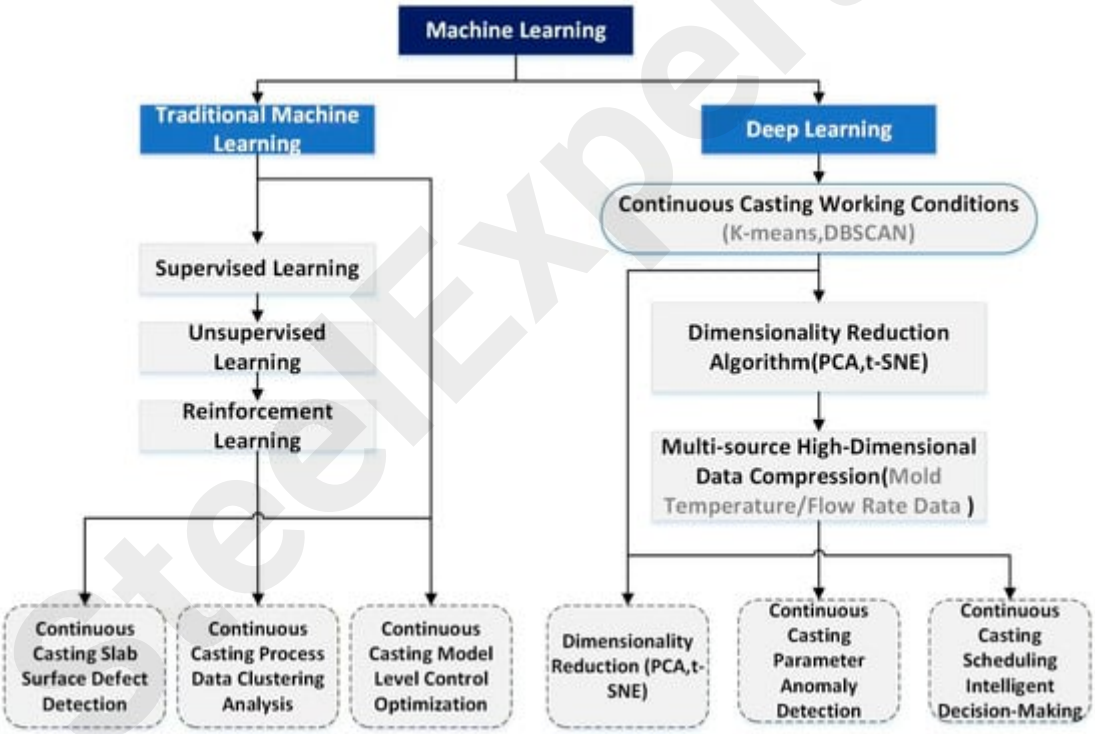
مرکز دانش شبکه خبرگان صنعت فولاد

پیشرفت‌های پژوهشی در کاربرد یادگیری ماشین در ریخته‌گری مداوم

مقالات تخصصی | علی ارجمندی اصل | ۱۴۰۵/۰۸/۰۵

مروری تخصصی بر کاربرد یادگیری ماشین در ریخته‌گری مداوم، شامل هشدار بیرون‌ریزی مذاب، کنترل نوسان سطح قالب، پیش‌بینی گرفتگی نازل، شناسایی ترک و آخال و بهینه‌سازی سرعت و سرمایش.



چکیده

ریخته‌گری مداوم یکی از مراحل محوری تولید فولاد است؛ فرایندی که با رفتار شدیداً غیرخطی، برهم‌کنش هم‌زمان چندین پارامتر و نوسان شرایط عملیاتی شناخته می‌شود. مدل‌های متعارفِ متکی بر تجربه یا سازوکارهای فیزیکی، دیگر به‌تنهایی پاسخگوی الزامات تولید باکیفیت و پربازده در صنعت فولاد امروز نیستند.

یادگیری ماشین به پشتوانه توانایی بالای خود در داده‌کاوی و تشخیص الگو، مسیر فنی مؤثری برای حل مسائل پیچیده کنترل فرایند ریخته‌گری مداوم فراهم کرده است. این مقاله پیشرفت‌های پژوهشی کاربرد یادگیری ماشین در ریخته‌گری مداوم را به‌صورت نظام‌مند مرور می‌کند و بر سه حوزه اصلی تمرکز دارد: پیش‌بینی شرایط غیرعادی، شناسایی عیوب کیفی و بهینه‌سازی پارامترهای فرایند. همچنین روند تکامل روش‌ها را از مدل‌های منفرد به بهینه‌سازی و تلفیق ویژگی‌ها، مدل‌های ترکیبی یادگیری عمیق و مدل‌های دوگانه مبتنی بر سازوکارهای فیزیکی و داده تشریح می‌کند. دستاوردهای این فناوری در کاهش مخاطرات تولید و افزایش پایداری کیفیت محصول ریختگی جمع‌بندی می‌شود و چالش‌های مهم آن، از جمله تحریف داده‌ها و نامتوازن‌بودن توزیع آن‌ها، تفسیرپذیری ناکافی مدل‌ها و محدودیت تعمیم‌پذیری میان شرایط عملیاتی متفاوت بررسی می‌شوند. در پایان نیز مسیرهای نوآوری فناورانه و گسترش کاربردها در آینده ترسیم می‌شود تا پشتوانه‌ای نظری و مرجعی فنی برای تحول دیجیتال و هوشمندسازی صنعت فولاد فراهم آید.

کلیدواژه‌ها: ریخته‌گری مداوم؛ یادگیری ماشین؛ پیش‌بینی شرایط غیرعادی؛ تشخیص عیب؛ بهینه‌سازی پارامترهای فرایند.

۱. مقدمه

ریخته‌گری مداوم، حلقه اتصال فولادسازی و نورد است و بهره‌وری و کیفیت محصول ریختگی در آن مستقیماً بر منافع اقتصادی و توان رقابتی شرکت‌های فولادی اثر می‌گذارد [۱، ۲]. در این فرایندِ دمای بالا، پدیده‌های پیچیده فیزیکی و شیمیایی، از جمله انتقال حرارت و جرم و دگرگونی فازی هنگام انجماد، هم‌زمان رخ می‌دهند. میان پارامترهایی نظیر سرعت ریخته‌گری، شدت سرمایش، فوق‌گرمایش مذاب و ترکیب شیمیایی فولاد از یک سو و کیفیت محصول و ایمنی تولید از سوی دیگر، رابطه‌ای به‌شدت غیرخطی و به‌هم‌پیوسته وجود دارد [۳–۵]. برای مثال، سرعت بیش‌ازحد ریخته‌گری پوسته اولیه منجمدشده را نازک می‌کند و ممکن است به چسبندگی پوسته و بیرون‌ریزی مذاب بینجامد؛ درحالی‌که سرمایش ناکافی می‌تواند جدایش مرکزی را تشدید کند. تغییر یک پارامتر، اغلب دستیابی هم‌زمان به چند هدف را دشوار می‌سازد [۶–۸].

تولید امروز در ماشین‌های ریخته‌گری مداوم با سه گلوگاه اصلی مواجه است [۹–۱۱]. نخست، خطر وقوع ناگهانی رویدادهای غیرعادی زیاد است: چسبیدن پوسته و بیرون‌ریزی فولاد یا گرفتگی نازل ممکن است با یک حادثه، تجهیزات را آسیب بزند، تولید را متوقف کند و زیان قابل‌توجهی به بار آورد. دوم، کنترل عیوب کیفی دشوار است. شناسایی ترک‌ها و آخال‌ها در بسیاری از موارد به بازرسی دستی وابسته است که هم با تأخیر انجام می‌شود و هم احتمال تشخیص نادرست در آن بالاست. سوم، بهینه‌سازی فرایند کارایی لازم را ندارد؛ شبیه‌سازی عددی متعارف مبتنی بر مدل‌های متالورژیکی به‌سختی از عهده تغییرات پویای گریدهای فولاد و شرایط کاری برمی‌آید.

کنترل سنتی عمدتاً بر دو راه تکیه دارد [۱۲]. در روش نخست، با اتکا به انتقال حرارت و مکانیک سیالات، مدل انجماد و انتقال حرارت محصول ساخته می‌شود و پارامترها با محاسبات عددی بهینه می‌شوند؛ اما برای مدل‌سازی باید اثر متقابل چند میدان فیزیکی ساده‌سازی شود. نتیجه به شرایط مرزی حساس است و در وضعیت‌های پیچیده، خطای محاسبه به‌طور محسوسی افزایش می‌یابد. روش دوم، آزمون‌وخطای تجربی است؛ برای نمونه مهندس بهره‌بردار دبی آب سرمایش ثانویه را براساس تجربه تغییر می‌دهد. اجرای آن آسان است، اما به قضاوت فردی وابستگی زیادی دارد، پایدار نیست و هنگام تعویض گرید فولاد به‌خوبی پاسخ نمی‌دهد. با گسترش اتوماسیون، خطوط ریخته‌گری اکنون داده‌های فراوانی از منابع مختلف گردآوری می‌کنند، ولی روش‌های قدیمی نمی‌توانند همه ارتباط‌های پنهان میان وضعیت فرایند و کیفیت محصول را از این داده‌ها آشکار سازند. همین محدودیت‌ها صنعت را به جست‌وجوی فناوری‌های هوشمند سوق داده است.

یادگیری ماشین، به‌عنوان یکی از شاخه‌های اصلی هوش مصنوعی، به کمک الگوریتم‌ها از داده‌های پرحجم الگو می‌آموزد و رابطه میان پارامترهای فرایند و اهداف کنترلی را مدل می‌کند [۱۳]. این قابلیت می‌تواند پیشران تحول هوشمند ریخته‌گری مداوم باشد. در فرایندی که چند میدان فیزیکی با یکدیگر کوپل شده‌اند، مدل‌های خطی متعارف دقت محدودی دارند؛ در مقابل، شبکه‌های چندلایه و روش‌های تجمیعی می‌توانند روابط غیرخطی را به‌خوبی برازش دهند و مبنایی برای کنترل دقیق فراهم کنند [۱۴]. ریخته‌گری مداوم به تغییر سریع پارامترها متناسب با شرایط عملیاتی نیاز دارد و قابلیت پاسخ‌گویی بلادرنگ برخی مدل‌های یادگیری ماشین برای این هدف مناسب است. همچنین، ادغام اطلاعات دما، دبی، تصاویر و سایر داده‌ها می‌تواند الگوهای ناشناخته را آشکار کند و نظارت بر کیفیت را جامع‌تر سازد.

در سال‌های اخیر چند مرور پژوهشی درباره کاربرد یادگیری ماشین در ریخته‌گری مداوم منتشر شده است. زونگ و همکاران [۱۵] عمدتاً روی عیوب تختال و فناوری تشخیص آن‌ها تمرکز کرده‌اند و پیش‌بینی ناهنجاری، بهینه‌سازی پارامترها و ویژگی مجموعه‌داده‌ها را پوشش نمی‌دهند. چمرنک و همکاران [۱۶] پژوهش خود را براساس دسته‌بندی الگوریتم‌ها و کاربردها سازمان داده‌اند، اما بیشتر به مرور کلی اصول روش‌ها و نمونه‌های منفرد پرداخته‌اند و چارچوب تحلیلی یکپارچه‌ای ارائه نکرده‌اند. علاوه‌براین، منابع مرورشده در آن پژوهش تا سال ۲۰۲۱ محدود است و پیشرفت‌های پس از ۲۰۲۲، مانند مدل‌های دوگانه فیزیک‌محور و داده‌محور، را شامل نمی‌شود. لیان و همکاران [۱۷] دستاوردهای تحلیل ذرات آخال غیرفلزی در فولادهای پیشرفته به کمک یادگیری ماشین را بررسی کرده‌اند، ولی به پایش هوشمند و بهینه‌سازی کیفیت در جریان ریخته‌گری نپرداخته‌اند. وارفولومیف و همکاران [۱۸] نیز بررسی خود را به آمار عیوب و الگوریتم‌های پایه محدود کرده و روش‌های نوپدیدی چون مدل‌های ترکیبی یادگیری عمیق را در بر نگرفته‌اند.

وجه تمایز مرور حاضر در سه موضوع است. نخست، چارچوبی نظام‌مند از مبانی کاربرد، حوزه‌های اصلی، مقایسه مجموعه‌داده‌ها و الگوریتم‌ها، چالش‌ها و چشم‌اندازها ارائه می‌کند؛ فصل مستقلی نیز به مقایسه

استاندارد مجموعه‌داده‌ها و الگوریتم‌ها اختصاص داده شده تا نبود معیار ارزیابی یکپارچه تا حدی جبران شود. دوم، نتایج نوین سال‌های ۲۰۲۲ تا ۲۰۲۵ و نمونه‌های صنعتی ۲۰۲۴ و ۲۰۲۵ را در بر می‌گیرد و از نظر زمانی به تحولات اخیر نزدیک است. سوم، بر استفاده عملی در صنعت تأکید دارد: چالش‌های مهندسی را با توجه به شرایط واقعی کارگاه تحلیل و راهکارها را در قالب یک سامانه فنی جامع، از ایمنی تولید تا کیفیت محصول و بهره‌وری، دسته‌بندی می‌کند.

برای تضمین جامعیت، روزآمدی و دقت علمی این مرور، جست‌وجوی چندبعدی منابع و غربالگری مرحله‌ای انجام شده است. پایگاه‌های بین‌المللی Web of Science Core Collection، Scopus، IEEE Xplore، SpringerLink و Elsevier ScienceDirect و نیز پایگاه‌های چینی CNKI، VIP و Wanfang بررسی شده‌اند. نشریات تخصصی صنعت فولاد، از جمله Ironmaking & Steelmaking، Steel Research International، Iron and Steel و China Metallurgy و مجموعه مقالات کنفرانس IEEE درباره انفورماتیک صنعتی نیز در دامنه جست‌وجو بوده‌اند. بازه منابع، ۳۰ سال گذشته را شامل می‌شود؛ با این حال، دستاوردهای نوین ۲۰۲۰ تا ۲۰۲۵ در اولویت قرار گرفته‌اند.

جست‌وجو با ترکیبی از اصطلاحات موضوعی و کلیدواژه‌ها صورت گرفته است. واژه‌ها در سه گروه جای می‌گیرند: اصطلاحات مربوط به ریخته‌گری مداوم، مانند mold، continuous casting و secondary cooling؛ اصطلاحات یادگیری ماشین، مانند deep learning، machine learning و CNN؛ و اصطلاحات حوزه‌های کاربرد، مانند anomaly prediction و defect detection. ترکیب این گروه‌ها شناسایی دقیق‌تر مطالعات مرتبط را ممکن ساخته است.

بر این مبنا، مقاله حاضر پیشرفت‌های یادگیری ماشین در ریخته‌گری مداوم را در سه حوزه بررسی می‌کند. در پیش‌بینی ناهنجاری، حوادثی مانند بیرون‌ریزی مذاب، نوسان سطح مذاب قالب و گرفتگی نازل بررسی می‌شوند. در تشخیص عیوب کیفی، منطق استفاده از یادگیری ماشین برای شناسایی، ارزیابی کمی و تحلیل علل ترک، جدایش مرکزی و آخال تشریح می‌شود. در بهینه‌سازی فرایند، سرعت ریخته‌گری، شدت سرمایش ثانویه و پارامترهای عملیاتی قالب محور بحث‌اند و اهداف کنترلی، داده‌های موردنیاز و معیار انتخاب الگوریتم برای هرکدام معرفی می‌شوند. روند تحول از کنترل یک پارامتر به بهینه‌سازی هماهنگ چندهدفه و از مدل‌های منفرد به مدل‌های تجمیعی و سپس مدل‌های دوگانه متکی بر سازوکار و داده، بررسی می‌شود. در نهایت، مسیرهای پژوهشی و کاربردی آینده برای استقرار عمیق‌تر یادگیری ماشین و ارتقای هوشمندی صنعت فولاد ترسیم می‌گردد.

