



اجرای الگوریتم یادگیری ماشین پیش‌بینی استحکام کششی و مدول یانگ قطعات ساخت افزودنی بر پایه اکستروژن ذوبی مواد

امین جباری*

پژوهشکده مهندسی مکانیک، پژوهشگاه فناوری‌های نوین، سازمان پژوهش‌های علمی و صنعتی ایران، تهران، ایران
* ایمیل نویسنده مسئول: Jabbari@irost.ir

اطلاعات مقاله	چکیده
مقاله پژوهشی دریافت: ۱۵ مهر ۱۴۰۴ پذیرش: ۲۳ آذر ۱۴۰۴	فناوری ساخت افزودنی، هوش مصنوعی و الگوریتم‌های یادگیری ماشین از زمینه‌های فنی مهندسی هستند که در سال‌های اخیر به طور گسترده مورد استفاده قرار گرفته‌اند. از این‌رو مقاله حاضر به برقراری ارتباط بین این زمینه‌های نوین در طراحی و ساخت و تولید قطعات توجه دارد. با توسعه مواد جدید و نیاز روزافزون مهندسی و طراحان به پیش‌بینی خصوصیات مکانیکی قطعات پرینت‌شده با فرآیند لایه‌گذاری، به ایجاد دادگان و گسترش الگوریتم یادگیری ماشین جهت پیش‌بینی خواص قطعات ساخته‌شده به روش اکستروژن، پرداخته شده است. با تحلیل و دسته‌بندی نتایج آزمون کشش روی قطعات چاپ سه بعدی، داده‌های مناسب جهت پیاده‌سازی الگوریتم‌های یادگیری ماشین ایجاد شد. سپس شبکه‌های مختلف تحت الگوریتم‌های طبقه‌بندی‌کننده مانند درخت تصمیم‌گیری، دستگاه بردار پشتیبان، و نزدیک‌ترین همسایه‌های k برای پیش‌بینی استحکام کششی و مدول یانگ قطعات تولیدشده با ورودی‌های متفاوت دستگاه چاپگر بر پایه اکستروژن ذوبی و لایه‌نشانی مواد، ایجاد شده و طبق معیارهای استاندارد، دقت آن اندازه‌گیری شد. در نهایت مدل تولیدشده توسط الگوریتم طبقه‌بندی‌کننده درخت تصمیم‌گیری با به‌دست‌آوردن نمرات دقت‌سنجی بالا (دقت: ۰.۹۰۹)، سطح زیر منحنی: ۰.۹۲، نمره F1: ۰.۸۸) دارای قابلیت مناسب برای استفاده در پیش‌بینی استحکام کششی مواد شناخته شد. از نتایج این پژوهش می‌توان جهت بهینه‌سازی طراحی و همچنین تولید پایگاه‌های داده آزمایشی قابل قبول بهره‌گرفت چون می‌توان گفت مسیر آینده طراحی و ساخت دیجیتال با شناخت بهتر علم داده و ابزارهای شبیه‌سازی خواص نهایی دسته‌بندی شده قابل تصور است.
کلیدواژگان: چاپ سه بعدی علم داده هوش مصنوعی ساخت با رشته ذوب‌شونده خواص مکانیکی	

Applying machine learning algorithms to predict tensile strength and young's modulus of parts produced by extrusion-based additive manufacturing

Amin Jabbari*

Mechanical Engineering Research Institute, Institute of New Technologies, Iranian Research Organization for Science and Technology, Tehran, Iran
* Corresponding Author's Email: Jabbari@irost.ir

Article Information	Abstract
Original Research Paper Received: 7 October 2025 Accepted: 14 December 2025	Recent advancements in additive manufacturing (AM), artificial intelligence (AI), and machine learning (ML) have significantly influenced engineering practices, particularly in the design and fabrication of complex components. As the demand grows for predictive capabilities in assessing the mechanical properties of parts designed and produced via layer-by-layer 3D printing, machine learning algorithms offer promising solutions. This study examines the application of classification models to predict the tensile strength and Young's modulus of components manufactured via fused deposition modeling (FDM) under various process parameters. Tensile test data were systematically analyzed to train decision tree, support vector machine (SVM), and k-nearest neighbor (KNN) models. Among these, the decision tree algorithm exhibited the highest predictive accuracy (90.9%), with an AUC of 0.92 and an F1 score of 0.88. These findings underscore the value of data-driven methodologies in enhancing engineering design processes and establishing reliable experimental databases, contributing to the evolution of intelligent digital manufacturing systems.
Keywords: 3D Printing Data Science Artificial Intelligence Fused Filament Fabrication Mechanical Properties	

Please cite this article using:

برای ارجاع به این مقاله از عبارت ذیل استفاده نمایید:

Jabbari A. Applying machine learning algorithms to predict tensile strength and young's modulus of parts produced by extrusion-based additive manufacturing. Iranian Journal of Manufacturing Engineering. 2025 Dec 22;12(10):17-34. doi: 10.22034/ijme.2025.551862.2139 [In Persian]

۱- مقدمه

همگرایی تحول دیجیتال و نوآوری در تولید، چشم‌انداز صنعتی جهان را تغییر داده است و از سویی هوش مصنوعی (AI) و یادگیری ماشین (ML) به عنوان توانمندسازهای محوری انقلاب صنعتی چهارم در آن نقش جدی ایفا می‌کنند. همچنین فناوری‌های ساخت افزودنی (AM) از روش‌های نمونه‌سازی صرف به سیستم‌های با قابلیت تولید در حال تکامل‌اند که روندهای ساخت و تولید سنتی را تغییر می‌دهد. هم‌افزایی هوش مصنوعی با فرایندهای AM نشان‌دهنده مرز جدید در تولید مدرن است که فرصت‌های جدیدی را نیز برای بهینه‌سازی فرایند، کنترل کیفیت، پیش‌بینی و حتی افزایش خواص مواد ارائه می‌دهد.

سرعت گسترش ساخت افزودنی نه تنها نشان‌دهنده پیشرفت فناوری است، بلکه نشان‌دهنده تغییر به سمت تولید هوشمند است که از فرایندهای تصمیم‌گیری مبتنی بر داده بهره می‌برند. محیط‌های تولیدی به شکل فزاینده به الگوریتم‌هایی وابسته می‌شوند که قادر به پیش‌بینی، نظارت و بهینه‌سازی پارامترهای تولید است. تحول دیجیتال تولید، به کلی رویکرد صنعت به توسعه محصول، بهینه‌سازی فرایند و تضمین کیفیت را تغییر داده است. مفهوم صنعت ۴.۰ بر پایه ادغام سیستم‌های فیزیکی سایبری، فناوری‌های اینترنت اشیا (IoT) و تجزیه و تحلیل داده‌ها برای ایجاد زیست‌بوم‌های تولیدی هوشمند قرار دارد. در این چارچوب، قابلیت‌های مدل‌سازی پیش‌بینی تبدیل به ابزارهای ضروری برای حفظ رقابت‌پذیری و تضمین کیفیت محصول می‌شوند.

امروزه چالش‌های تولید فراتر از معیارهای سنتی بوده و شامل پایداری، سفارشی‌سازی و پاسخ سریع به تقاضای بازار می‌شوند. فناوری ساخت افزودنی با آزادی طراحی، کارایی مواد و قابلیت‌های تولید بر اساس تقاضا، مزایای منحصر به فردی برای این چالش‌ها ارائه می‌دهد. توصیف مواد همراه با قابلیت‌های جمع‌آوری داده‌های با توان عملیاتی بالا، روابط فرایند-ساختار-ویژگی را ارائه می‌دهد. با الگوریتم‌های یادگیری ماشین می‌توان از این مجموعه داده‌ها برای توسعه مدل‌های پیش‌بینی استفاده کرد.

پیش‌بینی خواص مکانیکی، رویکردهای مبنی بر شبیه‌سازی، آزمایش و اعتبارسنجی مجازی را ممکن و نیاز به نمونه‌سازی فیزیکی را کاسته و چرخه‌های توسعه محصول را تسریع می‌کند. سیستم‌های تولیدی آینده به الگوریتم‌های هوشمند متکی نیاز دارند که قادر به تصمیم‌گیری خودکار و بهبود مستمر فرایند هستند. این مقاله با هدف ادغام یادگیری ماشین با ساخت افزودنی، گامی در جهت دستیابی به این قابلیت‌های تولید خودکار است. مدل‌های تجاری جدید با بازتعریف رقابت‌پذیری، الگوهای تولید و ایجاد ارزش را ارائه می‌کنند که همزمان با بالغ شدن این فناوری‌ها است.

ساخت افزودنی بر پایه اکستروژن، به ویژه مدل‌سازی رسوب ذوبی (FDM)، به دلیل تطبیق‌پذیری، در دسترس بودن و سازگاری مناسب با مواد پلیمری و کامپوزیتی، به عنوان یکی از پرکاربردترین فناوری‌های AM پذیرفته شده است. فرایند FDM یا FFF قطعات سه‌بعدی را از طریق رسوب لایه به لایه مواد ترموپلاستیک مذاب ایجاد می‌کند و امکان تولید هندسه‌های پیچیده را فراهم می‌کند. خواص مکانیکی قطعات تولید شده به طور قابل توجهی تحت تأثیر پارامترهای فرایند متعدد از جمله دمای اکستروژن، ارتفاع لایه، چگالی پرشدن، سرعت چاپ و ویژگی‌های مواد قرار دارد.

مطالعه پژوهش‌های پیشین در حوزه‌های مختلف ساخت مشخص می‌کند الگوریتم‌های یادگیری ماشین پتانسیل مناسبی در پرداختن به چالش‌های پیش‌بینی خواص قطعات دارند [۱]. پیشرفت‌های اخیر در کاربردهای ML در ساخت افزودنی، نتایج قابل قبولی در پیش‌بینی زبری سطح، دقت ابعادی، وقوع نقص و خواص مکانیکی نشان داده است [۲]. توانایی الگوریتم‌های یادگیری ماشین در شناسایی الگوهای پیچیده در مجموعه داده‌های چندبعدی، آن‌ها را برای مدل‌سازی روابط پیچیده ذاتی در فرایندهای AM مناسب می‌کند [۳]. در میان خواص مکانیکی که عملکرد قطعه را تعیین می‌کنند، استحکام کششی و مدول یانگ از ویژگی‌های اساسی هستند که مستقیماً بر یکپارچگی ساختاری و تحمل بار تأثیر می‌گذارند [۴]. این خواص برای کاربردهای مهندسی که قطعات باید الزامات عملکرد خاصی را تحت شرایط عملیاتی برآورده کنند، ضروری اند [۵، ۶].

استفاده از هوش مصنوعی در کنترل کیفیت، قابلیت‌های تحلیلی را نیز در بر می‌گیرد [۷]. با یادگیری ماشین می‌توان حجم عظیمی از داده‌ها برای شناسایی پنجره‌های پردازش بهینه، پیش‌بینی نقص‌های بالقوه و تنظیمات پارامتری برای نتایج مطلوب را پردازش کرد [۸]. این قابلیت در ساخت افزودنی ارزشمندتر است، زیرا که پیچیدگی فرایند و رفتار تعاملی مواد، چالش‌هایی برای روش‌های سنتی کنترل کیفیت هستند [۹].

