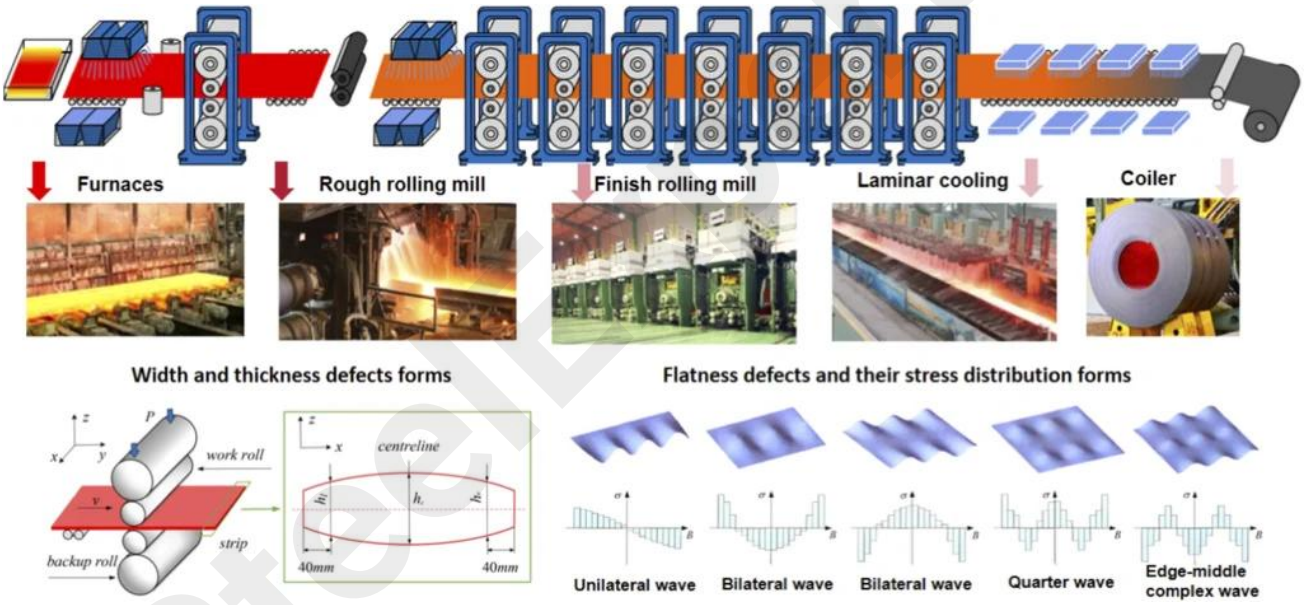
مرکز دانش شبکه خبرگان صنعت فولاد

نورد گرم در عصر هوش مصنوعی؛ به‌سوی افزایش بهره‌وری، کیفیت و پایداری در صنعت فولاد

مقالات تخصصی | علی ارجمندی اصل | ۱۴۰۵/۰۸/۰۴

مرور تخصصی کاربردهای هوش مصنوعی و یادگیری ماشین در نورد گرم فولاد؛ از پیش‌بینی نیروی نورد، تاج، ضخامت و خواص مکانیکی تا تشخیص عیوب، کنترل تطبیقی و بهره‌وری منابع.



چکیده

تولید پایدار، که ملاحظات زیست‌محیطی را با عملکرد مطلوب خطوط صنعتی پیوند می‌دهد، به یکی از جهت‌گیری‌های اصلی آینده صنعت تبدیل شده است. هم‌زمان، پیشرفت سریع یادگیری ماشین و یادگیری عمیق، تحول هوشمند نورد گرم را شتاب داده است؛ فرایندی که به‌طور سنتی به انرژی و مواد اولیه فراوان نیاز دارد.

