

واژه‌های کلیدی:

هوش مصنوعی (AI)،
پلیمر،
اختلاط،
اکسترودر،
لاستیک،
کامپوزیت

فرایندهای پلیمری در پرتو هوش مصنوعی

زینب سادات حسینی*

تهران، دانشگاه تربیت مدرس، دانشکده مهندسی شیمی، گروه فرایندهای پلیمریزاسیون

چکیده ...

هوش مصنوعی (AI) (Artificial Intelligence) با ورود به زمینه‌های مختلف، در حال متحول کردن زندگی روزمره بشر در کره خاکی است. این ابزار پنجره جدیدی را بر روی فعالان در زمینه علوم و مهندسی پلیمر مانند سایر علوم گشوده است و قادر است به‌طور گسترده در ساخت پلیمرها و مشتقات آن‌ها، فرایندهای اختلاط، شکل‌دهی پلیمرها، کامپوزیت‌ها و طراحی و ساخت تجهیزات مربوط استفاده شود. الگوریتم‌های هوش مصنوعی می‌توانند تجزیه و تحلیل حجم وسیع و نامحدودی از داده‌های اخذ شده از حسگرها و سامانه‌های نظارت بر فرایند را میسر سازند. این الگوها و روندها، توانایی پردازش مواردی که تشخیص دستی آن‌ها دشوار یا ناممکن است، فراهم کرده‌اند و در مدل‌سازی و شبیه‌سازی، کنترل فرایند، تشخیص خطا و سامانه‌های توصیه‌کننده، کاربرد دارند و می‌تواند برای حصول اختلاط بهینه با عنایت به خواص اجزای مخلوط و مشخصات فنی محصول مورد نظر، توصیه‌هایی ارائه دهد. هوش مصنوعی می‌تواند عوامل فرایندی را برای اطمینان از سازگاری و پراکندگی یکنواخت افزودنی‌ها، پرکننده‌ها و رنگ‌ها که منجر به مخلوطی با کیفیت بالاتر و محصولات با خواص بهینه می‌شود، کنترل کند. همچنین می‌تواند به کاهش زمان چرخه، بدون به خطر انداختن کیفیت محصول کمک کند که می‌تواند منجر به صرفه‌جویی قابل توجهی در هزینه و بهره‌وری بیشتر شود و می‌تواند امکان تعمیر و نگهداری پیشگیرانه را فراهم کند. در این مطالعه به کاربرد هوش مصنوعی در برخی از فرایندهای پلیمری به‌طور خاص در آمیزه‌سازی لاستیک، تهیه کامپوزیت و اکستروژن اشاره می‌شود که نویدبخش مسیر جدیدی در فرایندهای پلیمری است.

*پست الکترونیکی مسئول مکاتبات:

zeinabsadat_hosseini@modares.ac.ir

۱ معرفی

بیل گیتس: «قدرت هوش مصنوعی باورنکردنی است و جامعه را به روش‌های بسیار متفاوت تغییر خواهد داد.»

هوش مصنوعی علمی میان‌رشته‌ای است که به سرعت در حال توسعه است و محبوبیت زیادی پیدا کرده، نویدبخش پیشرفت‌های سریع و قابل توجه در صنایع مختلف است، در جدول ۱ به برخی از مزایا و معایب استفاده از هوش مصنوعی اشاره شده است. این فناوری قدرتمند و پیچیده جمع‌آوری و تحلیل داده‌ها منجر به آفرینش مواد و فرایندهای تولید هوشمند شده است. ادغام هوش مصنوعی (AI) با فرایندهای رایج، آن‌ها را قادر ساخته تا بر کاستی‌ها در بخش‌های مختلف مانند ذخیره‌سازی انرژی، ساخت‌وساز، زیست‌پزشکی، هوافضا، چاپ‌سه‌بعدی و غیره به‌طور موثر غلبه کند [۱]. در این مطالعه، پیشرفت‌های اخیر در فرایندهای پلیمری به‌کمک هوش مصنوعی به‌ویژه در آمیزه‌های لاستیکی و کامپوزیت‌ها و اکستروژن ارائه می‌شود. چالش‌های فعلی و چشم‌اندازهای آینده این هوشمندسازی نیز مورد بحث قرار می‌گیرد.

۲ هوش مصنوعی، یادگیری ماشین (Machine Learning) (ML) و دسته‌بندی کلی آن‌ها

هوش مصنوعی (AI) را می‌توان به عنوان مجموعه‌ای از روش‌ها تعریف کرد که امکان بازتولید رفتار انسان را به‌منظور حل مسائل با پیچیدگی زیاد، مانند تشخیص گفتار، ترجمه زبانی و تحلیل تصویر، فراهم می‌کند. ML زیرمجموعه هوش مصنوعی است و به مجموعه‌ای از الگوریتم‌ها اشاره دارد که عملکرد آن‌ها، موجب بهبود فزاینده مسئله‌ای معین، با بررسی و تحلیل داده‌های مرتبط می‌شود، به عبارت دیگر، برنامه‌ای رایانه‌ای است که از تجربه یاد می‌گیرد و برای بهبود خویش به کار می‌برد [۲]. با توجه به مجموعه داده‌هایی که کاربر به الگوریتم ارائه می‌دهد، الگوریتم به‌تنهایی، بدون برنامه‌ریزی صریح توسط کاربر، روابط و الگوهای ریاضی‌نمایی را بین داده‌ها شناسایی می‌کند. محبوبیت بزرگ فعلی

جدول ۱ مزایا و معایب هوش مصنوعی در ساخت.

مزایا	معایب
ویژگی‌های تحلیلی پیشرفته و هوشمند	هزینه بالا
ظرفیت کاری بالا	ترس از جایگزینی شغل
ظرفیت تصمیم‌گیری سریع	فقدان راهبرد مشخص برای تولید
در دسترس بودن	بیکاری
ظرفیت بهینه‌سازی بالا	شانس کمتر برای خلاقیت

هوش مصنوعی و ML عمدتاً ناشی از دسترسی آسان به حجم زیادی از داده‌ها، همراه با پیشرفت‌های عمده در سامانه‌های محاسباتی نوین است که هر روز قدرتمندتر و مقرون به صرفه‌تر می‌شوند. علاوه بر این، روش‌های ML ظرفیت امیدوارکننده‌ای را در مقابله با مسائل پیچیده در زمینه‌های مختلف (مانند رباتیک، رایانه و پردازش زبان) و همچنین در مهندسی شیمی، فرایندهای پلیمری و مهندسی محصولات شیمیایی (CPE) (Chemical Product Engineering) مانند کشف روش‌های جدید برای طراحی مولکول‌هایی با ویژگی‌های عملکردی هدفمند یا بهینه‌سازی شرایط فرایند برای به‌دست‌آوردن خواص ویژه نشان داده‌اند [۳،۴].

CPE به حوزه علمی اطلاق می‌شود که فرایندهای مختلف و رویکردهای روش‌شناختی را با هدف بسط محصولات یا مواد با ویژگی‌های سفارشی مشخص شده مورد مطالعه قرار می‌دهد. به‌طور خاص، در این محصولات با برهم‌کنش قوی بین عوامل فرایندی، ویژگی‌های مواد تشکیل‌دهنده و خواص و ساختار محصول نهایی مشخص می‌شوند. چالش‌های متعددی در ارتباط با مدل‌سازی این محصولات و سامانه‌ها وجود دارد که بیشتر به ماهیت چندعاملی و پیچیده آن‌ها مربوط می‌شود. در واقع، چنین محصولاتی مانند آمیزه‌های لاستیکی، اغلب چند منظوره و/یا چند عنصری هستند و نیاز خاصی به کنترل چندین عامل و ویژگی مصرف نهایی دارند. با توجه به پیچیدگی‌های مدل‌سازی پدیدارشناختی و از طرفی اهمیت ضرورت درک ارتباط بین فرایندها، مواد تشکیل‌دهنده و ساختار و خواص محصول، همچنین چالش‌های مهم برای توسعه تولیدات جدید صنعتی، طراحی مواد و محصولات در محیط رقابتی با عنایت به تقاضاهای متنوع و روزافزون بازار، باعث علاقه فزاینده به کاربرد روش‌های ML برای مهندسی محصولات شیمیایی شده است. این روش‌ها به‌طور خاص با افزایش پیچیدگی‌های سامانه‌های هدف سازگار هستند. تعدادی از مطالعات درباره کاربردهای ML در حوزه‌های مختلف مهندسی شیمی و پلیمر در جدول ۲ ارائه شده است. حوزه CPE در ۲۰ سال گذشته بر این اساس، توجه ویژه‌ای به طراحی و کشف مولکول‌ها و مواد جدید، مدل‌سازی رابطه بین فرایند و ساختار یا خواص محصول، پیش‌بینی واکنش‌های شیمیایی از طریق ML داشته است.