با مروری بر کارهای گذشته می‌توان گفت الگوریتم‌های مختلف یادگیری ماشین، از جمله درخت‌های تصمیم‌گیری، ماشین‌های بردار پشتیبان (SVM) و k-نزدیک‌ترین همسایه‌ها (k-NN)، می‌تواند به طور موثر خواص مکانیکی را در کاربردهای AM پیش‌بینی کند [۱۰]. درخت تصمیم‌گیری قابلیت تفسیر و سهولت پیاده‌سازی ارائه می‌دهند و برای کاربردهای صنعتی که درک منطق تصمیم‌گیری مهم است، مناسب هستند. ماشین‌های بردار پشتیبان در مدیریت روابط غیرخطی از طریق توابع هسته برتری دارند و نزدیک‌ترین همسایه‌ها، طبقه‌بندی شهودی بر اساس معیارهای شباهت ارائه می‌دهند [۱۱].

ارزیابی عملکرد مدل یادگیری ماشین نیازمند ارزیابی با استفاده از معیارهای چندگانه برای پیش‌بینی‌های قابل اعتماد است [۱۲، ۱۳]. مفهوم دقت، میزان صحیح بودن کلی را اندازه‌گیری می‌کند، اما می‌تواند در مجموعه داده‌های نامتوازن گمراه‌کننده باشد، در حالی که مساحت زیر منحنی (AUC) معیاری در مورد قابلیت تمایز مدل در بازه‌های مختلف ارائه می‌دهد [۱۴]. امتیاز F1 با ترکیب هارمونیک دقت و یادآوری، ارزیابی متعادلی ارائه می‌دهد که برای ارزیابی عملکرد طبقه‌بندی بسیار مهم است [۱۵].

در مقایسه با ادبیات موجود، این مقاله بر روی الگوریتم‌های ML منتخب (درختان تصمیم، SVM، k-NN) با مقاومت کششی و پیش‌بینی مدول یانگ با تاکید بر معیارهای ارزیابی مدل (دقت، امتیازات AUC، F1) و کاربرد در شرایط ورودی ناهمگن چاپگر تمرکز دارد. در مقایسه با مقالات موجود، یک مجموعه الگوریتم هدفمند به جای یک نظرسنجی ML گسترده اتخاذ می‌شود و معیارهای دقت مبنی بر طبقه‌بندی را به طور خاص برای پیش‌بینی مقاومت کششی ترکیب می‌کند [۱۶]. همچنین شرایط چاپگر چند پارامتری را برطرف می‌کند و بهینه‌سازی تک هدفه می‌باشد. ضمناً دامنه تجربی باریک تر نسبت به مقالات پیشین فراهم می‌کند، اما ارزیابی طبقه‌بندی‌گرا را اضافه می‌کند که با بررسی مقالات پیشین با روش پایه ای با اعتبارسنجی تجربی و مدل‌های ML کاربردی متفاوت است. بطور کلی این مقاله به روش طبقه‌بندی متمرکز و ارزیابی تنوع پارامترهای چاپگر سه بعدی FDM در زمینه گسترده تری که توسط مقالات پیشین ارائه شده است، کمک می‌کند.

استفاده از الگوریتم‌های یادگیری ماشین در حوزه چاپ سه بعدی شامل جنبه‌های متنوعی که تأثیر مستقیمی بر روی کیفیت قطعات چاپ شده نهایی دارند می‌شود [۱۷]. این امر شامل: طراحی برای چاپ سه بعدی، بهینه‌سازی فرایند و کیفیت قطعات، و نظارت در موقعیت مناسب برای کنترل کیفی. جنبه‌های دیگری نیز مربوط به کارآمد بودن طراحی و فرایند ساخت برای تکنیک‌های چاپ سه بعدی هستند که شامل این موارد می‌شوند: بررسی امکان چاپ، شتاب تغذیه و قطع، برنامه‌ریزی مسیر نازل، پلتفرم خدمات فضای ابری و ارزیابی خدمات.

این مقاله با استفاده از الگوریتم‌های یادگیری ماشین به چالش پیش‌بینی خواص مکانیکی در ساخت افزودنی اکستروژن مواد می‌پردازد و از روابط پیچیده و غیرخطی بین پارامترهای فرایند و ویژگی‌های قطعه نهایی اجتناب کند. ضرورت انجام آن افزایش سرعت و سهولت در مقایسه با رویکردهایی که به روش‌های آزمون و خطا متکی هستند، زمان‌بر، پرهزینه و برای تعاملات پیچیده بین متغیرهای متعدد ناکافی هستند. این محدودیت، نیازی جدی به رویکردهای مدل‌سازی پیش‌بینی ایجاد کرده است که قادر به پیش‌بینی خواص مکانیکی بر اساس شرایط فرایند باشند. این پژوهش گامی در ارائه روشی ساده و هدفمند برای ایجاد دسته‌بندی قابل درک ماشین برای پیش‌بینی خواص نهایی قطعه است. مقاله حاضر با بررسی کاربرد الگوریتم‌های یادگیری ماشین برای پیش‌بینی استحکام کششی و مدول یانگ، به نیاز به مدل‌های پیش‌بینی قابل اعتماد در ساخت افزودنی برپایه اکستروژن می‌پردازد. این مقاله با مقایسه مدل‌های درخت تصمیم‌گیری، ماشین بردار پشتیبان (SVM) و مدل‌های k-نزدیک‌ترین همسایه، به دانش رو به رشد در تعامل هوش مصنوعی و ساخت و تولید پیشرفته کمک می‌کند. این مقاله به دنبال راهکارهایی را برای بهبود فرایند طراحی مهندسی و ایجاد پایگاه‌های داده تجربی ضروری و قابل اعتماد برای سیستم‌های تولید دیجیتال است.

۲- مواد و روش‌ها

ویژگی‌ها و خواص مکانیکی قطعات از مهم‌ترین نیازهای مهندسی برای طراحی است. با استفاده از فرایندها و الگوریتم‌های یادگیری ماشین و با مدلسازی بخشی از آزمایش‌های انجام شده بر روی قطعات تولید شده بروش چاپ سه بعدی FDM از جنس پلی لاکتیک اسید (PLA)، به پیش‌بینی خصوصیات مکانیکی مقاومت کششی و مدول یانگ قطعات با پارامترهای مختلف قابل تنظیم در دستگاه‌های ساخت افزودنی یا همان چاپگر سه بعدی پرداخته شده است.

در مدلسازی ارائه شده برهم‌کنش سه پارامتر تأثیرگذار شامل ضخامت لایه، جهت‌گیری ساخت و سرعت ورود مواد به عنوان پارامترهای ورودی دستگاه چاپگر و مقاومت کششی و مدول یانگ به عنوان پارامترهای خروجی و مورد پیش‌بینی هستند. در این روش مدلسازی برخلاف روش‌های مرسوم به تأثیر توان این متغیرها بر متغیرهای خروجی پرداخته شده است [۱۸]. با توجه به استفاده از الگوریتم‌های یادگیری ماشین، نتایج حاصل تبدیل به مدل‌هایی شده‌اند که با تخصیص ورودی‌ها می‌توانند خصوصیات مکانیکی مورد نظر را پیش‌بینی نمایند. مهم‌ترین هدف بررسی و تولید مدل‌های پیش‌بینی، ساده‌سازی بررسی تأثیر توام متغیرهای ورودی دستگاه بر روی کیفیت قطعات خروجی، ساده‌سازی پروسه تنظیم دستگاه جهت دستیابی به قطعات با کیفیت، کاهش وابستگی به تست‌های آنالیز قطعه، کمک به طراحان جهت طراحی دقیق‌تر قطعات بدون نیاز به آنالیزهای پرهزینه، کمک به ایجاد دیتاست‌های آزمایش خصوصیات مکانیکی قطعات با دقت بالا، کاهش هزینه‌های تولید از طریق ایجاد ساختارهای کنترل‌کننده، افزایش دقت تولید از طریق ایجاد ساختارهای پیش‌بینی‌کننده، افزایش سرعت فرایند ساخت افزودنی به واسطه ساختارهای خود تنظیم‌شونده، و افزایش کیفیت قطعات تولید شده به واسطه ساختارهای خود تنظیم‌شونده می‌باشند [۱۹، ۲۰].

۲-۱- بهینه‌سازی فرایند و کیفیت قطعات

بهینه‌سازی فرایند اغلب زمانی انجام می‌شود که مواد یا فرایندهای جدیدی عرضه یا طراحی شوند. بهینه‌سازی فرایندهای ساخت افزودنی به هدف ایجاد ویژگی‌های خاص در قطعات چاپ شده در چاپ سه بعدی انجام می‌شوند. وجود یک بانک داده از رابطه میان فرایند-ساختار-ویژگی (PSP) در یک فرایند ساخت افزودنی و مواد آن، این امکان را فراهم می‌کند تا پارامترها بر اساس اطلاعات موجود در بانک داده به درستی انتخاب شوند. رابطه PSP اغلب به دلیل زیاد بودن ویژگی‌های ابعادی پارامترهای فرایند، پیچیده است. این امر طراحی فرمول‌های ریاضی کنترل‌کننده در فرایند را دشوار می‌کند [۲۱]. این پیچیدگی باعث شده که از الگوریتم‌های یادگیری ماشین برای تعیین روابط فرایند-ساختار-ویژگی در بسیاری از فرایندهای ساخت افزودنی استفاده شود. جدول ۱ خلاصه‌ای از کاربردهای الگوریتم‌های یادگیری ماشین در بهینه‌سازی فرایندهای ساخت افزودنی، پارامترهای ورودی فرایند و ویژگی‌های هدف را نشان می‌دهد.

جدول ۱ استفاده از یادگیری ماشین برای بهینه‌سازی فرایند در فرایند ساخت افزودنی

پارامترهای ورودی	روش	هدف
ضخامت لایه، جهت، زاویه شطرنجی، عرض شطرنجی، شکاف هوا	پس انتشار انعطاف پذیر (RBP) در ANN	بهینه‌سازی مقاومت فشاری
ضخامت لایه، جهت، زاویه شطرنجی، عرض شطرنجی، شکاف هوا	۵-۸-۱ ANN.RBP	پیش‌بینی حجم سایش
ضخامت لایه، جهت، زاویه شطرنجی، عرض شطرنجی، شکاف هوا	MGGP, SVR, ANN	MGGP, SVR, ANN
جهت‌گیری، ضخامت برش	ANN, GA	پیش‌بینی خطای حجمی
ضخامت لایه، جهت، زاویه شطرنجی، عرض شطرنجی، شکاف هوا	منطق فازی، NN، تاگوچی	دقت ابعادی
ضخامت لایه، جهت، زاویه شطرنجی، عرض شطرنجی، شکاف هوا	خاکستری تاگوچی، NN.BP	دقت ابعادی
ضخامت لایه، دمای اکستروژن، سرعت تغذیه به سرعت جریان	الگوریتم Ensemble	زبری سطح
زاویه قطعه و فاصله بین وجوه موازی	ANN	دقت هندسی
سرعت حرکت بستر، سرعت اکستروژن، قطر نازل، فاصله خطوط	ANN و GA	عرض خط داربست
ضخامت لایه، شکاف هوا، زاویه شطرنجی، جهت ساخت، عرض مسیر، تعداد خطوط	ANN	مدول الاستیسیته دینامیکی
ضخامت، دما، الگوی شطرنجی	ANN	استحکام کششی

در دستگاه FDM واحد کنترل رایانه ای سرعت و موقعیت سه محور دکارتی را از طریق تنظیم سرعت چرخش و پله‌های موتور استپر کنترل می‌کند. با کنترل موتور استپر مکانیزم وارد کننده فیلامنت، می‌توان شرایط ورود و خروج فیلامنت را تعیین کرد. دمای محفظه کنار نازل‌ها نیز به همین شکل در یک چرخه کنترل بسته تنظیم می‌شود. دستگاه‌های FDM با منبع باز برای کاربر این امکان را فراهم می‌کنند که کد NC که در زبان استاندارد ISO نوشته شده است و حاوی مختصات نقاط موجود در مسیر نازل است را ویرایش کنند. کد

G1 برای تعریف نقطه به نقطه حرکت در خطوط مستقیم است، در حالی که کد M کارایی‌های دیگر را کنترل می‌کند، مثل ورود فیلامنت، گرمایش لازم برای خروج فیلامنت و یا تمیز کردن نازل [۲۲]. پارامترهای فرایندی بسیار بیشتری در فرایندهای بر پایه اکستروژن مواد در چاپ سه بعدی گزارش شده است [۲۳، ۲۴] که مشابهت‌های اصلی در این مقاله مورد استفاده قرار گرفته است.