این مقاله با تمرکز بر مراحل اصلی نورد گرم، کاربردهای یادگیری ماشین را در پیش‌بینی و کنترل شاخص‌های

کلیدی کیفیت، از جمله تاج ورق (Crown)، ضخامت و عرض، به‌صورت نظام‌مند مرور می‌کند. ترکیب داده‌های فرایندی از منابع گوناگون با الگوریتم‌های هوشمند پیشرفته، چارچوبی برای پیش‌بینی کیفیت در محیط نورد گرم فراهم می‌آورد؛ چارچوبی که امکان پایش دقیق و تنظیم به‌موقع انحراف تاج، نوسان ضخامت و تغییرات عرض را فراهم می‌کند.

نتایج مطالعات مرورشده نشان می‌دهد روش‌های یادگیری ماشین می‌توانند وابستگی‌های پیچیده و غیرخطی میان پارامترهای فرایند و کیفیت محصول را شناسایی کنند و در نتیجه، پایداری تولید و یکنواختی کیفیت را بهبود دهند. مقاله همچنین چارچوبی مبتنی بر ادراک چندوجهی برای هشدار زودهنگام و بهینه‌سازی پویا مطرح می‌کند تا تنظیم هماهنگ پارامترها در زمان واقعی امکان‌پذیر شود. حاصل این رویکرد، هم مسیری فنی برای تولید هوشمند است و هم راهنمایی کاربردی برای افزایش پایداری و بهره‌وری منابع در نورد گرم.

۱. مقدمه

قلب تولید محصولات تخت نوردگرم باکیفیت، قفسه‌ها و تجهیزات نورد گرم است. با وجود پیشرفت چشمگیر سامانه‌های کنترل فرایند در این خطوط، مشکلاتی مانند دقت پیش‌بینی نیروی نورد، عیوب تاج، تغییرات ضخامت و انحراف عرض همچنان بازده تولید و امکان بهینه‌سازی کیفیت را محدود می‌کنند (Muntin, 2019).

تحول دیجیتال در تولید و دسترسی روزافزون به داده‌های فرایندی و کیفی، ظرفیت تازه‌ای برای استفاده از یادگیری ماشین و یادگیری عمیق در تضمین کیفیت محصولات نوردی ایجاد کرده است (Durmaz et al., 2026; Zong et al., 2025a). این همگرایی، پیش‌بینی و تصمیم‌گیری پیشرفته‌تر را ممکن می‌سازد و شیوه پایش، کنترل و بهینه‌سازی کیفیت را در سامانه‌های تولید امروزی دگرگون می‌کند (Zong et al., 2026a, 2026b, 2026c).

نوآوری‌های مبتنی بر هوش مصنوعی در پیش‌بینی نیروی نورد، بهینه‌سازی نیروی خم‌کاری غلتک‌ها، کنترل ضخامت و پروفیل، بهبود تختی ورق و مهار ارتعاشات، مرزهای دقت، پایداری و کارایی را جابه‌جا کرده‌اند. با پیشرفت اتوماسیون صنعتی و فناوری‌های هوشمند، استفاده از تحلیل پیشرفته داده و یادگیری ماشین در نورد گرم فرصت مهمی برای افزایش عملکرد خط، ارتقای کیفیت محصول و بهبود بهره‌وری عملیاتی به شمار می‌رود.