۲-۱ دسته‌بندی الگوریتم‌های ML

الگوریتم‌های ML معمولاً به چهار دسته یادگیری مختلف، یعنی یادگیری تحت نظارت (Supervised Learning)، یادگیری بدون نظارت (Unsupervised Learning)، یادگیری نیمه (شبه)

جدول ۲ کاربردهای ML در حوزه‌های مختلف مهندسی شیمی و پلیمر.

موضوع	حوزه
[۹]-[۲]	علم مولکولی و مواد
[۱۲]-[۱۰]	طراحی و کشف دارو
[۱۵]-[۱۳]	کاتالیزور
[۱۶، ۱۷]	سنتر شیمیایی
[۱۸، ۱۹]	مهندسی شیمی و فرایندهای پلیمری

۲-۱-۱ یادگیری تحت نظارت

این روش یادگیری که «نظارت‌شده» نامیده می‌شود، مانند ارجاع به معلمی است که با در نظر گرفتن عوامل مختلف (معروف به ویژگی‌ها) مسئله، پاسخ صحیح را برای آن مسئله معین به دانش‌آموز می‌آموزد تا هنگامی که دانش‌آموز با مجموعه‌ای از ویژگی‌های جدید، اما مشابه، دوباره با مسئله روبرو شد، بتواند براساس مثال‌هایی که از معلم آموخته، پاسخ درست را حدس بزند. با این حال، اگر مجموعه ویژگی‌های جدید بسیار متفاوت از نمونه‌های مثال معلم باشد، پاسخ دانش‌آموز به احتمال زیاد اشتباه است [۱۶].

۲-۱-۲ یادگیری بدون نظارت

همان‌طور که از نام آن پیداست، یادگیری در اینجا «بدون نظارت» است، به این معنی که معلم به دانش‌آموز آموزش نمی‌دهد که پاسخ مناسب برای مجموعه‌های مختلف ویژگی‌های یک مسئله معین چیست. در عوض، دانش‌آموز ویژگی‌ها را با هم مقایسه می‌کند و تلاش می‌کند تا مشخص کند که آیا شباهت‌هایی دارند یا خیر. بر این اساس، در یادگیری بدون نظارت، مجموعه داده از N مثال بدون برچسب $\{(x_i)\}_{i=1..N}$ تشکیل شده است، که

نظارتی (Semi-supervised Learning) و یادگیری تقویتی (Reinforcement Learning) طبقه‌بندی می‌شوند [۱۶، ۲۰]. این دسته‌ها برحسب پیکر بندی مجموعه داده‌ها تعریف می‌شوند که براساس آن، الگوریتم ML تلاش می‌کند تا روابط ریاضی را در قالب مدل شناسایی کند، تا قادر به حل مسئله شود. انواع مختلفی از مسائل را می‌توان در دسته‌های مختلف یادگیری بررسی کرد. این موارد به اختصار در جدول ۳ آورده شده، که در ادامه این بخش به تفصیل توضیح داده خواهد شد [۴].

جدول ۳ مقایسه دسته‌های مختلف ML.


پیکربندی مجموعه داده‌ها	هدف	مثال‌های در مهندسی محصولات و نمونه‌هایی از الگوریتم‌ها
داده‌های برچسب گذاری شده تحت نظارت $\{(x_i, y_i)\}_{i=1..N}$	الگوریتم رابطه بین ورودی X و خروجی Y را توصیف می‌کند	• مشکل رگرسیون (خروجی پیوسته): پیش‌بینی گرانشی آب در روغن با توجه به دما، کسر حجمی فاز پراکنده، نرخ برش و خواص روغن [۲۱] (LSSVM*) ANN ^{2*} , SVM ^{3*} /SVR ^{4*} , GP ^{5*} , DT ^{6*} , RF ^{7*} , kNN ^{8*} , MR ^{9*}
داده‌های بدون برچسب بدون نظارت $\{(x_i)\}_{i=1..N}$	الگوریتم الگوهای پنهان در ویژگی‌های ورودی X را بررسی و استخراج می‌کند	• مشکل کاهش ابعاد: فشرده‌سازی ابعاد داده‌های فرایند برای پرداختن به روابط بین متغیرهای مختلف و کاهش هزینه محاسباتی در طول پیش‌بینی شاخص مذاب پلی‌پروپیلن با استفاده از GP (PCA) [۲۲] PCA ^{10*} , k-means clustering, ANN ^{2*} , HCA ^{11*} , AE ^{12*} , ICA ^{13*} , GMM ^{14*}
تعداد کمی از داده‌های برچسب‌دار با مقدار زیادی داده بدون برچسب نیمه‌نظارت شده	این الگوریتم اطلاعات پنهان در داده‌های بدون برچسب را به منظور بهبود عملکرد پیش‌بینی مدل یادگیری نظارت شده با داده‌های برچسب‌دار بررسی می‌کند.	• پیش‌بینی برخط گرانشی مونی در مخلوط کن‌های لاستیکی صنعتی [۲۳] • پیش‌بینی هدایت حرارتی کامپوزیت‌های پلیمری پر شده [۲۴] ANN مدل‌های مولد، روش‌های مبتنی بر نمودار، آموزش مشترک، خودآموزی
تقویت داده‌های ورودی حالت‌ها و علائم بازخورد محیط هستند.	الگوریتم روش بهینه را می‌آموزد و بهترین اقدامی را که باید با توجه به وضعیت محیط اجرا شود، انتخاب می‌کند	کنترل فرایندهای پلیمری شدن [۲۶، ۲۵]. برنامه‌نویسی دینامیک، روش‌های مونت کارلو

LSSVM (Least Squares Support Vector Machine), ^{2}ANN (Artificial Neural Network), ^{3*}SVM (Support Vector Machine), ^{4*}SVR (Support Vector Regression), ^{5*}GP (Gaussian Process), ^{6*}DT (Decision Tree), ^{7*}RF (Random Forest), ^{8*}kNN (k-Nearest Neighbors), ^{9*}MR (Multivariate Regression), ^{10*}PCA (Principal Component Analysis), ^{11*}HCA (Hierarchical Clustering Analysis), ^{12*}AE (Auto Encoders), ^{13*}ICA (Independent Clustering Analysis), ^{14*}GMM (Gaussian Mixture Model)

دانش قبلی توصیف می‌کند و به این ترتیب، ظرفیت پیش‌بینی قابل توجهی در حوزه بسیار وسیعی از کاربردها را دارد. از جنبه منفی، آن‌ها نیازمند رویکرد توسعه‌ای نسبتاً پر زحمت هستند و ممکن است به دشواری حل شوند، به‌ویژه هنگامی که برای توصیف سامانه‌های پیچیده، پیاده‌سازی می‌شوند. از سوی دیگر، مدل‌های مبتنی بر داده، در تلاش برای ایجاد ارتباط بین برخی ورودی‌ها (ها) و پاسخ‌ها (های) منتخب سامانه، بر اساس داده‌های موجود است. شکل معادلات می‌تواند هر عبارت ریاضی باشد که ممکن است معنای فیزیکی نداشته باشند. به این ترتیب، آن‌ها معمولاً بسیار سریع توسعه می‌یابند، با این حال، دارای برون‌یابی محدود هستند و درک ضعیفی از سازوکارها دارند. بر این اساس، رویکردهای مدل‌سازی ترکیبی، با ادغام ویژگی‌های مبتنی بر دانش و داده‌محور، محبوبیت فزاینده‌ای را در حل مسائل به‌دست آورده است، کاربردهای متعددی از آن در صنایع غذایی، صنایع داروسازی، طراحی محصولات آرایشی، طراحی و کشف کاتالیزورها و پیش‌بینی واکنش و فرایندهای پلیمری گزارش شده است. از مدل‌های ترکیبی برای غلبه بر مسائل طراحی پیچیده و چندبعدی که در آن عوامل موادی و فرایندی به شدت تأثیرگذار است و به طراحی هم‌زمان مواد و فرایند نیاز دارند، استفاده می‌شود [۳۱،۳۲].

۳-۲ مروری بر روش‌های ML در فرایندهای پلیمری و مهندسی شیمی

در این بخش نمایی کلی از روش‌های ML که در مسائل CPE اجرا شده‌است، ارائه می‌شود. پس از تشریح تصویر کلی، در حوزه موضوعی CPE به تعدادی از حوزه‌های کاربردی و مطالعات اخیر در فرایندهای پلیمری پرداخته می‌شود. به طور کلی، در حوزه‌های کاربردی CPE استفاده از هوش مصنوعی، روش‌های یادگیری نظارت‌شده ۶۹ درصد را اشغال کرده است (شکل ۱) و روش‌های بدون نظارت و ترکیبی به ترتیب ۱۱، ۱۰ درصد از مطالعات را به خود اختصاص داده‌اند.



