

مدلسازی مبتنی بر یادگیری ماشین فرآیندهای ساخت افزایشی فلزی با استفاده از روش‌های داده افزایی و یادگیری گروهی

نیما ایوبی^۱، رضا محبوبی اسفنجانی^۲، احمد اکبری^۳، حبیب بدری قویفکر^۴

چکیده با وجود قابلیت‌های فراوان ساخت افزایشی فلزی، این روش با محدودیت‌هایی از جمله قابلیت تکرارپذیری و تضمین کیفیت قطعات مواجه می‌باشد. جهت رفع این محدودیت‌ها به مدلسازی دقیق فرآیند نیاز است. از طرفی، کارایی روش‌های مدلسازی سنتی برای این امر پایین می‌باشد. یکی از روش‌های جدید مدلسازی مبتنی بر داده که امکان کشف الگوهای پنهان در فرآیندهای غیرخطی را فراهم می‌کند، یادگیری ماشین است. با وجود مزایای فراوان، به دلیل تعداد محدود داده در فرآیند ساخت افزایشی، پیاده‌سازی یادگیری ماشین با مشکلاتی مواجه است. در این مقاله برای رفع این موارد از ترکیب داده‌افزایی و یادگیری ماشین برای مدلسازی دو روش شناخته شده ساخت افزایشی فلزی استفاده شده است. نتایج شبیه‌سازی نشان دهنده کارایی روش پیشنهادی در مدلسازی مناسب فرآیند ساخت افزایشی فلزی می‌باشد.

واژه‌های کلیدی – ساخت افزایشی فلزی، یادگیری ماشین، داده افزایی، یادگیری گروهی، مدلسازی

Machine Learning-Based Modeling of Metal Additive Manufacturing Processes Using Data Augmentation and Ensemble Learning

Abstract Although metal additive manufacturing offers many advantages, it is restricted by the repeatability and quality assurance of the produced parts. Accurate mathematical modeling of the process is essential to tackle these limitations. Traditional mathematical modeling approaches are inefficient in describing this complicated system. Machine learning is a novel data-driven modeling approach to discover hidden patterns in nonlinear systems. However, applying this scheme in the metal additive manufacturing process is challenging due to the limited data samples. This paper uses machine learning and data augmentation to tackle the mentioned issues and model two well-known metal additive manufacturing processes. Simulation results demonstrate the effectiveness of the proposed method in modeling the metal additive manufacturing processes.

Key Words – Metal additive manufacturing, Machine learning, Data augmentation, Ensemble learning, Modeling.

نمونه‌سازی سریع، ساخت افزایشی فلزی که با استفاده از آن می‌توان قطعات با ساختار پیچیده را از آلیاژهای فلزی مختلف تولید کرد، مورد توجه واقع شده است. در صورت نیاز می‌توان با استفاده از ساخت افزایشی فلزی قطعات فرسوده و معیوب که در طول زمان دچار خرابی شده‌اند را نیز تعمیر کرد. امکان ساخت قطعات با چگالی و استحکام بالا با کم‌ترین میزان تولید پسماند به وسیله این فرآیندها ممکن شده است [۲].

با وجود مزایای فراوانی که ساخت افزایشی فلزی دارد، روش مذکور در سطح تجاری مشکلاتی از جمله تضمین کیفیت بالا و تکرارپذیری دارد. مدلسازی این فرآیندها برای بررسی اثر پارامترهای مختلف روی خروجی و حفظ برخی ویژگی‌های قطعه ساخته شده چالشی می‌باشد. پارامترهایی مانند تخلخل، چگالی و کیفیت سطح جهت ساخت قطعات

۱- مقدمه

در سالیان اخیر نیاز به ساخت قطعات با کیفیت و دارای ساختارهای پیچیده بیش از پیش احساس می‌شود. روش‌های تولید سنتی از جمله ریخته‌گری، شکل‌دهی و فرآیندهای ساخت کاهشی با محدودیت‌هایی در ساخت اشکال پیچیده مواجه هستند. این روش‌ها پسماند فراوانی تولید کرده و مصرف انرژی بالایی دارند. از طرفی روش‌های یاد شده برای ساخت قطعات سفارشی و شخصی‌سازی شده مناسب نبوده و از نظر اقتصادی برای نمونه‌سازی کارایی ندارند. برای رفع این مشکلات روش‌های ساخت افزایشی توسعه داده شده‌اند. ساخت افزایشی عبارت رسمی و تخصصی برای فرآیند نمونه‌سازی سریع می‌باشد و در عموم از آن به عنوان فناوری چاپ سه بعدی یاد می‌شود [۱]. از بین روش‌های

^۱ دانشجوی مقطع دکتری، دانشکده مهندسی برق-کنترل، دانشگاه صنعتی سهند تبریز، تبریز

^۲ نویسنده مسئول: استاد، دانشکده مهندسی برق-کنترل، دانشگاه صنعتی سهند تبریز، تبریز، Email: mahboobi@sut.ac.ir

^۳ دانشیار، دانشکده مهندسی برق-کنترل، دانشگاه صنعتی سهند تبریز، تبریز

^۴ استاد، دانشکده مهندسی برق-الکترونیک، دانشگاه صنعتی سهند تبریز، تبریز

با کیفیت باید در یک بازه مشخص حفظ شوند. پارامترهای متعددی مانند ویژگی‌های ماده، تنظیمات دستگاه و پایداری فرآیند روی کیفیت قطعه اثر گذار هستند؛ بنابراین مدل‌سازی ریاضی این فرآیندها چالشی می‌باشد. مدل‌های فیزیکی و سنتی ارائه داده شده برای این فرآیندها اغلب بسیار پیچیده هستند و به منابع محاسباتی قدرتمندی برای حل آن‌ها احتیاج است. این نوع مدل‌سازی اغلب توانایی آشکارسازی الگوهای پنهان در فرآیند به دلیل وقوع دینامیک‌های سریع و وجود پدیده‌های مختلف فیزیکی را ندارد. همچنین مدل‌سازی فیزیکی با ساده‌سازی در روابط همراه است که روی دقت پیش‌بینی خروجی اثر نامطلوبی دارد. از طرفی در حضور نامعینی کارکرد مدل‌سازی فیزیکی دچار مشکل می‌شود [۳]. امروزه برای غلبه بر مشکلات مدل‌سازی در فرآیندهای پیچیده و غیرخطی مانند ساخت افزایشی فلزی از روش‌های مبتنی بر داده یا ترکیبی از این روش‌ها با مدل‌سازی فیزیکی استفاده می‌شود. از میان این روش‌ها هوش مصنوعی و زیرشاخه شناخته شده آن یعنی یادگیری ماشین کارایی بالایی در زمینه مدل‌سازی غیرخطی دارند. در این میان ساخت افزایشی نیز به عنوان یک روش ساخت و تولید مدرن مطرح شده و ترکیب آن با هوش مصنوعی به عضو جدانشدنی زنجیره‌های تامین و تولید کارخانه‌ها مبدل شده است [۴]. یادگیری ماشین، توانایی یادگیری از داده‌های ورودی را بدون برنامه‌ریزی آشکار و صریح برای کامپیوتر فراهم می‌کند. استفاده از این روش نسبت به روش‌های مدل‌سازی سنتی ساده‌تر بوده و به سرعت می‌توان مدل‌های مختلفی برای داده‌های ورودی توسعه داد [۵]. داده‌های حاصل از خروجی فرآیندهای ساخت افزایشی چند بعدی، پیچیده و غیرخطی هستند. برخلاف روش‌های داده‌کاوی و یادگیری ماشین، رگرسیون‌های ساده و سنتی توانایی کشف الگوهای پنهان میان متغیرهای فرآیند را ندارند. این مورد در حضور نامعینی پارامتری، نویز اندازه‌گیری و عدم تعادل داده‌های به دست آمده که در ساخت افزایشی رایج است بیشتر نمایان می‌شود. سرعت توسعه مدل‌های یادگیری ماشین بسیار بالاتر بوده و به راحتی می‌توان از میان مدل‌های توسعه یافته بهترین مدل را انتخاب کرد. به خصوص در مورد داده‌هایی که تاکنون مدل ندیده است امکان ارائه پیش‌بینی‌های دقیق‌تری وجود دارد. همچنین ابزارهای موجود در این حوزه از جمله داده‌افزایی، توانایی بالایی در افزایش دقت مدل‌ها و صرفه جویی در هزینه و زمان دارند و امکان مدل‌سازی تطبیقی را فراهم می‌کنند. استفاده همزمان از داده‌افزایی و یادگیری ماشین سبب افزایش چشمگیر دقت مدل‌های ارائه داده شده می‌شود، امری که با رگرسیون‌های ساده امکان‌پذیر نیست. امروزه از هوش مصنوعی و یادگیری ماشین در زمینه‌های مختلف مهندسی استفاده می‌شود [۶]، [۷]، [۸]، [۹]. در ساخت افزایشی نیز از یادگیری ماشین برای