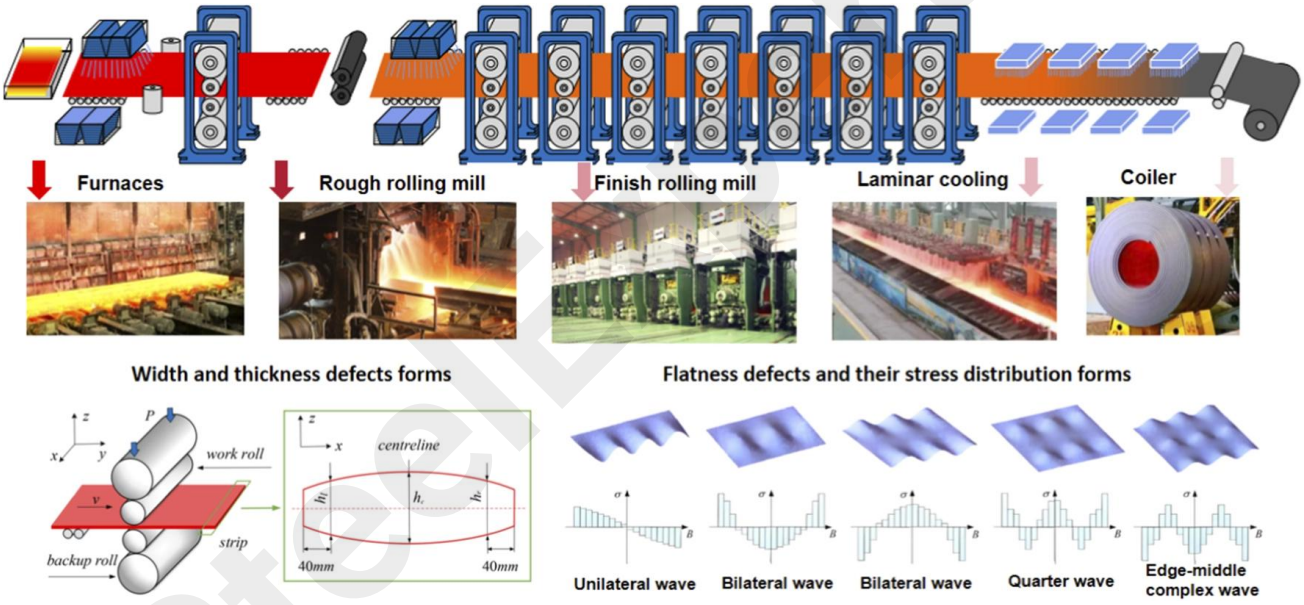
این مرور، تحولات شاخص و دستاوردهای نماینده هوشمندسازی صنعت فولاد را با تمرکز بر نورد گرم بررسی می‌کند. دامنه بررسی از گرم‌کردن تختال و نورد خشن تا نورد نهایی، خنک‌کاری و کلاف‌پیچی امتداد دارد و اثر فناوری‌های هوشمند را بر کیفیت محصول، پایداری فرایند و بهره‌وری تولید می‌سنجد. نویسنده با جمع‌بندی پیشرفت‌های اخیر و روندهای نوظهور، در پی ارائه چارچوبی منسجم و مسیرهای اجرایی برای نورد گرم هوشمند

و پایدار است.

۲. هوشمندی دیجیتال در کاربردهای صنعتی

۲.۱. چالش‌های ارتقای کیفیت

دقت ضخامت در محصولات نوردگرم باید در محدوده‌ای سخت‌گیرانه کنترل شود. همان‌طور که شکل ۱ نشان می‌دهد، عیوب تاج ورق، انحراف عرض و تغییرات ضخامت از مهم‌ترین چالش‌های کیفی نورد گرم‌اند. این مشکلات می‌توانند بر عملکرد محصول نهایی اثر بگذارند، تختی ورق را کاهش دهند، پایداری نورد را مختل کنند و هزینه‌های عملیاتی را افزایش دهند.



شکل ۱. نمای شماتیک عیوب در فرایند نورد گرم. منبع تصویر: Zong (2026)، Frontiers in Materials، با مجوز CC BY 4.0.

کنترل پایدار نورد گرم تحت تأثیر عوامل متعددی قرار دارد: نوسان ترکیب شیمیایی مواد، یکنواخت‌نبودن ضخامت و توزیع عرض تختال ورودی، و تغییرات شرایط دینامیکی نورد (Zong et al., 2025b; 2022; 2021). این تغییرات عدم‌قطعیت‌هایی ایجاد می‌کنند که پیش‌بینی و مهارشان با روش‌های سنتی دشوار است.