شکل ۱ توزیع دسته‌های مختلف ML در کاربردهای CPE.

در آن xi بردار ورودی مثال i را نشان می‌دهد. الگوریتم از این بردارهای ورودی برای ساخت مدلی استفاده می‌کند که الگوهای پنهان درون ویژگی‌ها را کشف و استنتاج می‌کند [۲۲،۲۷].

۲-۱-۲ یادگیری نیمه‌نظارتی


در یادگیری نیمه‌نظارتی، مجموعه داده‌ها عموماً از مقدار کمی از داده‌های برچسب‌دار و اکثریت داده‌های بدون برچسب تشکیل شده است. هدف با یادگیری نظارت‌شده یکسان است، اما علاوه بر این، ایده در اینجا کاوش اطلاعات پنهان در مقادیر زیادی از داده‌های بدون برچسب به منظور بهبود عملکرد پیش‌بینی مدل یادگیری نظارت‌شده با داده‌های برچسب‌دار است. فرض این است که بزرگ‌تر شدن مجموعه داده‌ها که با افزودن مثال‌های بدون برچسب به دست می‌آید، منجر به نمایش دقیق‌تری از توزیع احتمالی می‌شود که داده‌های برچسب‌گذاری شده از آن به دست آمده‌اند [۲۰].

۲-۱-۲ یادگیری تقویتی


در یادگیری تقویتی، هدف آموزش یک عامل برای یادگیری روشی بهینه است که با توجه به وضعیت محیط یا سامانه، بهترین اقدام را برای اجرا انتخاب می‌کند. برای انجام این کار، عامل با اجرای کنش‌ها، برای حالات مختلف محیط و بازانتخاب رفتار خود با توجه به بازخورد مثبت یا منفی که پس از هر عمل دریافت خواهد کرد، به صورت پویا با محیط خود تعامل دارد. بنابراین وضعیت محیط و علایم مثبت یا منفی را می‌توان ورودی‌های این روش یادگیری و عمل را خروجی آن دانست. روش بهینه زمانی به دست می‌آید که اقدامات، پاسخ مثبت را به حداکثر برسانند [۲۵،۲۸،۲۹].

۲-۲ رویکردهای ترکیبی (هیبریدی)

پیچیدگی‌های ریاضی رایجی که عمدتاً در مسائل CPE با آن مواجه می‌شوند، عبارتند از: غیرخطی بودن، سامانه‌های بزرگ و چندبعدی و عدم قطعیت‌ها [۳۰]. علاوه بر این، زمانی که دانش کافی در مورد قوانین فیزیکی و شیمیایی حاکم بر سامانه وجود نداشته باشد، توسعه مدل‌های فیزیکی-شیمیایی خالص (یعنی مبتنی بر دانش) برای حل این مسائل بسیار دشوار و زمان‌بر است. در این موارد، مدل‌های ترکیبی می‌توانند راه‌حل جالبی را ارائه دهند. رویکرد ترکیبی مدل‌سازی برای توصیف ترکیب مدل‌های مبتنی بر داده با مدل‌های مبتنی بر دانش، در تلاش برای بهره‌برداری از ویژگی مثبت هر دو نوع مدل استفاده می‌شود. به طور کلی، مدل‌های مبتنی بر دانش، پدیده‌های زیربنایی فرایند را بر اساس



شکل ۴ توزیع الگوریتم‌های ML با رویکرد مدل‌سازی ترکیبی در کاربردهای CPE.



شکل ۲ توزیع الگوریتم‌های یادگیری تحت نظارت در کاربردهای CPE.

می‌توانند عوامل اختلاط را در محدوده‌های از پیش تعریف شده، کنترل و تنظیم کنند.


۳- تشخیص خطا: هوش مصنوعی می‌تواند داده‌های حسگر را برای شناسایی و تشخیص عیوب یا ناهنجاری‌ها در تجهیزات حین فرایند اختلاط، تجزیه و تحلیل کند و امکان تعمیر به موقع و جلوگیری از خرابی را فراهم آورد.

۴- سامانه‌های توصیه‌کننده: هوش مصنوعی می‌تواند توصیه‌هایی برای اختلاط بهینه بر اساس خواص پلیمر مخلوط شده و مشخصات فنی محصول موردنظر، ارائه دهد.

برخی از کاربردهای ML در فرایندهای اختلاط پلیمرها در جدول ۴ آمده است.

۴ اکستروژن

اکستروژن تک‌پیچ یکی از مهم‌ترین روش‌های فراورش گرمانرم‌هاست که امکان تولید محصولات متنوعی از جمله لوله، پروفایل، فیلم و الیاف را فراهم کرده است. این فرایند چندین مرحله را طی می‌کند: نرم و ذوب کردن پلیمرهای گرمانرم، شکل‌دهی و عملیات جانبی که به نوع محصولی که باید تولید شود بستگی دارد. نرم و ذوب کردن مهم‌ترین مرحله است، زیرا امکان انتقال پلیمر جامد، ذوب شدن و مخلوط شدن با افزودنی‌ها و ایجاد فشار مورد نیاز برای عبور از حدیده را برای شکل‌گیری



شکل ۵ (الف) توزیع حوزه‌های کاربرد CPE فقط در یادگیری تحت نظارت (ب) در همه دسته‌های ML.


در عین حال، اجرای روش‌های یادگیری نیمه‌نظارتی (۲ درصد) و روش‌های یادگیری تقویتی (کمتر از ۱ درصد) تاکنون در این کاربردها استفاده شده است. علاقه به روش‌های نیمه‌نظارت شده کاملاً جدید به نظر می‌رسد ولی روند روبه‌افزایشی دارد، که نشان می‌دهد این دسته از روش‌های ML ممکن است برای حل مسائل در حوزه‌های مهم‌تر استفاده شود. شکل‌های ۲ تا ۴ به ترتیب توزیع الگوریتم‌های نظارت شده، بدون نظارت و ترکیبی را در کاربردهای CPE توصیف می‌کنند. شکل ۵ نشان می‌دهد که روش‌های ML در چه حوزه‌هایی بیشترین استفاده را دارند. با در نظر گرفتن همه دسته‌های ML، بخش‌های عمده عبارتند از: علم مواد (۲۶٪)، صنایع غذایی (۲۳٪)، فرایندهای شیمیایی و پلیمری (۱۷٪) و علوم مولکولی (۱۵٪) [۴].

۳ کاربردهای هوش مصنوعی در فرایندهای پلیمری:

به طور کلی استفاده از ML و هوش مصنوعی کاربردهای مختلفی از جمله در اختلاط پلیمرها دارد که شامل:

۱- مدل‌سازی و شبیه‌سازی: هوش مصنوعی می‌تواند برای توسعه مدل‌های پیچیده اختلاط پلیمرها با توجه به عوامل فرایندی استفاده شود و امکان پیش‌بینی رفتار اختلاط و بهینه‌سازی آن را فراهم کند.

۲- کنترل فرایند: کنترل‌کننده‌های مجهز به هوش مصنوعی



شکل ۳ توزیع الگوریتم‌های یادگیری بدون نظارت در کاربردهای CPE.

جدول ۴ کاربردهای ML در مدل‌سازی عوامل فرایندی [۳۳].

ورودی ها	الگوریتم ML	خروجی ها
زمان ماند، دمای کوره، کشش اعمال شده بر روی رشته‌ها	ANN ^{1*}	بازده، خواص نهایی الیاف کربن
فشار/دما راکتور، سطح مایع و دبی کاتالیزور	DBN ^{2*}	شاخص مذاب
عوامل فرایندی	ANN	تبدیل مونومر، میانگین وزن مولکولی و گرانشی، زمان واکنش، پراکندگی و پایداری حرارتی
دما، نرخ خوراک دهی، زمان واکنش و مقدار کاتالیزور	SVM ^{3*}	گرانشی
سرعت تزریق / فشار، مدت اعمال فشار، دمای قالب، زمان خنک کننده، مقدار تزریق، سرعت چرخش پیچ، فشار بدنه، دمای بدنه، دمای مایع خنک کننده و دقت اندازه‌گیری حسگر	ANN، SVR ^{4*} ، GP ^{5*}	کیفیت محصول (تغییر شکل، عیوب)، حالت مذاب، عوامل فرایندی، توزیع جهت الیاف، خواص فیزیکی / مکانیکی، زبری سطح
غلظت هیدروژن، سرعت خوراک دهی و دمای واکنش	PCA ^{6*} + GP	شرایط فرایند و کیفیت محصول
دما و ترکیب خاک رس	ANN	خواص مکانیکی دینامیکی (مدول ذخیره و مدول اتلاف)
عوامل فرایندی (موقعیت، زاویه انقباض، عرض کانال، جریان پلیمر و حلال)	GP	مشخصه‌های محصول (طول متوسط، قطر متوسط و کیفیت الیاف)
عوامل موادی و فرایندی (سرعت چرخش، سرعت جریان خروجی، دما و ترکیبات)	ANN، C2V ^{7*} ، sPGD ^{8*} ، SVM، DT و iDMD ^{9*}	خواص و عملکرد (مدول یانگ، تنش تسلیم، تنش هنگام شکست، کرنش در شکست و قدرت ضربه)
شرایط واکنش (غلظت آغازگر، دما و زمان)	LMNNR ^{10*} ، نزدیک‌ترین همسایه، رگرسیون با معیارهای تطبیقی	تبدیل مونومر و وزن مولکولی متوسط
شرایط واکنش (غلظت آغازگر، دما و زمان)	ترکیبی: مبتنی بر دانش و ANN	تبدیل مونومر و وزن مولکولی متوسط
شرایط واکنش (غلظت آغازگر و دما)	ANN	تبدیل مونومر، وزن مولکولی متوسط و گرانشی جرمی واکنش