۲-۲- بررسی روش‌های یادگیری ماشین

تکنیک‌های یادگیری ماشین به طور کلی در چهار دسته تقسیم‌بندی می‌شوند: یادگیری تحت نظارت، یادگیری بدون نظارت، یادگیری با نظارت نسبی و یادگیری تقویت شده. الگوریتم‌های یادگیری تحت نظارت، مدل رابطه میان خصوصیات داده‌های ورودی و خروجی‌های عنوان‌دار را ترسیم می‌کنند و بدین صورت می‌توانند خصوصیات ورودی لازم برای دست‌یابی به خروجی‌های مدنظر را پیش‌بینی کنند. الگوریتم‌های طبقه‌بندی درخت تصمیم‌گیری و رگرسیون درخت تصمیم‌گیری یا به اختصار الگوریتم‌های CART محبوب‌ترین روش شاخه‌بندی است که توسط بریمن معرفی و استفاده شده است. انواع مختلفی از روش اولیه پیشنهاد شده‌اند و ایده کلی در شاخه‌بندی CART تقسیم فضای متغیرهای توضیحی به چند مثلث چند بعدی است. به این صورت می‌توان روی هر کدام از آن‌ها یک پیش‌بینی‌کننده ساده استفاده کرد [۲۵]. تشکیل ساختار شاخه‌بندی بر اساس طبقه‌بندی بازگشتی داده اصلی به دو زیر گروه است. بدین صورت یک ساختار شاخه‌ای تشکیل می‌شود. همین‌طور که شاخه‌ها بیشتر می‌شوند، هر گره نیز همگن‌تر می‌شود.

تقسیم داده‌های فعلی توسط یک قانون باینری بر روی متغیرهای توضیحی انجام شده است. برای متغیرهای پیوسته تقسیم به صورت $x < s$ است که در آن s یک آستانه از متغیر x است. همگن بودن با در نظر داشتن متغیر هدف Y بررسی می‌شود. به هر کدام از نمونه‌های زیرگروه یا leaf، یک مقدار از Y داده می‌شود. برای شاخه‌های رگرسیون، این مقدار برابر میانگین مقدار Y بر روی مشاهده‌های leaf یا برگ است. برای شاخه‌های گروه‌بندی از معمول‌ترین سطح Y در زیرگروه استفاده شده است [۲۶].

اگر تعداد تکرارها کم باشد باید شاخه‌بندی متوقف شود. در هر کدام از گره‌های ترمینال مقدار زیادی داده وجود خواهد داشت که منجر به خطاهای آماری کوچک و خطاهای مدل‌سازی بزرگ می‌شوند. این تعداد را می‌توان با اضافه کردن یک شرط به اندازه‌گیری شاخص همگن بودن گره‌ها محاسبه کرد. این شرط به صورت خطی متکی به تعداد برگ هاست و برای پیچیدگی شاخه‌ها امتیاز منفی در نظر می‌گیرد. به این فرایند اصطلاحاً هرس کردن گفته می‌شود که نتایج بسیار کارآمدی دارد.

در استفاده از CART نتایج به دست آمده به راحتی قابل فهم هستند. همین‌طور که پیچیدگی افزایش می‌یابد، در مقایسه با روش‌های جایگزین قوی‌تر عمل می‌کند. همچنین می‌تواند در چهارچوب تحلیل داده کاربردی استفاده شود که در آن X یک بازه زمانی یا یک سیگنال است. [۲۷، ۲۸].

اما SVM روش دیگری برای گروه‌بندی داده‌ها و رگرسیون فراهم می‌کند. ایده پایه‌ای این روش در چهارچوب گروه‌بندی بررسی می‌شود. فرض بر یک سری نمونه با ورودی R^d و یک خروجی باینری $Y \in \{-1, 1\}$ که در آن داده‌ها به صورت خطی قابل جداسازی هستند. به عنوان مثال حداقل یک ابرپهنه^۱ در R^d وجود دارد که به صورت کاملاً ایده‌آل به دو زیرگروه تقسیم می‌شود که هر کدام، به یک سطح از Y مرتبط هستند. یک ابرپهنه^۱ H که به صورت $F(x) = 0$ و با فرمول $f(x) = \langle w, x \rangle + b$ تعریف می‌شود که در آن $w \in R^d$ مرتبط با بردار معمولی ابرپهنه است و $\langle \cdot, \cdot \rangle$ محصول نقطه در R^d را مشخص می‌کند [۱۸]. حاشیه ابرپهنه با در نظر گرفتن نمونه S به صورت $\gamma_H = \min_{i=1, \dots, n} \gamma_i$ تعریف می‌شود و مرتبط با حاشیه نزدیکترین نقطه به H است. هدف دستگاه‌های دستگاه بردار پشتیبان پیدا کردن تمام ابرپهنه‌هایی در R^d است که حاشیه‌ها را به حداکثر می‌رساند:

$$H^* = \operatorname{argmax}_H \gamma_H. \quad (1)$$


مشاهده شده است که در موارد قابل جداسازی خطی، بهترین حالت ابرپهنه H از بهینه‌سازی‌هایی استفاده می‌کند، که در آنها γ_H تحت این قید که تمام مشاهدات در این نمونه به درستی تقسیم‌بندی شده‌اند، به حداکثر خود می‌رسد. برای موارد قابل جداسازی غیرخطی، داده‌ها در یک فضا در بُعد بالاتر جاسازی می‌شوند که به آن فضای آینده با استفاده از تابع کرنل^۲ گفته می‌شود. ایده این است که در بعد بالاتر، دسته‌ها می‌توانند راحت‌تر جدا شوند. کرنل تبدیل داده‌ها را مشخص می‌کند. اینجا از تابع Gaussian Kernel با فرمول (۲) استفاده می‌شود که در آن $\delta > 0$ [۴].

¹ Hyperplane

² Kernel

$$K(x, y) = \exp^{-\delta \|x-y\|^2} \quad (2)$$

شکل ۱، دو دسته در R که به صورت خطی جدا شده‌اند را نشان می‌دهد.



شکل ۱ دو دسته در R که به صورت خطی جدا شده‌اند. γ_i حاشیه مشاهده i و γ حاشیه ابر پهنه با در نظر گرفتن نمونه است

روش‌های نزدیکترین همسایه‌ها از بصری‌ترین روش‌ها هستند. برای محاسبه پیش‌بینی کننده $f(x)$ در نقطه x لازم است که یک $N_k(x)$ تعریف شود که با آن دسته از k که به مشاهدات x در بین نمونه‌های R^d نزدیک‌تر است، مرتبط باشد. برای رگرسیون پیش‌بینی‌کننده، میانگین خروجی روی نزدیکترین همسایه‌های k است که با فرمول زیر محاسبه می‌شود [۱۲].

$$f(x) = \frac{1}{k} \sum_{i \in N_k(x)} y_i \quad (3)$$

در گروه‌بندی باینری، مرز میان دو دسته معمولاً یک منحنی بسیار نامنظم است. روش «نزدیکترین همسایه‌های k » در مقابل داده‌های منزوی مقاوم است. پارامتر ناشناس در این روش k است. [۲۹].

یادگیری بدون نظارت بر خلاف یادگیری تحت نظارت نیاز به نیروی متخصص برای عنوان‌گذاری داده‌ها ندارد. روش‌های بدون نظارت، خصوصیات در داده‌های ورودی که بدون عنوان هستند را استخراج کرده و آن‌ها را از طریق قوانین خودآموزخته دسته‌بندی می‌کنند. لذا این مدل‌ها معمولاً برای تشخیص روابط پنهان یا ناشناخته در میان داده‌ها استفاده می‌شوند [۳۰].

یادگیری با نظارت نسبی نیز ترکیبی از یادگیری تحت نظارت و بدون نظارت است. الگوریتم‌های یادگیری با نظارت نسبی زمانی استفاده می‌شوند که با حجم زیادی از داده‌ها مواجه‌اند و باعث می‌شود عنوان‌گذاری داده‌ها کاری غیرعملی و پرهزینه شود. بدین ترتیب داده‌های وارد شده به الگوریتم‌های یادگیری، ترکیبی از داده‌های با عنوان و بدون عنوان هستند. مدل‌های نظارت نسبی از این دو دسته داده‌ها (با عنوان و بدون عنوان) استفاده می‌کنند و به دلیل وجود مقدار کمی از داده‌های با عنوان، به طور کلی بهتر از مدل‌های یادگیری بدون نظارت عمل می‌کنند. این مدل‌ها مقرون به صرفه‌تر هستند و تعلیم آن‌ها از حالت یادگیری تحت نظارت آسان‌تر است [۲۹].

برخلاف یادگیری تحت نظارت که داده‌ها عنوان‌گذاری می‌شوند، در تعلیم داده‌ها برای یادگیری تقویت شده تنها ویژگی صحیح یا غلط بودن برای داده‌ها تعریف می‌شود. این مدل‌ها به صورت مکرر رفتار را در تعامل با محیط یاد می‌گیرند. قواعد تعلیم این مدل‌ها مانند یادگیری تحت نظارت است ولی به جای استفاده از حجم زیادی از داده‌های با عنوان، مدل مدام با محیط خود در تعامل است که این تعامل منجر به پاداش مثبت و یا تنبیه منفی می‌شود. این بازخورد، رفتار این مدل را تقویت می‌کند که نام این مدل از همین گرفته شده است. الگوریتم‌های یادگیری تقویت شده اغلب از اصطلاحات کاوش و بهره‌گیری استفاده می‌کنند. بهره‌گیری به انجام اقداماتی اشاره دارد که بیشترین بهره ممکن از قانون پاداش را دارند، و کاوش به معنی انجام اقداماتی است که قبل‌تر از آن انجام نشده بودند. این مدل با استفاده از ترکیب این دو تکنیک می‌تواند به آرامی با محیط خود آشنا شود و داده‌های ورودی که منجر به پاداش‌های مثبت می‌شوند را شناسایی کرده و راه‌حل‌های مناسبی پیدا کند [۳۱].