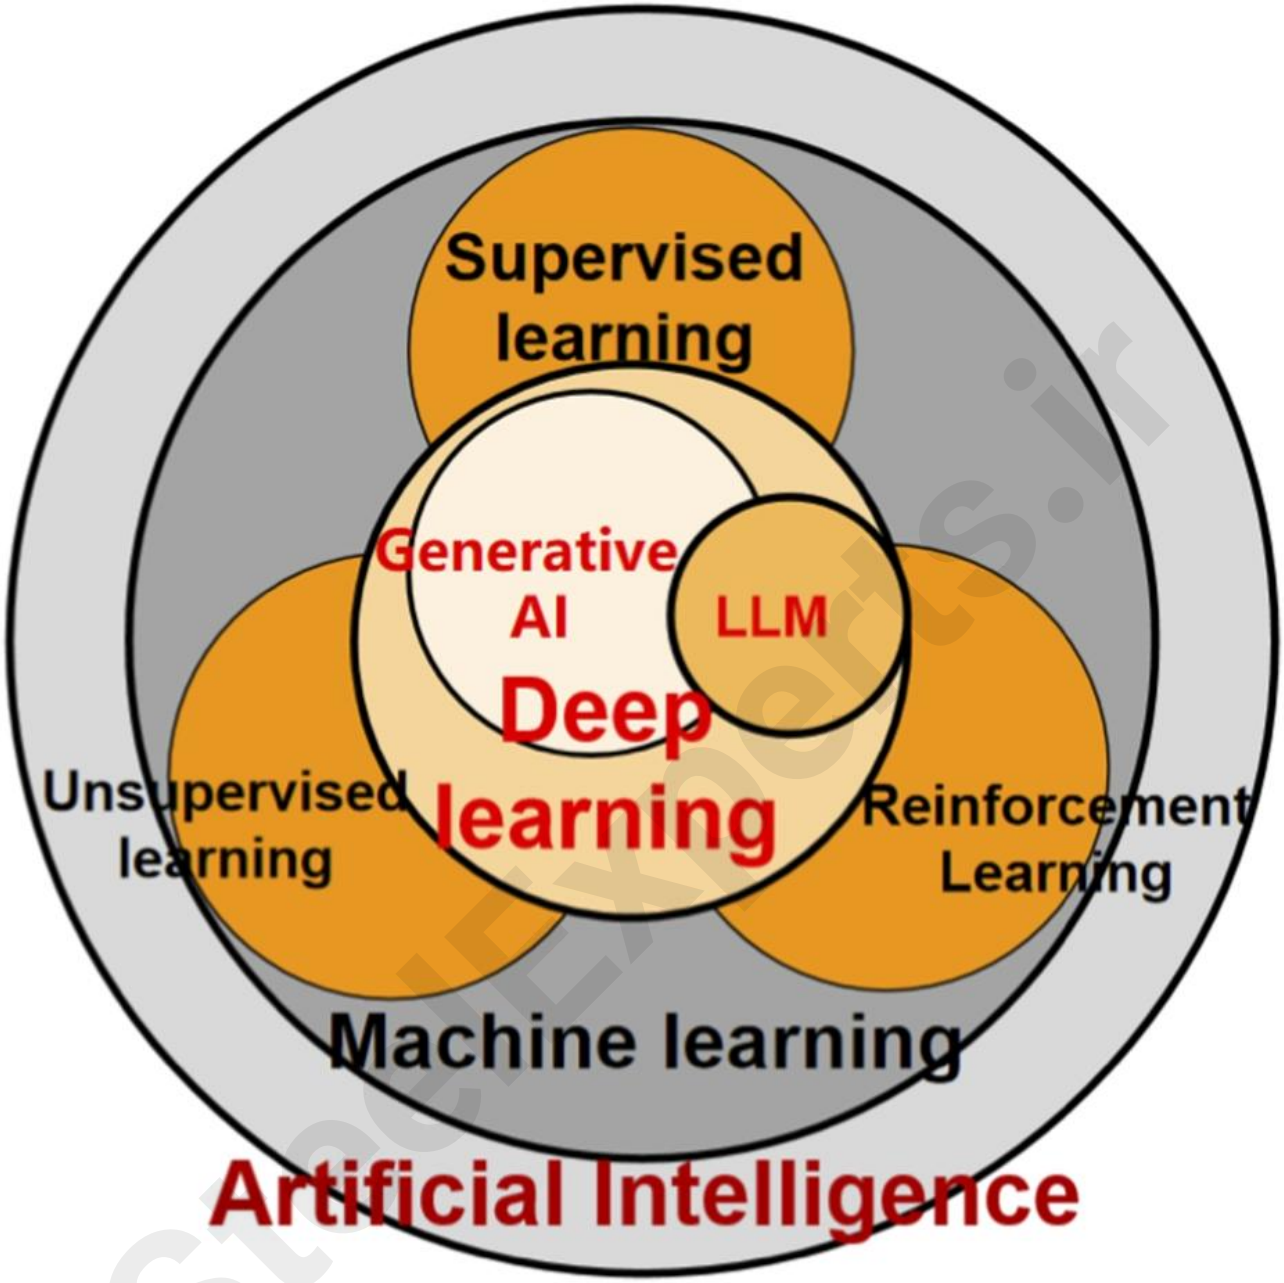
هرچند فناوری‌های هوشمند راهی عملی برای مواجهه با این وضعیت فراهم می‌کنند، مدل‌سازی دقیق تغییرات و سازگارکردن مدل در زمان واقعی هنوز چالش‌برانگیز است. تحقق چنین قابلیتی به الگوریتم‌های پیشرفته و حجم کافی از داده‌های باکیفیت برای آموزش و اعتبارسنجی قابل‌اعتماد نیاز دارد. از سوی دیگر، پیوستگی و سرعت بالای نورد گرم ایجاب می‌کند سامانه هوش مصنوعی تصمیم‌های خود را بی‌درنگ اتخاذ کند؛ قابلیتی که