^{1*}ANN (Artificial Neural Network), ^{2*}DBN (Deep Belief Network), ^{3*}SVM (Support Vector Machine), ^{4*}SVR (Support Vector Regression), ^{5*}GP (Gaussian Process), ^{6*}PCA (Principal Component Analysis), ^{7*}C2V (Code2Vect), ^{8*}sPGD (sparse Proper Generalized Decomposition), ^{9*}iDMD (inspired by Dynamic Model Decomposition), ^{10*}LMNNR (Large Margin Nearest Neighbor for Regression)

به‌دست آمدن نتایج تجربی، برخی از روش‌های تحلیل داده‌ها یا رگرسیون به‌کار می‌روند. برای داشتن نمایش خوبی از واقعیت، تعداد آزمایش‌هایی که باید انجام شوند به میزان قابل توجهی با تعداد متغیرهای تصمیم‌گیری مورد نیاز افزایش می‌یابد و باید از روش‌های خاصی برای در نظر گرفتن اهداف متعدد استفاده شود. با توسعه نرم‌افزارهای مدل‌سازی عددی، محاسبات رایانه‌ای جایگزین آزمایش‌ها شده است که امکان طراحی و بهینه‌سازی سریع و کم هزینه را فراهم می‌کند. با این حال، مانند بسیاری از مسائل بهینه‌سازی واقعی، اکستروژن نرم و ذوب‌سازی پلیمرها مساله‌ای دشوار برای حل است، که شامل متغیرهای گسسته و پیوسته، تعداد زیادی متغیر تصمیم‌گیری و محدودیت‌ها و اهداف متعدد است. اکستروژن در معرض محیط قرار می‌گیرد، به‌این معنی که در معرض برخی عدم قطعیت‌های مهم است، مانند دمای محیط که بر دمای بدنه و در نتیجه، ذوب

نهایی فراهم می‌کند. اکستروژن فرایندی پیچیده است که در آن مواد خام، به شکل گرانول یا پودر، وارد اکستروژن می‌شود و در آنجا در اثر گرمای هدایت‌شده از بدنه و گرمای تولیدشده توسط اصطکاک و اتلاف ویسکوز، نرم و ذوب می‌شود. جریان پلیمر در حالت‌های فیزیکی مختلف جامد، مذاب و هم‌زیستی هر دو است. همچنین، این ماده دارای خواص بسیار خاصی مانند هدایت حرارتی کم، رفتار غیرنیوتنی و هندسه‌ای پیچیده است [۳۴، ۳۵].

مهندسی پلیمر، مانند سایر رشته‌های مهندسی و علوم، به‌طور مکرر با چالش بهبود ویژگی‌های محصول و کاهش هزینه‌ها و مقدار مواد مورد نیاز مواجه است که مستلزم تلاشی طولانی و پرهزینه است. امروزه استفاده از روش‌های تاگوچی [۳۶] برای تعریف مجموعه آزمایش‌هایی که باید انجام شود، به‌عنوان تابعی از متغیرهای تصمیم‌گیری، بسیار متداول است و پس از

در مطالعه‌ای با هدف استفاده از روش‌های هوش مصنوعی برای بهینه‌سازی فرایند اکسترودر تک‌پیچه، مسئله بهینه‌سازی چندهدفه که شامل برآورده کردن هم‌زمان چندین هدف و محدودیت است، مورد بررسی قرار گرفت. این بهینه‌سازی به تعریف بهترین مجموعه از متغیرهای طراحی، شرایط عملیاتی و پارامترهای هندسی وابسته است. معمولاً، در مدل‌سازی عددی با الگوریتم‌های بهینه‌سازی برای حل این مسئله، نیاز است روال مدل‌سازی چندین بار اجرا شود که به دلیل پیچیدگی کدهای عددی زمان‌های محاسباتی بالایی را نشان می‌دهد. روش جایگزینی که با استفاده از هوش مصنوعی برای کاهش تعداد ارزیابی‌های مدل‌سازی مورد نیاز در طول بهینه‌سازی پیشنهاد شده است مبتنی بر روش تجزیه و تحلیل داده‌ها به نام DAMICORE است، که می‌تواند روابط متقابل مهمی را بین تمام متغیرهای مربوط به اکسترودر تعریف و سپس فرایند را بهینه کند [۳۴].


۴-۱ اکستروژن پلیمری تک‌پیچه

اکستروژن پلیمری فرایندی است که در آن پلیمر مذاب مجبور است از حدیده در خروجی دستگاه عبور کند تا شکل نهایی محصول را فراهم کند. همان‌طور که در شکل ۶ مشاهده می‌شود، اکسترودر از بدنه‌ای داغ تشکیل شده که درون آن، پیچ ارشمیدسی قرار دارد و با سرعت قابل تغییر می‌چرخد. پلیمر جامد وارد قیف تغذیه می‌شود و در اثر گرانش به داخل بدنه می‌ریزد و در اثر چرخش پیچ مجبور به حرکت به ناحیه مذاب می‌شود و پس از ذوب شدن کامل تحت فشار قرار می‌گیرد و مجبور به عبور از حدیده می‌شود. این فرایند به اکستروژن نرم‌کنندگی و ذوب‌سازی معروف است [۳۴].

عملکرد فرایند به متغیرهای مربوط به خواص مواد (فیزیکی، حرارتی و رئولوژیکی)، هندسه سامانه (عمدتاً پیچ) و شرایط عملیاتی (دمای بدنه و سرعت چرخش پیچ) بستگی دارد. به‌طور هم‌زمان، عملکرد را می‌توان با در نظر گرفتن خروجی جرمی، دمای مذاب، طول پیچ مورد نیاز برای ذوب، توان مکانیکی، درجه اختلاط و اتلاف ویسکوز تعیین کرد. بنابراین، برای بهینه‌سازی فرایند متغیرهای تصمیم‌گیری به شرایط عملیاتی و هندسه پیچ مربوط می‌شوند، هدف از آن به حداکثر رساندن خروجی و مخلوط کردن و به حداقل رساندن انرژی لازم برای تمام اقدامات عملکردی است [۳۴].

مطالعه مطرح‌شده در اینجا مبتنی بر استفاده از روش تجزیه و تحلیل داده‌ها به نام DAMICORE است که قادر به تعریف روابط متقابل مهم بین همه متغیرهای مربوط به اکسترودر و سپس بهینه‌سازی فرایند است. این روش در چهار سطح از یادگیری