۳- آزمون‌های عملی و پارامترهای فرایند

هدف این مقاله تحلیل عملکرد مکانیکی نمونه‌های PLA است. در آزمون‌های عملی از فیلامنت‌های با جنس PLA و قطر ۱.۷۵ میلیمتر استفاده شده است. مواد مورد استفاده در این پژوهش از برند eSun تولید کشور چین می‌باشد. مقادیر معمول در ویژگی‌های اصلی ماده PLA تولید شده با فناوری FDM در جدول ۲ نشان داده شده‌اند [۲۲].

جدول ۲ مقادیر معمول در ویژگی‌های اصلی مواد PLA چاپ شده با پرینت سه بعدی فیلامنتی

خواص مکانیکی	PLA
استحکام کششی (MPa)	۷۲.۲-۱۵.۵
مدول کششی (GPa)	۳.۵۵۰-۲.۰۲۰
ازدیاد طول در هنگام شکست (%)	۹.۲-۰.۵
مقاومت خمشی (MPa)	۱۱۵.۱-۵۲
مدول خمشی (GPa)	۴.۹۳۰-۲.۳۹۲

نمونه‌های تست کشش از جنس PLA توسط چاپگر سه بعدی رومیزی Creality k1Max، تولید شده‌اند. که یک چاپگر رومیزی پلیمری است که بعنوان ورودی از مواد تجاری استفاده می‌کند و نازل استاندارد برنجی به قطر ۰/۴ میلی‌متر است. دستگاه توسط نرم‌افزارهای متن باز قابل کنترل است [۳۲]. در این مقاله از نرم افزار Creality برای ایجاد فایل‌های G-code و برای کنترل تمام پارامترهای فرایند استفاده شده است. برای آزمون خواص کششی قطعات ساخته شده توسط FDM در این آزمون‌ها از روش ASTM D638-10 برای آزمایش خواص کششی قطعات استفاده شده است. مدل هندسی نمونه‌های کشش چاپ شده با استفاده از نرم افزار SolidWorks طراحی شده و با تبدیل به صورت فایل STL وارد نرم‌افزار چاپ سه بعدی شده است.

۳-۱- پارامترهای فرایند چاپ سه بعدی

ویژگی‌های مکانیکی قطعاتی که توسط فناوری FDM تولید می‌شوند به پارامترهای فرایند بستگی دارد. با بررسی پژوهش‌های پیشین و در نظر گرفتن سخت افزار مورد استفاده در این پژوهش، پارامترهای فرایند FDM استفاده شده در این مقاله به شرح آمده در جدول ۳ تعیین شد. در این آزمایش سه جهت‌گیری ساخت ارزیابی شدند (شکل ۲): صاف (F) و روی لبه (O) که در آن‌ها قرارگیری فیلامنت‌های ترکیبی در راستای جهت کشش است و جهت‌گیری ایستاده (U) که در آن لایه‌ها به صورت عمودی در جهت کشش قرار داده شده‌اند.


جدول ۳ پارامترهای فرایند و سطح آن‌ها در این آزمایش

پارامتر	مقدار
جهت‌گیری ساخت	تخت (F)، روی لبه (O)، عمودی (U)
ضخامت لایه (میلی متر)	$\{0.06, 0.12, 0.18, 0.24\} = Lt$
نرخ تغذیه (سرعت جریان) mm ³ /s	$\{(7.7)80, (4.8)50, (1.9)20\} = Fr$

علاوه بر آن، برای تحلیل تأثیر ضخامت لایه‌ها، ۴ ضخامت مختلف مد نظر قرار داده شده‌اند $Lt = \{0.06, 0.12, 0.18, 0.24\}$. که ضخامت لایه‌ها در راستای محور Z اندازه‌گیری شده است. این مقادیر بر اساس ویژگی‌های چاپگر سه بعدی FDM انتخاب شدند. حداقل ضخامت لایه در چاپگر سه بعدی برابر با $Lt = 0.06 \text{ mm}$ بوده است. در ادامه تأثیر سرعت ورود مواد (Fr) بر ویژگی‌های مکانیکی نیز ارزیابی شده است. سه سرعت چاپ متفاوت مد نظر قرار داده شدند Fr برابر ۲۰، ۴۰ و ۸۰ mm/s. به منظور حفظ یک پهنای ثابت در خطوط احاطه‌کننده، سرعت خروج مواد تغییر داده شده است.

به دلیل طیف گسترده موجود در الگوهای مغزی، تحلیل تأثیر الگوهای رستر دشوار است [۳۳]. در این مقاله نمونه‌های توپر با الگوی خطی و چگالی پر کردن ۱۰۰ درصد که توسط یک رستر محیطی پر شده‌اند، مورد بررسی قرار گرفتند. در این قطعات مبدا مسیر ابزار

بر روی محیط با فاصله‌ای برابر با اندازه نازل بوده است (شکل ۲). لذا ضخامت پوسته به اندازه‌ای بلند در نظر گرفته شده که بتوان نمونه را با زاویه رستر صفر درجه پر کرد. سایر پارامترهای پرینت مانند شکاف هوا، زاویه رستر دمای چاپ و دمای صفحه ساخت برای تمام نمونه‌ها یکسان بوده‌اند تا بر روی تأثیر سه پارامتر قبلی تمرکز شود. همچنین مقدار پارامترهای ثابت چاپ: فاصله هوا، زاویه شطرنجی به ترتیب ۰ و ۰ درجه، دمای نازل 210°C و دمای صفحه 40°C در نظر گرفته شد.




شکل ۲ تنظیم پارامترهای فرایند چاپ (a) جهت‌گیری ساخت (b) ضخامت لایه‌ها و رستر محیطی (c) نمونه لایه-لایه کردن یا اسلایسنگ در نرم افزار کرلیتی با جهت گیری‌های سه گانه

۲-۳- آزمایش‌های تجربی چاپ

هر گروه از نمونه‌ها شامل ۵ قطعه برای بررسی یک پارامتر خاص بوده است و به طور کلی ۱۸۰ نمونه تولید شده است. از آنجایی که جذب رطوبت بر روی خواص مکانیکی مواد PLA چاپ شده تأثیرگذار است فیلامنت‌های PLA و نمونه‌های ساخته شده برای کاهش جذب رطوبت در جعبه با رطوبت گیر نگهداری می‌شدند [۳۴]. در آزمون‌های مکانیکی مقادیر میانگین استحکام و سختی بدست آمده به عنوان نتایج در نظر گرفته شدند.

آزمایشات تست کشش بر اساس استاندارد ASTM D638-10 انجام شدند. آزمایش تجربی از یک دستگاه یونیورسال الکترومکانیکی 50 kN که یک لودسل 5 kN داخل آن تعبیه شده و با سرعت کشش 2 mm/min تنظیم شده، استفاده شد. سرعت جابجایی در بازه مشخص شده استاندارد $1-5\text{ mm/min}$ است و با جابجایی استفاده شده در دیگر پژوهش‌ها مطابقت دارد. کرنش توسط یک فشارسنج محوری MTS 634.14 با عملکرد مناسب اندازه‌گیری شده است. برای تعیین حداکثر تنش کششی و مدول یانگ، داده‌ها بر اساس استانداردهای مذکور پردازش شدند. در راستای بررسی تفاوت‌های عملکردی نمونه‌های ساده، مدول یانگ با در نظر گرفتن بخش خطی منحنی تنش-کرنش تعیین شده و شیب آن به شکل خطی تخمین زده شد [۳۵]. شکل ۳ نمونه‌های تست کشش پرینت شده با جهت گیری مختلف و استراتژی‌های مختلف لایه گذاری را نشان می‌دهد که پرینت شده‌اند.

مقادیر استاندارد و میانگین نتایج آزمایش برای حداکثر تنش کششی و حداکثر مدول یانگ نمونه‌های چاپ شده PLA در جدول ۴ نوشته شده‌اند.



شکل ۳ نمونه قطعات با ساختار داخلی توپر در سه جهت گیری مختلف پرینت شده با دستگاه Crealty و پلیمر پایه PLA

جدول ۴ میانگین آزمایش مقاومت مکانیکی برای نمونه‌ها و برد پارامترهای فرایند (اختلاف مقادیر استاندارد داخل پرانتز مشخص شده‌اند)

جهت ساخت	Fr = ۲۰ میلی متر بر ثانیه σ_t (MPa)	E (GPa)	Fr = ۵۰ میلی متر بر ثانیه σ_t (MPa)	E (GPa)	Fr = ۸۰ میلی متر بر ثانیه σ_t (MPa)	E (GPa)
Lt = 0.06 میلی متر						
رو به بالا	۲۸/۸ (۰/۲)	۴/۰۱۱ (۰/۰۴۰)	۲۰/۲ (۱/۳)	۳/۷۶۵ (۰/۱۲۷)	۲۲/۴ (۱/۷)	۳/۲۶۶ (۰/۱۲۲)
بر لبه	۷۳/۲ (۰/۹)	۴/۰۴۲ (۰/۰۷۵)	۸۴/۷ (۰/۵)	۴/۰۱۸ (۰/۰۰۲)	۸۳/۴ (۰/۲)	۴/۰۴۰ (۰/۰۸۲)
تخت	۷۵/۲ (۰/۳)	۳/۷۶۸ (۰/۰۳۴)	۸۹/۱ (۰/۲)	۴/۱۹۲ (۰/۰۷۰)	۸۸/۲ (۰/۴)	۴/۴۰۹ (۰/۱۰۹)
Lt = 0.12 میلی متر						
رو به بالا	۳۴/۹ (۱/۵)	۳/۵۹۹ (۰/۲۵۱)	۴۶/۲ (۰/۷)	۳/۸۸۷ (۰/۱۴۵)	۲۷/۵ (۲/۲)	۳/۷۹۶ (۰/۱۲۸)
بر لبه	۷۲/۴ (۰/۶)	۴/۰۱۸ (۰/۰۶۳)	۷۷/۳ (۰/۱)	۳/۹۹۲ (۰/۰۳۴)	۶۵/۴ (۱/۳)	۳/۹۷۶ (۰/۰۳۹)
تخت	۷۲/۸ (۱/۴)	۳/۹۲۵ (۰/۰۰۶)	۷۴/۵ (۳/۰)	۳/۸۶۰ (۰/۰۴۸)	۶۸/۶ (۱/۰)	۳/۸۹۲ (۰/۰۳۵)
Lt = 0.18 میلی متر						
رو به بالا	۴۰/۹ (۴/۸)	۳/۵۲۱ (۰/۰۸۹)	۴۱/۱ (۱/۷)	۳/۷۲۶ (۰/۱۶۹)	۳۲/۶ (۰/۴)	۳/۶۶۸ (۰/۰۶۱)
بر لبه	۷۸/۵ (۱/۲)	۳/۹۱۳ (۰/۰۵۷)	۶۴/۹ (۱/۸)	۴/۰۰۴ (۰/۰۷۳)	۶۶/۱ (۲/۷)	۳/۹۵۵ (۰/۰۳۳)
تخت	۷۶/۵ (۰/۹)	۳/۸۸۲ (۰/۰۵۶)	۷۷/۳ (۰/۸)	۴/۰۱۷ (۰/۰۳۷)	۶۹/۸ (۱/۵)	۴/۰۳۰ (۰/۰۲۳)
Lt = 0.24 میلی متر						
رو به بالا	۴۶/۶ (۲/۸)	۳/۳۵۶ (۰/۰۹۷)	۴۰/۵ (۳/۳)	۳/۴۵۱ (۰/۱۷۵)	۳۹/۵ (۴/۴)	۳/۴۶۸ (۰/۰۴۶)
بر لبه	۷۸/۴ (۱/۷)	۳/۹۲۴ (۰/۰۳۱)	۷۸/۱ (۰/۳)	۴/۰۲۵ (۰/۰۵۸)	۷۱/۹ (۱/۲)	۳/۹۳۴ (۰/۰۶۳)
تخت	۷۳/۶ (۰/۷)	۳/۹۱۵ (۰/۱۱۲)	۷۲/۳ (۰/۲)	۳/۷۶۹ (۰/۰۳۴)	۶۴/۶ (۰/۵)	۳/۶۲۲ (۰/۰۲۸)

۳-۳- دسته‌بندی داده‌ها

با توجه به نتایج تست‌های انجام شده و سعی این مقاله بر استفاده از الگوریتم‌های یادگیری ماشین جهت پیش‌بینی کیفیت قطعات خروجی بر پایه مقاومت کششی و مدول یانگ، داده‌های نتایج آزمایش در دو دسته بالا (با نماد ۱) و پایین (با نماد ۰) طبقه‌بندی شد که اساس این تقسیم‌بندی بر پایه میانه آماری داده‌های موجود بوده است که در جدول ۵ نشان داده شده است.