پیش‌بینی کیفیت و ابعاد قطعات ساخته شده [۱۰]، تعیین پارامترهای بهینه برای تضمین کیفیت قطعه در فرآیند بستر پودر لیزری [۱۱]، پیش‌بینی دمای حوضچه مذاب در فرآیند DED [۱۲] و کنترل زمان حقیقی فرآیند ساخت فیلامان ذوبی [۱۳] استفاده شده است. به طور کلی کاربردهای یادگیری ماشین در ساخت افزایشی شامل بهینه‌سازی پارامترهای فرآیند، پیش‌بینی ویژگی‌ها و کیفیت قطعه، تشخیص خرابی، کنترل حلقه بسته فرآیندها، برآورد هزینه تولید قطعات و بهینه‌سازی ساختار می‌باشند [۱۴]. با وجود مزایای فراوان ذکر شده برای یادگیری ماشین روش‌های مذکور با چند محدودیت مواجه هستند. این روش‌ها جهت اجرای مناسب و داشتن دقت بالا در پیش‌بینی مقادیر جدید نیاز به تعداد زیادی داده دارند. به عبارتی ماشین برای یادگیری رفتار فرآیند نیاز به داده‌های با کیفیت و بدون نویز با تعداد بالا دارد. همچنین انتخاب مدل مناسب و تنظیم پارامترهای مدل انتخابی نیز امری چالش‌انگیز است. از طرفی ادوات محاسباتی و پردازنده‌های موجود دارای توان محاسباتی و پردازشی محدود هستند. بنابراین استفاده از مدل‌های پیچیده می‌تواند سبب افزایش بی‌رویه بار محاسباتی شده و مشکلاتی از جمله بیش برآزش را در این مدل‌ها ایجاد کند [۱۵]. در برخی از کاربردهای یادگیری ماشین مانند پردازش تصویر و پردازش سیگنال‌های صوتی تعداد زیادی داده برای آموزش الگوریتم در دسترس هستند. با این وجود در تعدادی از کاربردهای علم مواد از جمله ساخت افزایشی امکان گرفتن هزاران نمونه داده از فرآیند وجود ندارد. انجام این کار مستلزم صرف هزینه و زمان بسیار زیاد می‌باشد و از لحاظ اقتصادی مقرون به صرفه نیست. همچنین هر چه مدل‌های ارائه داده شده برای مدل‌سازی این فرآیندها دقیق‌تر باشد، نیاز به انجام آزمایش‌های پرهزینه برای گرفتن نتایج خروجی مرتفع می‌گردد [۱۶].

جهت استفاده از روش‌های یادگیری ماشین برای مدل‌سازی این فرآیندها باید درجه و پارامترهای مدل را به صورت مناسب انتخاب کرد. از طرفی با استفاده از تکنیک‌های موجود مانند یادگیری انتقالی یا داده افزایی می‌توان مشکل کمبود داده‌ها را به صورت نرم‌افزاری مرتفع کرد. جهت رفع مشکلات یاد شده در این مقاله از ترکیب داده افزایی و یادگیری گروهی جهت ارائه یک مدل بهبود یافته برای مدل‌سازی فرآیندهای ساخت افزایشی فلزی استفاده شده است. جهت ارزیابی دقیق کارایی چهارچوب پیشنهادی، چندین مدل یادگیری ماشین برای ۲ نوع فرآیند ساخت افزایشی فلزی از جمله ذوب لیزری انتخابی (SLM) و رسوب‌گذاری مستقیم فلز لیزری (LDMD) استفاده شده است. مدل‌های ارائه داده شده قبل و بعد از اعمال داده‌افزایی به وسیله معیارهای آماری ارزیابی شده‌اند. با مقایسه مدل‌های موجود می‌توان

بهترین رهیافت را برای مدلسازی هر فرآیند انتخاب کرد. روش موجود امکان ترکیب با سایر روش‌های مبتنی بر داده را نیز دارد و می‌تواند در جهت افزایش کارایی و بهبود عملکرد این روش‌ها از جمله شبکه عصبی استفاده شود.


مقاله به این شرح ساختار بندی شده است: در بخش ۲ چهارچوب پیشنهادی به تفصیل مورد بررسی قرار داده می‌شود. در بخش ۳ فرمول‌بندی ریاضی و روش‌های مورد استفاده برای پیاده‌سازی چهارچوب پیشنهادی در قالب الگوریتم و معادلات ریاضی بیان می‌شوند. در بخش ۴ نتایج شبیه‌سازی در محیط پایتون و پیاده‌سازی الگوریتم‌ها برای چهارچوب پیشنهادی تحلیل می‌شود و در نهایت مقاله در بخش ۵ مقاله توسط بخش نتیجه‌گیری خاتمه می‌یابد.

۲- چهارچوب پیشنهادی

در این مقاله از ترکیب داده‌افزایی به روش CTGAN و یادگیری گروهی برای مدلسازی فرآیندهای ساخت افزایشی فلزی استفاده شده است. مطابق با شکل ۱ چهارچوب پیشنهادی شامل دو قسمت اصلی می‌باشد. در قسمت اول داده‌های حاصل از فرآیند ساخت افزایشی فلزی جمع‌آوری شده و پس از آماده‌سازی‌های اولیه داده‌افزایی روی آن‌ها اجرا می‌شود. در این قسمت الگوریتم CTGAN که در محیط پایتون پیاده‌سازی شده است، توزیع داده‌های اصلی را یاد می‌گیرد. در گام بعدی این الگوریتم بر اساس توزیع داده‌های اصلی شروع به اجرای فرآیند داده‌افزایی می‌کند. پس از اجرای این مرحله داده‌های جدید که تعدادشان از نمونه‌های اولیه بیشتر است برای آموزش مدل پیش‌بینی بهبود یافته مورد استفاده قرار داده می‌شوند. در صورت استفاده از مدل‌های با درجه مناسب و یادگیری گروهی می‌توان کارایی مدل را تا حد زیادی بهبود بخشید.

در این مقاله، بر اساس داده‌های ورودی و خروجی، نگاشتی بین پارامترهای ورودی (ویژگی‌ها) و خروجی مطلوب فرآیند (Target) به فرم یک مساله رگرسیون برقرار می‌شود. بنابراین مدل ایجاد شده جزو زیرشاخه یادگیری نظارت شده از روش‌های یادگیری ماشین دسته‌بندی می‌شود. در بخش دوم نیز مدل‌های ارائه داده شده مورد ارزیابی قرار داده شده و با استفاده از معیارهای آماری کارایی آن‌ها مورد بررسی قرار داده می‌شود. بعد از انتخاب بهترین مدل ممکن می‌توان از آن برای پیش‌بینی دقیق مقادیر خروجی فرآیند در مواجهه با داده‌های ورودی جدید استفاده کرد.

چهارچوب پیشنهادی نسبت به روش‌های مدلسازی فیزیکی و سنتی توانایی بیشتری در مدلسازی فرآیند غیرخطی و پیچیده ساخت افزایشی فلزی دارد. از طرفی مدل به دست آمده از سرعت اجرا و پاسخ‌دهی بسیار بیشتری نسبت به شبیه‌سازی‌های صورت گرفته با روش المان محدود یا دینامیک سیالاتی محاسباتی برخوردار است. روش‌های مذکور نیازمند توان محاسباتی بالا و صرف زمان زیاد و چندین ساعته برای حل مدل هستند. در صورتی که در محیط‌های صنعتی رسیدن به یک تخمین دقیق از خروجی فرآیند در مدت زمان محدود مورد نیاز است. با تنظیم درست پارامترهای مدل یادگیری ماشین می‌توان در زمان بسیار کوتاه‌تری نسبت به روش‌های فیزیکی و المان محدود به تخمین خروجی دست یافت. در نتیجه رهیافت ارائه شده برای کاربردهای زمان-حقیقی و کنترل این فرآیندها در محیط‌های صنعتی انتخاب بهتری می‌باشد. روش پیشنهادی با توجه به کارایی بالا در برابر نامعینی‌های پارامتری و نویز اندازه‌گیری توانایی تلفیق با فرآیند جهت ایجاد یک سامانه هوشمند کنترل ابعادی زمان-واقعی را دارد. چهارچوب پیشنهادی می‌تواند به صورت یک سامانه نرم افزاری انحرافات ابعادی قطعه نهایی را پیش‌بینی کند. این سامانه توانایی تخمین دقیق وضعیت ابعادی قطعه حین تولید را داشته و در صورت وقوع نقص در قطعه یا وقوع عیب در سنسورها هشدار صادر کرده یا اصلاح خودکار انجام می‌دهد. در نتیجه عملکرد دستگاه بهبود یافته و با تشخیص عیوب در حین تولید می‌توان در مواد و هزینه‌ها صرفه جویی کرد.



شکل ۱: چهارچوب پیشنهادی برای مدلسازی فرآیند ساخت افزایشی فلزی با تلفیق داده‌افزایی و یادگیری ماشین

۳- فرمول بندی مساله

عبارت $L_{\varepsilon}(x_i, y_i, f_1)$ تابع زیان غیر حساس به ε بوده و خطاهای بزرگتر از ε را جریمه می کند [۱۹].

۳-۲- یادگیری گروهی

یادگیری گروهی رهیافتی است که اغلب از آن برای تلفیق دو یا چند الگوریتم یادگیری ماشین با هم استفاده می شود. با این روش می توان بازدهی و کارایی بیشتری نسبت به همان الگوریتم های یادگیری ماشین به صورت تکی حاصل کرد. یادگیری گروهی ابزاری مناسب برای پیاده سازی بهینه یادگیری ماشین برای مسائل با داده های محدود می باشد. امروزه محققین اغلب از یادگیری گروهی و یادگیری عمیق جهت ایجاد مدل های بهینه با قابلیت تعمیم به داده های جدید استفاده می کنند. مدل های به دست آمده با این روش قوام و عملکرد بهتری دارند. یادگیری گروهی اغلب به سه دسته تقویت کردن، بسته بندی و انباشته کردن تقسیم می شوند. روش های EGB و AdaBoost از نوع روش های تقویت کردن می باشند. الگوریتم شناخته شده جنگل تصادفی نیز از نوع روش های بسته بندی می باشد [۲۰]. در این بررسی از الگوریتم AdaBoost و EGB برای بهبود کارایی پیش بینی مقادیر جدید استفاده شده است. جزئیات مربوط به این دو روش در مراجع کتابخانه Scikit Learn قابل دسترسی است.