هنوز برای تضمین پایداری در کاربردهای صنعتی بزرگ‌مقیاس به بلوغ کامل نرسیده است.

۲.۲. طبقه‌بندی نظام‌مند روش‌های هوش مصنوعی

شکل ۲ تصویری سلسله‌مراتبی از شاخه‌های اصلی هوش مصنوعی و ارتباط آن‌ها ارائه می‌دهد و بر الگوهای یادگیری ماشینِ مرتبط با نورد هوشمند فولاد تمرکز دارد. هوش مصنوعی چتر مفهومی گسترده‌تری است و یادگیری ماشین یکی از پایه‌های فنی اصلی آن به شمار می‌رود. در این حوزه، سه الگوی عمده یادگیری نظارت‌شده، یادگیری بدون نظارت و یادگیری تقویتی اهمیت ویژه‌ای دارند؛ به‌ویژه آنجا که هدف، بهینه‌سازی فرایند و طراحی راهبرد کنترل باشد.

SteelExperts.ir



شکل ۲. الگوریتم‌ها و شاخه‌های یادگیری ماشین در نورد هوشمند فولاد. منبع تصویر: Zong (2026)، Frontiers in Materials، CC BY 4.0.

در کنار دقت پیش‌بینی، توضیح‌پذیری مدل مسئله‌ای حیاتی است که گاه در استقرار صنعتی یادگیری ماشین نادیده گرفته می‌شود. برخلاف پژوهش‌های آزمایشگاهی، مهندسان و اپراتورهای خط باید نه‌تنها به خروجی مدل اعتماد کنند، بلکه بفهمند مدل بر چه مبنایی به آن نتیجه رسیده است؛ به‌خصوص هنگامی که پیش‌بینی با محدوده مورد انتظار اختلاف دارد. حتی مدل بسیار دقیق نیز اگر فاقد شفافیت باشد، ممکن است به دلیل نگرانی‌های ایمنی در محیط کارخانه پذیرفته نشود.