۲. کاربرد یادگیری ماشین در فرایند ریخته‌گری مداوم

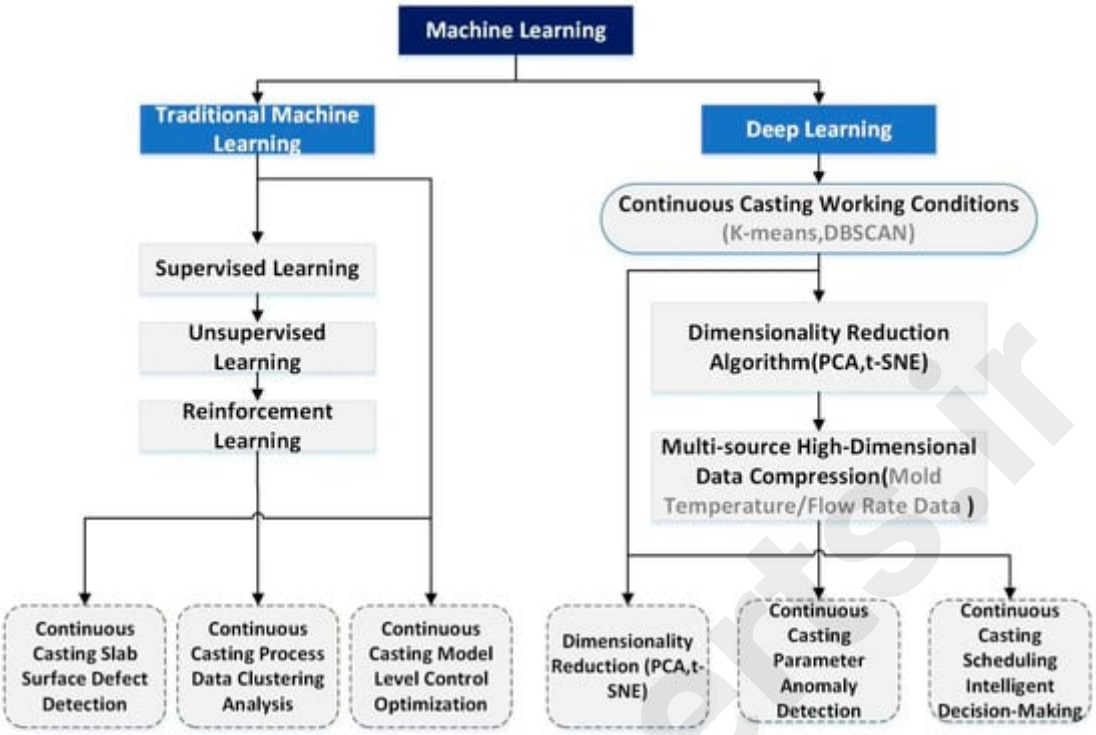
۲.۱. مراحل اصلی فرایند و اهداف کلیدی کنترل

ریخته‌گری مداوم پنج مرحله اصلی دارد: تخلیه فولاد از پاتیل، عملیات متالورژیکی تاندیش، انجماد در قالب، سرمایش ثانویه و صاف‌کاری و برش. در هر مرحله با تنظیم پارامترهای کلیدی، اهداف ایمنی، بهره‌وری و کیفیت دنبال می‌شوند [۱۹، ۲۰]؛ هرچند میان این اهداف تعارض‌هایی نیز وجود دارد. برای مثال، افزایش سرعت ریخته‌گری ممکن است نوسان سطح مذاب را تشدید کند و از همین رو بهینه‌سازی هماهنگ چندهدفه ضرورت می‌یابد. در مرحله تخلیه پاتیل، انتقال و حفظ دمای فولاد مذاب و جلوگیری از افت دما و اکسیداسیون ثانویه مهم است. تاندیش، جریان مذاب را تعدیل می‌کند و با کمک به حذف آخال‌ها، یکنواختی دما را حفظ می‌کند. انجماد در قالب، پوسته اولیه را شکل می‌دهد و مستلزم کنترل ضخامت پوسته و نوسان سطح مذاب است. سرمایش ثانویه باید پوسته را ضخیم‌تر کند، انجماد را کامل سازد و مانع ترک شود. در مرحله صاف‌کاری و برش، محصول با طول تعیین‌شده و ابعاد دقیق بریده و از نظر کیفیت غربال می‌شود. جدول ۱، ویژگی‌ها و اهداف کنترلی این مراحل را مقایسه می‌کند [۲۱–۲۴].

مرحله	وظیفه اصلی	پارامترهای کلیدی	هدف کنترلی
تخلیه پاتیل	انتقال فولاد مذاب و حفظ دما	دمای پیش‌گرم پاتیل؛ زمان ریخته‌گری	افت دمای مذاب کمتر از ۵ درجه سانتی‌گراد بر ساعت؛ جلوگیری از اکسیداسیون ثانویه
متالورژی تاندیش	متعادل‌سازی جریان مذاب و حذف آخال	دمای تاندیش؛ دبی آرگون؛ زمان ماند	حذف بیش از ۸۰٪ آخال‌ها؛ یکنواختی دما در محدوده ±۳ درجه سانتی‌گراد
انجماد در قالب	تشکیل پوسته اولیه تختال	سطح مذاب؛ دبی آب سرمایش؛ پارامترهای نوسان قالب	ضخامت پوسته حداقل ۱۰ میلی‌متر هنگام خروج از قالب؛ نوسان سطح کمتر از ±۳ میلی‌متر
سرمایش ثانویه	افزایش ضخامت پوسته و تکمیل انجماد	دبی آب در هر ناحیه؛ شدت سرمایش	جلوگیری از ترک (تنش حرارتی کمتر از تنش بحرانی)؛ تکمیل انجماد پیش از صاف‌کاری
صاف‌کاری و برش	برش محصول به طول معین و کنترل کیفیت	دمای صاف‌کاری؛ طول برش	دمای صاف‌کاری بیشتر از ۹۰۰ درجه سانتی‌گراد برای فولاد کم‌کربن؛ خطای طول کمتر از ±۵ میلی‌متر

۲.۲. دسته‌بندی الگوریتم‌های مناسب برای ریخته‌گری مداوم

متناسب با نیازهای گوناگون خط تولید، الگوریتم‌های یادگیری ماشین مورد استفاده در ریخته‌گری مداوم را می‌توان به دو گروه کلی یادگیری ماشین متعارف و یادگیری عمیق تقسیم کرد [۱۶]. طبقه‌بندی این الگوریتم‌ها در شکل ۱ آمده است.



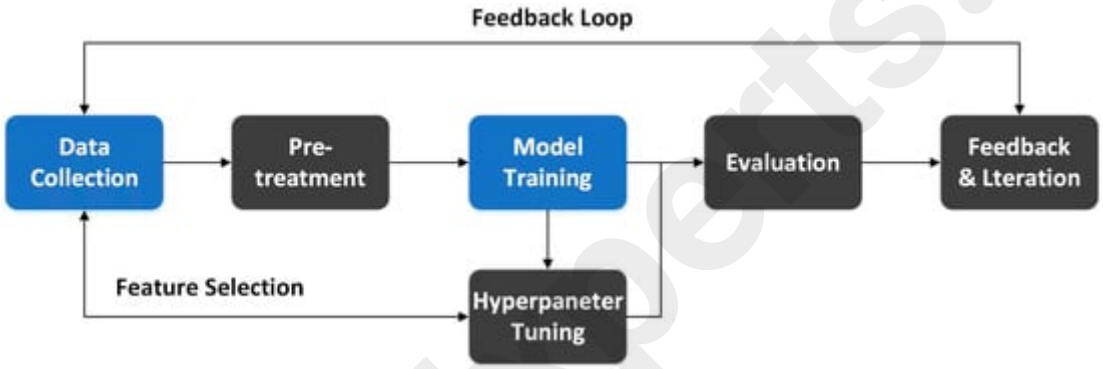
شکل 1. دسته‌بندی الگوریتم‌های یادگیری ماشین متناسب با کاربردهای ریخته‌گری مداوم. منبع: Wang و همکاران، Metals (2025)، DOI: 10.3390/met15121383، مجوز CC BY 4.0.

در گروه روش‌های متعارف، یادگیری بدون‌ناظر با ابزارهایی مانند K-Means و DBSCAN شرایط عملیاتی را خوشه‌بندی می‌کند و روش‌هایی مانند PCA ابعاد داده‌های پرمتغیر را کاهش می‌دهند. یادگیری باناظر با تکیه بر داده‌های برچسب‌خورده برای شناسایی عیب و پیش‌بینی بیرون‌ریزی فولاد به کار می‌رود. یادگیری تقویتی، از طریق تعامل با محیط تولید، راهبردهای پویایی مانند کنترل سطح مذاب و تنظیم سرعت کشش را بهبود می‌بخشد. برای مسائل پیچیده‌تر می‌توان از یادگیری عمیق استفاده کرد: CNN برای شناسایی عیوب در تصاویر محصول ریختگی؛ LSTM و RNN برای استخراج الگوهای زمانی و هشدار زودهنگام؛ و Transformer برای کشف وابستگی میان میدان‌های فیزیکی مختلف و کمک به تصمیم‌گیری درباره بهینه‌سازی فرایند. چنین مدل‌هایی همچنین در زمان‌بندی تولید و تشخیص وضعیت غیرعادی تجهیزات کاربرد دارند [۲۵–۲۸].

۲.۳. فرایند کامل مدل‌سازی داده‌محور در ریخته‌گری مداوم

گردش کار مدل‌سازی داده‌محور در شکل ۲ نشان داده شده است. نخست باید داده‌های مهم سراسر فرایند جمع‌آوری شوند: پارامترهای فرایندی، مانند دمای تاندیش، سرعت ریخته‌گری و ترکیب مذاب؛ وضعیت تجهیزات، مانند دمای کار و فشار؛ کیفیت محصول، مانند عیوب و ابعاد؛ و اطلاعات محیطی، مانند دما و رطوبت سالن. بهنگام‌بودن، کامل‌بودن و صحت داده‌ها در این مرحله اهمیت دارند. سپس پیش‌پردازش انجام می‌شود: داده‌ها پاک‌سازی و نقاط پرت حذف می‌شوند؛ مقادیر گمشده تخمین زده می‌شوند؛ مقیاس متغیرها استاندارد

یا نرمال می‌شود؛ و داده‌های بدون ساختار، در صورت نیاز، به ساختار قابل‌پردازش تبدیل می‌گردند. مرحله بعد انتخاب ویژگی است؛ با تحلیل همبستگی، متغیرهای کم‌ارتباط حذف می‌شوند، با مدل‌های درختی و ANOVA اهمیت متغیرها سنجیده می‌شود و با PCA و اطلاعات متقابل، ویژگی‌های تکراری کنار می‌روند تا پیچیدگی مدل کاهش یابد. سپس با توجه به هدف، مدل‌هایی چون SVM یا CNN انتخاب می‌شوند؛ داده‌ها به مجموعه آموزش، اعتبارسنجی و آزمون تقسیم می‌گردند؛ ساختار مدل، تابع زیان و بهینه‌ساز تعیین می‌شود؛ و پارامترها در تکرارهای متوالی به‌روزرسانی می‌شوند تا خروجی به مقادیر واقعی نزدیک شود. در پایان، با روش‌هایی مانند جست‌وجوی شبکه‌ای و بهینه‌سازی بیزی و شاخص‌های مجموعه اعتبارسنجی، مانند دقت و RMSE، ابرپارامترهایی چون نرخ یادگیری و اندازه کرنل کانولوشن تنظیم می‌شوند [۲۹–۳۱].



شکل 2. گردش کار مدل‌سازی داده‌محور در ریخته‌گری مداوم. منبع: Wang و همکاران، Metals (2025)، DOI: 10.3390/met15121383، مجوز CC BY 4.0.

این گردش کار عمومی در سه حوزه اصلی مطرح‌شده در بخش‌های ۳، ۴ و ۵ ویژگی‌های متفاوتی پیدا می‌کند و انتخاب نوع داده و الگوریتم به نیاز کاربرد، ویژگی داده و محدودیت‌های صنعتی وابسته است. **پیش‌بینی ناهنجاری** عمدتاً با سری‌های زمانی و مدل‌های طبقه‌بندی سر و کار دارد؛ چون رویدادهایی مانند چسبندگی پوسته و نوسان سطح مذاب در طول زمان شکل می‌گیرند و نشانه‌های اولیه آن‌ها را باید از تغییر ناگهانی دما و رانش پارامترها شناسایی کرد. SVM و LSTM می‌توانند مرز وضعیت عادی و غیرعادی را بیاموزند، طبقه‌بندی دودویی یا درجه‌بندی خطر انجام دهند و در عین حذف نویز، الزامات پاسخ سریع را رعایت کنند. **بازرسی کیفیت** به داده‌های تصویری و شبکه‌های عمیق متکی است؛ زیرا شکل، اندازه و جزئیات مکانی عیب در تصاویر نمایان می‌شود. مدل‌های CNN و CNN-LSTM ویژگی‌ها را به‌صورت سلسله‌مراتبی استخراج می‌کنند، وابستگی به طراحی دستی ویژگی را کاهش می‌دهند و قادرند حجم بزرگی از تصاویر را سریع پردازش کنند. **بهینه‌سازی پارامترها** از مدل‌های یادگیری ماشین به‌عنوان مدل جانشین سریع بهره می‌گیرد؛ زیرا شبیه‌سازی عددی سنتی اغلب برای تنظیم پویا بیش‌ازحد کند است. مدل آموزش‌دیده می‌تواند رابطه دقیق میان پارامترها و هدف را بیاموزد و در حلقه بهینه‌سازی، در مقیاس میلی‌ثانیه پاسخ دهد. سبک‌بودن برخی از این مدل‌ها، اجرای آن‌ها را حتی روی سخت‌افزارهای صنعتی کم‌توان ممکن می‌کند و به بهینه‌سازی سریع در حضور اهداف متعارض کمک

می‌رساند.

۳. کاربرد یادگیری ماشین در پیش‌بینی ناهنجاری‌های ریخته‌گری مداوم

ریخته‌گری مداوم تحت تأثیر تغییر ترکیب فولاد مذاب، وابستگی متقابل پارامترهای فرایندی و تغییر وضعیت تجهیزات قرار دارد؛ به همین دلیل، در معرض مشکلات ایمنی و کیفی مانند بیرون‌ریزی مذاب، ترک سطحی و نوسان غیرعادی سطح مذاب است. روش‌های سنتی تشخیص ناهنجاری بر پایه حدود آستانه تجربی، نشانه‌های پنهان ناشی از برهم‌کنش چند متغیر را به‌خوبی تشخیص نمی‌دهند؛ پیش‌بینی آن‌ها دیرهنگام است و هشدار اشتباه زیادی تولید می‌کنند. یادگیری ماشین می‌تواند از داده‌های گسترده تولید، الگوهای زمانی و مکانی رویدادهای غیرعادی و چگونگی تحول آن‌ها را استخراج کند و مبنایی برای پیش‌بینی دقیق و زودهنگام فراهم آورد. درباره سه مسئله مهمِ بیرون‌ریزی فولاد از قالب، نوسان سطح مذاب و گرفتگی نازل، مطالعات متعددی انجام شده است.