۳-۳- مدل سازی مبتنی بر درخت تصمیم

درخت تصمیم روشی شناخته شده و از دسته یادگیری نظارت شده بدون متغیر می باشد که در مسائل رگرسیون و دسته بندی کاربرد دارد. نمونه های ورودی به وسیله ساختاری درخت مانند شامل ریشه و برگ دسته بندی می شوند. نمونه ها با بررسی ویژگی های تعریف شده توسط گره های درخت دسته بندی می شوند. در نهایت نمونه ها به گره برگ رسیده و در آن ارزش کلاس داده ها بر اساس مقدار میانگین نمونه های خروجی که دسته بندی شده اند محاسبه می شود. برای تقسیم داده ها متداول ترین روش استفاده از شاخص Gini، ناخالصی Gini و شاخص بی نظمی (Entropy) برای به دست آوردن اطلاعات می باشد. معادلات ریاضی این روش به فرم معادلات (۴) و (۵) قابل بیان می باشند.

$$Entropy: H(x) = - \sum_{i=1}^n p(x_i) \log_2 p(x_i) \quad (4)$$

$$Gini(\varepsilon) = 1 - \sum_{i=1}^c p_i^2 \quad (5)$$

بر اساس مساله و اهداف تعیین شده برای آن باید الگوریتم های یادگیری ماشین مناسب را انتخاب کرد. با توجه به اینکه مسائل مورد بررسی در این مقاله دارای تعداد داده های محدود در مقیاس یادگیری ماشین می باشند، انتخاب مدل مناسب سراسر نیست. مدل های انتخابی باید حداکثر کارایی را با حداقل درجه مدل داشته باشند تا بتوانند در پیش بینی داده های جدید عملکرد مناسبی داشته باشند. در این بخش مدل های یادگیری ماشینی که در این مقاله مورد استفاده قرار داده شده اند به وسیله معادلات ریاضی حاکم بر الگوریتم ها توضیح داده خواهند شد.

۳-۱- ماشین بردار پشتیبان

در یک فضای با ابعاد بزرگ این روش یک ابر صفحه یا گروهی از آن ها را ایجاد می کند. ابر صفحه ساخته شده با بیشترین فاصله از داده های آموزش در هر کلاس، یک جداساز قوی می شود. هر چه حاشیه ایجاد شده بزرگتر باشد خطای تعمیم الگوریتم به داده های جدید کم تر می شود. روش یاد شده در فضاهای با ابعاد بالا کارایی مناسبی داشته و بنا به نوع توابع ریاضی استفاده شده که از آن ها تحت عنوان هسته یاد می شود، می تواند رفتار متفاوتی داشته باشد [۱۷]. روش یاد شده توابع رگرسیون تقریب زده شده را با استفاده از معادلات خطی با ابعاد بالا مقداردهی اولیه می کند. این معادلات را می توان به شکل معادله (۱) ارائه کرد:

$$y = w\varphi(x) + b \quad (1)$$

که در آن $w, y, x, \varphi(x)$ به ترتیب ضریب اصلی، ویژگی فضای ابعادی، ورودی، خروجی و بایاس هستند. متغیرهای یاد شده را می توان بعد از ساده سازی معادله (۲) که از آن به عنوان معادله ریسک تنظیم شده یاد می شود تقریب زد [۱۸].

$$R = \frac{\|w\|^2}{2} + C \sum_{i=1}^n L_{\varepsilon}(x_i, y_i, f_1) \quad (2)$$

که در آن

$$L_{\varepsilon}(x_i, y_i, f_1) = \begin{cases} |y_i - f(x_i)| - \varepsilon, & |y_i - f(x_i)| \geq \varepsilon \\ 0, & otherwise \end{cases} \quad (3)$$

در اینجا $\frac{\|w\|^2}{2}$ عبارت تنظیم بوده و از آن به عنوان معیاری برای سنجش سادگی مدل استفاده می شود. C پارامتر تنظیم گری است که بین سادگی مدل و خطای آموزش مصالحه ایجاد می کند. ε اندازه مسیر و

که در معادلات بالا از *Entropy* به عنوان شاخصی برای اندازه‌گیری شاخص بی‌نظمی یا عدم قطعیت در مجموعه داده‌ها یا سیستم استفاده می‌شود. به عبارتی از این شاخص برای ارزیابی کیفیت مدل و توانایی آن برای تولید پیش‌بینی‌های دقیق استفاده می‌شود. عدم قطعیت یا ناخالصی به عنوان حاصل جمع لگاریتم احتمال با مبنای ۲ برای یک دسته از داده‌ها یعنی p_i ضربدر احتمال آن‌ها تعریف می‌شود. شاخص i بیانگر تعداد دسته‌های امکان‌پذیر در میان داده‌ها می‌باشد. از شاخص *Gini* نیز برای ارزیابی میزان ناخالصی یا مخلوط شدگی مجموعه داده‌ها استفاده می‌شود. در معادله (۵) عبارت p_i احتمال وقوع یک گروه مشخص از داده‌ها بوده و این حاصل جمع برای تمامی گروه‌های موجود در داده‌ها پیاده‌سازی می‌شود. جنگل تصادفی یکی دیگر از روش‌های متداول یادگیری ماشین مبتنی بر درخت می‌باشد که در واقع، تعمیم یافته حالت یادگیری گروهی درخت تصمیم می‌باشد. این روش از گروهی موازی از تقسیم‌کننده‌های درخت تصمیم در ترکیب با زیر نمونه‌ها استفاده می‌کند. سپس از رای‌گیری تجمعی یا میانگین‌گیری برای محاسبه نتیجه نهایی استفاده می‌شود. به این ترتیب این روش می‌تواند کارایی مدل را بهبود داده و از بیش‌برازش الگوریتم جلوگیری کند [۱۷].

۳-۵- رگرسیون LASSO و Ridge

این روش‌ها توانایی بالایی برای جلوگیری از بیش‌برازش داشته، پیچیدگی مدل را کاهش داده و توانایی تعمیم به داده‌های جدید مدل را بهبود می‌دهند. روش LASSO از تنظیم‌گری L_1 در تلفیق با جمع شدگی برای جریمه کردن مقادیر مطلق ضرایب استفاده می‌کند. بنابراین با این روش می‌توان تعداد ویژگی‌های مدل را کاهش داد و زیر مدل پیش‌بینی با کم‌ترین مقدار خطای پیش‌بینی را به دست آورد. از طرفی رگرسیون Ridge از تنظیم‌گری L_2 که به عنوان مربع اندازه ضرایب تعریف می‌شود استفاده می‌کند. این کار سبب می‌شود که ضرایب و وزن‌های به دست آمده کوچک شده ولی صفر نشوند. در حالت کلی روش LASSO توانایی بسیار بالایی در به دست آوردن زیرگروهی از پیش‌بینی‌ها با حذف ویژگی‌های غیرضروری دارد. در طرف دیگر روش Ridge زمانی کاربردی است که داده‌های ورودی هم خطی چندگانه با سایر پیش‌بین‌های موجود داشته باشند [۱۷].

۳-۶- داده‌افزایی به روش CTGAN

در برخی از فرآیندهای دنیای واقعی که بیشتر حاصل از فرآیندهای فیزیکی و شیمیایی هستند تعداد داده‌های در دسترس محدود می‌باشند. این امر سبب ایجاد محدودیت در به کارگیری روش‌های هوش مصنوعی برای این دسته از فرآیندها می‌شود [۲۱]. تعداد داده کم با کیفیت پایین می‌تواند ضعف بزرگی برای یادگیری ماشین باشد و سبب کاهش دقت و بازدهی شود. یکی از روش‌های شناخته شده برای بهبود دقت روش‌های مبتنی بر داده به خصوص در داده‌های با تعداد نمونه محدود داده‌افزایی می‌باشد. استفاده از این روش باعث می‌شود که از تعداد داده محدود در دسترس داده‌های بیشتری با همان توزیع تولید شده و در نتیجه مشکل بیش‌برازش تا حد زیادی مرتفع گردد [۲۲].

عمده کاربرد داده‌افزایی برای افزایش تعداد داده در روش‌های قابل پیاده‌سازی در هوش مصنوعی از جمله یادگیری ماشین و شبکه عصبی می‌باشد. علاوه بر افزایش تعداد داده محدود می‌توان از داده‌افزایی برای تبدیل تعداد نمونه زیاد به نمونه‌های حجیم برای استفاده در یادگیری عمیق و مدل‌های با درجات بالاتر استفاده کرد [۲۳]، [۲۴]، [۲۵]، [۲۶] و [۲۷]. از روش‌های متداول داده‌افزایی می‌توان به دو روش GAN و VAE اشاره کرد که روش‌های مذکور برای مسائل رگرسیون و دسته بندی پیاده‌سازی شده‌اند. پس از یادگیری توزیع نمونه‌ها توسط الگوریتم

۳-۴- رگرسیون خطی و چند جمله‌ای

در رگرسیون خطی متغیر وابسته پیوسته بوده و متغیر مستقل می‌تواند پیوسته یا گسسته باشد. این روش یک رابطه ریاضی بین متغیر وابسته y و یک یا چند متغیر مستقل x به وسیله بهترین برازش با یک خط مستقیم برقرار می‌کند. این روند را می‌توان به صورت معادلات زیر بیان کرد:

$$y = a + bx + e \quad (۶)$$


$$y = a + b_1x_1 + b_2x_2 + \dots + b_nx_n + e \quad (۷)$$

که در معادلات بالا a عرض از مبدا، b شیب خط و e مقدار خطا می‌باشد. رگرسیون چند جمله‌ای در مسائلی استفاده می‌شود که رابطه بین x و y به شکل معادلات چند جمله‌ای مبتنی بر x با درجه n می‌باشد. رابطه مربوطه را می‌توان از معادله رگرسیون خطی با تعریف درجه متغیر مستقل برابر با ۱ به دست آورد. معادلات رگرسیون چند جمله‌ای به شکل زیر قابل تعریف هستند.

$$y = b_0 + b_1x + b_2x^2 + b_3x^3 + \dots + b_nx^n + e \quad (۸)$$

که در معادله (۸)، $y, b_0, b_1, \dots, b_n, x$ به ترتیب متغیرهای وابسته، ضرایب رگرسیون و متغیر مستقل هستند [۱۷].