جدول ۵ طبقه‌بندی داده‌ها بر پایه میانه آماری داده‌ها

دسته	بالا (۱)	پایین (۰)
مقاومت کششی (MPa)	< 70.85	> 70.85
مدول یانگ (GPa)	< 3.91	> 3.91

۳-۴- روش‌های دقت سنجی الگوریتم‌های یادگیری ماشین

طبق تعریف استاندارد دقت عبارت است از نسبت پیش‌بینی‌های درست یک مدل به تمامی پیش‌بینی‌های آن که از رابطه زیر به دست می‌آید.

$$Accuracy = (TP+TN) / (TP+FP+FN+TN)$$

(۴)

ماتریس درهم‌ریختگی^۱ همانطور که از نام آن پیداست یک ماتریس خروجی است که عملکرد کامل مدل را مشخص می‌کند. مثبت‌های حقیقی: مواردی که در آنها پیش‌بینی مثبت است و خروجی واقعی نیز مثبت است. منفی‌های حقیقی: مواردی که در آنها پیش‌بینی منفی است و خروجی واقعی نیز منفی است. مثبت‌های کاذب: مواردی که در آنها پیش‌بینی مثبت است ولی خروجی واقعی منفی است. منفی‌های کاذب: مواردی که در آنها پیش‌بینی منفی است ولی خروجی واقعی مثبت است. مساحت زیر منحنی^۲ یکی از انواع پرکاربرد اندازه‌گیری برای ارزیابی است که از آن برای مسئله تقسیم‌بندی باینری استفاده می‌شود. مساحت زیر منحنی یک روش تقسیم‌بندی^۳ برابر با احتمال آن است که این روش یک مثبت رندوم را در جایگاه بالاتری از یک منفی رندوم قرار دهد. همچنین از امتیاز F1 برای محاسبه دقت یک آزمایش استفاده می‌شود. امتیاز F1 یک میانگین متوازن در بین صحت^۴ و فراخوان^۵ است. امتیاز F1 یک مقدار در بازه [۰، ۱] است. این امتیاز مشخص می‌کند که این روش تقسیم‌بندی چقدر دقیق (چه تعداد از موارد به درستی تقسیم‌بندی شده‌اند) و چقدر مقاوم است (زمانی که تعداد موارد از دست رفته چشم‌گیر نباشد). صحت بالا و فراخوان کم، نشان‌دهنده دقت بسیار آن روش است؛ اما باعث نادیده گرفته شدن تعداد زیادی از مواردی که تقسیم‌بندی آن‌ها دشوار است، می‌شود. هر چه امتیاز F1 بیشتر باشد، عملکرد مدل بهتر است [۳۷]. می‌توان به صورت ریاضی نیز بدین صورت تعریف کرد:

$$Precision = TP / (TP + FP)$$

(۵)

$$Recall = TP / (TP + FN)$$

(۶)

$$F1\ Score = (2 * precision * recall) / (precision + recall)$$

(۷)

امتیاز F1 تلاش در یافتن تعادل میان دقت و فراخوان دارد.

صحت: برابر با تعداد نتایج مثبت درست، تقسیم بر تعداد نتایج مثبت پیش‌بینی شده با استفاده از آن روش است.
فراخوان: برابر با تعداد نتایج مثبت درست، تقسیم بر تعداد تمام نمونه‌های مربوطه است (تمام نمونه‌هایی که باید مثبت در نظر گرفته می‌شدند)

¹ Confusion Matrix

² Area Under Curve (AUC)

³ Classifier

⁴ Precision

⁵ Recall

۴- نتایج بکارگیری الگوریتم‌های یادگیری ماشین

۴-۱- چارچوب بهینه‌سازی پارامتری

انتخاب پارامترهای الگوریتم یادگیری ماشین برای دستیابی به عملکرد پیش‌بینی بهینه، نیازمند بهینه‌سازی سیستماتیک است. برای الگوریتم‌های درخت تصمیم‌گیری، ابرپارامترهای حیاتی شامل حداکثر عمق درخت، حداقل نمونه در هر برگ و معیارهای تقسیم (ناخالصی جینی یا آنترپی) هستند [۳۸]. تکنیک‌های جستجوی شبکه‌ای، ارزیابی جامعی از ترکیبات ابرپارامتر ارائه می‌دهند. انتخاب ابرپارامتر ماشین بردار پشتیبان بر انتخاب نوع هسته (خطی، چندجمله‌ای، تابع پایه شعاعی)، پارامتر تنظیم (C) و پارامترهای خاص هسته تمرکز دارد. نزدیک‌ترین همسایه‌های K نیاز به بهینه‌سازی اندازه همسایگی (k)، معیارهای فاصله (اقلیدسی، منهتن، مینکوفسکی) و طرح‌های وزنی (یکنواخت یا مبتنی بر فاصله) دارند.

۴-۲- منطق انتخاب پارامتر برای کاربرد چاپ سه‌بعدی

در محیط‌های تولیدی درخت‌های تصمیم‌گیری به دلیل قابلیت تفسیر انتخاب شدند، چون درک منطق تصمیم‌گیری برای کنترل فرایند بسیار مهم است. توانایی الگوریتم در مدیریت روابط غیرخطی بدون تبدیل‌های پیچیده، آن را برای روابط پارامتر-ویژگی FDM مناسب می‌کند. ماشین‌های بردار پشتیبان در فضاهای با ابعاد بالا عالی هستند و برای مجموعه داده‌های کوچک معمول در آزمایش‌های تولیدی مؤثر هستند [۳۹]. همسایه‌های K-نزدیک‌ترین، طبقه‌بندی شهودی بر اساس معیارهای شباهت ارائه می‌دهد و زمانی که پارامترهای فرایند رفتار خوشه‌بندی محلی را نشان دهند، ارزشمند است.

۴-۳- روش‌شناسی تقسیم داده‌ها و اعتبارسنجی متقابل

دسته‌بندی مناسب داده‌ها برای ارزیابی قوی مدل ضروری است. رویکرد پیشنهادی از اعتبارسنجی متقاطع k-fold طبقه‌بندی‌شده با $k=5$ یا $k=10$ استفاده می‌کند که توزیع نماینده کلاس را در سراسر foldها تضمین می‌کند [۴۰]. داده‌های آموزشی معمولاً ۷۰ تا ۸۰ درصد از مجموعه داده‌ها را تشکیل می‌دهند که ۱۵ تا ۲۰ درصد برای اعتبارسنجی و ۱۰ درصد برای آزمایش نهایی در نظر گرفته شده است. اعتبارسنجی متقاطع سری‌های زمانی استفاده می‌شود که وابستگی‌های زمانی در داده‌ها وجود داشته باشد و ترتیب زمانی در طول تقسیم حفظ شود. برای کاربردها خواص مکانیکی قطعات FDM، نمونه‌گیری طبقه‌بندی‌شده، نمایش متعادل ترکیب پارامترهای مختلف و خواص مواد را ارائه می‌کند.

بر پایه الگوریتم‌های طبقه‌بندی توضیح داده شده، ساختار هوش مصنوعی تحلیلی ایجاد گردیده است که نتایج دقت سنجی آنان در جداول زیر آورده شده‌اند. هم چنین ماتریس‌های درهم‌ریختگی آن‌ها در ادامه ترسیم شده‌اند.

ماتریس درهم‌ریختگی برای الگوریتم طبقه بندی کننده درخت تصمیم گیری جهت پیش بینی مقاومت کششی در شکل ۴ نشان داده شده است، همانطور که در ماتریس مشخص است این الگوریتم در پیش بینی یک طبقه از جنس دسته ۰ اشتباه داشته است اما در پیش بینی هر چهار مورد دسته ۱ به درستی عمل کرده است که نشان می‌دهد این الگوریتم در پیش بینی تا حد قابل قبولی درست عمل می‌کند. ماتریس درهم‌ریختگی برای الگوریتم دستگاه بردار پشتیبان جهت پیش بینی مقاومت کششی در شکل ۴ نشان داده شده است، همانطور که در ماتریس مشخص است این الگوریتم در پیش بینی طبقه بندی‌ها دچار سه مورد اشتباه شده است که از این سه مورد یک مورد متعلق به دسته ۰ و دو مورد متعلق به دسته ۱ بوده‌اند که نشان می‌دهد این الگوریتم در پیش بینی‌های خود دچار خطاهایی بوده است که در تعداد بالا عدم دقت و اطمینان را ایجاد خواهد نمود.

ماتریس درهم‌ریختگی برای الگوریتم نزدیک‌ترین همسایه‌های k جهت پیش بینی مقاومت کششی در شکل ۴ نشان داده شده است، همانطور که در ماتریس مشخص است این الگوریتم در پیش بینی یک طبقه از جنس دسته ۰ اشتباه داشته است اما در پیش بینی هر ۵ مورد دسته ۱ به درستی عمل کرده است که نشان می‌دهد این الگوریتم در پیش بینی تا حد قابل قبولی درست عمل می‌کند اما با توجه به جدول ۶ این الگوریتم نمرات دقت سنجی به نسبت پایین تری نسبت به الگوریتم طبقه بندی کننده درخت تصمیم گیری کسب نموده است. پس می‌توان گفت که این الگوریتم دقت بالایی جهت پیش بینی مقاومت کششی مواد دارد اما نسبت به الگوریتم طبقه بندی کننده درخت تصمیم گیری کیفیت پایین تری خواهد داشت. ماتریس برای الگوریتم طبقه بندی کننده درخت تصمیم گیری

جهت پیش‌بینی مدول یانگ در شکل ۵ نشان داده شده است، همانطور که در ماتریس مشخص است این الگوریتم در پیش‌بینی‌های خود دچار سه مورد اشتباه بوده است که از این سه مورد، دو مورد متعلق به دسته ۰ و یک مورد متعلق به دسته ۱ بوده است که با توجه به دیگر نمرات این الگوریتم در جدول ۶، برخلاف اینکه بهترین الگوریتم در این زمینه شناخته شده است، نمیتوان اعتماد زیادی به آن نمود.