۳.۱. پیش‌بینی بیرون‌ریزی مذاب (Breakout)

بیرون‌ریزی مذاب ناشی از چسبندگی پوسته (*sticker breakout*) از خطرناک‌ترین حوادث ریخته‌گری مداوم است. در این وضعیت پوسته جامدشونده به صفحه مسی قالب می‌چسبد و با حرکت شمش در حین ریخته‌گری پاره می‌شود؛ در نتیجه فولاد مذاب به بیرون راه می‌یابد. دشواری اصلی پیش‌بینی، کشف تغییرات بسیار ضعیف دما در آغاز چسبندگی پوسته است. هی و همکاران [۳۲] با تحلیل سری زمانی دمای ترموکوپل‌های قالب دریافتند که پیش از بیرون‌ریزی، دما ابتدا به‌سرعت بالا می‌رود و سپس کاهش می‌یابد. آن‌ها بر این اساس شبکه عصبی GA-BP ساختند و با افزودن قواعد منطقی به آستانه خروجی، پیش‌بینی بیرون‌ریزی را مؤثرتر کردند؛ به‌ویژه مشکل گیرکردن شبکه BP متعارف در بهینه محلی را کاهش دادند. وانگ و همکاران [۳۳] همبستگی مکانی چند ترموکوپل را لحاظ کردند و مدلی برای روند زمانی یک ترموکوپل و مدلی دیگر برای ویژگی‌های مکانی چند ترموکوپل ساختند. مدل تک‌حسگر تغییر ناگهانی دما را ردیابی می‌کند و مدل چندحسگر تفاوت گرادیان دمای حسگرهای مجاور را می‌سنجد؛ سپس با تلفیق وزن‌دار دو خروجی، دقت افزایش می‌یابد و هشدار کاذب ناشی از خرابی یک ترموکوپل کاهش پیدا می‌کند. دوان و همکاران [۳۴] نیز برای اندازه‌گیری شباهت سری‌های زمانی دما، الگوریتم هم‌ترازی زمانی پویا (DTW) را به‌جای فاصله اقلیدسی به کار گرفتند تا مدل در شرایط پیچیده مقاومت بیشتری داشته باشد. لیو و همکاران [۳۵] از دمای ثبت‌شده با ترموکوپل قالب، نگاشت حرارتی دما و نرخ تغییر دما را تهیه و روش تشخیص دیداری ارائه کردند. در **شکل ۳**، بخش «الف» نقشه حرارتی فعلی صفحه مسی و بخش «ب» نقشه مربوط به چند ثانیه پیش را برای مقایسه نشان می‌دهد. رنگ‌ها

نماینده دماهای متفاوت و توزیع دمای سطح قالب‌اند. بخش «ج»، نقشه حرارتی نرخ تغییر دماست که ناحیه غیرعادی Vشکل، مرتبط با احتمال بیرون‌ریزی، را آشکار می‌کند. این روش می‌تواند نظارت تصویری و هوشمند بر قالب را تقویت کند و دقت هشدار را افزایش دهد.

شکل 3 (تصویر بازنشر نشده). مقایسه تصویری تشخیص بیرون‌ریزی مذاب از ریخته‌گری مداوم؛ بازنشر از مرجع [۳۵]. اعتبار: Informa UK Limited (2015). به علت روشن‌نبودن مجوز بازنشر مستقل، تصویر در ترجمه درج نشده است؛ مشاهده در مقاله اصلی ناشر.

در حوزه ایمنی ریخته‌گری مداوم، هدف اصلی مدل‌های یادگیری ماشین، هشدار زودهنگام با خطای کم و مقاومت زیاد در برابر اختلال است و به‌تدریج راهکارهایی با چند الگوریتم و داده‌های تلفیقی شکل گرفته‌اند. مدل‌های کلاسیکی مانند GA-BP و مدل‌های ادغام ویژگی‌های چند ترموکوپل با استفاده از ویژگی‌های زمانی و حذف وابستگی به یک حسگر، اطمینان پیش‌بینی را بالا می‌برند. مدل‌های پیشرفته‌تری مانند ACWGAN-GP و SVM همراه PCA تطبیقی، در شناسایی نشانه‌های ضعیف و کنترل نوسان داده‌ها توانمندترند. با این حال، رانش حسگر و اعوجاج داده، تعمیم‌ناپذیری میان گریدهای فولادی و ماشین‌های مختلف و دشواری برقراری توازن میان زمان پیش‌آگاهی و اطمینان هشدار همچنان مسئله‌ساز است. توسعه مدل‌های چندبعدی، یادگیری آنلاین و بانک‌های استاندارد نمونه‌های غیرعادی می‌تواند به رفع این محدودیت‌ها کمک کند.

۳.۲. تشخیص نوسان سطح مذاب قالب

کنترل پایدار سطح مذاب در قالب برای تداوم بی‌وقفه ریخته‌گری ضروری است. نوسان غیرعادی سطح، به‌ویژه در سرعت‌های بالای ریخته‌گری، خطر ورود سرباره به مذاب و بیرون‌ریزی فولاد را افزایش می‌دهد. روش‌های کنترل سنتی در برابر اغتشاشات پویای شرایط پیچیده کارگاهی محدودیت دارند. مدل پیش‌بینی مبتنی بر یادگیری عمیق می‌تواند با تحلیل داده‌های گسترده فرایند، رابطه‌های عمیق میان پارامترهای تولید و نوسان سطح را شناسایی کند و ویژگی‌های آن‌ها را در حوزه فرکانس نیز بررسی نماید. به این ترتیب، پیش‌بینی سریع و دقیق نوسان لحظه‌ای سطح مذاب ممکن می‌شود؛ کنترل فرایند بهبود می‌یابد، زیان ناشی از نوسانات کاهش پیدا می‌کند و کیفیت تختال و بهره‌وری بالا می‌رود.

سان و همکاران [۳۶] شبکه عصبی پیش‌خور را با بهینه‌سازی بیزی و اعتبارسنجی متقاطع تودرتو ترکیب کردند تا نوسان سطح قالب را با داده‌های صنعتی کم‌نمونه پیش‌بینی کنند. این روش، بیش‌برازش را کاهش داد و از نظر پایداری و دقت از مدل‌های متعارف بهتر عمل کرد. همچنین نقش پارامترهای فرایندی را روشن کرد و به کمک تحلیل تصویری، محدوده عملیاتی باثبات و راهنمایی روشن برای بهینه‌سازی در کارخانه ارائه داد. **شکل ۴-الف** گردش کار BO-NCV-FNN و بخش «ب» ساختار شبکه را نشان می‌دهد. سرعت ریخته‌گری، میزان گاز آرگون،

ضخامت سرباره محافظ و فاصله از نازل غوطه‌ور، متغیرهای ورودی شبکه‌اند. ساختار ساده و تعداد کم پارامترها به همگرایی سریع مدل با نمونه‌های کم کمک می‌کند. در این شکل، H_ave نوسان میانگین زمانی سطح مذاب و h ضخامت اولیه لایه سرباره است. بخش «ج» نیز برازش مقدار واقعی و پیش‌بینی‌شده را نشان می‌دهد؛ تراکم نقاط نزدیک خط مبنای ۴۵ درجه و روشن‌تر بودن رنگ، نشانه برازش بهتر است.

شکل 4 (تصویر بازنشر نشده). روش‌های پیش‌بینی BO-NCV-FNN: گردش کار، ساختار شبکه و نمودار پراکندگی چگالی هسته؛ بازنشر از [۳۶]. اعتبار: Springer Nature (2025). به علت روشن‌نبودن مجوز بازنشر مستقل، تصویر در ترجمه درج نشده است؛ مشاهده در مقاله اصلی ناشر.

سو و همکاران [۳۷] برای افزایش دقت پیش‌بینی سطح مذاب، تجزیه مد متغیر (VMD) را با رگرسیون بردار پشتیبان (SVR) تلفیق کردند. ابتدا سیگنال سطح با VMD و تجزیه مد تجربی پردازش شد، سپس نویز با آستانه‌گذاری موجک حذف و در نهایت پیش‌بینی با SVR انجام شد. ضریب همبستگی مدل ترکیبی ۳٪ افزایش یافت و RMSE آن ۳۶٫۱٪ کاهش پیدا کرد؛ مقاومت مدل در برابر نویز نیز بهتر شد. هی و همکاران [۳۸] برای مقابله با عوامل مزاحم متعدد، ساختار شبکه کانولوشنی را با الگوریتم ژنتیک بهینه کردند. از میان ۱۳۸ پارامتر تولید، ۱۵ ویژگی مهم انتخاب شد و نرخ موفقیت پیش‌بینی نوسان سطح از مدل‌هایی مانند جنگل تصادفی، SVM و پرسپترون چندلایه بیشتر بود. تیریان و همکاران [۳۹] سامانه کنترل تطبیقی ریخته‌گری مداوم را با ترکیب شبکه عصبی و منطق فازی ارائه کردند که قادر به شناسایی نوسان سطح و خطاهای دماست. لی و همکاران [۴۰] نیز با راهبرد تجزیه و بازسازی، سیگنال پیچیده حسگر جریان گردابی را با EMD پردازش و برای پیش‌بینی به SVR وارد کردند و دقت مناسبی به دست آوردند.

۳.۳. شناسایی گرفتگی نازل غوطه‌ور (SEN)

گرفتگی نازل ورودی غوطه‌ور (*Submerged Entry Nozzle* یا SEN) از عوامل مهم اختلال در استمرار ریخته‌گری مداوم است. این پدیده جریان فولاد را غیریکنواخت می‌کند و ممکن است جدایش ترکیبی در تختال ایجاد کند؛ در وضعیت شدید حتی خطر شکست و توقف فرایند وجود دارد. مشاهده انسانی و آستانه‌های تجربی نمی‌توانند روند تدریجی ایجاد گرفتگی را به‌موقع شناسایی کنند. یادگیری ماشین با تحلیل پویای سری‌های زمانی و مدل‌کردن روابط غیرخطی، نشانه‌های گرفتگی را از پارامترهای فرایند و ترکیب فولاد استخراج می‌کند و امکان برآورد کمی خطر و هشدار زودهنگام را فراهم می‌آورد [۴۱].

وانگ و همکاران [۴۲] برای پیش‌بینی شاخص گرفتگی QI که پایش مستقیم و بلادرنگ آن دشوار است، مدلی مبتنی بر LSTM پیشنهاد کردند. دوازده پارامتر زمانی، از جمله سرعت ریخته‌گری، اختلاف دمای مذاب و دبی آرگون، به مدل داده شد. مدل توانست تفاوت توزیع شاخص گرفتگی در گریدهای گوناگون فولاد را به‌صورت

دیداری نشان دهد و مبنایی کمی برای درجه‌بندی خطر ایجاد کند. گیراسه و همکاران [۴۳] شاخص‌هایی برای اندازه‌گیری شدت گرفتگی تعریف کردند و با استفاده از سرعت خروج فولاد از نازل و افت فشار، معیارهایی چون نرخ گرفتگی و یکنواختی جریان را به دست آوردند تا اهداف مشخصی برای مدل‌های پیش‌بینی فراهم شود. دینیز و همکاران [۴۴] مدلی مبتنی بر شبکه عصبی عمیق (DNN) ساختند که بدون نیاز به دانش پیشینی متالورژی، از هشت پارامتر عملیاتی بلادرنگ، مانند نوسان سطح قالب و تعداد دفعات تنظیم موقعیت استاپر، استفاده می‌کرد. مدل در آزمون‌ها به **بازخوانی ۹۸٫۷۵٪** و **دقت ۹۷٫۸٪** رسید و توانست نشانه‌های ابتدایی گرفتگی را شناسایی کند تا فرصت کافی برای اقدام اصلاحی باقی بماند. کوته و همکاران [۴۵] سامانه استنتاج عصبی-فازی تطبیقی (ANFIS) را با LSTM ترکیب کردند و مدلی برای پیش‌بینی شاخص گرفتگی ساختند. این روش در مقایسه با راهکارهای سنتی روند گرفتگی را زودتر آشکار کرد و دقت و سرعت پیش‌بینی را افزایش داد. **شکل ۵-الف** شاخص قابلیت ریخته‌گری (CI)، برآورد ANFIS و پیش‌بینی LSTM را برای چند ذوب نشان می‌دهد؛ رنگ‌های سبز، زرد و قرمز به‌ترتیب وضعیت عادی، هشدار و گرفتگی را مشخص می‌کنند. بخش «ب»، نتیجه پیش‌بینی LSTM را در یک پنجره زمانی، از جمله پنجره لغزان حدود ۲۴ دقیقه‌ای، نمایش می‌دهد و برای مداخله پیش‌دستانه مفید است.

شکل 5 (تصویر بازنشر نشده). پاسخ برآوردی و پیش‌بینی مدل LSTM در پنجره لغزان حدود ۲۴ دقیقه؛ بازنشر از [۴۵]. اعتبار: حق نشر اثر ثالث در منبع مشخص شده است. به علت روشن‌نبودن مجوز بازنشر مستقل، تصویر در ترجمه درج نشده است؛ مشاهده در مقاله اصلی ناشر.

بر پایه مطالعات منتشرشده، نمونه‌های شاخص کاربرد یادگیری ماشین در پیش‌بینی شرایط غیرعادی ریخته‌گری مداوم در جدول ۲ گردآوری شده‌اند.