پلیمر تأثیر می‌گذارد. این نشان می‌دهد که راه‌حل به‌دست آمده باید در برابر تغییرات محیطی قوی باشد. با در نظر گرفتن ماهیت چند هدفه این مسئله، الگوریتم‌های تکاملی چندهدفه (MOE-) (Multi-Objective Evolutionary Algorithms) یا سایر الگوریتم‌های مبتنی بر جمعیت پیشنهاد شده‌اند، به‌عنوان مثال، بهینه‌سازی کلونی مورچه‌های چندهدفه (MOACO) (Multi-Objective Ant Colony Optimization)، بهینه‌سازی ازدحام ذرات چندهدفه (MOPSO) (Multi-Objective Particle Swarm Optimization) و تکامل دیفرانسیل چندهدفه (MODE) (Multi-Objective Differential Evolution). با این وجود، عملکرد روش بهینه‌سازی به‌شدت به ظرفیت مدل‌سازی برای ثبت ویژگی‌های فرایند مورد مطالعه وابسته است. با توجه به پیچیدگی اکستروژن نرم و ذوب‌سازی، معادلات دیفرانسیل حاکم بر فرایند را می‌توان به صورت تحلیلی یا عددی حل کرد. در روش تحلیلی، معادلات حاصل قادر به در نظر گرفتن تمام پارامترها نیستند و ممکن است به دلیل ساده‌سازی‌ها، پیوند دادن مراحل مختلف فرایند دشوار باشد. در روش عددی زمان‌های محاسباتی بالا برای ارزیابی راه‌حلی واحد مورد نیاز است. همچنین برخی از مسائل پیچیده مهندسی نیاز به استفاده بیش از یک نرم‌افزار مدل‌سازی عددی دارند، مثلاً تحلیل رفتار مکانیکی قطعه‌ای پلاستیکی و به‌طور هم‌زمان، تحلیل جریان پلیمر داخل دستگاه مورد استفاده در ساخت آن قطعه. بنابراین، استفاده از روش‌های هوش مصنوعی برای مقابله با کمبود نهایی داده‌ها می‌تواند از اهمیت زیادی برخوردار باشد. استفاده از روش‌های داده‌کاوی به راحتی می‌تواند جایگزین مناسبی برای برقراری ارتباط مستقیم اهداف با متغیرهای تصمیم‌گیری باشد. در مرحله ارزیابی، الگوریتم بهینه‌سازی چندهدفه (Multi-Objective Optimization Algorithm) (MOOA) برای بهینه‌سازی فرایند قابل استفاده است، با این حال، ماهیت این مسائل پیچیده نیازمند درجاتی از تعامل با تصمیم‌گیرنده (DM) (Decision Maker) است، زیرا برای تصمیم‌گیری، تعریف متغیرها، محدودیت‌ها و اهداف ضروری است. هم‌زمان، در محیطی چندهدفه، راه‌حل نهایی بهینه‌سازی چندهدفه مسئله (MOOP) (Multi-Objective Optimization Problem) مجموعه‌ای از نقاط است که نیاز به مداخله DM برای انتخاب راه‌حل واحدی است که در دنیای واقعی استفاده شود. در این زمینه، ML به‌عنوان زیر مجموعه هوش مصنوعی نقش مهمی در کاهش این تعاملات دارد و پاسخ خوبی یا حداقل تقریب خوبی در رابطه با راه حل مسئله مورد مطالعه به‌دست می‌دهد [۳۴، ۳۵، ۳۷].



شکل ۶ الف) اکسترودر تک پیچه: نواحی مختلف، مولفه های سرعت، (ب) شرایط (دما و مشخصه های هندسی) مدل.

نظری این متغیرها، تأثیراتی قوی بر فرایند دارند [۳۵]. بنابراین روش های هوش مصنوعی برای تحلیل و بهینه سازی فرایند اکستروژن پلیمری با در نظر گرفتن جنبه های مختلف فرایندی قابل استفاده است. داده های محاسباتی مورد استفاده بدون در نظر گرفتن هیچ گونه تحلیل فرایند قبلی به دست آمده

است، در نهایت، جدول ۵ میانگین فاصله نرمال شده از متغیرها تا تمام اهداف حاصل از یادگیری سطح دوم را نشان می دهد. می توان دید در این مورد، متغیرهایی که بیشترین تأثیر را بر اهداف دارند عبارتند از: سرعت چرخش پیچ (N)، گام پیچ و قطر ناحیه مذاب (D3) که همان هایی است که انتظار می رفت، زیرا از حیث

جدول ۵ نتایج حاصل از یادگیری سطح دو - مجموعه داده ماریچ.

متغیر	خروجی	T_{melt}	توان	$L_{melting}$	WATS	خطا	میانگین
N	۰/۳۶	۰/۳۶	۰/۲۸	۰/۲۱	۰/۳۶	۰/۲۱	۰/۳۰
گام پیچ	۰/۵۰	۰/۵۰	۰/۴۳	۰/۲۱	۰/۵۰	۰/۲۱	۰/۴۰
شیار	۰/۴۳	۰/۵۰	۰/۵۰	۰/۵۰	۰/۵۰	۰/۲۱	۰/۴۳
D_3	۰/۴۳	۰/۵۰	۰/۵۰	۰/۵۰	۰/۵۰	۰/۲۱	۰/۴۳
T_{feed}	۰/۵۶	۰/۶۴	۰/۶۴	۰/۶۴	۰/۶۴	۰/۲۱	۰/۵۵
L_{feed}	۰/۷۱	۰/۷۹	۰/۷۹	۰/۷۹	۰/۷۹	۰/۳۶	۰/۷۰
T_{barre}^I	۰/۷۱	۰/۷۹	۰/۷۹	۰/۷۹	۰/۷۹	۰/۳۶	۰/۷۰
L_3	۰/۷۹	۰/۸۶	۰/۸۶	۰/۸۶	۰/۸۶	۰/۴۳	۰/۷۷
L_2	۰/۷۹	۰/۸۶	۰/۸۶	۰/۸۶	۰/۸۶	۰/۴۳	۰/۷۷
RBS	۰/۸۶	۰/۹۳	۰/۹۳	۰/۹۳	۰/۹۳	۰/۵۰	۰/۸۴
L_1	۰/۸۶	۰/۹۳	۰/۹۳	۰/۹۳	۰/۹۳	۰/۵۰	۰/۸۴
D_1	۰/۹۳	۱/۰۰	۱/۰۰	۱/۰۰	۱/۰۰	۰/۵۶	۰/۹۱
D_{ext}	۰/۹۳	۱/۰۰	۱/۰۰	۱/۰۰	۱/۰۰	۰/۵۶	۰/۹۱

طبق نمودار (شکل ۷)، هر تکرار مستلزم ساخت ترکیبی لاستیکی و انجام آزمون‌هاست. بدیهی است که این روش زمان‌بر و پرهزینه و از نظر اقتصادی و رقابتی روش ایده‌آلی نیست. از طرفی در روش تجربی، طراح اولین ترکیبی که خواص مورد نظر را داشته باشد، انتخاب می‌کند، در حالی که ممکن است این ترکیب از نظر قیمت و خواص بهترین ترکیب نباشد. علاوه بر این، روش آزمایشی به تجربه طراح بستگی دارد. بنابراین یافتن روشی دقیق، سریع و ارزان برای طراحی ترکیبی لاستیکی که به فرد وابسته نباشد برای صنعت لاستیک ضروری است. طراح ترکیب لاستیکی با مسئله تأثیر هر ماده بر هر یک از ویژگی‌ها و انتخاب بهترین ترکیب از نظر قیمت و مشخصات مواجه است. البته توجه به تأثیر متقابل مواد اولیه بر خواص و مدت و هزینه روش طراحی نیز حائز اهمیت است [۱۸، ۳۸].

در نتیجه، فقدان دستورالعمل‌های طراحی برای ایجاد درکی جامع از رابطه طراحی معکوس بین رفتارهای مکانیکی و طراحی توصیف‌کننده، وجود دارد که مانع از تعیین کارآمد رابطه ویژگی به ساختار در کاربردهای عملی می‌شود. راهبردهای طراحی مرسوم، مانند طراحی مبتنی بر متغیرها و طراحی آزمایش، اغلب به دلیل زمان‌بر بودن و ضرورت جستجوی جامع در پایگاه‌های داده مواد با چالش‌هایی مواجه است، به‌ویژه برای طراحی‌هایی که شامل بسیاری از متغیرها و درجات آزادی است. این روش‌ها توسط هزینه‌های محاسباتی مرتبط با توابع همبستگی و تکیه بر توصیف‌گرهای فیزیکی، بر اساس تجربه طراح محدود می‌شوند [۳۸].

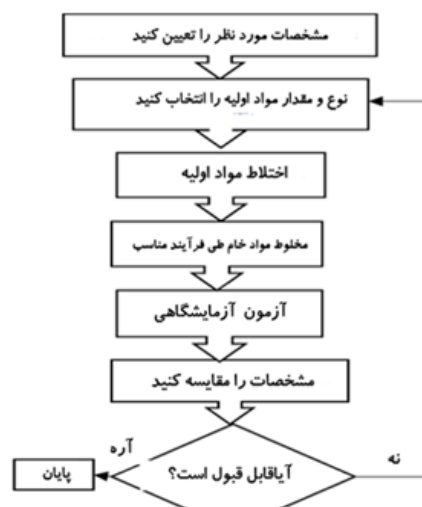
پیشرفت‌ها در روش‌های یادگیری ماشینی (ML) و هوش مصنوعی (AI) انقلابی در علم مواد، مکانیک سازه‌ها و بهینه‌سازی و طراحی کامپوزیت‌ها و لاستیک‌ها در سال‌های اخیر ایجاد کرده است. AI/ML توانایی تجزیه و تحلیل پایگاه‌های اطلاعاتی گسترده و ایجاد روابط ریاضی را ارائه داده، پتانسیل فوق‌العاده‌ای برای کشف و طراحی مواد جدید به‌نمایش گذاشته است. راه‌های نوآوری و بهینه‌سازی برنامه‌های کاربردی جدید AI/ML که می‌توانند حجم زیادی از داده‌ها را پردازش کنند، از الگوها یاد بگیرند و تصمیمات الگوریتمی را اتخاذ کنند که منجر به بهبود عملکرد، افزایش کارایی و افزایش شاخص اطمینان شده است، به ابزاری قدرتمند برای مهندسان و محققان تبدیل شده که در زمینه‌های بین‌رشته‌ای شیمی، مهندسی مکانیک، علم مواد، مهندسی زیست پزشکی و ساخت و تولید رواج یافته است [۱۸]. کاربرد AI/ML در طراحی مواد کامپوزیتی و لاستیکی مزایای متعددی را ارائه می‌دهد. الگوریتم‌ها می‌توانند به‌طور موثر مجموعه داده‌های گسترده‌ای را که شامل خواص مواد، عوامل

است. نتیجه اصلی که می‌توان از این کار به‌دست آورد این است که روش‌های هوش مصنوعی مبتنی بر داده‌کاوی، می‌توانند برای بهینه‌سازی فرایندهای مهندسی با استفاده از مقدار کمی داده و بدون راهبرد بهینه‌سازی مسئله محور دقیق، استفاده شوند [۳۴، ۳۵، ۳۷].