را برای جریمه کردن کاهش به وسیله اضافه کردن آنتروپی متقاطع به تمامی نمونه‌های بین m_i^* و d_i^* بسازد. بنابراین در حالی که روند آموزش ادامه می‌یابد مولد یاد می‌گیرد که یک نسخه مشابه و دقیق از m_i^* متناظر را برای d_i^* ایجاد کند.



شکل ۲: ساختار کلی روش CTGAN [۲۸]

در گام بعدی آموزش به وسیله نمونه‌برداری پیاده‌سازی می‌گردد. خروجی تولید شده به وسیله مولد شرطی باید به وسیله قسمت critic که فاصله بین توزیع شرطی یادگرفته شده $P_g(row|cond)$ و توزیع شرطی روی داده‌های واقعی یعنی $P(row|cond)$ را تخمین می‌زند مورد ارزیابی قرار داده شود. داده‌های آموزش واقعی و تولید بردار $cond$ باید به بخش critic برای تخمین فاصله کمک کنند. با نمونه‌برداری درست و اصولی از بردار $cond$ و داده‌های ورودی مدل تولید شده می‌تواند تمامی مقادیر ممکن را در ستون‌های گسسته بررسی کند. روند کلی و مراحل پیاده‌سازی رهیافت پیاده‌سازی شده در این مقاله در الگوریتم ۱ ارائه داده شده است. قابل ذکر است الگوریتم CTGAN نیازی به نرمالسازی داده‌ها به صورت معمول و دستی ندارد. الگوریتم یاد شده به وسیله نرمالسازی ویژگی‌های پیوسته، تبدیل داده‌ها به فضای توزیع نرمال شده و one-hot encoding این کار را به صورت خودکار انجام می‌دهد.

الگوریتم ۱: فرآیند آموزش و نمونه‌برداری پیاده‌سازی شده در CTGAN

[۲۸]

Input: The distribution of real data

Output: $\hat{t} = P_g(row|D_{i^*})$; The conditional generator

```

while 1 do
  Step 1
  for  $i = 1:1:N_d$  do
    Generate mask vectors  $m_i = [m_i^{(k)}]_{k=1,...,|D_i|}$  with zero elements
  end
  Step 2

```

داده‌افزایی، داده‌های با تعداد و کیفیت بالا بر اساس توزیع اولیه توسط الگوریتم تولید می‌شوند.

در این مقاله از روش CTAGN که در [۲۸] توسط Xu و همکاران ارائه داده شده است برای پیاده‌سازی روش داده‌افزایی استفاده شده است. روش استفاده شده نسبت به سایر روش‌های مورد استفاده در این حوزه مانند MedGAN [۲۹]، VeeGAN [۳۰] و TableGAN [۳۱] کارایی بهتری دارد. الگوریتم پیشنهادی از روش‌های مبتنی بر GAN بوده و از آن برای مدل‌سازی و داده‌افزایی داده‌هایی که به فرم جدول هستند، استفاده می‌شود. این روش بر اساس یک مولد شرطی شکل داده شده و سپس توسط یک روش نمونه‌برداری آموزش داده می‌شود. نمای کلی روش CTGAN در شکل ۲ نمایش داده شده است. قسمت مولد شرطی باید توزیع داده شرطی داده‌های واقعی را یاد بگیرد که به صورت رابطه (۹) قابل بیان می‌باشد:

$$P_G(row|D_{i^*} = k^*) = P(row|D_{i^*} = k^*) \quad (9)$$

که در آن row ردیفی از توزیع داده‌های نمونه برداری شده می‌باشد. در گام بعدی توزیع اصلی داده‌ها را می‌توان به صورت زیر بازتولید کرد

$$P(row) = \sum_{k \in D_{i^*}} P_G(row|D_{i^*} = k^*) P(D_{i^*} = k) \quad (10)$$

راه حل این مساله شامل سه مرحله اصلی بردار شرطی، کاهش مولد و بخش آموزش با نمونه‌برداری می‌باشد. در بخش بردار شرطی، بردار $cond$ به عنوان روالی برای طراحی شرط $(D_{i^*} = k^*)$ بیان می‌شود. توجه داشته باشید که تمامی ستون‌های گسسته $D_1, \dots, D_{N_d}$ در نهایت تبدیل به بردارهای وان‌هات $d_1, \dots, d_{N_d}$ می‌شوند به نحوی که بردار وان‌هات i ام برای تمامی مقادیر $k = 1, \dots, |D_i|$ برابر است با $d_i = [d_i^{(k)}]$. فرض کنید $m_i = [m_i^{(k)}]$ برای مقادیر $k = 1, \dots, |D_i|$ امین بردار پوششی متناظر با بردار وان‌هات i ام برای d_i باشد. بنابراین شرط مربوطه را می‌توان به صورت بردارهای پوششی به فرم معادله (۱۱) ارائه داد

$$m_i^{(k)} = \begin{cases} 1, & \text{if } i = i^* \text{ and } k = k^* \\ 0, & \text{otherwise.} \end{cases} \quad (11)$$

سپس بردار $cond$ را می‌توان به فرم زیر نشان داد

$$cond = m_1 \oplus \dots \oplus m_{N_d} \quad (12)$$

پس از ارائه بردار شرطی نوبت به بررسی مولد کاهش می‌رسد. مولد شرطی توانایی ساختن هر گروهی از بردارهای وان‌هات به فرم $d_1, \dots, d_{N_d}$ را دارد. به ویژه با شرط $(D_{i^*} = k^*)$ که برای بردار $cond$ در نظر گرفته شده است هیچ عاملی توانایی جلوگیری از تولید $\hat{d}_{i^*}^{(k^*)}$ یا $\hat{d}_{i^*}^{(k)}$ برای مقادیر $k \neq k^*$ در مسیر مستقیم را ندارد. این روال به این دلیل طراحی شده است که مولد شرطی را مجبور کند که $\hat{d}_{i^*} = m_{i^*}$

مورد استفاده در این مقاله، روش توقف زودهنگام و معادل‌های آن برای هر مدل پیاده شده تا مشکلات یاد شده رفع شوند.

۴- نتایج شبیه‌سازی

ابتدا الگوریتم‌های یادگیری ماشین ذکر شده در قسمت فرمول‌بندی ریاضی مساله به همراه یادگیری گروهی در محیط پایتون پیاده‌سازی شده‌اند. شبیه‌سازی و پیاده‌سازی این الگوریتم‌ها با استفاده از کتابخانه Scikit Learn انجام داده شده است. این کتابخانه شامل مدل‌های یادگیری ماشین از جمله مدل‌های رگرسیون بوده که به سادگی می‌توان آن‌ها را به کار گرفت. در تمامی مدل‌های به کارگرفته شده میانگین مربع خطا به عنوان تابع هزینه و کاهش خطا در نظر گرفته شده است. از آنجایی که تعداد محدودی نمونه از فرآیند در دسترس است از روش Cross Validation برای ارزیابی مدل‌ها استفاده شده است. در این بررسی علاوه بر یادگیری گروهی اثر داده افزایی پیاده‌سازی شده با روش CTGAN نیز مطالعه شده است. این الگوریتم برای ۵۰۰۰ تکرار روی داده‌های اصلی اجرا شده و الگوریتم بعد از پایان اجرا توزیع داده‌های اصلی را یاد گرفته می‌گیرد. بعد از فرآیند آموزش الگوریتم داده افزایی تولید داده‌های افزوده شده جهت بهبود مدل انجام داده شده است. قابل ذکر است که حد خاصی برای تولید داده‌ها افزوده وجود دارد. مجموعه داده‌های تولید شده در این بررسی شامل ۲۰ درصد داده واقعی و ۸۰ درصد داده‌ای افزوده شده می‌باشد. تولید داده‌های بیشتر به صورت مستقیم توزیع داده‌ها را تحت تاثیر قرار می‌دهد و ممکن است سبب کاهش کارایی مدل شود. در ادامه مدل‌های یادگیری ماشین بررسی شده و روش CTGAN روی دو فرآیند شناخته شده ذوب لیزری انتخابی و رسوب‌گذاری مستقیم فلز لیزری پیاده‌سازی شده و نتایج آن‌ها بررسی می‌شوند. جهت ارزیابی بهتر چهارچوب پیشنهادی از خروجی‌های متفاوت برای هر مورد مطالعاتی استفاده شده است.

