure Analysis,* vol. 95, pp. 66-81, 2019. doi: 10.1016/j.engfailanal.2018.08.022

[2] A. C. Petare and N. K. Jain, "A critical review of past research and advances in abrasive flow finishing process," *The International Journal of Advanced Manufacturing Technology,* vol. 97, no. 1, pp. 741-782, 2018. doi: 10.1007/s00170-018-1928-7
[3] P. Sender and I. Buj-Corral, "Influence of honing parameters on the quality of the machined parts and innovations in honing processes," *Metals,* vol. 13, no. 1, p. 140, 2023. doi: 10.3390/met13010140
[4] X. Wang, X. Li, W. Li, and S. Yang, "Role of dry media in influencing performance during processing by centrifugal superfinishing," *Materials and Manufacturing Processes,* vol. 40, no. 3, pp. 353-364, 2025. doi: 10.1080/10426914.2024.2425618
[5] Y. Yang, W. Li, S. Yang, and X. Li, "Investigation and optimization of parameters for bidirectional composite vibratory finishing of gears," *Materials and Manufacturing Processes,* vol. 40, no. 4, pp. 547-556, 2025. doi: 10.1080/10426914.2024.2437762
[6] A. M. Mebarek, M. Bourebia, L. Laouar, and N. Bouchelaghem, "Effect of ball burnishing process on surface roughness and corrosion behavior of S235JR steel," *The International Journal of Advanced Manufacturing Technology,* vol. 130, no. 7, pp. 3431-3444, 2024. doi: 10.1007/s00170-023-12906-9
[7] M. Ozer, K. Dalli, and A. Ozer, "Effect of ball-burnishing on surface integrity and fatigue behaviour of 7175-T6 AA," *Materials Science and Technology,* vol. 39, no. 2, pp. 248-257, 2023. doi: 10.1080/02670836.2022.2142744
[8] A. Khodabandeh, D. Sayadi, S. Rajabi, M. Khosrojerdi, M. Khajehzadeh, and M. R. Razfar, "Surface integrity and fatigue behavior of AISI 4340 steel after hybrid laser-ultrasonic assisted ball burnishing process," *Proceedings of the Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science,* vol. 238, no. 15, pp. 7607-7626, 2024. doi: 10.1177/09544062241232236
[9] A. Torres, N. Cuadrado, J. Llumà, M. Vilaseca, and J. A. Travieso-Rodriguez, "Influence of the stainless-steel microstructure on tribological behavior and surface integrity after ball burnishing," *Materials,* vol. 15, no. 24, p. 8829, 2022. doi: 10.3390/ma15248829
[10] H. Pathade *et al.*, "A review on surface integrity of ball burnishing process," *Int. J. Res. Publ. Rev,* vol. 3, pp. 137-151, 2022. doi: 10.55248/gengpi.2022.3.10.3
[11] R. O. Vaishya *et al.*, "Mathematical modeling and experimental validation of surface roughness in ball burnishing process," *Coatings,* vol. 12, no. 10, p. 1506, 2022. doi: 10.3390/coatings12101506
[12] M. S. Uddin, C. Hall, R. Hooper, E. Charrault, P. Murphy, and V. Santos, "Finite element analysis of surface integrity in deep ball-burnishing of a biodegradable AZ31B Mg alloy," *Metals,* vol. 8, no. 2, p. 136, 2018. doi: 10.3390/met8020136
[13] G. Jagadeesh and S. Gangi Setti, "A review on latest trends in ball and roller burnishing processes for enhancing surface finish," *Advances in Materials and Processing Technologies,* vol. 8, no. 4, pp. 4499-4523, 2022. doi: 10.1080/2374068X.2022.2077534
[14] A. Rasti, J. Kazemi, S. Mohammadi, and A. Zeinolabedin-Beygi, "Deep ball burnishing of Al 2024-T4: insights into surface roughness, microhardness, topography, and chemical alteration," *Materials and Manufacturing Processes,* vol. 40, no. 16, pp. 2203-2217, 2025. doi: 10.1080/10426914.2025.2575175
[15] S. Dzionk, B. Ścibiorski, and W. Przybylski, "Problems of flaking in strengthening shaft burnishing," in *International Scientific-Technical Conference MANUFACTURING*, 2019: Springer, pp. 108-121. doi: 10.1007/978-3-030-16943-5_10