۵ لاستیک

لاستیک‌های پلیمرهایی هستند با خواص فیزیکی خاص مانند انعطاف‌پذیری، کشش‌پذیری، خاصیت ارتجاعی و دوام. این خواص منحصر به فرد در لاستیک‌ها باعث شده است که در طیف وسیعی از کاربردها به‌طور گسترده مورد استفاده قرار گیرند. خواص مورد نیاز مانند سایش، چقرمگی، سختی، سفتی و استحکام کششی محصولات لاستیکی مستلزم اختلاط لاستیک با مقادیر مختلفی از افزودنی‌هاست.

یکی از مسائل مهم در صنعت لاستیک، انتخاب نوع و کمیت این مواد اولیه در فرمول‌بندی لاستیک است. اگر انتخاب مواد اولیه به روش صحیحی انجام نشود، مشکلاتی مانند خواص نامناسب محصول نهایی و طولانی شدن و پرهزینه شدن فرایند انتخاب به‌وجود می‌آید. هنگام طراحی ترکیب لاستیکی معمولاً به‌دست آوردن یکی از خواص ذکر شده در مشخصات مورد نیاز به‌تهایی دشوار نیست، اما زمانی که قرار است چندین ویژگی به‌طور هم‌زمان حاصل شود، به‌دلیل تفاوت در خواص، مشکل ایجاد می‌شود. در روش معمول، طراح پس از دریافت مشخصات ترکیب، دانش نظری و تجربه عملی خود را با انتخاب ترکیب ادغام می‌کند. مراحل طراحی فرمول‌بندی لاستیک به روش تجربی در شکل ۷ نشان داده شده است [۳۸].



شکل ۷ فرایند طراحی فرمول‌بندی لاستیکی.

معمولی مانند فلزات، سرامیک‌ها یا پلیمرها پیشی بگیرند. با معرفی ساخت و تولید افزایشی (AM) (Additive Manufacturing) به شیوه‌ای کنترل شده از طریق چاپ سه بعدی، می‌توان سازه‌های پیچیده هندسی را شکل داد و امکان طراحی خواص مواد مانند سفتی، استحکام، ناهمسانگردی و ناهمگنی را فراهم کرد [۴۱، ۴۰، ۱۸].

کاربرد هوش مصنوعی در چاپ سه بعدی بر توسعه برنامه‌های ML و در دسترس بودن داده‌ها برای یادگیری متکی است. در سال‌های اخیر، نظارت درجا و یادگیری فرایند در ساخت و تولید افزایشی (AM) مورد توجه قرار گرفته است. در جنبه تحقیقاتی، ML در جنبه‌های مختلف بهینه‌سازی فرایند، دستکاری و سفارشی‌سازی به کار گرفته شده است. یکی از حوزه‌های مورد علاقه کنترل عواملی مانند نواقص موضعی و محلی، تنش‌های داخلی، دقت طراحی و تغییر ریزساختار است. با این حال، کنترل این عوامل به دلیل تعداد بسیار زیاد متغیرهای درگیر در تجزیه و تحلیل داده‌ها، چالش برانگیز است. عوامل فرایندی، انواع مواد، هندسه قطعه، گزینه‌های طراحی و عوامل محیطی به نتیجه کمک می‌کنند. در حالی که برخی از متغیرها را می‌توان کنترل کرد، برخی دیگر به عنوان خطا (Noise) یا عوامل اضافی تلقی می‌شوند که تأثیر آن‌ها فقط در طول زمان قابل یادگیری است و AI/ML می‌تواند نقش مهمی در درک تأثیرات آن بازی کند. از الگوریتم‌های AI/ML از جمله یادگیری تحت نظارت، بدون نظارت و تقویت شده در AM استفاده شده است. الگوریتم‌های یادگیری بدون نظارت و تقویت شده می‌توانند به صورت محلی از فرایند یاد بگیرند، الگوها و مدل‌ها را توسعه دهند و عوامل را در فرایند ساخت و تولید تغییر دهند تا خطاها کاهش یابد، نقص‌ها به حداقل برسد یا ریزساختار تنظیم شود. این رویکرد نیازمند نظارت محلی، پردازش داده‌ها، تجزیه و تحلیل داده‌ها و کنترل بازخورد است. این امر مستلزم جمع‌آوری گسترده داده‌ها، تجزیه و تحلیل سریع، پردازش و بازخورد مؤثر است. تجزیه و تحلیل آماری ممکن است در مواردی که رویکردهای قطعی برای تصمیم‌گیری محلی کافی نیست، مورد نیاز باشد. یادگیری تحت نظارت می‌تواند از تاریخچه داده‌ها و برچسب‌گذاری برای بهینه‌سازی و سفارشی‌سازی فرایندها استفاده کند. با این حال، سوالات مربوط به انواع داده‌ها، دسته‌بندی، استانداردسازی، ذخیره‌سازی و اشتراک‌گذاری، مباحثی چالش برانگیز یا تا حدی حل نشده باقی می‌مانند. تنوع داده‌ها، چالش‌هایی را در رابطه با قابلیت اطمینان و دقت ایجاد می‌کند و تکرار یا استفاده برای یادگیری فرایند در طیف گسترده‌ای از ماشین‌ها و مواد را دشوار می‌سازد.

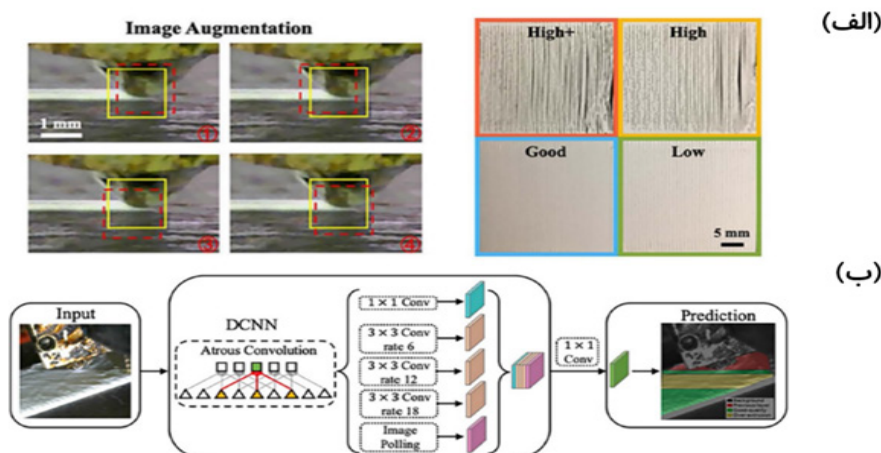
ساخت و معیارهای عملکردی است، تجزیه و تحلیل کنند. از طریق تجزیه و تحلیل AI/ML می‌توان الگوها و روابط پیچیده‌ای را کشف کرد که تشخیص آن‌ها برای فرایندهای طراحی مرسوم ناممکن است. این بینش‌ها توسعه مواد لاستیکی پیشرفته را از طراحی شیمیایی نانومقیاس، ترکیبات ذاتی و ریزساختارها تا طراحی سازه‌ها در مقیاس بزرگ و روش‌های پردازش متناسب با کاربردهای خاص را امکان‌پذیر کرده و منجر به خواص مکانیکی، حرارتی و الکتریکی برتر شده است. محققان با استفاده از تشخیص تصویر، خوشه‌بندی داده‌ها و سایر روش‌های AI/ML، می‌توانند ویژگی‌های ضروری را از سامانه‌های پیچیده مواد استخراج کنند که درک، کنترل، ساخت و پیش‌بینی بهتر رفتار مواد را موجب شوند [۱۸].