۴-۱- مورد مطالعاتی اول: مدلسازی فرآیند ذوب لیزری انتخابی

در این مورد مطالعاتی قطعات با استفاده از یک دستگاه SLM 280^{HL} (SLM solutions GmbH) ساخته شده‌اند. پودر افشانش گازی شده AlSi10Mg به با ابعاد ذره‌ای در بازه ۵۰-۲۰ میکرومتر به صورت انحصاری تهیه شده است. ترکیب‌بندی شیمیایی پودر استفاده شده به

Choose a discrete column D_i randomly from entire N_d discrete columns with uniform distribution

Step 3

Generate PMF across a range of values of the column picked in Step 2

Step 4

k^* picked up uniformly following PMF of Step 3

Step 5

Set the k^* -th component of the i^* mask to 1, $(m_{i^*}^{(k^*)} \leftarrow 1)$

Step 6

$cond = m_1 \oplus \dots \oplus m_{i^*} \oplus m_{N_d}$

end

۳-۷- معیارهای آماری ارزیابی

یکی از روش‌های متداول در یادگیری ماشین برای ارزیابی دقت مدل روش اعتبارسنجی متقابل می‌باشد. این روش اغلب سبب بهبود کارایی مدل در تعمیم به ورودی‌های جدید شده و از مشکل بیش برازش جلوگیری می‌کند. بیش برازش سبب می‌شود که مدل به خوبی به داده‌های در دسترس و اندازه‌گیری شده از فرآیند برازش شود ولی در مقابله با داده‌های جدید دقت مدل نامطلوب خواهد بود. با این روش می‌توان داده‌های ورودی را به صورت تصادفی به چندین زیر گروه تقسیم کرد و به صورت تکراری مدل را ارزیابی نمود. خطای نهایی از میانگین تمامی خطاهای محاسبه شده به دست می‌آید. اگر تعداد داده‌ها کم باشد می‌توان هر داده را به عنوان یک زیرگروه انتخاب کرد و بنابراین به تعداد داده‌ها زیرگروه خواهیم داشت. بیان ریاضی این معیار آماری را می‌توان به صورت زیر نشان داد:

$$CV - RMSE_{(n)} = \frac{1}{n} \sum_{i=1}^n RMSE_i \quad (13)$$

که در آن $RMSE_i$ برای زیر گروه اعتبارسنجی محاسبه می‌شود [۱۷]. در کنار مفهوم بیش برازش، مفهوم دیگری تحت عنوان بیش آموزش وجود دارد که به نوعی این دو مفهوم مترادف هم می‌باشند. دو مفهوم یاد شده به معنی ایجاد حافظه ماشینی به جای درک روند می‌باشند. در صورت استفاده از یادگیری گروهی، خطاهای خاص هر مدل توسط مدل‌های دیگر خنثی شده و مدل‌های بیش برازش شده وزن کم‌تری در خروجی نهایی خواهند داشت. استفاده از روش اعتبارسنجی متقابل در ترکیب با یادگیری گروهی و داده‌افزایی به دلیل تغییر داده‌های تست به صورت متناوب و افزایش تنوع داده‌ها، سبب کاهش مشکل بیش برازش و بیش آموزش می‌شود. هم‌چنین در تا حد امکان باید با استفاده از امکانات موجود در محیط برنامه‌نویسی روش‌هایی مانند توقف زودهنگام را پیاده‌سازی کرد تا از بیش آموزش جلوگیری شود [۳۲]. در مدل‌های

صورت جدول ۱ ارائه داده شده است. قبل از ساخت نمونه‌ها پودر ذکر شده در یک اجاق با دمای ۱۰۰ درجه سانتی‌گراد خشک شده است.

جدول ۱: ترکیب‌بندی شیمیایی پودر AlSi10Mg در ساخت قطعات [۳۳]

Elements	Al	Si	Mg	Fe	Cu	Mn	Zn	Ti	Ni	Pb	Sn
W.t %	Balance	9.5	0.38	0.18	<0.01	<0.01	<0.01	<0.01	<0.01	<0.01	<0.01

در این مورد مطالعاتی از ترکیب‌های متفاوت پارامترها برای بررسی فرآیند SLM استفاده شده است. ضخامت لایه‌ها در طی انجام آزمایش‌ها به صورت ثابت و برابر با ۳۰ میکرومتر در نظر گرفته شده است. پارامترهای فرآیند از جمله توان لیزر، سرعت اسکن و نرخ همپوشانی به صورت متغیر برای روش فاکتوریال کامل در نظر گرفته شده‌اند. در گام نخست آزمایش‌هایی برای بررسی عرض تک مسیرهای ذوب شده انجام داده شده است. برای هر گروه یکتا از پارامترهای فرآیند ۳ بار آزمایش مربوطه تکرار شده است. در گام بعدی از آزمایش‌های دو مسیر برای بررسی اثر نرخ همپوشانی استفاده شده است. بعد از انجام آزمایش‌های تک مسیر و دو مسیر نتایج مربوط به اسکن‌های چند مسیر برای بررسی تخلخل، سختی و استحکام کششی قطعات ساخته شده انجام داده شده‌اند. برای هر ترکیب یکتا از پارامترهای انتخاب شده سه مکعب حجیم با ابعاد ۸×۶×۱۰ میلی‌متر و یک مکعب مستطیل با ابعاد ۱۰×۵×۱۴ میلی‌متر ساخته شده‌اند.

در کل ۸۱ نمونه برای بررسی خروجی‌های مورد نظر تولید شده‌اند. قطعات تولید شده با استفاده از روش ماشینکاری تخلیه الکتریکی از بستر ساخت جدا شده‌اند. برای اندازه‌گیری مشخصات قطعه در ابتدا هر نمونه ساخته شده به سه قسمت برش داده شده و مشخصات قطعه اندازه‌گیری شده‌اند. اندازه‌گیری‌های انجام داده شده برای سنجش چگالی، استحکام کششی و سختی برای هر قطعه سه بار انجام داده شده و نتایج میانگین گزارش شده‌اند. نتایج حاصل از اندازه‌گیری‌های انجام داده شده برای هر گروه از پارامترها مطابق با جدول ۲ ارائه داده شده‌اند [۳۳].

جدول ۲: مقادیر پارامترهای ورودی و نتایج اندازه‌گیری‌های انجام شده در ۲۷ آزمایش مربوط به مورد مطالعاتی اول [۳۳]


No	Process Parameters				Measured Parameters		
	Laser Power [W]	Scan Speed [mm/s]	Hatch Distance [um]	Overlap Rate	Density [g/cm ³]	Tensile Strength [MPa]	Hardness [HV]
1	320	600	102.4	0.25	2.6102	455.00	119.0
2	320	600	95.5	0.3	2.6266	450.00	123.2
3	320	600	88.7	0.35	2.6270	443.33	130.8
4	320	750	93.1	0.25	2.6196	448.33	124.4
5	320	750	86.9	0.3	2.6094	443.33	123.2
6	320	750	80.7	0.35	2.6204	445.00	127.8
7	320	900	81.8	0.25	2.6310	443.33	127.6
8	320	900	76.3	0.3	2.6221	446.67	127.8
9	320	900	70.9	0.35	2.6298	450.00	122.6
10	360	600	111.0	0.25	2.5965	431.67	127.2
11	360	600	103.6	0.3	2.6237	436.67	135.2
12	360	600	96.2	0.35	2.6063	441.67	116.4
13	360	750	98.0	0.25	2.6083	430.00	129.8
14	360	750	91.4	0.3	2.6308	441.67	123.2
15	360	750	84.9	0.35	2.6087	445.00	128.8
16	360	900	88.9	0.25	2.6092	420.00	119.0
17	360	900	83.0	0.3	2.6260	431.67	127.2
18	360	900	77.1	0.35	2.6252	446.67	122
19	400	600	116.4	0.25	2.5618	420.00	118.6
20	400	600	108.6	0.3	2.6241	445.00	131.0
21	400	600	100.9	0.35	2.6296	438.33	139.2
22	400	750	104.7	0.25	2.6056	430.00	124.8
23	400	750	97.7	0.3	2.6164	431.67	127.4
24	400	750	90.7	0.35	2.5981	446.67	120.8
25	400	900	94.1	0.25	2.6250	416.67	125.4
26	400	900	87.8	0.3	2.5864	443.33	113.2
27	400	900	81.5	0.35	2.6152	438.33	118.4

بعد از وارد کردن مقادیر اندازه‌گیری شده به عنوان ورودی به مدل، الگوریتم‌های یادگیری ماشین مختلف برای مدلسازی این فرآیند و ایجاد نگاشت بهینه بین ورودی و خروجی روی داده‌ها پیاده‌سازی شده‌اند. پیاده‌سازی الگوریتم‌های مختلف روی داده‌ها سبب می‌شود که کارایی هر الگوریتم برای پیش‌بینی هر خروجی بررسی شده و بهترین مدل


شکل ۳: نمودار مقادیر R^2 و CV-RMSE برای سه خروجی چگالی، استحکام کششی و سختی در فرآیند ذوب لیزری انتخابی

در گام بعدی از روش CTGAN برای اجرای داده‌افزایی و افزایش تعداد نمونه‌های در دسترس برای آموزش مدل‌ها استفاده شده است. هدف از این کار کاهش خطای پیش‌بینی الگوریتم در مواجهه با داده‌های ورودی جدید می‌باشد. به عبارتی، در این روش با یک راه حل نرم افزاری و بدون اجرای آزمایش‌های بیشتر می‌توان تعداد بیشتری نمونه برای آموزش مدل فراهم کرد. به این صورت می‌توان دقت مدل‌ها را افزایش داده و با تنظیم پارامترها با سعی و خطا به دقت بهینه برای هر مدل دست پیدا کرد. در این قسمت مقادیر CV-RMSE برای مدل‌های پیاده‌سازی شده روی فرآیند قبل و بعد از اجرای فرآیند داده‌افزایی محاسبه شده و مطابق با شکل ۴ ارائه داده شده‌اند. برای هر سه پارامتر خروجی چگالی، استحکام کششی و سختی این فرآیند تکرار شده و جهت مقایسه گزارش شده‌اند. از مقایسه نمودارهای ارائه شده در شکل‌ها می‌توان به این نتیجه رسید که اجرای فرآیند داده‌افزایی به طور میانگین برای خروجی‌های چگالی، استحکام کششی و سختی به ترتیب سبب کاهش ۵۸، ۴۲ و ۵۹ درصدی مقدار CV-RMSE شده است. مقادیر بهبود الگوریتم‌ها بسته به نوع الگوریتم و ساختار مدل با هم تفاوت دارند. با این وجود بهبود کلی در تمامی مدل‌های ارائه داده شده قابل مشاهده است. در تخمین مقدار چگالی دو مدل AdaBoost و EGB بهترین عملکرد را دارند در حالی که برای تخمین مقدار سختی و استحکام کششی مدل‌های Poly و Ensemble کارایی بیشتری بعد از اجرای داده‌افزایی از خود نشان داده‌اند. برای هر خروجی می‌توان از بهترین مدل ممکن برای پیش‌بینی استفاده کرد. همچنین قابل ذکر است که زمان اجرای این الگوریتم‌ها در محیط Google Colab به ترتیب برابر با ۲ دقیقه و ۱۰ ثانیه و ۴ دقیقه و ۱۴ ثانیه بوده است. طولانی‌تر شدن زمان شبیه‌سازی در حالتی که داده‌افزایی اجرا می‌شود به دلیل آموزش الگوریتم CTGAN برای ۵۰۰۰ تکرار می‌باشد. از لحاظ بار محاسباتی اجرای این الگوریتم‌ها در بستر اینترنت بوده و از لحاظ زمان اجرا نسبت به سایر روش‌های مدل‌سازی مانند المان محدود کارایی بسیار بیشتری دارد. بنابراین از این الگوریتم‌ها می‌توان به صورت آنلاین و در محیط‌های صنعتی برای تخمین سریع خروجی فرآیند و تنظیم آن استفاده کرد.