پژوهشگران	الگوریتم	کاربرد	داده ورودی	شاخص ارزیابی	نتیجه و بهبود حاصل	مرجع
He و همکاران	GA-BPNN	پیش‌بینی بیرون‌ریزی	سیگنال سطح مذاب قالب، اندازه‌گیری‌شده با حسگر جریان گردابی	CC، RMSE، MAE، MAPE	ادغام قواعد منطقی برای افزایش اطمینان پیش‌بینی و هشدار زودهنگام بیرون‌ریزی	[32]
Duan و همکاران	DBSCAN-DTW	پیش‌بینی بیرون‌ریزی	دمای قالب و پارامترهای نوسان، از ترموکوپل‌ها و حسگر لرزش	Accuracy، Recall، F1، نرخ هشدار کاذب	خوشه‌بندی و هم‌ترازی زمانی پویا برای افزایش اطمینان داده و بهبود ورودی پیش‌بینی	[34]
Sun و همکاران	FNN	نوسان سطح مذاب	ترکیب شیمیایی فولاد و ابعاد محصول، از آنالیزور ترکیب و ابزار اندازه‌گیری	RMSE، R^2، MAE	پیش‌بینی مؤثر نوسان سطح با شبکه پیش‌خور و پشتیبانی از کنترل پایدار سطح	[36]

پژوهشگران	الگوریتم	کاربرد	داده ورودی	شاخص ارزیابی	نتیجه و بهبود حاصل	مرجع
Su و همکاران	VMD-SVR	نوسان سطح مذاب	دبی آب سرمایش قالب و دمای صفحه مسی، از دبی‌سنج و ترموکوپل	Precision، Recall، Accuracy، MSE	پردازش سیگنال با VMD و افزایش دقت SVR برای تنظیم سطح مذاب	[37]
He و همکاران	GA-CNN	نوسان سطح مذاب	سری زمانی سرعت ریخته‌گری و سطح تاندیش از حسگرهای سرعت و سطح	MAPE، RMSE، CC	بهینه‌سازی ساختار CNN با الگوریتم ژنتیک و سازگاری بهتر با نوسان سیگنال	[38]
Lei و همکاران	EMD-SVR-GA	نوسان سطح مذاب	سری زمانی سطح قالب، عرض، فشار و دبی آرگون، موقعیت استاپر و …	NRMSE	ترکیب مزیت الگوریتم‌ها برای پایداری و دقت بیشتر پیش‌بینی سطح	[40]
Wang و همکاران	LSTM	گرفتگی نازل	میزان بازشدگی دریچه کشویی، سطح قالب، سرعت کشش، وضعیت تاندیش	Accuracy، Precision، Recall، F1، MCC	پیش‌بینی شاخص گرفتگی QI برای ۴۸ ثانیه آینده و نمایش توزیع شاخص	[42]
Diniz	DNN	گرفتگی نازل	ترکیب مذاب (Al، Si، Ca، Mn، S و …) و موقعیت استاپر	RMSE	طبقه‌بندی دودویی براساس پارامترهای عملیاتی، بدون اتکا به دانش پیشینی متالورژی	[44]
Kuthe و همکاران	ANFIS-LSTM	گرفتگی نازل	دمای صفحه مسی قالب از آرایه ترموکوپل	عملکرد طبقه‌بندی مدل (تفکیک چسبندگی واقعی/کاذب)	تعیین سهم عناصر Al، Ca و Si در گرفتگی و پیش‌بینی قابلیت ریخته‌گری در ۲۴ دقیقه آینده	[45]
Wang و همکاران	ACWGAN-GP	پیش‌بینی بیرون‌ریزی	سطح قالب، سرعت کشش و سیگنال کنترل استاپر تاندیش	MSE	ادغام شبکه مولد تخاصمی و تشخیص تصویری برای کشف نشانه‌های پیش‌درآمد بیرون‌ریزی	[46]
Salah و همکاران	SVM	پیش‌بینی بیرون‌ریزی	۹ پارامتر کلیدی؛ دمای مذاب تاندیش، دمای صفحه مسی قالب، سرعت و سطح مذاب و …	دقت پیش‌بینی، نرخ هشدار، MSE، RMSE، R^2	ترکیب PCA تطبیقی برای کنترل نوسان داده و بهبود تشخیص سطح غیرعادی و جلوگیری از بیرون‌ریزی	[47]
Shi و همکاران	LWOA-TSVR	پیش‌بینی بیرون‌ریزی	سری زمانی سطح مذاب قالب از حسگر	Precision، Recall، F1	افزایش تعمیم‌پذیری و پایداری پیش‌بینی خطر بیرون‌ریزی	[11]
Wu و همکاران	SAC	نوسان سطح مذاب	ترکیب شیمیایی مذاب (Ca، Al، S)، دمای تاندیش و زمان هم‌زدن	درصد صحت؛ درصد عدم‌تشخیص نامطلوب؛ هشدارهای کاذب	افزایش حساسیت تشخیص تغییر غیرعادی سطح مذاب و کمک به کنترل پایدار	[48]

پژوهشگران	الگوریتم	کاربرد	داده ورودی	شاخص ارزیابی	نتیجه و بهبود حاصل	مرجع
Vannucci و همکاران	NN-FL	گرفتگی نازل	تصاویر عیوب سطح تختال و پارامترهای فرایندی از حسگرهای تصویری و عملیاتی	Accuracy، IoU، Recall	بهبود طبقه‌بندی داده‌های ناهمگون و سازگاری مدل در شرایط حساس	[49]

مدل‌های یادگیری ماشین اکنون سه گروه اصلی ناهنجاری، یعنی چسبندگی پوسته و بیرون‌ریزی، نوسان سطح مذاب و گرفتگی نازل را با دقت نسبتاً بالایی پیش‌بینی می‌کنند، اما سازگاری با شرایط متفاوت و تعمیم‌پذیری همچنان چالش اصلی است. در پیش‌بینی بیرون‌ریزی، مدل باید تغییرات بسیار ظریف حسگرها را در محیط داغ شناسایی کند. هرچند GA-BP و LSTM هشدار زودهنگام تولید می‌کنند، خرابی چند ترموکوپل یا تغییر گرید فولاد می‌تواند دقت آن‌ها را کاهش دهد؛ ازاین‌رو لازم است ویژگی‌های مکانی و اصول متالورژیکی نیز لحاظ شوند. برای نوسان سطح، روش‌های ترکیبی VMD-SVR و GA-CNN دقت را افزایش می‌دهند، ولی آموزش روی شرایط عملیاتی یکنواخت، توان مقابله با تغییر ناگهانی گرید یا دبی آرگون را محدود می‌کند و هشدار کاذب ممکن است رخ دهد. در پیش‌بینی گرفتگی نازل، LSTM و ANFIS-LSTM روند گرفتگی و اثر ترکیب شیمیایی را استخراج می‌کنند، اما به سری زمانی پیوسته و پایدار وابسته‌اند و هنگام توقف ماشین یا قطع داده اطمینانشان کاهش می‌یابد. انتقال این مدل‌ها میان ماشین‌های مختلف نیز باید بهبود پیدا کند. در مجموع، حذف نویز، ادغام ویژگی‌های چندمنبعی و پیوند داده با سازوکارهای متالورژیکی باید به‌صورت مستمر تقویت شوند.

۴. کاربرد یادگیری ماشین در بازرسی کیفیت تختال

بازرسی کیفیت تختال از اجزای اصلی کنترل هوشمند ریخته‌گری مداوم است. ترک، جدایش و آخال از مهم‌ترین عیوبی هستند که کیفیت تختال را کاهش می‌دهند. سازوکار تشکیل این عیوب پیچیده است و به اثر هم‌زمان چند پارامتر وابسته است [۵۰–۵۳]. یادگیری ماشین به دلیل توان بالای برازش غیرخطی و استخراج الگو از داده‌ها، در شناسایی و پیش‌بینی دقیق هر سه گروه عیب مزیت دارد و مسیر فنی تازه‌ای برای کنترل کیفیت فراهم می‌کند [۱۸، ۵۴، ۵۵].

۴.۱. تشخیص عیوب ترک

ترک از رایج‌ترین عیوب تختال ریختگی است. یادگیری ماشین با کشف دقیق رابطه میان پارامترهای فرایندی و ایجاد ترک، به یکی از ابزارهای اصلی پیش‌بینی و تشخیص خطر ترک‌خوردگی تبدیل شده است.

زو و همکاران [۵۶] الگوریتم ترکیبی PCA و شبکه عصبی عمیق (DNN) را برای شناسایی ترک داخلی در تختال فولاد ML40Cr به کار گرفتند. اعتبارسنجی با نمونه‌های فراوان نشان داد دقت پیش‌بینی آن از روش‌هایی مانند

BP به‌مراتب بیشتر است و سرعت محاسبه نیز برای تصمیم‌گیری آنلاین کفایت می‌کند؛ ازاین‌رو راهکاری عملی برای کنترل ترک‌های داخلی به شمار می‌رود. ژانگ و همکاران [۵۷] جنگل تصادفی (RF) را با K-Means تلفیق کردند و در تشخیص ترک طولی سطح قالب به کار بردند. این روش ابعاد ویژگی‌های داده ترموکوپل را کاهش داد و در آزمون‌های گزارش‌شده، ترک‌های طولی را بدون هشدار اشتباه یا ازدست‌دادن مورد شناسایی کرد. لیو و همکاران [۵۸] برای تشخیص ترک طولی مدل PCA-PSO-XGBoost را ارائه کردند. کاهش ابعاد ویژگی‌ها و بهینه‌سازی پارامترها دقت بالایی ایجاد کرد، نرخ هشدار کاذب را پایین آورد و سازگاری مدل را در شرایط پیچیده خط بالا برد. کونگ و همکاران [۵۹] نیز شبکه BP اصلاح‌شده را برای شناسایی انواع ترک داخلی در قالب به کار گرفتند. آزمون روی مجموعه بزرگی از نمونه‌ها نشان داد نرخ شناسایی کل، به‌ویژه برای ترک‌های شدید، بالا و با رفتار واقعی تولید هم‌خوان است.

دوان و همکاران [۶۰] روش PCA-SVM را برای شناسایی ترک طولی در تختال فولاد کم‌کربن مطالعه کردند. پس از کاهش ابعاد داده‌های ترموکوپل قالب، مدل در آزمون‌ها دقت بالایی داشت و در شرایط خاصِ تقسیم داده، هیچ ترک طولی را از دست نداد. **شکل ۶** روند شناسایی ترک را از پایش دمای بلادرنگ تا خروجی مدل نشان می‌دهد: بخش «الف» منحنی دمای ترموکوپل‌ها و تغییر مشخصه از کاهش به افزایش را در دوره وقوع ترک ثبت می‌کند؛ بخش «ب» فاصله نمونه تا ابرصفحه تصمیم‌گیری را نشان می‌دهد که مقدار مثبت بیانگر دوره وقوع ترک و مقدار منفی نماینده وضعیت عادی است؛ بخش «ج» مقدار تابع تصمیم را نمایش می‌دهد که در آن ۱+ نشان‌دهنده ترک و ۱- نشان‌دهنده حالت عادی است. کنار هم قرار گرفتن این سه بخش، چگونگی تبدیل سیگنال دما به تصمیم تشخیص ترک و واکنش به‌موقع مدل را روشن می‌کند.

شکل 6 (تصویر بازنشر نشده). پیش‌بینی ترک طولی: دما، فاصله از ابرصفحه و مقدار تابع تصمیم؛ بازنشر از [۶۰]. اعتبار: John Wiley and Sons (2021). به علت روشن‌نبودن مجوز بازنشر مستقل، تصویر در ترجمه درج نشده است؛ مشاهده در مقاله اصلی ناشر.

پژوهش درباره عیوب ریخته‌گری از شناسایی ساده به زنجیره کاملِ تشخیص، برآورد کمی، تحلیل علت و بهینه‌سازی فرایند پیش رفته است. برای ترک، جدایش و آخال، مسیرهای فنی متناسبی شکل گرفته‌اند. کاهش ابعاد، تنظیم پارامترها و ادغام داده‌های چندمنبعی به افزایش دقت می‌انجامند و ابزارهایی مانند مقدارهای SHAP تحلیل تفسیرپذیر علل عیوب را ممکن می‌کنند. بااین‌حال، نامتوازن‌بودن داده‌ها، تحلیل ناکافی برهم‌کنش‌های پویای فرایند و دشواری حفظ هم‌زمان دقت و سرعت، استقرار صنعتی گسترده را محدود می‌کنند.

۴.۲. شناسایی عیوب جدایش

جدایش معمولاً به‌صورت جدایش مرکزی بروز می‌کند و نتیجه تفکیک انتخابی اجزا هنگام انجماد مذاب است. این پدیده در فولادهای پرکربن شدیدتر است و اغلب با عملیات حرارتی بعدی نیز به‌طور کامل برطرف نمی‌شود [۶۱–۶۵]. مدل‌های یادگیری ماشین با برقراری رابطه غیرخطی میان پارامترهای تولید و میزان جدایش، پیش‌بینی کمی و ارزیابی خطر را امکان‌پذیر کرده‌اند [۶۶–۶۸].

نیتو و همکاران [۶۹] ابتدا اثر پارامترهای ریخته‌گری بر جدایش مرکزی را بررسی کردند و سپس با روش اسپلاین تطبیقی چندمتغیره برای داده‌کاوی، مدلی برای پیش‌بینی جدایش مرکزی تختال ارائه دادند؛ نتایج با مقادیر واقعی هم‌خوانی مطلوبی داشت. همین پژوهشگران [۷۰] روش ترکیبی بهینه‌سازی ازدحام ذرات (PSO) و ماشین بردار پشتیبان (SVM) را نیز معرفی کردند. با تنظیم پارامترهای تابع کرنل و ضریب منظم‌سازی SVM به کمک PSO، توان برازش مدل برای پارامترهای شدیداً وابسته افزایش یافت و برآوردها به داده‌های واقعی نزدیک شدند. زو و همکاران [۷۱] برای تشخیص جدایش مرکزی کربن در تختال، مدل ماشین یادگیری حدی با منظم‌سازی (R-ELM) را پیشنهاد کردند. منظم‌سازی، خطر بیش‌برازش در داده‌های پُربعد را کاهش داد و **۹۴٪ پیش‌بینی‌ها در محدوده خطای ±۰٫۰۳** قرار گرفتند؛ در نتیجه، امکان راهنمایی بلادرنگ برای تنظیم فرایند فراهم شد. در **شکل ۷-الف** رابطه مقادیر هدف و مقادیر پیش‌بینی‌شده در رگرسیون R-ELM نشان داده می‌شود؛ بخش «ب» توزیع خطاهاست که عمدتاً حول محدوده ±۰٫۰۳ تمرکز دارد و به توزیع نرمال نزدیک است. بخش «ج» اثر فوق‌گرمایش و سرعت ریخته‌گری بر جدایش را نشان می‌دهد: رنگ تیره‌تر نماینده جدایش مرکزی کربن شدیدتر و رنگ روشن‌تر نماینده توزیع یکنواخت‌تر ترکیب است. بخش «د» شاخص جدایش مرکزی کربن (CSI) پیش‌بینی‌شده و آزمایشگاهی را برای ماشین‌های مختلف مقایسه می‌کند. این چهار نمودار، ارزیابی چندوجهی توان مدل را فراهم می‌کنند.

شکل 7 (تصویر بازنشر نشده). تشخیص جدایش با R-ELM: همبستگی، خطا، سطح پاسخ و مقایسه با نتایج آزمایشگاهی؛ بازنشر از [۷۱]. اعتبار: بازنشر اثر ثالث. به علت روشن‌نبودن مجوز بازنشر مستقل، تصویر در ترجمه درج نشده است؛ مشاهده در مقاله اصلی ناشر.

۴.۳. تشخیص آخال‌ها

آخال‌های موجود در تختال عمدتاً از پالایش ناکافی فولاد مذاب، ورود سرباره در قالب و عوامل مشابه ناشی می‌شوند. تعداد و پراکندگی آن‌ها به‌طور مستقیم بر چقرمگی و مقاومت خستگی فولاد اثر می‌گذارد [۷۲–۷۶]. یادگیری ماشین با ادغام داده‌های فرایندی از چند منبع، به شناسایی دقیق و پیش‌بینی کمی عیوب آخال کمک کرده است [۷۷، ۷۸].