روش‌هایی مانند SHAP (SHapley Additive exPlanations) و نمودارهای وابستگی جزئی می‌توانند اثر متغیرهایی نظیر دمای ورود، سرعت نورد و نسبت کاهش ضخامت را بر پیش‌بینی کمی‌سازی کنند. این تحلیل‌ها

علاوه بر روشن‌ترکردن رفتار مدل، ناسازگاری‌های احتمالی با مبانی فیزیکی فرایند را آشکار می‌کنند و از این راه به اصلاح مستمر مدل و جلب اعتماد متخصصان کمک می‌رسانند.

۲.۳. روش انجام مرور نظام‌مند

برای پوشش جامع پژوهش‌ها، در ماه مه ۲۰۲۶ جست‌وجوی نظام‌مند ادبیات در پنج پایگاه Elsevier، CNKI، IEEE، Springer و Scopus انجام شد. مقالات منتشرشده در فاصله سال‌های ۲۰۲۰ تا ۲۰۲۶ با کلیدواژه‌های «فرایند نورد»، «نورد گرم»، «نورد سرد»، «تولید هوشمند»، «هوش مصنوعی»، «یادگیری ماشین» و «یادگیری عمیق» در عنوان و چکیده جست‌وجو شدند. سپس با بررسی متن کامل و حذف موارد نامرتبط، مجموعه نهایی به ۵۵ مقاله رسید. این روش، مبنایی ساختاریافته برای بررسی هم‌زمان مبانی علمی و روندهای نوظهور فراهم کرده است.

۲.۴. پیش‌بینی و بهینه‌سازی هوشمند

هوش مصنوعی با ترکیب حسگری دقیق و تحلیل کلان‌داده، امکان بهینه‌سازی هوشمند مراحل گرم‌کردن تختال، نورد خشن، نورد نهایی و خنک‌کاری را فراهم می‌کند. مدل‌های هوشمند می‌توانند توزیع دما، تحول ریزساختار و روند تغییرات تاج و ضخامت را پیش‌بینی کرده و با تنظیم پویا و متناسب برنامه نورد و پارامترها، پایداری فرایند، بازده تولید و توان جبران تغییرات ماده ورودی را بهبود دهند.

پیش‌بینی و کنترل پویای نیروی نورد، نیروی خم‌کاری غلتک و فاصله غلتک‌ها نیز در حفظ ریتم پایدار نورد و کاهش نوسانات ضخامت و تختی نقش دارد. در خنک‌کاری لایه‌ای و کلاف‌پیچی، همین فناوری می‌تواند مسیر خنک‌کاری، دمای کلاف‌پیچی و یکنواختی خواص را با دقت بیشتری پیش‌بینی و در یک حلقه بسته کنترل کند. جدول ۱، کاربردهای گزارش‌شده هوش مصنوعی در نورد گرم را در پژوهش‌های بین‌المللی مقایسه می‌کند.

کاربرد مدل	پژوهش	کشور	روش یادگیری ماشین	خط نورد	ویژگی‌های داده ورودی	داده آموزش و آزمون	شاخص ارزیابی
پیش‌بینی نیروی خم‌کاری	Li W. G. et al. (2020)	چین	ANN، SVR، CART، BRT، LASSO و GPR	نورد گرم نواری ۱۵۸۰ میلی‌متری، ۸ قفسه نهایی	دمای ورودی، ضخامت ورودی و خروجی، عرض نوار، نیرو و سرعت نورد، جابه‌جایی غلتک، تنش تسلیم و پروفیل هدف	۱۴۴۰ جفت داده اندازه‌گیری‌شده نیروی خم‌کاری	R^2=0.9735؛ RMSE=8.51؛ MAE=6.61
پیش‌بینی نیروی خم‌کاری	Svyetlichnyy (2025)	لهستان	مدل مرتبه‌کاهش‌یافته ROM مبتنی بر FNN	قفسه چهارغلتکه	نیروی نورد، عرض ورق، تاج اولیه غلتک، نیروی ضدخم‌کاری، قطر و خواص الاستیک غلتک	۳۵۷۵ نمونه شبیه‌سازی FEM	حداکثر خطای تحدب 0.0451 mm؛ دقت نیرو 79.6%؛ بیشینه خطای ضدخم‌کاری 253.5 kN؛ انحراف معیار 59.8 kN