ممکن برای فرآیند انتخاب شود. به عبارتی مدل‌سازی با استفاده از یادگیری ماشین ساده بوده و باید به سرعت مدل‌های یادگیری ماشین را توسعه داد و از بین آن‌ها بهترین را انتخاب کرد. در مورد مطالعاتی اول از ۶ مدل رگرسیون EGB، RF، RBF، Poly، Ensemble و AdaBoost استفاده شده است. مدل استفاده شده برای یادگیری گروهی (Ensemble) شامل مدل‌های DT، EGB و RBF می‌باشد. کارایی هر یک از این مدل‌ها برای پیش‌بینی مقادیر چگالی، استحکام کششی و سختی با استفاده از معیارهای R^2 و CV-RMSE بررسی شده و نتایج آن‌ها در شکل ۳ ارائه داده شده است. بر اساس شبیه‌سازی‌های انجام داده شده می‌توان گفت که دو مدل EGB و Ensemble نسبت به سایر مدل‌ها دقت و کارایی بیشتری برای مدل‌سازی فرآیند داشته و قابلیت اطمینان بالایی دارند. در واقع کم‌ترین مقدار خطا همراه با بیشترین دقت در پیش‌بینی خروجی‌ها توسط این دو مدل حاصل شده است. با این وجود در صورت پیاده‌سازی روش CTGAN می‌توان خطای پیش‌بینی را کاهش داده و دقت مدل را بهبود داد.




الف) چگالی




ب) استحکام کششی




ج) سختی



الف) چگالی




ب) استحکام کششی




ج) سختی


شکل ۵: مقایسه مقادیر اندازه‌گیری شده و پیش‌بینی شده توسط بهترین مدل یادگیری ماشین برای سه خروجی چگالی، استحکام کششی و سختی در فرآیند ذوب لیزری انتخابی



الف) چگالی



ب) استحکام کششی



ج) سختی

شکل ۴: مقایسه مقادیر CV-RMSE برای سه خروجی چگالی، استحکام کششی و سختی قبل و بعد از اجرای داده افزایی در فرآیند ذوب لیزری انتخابی

برای ارزیابی بهتر عملکرد چهارچوب پیشنهادی در پیش‌بینی مقادیر خروجی آزمایش‌ها، برای هر آزمایش انجام داده شده مقادیر خروجی و مقادیر پیش‌بینی شده الگوریتم رسم شده‌اند. شکل ۵ نشان دهنده مقایسه مقادیر خروجی حاصل از آزمایش‌ها برای سه خروجی چگالی، استحکام کششی و سختی و مقادیر خروجی پیش‌بینی شده حاصل از چهارچوب پیشنهادی می‌باشد. برای رسم هر خروجی از بهترین مدل ممکن با کم‌ترین میزان خطا استفاده شده است. مقادیر حاصل از خروجی آزمایش‌ها با  و مقادیر حاصل از مدل‌های یادگیری ماشین با  رسم شده‌اند. همان گونه که در شکل‌ها قابل مشاهده است مدل‌های یادگیری ماشین توانسته‌اند با دقت بسیار بالایی خروجی‌های آزمایش‌ها را پیش‌بینی کنند.

۴-۲- مورد مطالعاتی دوم: مدلسازی فرآیند رسوب‌گذاری مستقیم فلز لیزری

در مورد مطالعاتی دوم از یک لیزر برای لایه نشانی خطی آلیاژ Al 2024 استفاده شده است. از لیزر Yb:YAG فیبری با توان ۴ کیلو وات در حالت تابش پیوسته استفاده شده است. سیستم موقعیت دهی نازل با استفاده از یک ربات ۶ محوره صنعتی پیاده‌سازی شده است که امکان کنترل دقیق موقعیت را فراهم می‌کند. برای تزریق پودر به سر نازل از یک سیستم نازل سه راهی که پودر را از یک حمل کننده نوسانی دریافت می‌کند استفاده شده است. گاز آرگون به عنوان حمل کننده پودر و محافظت کننده حوضچه مذاب از عوامل محیطی به کار گرفته می‌شود. جهت محافظت از سیستم اپتیکی و جلوگیری از ورود مقابل مواد زائد

12	250 0	100	5	10.7	2.83	0.82
13	250 0	150	5	8.5	1.51	1.04
14	250 0	150	7	8.9	1.52	2.06
15	250 0	200	5	8.05	1.5	1.05
16	250 0	200	7	8.66	1.62	1.89
17	250 0	250	5	8.32	1.69	0.78
18	250 0	400	3	5.3	2.13	1.1
19	300 0	150	5	8.6	2.42	1.16
20	300 0	150	7	9.4	2.6	1.53
21	300 0	200	5	8.05	2.43	0.99
22	300 0	200	7	8.8	2.41	1.34
23	300 0	200	4	8.08	2.39	0.79
24	300 0	200	6	9.22	1.83	1.2
25	300 0	200	3	7.5	2.27	0.67
26	300 0	200	10	9.3	2.33	1.86
27	300 0	300	3	7.04	3.23	1.07
28	300 0	500	3	5.38	2.25	0.96
29	300 0	600	3	4.67	0.92	0.29
30	300 0	600	10	5.5	1.04	1.28


مشابه با مورد اول در این مورد مطالعاتی نیز مدل‌های یادگیری ماشین مختلف برای مدل‌سازی این فرآیند به کار گرفته شده‌اند. در این قسمت از مدل‌های Ridge، Ensemble، Poly، RBF، RF، EGB برای ایجاد نگاشت بین ورودی‌ها و عرض، عمق و ارتفاع مسیرهای لایه نشانی شده استفاده شده است. در این مورد مطالعاتی مدل Ensemble استفاده شده شامل الگوریتم‌های Ridge، LASSO، Poly، EGB، RF و DT می‌باشد. معیارهای R^2 و CV-RMSE برای مقایسه عملکرد این الگوریتم‌ها مورد استفاده قرار داده شده و مقادیر محاسبه شده برای این دو معیار در شکل ۶ نشان داده شده‌اند. در پیش‌بینی مقادیر عرض و عمق و ارتفاع مسیرهای لایه نشانی شده مدل EGB دارای بهترین عملکرد در بین سایر مدل‌ها می‌باشد.

برگشتی، نازل با یک زاویه ۴ درجه‌ای شروع به فرآیند ساخت خواهد نمود. ذره‌های پودر مطابق با ادعای سازنده دارای ابعاد ۲۰ تا ۶۰ میکرومتری بوده و قبل از استفاده در دمای ۱۸۰ درجه سانتی‌گراد به مدت ۲ ساعت خشک شده‌اند. بستر استفاده شده برای لایه نشانی مسیرها از جنس Al 2024 با ضخامت ۵ میلی‌متر می‌باشد. مسیرهای ساخته شده دارای طول ۱۰۰ میلی‌متری بوده و برای هر گروه یکتا از پارامترها شامل توان لیزر، سرعت حرکت نازل و نرخ تزریق پودر سه مسیر لایه نشانی شده است. هدف از تکرار مسیرها جلوگیری و کاهش خطاهای سیستماتیک در اندازه‌گیری مشخصات و پارامترهای مسیرهای ساخته شده می‌باشد. برای اندازه‌گیری عرض، عمق و ارتفاع مسیرهای لایه نشانی شده ابتدا قطعات به صورت مقطعی برش داده شده و سپس قطعات پولیش شده‌اند تا برای اندازه‌گیری آماده شوند. از مقادیر میانگین برای آموزش مدل استفاده می‌شود. تعداد ۳۰ آزمایش انجام داده شده و پارامترهای مربوط به هر آزمایش در جدول ۳ گزارش داده شده‌اند [۳۴]. قابل ذکر است پیش‌بینی و کنترل ابعادی جزو مهم‌ترین چالش‌ها در تولید دقیق و تکرارپذیری قطعات فلزی در کاربردهای صنعتی می‌باشد. در طی سالیان اخیر مطالعات فراوانی در این مورد برای انواع مختلف فرآیندهای ساخت افزایشی انجام داده شده است [۳۵]، [۳۶] و [۳۷]. هم‌چنین کنترل ابعادی در صنایع حساس و ساخت سفارشی مانند ایمپلنت‌های پزشکی اهمیت بسیار بالایی دارد زیرا به طور مستقیم روی راحتی بیمار و کارایی ایمپلنت اثر گذار است [۳۸].


جدول ۳: مقادیر پارامترهای ورودی و نتایج اندازه‌گیری‌های انجام داده شده در ۳۰ آزمایش مربوط به مورد مطالعاتی دوم [۳۴]

N o.	Process Conditions			Measured Geometrical Parameters		
	P(W)	v(mm/m in)	$\dot{m}$ (g/mi n)	Width(m m)	Depth(m m)	Height(m m)
1	120 0	400	4	3.09	0.25	0.98
2	150 0	400	4	3.71	0.46	1.08
3	150 0	400	6	3.61	0.37	1.46
4	150 0	400	8	3.49	0.11	1.98
5	150 0	400	10	4.3	0.21	2.14
6	200 0	200	3	5.24	0.70	0.85
7	200 0	200	10	5.28	0.74	2.11
8	200 0	300	3	5.32	1.81	1.38
9	200 0	400	8	4.07	0.59	1.75
10	200 0	500	8	3.94	0.65	1.49
11	200 0	500	3	4.31	1.22	1.11


مطالعاتی دوم بدون داده افزایی و با لحاظ اثر داده افزایی به ترتیب ۱ دقیقه و ۲۶ ثانیه و ۳ دقیقه و ۳۱ ثانیه هستند.