کوته و همکاران [۴۵] روشی ترکیبی از ANFIS و LSTM ارائه کردند. بخش ANFIS امکان تحلیل تصویری تأثیر عناصر Al، Ca، Si و S بر تشکیل آخال را فراهم کرد و LSTM قابلیت ریخته‌گری را برای ۲۴ دقیقه آینده پیش‌بینی کرد؛ ازاین‌رو مبنایی برای تنظیم فرایند و کنترل آخال به دست آمد. ژانگ و همکاران [۷۹] جنگل تصادفی بهینه‌شده را معرفی کردند که با تلفیق چند دسته پارامتر از جمله نوسان سطح قالب و دبی آرگون و آموزش روی **۷۳۰۰ نمونه**، به دقت بالایی در تشخیص آخال رسید و ابزاری برای کنترل پاکیزگی فولاد مذاب فراهم کرد. جی و همکاران [۸۰] برای پیش‌بینی عیوب آخال در تختال، مدل BO-XGBoost با بهینه‌سازی بیزی را ساختند. پس از گزینش ویژگی‌های مهم با روش غربال‌گری ضرایب، مدل در شرایط نامتوازن‌بودن داده‌ها عملکرد خوبی داشت و راهنمایی روشنی برای بهینه‌سازی پارامترها ارائه کرد. ژو و همکاران [۸۱] برای تشخیص آخال در فولاد کورد، مدل ترکیبی CNN-LSTM را به کار گرفتند که تغییرات زمانی سرعت ریخته‌گری و سطح مذاب را دریافت می‌کند و با تلفیق اطلاعات تک‌متغیره و چندمتغیره، عیب را دقیق‌تر شناسایی می‌کند.

نمونه‌های پژوهشی کاربرد یادگیری ماشین در بازرسی کیفیت تختال در **جدول ۳** آمده است.

پژوهشگران	الگوریتم	کاربرد	نتیجه و بهبود حاصل	مرجع
Zou و همکاران	PCA-DNN	تشخیص ترک	دقت بیشتر از روش‌های سنتی و سرعت محاسبه مناسب تصمیم‌گیری آنلاین	[56]
Zhang و همکاران	RF-K-Means	تشخیص ترک	کاهش ابعاد ویژگی‌ها و دستیابی به نبود موارد ازدست‌رفته یا هشدار اشتباه در ترک طولی	[57]
Liu و همکاران	PCA-PSO-XGBoost	تشخیص ترک	دقت بالا و هشدار کاذب کم در شرایط پیچیده تولید	[58]
Kong و همکاران	BPNN اصلاح‌شده	تشخیص ترک	نرخ شناسایی کلی بالا به‌ویژه برای ترک شدید؛ سازگار با مشاهدات تولید	[59]
Duan و همکاران	PCA-SVM	تشخیص ترک	تشخیص دقیق ترک طولی با نبود موارد ازدست‌رفته در شرایط خاص	[60]
Nieto و همکاران	PSO-SVM	تشخیص جدایش	ضریب تعیین R^2 برابر با ۰٫۹۸ و امکان برآورد کمی درجه جدایش	[70]
Zou و همکاران	R-ELM	تشخیص جدایش	قرارگرفتن ۹۴٪ پیش‌بینی‌ها در خطای ±۰٫۰۳ و سازگاری با چند گرید	[71]
Kuthe و همکاران	ANFIS-LSTM	تشخیص آخال	نمایش اثر ترکیب شیمیایی، پیش‌بینی عملکرد و ارائه مبنای تنظیم فرایند	[45]
Zhang و همکاران	ORF	تشخیص آخال	ادغام پارامترهای چندبعدی و کمک به کنترل پاکیزگی مذاب	[79]
Ji و همکاران	BO-XGBoost	تشخیص آخال	گزینش ویژگی مهم، سازگاری با داده نامتوازن و کمک به بهینه‌سازی پارامترها	[80]
Zhou و همکاران	CNN-LSTM	تشخیص آخال	تلفیق پارامترهای متغیر در زمان و اطلاعات چندگانه برای افزایش بازخوانی تشخیص عیب	[81]

پژوهشگران	الگوریتم	کاربرد	نتیجه و بهبود حاصل	مرجع
Li و همکاران	BP	تشخیص جدایش	ساخت مجموعه ویژگی چندبعدی برای تحلیل و پیش‌بینی عیوب کیفی و بهینه‌سازی ریخته‌گری	[67]
Zhou و همکاران	CNN	تشخیص ترک	طبقه‌بندی ویژگی‌ها از سطح پایین تا بالا؛ روشی ساده، مؤثر و مقاوم برای عیوب سطح ورق فولادی	[82]

یادگیری ماشین امکان تشخیص دقیق‌تر و اندازه‌گیری کمی ترک، جدایش و آخال را فراهم کرده است، اما پیچیدگی عیوب و ماهیت داده‌ها اجرای صنعتی را دشوار می‌سازد. در تشخیص ترک، روش‌هایی چون PCA-DNN و RF-K-Means با کاهش ابعاد و یادگیری تجمیعی در بعضی آزمون‌ها به شناسایی بدون ازدست‌دادن نمونه رسیده‌اند؛ بااین‌حال، به دلیل تفکیک‌پذیری محدود داده‌ها و آرایش ترموکوپل‌ها، تشخیص ریزترک‌ها همچنان دشوار است و مدل باید برای گریدهای مختلف سازگارتر شود. در پیش‌بینی جدایش، PSO-SVM و R-ELM خطا را بهتر کنترل می‌کنند، ولی داده‌های ایستا نمی‌توانند پویایی کامل انجماد را بازنمایی کنند؛ بنابراین واکنش مدل در برابر جهش فوق‌گرمایش یا تغییر ناگهانی شدت سرمایش محدود است. شناسایی آخال نیز به نوسان ترکیب و نویز حسگر حساس است. مدل‌های ORF و CNN-LSTM اگرچه پارامترهای متعددی را ادغام می‌کنند، تغییر توزیع ویژگی‌ها میان گریدهای مختلف فولاد را به‌طور کامل لحاظ نکرده‌اند. در ادامه باید داده‌محوری با قیود سازوکارهای متالورژیکی تلفیق شود، افزایش داده برای عیوب کم‌نمونه بهبود یابد و مقاومت تشخیص در شرایط پیچیده بیشتر شود.

۵. کاربرد یادگیری ماشین در بهینه‌سازی پارامترهای ریخته‌گری مداوم

میان پارامترهای ریخته‌گری مداوم و کیفیت تختال، بهره‌وری تولید و ایمنی تجهیزات، وابستگی غیرخطی پیچیده‌ای وجود دارد. مدل‌های تجربی یا صرفاً فیزیکی متعارف نمی‌توانند به‌خوبی نیازهای بهینه‌سازی چندهدفه هماهنگ را برآورده کنند [۲۹، ۴۴، ۸۳]. یادگیری ماشین با استخراج الگوهای نهفته در داده‌های تولید و شناسایی پیوندهای پویای پارامترها، برای بهینه‌سازی سرعت ریخته‌گری، شدت سرمایش و عملکرد قالب به کار رفته است و حرکت از تنظیم منفرد به بهینه‌سازی چندهدفه را تسهیل کرده است [۸۴، ۸۵].

۵.۱. بهینه‌سازی سرعت ریخته‌گری

سرعت ریخته‌گری بر بهره‌وری و کیفیت محصول اثر اصلی دارد. هدف بهینه‌سازی، افزایش سرعت در کنار کاهش خطر عیب و حفظ سلامت پوسته جامدشده و پایداری سطح مذاب است. میریالا و همکاران [۸۶] مدل TRANSFORM-ANN را ارائه کردند که با استفاده از سرعت آب سرمایش ثانویه به‌عنوان ورودی، چارچوبی برای بهینه‌سازی هم‌زمان حداکثر سرعت ریخته‌گری، دمای خروجی شمش و کمینه‌کردن میزان بادکردگی (*bulging*)

فراهم می‌کند؛ مدلی که می‌تواند جانشین سریع برای تنظیم آنلاین پارامترها باشد. گرشوونیک و همکاران [۸۷، ۸۸] با استفاده از شبکه عصبی مصنوعی (ANN)، ترکیب شیمیایی فولاد، ابعاد محصول و داده‌های دبی آب سرمایش را ادغام کردند و ترکیب مناسب سرعت ریخته‌گری و شدت سرمایش ثانویه را برای هر گرید به دست آوردند. در مقایسه با تنظیم تجربی سنتی، نرخ قبولی کیفیت داخلی محصول به‌طور محسوسی بهبود یافت. لو و همکاران [۸۹] برای حل کندی محاسبات میدان دمای سه‌بعدی در روش‌های سنتی، مدل پیش‌بینی بلادرنگی از خودرمزگذار شبکه کانولوشنی و ترکیب‌گر پرسپترون چندلایه ارائه کردند و آن را با بهینه‌سازی بیزی همراه ساختند. این مدل میدان دمای سه‌بعدی را در مقیاس میلی‌ثانیه برآورد کرد و هنگام افزایش سرعت ریخته‌گری و خروج طول متالورژیکی از محدوده مطلوب، امکان تنظیم سریع پارامترها را فراهم آورد. **شکل ۸** چارچوب دوماژوله آن را نمایش می‌دهد: بالا سمت چپ، نتایج شبیه‌سازی میدان دما با رنگ‌های متناظر دما دیده می‌شود. داده‌های سه‌بعدی پس از پیش‌پردازش، با CNN به نمایش نهفته فشرده شده و برای ارزیابی بازسازی می‌شوند. رمزگذار پارامترها در سمت راست، **۹ پارامتر فرایندی** را به بردارهای نهفته سازگار تبدیل می‌کند. پس از تلفیق بردارهای دو ماژول، رمزگشا میدان دمای سه‌بعدی پیش‌بینی‌شده را تولید می‌کند. در این چارچوب، CWFR مخفف دبی آب سرمایش است. ترکیب سرعت پاسخ میلی‌ثانیه‌ای و دقت، مدل را برای کنترل صنعتی بلادرنگ مناسب می‌سازد.

شکل 8 (تصویر بازنشر نشده). چارچوب مدل پیش‌بینی بلادرنگ میدان دمای سه‌بعدی؛ بازنشر از [۸۹]. اعتبار: بازنشر اثر ثالث. به علت روشن‌نبودن مجوز بازنشر مستقل، تصویر در ترجمه درج نشده است؛ مشاهده در مقاله اصلی ناشر.

۵.۲. بهینه‌سازی پارامترهای سرمایش

هدف بهینه‌سازی سرمایش، ضخیم‌شدن یکنواخت پوسته تختال و جلوگیری از ترک ناشی از تنش حرارتی است. برای این منظور، دبی آب و شدت سرمایش در نواحی مختلف باید دقیقاً با پیشرفت جبهه انجماد هماهنگ شوند. لیو و همکاران [۵۸] با PSO-XGBoost، داده‌های **۱۲۰ اندازه‌گیری دما** از ترموکوپل‌ها را تحلیل کردند و توزیع آب در نواحی سرمایش قالب را بهینه ساختند. این کار ترک طولی را کاهش داد و دقت مدل در آزمون به **۹۵٫۸٪** رسید. گرشوونیک و همکاران [۸۷، ۸۸] نیز در کنار بهینه‌سازی سرعت ریخته‌گری، داده‌های دبی آب را وارد مدل کردند و طرحی هماهنگ برای تنظیم شدت سرمایش ثانویه و سرعت ارائه دادند که کیفیت داخلی تختال را بیشتر بهبود بخشید.

۵.۳. بهینه‌سازی عملکرد قالب و ترکیب فولاد مذاب

در بهینه‌سازی عملکرد قالب، پایداری سطح مذاب و تناسب پارامترهای نوسان قالب اهمیت دارد؛ در بهینه‌سازی

ترکیب فولاد مذاب نیز هدف، کاهش خطرهایی مانند گرفتگی نازل و حفظ پایداری عملیات است. لوگونوا [۹۰] درخت تصمیم فازی تطبیقی را در سامانه خبره تعبیه کرد تا عوامل ایجاد عیوب ریخته‌گری تحلیل و مبنایی برای تنظیم پارامترها فراهم شود. ماتسکو [۹۱] مدلی از درخت تصمیم فازی تطبیقی توسعه داد و پارامترهای بهینه‌شده با یادگیری ماشین را در سامانه خبره به کار گرفت تا تنظیم پارامترهای ریخته‌گری با سرعت و دقت بیشتر و به‌صورت تطبیقی و بلادرنگ انجام شود. کوته و همکاران [۴۵] با مدل ترکیبی ANFIS-LSTM، اثر عناصر Al و Ca را بر گرفتگی نازل به‌صورت دیداری تحلیل کردند؛ محدوده کنترل ترکیب مذاب را بهبود دادند و پیش‌بینی قابلیت عبور مذاب از نازل را دقیق‌تر کردند.

جی و همکاران [۸۰] با استفاده از مقدارهای SHAP، سهم اثر یک ویژگی را در شرایط ثابت‌ماندن سایر ویژگی‌ها به‌صورت کمی سنجیدند. این رویکرد برای داده‌کاوی صنعتی کاربردی است و راه تازه‌ای برای کنترل و بهینه‌سازی گریدهای فولادی فراهم می‌کند؛ مهندسان می‌توانند براساس نتایج آن پارامترهای مناسب را برای بهبود کیفیت تعیین کنند. تاکالو و همکاران [۹۲] نیز در پیش‌بینی عیوب محصول ریختگی، پس از آموزش مدل GBDT، با ابزار SHAP اثر پارامترهای ورودی بر عیوب سطحی را به‌شکل دیداری ارائه کردند.

یادگیری ماشین، بهینه‌سازی فرایند را از تنظیم یک پارامتر به هماهنگی چند هدف ارتقا داده و در زمینه سرعت ریخته‌گری، سرمایش ثانویه و عملکرد قالب دستاوردهایی داشته است، اما سازگاری پویا و استقرار صنعتی هنوز چالش‌اند. در بهینه‌سازی سرعت، ANN و TRANSFORM-ANN به برقراری توازن میان بهره‌وری و کیفیت کمک می‌کنند؛ بااین‌حال، تعارض اهداف ــ برای نمونه میان افزایش سرعت، پایداری سطح مذاب و ضخامت پوسته ــ همچنان وجود دارد و بسیاری از کاربردهای صنعتی هنوز بیشتر به بهینه‌سازی آفلاین متکی‌اند. در سرمایش ثانویه، PSO-XGBoost و مدل‌های ترکیبی عمیق، امکان تنظیم دقیق آب در هر ناحیه و کاهش ترک را ایجاد کرده‌اند، اما در هنگام تغییر گرید یا ابعاد محصول، به یادگیری آنلاین برای انطباق بهتر نیاز است.
بهینه‌سازی قالب نیز با LSTM و یادگیری تقویتی دقیق‌تر شده، ولی تأخیر پاسخ حسگرها و نویز داده، سرعت و پایداری تنظیم را محدود می‌کند. بنابراین باید یادگیری بلادرنگ، مدیریت تعارض اهداف و مدل‌های سبک تقویت شوند تا حرکت از بهینه‌سازی آفلاین به کنترل تطبیقی آنلاین امکان‌پذیر شود.