ماتریس برای الگوریتم دستگاه بردار پشتیبان جهت پیش‌بینی مدول یانگ در شکل ۵ نشان داده شده است، همانطور که در ماتریس مشخص است این الگوریتم در پیش‌بینی طبقه بندی‌ها دچار چهار مورد اشتباه شده است که از این چهار مورد دو مورد متعلق به دسته ۰ و دو مورد متعلق به دسته ۱ بوده‌اند که با توجه به دیگر نمرات کسب شده توسط این الگوریتم در جدول ۶، این الگوریتم در پیش‌بینی‌های خود دچار خطاهایی بوده است که عدم اطمینان زیادی را نسبت به آن ایجاد می‌کند. ماتریس درهم‌ریختگی برای الگوریتم نزدیک‌ترین همسایه‌های k جهت پیش‌بینی مقاومت کششی در شکل ۴ نشان داده شده است. همانطور که در ماتریس مشخص است این الگوریتم در پیش‌بینی‌های خود دچار چهار مورد خطا بوده است که از این چهار مورد، سه مورد متعلق به دسته ۰ و یک مورد متعلق به دسته ۱ بوده است که با توجه به دیگر نمرات کسب شده توسط این الگوریتم در جدول ۷، این الگوریتم هم نیز دقت قابل قبولی جهت پیش‌بینی مدول یانگ قطعات نخواهد داشت.

جدول ۶ تست دقت سنجی الگوریتم‌ها جهت پیش‌بینی مقاومت کششی


الگوریتم	طبقه بندی کننده درخت تصمیم گیری	SVM (مدل SVC)	KNN
معیار دقت	دقت	۷۲.۷۷	۹۰.۹
امتیاز AUC-ROC	۰.۹۲	۰.۷۳	۰.۹۱
امتیاز F1	۰.۸۸	۰.۰۷۲	۰.۹۱

جدول ۷ نتایج دقت سنجی الگوریتم‌ها جهت پیش‌بینی مدول یانگ

الگوریتم	طبقه بندی کننده درخت تصمیم گیری	SVM (مدل SVC)	KNN
معیار دقت	دقت	۷۲.۷۲	۶۳.۶۳
امتیاز AUC-ROC	۰.۷۳	۰.۶۳	۰.۶۶
امتیاز F1	۰.۷۲	۰.۶۶	۰.۶



شکل ۴ ماتریس درهم‌ریختگی برای الگوریتم طبقه‌بندی کننده (الف) درخت تصمیم‌گیری (ب) دستگاه بردار پشتیبان (ج) نزدیک‌ترین همسایه‌های k جهت پیش‌بینی مقاومت کششی



شکل ۵ ماتریس درهم‌ریختگی برای الگوریتم (الف) طبقه‌بندی کننده درخت تصمیم‌گیری (ب) دستگاه بردار پشتیبان (ج) نزدیک‌ترین همسایه‌های k جهت پیش‌بینی مدول یانگ

۴-۴- تحلیل علت و معلولی رفتار مدل یادگیری ماشین

عوامل تعیین‌کننده عملکرد مدل در کاربردهای FDM تحت تأثیر عوامل متعدد به هم پیوسته قرار دارد. کیفیت داده‌ها به عنوان عامل تعیین‌کننده اصلی عمل می‌کند، و مجموعه داده‌های ناقص، نویزدار یا اشتباه منجر به تعمیم ضعیف می‌شوند. ارتباط ویژگی‌ها به طور قابل توجهی بر رفتار مدل تأثیر می‌گذارد، جایی که ویژگی‌های نامربوط یا اضافی می‌توانند باعث بیش‌برازش و کاهش دقت پیش‌بینی شوند [۴۱].

پیچیدگی الگوریتم، بده‌بستان‌هایی بین ظرفیت مدل و توانایی تعمیم ایجاد می‌کند. درخت‌های تصمیم با عمق بیش از حد ممکن است الگوهای آموزشی را به خاطر بسپارند، در حالی که مدل‌های بیش از حد ساده‌شده ممکن است روابط پیچیده را به خوبی برازش ندهند [۴۲]. کمیت داده‌های آموزشی بطور مستقیم بر قابلیت اطمینان مدل تأثیر می‌گذارد، به طوری که نمونه‌های ناکافی منجر به واریانس بالا و تعمیم ضعیف می‌شوند.

۴-۵- اثرات هایپرپارامتر بر رفتار مدل

رفتار درخت تصمیم به این گونه است که افزایش حداکثر عمق، پیچیدگی مدل را افزایش می‌دهد اما خطر بیش‌برازش را به همراه دارد. حداقل نمونه در هر برگ، بیش‌برازش را با جلوگیری از گره‌های برگ خالص روی نمونه‌های کوچک کنترل می‌کند. معیارهای انتخاب ویژگی (چینی در مقابل آنتروپی) بر کیفیت تقسیم و ساختار درخت تأثیر می‌گذارد. با بررسی الگوهای رفتاری SVM می‌توان گفت مقادیر بالاتر C خطای آموزش را کاهش می‌دهد اما ممکن است خطر بیش‌برازش را افزایش دهد. انتخاب هسته، پیچیدگی مرز تصمیم‌گیری و الزامات محاسباتی را تعیین می‌کند. پارامترهای گاما در هسته‌های تابع پایه شعاعی، تأثیر نمونه‌های آموزشی منفرد را کنترل می‌کند [۴۳]. ویژگی‌های عملکرد K-NN نیز بدین شکل است که مقادیر پایین‌تر k پیچیدگی مدل و حساسیت به نویز را افزایش می‌دهند. معیارهای فاصله بر محاسبات شباهت و تعاریف همسایگی تأثیر می‌گذارند. همچنین نفرین ابعاد بر عملکرد در فضاهای ویژگی با ابعاد بالا تأثیر می‌گذارد [۴۴، ۴۵].

۴-۶- محدودیت‌های مدل و تحلیل دامنه

وابستگی داده‌ها یکی از محدودیت‌ها و مسائل اساسی است و مدل‌های یادگیری ماشین برای پیش‌بینی خواص FDM اساساً به دلیل کیفیت داده‌ها و نمایندگی محدود هستند. مدل‌ها نمی‌توانند فراتر از محدوده پارامترهای موجود در مجموعه داده‌های آموزشی، برون‌یابی کنند. الزامات مهندسی ویژگی: عملکرد موفق مدل به شدت به انتخاب و مهندسی ویژگی مناسب بستگی دارد. پارامترهای فرایند بحرانی ممکن است نادیده گرفته شوند و قابلیت پیش‌بینی مدل را محدود کنند. همچنین محدودیت‌های تعمیم‌پذیری وجود دارد که مدل‌های

آموزش دیده بر روی پیکربندی‌های چاپگر، مواد یا شرایط محیطی خاص ممکن است به سیستم‌های مختلف منتقل نشوند. روابط غیرخطی: تعاملات پیچیده بین پارامترهای فرایند چندگانه، چالش‌هایی را برای مدل‌های خطی ایجاد می‌کند و نیاز به الگوریتم‌های پیچیده دارد [۴۶].

محدودیت‌های دامنه در کاربردهای FDM شامل ویژگی مواد می‌شود. مدل‌های فعلی معمولاً بر روی مواد ABS، PLA با قابلیت کاربرد محدود بین مواد تمرکز می‌کنند. اکثر مطالعات مجموعه پارامترهای محدودی را بررسی می‌کنند که به طور بالقوه عوامل حیاتی مؤثر بر خواص مکانیکی را از قلم می‌اندازند. عوامل محیطی مانند دما، رطوبت و سایر شرایط محیطی اغلب از ملاحظات مدل حذف می‌شوند. با محدودیت‌های هندسی هم اعتبار مدل ممکن است به هندسه‌های خاص قطعات یا محدوده‌های اندازه محدود شود. همچنین مدل‌ها ممکن است به مرور زمان به دلیل فرسودگی چاپگر، تغییرات محیطی یا تغییرات دسته‌ای مواد، دچار افت کیفیت شوند [۴۷].

۴-۷- تحلیل آماری و پیشگیری از بیش‌برازش

تشخیص جامع بیش‌برازش با تحلیل منحنی یادگیری قابل انجام است. رسم نمودار عملکرد آموزش و اعتبارسنجی در مقابل اندازه مجموعه آموزش برای شناسایی الگوهای بیش‌برازش. بیش‌برازش به صورت افزایش شکاف عملکرد بین مجموعه داده‌های آموزش و اعتبارسنجی ظاهر می‌شود. در عملکرد اعتبارسنجی متقابل نیز تفاوت‌های معنادار بین چین‌های اعتبارسنجی متقابل، نشان‌دهنده بیش‌برازش بالقوه یا ناهمگونی داده‌ها است [۴۸]. ارزیابی پیچیدگی مدل با مقایسه عملکرد در پیچیدگی‌های مختلف مدل برای شناسایی تعادل بهینه قابل انجام است.

از جمله استراتژی‌های پیشگیری از بیش‌برازش می‌توان به تکنیک‌های منظم‌سازی اشاره کرد. منظم‌سازی L_1 و L_2 پیچیدگی مدل را جریمه می‌کند و خطر بیش‌برازش را کاهش می‌دهد. توقف زود هنگام: نظارت بر عملکرد اعتبارسنجی در طول آموزش و توقف در هنگام توقف بهبود. افزایش داده‌ها: افزایش تنوع مجموعه داده‌ها از طریق تولید نمونه مصنوعی یا اختلال پارامتر. انتخاب ویژگی: کاهش ابعاد از طریق انتخاب ویژگی آماری یا دانش دامنه. روش‌های گروهی: ترکیب چندین مدل برای کاهش بیش‌برازش و بهبود تعمیم.

در چارچوب تحلیل خطای پیشرفته ارزیابی خطای پیش‌بینی نیاز است. آزمون معناداری آماری: استفاده از آزمون‌های t یا آزمون‌های رتبه علامت‌دار ویلکاکسون برای ارزیابی معناداری خطای پیش‌بینی. بررسی باقیمانده‌های پیش‌بینی برای الگوهایی که نشان‌دهنده ناکافی بودن یا بایاس مدل هستند [۴۵، ۴۹]. با تحلیل توزیع خطا ارزیابی فرضیات نرمال بودن خطا و همگنی واریانس صورت می‌گیرد. همچنین با ساخت فاصله اطمینان روش‌های بوت‌استرپ، تولید فواصل اطمینان از طریق تکنیک‌های نمونه‌گیری مجدد برای توزیع‌های غیرپارامتری. ساخت فواصلی که هم عدم قطعیت مدل و هم تغییرپذیری ذاتی را در نظر می‌گیرند. فواصل مبتنی بر اعتبارسنجی متقابل با استخراج مرزهای اطمینان از آمار عملکرد اعتبارسنجی متقابل تعیین می‌شوند [۴۶].