الف) عرض




ب) عمق




ج) ارتفاع

شکل ۷: مقایسه مقادیر CV-RMSE برای سه خروجی عرض، عمق و ارتفاع مسیرهای لایه نشانی شده قبل و بعد از اجرای داده افزایی در فرآیند رسوب گذاری مستقیم فلز لیزری


مشابه با مورد مطالعاتی اول، در این مورد مطالعاتی نیز از مقایسه مقادیر خروجی آزمایش ها و خروجی مدل های یادگیری ماشین برای ارزیابی عملکرد استفاده شده است. در شکل ۸ برای سه پارامتر عرض، عمق و ارتفاع مقادیر خروجی آزمایش با $\odot$ و مقادیر پیش بینی شده توسط الگوریتم با * رسم شده اند. همان گونه که قابل مشاهده است عملکرد مدل ها قابل قبول بوده و با دقت بالایی مقادیر آزمایش ها و پیش بینی شده بر هم منطبق شده اند که نشان از کارایی چهارچوب پیشنهادی دارد.



الف) عرض مسیر



ب) عمق مسیر




ج) ارتفاع مسیر


شکل ۶: نمودار مقادیر R^2 و CV-RMSE برای سه خروجی عرض، عمق و ارتفاع مسیرهای لایه نشانی شده در فرآیند رسوب گذاری مستقیم فلز لیزری

پس از بررسی کارایی مدل ها روی داده های واقعی، اثر داده افزایی نیز مورد بررسی قرار داده می شود. برای خروجی های عرض، ارتفاع و عمق مسیرهای لایه نشانی شده داده افزایی با روش CTGAN پیاده سازی شده است. سپس از معیار آماری CV-RMSE برای مقایسه عملکرد الگوریتم ها با حالت بدون داده افزایی استفاده شده است. با مقایسه نمودارهای ارائه داده شده برای مدل های پیاده سازی شده در شکل ۷ می توان به این نتیجه رسید که داده افزایی سبب کاهش خطای پیش بینی در تمامی مدل های موجود شده است. به طور میانگین داده افزایی برای خروجی های عرض، عمق و ارتفاع مسیرهای لایه نشانی شده به ترتیب سبب کاهش ۴۴، ۵۱ و ۴۹ درصدی خطا در مدل های پیشنهادی شده است. مدت زمان اجرای مدل های ذکر شده در مورد


درجه مدل‌های استفاده شده در حد امکان، پایین انتخاب شده‌اند. داده‌های افزایشی با روش شناخته شده CTGAN انجام داده شده است. داده‌های حاصل از فرآیند داده افزایشی برای آموزش روش‌های یادگیری ماشین استفاده شده و نتایج با داده‌های اصلی مقایسه شده‌اند. تمامی شبیه‌سازی‌ها و ارزیابی مدل‌ها در کتابخانه Scikit Learn پایتون و در محیط Google Colab اجرا شده‌اند. برای هر مدل از معیارهای آماری R^2 و CV-RMSE جهت ارزیابی عملکرد استفاده شده است. نتایج شبیه‌سازی نشان دهنده بهبود عملکرد مدل‌های مربوط به فرآیندهای SLM و DLMD به ترتیب به اندازه ۵۳ و ۴۸ درصدی نسبت به حالت بدون داده افزایشی می‌باشد. با توجه به مدت زمان کوتاه اجرای مدل‌ها می‌توان از چهارچوب پیشنهادی برای تخمین دقیق مقادیر خروجی به صورت زمان-حقیقی در صنعت استفاده کرد. روش مذکور نسبت به روش المان محدود زمان اجرای بسیار کم‌تری داشته و از نظر حجم محاسباتی هم کارایی بسیار بیشتری دارد. همچنین می‌توان از این چهارچوب برای بهبود عملکرد روش‌های المان محدود استفاده کرد. ترکیب CTGAN با شبکه عصبی نیز می‌تواند برای بهبود کارایی سایر مدل‌های ارائه شده در علم مواد استفاده شود. مواردی از جمله استفاده از مدل‌های ارائه شده برای کنترل مبتنی بر داده فرآیندهای ساخت افزایشی فلزی مانند سامانه هوشمند کنترل ابعادی، تعمیم چهارچوب پیشنهادی به سایر خروجی‌های متالورژیکی، مقایسه روش‌های یادگیری ماشین مورد استفاده با شبکه عصبی و بهینه‌سازی فرآیند مبتنی بر روش‌های الهام گرفته شده از طبیعت مانند الگوریتم بهینه‌سازی ازدحام ذرات برای یافتن نقاط کاری و مصرف انرژی بهینه بر اساس مدل ارائه داده شده موضوعات پیشنهادی برای کارهای آینده هستند.



الف) عرض



ب) عمق



ج) ارتفاع

شکل ۸: مقایسه مقادیر اندازه‌گیری شده و پیش‌بینی شده توسط بهترین مدل یادگیری ماشین برای سه خروجی عرض، عمق و ارتفاع مسیرهای لایه نشانی شده در فرآیند رسوب‌گذاری مستقیم فلز لیزری

۵- نتیجه‌گیری

در این مقاله چندین رهیافت یادگیری ماشین از جمله DT، EGB، Adaboost، RBF، یادگیری گروهی، رگرسیون چند جمله‌ای و RF برای مدلسازی دو فرآیند ساخت افزایشی فلزی پیاده‌سازی شده‌اند. از دو فرآیند متفاوت با پارامترها و داده‌های مستقل برای ارزیابی روش پیشنهادی استفاده شده است. این دو فرآیند شامل روش‌های SLM و DLMD بوده و هر کدام به ترتیب شامل ۲۷ و ۳۰ نمونه هستند. تعداد نمونه‌های یاد شده برای این دو فرآیند در مقیاس یادگیری ماشین محدود هستند. برای رفع این مشکل و جلوگیری از بیش برآورد از ترکیب روش‌های یادگیری گروهی و داده‌افزایی استفاده شده است.

واژه نامه

Adaptive Boost (AdaBoost)	روش تقویت تطبیقی
Computational Fluid Dynamics (CFD)	دینامیک سیالات محاسباتی
Conditional Tabular Generative Adversarial Networks (CTGAN)	شبکه‌های مولد تخصصی جدولی شرطی
Cross Validation	اعتبارسنجی متقابل
Decision Tree	درخت تصمیم
Directed Energy Deposition (DED)	رسوب‌گذاری انرژی هدایت‌شده

Least Absolute Shrinkage and Selection Operator (LASSO)	عملگر انقباض مطلق کمینه و انتخاب	Ensemble Gradient Boosting (EGB)	تقویت گرادیان تجمیعی
Over Training	بیش آموزش	Ensemble Learning	یادگیری گروهی
Radial Basis Function (RBF)	تابع پایه شعاعی	Finite Element Method (FEM)	روش المان محدود
Random Forest	جنگل تصادفی	Generative Adversarial Network (GAN)	شبکه مولد تخصصی
Selective Laser Melting (SLM)	ذوب لیزری انتخابی	Kernel	هسته
Variational Auto Encoder (VAE)	خود رمزگذار متغیر	Laser Direct Metal Deposition (LDMD)	رسوب گذاری مستقیم فلز لیزری

مراجع

- [۱] I. Gibson, D. Rosen, B. Stucker, and M. Khorasani, "Introduction and Basic Principles," in *Additive Manufacturing Technologies*, I. Gibson, D. Rosen, B. Stucker, and M. Khorasani Eds. Cham: Springer International Publishing, 2021, pp. 1-21.
- [۲] S. Dharmadhikari, N. Menon, and A. Basak, "A reinforcement learning approach for process parameter optimization in additive manufacturing," *Additive Manufacturing*, vol. 71, p. 103556, 2023/06/05/ 2023, doi: <https://doi.org/10.1016/j.addma.2023.103556>.
- [۳] J. Qin *et al.*, "Research and application of machine learning for additive manufacturing," *Additive Manufacturing*, vol. 52, p. 102691, 2022/04/01/ 2022, doi: <https://doi.org/10.1016/j.addma.2022.102691>.
- [۴] S. Kumar *et al.*, "Machine learning techniques in additive manufacturing: a state of the art review on design, processes and production control," *Journal of Intelligent Manufacturing*, vol. 34, no. 1, pp. 21-55, 2023/01/01 2023, doi: 10.1007/s10845-022-02029-5.
- [۵] A. M. Schweidtmann *et al.*, "Machine Learning in Chemical Engineering: A Perspective," *Chemie Ingenieur Technik*, vol. 93, no. 12, pp. 2029-2039, 2021/12/01 2021, doi: <https://doi.org/10.1002/cite.202100083>.
- [۶] F. Rahimi, S. Ziaei, and R. M. Esfanjani, "A Reinforcement Learning-Based Control Approach for Tracking Problem of a Class of Nonlinear Systems: Applied to a Single-Link Manipulator," in *2023 31st International Conference on Electrical Engineering (ICEE)*, 9-11 May 2023 2023, pp. 58-63, doi: 10.1109/ICEE59167.2023.10334874 .
- [۷] M. H. Sulaiman ,M. S. Jadin, Z. Mustaffa, M. N. M. Azlan, and H. Daniyal, "Short-Term Forecasting of Floating Photovoltaic Power Generation Using Machine Learning Models," *Cleaner Energy Systems*, p. 100137, 2024/08/16/ 2024, doi: <https://doi.org/10.1016/j.cles.2024.100137>.
- [۸] H. Mahanna, N. El-Rashidy, M. R. Kaloop, S. El-Sapakh, A. Alluqmani, and R. Hassan, "Prediction of wastewater treatment plant performance through machine learning techniques," *Desalination and Water Treatment*, vol. 319, p. 100524, 2024/07/01/ 2024, doi: <https://doi.org/10.1016/j.dwt.2024.100524>.
- [۹] S. Hamal, B. K. Mishra, R. Baldock, W. Sayers, T. N. Adhikari, and R. M. Gibson, "A comparative analysis of machine learning algorithms for detecting COVID-19 using lung X-ray images," *Decision Analytics Journal*, vol. 11, p. 100460, 2024/06/01/ 2024, doi: <https://doi.org/10.1016/j.dajour.2024.100460>.
- [۱۰] D. J. McGregor, M. V. Bimrose, C. Shao, S. Tawfick, and W. P. King, "Using machine learning to predict dimensions and qualify diverse part designs across multiple additive machines and materials," *Additive Manufacturing*, vol. 55, p. 102848, 2022/07/01/ 2022, doi: <https://doi.org/10.1016/j.addma.2022.102848>.
- [۱۱] Z. Gu *et al.*, "A universal predictor-based machine learning model for optimal process maps in laser powder bed fusion process," *Journal of Intelligent Manufacturing*, vol. 34, no. 8, pp. 3341-3363, 2023/12/01 2023, doi: 10.1007/s10845-022-02004-0.
- [۱۲] Z. Zhang, Z. Liu, and D. Wu, "Prediction of melt pool temperature in directed energy deposition using machine learning," *Additive Manufacturing*, vol. 37, p. 101692, 2021/01/01/ 2021, doi: <https://doi.org/10.1016/j.addma.2020.101692>.
- [۱۳] J. Akhavan, J. Lyu, and S. Manoochhehri, "A deep learning solution for real-time quality assessment and control in additive manufacturing using point cloud data," *Journal of Intelligent Manufacturing*, vol. 35, no. 3, pp. 1389-1406, 2024/03/01 2024, doi: 10.1007/s10845-023-02121-4.
- [۱۴] L. Meng *et al.*, "Machine Learning in Additive Manufacturing: A Review," *JOM*, vol. ۷۲, no. 6, pp. 2363-2377, 2020/06/01 2020, doi: 10.1007/s11837-020-04155-y.