۶. تحلیل مقایسه‌ای مجموعه‌داده‌ها و الگوریتم‌ها

۶.۱. ویژگی‌های مجموعه‌داده‌ها

مجموعه‌داده‌های ریخته‌گری مداوم اغلب یا کوچک و پُربعدند یا حجم زیادی دارند اما تنها یک وضعیت عملیاتی را پوشش می‌دهند. داده‌های مدل VMD-SVR سو و همکاران [۳۷] حداکثر **۵۰۰۰ رکورد** از سطح مذاب را شامل

می‌شد و فقط عملکرد پایدار یک ماشین ریخته‌گری قوسی را پوشش می‌داد. هی و همکاران [۳۸] در مدل GA-CNN از **۵۷,۶۱۶ رکورد** یک ماشین دورشته‌ای استفاده کردند، ولی مطالعه به نوسان سطح مذاب محدود بود و تغییر گرید فولاد را در بر نمی‌گرفت. مجموعه‌داده مدل ANFIS-LSTM کوته و همکاران [۴۵] شامل اطلاعات **۱۵۰ ذوب فولاد SAE1055** بود؛ هرچند ترکیب شیمیایی و چند بُعد دیگر را پوشش می‌داد، داده‌ای از انواع دیگر ماشین‌های ریخته‌گری برای مقایسه نداشت و نمایندگی آن از شرایط متنوع محدود بود. مجموعه‌داده ژانگ و همکاران [۵۶] برای پیش‌بینی ترک داخلی **۱۶۰۰ نمونه** با **۱۹ پارامتر صنعتی** داشت. داده‌های مدل R-ELM زو و همکاران [۷۱] نیز شامل **۲۴۷۶ رکورد** درباره جدایش مرکزی کربن بود که با وجود حجم بیشتر، همچنان به یک گرید مشخص فولاد محدود می‌شد.

کمیاب‌بودن نمونه‌های وضعیت غیرعادی، مسئله نامتوازن‌بودن گروه‌های داده را تشدید می‌کند. هی و همکاران [۳۸] با جنگل تصادفی ۱۵ ویژگی مهم را انتخاب و برای کاهش بیش‌برازش از لایه Dropout استفاده کردند، اما تحلیل واریانس اعتبارسنجی متقاطع را گزارش نکردند. مدل PCA-DNN ژانگ و همکاران [۵۶] برای طبقه‌بندی ترک داخلی در **چهار سطح شدت** طراحی شده بود. در آن پژوهش، سهم نمونه‌های ترک شدید به‌طور کنترل‌شده افزایش یافت تا عدم توازن کمتر شود و نتیجه نشان داد مدل نسبت به آموزش با داده‌های اصلاح‌نشده پایداری بیشتری دارد. مجموعه‌داده ژو و همکاران [۷۵] برای تشخیص ناهنجاری حاوی اطلاعات **۲۶۸ ذوب** بود؛ **۶۴٫۵٪** از نمونه‌ها عیب آخال داشتند، اما تنها **۹۵ نمونه بدون عیب** موجود بود و عدم توازن خفیفی همچنان مشاهده می‌شد.

انتقال مدل میان گریدهای فولاد یا تجهیزات مختلف می‌تواند عملکرد را به‌شدت کاهش دهد. مدل کوته و همکاران [۴۵] روی فولاد SAE1055 به دقت **۹۵٪** رسید، اما برای فولاد کم‌آلیاژ، به دلیل تغییر آستانه حساسیت به عناصر Al و Ca، دقت به **۷۸٪** افت کرد. مدل BPNN کونگ و همکاران [۵۹] در ماشین ریخته‌گری تختال شماره یک یک کارخانه به دقت **۸۶٫۸۵٪** رسید، ولی برای ماشین‌های دارای مشخصات دیگر اعتبارسنجی نشد. داده‌های آموزش مدل ReP لو و همکاران [۸۸] سرعت ریخته‌گری **۰٫۷۵ تا ۱٫۶۵ متر بر دقیقه** را پوشش می‌دادند. خارج از این محدوده، برای نمونه در سرعت بالاتر از ۱٫۶۵ متر بر دقیقه، خطای پیش‌بینی دما به‌طور محسوس افزایش یافت و مدل برای شرایط حدی مناسب نبود.

۶.۲. مقایسه الگوریتم‌ها

برای جبران نبود مقایسه ساختاریافته و هم‌شرط میان الگوریتم‌ها، در این مرور معیار مشترکی با **حداقل ۱۰۰۰ رکورد، دست‌کم ۱۰ ویژگی اصلی و سهم ۱ تا ۱۰ درصدی نمونه‌های غیرعادی** پیشنهاد شده است. مقایسه بر سه محور شرایط داده، دشواری وظیفه و شاخص‌های ارزیابی انجام می‌شود تا تفاوت عملکرد روش‌های متعارف و یادگیری عمیق روشن‌تر شود. مدل VMD-SVR سو و همکاران [۳۶] در پیش‌بینی سطح مذاب به **R = 0.9992**

و **RMSE = 0.6910** رسید، درحالی‌که هزینه محاسباتی آن تنها یک‌هشتم یادگیری عمیق بود. مدل GA-CNN هی و همکاران [۳۸] با **MAE = 0.1093**، **R^2 = 0.98** و تأخیر پیش‌بینی حداکثر **۱۰۰ میلی‌ثانیه** مزیت یادگیری عمیق را در کاربرد بلادرنگ نشان داد. مدل PCA-DNN ژانگ و همکاران [۵۶] دقت اعتبارسنجی **۹۲٫۲٪** داشت. مقدار MAPE مدل ReP لو و همکاران [۸۹] برای میدان دمای سه‌بعدی به **۰٫۴۹٪** رسید و از مدل سنتی DNS بهتر بود.

کاربردها را از نظر پیچیدگی نیز می‌توان به ساده، متوسط و پیچیده تقسیم کرد. در مسئله ساده‌ای مانند پیش‌بینی یک پارامتر، روش‌های متعارف گاه تقریباً به اندازه شبکه‌های عمیق دقیق‌اند؛ مثلاً اختلاف دقت پیش‌بینی سطح مذاب میان VMD-SVR سو و همکاران [۳۷] و GA-CNN هی و همکاران [۳۸] کمتر از **۳٪** بود. اما در مسائل پیچیده، مانند بهینه‌سازی چندهدفه و پیش‌بینی میدان سه‌بعدی، شبکه‌های عمیق مزیت روشن‌تری دارند. ANFIS-LSTM کوته و همکاران [۴۵] گرفتگی نازل را با **۲۴ دقیقه** زمان پیش‌آگاهی پیش‌بینی کرد؛ مدل ReP لو و همکاران [۸۸] با بهینه‌سازی بیزی، پارامترهای سرمایش ثانویه را ظرف **۵٫۲ ثانیه** به‌صورت تطبیقی تنظیم کرد. این سرعت‌ها از مدل‌های محاسباتی سنتی بالاترند. در ارزیابی پیش‌بینی ناهنجاری، نرخ بازخوانی و هشدار کاذب اهمیت ویژه‌ای دارند. در گزارش هی و همکاران [۳۸] نرخ هشدار کاذب GA-CNN بیش از **۱٪** نبود و در مدل چندمقیاسی CNN-LSTM ژو و همکاران [۷۵]، بازخوانی تشخیص ناهنجاری **۹۳٫۰۶٪** بود. در بازرسی کیفیت، شاخص F1 توازن میان دقت و بازخوانی را می‌سنجد؛ مدل PCA-SVM دوان و همکاران [۶۰] برای ترک طولی **F1 = 0.95** و مدل BO-XGBoost جی و همکاران [۸۰] برای پیش‌بینی عیب ورود سرباره **AUC = 0.811** داشت. برای ارزیابی بهینه‌سازی فرایند نیز شاخص AMR گزارش‌شده از سوی سان و همکاران [۳۶] و مقدار MAE گزارش‌شده از سوی لو و همکاران [۸۹] به کار رفته‌اند.

مقایسه در شرایط یکسان نشان می‌دهد هر الگوریتم میان عملکرد، هزینه و نوع کاربرد مبادله‌ای متفاوت دارد؛ بنابراین انتخاب الگوریتم باید دقیقاً با نیاز صنعتی هماهنگ شود. مدل‌های درختی و خطی متعارف معمولاً در مجموعه‌داده کوچک، انتقال به کاربردهای دیگر و تفسیرپذیری مزیت دارند. مدل RF-K-Means ژانگ و همکاران [۵۷] در تشخیص ترک طولی هیچ مورد مثبتی را از دست نداد و هزینه محاسباتی آن **۶۰٪ کمتر از CNN** بود؛ پس برای نوسازی تجهیزات قدیمی مناسب است. مدل XGBoost جی و همکاران [۸۰] با SHAP اثر سرعت ریخته‌گری و عرض تختال بر عیوب ورود سرباره را کمی می‌کند و به ردیابی علت کیفیت کمک می‌رساند. مدل ELM زو و همکاران [۷۱] می‌تواند جدایش مرکزی کربن را در **۰٫۰۲ ثانیه** پیش‌بینی کند و برای پاسخ سریع آنلاین مفید است. در برابر، دقت بالای بعضی مدل‌های عمیق نیازمند سرمایه سخت‌افزاری بیشتر است: GA-CNN هی و همکاران [۳۸] به دو پردازنده گرافیکی **Tesla V100** و نرخ نمونه‌برداری **۱۰۰ هرتز** نیاز دارد، حال آنکه VMD-SVR سو و همکاران [۳۷] می‌تواند با CPU و نرخ **۲۰ هرتز** کار کند و هزینه سخت‌افزار را **۷۰٪** کاهش دهد؛ امری سازگارتر با امکانات کارخانه‌های فولاد کوچک و متوسط. البته بعضی مدل‌های عمیق نیز پس از

بهینه‌سازی میان هزینه و توان توازن یافته‌اند. برای مثال، ReP لو و همکاران [۸۹] با اینکه در آموزش به GPU نیاز دارد، هنگام استقرار روی رایانه معمولی اجرا می‌شود و هر پیش‌بینی آن تنها **۰٫۱۲ ثانیه** طول می‌کشد. با توجه به نوع وظیفه، در پیش‌بینی ناهنجاری، VMD-SVR [۳۷] برای سخت‌افزار کم‌توان و GA-CNN [۳۸] برای کنترل بلادرنگ مناسب‌تر است. در شناسایی عیوب، PCA-SVM [۶۰] برای پردازش آفلاین و PCA-DNN [۵۶] برای بازرسی آنلاین ترجیح دارد. در بهینه‌سازی پارامترها، PSO-SVM [۷۰] برای هدف منفرد و ReP + BO [۸۸] برای اهداف متعدد مناسب‌ترند. برای پیش‌بینی ترکیب و جدایش نیز ELM [۷۱] سرعت کافی دارد و در کاربردهای نیازمند دقت بیشتر، R-ELM [۷۱] یا ANFIS-LSTM [۴۵] استفاده می‌شوند. این انتخاب ساختاریافته، از داوری یک‌جانبه فقط براساس دقت مدل جلوگیری می‌کند.

۷. جمع‌بندی و چشم‌انداز

کاربرد یادگیری ماشین در ریخته‌گری مداوم به مجموعه‌ای منسجم از روش‌های فنی تبدیل شده است. با پاک‌سازی داده و به‌کارگیری مدل‌ها، دستاوردهایی در پیش‌بینی ناهنجاری و بازرسی کیفیت حاصل شده و در مواردی کارایی این فناوری از روش‌های سنتی فراتر رفته است؛ بااین‌حال، فاصله میان نتیجه پژوهشی و واقعیت کارگاه صنعتی همچنان چشمگیر است. محیط سخت کارگاه‌های ریخته‌گری می‌تواند داده‌ها را دچار اعوجاج کند: حسگرها در کار طولانی‌مدت رانش دارند، ارتقای تجهیزات ممکن است توزیع داده را ناگهان تغییر دهد و هزینه نگهداری مدل بالا برود. نویز حسگر نیز نمونه‌های بی‌اعتبار تولید می‌کند و پیش‌پردازش ویژه برای آموزش مؤثر را ضروری می‌سازد. اولویت حفظ تولید باکیفیت، به‌طور طبیعی باعث کمیاب‌شدن نمونه‌های خطا می‌شود؛ در شرایط حادثه شدید نیز توقف خط مانع ثبت کامل رویداد می‌شود، بنابراین داده‌های لازم برای یادگیری کامل ویژگی‌های خرابی محدودند. از سوی دیگر، بیشتر مدل‌های عمیق ارتباط کافی با سازوکارهای متالورژیکی ندارند تا مبنای قابل‌اعتماد تنظیم فرایند باشند. اختلاف میان توان پردازشی محدود تجهیزات قدیمی و نیاز تولید به کنترل پُربسامد بلادرنگ نیز استقرار مدل‌های بسیار دقیق را دشوار می‌کند.

برای روبه‌روشدن با این محدودیت‌های واقعی، پژوهش‌های موجود چند راهکار عملی مطرح کرده‌اند. در آماده‌سازی داده، نمونه‌برداری با تفکیک زمانی بالا همراه با روش‌های حذف نویز می‌تواند اثر رانش حسگر را کاهش دهد. بسته به حجم واقعی داده، کم‌نمونه‌برداری یا بیش‌نمونه‌برداری نیز می‌تواند توازن گروه‌های داده را اصلاح کند. برای افزایش تفسیرپذیری، باید دانش سازوکارهای متالورژیکی با سنجش کمی اهمیت ویژگی‌ها ترکیب شود: ابتدا پارامترهای اصلی با اتکا به دانش فنی فرایند انتخاب شوند؛ سپس وزن اثر هر پارامتر با تحلیل اهمیت ویژگی تعیین گردد؛ و در نهایت، خروجی مدل هم از نظر پیش‌بینی داده‌محور و هم از نظر سازگاری با اصول صنعتی اعتبارسنجی شود. استقرار مدل باید با توان پردازشی واقعی سایت هماهنگ باشد؛ در تجهیزات

کم‌توان، مدل‌های سبک متعارف هزینه را کنترل می‌کنند و در سامانه‌های میان‌رده یا پُرتوان می‌توان از فشرده‌سازی مدل و پردازش موازی برای افزایش سرعت استفاده کرد. هدف، یافتن بهترین توازن میان توان پیش‌بینی و هزینه اجرای صنعتی است.

در مجموع، ارزش یادگیری ماشین در ریخته‌گری مداوم نشان داده شده است، اما سازگاری مدل‌ها با شرایط مختلف همچنان گلوگاه اصلی است. پژوهش‌های آینده باید بر مدل‌سازی دوگانه بر پایه سازوکارهای فیزیکی و داده، تلفیق داده‌های چندوجهی و واردکردن دانش متالورژی در ساخت مدل تمرکز کنند تا تفسیرپذیری و تعمیم‌پذیری افزایش یابد. برای داده‌های کم‌نمونه و نامتوازن باید روش‌های مناسب محیط صنعتی توسعه داده شود. برای پاسخ سریع نیز یادگیری آنلاین و مدل‌های سبک با وابستگی کمتر به سخت‌افزار ضروری است. در کنار آن، باید سامانه تصمیم‌یار هوشمند در سراسر زنجیره فرایند شکل بگیرد، مدل‌ها متناسب با ویژگی گریدهای فولاد تنظیم شوند و فناوری‌های حوزه‌های دیگر برای گسترش کاربردها به کار روند. چنین مسیری ریخته‌گری مداوم را از صرفاً دستیابی به استانداردهای تولید، به کیفیت و بهره‌وری بالاتر هدایت می‌کند و به هوشمندسازی صنعت فولاد کمک خواهد کرد.

نقش نویسندگان

طراحی ایده: S.Z.؛ سامان‌دهی داده‌ها: Y.P.؛ تحلیل رسمی: J.S. و J.Z.؛ روش‌شناسی: J.Z. و J.S.؛ اعتبارسنجی: Y.P.؛ روش‌شناسی (تکرارشده در منبع): J.Z. و J.S.؛ تحقیق: Y.P.؛ نگارش نسخه اولیه: Z.W. و S.Z.؛ بازبینی و ویرایش متن: S.Z. و J.Z.؛ تأمین منابع مالی: Z.W. همه نویسندگان نسخه منتشرشده مقاله را خوانده و تأیید کرده‌اند.