بر اساس تحقیقات انجام شده، استفاده از مدل‌سازی شبکه عصبی مصنوعی برای پیش‌بینی رفتار غیرخطی ترکیبات لاستیکی مناسب است. کوریا و همکاران [۳۹] مقادیر سه فرمول‌بندی لاستیکی با پایه EPDM را برای دستیابی به حداقل قیمت بهینه کردند. نتایج نشان داد که با روش‌های ترکیبی ML می‌توان شرایط بهینه با کمترین قیمت را به سرعت به دست آورد. در پژوهشی غفاریان و حامدی [۱۸، ۳۸] با هدف کاهش زمان، هزینه و افزایش دقت و سهولت در فرایند طراحی آمیزه لاستیکی، موضوع بهینه‌سازی فرایند را مورد بررسی قرار دادند. در این مسئله، دریافتند که رابطه بین مقدار مواد اولیه و خواص مدل‌سازی شده توسط شبکه عصبی مصنوعی، دارای رابطه‌ای کاملاً غیرخطی است و رفتار مشخصه‌های مختلف با مواد اولیه ثابت، کاملاً متفاوت است، بنابراین برای هر مشخصه، مدل شبکه عصبی مصنوعی خاصی در نظر گرفته شد. نتایج نشان داد که فرایند طراحی آمیزه لاستیکی با این روش نتایج بهتری نسبت به روش تجربی دارد.

۶ کامپوزیت‌ها

چاپ سه بعدی با هدایت هوش مصنوعی

دهه‌ها تحقیق بر روی مواد کامپوزیت، آن‌ها را به اجزای حیاتی در صنایع مختلف تبدیل کرده است و فرایندهای طراحی و تولید را در بخش‌هایی مانند خودروسازی، هوافضا، ساخت و ساز و سازه‌های هوشمند پیش برده است. کامپوزیت‌ها، مواد مهندسی شده متشکل از ماتریس و تقویت‌کننده‌های دو یا چند جزئی مجزا، ویژگی‌های استثنایی مانند استحکام بالا و نسبت سفتی به وزن زیاد را ارائه می‌دهند. این ویژگی‌های عملکردی مناسب و همچنین عملکرد منحصر به فرد مانند پاسخ دینامیکی به محرک‌های خارجی و سامانه‌های هوشمند باعث شده که از مواد



شکل ۸ (الف) رصد در لحظه فرایند چاپ سه بعدی در شرایط مختلف و کیفیت چاپ سه بعدی حاصل از آن‌ها، (ب) مدل هوش مصنوعی یادگیری عمیق در رصد درجا و پیش‌بینی دقیق محلی چاپ سه بعدی.

فناوری‌های مختلف نقطه‌ای کانونی در فرایندهای بستر پودری، همراه با سامانه‌های تصویربرداری حرارتی یا نوری رایج است. برخی از مطالعات نیز بر اندازه‌گیری کیفیت سطح یا ابعاد سازه‌های چاپ‌شده سه بعدی متمرکز شده‌اند [۱۸].

۷ نتیجه‌گیری

در حوزه فراروش پلیمرها، اخیراً هوش مصنوعی (AI) به عنوان ابزاری قدرتمند برای بهینه‌سازی فرایندهای پلیمری و افزایش کیفیت محصولات پلیمری مطرح است. الگوریتم‌های هوش مصنوعی می‌توانند تجزیه و تحلیل حجم وسیعی از داده‌های اخذشده از حسگرها و سامانه‌های نظارت بر فرایند را انجام دهند. الگوها و روندها، آن‌ها را قادر می‌سازد، به مواردی که تشخیص دستی آن‌ها دشوار یا ناممکن است بپردازند. سپس می‌توان از اطلاعات برای بهینه‌سازی عوامل فرایندی مانند نرخ برش، دما و زمان اقامت برای دستیابی به نتایج بهینه استفاده کرد. در این مطالعه بعد از بررسی کلی روش‌های یادگیری ماشینی و کاربردهای آن در فرایندهای پلیمری، به بررسی چند فرایند مهم پلیمری (آمیزه‌سازی در لاستیک، تهیه کامپوزیت‌ها و اکستروژن پلیمر) پرداخته شده است.

۸ چشم‌انداز آینده

انتظار می‌رود هوش مصنوعی نقش مهمی را در بهینه‌سازی و کنترل فرایندهای پلیمری ایفا کند. هر چه الگوریتم‌های هوش مصنوعی پیچیده‌تر شوند، امکان مدیریت داده‌های حجیم‌تر فراهم می‌شود. به علاوه، آن‌ها قادر خواهند بود بینش‌ها و توصیه‌های ارزشمندتری برای بهبود بازده اختلاط و کیفیت

ادبیات نظارت درجا در چاپ سه بعدی به‌طور قابل توجهی در دهه گذشته رشد کرده است. می‌توان از آن برای بهبود مستمر فرایند از طریق تجزیه و تحلیل داده‌ها و بازخورد نتایج استفاده کرد. در مقالات اخیر، روش‌های تشخیص پیشرفته در چاپ سه بعدی توسعه یافته است. میانگین دقت مدل‌ها بیش از ۹۲ درصد در سطح محلی و کلی است. بررسی کیفیت در هر لایه امکان ارزیابی جامع عیوب صفحه را فراهم می‌کند [شکل ۸ (الف)]. مطالعات آن‌ها همچنین بر شناسایی و پیش‌بینی نتایج جدید چاپ در زمان واقعی متمرکز بوده، گرچه تأخیر زمانی در سخت‌افزار چاپ همچنان چالش برانگیز است [شکل ۸ (ب)]. در آینده بررسی بهبود کیفیت چاپ، پیش‌بینی خواص مکانیکی بر اساس اطلاعات مربوط به نواقص و درک عوامل فرایندی و روابط بین عوامل مورد نیاز است. تجزیه و تحلیل مؤلفه‌های اصلی و روش‌های خوشه‌بندی می‌تواند نظارت بر عیوب مختلف را تسهیل کند. بهبود کیفیت قطعات AM چالش دائمی اصلی است. تحقیقات جستجوی درجا، به مسائلی مانند ناپیوستگی فرایند، زبری سطح و کیفیت نهایی خواص مکانیکی می‌پردازد. ماهیت پیچیده چاپ سه بعدی، برای مثال، در فرایندهای هم‌جوشی بستر پودری، بیش از ۵۰ عامل موثر را نتیجه داده است. تعمیم رویکردهای بهینه‌سازی چالش برانگیز است، زیرا اغلب باید برای هر ماده جدید تکرار شود. برای مقابله با این چالش‌ها، سامانه نظارت در محل باید با الگوریتم‌های AI/ML ادغام شود تا فرایندها را به‌صورت محلی یاد بگیرد و بهبود ببخشد. این امر برای استانداردسازی بسیار مهم است، زیرا مواد در نظر گرفته شده برای بخش‌های صنعتی خاص باید استانداردهای کیفی سختگیرانه را ارضا کنند. اندازه‌گیری دما با استفاده از

ابزارها داده‌های حسگرها را برای پیش‌بینی خرابی‌های احتمالی تجهیزات، تجزیه و تحلیل می‌کنند و امکان تعمیر و نگهداری پیشگیرانه و کاهش زمان رفع خرابی‌ها را فراهم می‌کنند.

۳- سامانه‌های کنترل کیفیت مبتنی بر هوش مصنوعی: این سامانه‌ها از الگوریتم‌های هوش مصنوعی برای بازرسی و ارزیابی کیفیت مخلوط پلیمری، همچنین، شناسایی عیوب یا ناسازگاری‌های بالقوه استفاده می‌کنند.

قدردانی

لازم می‌داند از دکتر مهرداد کوکبی استاد گروه مهندسی پلیمر به خاطر ایده اولیه، تصحیح مطالب و ویراستاری مقاله حاضر قدردانی نماید.

محصول ارائه دهند.

در نتیجه، هوش مصنوعی ابزار قدرتمندی است که می‌تواند برای ایجاد انقلابی در فرایندهای پلیمری مورد استفاده قرار گیرد و منجر به بهبود کارایی فرایند، کاهش هزینه‌ها و افزایش کیفیت محصول شود.