- [١٥] K. Azizi, H. Taheri, and S. Khooyooz, "Using Structured Pruning to Find Winning Lottery Tickets," in *2023 28th International Computer Conference, Computer Society of Iran) CSICC*, 25-26 Jan. 2023 2023, pp. 1-5, doi: 10.1109/CSICC58665.2023.10105376 .
- [١٦] J. F. Rodrigues, L. Florea, M. C. F. de Oliveira, D. Diamond, and O. N. Oliveira, "Big data and machine learning for materials science," *Discover Materials*, vol. 1, no. 1 ,p. 12, 2021/04/19 2021, doi: 10.1007/s43939-021-00012-0.
- [١٧] I. H. Sarker, "Machine Learning: Algorithms, Real-World Applications and Research Directions," *SN Computer Science*, vol. 2, no. 3, p. 160, 2021/03/22 2021, doi: 10.1007/s42979-021-00592-x.
- [١٨] A. Yafouz *et al.*, "Comprehensive comparison of various machine learning algorithms for short-term ozone concentration prediction," *Alexandria Engineering Journal*, vol. 61, no. 6, pp. 4607-4622, 2022/06/01/ 2022, doi: <https://doi.org/10.1016/j.aej.2021.1.0.021>
- [١٩] X. Su, J. An, Y. Zhang, P. Zhu, and B. Zhu, "Prediction of ozone hourly concentrations by support vector machine and kernel extreme learning machine using wavelet transformation and partial least squares methods," *Atmospheric Pollution Research*, vol. 11, no. 6, pp. 51-60, 2020/06/01/ 2020, doi: <https://doi.org/10.1016/j.apr.2020.02.024>.
- [٢٠] I. D. Mienye and Y. Sun, "A Survey of Ensemble Learning: Concepts, Algorithms, Applications, and Prospects," *IEEE Access*, vol. 10, pp. 99129-99149, 2022 ,doi: 10.1109/ACCESS.2022.3207287.
- [٢١] P. Kokol, M. Kokol, and S. Zagoranski, "Machine learning on small size samples: A synthetic knowledge synthesis," *Science Progress*, vol. 105, no. 1, p. 00368504211029777, 2022/01/01 2022, doi: 10.1177/003685042110297.٧٧
- [٢٢] K. Maharana, S. Mondal, and B. Nemade, "A review: Data pre-processing and data augmentation techniques," *Global Transitions Proceedings*, vol. 3, no. 1, pp. 91-99, 2022/06/01/ 2022, doi: <https://doi.org/10.1016/j.gltp.2022.04.020>.
- [٢٣] H. Ohno, "Auto-encoder-based generative models for data augmentation on regression problems," *Soft Computing*, vol. 24, no. 11, pp. 7999-8009, 2020/06/01 2020, doi: 10.1007/s00500-019-04094-0.
- [٢٤] L.-M. Liu, X.-Y. Ren, F. Zhang, L. Gao, and B. Hao, "Dual-dimension Time-GGAN data augmentation method for improving the performance of deep learning models for PV power forecasting," *Energy Reports*, vol. 9, pp. 6419-6433, 2023/12/01/ 2023, doi: <https://doi.org/10.1016/j.egyr.2023.05.226>.
- [٢٥] K. Nawa, K. Hagiwara, and K .Nakamura, "Prediction-accuracy improvement of neural network to ferromagnetic multilayers by Gaussian data augmentation and ensemble learning," *Computational Materials Science*, vol. 219, p. 112032, 2023/02/25/ 2023, doi: <https://doi.org/10.1016/j.commatsci.2023.112032>.
- [٢٦] E. Pérez and S. Ventura, "Progressive growing of Generative Adversarial Networks for improving data augmentation and skin cancer diagnosis," *Artificial Intelligence in Medicine*, vol. 141, p. 102556, 2023/07/01/ 2023, doi: <https://doi.org/10.1016/j.artmed.2023.102556>.
- [٢٧] G. Celik, "CovidCoughNet: A new method based on convolutional neural networks and deep feature extraction using pitch-shifting data augmentation for covid-19 detection from cough, breath, and voice signals," *Computers in Biology and Medicine*, vol. 163, p. 107153, 2023/09/01/ 2023, doi: <https://doi.org/10.1016/j.compbiomed.2023.107153>.
- [٢٨] L. Xu, M. Skoularidou, A. Cuesta-Infante, and K. Veeramachaneni, "Modeling Tabular data using Conditional GAN," 2019. [Online]. Available: https://proceedings.neurips.cc/paper_files/paper/2019/file/254ed7d2de3b23ab10936522dd547b78-Paper.pdf.
- [٢٩] E. Choi, S. Biswal, B. Malin, J. Duke, W. F. Stewart, and J. Sun, "Generating multi-label discrete patient records using generative adversarial networks," in *Machine learning for healthcare conference*, 2017: PMLR, pp. 286-305 .
- [٣٠] A. Srivastava, L. Valkov, C. Russell, M. U. Gutmann, and C. Sutton, "Veegan: Reducing mode collapse in gans using implicit variational learning," *Advances in neural information processing systems*, vol. 30, 2017.
- [٣١] N. Park, M. Mohammadi, K. Gorde, S. Jajodia, H. Park, and Y. Kim, "Data synthesis based on generative adversarial networks," *arXiv preprint arXiv:1806.03384*, 2018.
- [٣٢] G. a. W. James, Daniela and Hastie, Trevor and Tibshirani, Robert, *An Introduction to Statistical Learning: With Applications in R*, 2nd ed. Springer, 2021.
- [٣٣] T. Peng, J. Lv, A. Majeed, and X. Liang, "An experimental investigation on energy-effective additive manufacturing of aluminum parts via process parameter selection," *Journal of Cleaner Production*, vol. 279, p. 123609, 2021/01/10/ 2021, doi: <https://doi.org/10.1016/j.jclepro.2020.123609>.
- [٣٤] F. Caiazzo and A. Caggiano, "Laser Direct Metal Deposition of 2024 Al Alloy: Trace Geometry Prediction via Machine Learning," *Materials*, vol. 11, no. 3, p. 444, 2018. [Online]. Available: <https://www.mdpi.com/1996-1944/11/3/444>.
- [٣٥] G. Tapia, S. Khairallah, M. Matthews, W. E. King, and A. Elwany, "Gaussian process-based surrogate modeling framework for process planning in laser powder-bed fusion additive manufacturing of 316L stainless steel," *The International Journal of Advanced Manufacturing Technology*, vol. 94, no. 9, pp. 3591-3603, 2018/02/01 2018, doi: 10.1007/s00170-017-1045-z.
- [٣٦] Y. Li, Y. Sun, Q. Han, G. Zhang, and I. Horváth, "Enhanced beads overlapping model for wire and arc additive manufacturing of multi-layer multi-bead metallic parts," *Journal of Materials Processing Technology*, vol. 252, pp. 838-848, 2018/02/01/ 2018 ,doi: <https://doi.org/10.1016/j.jmatprotec.2017.10.017>.

- [۳۷] A. Kalilayeva, D. Zhumashev, D. Wei, A. Perveen, and D. Talamona, "Investigation of Stereolithography Additively Manufactured Components for Deviations in Dimensional and Geometrical Features," *Polymers*, vol. 16, no. 23, doi: 10.3390/polym16233311.
- [۳۸] A. Karadag and O. Ulkir, "Prediction of Dimensional Accuracy and Surface Quality in Additively Manufactured Biomedical Implants Using ANN," *International Journal of Precision Engineering and Manufacturing*, vol. 26, no. 5, pp. 1187-1213, 2025/05/01 2025, doi: 10.1007/s12541-025-01229-2.