منابع مالی پژوهش

این پژوهش از پروژه عمومی بنیاد علوم طبیعی استان لیائونینگ (کد MS-309-2025)، پروژه پژوهشی اداره آموزش استان لیائونینگ (کدهای LJ212513217002 و LJ212412595003) و بودجه طرح جذب استعداد دانشگاه فنی لیائونینگ (کد 552305900128) حمایت مالی دریافت کرده است.

دسترس‌پذیری داده‌ها

در این مطالعه داده جدیدی ایجاد یا تحلیل نشده است؛ بنابراین اشتراک‌گذاری داده در مورد این مقاله

موضوعیت ندارد.

تعارض منافع

نویسندگان اعلام کرده‌اند که تعارض منافعی ندارند.

فهرست اختصارات

اختصار	مفهوم فارسی
GA-BPNN	شبکه عصبی پس‌انتشار خطا بهینه‌شده با الگوریتم ژنتیک
DBSCAN-DTW	خوشه‌بندی چگالی‌مبنا همراه هم‌ترازی زمانی پویا
FNN	شبکه عصبی پیش‌خور
VMD-SVR	تجزیه مد متغیر همراه رگرسیون بردار پشتیبان
GA-CNN	شبکه عصبی کانولوشنی بهینه‌شده با الگوریتم ژنتیک
EMD-SVR-GA	تجزیه مد تجربی، رگرسیون بردار پشتیبان و الگوریتم ژنتیک
LSTM	حافظه بلندمدت کوتاه‌مدت
DNN	شبکه عصبی عمیق
ANFIS-LSTM	سامانه استنتاج عصبی-فازی تطبیقی همراه LSTM
ACWGAN-GP	شبکه مولد تخاصمی واسرشتاین با طبقه‌بند کمکی و جریمه گرادیان
SVM	ماشین بردار پشتیبان
LWOA-TSVR	بهینه‌سازی گرگ خاکستری همراه رگرسیون بردار پشتیبان دوقلو (مطابق بسط اختصار در منبع)
SAC	عامل-منتقد نرم (Soft Actor–Critic)
NN-FL	شبکه عصبی و منطق فازی
PCA-DNN	تحلیل مؤلفه‌های اصلی و شبکه عصبی عمیق
RF-K-Means	جنگل تصادفی و خوشه‌بندی میانگین‌های K
PCA-PSO-XGBoost	تحلیل مؤلفه‌های اصلی، بهینه‌سازی ازدحام ذرات و گرادیان بوستینگ پیشرفته
PCA-SVM	تحلیل مؤلفه‌های اصلی و ماشین بردار پشتیبان
PSO-SVM	بهینه‌سازی ازدحام ذرات و ماشین بردار پشتیبان
R-ELM	ماشین یادگیری حدی منظم‌سازی‌شده

SteelExperts.ir

اختصار	مفهوم فارسی
ORF	جنگل تصادفی بهینه‌شده
BO-XGBoost	بهینه‌سازی بیزی و گرادیان بوستینگ پیشرفته
CNN-LSTM	شبکه کانولوشنی همراه حافظه بلندمدت کوتاه‌مدت
BP	شبکه عصبی با پس‌انتشار خطا

منابع علمی

1. Sheng, Y.W.; Zhou, Z.Q.; Meng, X.N.; Ru, J.S. Numerical simulation of non-uniform solidified structure growth of continuous casting slab based on cellular automaton finite-element model. Can. Metall. Q. **2024**, 64, 2639–2648. [Google Scholar] [[CrossRef] [Scilit
2. Shen, Y.Y.; Yan, W.; Zhao, X.Y.; Chen, S.J.; Shi, C.B.; Yang, C.W.; Wang, K.P.; Wang, Y.Y. Development and application of mold flux for high-speed continuous casting of high-carbon steel billets. J. Iron Steel Res. Int. **2025**, 32, 2794–2807. [Google [Scholar] [CrossRef] [Scilit
3. Wang, P.; Wang, H.; Chen, L.; Zhang, Z.; Chen, G.; Fan, D.G.; Zhang, J.Q. Continuous casting soft reduction control of macro-/semimacro synergistic homogeneity of bloom and rod for CF53 camshaft steel. Steel Res. Int. **2025**, 96, 284–298. [[Google Scholar] [CrossRef] [Scilit
4. Thomas, B.G. Review on modeling and simulation of continuous casting. Steel Res. [Int. **2018**, 89, 1700312. [Google Scholar] [CrossRef] [Scilit
5. Wang, H.J.; Zhang, Z.; Fan, D.G.; Jiang, C.H.; Zhang, B.B.; Wang, P.; Zhang, J.Q. Soft reduction control investigation of spot segregation in continuous casting bloom for 42CrMoA crankshaft steel. J. Iron Steel Res. Int. **2025**, 32, 695–706. [[Google Scholar] [CrossRef] [Scilit
6. Cho, S.M.; Thomas, B.G. Electromagnetic effects on solidification defect formation in continuous steel casting. JOM **2020**, 72, 3610–3620. [Google Scholar]

[[CrossRef] [Scilit

7. Pan, Q.H.; Jin, W.; Huang, S.Z.; Guo, Y.F.; Jiang, M.Y.; Li, X. Simulation and study of influencing factors on the solidification microstructure of Hazelett continuous casting slabs using CAFE model. Materials **2024**, 17, 1869. [Google Scholar] [[CrossRef] [Scilit

8. Zhang, B.G.; Wu, H.; Yu, H.C.; Zhang, R.Z.; Fan, L.F. Application of deep learning and attention mechanisms in continuous casting breakout prediction. Metall. Res. [Technol. **2025**, 122, 307–316. [Google Scholar] [CrossRef] [Scilit

9. Li, J.; Nian, Y.; Liu, X.; Zong, Y.C.; Tang, X.Y.; Zhang, C.J.; Zhang, L.Q. Application of electromagnetic metallurgy in continuous casting: A review. Prog. Nat. Sci. Mater. [Int. **2024**, 34, 1–11. [Google Scholar] [CrossRef] [Scilit

10. Kulkarni, M.S.; Babu, A.S. Managing quality in continuous casting process using product quality model and simulated annealing. J. Mater. Process. Technol. **2005**, [166, 294–306. [Google Scholar] [CrossRef] [Scilit

11. Shi, C.; Guo, S.; Chen, J.; Zhong, R.X.; Wang, B.S.; Sun, P.; Ma, Z.C. Breakout prediction based on twin support vector machine of improved whale optimization [algorithm. ISIJ Int. **2023**, 63, 880–888. [Google Scholar] [CrossRef] [Scilit

12. Thomas, B.G.; Yuan, Q. Transport and entrapment of particles in steel continuous casting. Metall. Mater. Trans. B **2014**, 45, 1245–1262. [Google Scholar] [CrossRef] [[Scilit

13. Hayakawa, K.; Matsui, I.; Hamaguchi, T.; Maeguchi, T. Regular article machine learning algorithm for prediction of iron loss of electrical steel under stress. J. Jpn. [Inst. Met. **2024**, 88, 385–393. [Google Scholar] [CrossRef] [Scilit

14. Lee, S.Y.; Tama, B.A.; Choi, C.; Hwang, J.Y.; Bang, J.; Lee, S. Spatial and sequential deep learning approach for predicting temperature distribution in a steel-making continuous casting process. IEEE Access **2020**, 8, 21953–21965. [Google Scholar] [[CrossRef] [Scilit

15. Zong, N.; Jing, T.; Gebelin, J.C. Machine learning techniques for the comprehensive

analysis of the continuous casting processes: Slab defects. Ironmak. Steelmak. .2025; Online first

16. Cemernek, D.; Cemernek, S.; Gursch, H.; Pandeshwar, A.; Leitner, T.; Berger, M.; Klösch, G.; Kern, R. Machine learning in continuous casting of steel: A state-of-the-art survey. J. Intell. Manuf. **2022**, 33, 1561–1583. [Google Scholar] [CrossRef] [[Scilit

17. Lian, G.; Liu, X.; Wang, Q.; Shen, C.; Wang, Y.; Mu, W. Artificial intelligence-assisted non-metallic inclusion particles analysis in advanced steels using machine learning: [A review. Int. J. Miner. Metall. Mater. **2025**, 32, 3239. [Google Scholar

18. Varfolomeev, I.A.; Ershov, E.V.; Vinogradova, L.N. Statistical control of defects in a continuously cast billet based on machinelearning and data analysis methods. [Autom. Remote Control **2018**, 79, 1450–1457. [Google Scholar] [CrossRef] [Scilit

19. Wang, Z.F.; Wang, X.D.; Liu, F.B.; Yao, M.; Zhang, X.B.; Yang, L.S.; Lu, H.Z.; Wang, X. Vibration method to detect liquid–solid fraction and final solidifying end for continuous casting slab. Steel Res. Int. **2013**, 84, 724–731. [Google Scholar] [[CrossRef] [Scilit

20. Liu, D.W.; Zhang, G.F.; Zeng, J.H.; Xie, X. Numerical simulation of segregation in slabs under different secondary cooling electromagnetic stirring modes. Materials [**2024**, 17, 2721. [Google Scholar] [CrossRef] [Scilit

21. Wang, Z.F.; Yao, M.; Wang, X.D.; Zhang, X.B.; Yang, L.S.; Lu, H.Z.; Wang, X. Inverse problem-coupled heat transfer model for steel continuous casting. J. Mater. [Process. Technol. **2014**, 214, 44–49. [Google Scholar] [CrossRef] [Scilit

22. Toledo, G.A.; Lainez, J.; Cirion, J.C. Model optimization of continuous casting steel secondary cooling. Mater. Sci. Eng. A **1993**, 173, 287–291. [Google Scholar] [[CrossRef] [Scilit

23. Hardin, R.A.; Liu, K.; Kapoor, A.; Beckermann, C. Transient simulation and dynamic spray cooling control model for continuous steel casting. Metall. Mater. Trans. B [**2003**, 34, 297–306. [Google Scholar] [CrossRef] [Scilit

.24 Savage, J.; Pritchard, W.H. Problem of rupture of the billet in the continuous casting [of steel. Iron Steel Inst. **1954**, 178, 269–277. [Google Scholar

.25 Zhang, C.; Li, T.; Wang, B. Dynamic modeling method for the scheduling problem in steelmaking-continuous casting with disturbance of product quality. Energy [Procedia **2011**, 13, 253–261. [Google Scholar] [CrossRef] [Scilit

.26 Qin, Q.; Wang, X.; Dai, S.; Zhong, Y.; Wei, S. Machine learning-based prediction of mechanical properties for large bearing housing castings. Materials **2025**, 18, [4036. [Google Scholar] [CrossRef] [Scilit

.27 Wei, C.H.; Song, Z.H. Real-time forecasting of subsurface inclusion defects for continuous casting slabs: A data-driven comparative study. Sensors **2023**, 23, [5415. [Google Scholar] [CrossRef] [Scilit

.28 Liu, J.S.; Long, H.S.; Chen, D.Y.; Song, H.W.; Zhang, S.H.; Piccininni, A.; Chen, C.L. Machine learning-assisted process prediction of horizontal continuous casting for copper tubular billets. J. Mater. Eng. Perform. **2025**, 34, 9187–9197. [Google [Scholar] [CrossRef] [Scilit

.29 He, Y.B.; Zhou, H.L.; Li, Y.H.; Zhang, T.; Li, B.Z.; Ren, Z.F.; Zhu, Q. Multi-task learning model of continuous casting slab temperature based on DNNs and SHAP analysis. Metall. Mater. Trans. B **2024**, 55, 5120–5132. [Google Scholar] [[CrossRef] [Scilit

.30 Song, G.W.; Tama, B.A.; Park, J.; Hwang, J.Y.; Lee, S. Temperature control optimization in a steel-making continuous casting process using a multimodal deep learning approach. Steel Res. Int. **2019**, 90, 1900321. [Google Scholar] [CrossRef] [[Scilit

.31 Wu, X.; Jin, H.; Ye, X.; Wang, J.; Lei, Z.S.; Liu, Y.; Wang, J.; Guo, Y. Multiscale convolutional and recurrent neural network for quality prediction of continuous [casting slabs. Processes **2021**, 9, 33. [Google Scholar] [CrossRef] [Scilit

.32 He, F.; Zhang, L.Y. Mold breakout prediction in slab continuous casting based on combined method of GA-BP neural network and logic rules. Int. J. Adv. Manuf.

[Technol. **2018**, 95, 4081–4089. [Google Scholar] [CrossRef] [Scilit

.33 Wang, R.R.; Wang, M.; Wang, Z.L.; Xing, L.D.; Ai, X.G.; Bao, Y.P. Mechanism and forecast model of sticker breakout in continuous casting. China Metall. **2023**, 33, [138. [Google Scholar

.34 Duan, H.Y.; Wang, X.D.; Bai, Y.; Yao, M.; Guo, Q.T. Integrated approach to density-based spatial clustering of applications with noise and dynamic time warping for breakout prediction in slab continuous casting. Metall. Mater. Trans. B **2019**, 50, [2343. [Google Scholar] [CrossRef] [Scilit

.35 Liu, Y.; Wang, X.D.; Du, F.M.; Kong, L.W.; Yao, M.; Zhang, X.B. Visual detection based on computer vision for sticker breakout in slab continuous casting. IronMak. [SteelMak. **2015**, 42, 417. [Google Scholar] [CrossRef] [Scilit

.36 Sun, Y.; Liu, Z.Q.; Xiong, Y.T.; Yang, J.; Xu, G.D.; Li, B.K. A novel feedforward neural network model for predicting the level fluctuation in continuous casting mold. [Metall. Mater. Trans. B **2025**, 56, 5009–5026. [Google Scholar] [CrossRef] [Scilit

.37 Su, W.B.; Lei, Z.F.; Yang, L.D.; Hu, Q. Mold-level prediction for continuous casting [using VMD–SVR. Metals **2019**, 9, 458. [Google Scholar] [CrossRef] [Scilit

.38 He, Y.B.; Zhou, H.L.; Zhang, B.Q.; Guo, H.; Li, B.Z.; Zhang, T.; Yang, K.; Li, Y.H. Prediction model of liquid level fluctuation in continuous casting mold based on GA-CNN. Metall. Mater. Trans. B **2024**, 55, 1414–1425. [Google Scholar] [[CrossRef] [Scilit

.39 Tirian, G.O.; Filip, I.; Prostean, G. Adaptive control system for continuous steel casting based on neural networks and fuzzy logic. Neurocomputing **2014**, 125, [236. [Google Scholar] [CrossRef] [Scilit

.40 Lei, Z.F.; Su, W.B. Mold level predict of continuous casting using hybrid EMD-SVR-[GA algorithm. Processes **2019**, 7, 177. [Google Scholar] [CrossRef] [Scilit

.41 Yang, W.; Zhang, L.F.; Ren, Y.; Chen, W.; Liu, F.G. Formation and prevention of nozzle clogging during the continuous casting of steels: A review. ISIJ Int. **2024**, [64, 1. [Google Scholar] [CrossRef] [Scilit