۴-۸- تحلیل حساسیت و اهمیت ویژگی‌ها

ارزیابی تأثیر پارامتر با تحلیل SHAP تعیین کمیت سهم پارامترهای منفرد در پیش‌بینی‌های مدل. ارزیابی اهمیت ویژگی با اندازه‌گیری تخریب عملکرد زمانی که ویژگی‌ها به صورت تصادفی جایگشت می‌شوند. نمودارهای وابستگی جزئی تجسم اثرات حاشیه‌ای پارامترهای منفرد بر نتایج پیش‌بینی شده‌اند.

چارچوب اعتبارسنجی برای داده‌های مستقل با استراتژی اعتبارسنجی خارجی برای مجموعه‌های آزمایشی مستقل می‌توان مجموعه داده‌های کاملاً مستقل از کمپین‌های آزمایشی مختلف را برای اعتبارسنجی نهایی ذخیره کرد [۴۷]. عملکرد مدل را بر روی داده‌های آزمایشگاه‌ها یا سیستم‌های چاپگر مختلف آزمایش کرد. اعتبارسنجی زمانی و پایداری مدل را با استفاده از داده‌های جمع‌آوری شده در دوره‌های زمانی مختلف ارزیابی شود. معیارهای اعتبارسنجی آماری شامل ارزیابی دقت پیش‌بینی محاسبه RMSE، MAE و ضرایب همبستگی برای پیش‌بینی‌های استحکام کششی و مدول یانگ است [۴۸، ۴۹]. ارزیابی سوگیری با ارزیابی خطاهای پیش‌بینی سیستماتیک از طریق تحلیل خطای میانگین علامت‌دار قابل انجام است و ارائه فواصل پیش‌بینی با در نظر گرفتن عدم قطعیت‌های مدل و اندازه‌گیری برای کمی‌سازی عدم قطعیت همراه است.

۵- نتیجه‌گیری

با توجه به نتایج دقت سنجی الگوریتم‌های یادگیری ماشین جهت پیش‌بینی خواص مکانیکی قطعات پرینت سه بعدی شده می‌توان موارد زیر را نتیجه‌گیری کرد.

- از نظر دقت در جهت پیش‌بینی مقاومت کششی قطعات، الگوریتم‌های طبقه‌بندی کننده درخت تصمیم‌گیری و نزدیک‌ترین همسایه‌های k بالاترین نمره را کسب کرده‌اند؛ اما با توجه به برتری نسبی الگوریتم نزدیک‌ترین همسایه‌های k از نظر نمرات ROC_AUC و همچنین $F1$ می‌توان این الگوریتم را در این راستا مناسب‌تر دانست. با توجه به دقت بالای هر دو الگوریتم طبقه‌بندی کننده درخت تصمیم‌گیری و نزدیک‌ترین همسایه‌های k در پیش‌بینی مقاومت کششی قطعات می‌توان از هر دو مدل جهت پیش‌بینی این خاصیت استفاده نمود. حتی با توجه به دقت بالای آنها می‌توان از آنها برای شبیه‌سازی تست کشش قطعات پایه PLA بهره برد. با توجه به نتایج دقت سنجی الگوریتم‌های یادگیری ماشین در پیش‌بینی خواص مکانیکی قطعات پرینت سه بعدی شده، از نظر دقت جهت پیش‌بینی مدول یانگ قطعات، الگوریتم طبقه‌بندی کننده درخت تصمیم‌گیری با برتری در تمامی معیارها بهترین الگوریتم آزمایش شده و شناخته شده است. این الگوریتم از نظر دقت عملکرد مطلوبی داشته است؛ اما عملکرد آن به گونه‌ای نبوده که از آن به عنوان الگوریتم قدرتمند جهت پیش‌بینی مدول یانگ قطعات تولید شده نام برد. این امر می‌تواند ناشی از رابطه غیرخطی بین پارامترهای فرایند و مدول یانگ باشد که این مدل قادر به یادگیری مؤثر آن نیست لذا پیشنهاد می‌شود با بررسی دیگر تنظیمات دستگاه به منزله ورودی الگوریتم‌ها یا با تغییر دادن الگوریتم، به الگوریتم‌هایی با دقت بالاتر جهت پیش‌بینی مدول یانگ قطعات دست یافت. بدین صورت می‌توان با مدل‌های جدید، تست‌های مربوطه را مدلسازی و بررسی کرد.
- شکاف‌های تحقیقاتی بررسی شده در این مقاله شامل تنوع الگوریتم، اعتبارسنجی آماری، تعمیم‌پذیری و درک تعامل پارامتر می‌شود. مطالعات قبلی اغلب بر روی الگوریتم‌های واحد تمرکز دارند؛ این کار ارزیابی سیستماتیک چند الگوریتمی را ارائه می‌دهد. بسیاری از مطالعات موجود فاقد تحلیل آماری جامع و ارزیابی بیش‌برازش هستند. بررسی محدود چگونگی تعامل پارامترهای فرایند برای تأثیرگذاری بر خواص مکانیکی. ارزیابی ناکافی عملکرد مدل بر روی مجموعه داده‌های مستقل و شرایط عملیاتی مختلف. کمی‌سازی خطا: گزارش ناکافی از عدم قطعیت‌های پیش‌بینی و فواصل اطمینان. مقایسه چند الگوریتمی که برخلاف رویکردهای تک الگوریتمی در ادبیات موجود، این مطالعه مقایسه جامعی از درخت‌های تصمیم‌گیری، SVM و الگوریتم‌های k -NN ارائه می‌دهد. چارچوب ارزیابی یکپارچه: ترکیبی جدید از معیارهای طبقه‌بندی (دقت، $F1$ ، ROC-AUC) با معیارهای خطای رگرسیون (RMSE، MAE) برای ارزیابی جامع مدل. تحلیل علت و معلول و بررسی نظام‌مند روابط پارامتر-عملکرد از طریق تحلیل حساسیت، با پرداختن به شکاف‌های موجود در درک مکانیسمی. دقت و اعتبارسنجی آماری از طریق اعتبارسنجی متقابل، فواصل اطمینان و ارزیابی بیش‌برازش فراتر از گزارش ساده دقت.
- در نهایت می‌توان اینگونه بیان کرد که با توجه به الگوریتم منتخب، می‌توان از این مدل پرورش یافته جهت پیش‌بینی مقاومت کششی قطعات تولید شده توسط فرایند FFF با توجه به متغیرهای ورودی ضخامت لایه، سرعت ورود مواد و جهت‌گیری ساخت، استفاده نمود. این مدل به طراحان این امکان را می‌دهد که با توجه به شرایط قطعه مدنظر خود با انتخاب بهینه پارامترها به قطعات با کیفیت مناسب دست یابند. همچنین با توجه به کیفیت خوب این الگوریتم می‌توان از آن جهت تولید پایگاه داده‌های مصنوعی پرینت تحت تنظیمات متغیر این پارامترها استفاده نمود که این مسئله به محققین این حوزه، اجازه دسترسی به داده‌های آزمایش شکست بیشتری تحت شرایط آزمایشی را می‌دهد که با دقت قابل قبولی (۹۱٪) این داده‌ها موثق بوده که موجب کاهش هزینه‌های عمده در راستای کارهای پژوهشی یا تست عملکردی دستگاه‌ها خواهد شد. همچنین یافته‌های این مقاله راهکارهایی را برای بهبود فرایند طراحی مهندسی و ایجاد پایگاه‌های داده تجربی که برای سیستم‌های تولید دیجیتال ضروری هستند، ارائه می‌دهد.

تقدیر و تشکر

این پژوهش در آزمایشگاه تحقیقاتی پرینتر سه بعدی و ساخت افزودنی به کمک پژوهانه شماره ۰۳۴۵۶۲ سازمان پژوهش‌های علمی و صنعتی ایران انجام شده است. نویسندگان مراتب قدردانی صمیمانه خود را از کمک و همکاری این سازمان ابراز می‌دارند.

References

- [1] Iftekar SF, Aabid A, Amir A, Baig M. Advancements and limitations in 3D printing materials and technologies: a critical review. *Polymers*. 2023 May 30;15(11):2519. doi: 10.3390/polym15112519
- [2] Shangguan P, Zhou H, Huang X, Su J, Yeong WY, Sing SL. Artificial intelligence-driven material development for additive manufacturing: A critical review. *International Journal of AI for Materials and Design*. 2025 May 5;2(2):1-26. doi: 10.36922/IJAMD025100007
- [3] Roy A, Ahmed MJ, Mondol LC. AI-enhanced additive manufacturing: Intelligent 3D printing for complex designs. *Journal of Primeasia*. 2024 Oct 16;5(1):1-9.
- [4] Mengesha Medibew T. A Comprehensive Review on the Optimization of the Fused Deposition Modeling Process Parameter for Better Tensile Strength of PLA-Printed Parts. *Advances in Materials Science and Engineering*. 2022;2022(1):5490831. doi: 10.1155/2022/5490831
- [5] Wang L, Jiang J, Dong Y, Ghita O, Zhu Y, Sucala VI. Machine learning enabled 3D printing parameter settings for desired mechanical properties. *Virtual And Physical Prototyping*. 2024 Dec 31;19(1):e2425825. doi: 10.1080/17452759.2024.2425825
- [6] Nasrin T, Pourali M, Pourkamali-Anaraki F, Peterson AM. Active learning for prediction of tensile properties for material extrusion additive manufacturing. *Scientific reports*. 2023 Jul 15;13(1):11460. doi: 10.1038/s41598-023-38624-9
- [7] Sapkota A, Ghimire SK, Adanur S. A review on fused deposition modeling (FDM)-based additive manufacturing (AM) methods, materials and applications for flexible fabric structures. *Journal of Industrial Textiles*. 2024 Aug 28;54:15280837241282110. doi: 10.1177/15280837241282110
- [8] Özkül M, Kuncan F, Ulkir O. Predicting mechanical properties of FDM-produced parts using machine learning approaches. *Journal of Applied Polymer Science*. 2025 May 20;142(20):e56899. doi: 10.1002/app.56899
- [9] Qureshi TH, Siddiqui MA, Naqvi SD, Zeeshan M, Waseem M, Noreen Z. Machine Learning Prediction of Mechanical Properties in Reinforcement Bars: A Data-Driven Approach. *International Journal of Innovative Science and Technology*. 2024;6(2):413-25.
- [10] Chen ES, Ahmadianshalchi A, Sparks SS, Chen C, Deshwal A, Doppa JR, Qiu K. Machine Learning Enabled Design and Optimization for 3D-Printing of High-Fidelity Presurgical Organ Models. *Advanced Materials Technologies*. 2025 Jan;10(1):2400037. doi: 10.1002/admt.202400037
- [11] Boateng EY, Otoo J, Abaye DA. Basic tenets of classification algorithms K-nearest-neighbor, support vector machine, random forest and neural network: A review. *Journal of Data Analysis and Information Processing*. 2020 Sep 29;8(4):341-57. doi: 10.4236/jdaip.2020.84020
- [12] Zhang Y, Lu S, Zhou X, Yang M, Wu L, Liu B, Phillips P, Wang S. Comparison of machine learning methods for stationary wavelet entropy-based multiple sclerosis detection: decision tree, k-nearest neighbors, and support vector machine. *Simulation*. 2016 Sep;92(9):861-71.
- [13] Samal BB, Kumar A, Jena A, Mishra D, Varshney SK, Nath AK, Kumar CS. Importance of Additive Manufacturing in the Era of Industry 4.0. *4D Printing Technology: Principles, Materials and Applications*. 2025 Aug 8:1-27. doi: 10.1002/9781394213795.ch1
- [14] Greenbaum D. Digital twins: transformative technology for real-time optimization and simulation. In: De Silva S, et al., editors. *Expert Essentials*. Oxford: Oxford University Press; 2025. Chapter 35. doi: 10.1093/9780198972877.003.0035
- [15] Kartal F. Mechanical performance optimization in FFF 3D printing using Taguchi design and machine learning approach with PLA/walnut Shell composites filaments. *Journal of Vinyl and Additive Technology*. 2025 May;31(3):622-38. doi: 10.1002/vnl.22195
- [16] Patel KS, Trivedi N, Shah DB, Joshi SJ. Prediction of tensile strength using machine learning algorithms in fused deposition modeling. *Proceedings of the Institution of Mechanical Engineers, Part E: Journal of Process Mechanical Engineering*. 2024 Oct 3:09544089241286428.
- [17] Kumar M, Kumar R, Kumar R. Material extrusion-based additive manufacturing of sandwiched acrylonitrile butadiene styrene/glass fibers composites: machine learning approach to model tensile stress. *Polymer Composites*. 2024 Nov 10;45(16):15100-12.
- [18] Goh GD, Sing SL, Yeong WY. A review on machine learning in 3D printing: applications, potential, and challenges. *Artificial Intelligence Review*. 2020 Jul 16;54(1):63-94. doi: 10.1002/pc.28823
- [19] Calignano F, Manfredi D, Ambrosio EP, Biamino S, Lombardi M, Atzeni E, Salmi A, Minetola P, Iuliano L, Fino P. Overview on additive manufacturing technologies. *Proceedings of the IEEE*. 2017 Jan 2;105(4):593-612.
- [20] Dey A, Yodo N. A systematic survey of FDM process parameter optimization and their influence on part characteristics. *Journal of Manufacturing and Materials Processing*. 2019 Jul 29;3(3):64. doi: 10.3390/jmmp3030064
- [21] Crisci C, Ghattas B, Perera G. A review of supervised machine learning algorithms and their applications to ecological data. *Ecological Modelling*. 2012 Aug 10;240:113-22. doi: 10.1016/j.ecolmodel.2012.03.001