نمونه‌هایی از فناوری‌های فرایندهای اختلاط پلیمرها مبتنی بر هوش مصنوعی:

- ۱- سامانه‌های کنترل اختلاط مبتنی بر هوش مصنوعی: این سامانه‌ها از الگوریتم‌های هوش مصنوعی برای نظارت و کنترل عوامل اختلاط در زمان واقعی، اطمینان از کیفیت اختلاط ثابت و کاهش زمان‌های چرخه استفاده می‌کنند.
- ۲- ابزارهای نگهداری پیشگویانه مبتنی بر هوش مصنوعی: این

مراجع

1. Yuan S., The Roles of Artificial Intelligence Techniques for Increasing the Prediction Performance of Important Parameters and Their Optimization in Membrane Processes: A Systematic Review, *Ecotoxicol. Environ. Saf.*, 260, 115066-115075, **2023**.
2. Butler K.T., Davies D.W., Cartwright H., Isayev O., and Walsh A., Machine Learning for Molecular and Materials Science, *Nature*, 559, 547-555, **2018**.
3. Westermayr J., Gastegger M., Schütt K.T., and Maurer R.J., Perspective on Integrating Machine Learning into Computational Chemistry and Materials Science, *J. Chem. Phys.*, 154, 230903-23092, **2021**.
4. Trinh C., Meimaroglou D., and Hoppe S., Machine Learning in Chemical Product Engineering: The State of the Art and a Guide for Newcomers, *Processes*, 9, 8, 1456-1500, **2021**.
5. Elton D. C., Boukouvalas Z., Fuge M.D., and Chung P. W., Deep Learning for Molecular Design—a Review of the State of the Art, *Mol. Syst. Des. Eng.*, 4, 828-849, **2019**.
6. Paliani G., Machine Learning in Materials Science: From Explainable Predictions to Autonomous Design, *Comput. Mater. Sci.*, 193, 110360-110373, **2021**.
7. Winkler D.A., Machine Learning at the (Nano)Materials-Biology Interface, in Machine Learning in Chemistry, *The Royal Society of Chemistry*, 206-226, **2020**.
8. Bennett S., Tarzia A., Zwijnenburg M.A., and Jelfs K.E., Artificial Intelligence Applied to the Prediction of Organic Materials, in Machine Learning in Chemistry, *The Royal Society of Chemistry*, 12, 280-310, **2020**.
9. Chen A., Zhang X., and Zhou Z., Machine Learning: Accelerating Materials Development for Energy Storage and Conversion, *Info Mat*, 2, 553-576, **2020**.
10. Zhu H., Big Data and Artificial Intelligence Modeling for Drug Discovery, *Annu. Rev. Pharmacol. Toxicol.*, 60, 573-589, **2020**.
11. Yang X., Wang Y., Byrne R., Schneider G., and Yang S., Concepts of Artificial Intelligence for Computer-Assisted Drug Discovery, *Chem. Rev.*, 119, 18, 10520-10594, **2019**.
12. Brown N., Ertl P., Lewis R., Luksch T., Reker D., and Schneider N., Artificial Intelligence in Chemistry and Drug Design, *J. Comput. Aided. Mol. Des.*, 34, 709-715, **2020**.
13. Schlexer Lamoureux P., Machine Learning for Computational Heterogeneous Catalysis, *Chem Cat Chem*, 11, 3581-3601, **2019**.
14. Ma S., Kang P.L., Shang C., and Liu Z.P., Machine Learning for Heterogeneous Catalysis: Global Neural Network Potential from Construction to Applications, in Machine Learning in Chemistry, *The Royal Society of Chemistry*, 19, 488-511, **2020**.
15. Yang W., Fidelis T.T., and Sun W. H., Machine Learning in Catalysis, *From Proposal to Practicing*, *ACS Omega*, 5, 83-88, **2020**.
16. Haywood A. L., Redshaw J., Gaertner T., Taylor A., Mason A. M., and Hirst J. D., Machine Learning for Chemical Synthesis, in Machine Learning in Chemistry, *The Royal Society of Chemistry*, 7, 169-194, **2020**.
17. Nair V. H., Schwaller P., and Laino T., Data-driven Chemical Reaction Prediction and Retrosynthesis, *Chimia (Aarau)*, 73, 997-1000, **2019**.
18. Choi W., Advincula R. C., Wu H. F., and Jiang Y., Artificial Intelligence and Machine Learning in the Design and Additive Manufacturing of Responsive Composites, *MRS Commun.*, 13, 714-724, **2023**.
19. Wang C., Tan X. P., Tor S. B., and Lim C. S., Machine Learning in Additive Manufacturing: State-of-the-Art and Perspectives, *Addit. Manuf.*, 36, 101538-101558, **2020**.
20. Burkov A., The Hundred-Page Machine Learning Book, Andriy Bur. Quebec City, QC, Canada, **2019**.
21. Nasery S., Hoseinpour S., L. Phung T. K., and Bahadori A., Prediction of the Viscosity of Water-in-Oil Emulsions, *Pet. Sci. Technol.*, 34, 1972-1977, **2016**.
22. Ge Z., Chen T., and Song Z., "Quality Prediction for Polypropylene Production Process Based on CLGPR Model, *Control Eng. Pract.*, 19, 423-432, **2011**.
23. Zhang Y., Jin H., Liu H., Yang B., and Dong S., Deep Semi-Supervised Just-in-Time Learning Based Soft Sensor for Mooney Viscosity Estimation in Industrial Rubber Mixing Process, *Polymers (Basel)*, 14, 1018-1031, **2022**.
24. Liang Y., Liu Z., and Liu W., A Co-training Style Semi-Supervised Artificial Neural Network Modeling and its Application in Thermal Conductivity Prediction of Polymeric Composites Filled with BN Sheets, *Energy AI*, 4, 100052-100061, **2021**.
25. Singh V., and Kodamana H., Reinforcement Learning Based Control of Batch Polymerisation Processes, *IFAC-PapersOnLine*, 53, 1, 667-672, **2020**.
26. Ma Y., Zhu W., Benton M. G., and Romagnoli J., Continuous Control of a Polymerization System with Deep Reinforcement Learning, *J. Process Control*, 75, 40-47, **2019**.
27. Zhu H., Fei L., Yang Y., Lin C., Jingyuan L., Anhui G.,

- Jianqiang Z. and Chunwang D., Application of Machine Learning Algorithms in Quality Assurance of Fermentation Process of Black Tea-Based on Electrical Properties, *J. Food Eng.*, 263, 165–172, **2019**.
28. Venkatasubramanian V., The Promise of Artificial Intelligence in Chemical Engineering: Is it Here, Finally?, *AIChE J.*, 65, 466–478, **2019**.
29. Nian R., Liu J., and Huang B., A Review on Reinforcement Learning: Introduction and Applications in Industrial Process Control, *Comput. Chem. Eng.*, 139, 106886–106916, **2020**.
30. Uhlemann J., Costa R., and Charpentier J.C., Product Design and Engineering in Chemical Engineering: Past, Present State, and Future, *Chem. Eng. Technol.*, 42, 2258–2274, **2019**.
31. Ghiba L., Drăgoi E.N., and Curteanu S., Neural Network-Based Hybrid Models Developed for Free Radical Polymerization of Styrene, *Polym. Eng. Sci.*, 61, 716–730, **2021**.
32. Sadowski P., Fooshee D., Subrahmanya N., and Baldi P., Synergies Between Quantum Mechanics and Machine Learning in Reaction Prediction, *J. Chem. Inf. Model.*, 56, 2125–2128, **2016**.
33. Yan Y., Borhani T.N., and Clough P.T., Machine Learning Applications in Chemical Engineering, in Machine Learning in Chemistry, *The Royal Society of Chemistry*, 340–371, **2020**.
34. Gaspar-Cunha A., Delbem A., Costa P., and Monaco F., Application of Artificial Intelligence Techniques in the Optimization of Single Screw Polymer Extrusion, *Congr. Métodos Numéricos en Ing.*, **2022**.
35. Gaspar-Cunha A., Monaco F., Sikora J. W., and Delbem A., Multi-Objective Optimization of Single Screw Polymer Extrusion Based on Artificial Intelligence, *Int. Conf. Process. Compos. Nanocomposites Mater.*, **2022**.
36. Freddi A. and Salmon M., Introduction to the Taguchi Method, *Springer Tracts in Mech Eng*, 159–180, **2019**.
37. Gaspar-Cunha A., Monaco F., Sikora J., and Delbem A., Artificial Intelligence in Single Screw Polymer Extrusion: Learning from Computational Data, *Eng. Appl. Artif. Intell.* 116, 105397, **2022**
38. Ghaffarian N. and Hamed M., Optimization of Rubber Compound Design Process Using Artificial Neural Network and Genetic Algorithm, *International Journal of Engineering, Transactions B: Applications*, 33, 2319–2326, **2020**.
39. Correia S.L., Palaoro D., and Segadães A. M., Property Optimisation of EPDM Rubber Composites Using Mathematical and Statistical Strategies, *Adv. Mater. Sci. Eng.*, 2017, 1–7, **2017**.
40. Khan M. and Mazumder J., Application of Artificial Intelligence in New Materials Discovery, *Materials Research Foundations*, **2023**.
41. Martin T.B. and Audus D.J., Emerging Trends in Machine Learning: A Polymer Perspective, *ACS Polym. Au*, 3, 239–258, **2023**.