.42 Wang, R.B.; Li, H.; Guerra, F.; Cathcart, C.; Chattopadhyay, K. Predicting quantitative indices for SEN clogging in continuous casting using long short term memory time [series model. ISIJ Int. **2022**, 62, 2311. [Google Scholar] [CrossRef] [Scilit

.43 Girase, N.U.; Basu, S.; Choudhary, S.K. Development of indices for quantification of nozzle clogging during continuous slab casting. Ironmak. Steelmak. **2013**, 34, [506–512. [Google Scholar] [CrossRef] [Scilit

.44 Diniz, A.P.M.; Ciarelli, P.M.; Salles, E.O.T. Use of deep neural networks for clogging detection in the submerged entry nozzle of the continuous casting. Expert Syst. [Appl. **2024**, 238, 121963. [Google Scholar] [CrossRef] [Scilit

.45 Kuthe, S.; Ona, I.A.; Glaser, B. Adaptive neuro-fuzzy inference system long short-term memory hybrid model to forecast castability of Al-killed steel prior to continuous casting. Steel Res. Int. **2024**, 95, 2400220. [Google Scholar] [CrossRef] [[Scilit

.46 Wang, Y.Y.; Wang, X.D.; Yao, M. Integrated model of ACWGAN-GP and computer vision for breakout prediction in continuous casting. Metall. Mater. Trans. B **2022**, [53, 2873–2885. [Google Scholar] [CrossRef] [Scilit

.47 Salah, B.; Zoheir, M.; Slimane, Z.; Jurgen, B. Inferential sensor-based adaptive principal components analysis of mould bath level for breakout defect detection and evaluation in continuous casting. Appl. Soft Comput. **2015**, 34, 120–128. [[Google Scholar] [CrossRef] [Scilit

.48 Wu, X.J.; Kang, H.J.; Yuan, S.; Jiang, W.Z.; Gao, Q.; Mi, J.Z. Anomaly detection of liquid level in mold during continuous casting by using forecasting and error [generation. Appl. Sci. **2023**, 13, 7457. [Google Scholar] [CrossRef] [Scilit

.49 Vannucci, M.; Colla, V. Novel classification method for sensitive problems and uneven datasets based on neural networks and fuzzy logic. Appl. Soft Comput. [**2011**, 11, 2383–2390. [Google Scholar] [CrossRef] [Scilit

.50 Brimacombe, J.K.; Hawbolt, E.B.; Weinberg, F. Formation of off-corner internal cracks in continuously-cast billets. Can. Metall. Q. **1980**, 19, 215. [Google Scholar]

[[CrossRef

51. Brimacombe, J.K.; Weinberg, F.; Hawbolt, E.B. Formation of longitudinal, midface cracks in continuously-cast slabs. Metall. Mater. Trans. B **1979**, 10, 279. [Google [Scholar] [CrossRef] [Scilit

52. Thomas, B.G.; Samarasekera, I.V.; Brimacombe, J.K. Investigation of panel crack formation in steel ingots: Part 1. Off-corner panel cracks. Metall. Mater. Trans. B [**1988**, 19, 289. [Google Scholar] [CrossRef] [Scilit

53. Brimacombe, J.K.; Sorimachi, K. Crack formation in the continuous casting of steel. [Metall. Mater. Trans. B **1977**, 8, 489. [Google Scholar] [CrossRef] [Scilit

54. Sala, D.A.; Van Yperen-De Deyne, A.; Mannens, E.; Jalalvand, A. Hybrid-input FCN-CNN-SE for industrial applications: Classification of longitudinal cracks during [continuous casting. Metals **2023**, 13, 1699. [Google Scholar] [CrossRef] [Scilit

55. Zou, L.L.; Huang, J.X.; Li, Q.H.; Zhang, J.S.; Liu, Q. Research progress on the crack and segregation prediction of continuous casting strand. Contin. Cast. **2022**, 2, [2–9. [Google Scholar

56. Zou, L.L.; Zhang, J.S.; Han, Y.S.; Zeng, F.Z.; Li, Q.H.; Liu, Q. Internal crack prediction of continuous casting billet based on principal component analysis and deep neural [network. Metals **2021**, 11, 1976. [Google Scholar] [CrossRef] [Scilit

57. Zhang, H.; Duan, H.Y.; Wang, X.D.; YAO, M. Longitudinal crack prediction method of continuous cast slab based on random forest and clustering. Contin. Cast. **2022**, 6, [21–28. [Google Scholar

58. Liu, Y.; Jiang, L.; Shi, J.; Liu, J.B.; Li, G.H.; Wang, Z.F.; Zhang, Z. Recognition of longitudinal cracks on slab surfaces based on particle swarm optimization and eXtreme gradient boosting model. Processes **2024**, 12, 1087. [Google Scholar] [[CrossRef] [Scilit

59. Kong, Y.W.; Chen, D.F.; Liu, Q.; Long, M.J. A prediction model for internal cracks during slab continuous casting. Metals **2019**, 9, 587. [Google Scholar] [CrossRef] [[Scilit

.60 Duan, H.Y.; Wei, J.J.; Qi, L.; Wang, X.D.; Liu, Y.; Yao, M. Longitudinal crack detection approach based on principal component analysis and support vector machine for slab continuous casting. Steel Res. Int. **2021**, 92, 2100168. [Google Scholar] [[CrossRef] [Scilit

.61 Singh, A.K.; Basu, B.; Ghosh, A. Role of appropriate permeability model on numerical prediction of macrosegregation. Metall. Mater. Trans. B **2006**, 37, 799. [[Google Scholar] [CrossRef] [Scilit

.62 Han, Y.S.; Yan, W.; Zhang, J.S.; Chen, J.; Chen, W.Q.; Liu, Q. Comparison and integration of final electromagnetic stirring and thermal soft reduction on [continuous casting billet. J. Iron Steel Res. Int. **2021**, 28, 160. [Google Scholar

.63 Combeau, H.; Zaloznik, M.; Hans, S.; Richy, P.E. Prediction of macrosegregation in steel ingots: Influence of the motion and the morphology of equiaxed grains. Metall. [Mater. Trans. B **2009**, 40, 289. [Google Scholar

.64 Han, Y.; Yan, W.; Zhang, J.; Chen, W.Q.; Chen, J.; Liu, Q. Optimization of thermal soft reduction on continuous casting billet. ISIJ Int. **2020**, 60, 106. [Google Scholar] [[CrossRef] [Scilit

.65 Vušanović, I.; Vertnik, R.; Šarler, B. A simple slice model for prediction of macrosegregation in continuously cast billets. IOP Conf. Ser. Mater. Sci. Eng. [**2012**, 27, 12056. [Google Scholar] [CrossRef] [Scilit

.66 Luo, S.; Li, K.K.; Wang, W.L.; Zhu, M.Y. Numerical simulation of macrosegregation in continuously cast slab with application of S-EMS and MR. J. Mater. Res. Technol. [**2023**, 24, 6893-6907. [Google Scholar] [CrossRef] [Scilit

.67 Li, P.Z. Online quality prediction system of bloom castings based on BP neural [network. Ironmak. Steelmak. **2011**, 46, 33-37. [Google Scholar

.68 Liu, G.L.; Lu, H.B.; Li, B.; Ji, C.X.; Zhang, J.S.; Liu, Q.; Lei, Z.S. Influence of M-EMS on fluid flow and initial solidification in slab continuous casting. Materials **2021**, 14, [3681. [Google Scholar] [CrossRef] [Scilit

.69 Nieto, P.J.G.; Suárez, V.M.G.; Antón, J.C.A.; Bayón, R.M.; Blanco, J.A.S.; Fernández,

A.M.D. A new predictive model of centerline segregation in continuous cast steel slabs by using multivariate adaptive regression splines approach. Materials **2015**, [8, 3562. [Google Scholar] [CrossRef] [Scilit

.70 Nieto, P.J.G.; Garcia-Gonzalo, E.; Antón, J.C.A.; Suárez, V.M.G.; Bayón, R.M.; Martín, F.M. A comparison of several machine learning techniques for the centerline segregation prediction in continuous cast steel slabs and evaluation of its performance. J. Comput. Appl. Math. **2018**, 330, 877–895. [Google Scholar] [[CrossRef] [Scilit

.71 Zou, L.; Zhang, J.; Liu, Q.; Zeng, F.Z.; Chen, J.; Guan, M. Prediction of central carbon segregation in continuous casting billet using a regularized extreme learning [machine model. Metals **2019**, 9, 1312. [Google Scholar] [CrossRef] [Scilit

.72 Zhang, J.; Lee, H.G. Numerical modeling of nucleation and growth of inclusions in molten steel based on mean processing parameters. ISIJ Int. **2004**, 44, [1629–1638. [Google Scholar] [CrossRef] [Scilit

.73 Dai, W.B.; Yu, J.K.; Du, C.M.; Zhang, L.; Wang, X.L. Refinement of inclusions in molten steel by electric current pulse. Mater. Sci. Technol. **2015**, 31, 1555–1559. [[Google Scholar] [CrossRef] [Scilit

.74 Wang, L.T.; Peng, S.H.; Zhang, Q.Y.; Li, Z.B. Mathematical model for growth and removal of inclusions in molten steel under gas-stirring conditions. Steel Res. Int. [**2006**, 77, 25–31. [Google Scholar] [CrossRef] [Scilit

.75 Chen, M.C.; Yen, S.Y.; Lin, Y.F.; Tsai, M.Y.; Chuang, T.H. Intelligent casting quality inspection method integrating anomaly detection and semantic segmentation. [Machines **2025**, 13, 317. [Google Scholar] [CrossRef] [Scilit

.76 Zhao, J.; Zhu, H.; Luo, J.Z.Z. Motion behaviour of solid inclusions at the steel-slag interface in high-Al steel. Ironmak. Steelmak. **2023**, 50, 1749–1757. [Google [Scholar] [CrossRef] [Scilit

.77 Sowa, T.; Seki, Y.; Suzuki, T.; Tanaka, S. Evaluation of deoxidation state in molten steel using image recognition technique of reduction slag by machine learning.

[Metall. Ital. **2024**, 115, 6. [Google Scholar

.78 Wang, Y.; Zang, X.; Liu, C.; Liang, Z.G.; Liu, C.J. Evaluation of inclusion agglomeration behavior in molten steel based on the modified model of cavity bridge force. J. Mater. Res. Technol. **2024**, 31, 512–519. [Google Scholar] [[CrossRef] [Scilit

.79 Zhang, Y.X.; Gao, Z.G.; Sun, J.C.; Liu, L.L. Machine-learning algorithms for process condition data-based inclusion prediction in continuous-casting process: A case [study. Sensors **2023**, 23, 6719. [Google Scholar] [CrossRef] [Scilit

.80 Ji, Y.; Wang, W.L.; Zhou, L.J. Prediction and feature analysis of entrapped slag defect on casting slab based on optimized XGBoost model. Metall. Mater. Trans. B [**2024**, 55, 2026–2036. [Google Scholar] [CrossRef] [Scilit

.81 Zhou, Y.J.; Xu, K.; He, F.; Zhang, Z.Y. Application of time series data anomaly detection based on deep learning in continuous casting process. ISIJ Int. **2022**, 62, [689–698. [Google Scholar] [CrossRef] [Scilit

.82 Zhou, S.Y.; Chen, Y.P.; Zhang, D.L.; Xie, J.M.; Zhou, Y.F. Classification of surface defects on steel sheet using convolutional neural networks. Mater. Technol. **2017**, [51, 123. [Google Scholar

.83 Wu, Y.; Zhang, H.; Jian, L.; Lv, Z.M. A quantitative causal analysis and optimization framework for inclusions of steel products. Adv. Eng. Inform. **2024**, 62, 102629. [[Google Scholar] [CrossRef] [Scilit

.84 Norrena, J.; Louhenkilpi, S.; Visuri, V.V.; Alatarvas, T.; Bogdanoff, A.; Fabritius, T. Coupling of solidification and heat transfer simulations with interpretable machine learning algorithms to predict transverse cracks in continuous casting of steel. [Steel Res. Int. **2024**, 95, 2300529. [Google Scholar] [CrossRef] [Scilit

.85 Cho, K.; Kim, G.; Kwon, S.H.; Yim, C.H.; Hong, D.G. Prevention of thermal crack in steel slab using neural networks model to predict impact absorption energy. Steel [Res. Int. **2024**, 95, 2300732. [Google Scholar] [CrossRef] [Scilit

.86 Miriyala, S.S.; Subramanian, V.R.; Mitra, K. TRANSFORM-ANN for online

optimization of complex industrial processes: Casting process as case study. Eur. [J. Oper. Res. **2018**, 264, 294–308. [Google Scholar] [CrossRef] [Scilit

87. Grešovnik, I.; Kodelja, T.; Vertnik, R.; Sencic, B.; Kovacic, M.; Sarler, B. Application of artificial neural networks in design of steel production path. Comput. Mater. Contin. [**2012**, 30, 19–38. [Google Scholar

88. Grešovnik, I.; Kodelja, T.; Vertnik, R. A software framework for optimization of process parameters in material production. Appl. Mech. Mater. **2012**, 101, 838. [[Google Scholar] [CrossRef] [Scilit

89. Lu, Z.; Ren, N.; Xu, X. Real-time prediction and adaptive adjustment of continuous casting based on deep learning. Commun. Eng. **2023**, 2, 34. [Google Scholar] [[CrossRef] [Scilit

90. Logunova, O.S.; Matsko, I.I.; Posohov, I.A.; Luk'ynov, S.I. Automatic system for intelligent support of continuous cast billet production control processes. Int. J. [Adv. Manuf. Technol. **2014**, 74, 1407–1418. [Google Scholar] [CrossRef] [Scilit

91. Matsko, I.I. Adaptive fuzzy decision tree with dynamic structure for automatic process control system of continuous cast billet production. IOSR J. Eng. **2012**, 2, [53–55. [Google Scholar] [CrossRef] [Scilit

92. Takalo-Mattila, J.; Heiskanen, M.; Kyllönen, V. Explainable steel quality prediction system based on gradient boosting decision trees. IEEE Access **2022**, 10, 68099. [[Google Scholar] [CrossRef] [Scilit

مشخصات و حقوق انتشار

مقاله اصلی: *Research Progress on Application of Machine Learning in Continuous Casting*، نوشته Jiahui Zhang، Shuai Zhang، Jinghao Shao، Zhaofeng Wang و Yuqi Pang؛ نشریه Metals، سال ۲۰۲۵، جلد ۱۵، مقاله ۱۳۸۳. **DOI:** 10.3390/met15121383.

لینک منبع: https://www.mdpi.com/2075-4701/15/12/1383

مجوز متن و دو تصویر بازنشرشده: Creative Commons Attribution 4.0 International (CC BY 4.0).
این متن، ترجمه فارسی از مقاله انگلیسی است و ترجمه، تغییر محسوب می‌شود. نام نویسندگان، اطلاعات منبع و ارتباط با اثر اصلی حفظ شده‌اند. شکل‌های ۳ تا ۸ به دلیل احرازنشدن مجوز بازنشر مستقل، در نسخه فارسی تکثیر نشده‌اند و فقط به آن‌ها ارجاع داده شده است؛ نسخه اصلی آن‌ها در وب‌سایت ناشر قابل مشاهده است.

نسخه آنلاین مقاله: https://landing.steelexperts.ir/2026/10/27/sx-r046-machine-learning-continuous-casting/

SteelExperts.ir