[16] J. A. Travieso-Rodríguez, G. Dessein, and H. A. González-Rojas, "Improving the surface finish of concave and convex surfaces using a ball burnishing process," *Materials and Manufacturing Processes,* vol. 26, no. 12, pp. 1494-1502, 2011. doi: 10.1080/10426914.2010.544819
[17] G. Capilla-González, I. Martínez-Ramírez, D. Díaz-Infante, E. Hernández-Rodríguez, V. Alcantar-Camarena, and A. Saldaña-Robles, "Effect of the ball burnishing on the surface quality and mechanical properties of a TRIP steel sheet," *The International Journal of Advanced Manufacturing Technology,* vol. 116, no. 11, pp. 3953-3964, 2021. doi: 10.1007/s00170-021-07715-x
[18] C. Priyadarsini, V. V. Ramana, K. A. Prabha, and S. Swetha, "A review on ball, roller, low plasticity burnishing process," *Materials Today: Proceedings,* vol. 18, pp. 5087-5099, 2019. doi: 10.1016/j.matpr.2019.07.505
[19] Q. Zhang *et al.*, "A review of low-plasticity burnishing and its applications," *Advanced Engineering Materials,* vol. 24, no. 11, p. 2200365, 2022. doi: 10.1002/adem.202200365
[20] M. Safari, A. H. Rabiee, and J. Joudaki, "Developing a support vector regression (SVR) model for prediction of main and lateral bending angles in laser tube bending process," *Materials,* vol. 16, no. 8, p. 3251, 2023. doi: 10.1002/adem.202200365
[21] A. Rasti, A. H. Rabiee, A. Zeinolabedin-Beygi, and M. Yazdani, "Surface Roughness and Microhardness Prediction: A Machine Learning Approach for Electrochemical Grinding," *Modares Mechanical Engineering,* vol. 25, no. 9, 2025. doi: 10.48311/mme.2025.27590
[22] U. U. N. MRE and Z. NAPOVED, "Use of artificial neural networks in ball burnishing process for the prediction of surface roughness of AA 7075 aluminum alloy," *Materiali in tehnologije,* vol. 42, no. 5, pp. 215-219, 2008. UDK: 669.715:620.17.112
[23] R. Kluz, K. Antosz, T. Trzepieciński, and M. Bucior, "Modelling the influence of slide burnishing parameters on the surface roughness of shafts made of 42CrMo4 heat-treatable steel," *Materials,* vol. 14, no. 5, p. 1175, 2021. doi: 10.3390/ma14051175
[24] Z. Kanovic *et al.*, "The modelling of surface roughness after the ball burnishing process with a high-stiffness tool by using regression analysis, artificial neural networks, and support vector regression," *Metals,* vol. 12, no. 2, p. 320, 2022. doi: 10.3390/met12020320
[25] D. Mahajan and R. Tajane, "The optimization of surface roughnessof Al 6061 using Taguchi method in ball burnishing process," *International Journal of*

[28] D. C. Montgomery, E. A. Peck, and G. G. Vining, *Introduction to linear regression analysis*. John Wiley & Sons, 2021. ISBN: 978-1-119-57872-7
[29] L. Breiman, J. Friedman, R. A. Olshen, and C. J. Stone, *Classification and regression trees*. Chapman and Hall/CRC, 2017. doi: 10.1201/9781315139470
[30] L. Breiman, "Random forests," *Machine learning,* vol. 45, no. 1, pp. 5-32, 2001. doi: 10.1023/A:1010933404324
[31] T. Chen, "XGBoost: A Scalable Tree Boosting System," *Cornell University,* 2016. doi: 10.1145/2939672.2939785
[32] C. Molnar, *Interpretable machine learning*. Lulu. com, 2020. ISBN: 978-0-244-76852-2
Scientific and Research Publications, vol. 3, no. 10, 2013. ISSN: 2250-3153
[26] K. Wakamatsu, K. Takahashi, Y. Koyama, and M. Taniguchi, "Fatigue strength improvement of aluminum alloy with surface defect by ball burnishing," *Fatigue & Fracture of Engineering Materials & Structures,* vol. 47, no. 9, pp. 3464-3473, 2024. doi: 10.1111/ffe.14372
[27] Z. Liu, Q. Dai, J. Deng, Y. Zhang, and V. Ji, "Analytical modeling and experimental verification of surface roughness in the ultrasonic-assisted ball burnishing of shaft targets," *The International Journal of Advanced Manufacturing Technology,* vol. 107, no. 7, pp. 3593-3613, 2020. doi: 10.1007/s00170-020-05261-6