کاربرد مدل	پژوهش	کشور	روش یادگیری ماشین	خط نورد	ویژگی‌های داده ورودی	داده آموزش و آزمون	شاخص ارزیابی
پیش‌بینی نیروی نورد	Hwang et al. (2020)	کره جنوبی	DNN و درخت تصمیم مبتنی بر گرادیان بوستینگ	نورد گرم برگشتی	شعاع غلتک، زمان، دمای اولیه، ابعاد و گرید تختال؛ سرعت و کشش هر پاس، ضخامت، دما، کاهش ضخامت، طول تماس و کرنش	۵۰٪ آموزش و ۵۰٪ آزمون برای گرید هدف	نیروی نورد: RE=1.176% و RA=98.87%؛ دما: RE=1.010% و RA=99.25%
پیش‌بینی نیروی نورد	Liu et al. (2021)	چین	PCA–IPSO–SVR	نورد گرم نواری	۸ متغیر: دما، درصد کاهش، عرض و ضخامت اولیه، کشش جلو و عقب، قطر غلتک و سرعت	۲۱۸ نمونه؛ ۸۰٪ آموزش و ۲۰٪ آزمون	R^2=0.9821؛ MAPE=4.8153%؛ RMSE=1091.6 MAE=735.88
پیش‌بینی نیروی نورد	Cui et al. (2022a)	چین	BPNN و الگوریتم ژنتیک	نورد نهایی فولاد میکروآلیاژی تیتانیوم، ۷ پاس	ترکیب C،Si،Mn،Nb،Ti،N ؛ دما، کرنش، نرخ کرنش، فاصله پاس‌ها، ضخامت و شعاع غلتک	۵۸۳ نمونه داده فولاد میکروآلیاژی Ti	RMSE کمتر از 0.05
پیش‌بینی نیروی نورد و گشتاور	Thakur et al. (2023)	هند	مدل تجمیعی LM،SVM،RF و XGBoost	نورد ورق ضخیم برگشتی	زمان گرم‌کردن، تاج غلتک، ضخامت، عرض، طول، دما، سرعت، زمان انتظار، کاهش، کرنش و نرخ کرنش	بیش از ۱۰۰۰ داده صنعتی؛ ۷۵٪ آموزش و ۲۵٪ آزمون	نیرو: R^2=98.45%، RMSE=1568 kN؛ گشتاور: R^2=99.08%، RMSE=216 kN·m
پیش‌بینی نیروی نورد	Wang H. Y. et al. (2024)	چین	مدل فیزیکی و GBDT	نورد نهایی ۲۲۵۰ میلی‌متری	۴۲ ویژگی از ترکیب شیمیایی، پارامترهای فرایند و ضرایب مقاومت تغییرشکل و وضعیت تجهیزات	۱۱۴۱۳ نمونه؛ ۷۰٪ آموزش و ۳۰٪ آزمون	MAPE کمتر از 4.13%؛ خطای پیش‌بینی کمتر از 5%
پیش‌بینی نیروی نورد	Zhang S. H. et al. (2025)	چین	مدل مکانیزمی میدان سرعت بیضوی (EVF) همراه با پیش‌بینی هموارسازی نمایی تک‌پارامتری (SPESP) و دوپارامتری (DPESP)	خط تولید نورد گرم ورق ضخیم	پارامترهای نورد فولاد Q345 شامل سرعت غلتک، دمای نورد، کرنش، ضخامت ورودی و خروجی و عرض ورق	۸ مجموعه داده پیوسته از تولید فولاد Q345	میانگین خطا: 2.83%؛ حداکثر خطا: 6.57%
پیش‌بینی دما	Barrios et al. (2020)	مکزیک	سامانه فازی Takagi–Sugeno–Kang نوع ۲ با یادگیری ترکیبی	خط صنعتی دارای دو قفسه خشن برگشتی، ۶ قفسه نهایی و کوره Walking Beam	زمان و دمای خروج نورد خشن، زمان رسیدن به پوسته‌شکن، دمای ورودی آن، پیش‌بینی مدل و کنترل PI	۳۷۰۰۰ مجموعه	خطای میانگین 0.17°C؛ MAE=4.16°C؛ RMSE=5.35°C
پیش‌بینی دمای نهایی خنک‌کاری	Du et al. (2022)	چین	BO–XGBoost	نورد گرم ورق متوسط و ضخیم	۱۵ ورودی: عناصر آلیاژی، دمای آغاز خنک‌کاری، نرخ سرمایش، سرعت ورق، آب مصرفی، تعداد هدرهای فعال و دما و ابعاد ورق	۳۱۹۷۱ داده؛ ۸۰٪ آموزش و ۲۰٪ آزمون	آموزش: MAE=1.47، RMSE=1.97، R^2=0.994738؛ آزمون: MAE=2.03، RMSE=2.91، R^2=0.988590
پیش‌بینی دمای خروج نورد نهایی	Song et al. (2023)	چین	Extremely Randomized Trees بهینه‌شده با Harris Hawks	خط تولید نورد گرم	۳۹ ویژگی نورد نهایی شامل ضخامت و دمای تختال میانی، کاهش، اصطکاک، نیروی نورد و سرعت F1–F6	۲۴۷۰ مجموعه؛ ۱۷۲۹ آموزش و ۷۴۱ آزمون	MAE=4.1368؛ MSE=31.97؛ R^2=0.9322