- [22] Chacón JM, Caminero MA, García-Plaza E, Núñez PJ. Additive manufacturing of PLA structures using fused deposition modelling: Effect of process parameters on mechanical properties and their optimal selection. *Materials & Design*. 2017 Jun 15;124:143-57. doi: [10.1016/j.matdes.2017.03.065](https://doi.org/10.1016/j.matdes.2017.03.065)
- [23] Molero E, Fernández JJ, Rodríguez-Alabanda O, Guerrero-Vaca G, Romero PE. Use of data mining techniques for the prediction of surface roughness of printed parts in polylactic acid (PLA) by fused deposition modeling (FDM): A practical application in frame glasses manufacturing. *Polymers*. 2020 Apr 6;12(4):840. doi: [10.3390/polym12040840](https://doi.org/10.3390/polym12040840)
- [24] Jabbari A, Abrinia K. A metal additive manufacturing method: semi-solid metal extrusion and deposition. *The International Journal of Advanced Manufacturing Technology*. 2018 Feb;94(9):3819-28. doi: [10.1007/s00170-017-1058-7](https://doi.org/10.1007/s00170-017-1058-7)
- [25] Jabbari A, Khajehhaghverdi A. Additive Manufactured Parts Specifications and Applications in Catalytic Substrates and Fuel Cells. *Hydrogen, Fuel Cell & Energy Storage*. 2023 Jun 20;10(2):173-81. doi: [10.22104/hfe.2023.6051.1257](https://doi.org/10.22104/hfe.2023.6051.1257)
- [26] Oehlmann P, Osswald P, Blanco JC, Friedrich M, Rietzel D, Witt G. Modeling fused filament fabrication using artificial neural networks. *Production Engineering*. 2021 Jun;15(3):467-78. doi: [10.1007/s11740-021-01020-y](https://doi.org/10.1007/s11740-021-01020-y)
- [27] Barrios JM, Romero PE. Decision tree methods for predicting surface roughness in fused deposition modeling parts. *Materials*. 2019 Aug 12;12(16):2574. doi: [10.3390/ma12162574](https://doi.org/10.3390/ma12162574)
- [28] Bayraktar Ö, Uzun G, Çakiroğlu R, Guldaz A. Experimental study on the 3D-printed plastic parts and predicting the mechanical properties using artificial neural networks. *Polymers for Advanced Technologies*. 2017 Aug;28(8):1044-51. doi: [10.1002/pat.3960](https://doi.org/10.1002/pat.3960)
- [29] Nasiri S, Khosravani MR. Machine learning in predicting mechanical behavior of additively manufactured parts. *Journal of materials research and technology*. 2021 Sep 1;14:1137-53. doi: [10.1016/j.jmrt.2021.07.004](https://doi.org/10.1016/j.jmrt.2021.07.004)
- [30] Zhang Z, Femi-Oyetero J, Fidan I, Ismail M, Allen M. Prediction of dimensional changes of low-cost metal material extrusion fabricated parts using machine learning techniques. *Metals*. 2021 Apr 23;11(5):690. doi: [10.3390/met11050690](https://doi.org/10.3390/met11050690)
- [31] Asadi-Eydivand M, Solati-Hashjin M, Fathi A, Padashi M, Osman NA. Optimal design of a 3D-printed scaffold using intelligent evolutionary algorithms. *Applied Soft Computing*. 2016 Feb 1;39:36-47. doi: [10.1016/j.asoc.2015.11.011](https://doi.org/10.1016/j.asoc.2015.11.011)
- [32] Bacha A, Sabry AH, Benhra J. Fault Diagnosis in the Field of Additive Manufacturing (3D Printing) Using Bayesian Networks. *Int. J. Online Biomed. Eng.*. 2019 Mar 1;15(3):110-23.
- [33] Bin Maidin S, Campbell I, Pei E. Development of a design feature database to support design for additive manufacturing. *Assembly Automation*. 2012 Jul 27;32(3):235-44. doi: [10.1108/01445151211244375](https://doi.org/10.1108/01445151211244375)
- [34] Chen H, Zhao YF. Learning algorithm based modeling and process parameters recommendation system for binder jetting additive manufacturing process. In *International Design Engineering Technical Conferences and Computers and Information in Engineering Conference 2015 Aug 2 (Vol. 57045, p. V01AT02A029)*. American Society of Mechanical Engineers. doi: [10.1115/DETC2015-47627](https://doi.org/10.1115/DETC2015-47627)
- [35] Deng L, Feng B, Zhang Y. An optimization method for multi-objective and multi-factor designing of a ceramic slurry: Combining orthogonal experimental design with artificial neural networks. *Ceramics International*. 2018 Sep 1;44(13):15918-23. doi: [10.1016/j.ceramint.2018.06.010](https://doi.org/10.1016/j.ceramint.2018.06.010)
- [36] Francis J, Bian L. Deep learning for distortion prediction in laser-based additive manufacturing using big data. *Manufacturing Letters*. 2019 Apr 1;20:10-4. doi: [10.1016/j.mfglet.2019.02.001](https://doi.org/10.1016/j.mfglet.2019.02.001)
- [37] Muthu SS, Savalani MM, editors. *Handbook of sustainability in additive manufacturing*. Singapore: Springer; 2016.
- [38] Gobert C, Reutzel EW, Petrich J, Nassar AR, Phoha S. Application of supervised machine learning for defect detection during metallic powder bed fusion additive manufacturing using high resolution imaging. *Additive Manufacturing*. 2018 May 1;21:517-28. doi: [10.1016/j.addma.2018.04.005](https://doi.org/10.1016/j.addma.2018.04.005)
- [39] Huff TJ, Ludwig PE, Zuniga JM. The potential for machine learning algorithms to improve and reduce the cost of 3-dimensional printing for surgical planning. *Expert review of medical devices*. 2018 May 4;15(5):349-56.
- [40] Jiang Z, Liu Y, Chen H, Hu Q. Optimization of Process Parameters for Biological 3D Printing Forming Based on BP Neural Network and Genetic Algorithm. In *CE 2014 Sep 23 (pp. 351-358)*.
- [41] Jabbari A, Abrinia K. Preparing a Solid Filament for Use in Additive Manufacturing of Metals: Jabbari and Abrinia. *JoM*. 2019 Mar 15;71(3):1088-94. doi: [10.1007/s11837-018-3282-5](https://doi.org/10.1007/s11837-018-3282-5)
- [42] Jabbari A, Abrinia K. Developing thixo-extrusion process for additive manufacturing of metals in semi-solid state. *Journal of Manufacturing Processes*. 2018 Oct 1;35:664-71. doi: [10.1016/j.jmapro.2018.08.031](https://doi.org/10.1016/j.jmapro.2018.08.031)
- [43] Jabbari A, Abrinia K, inventors. Additive manufacturing apparatus using a semi-solid extrusion of wire. United States patent application US 15/898,836. 2018 Oct 11.

- [44] Khadilkar A, Wang J, Rai R. Deep learning-based stress prediction for bottom-up SLA 3D printing process. The International Journal of Advanced Manufacturing Technology. 2019 Jun 19;102(5):2555-69. doi: [10.1007/s00170-019-03363-4](https://doi.org/10.1007/s00170-019-03363-4)
- [45] Li Z, Zhang Z, Shi J, Wu D. Prediction of surface roughness in extrusion-based additive manufacturing with machine learning. Robotics and Computer-Integrated Manufacturing. 2019 Jun 1;57:488-95. doi: [10.1016/j.rcim.2019.01.004](https://doi.org/10.1016/j.rcim.2019.01.004)
- [46] Tan K. The framework of combining artificial intelligence and construction 3D printing in civil engineering. InMATEC web of conferences 2018 (Vol. 206, p. 01008). EDP Sciences.
- [47] Nagarajan HP, Mokhtarian H, Jafarian H, Dimassi S, Bakrani-Balani S, Hamed A, Coatanea E, Gary Wang G, Haapala KR. Knowledge-based design of artificial neural network topology for additive manufacturing process modeling: A new approach and case study for fused deposition modeling. Journal of Mechanical Design. 2019 Feb 1;141(2):021705. doi: [10.1115/1.4042084](https://doi.org/10.1115/1.4042084)
- [48] Qi X, Chen G, Li Y, Cheng X, Li C. Applying neural-network-based machine learning to additive manufacturing: current applications, challenges, and future perspectives. Engineering. 2019 Aug 1;5(4):721-9. doi: [10.1016/j.eng.2019.04.012](https://doi.org/10.1016/j.eng.2019.04.012)
- [49] Rong-Ji W, Xin-Hua L, Qing-Ding W, Lingling W. Optimizing process parameters for selective laser sintering based on neural network and genetic algorithm. The International Journal of Advanced Manufacturing Technology. 2009 Jun;42(11):1035-42. doi: [10.1007/s00170-008-1669-0](https://doi.org/10.1007/s00170-008-1669-0)