کاربرد مدل	پژوهش	کشور	روش یادگیری ماشین	خط نورد	ویژگی‌های داده ورودی	داده آموزش و آزمون	شاخص ارزیابی
پیش‌بینی خواص مکانیکی	Li X. et al. ((2020	چین	CNN با ماژول Inception اصلاح‌شده و شبکه پیش‌خور عمیق	نورد گرم ۱۷۸۰ میلی‌متری	۲۰ عامل از دماهای فرایند، ضخامت و ترکیب شیمیایی	۳۷۱۲۴ مجموعه داده	MAPE=3.14%؛ RMSE=22.87 MPa؛ خطای مطلق ±10% در 95.53% نمونه‌ها
پیش‌بینی خواص مکانیکی	Xie et al. ((2021	چین	DNN	خط نورد گرم نواری	۲۷ ویژگی شامل طول، دما، سرعت، دبی آب، نرخ سرمایش، ترکیب شیمیایی و تعداد پاس	۱۱۱۰۱ نمونه؛ ۸۰٪ آموزش و ۲۰٪ آزمون	R^2=0.907؛ RMSE استحکام تسلیم 21.06 MPa؛ کشش 16.67 MPa؛ ازدیاد طول 2.36%؛ انرژی ضربه 39.33 J
پیش‌بینی خواص مکانیکی	Hu et al. ((2021	چین	شبکه عصبی بیزی پس‌انتشار و Levenberg–Marquardt	نورد نواری ۱۷۸۰ میلی‌متری	C،Si،Mn،Nb،V،Ti و دماهای نورد و کلاف‌پیچی	۴۰۰۰ آموزش و ۹۶۴ آزمون	سهم خطای قابل قبول: تسلیم ±6% برابر 87.21%؛ کشش ±6% برابر 93.28%؛ ازدیاد طول ±4% برابر 94.7%
پیش‌بینی بازه خواص مکانیکی	Peng et al. ((2022	چین	LUBE، BLS و ABC–BLS	خط نورد گرم نواری	۳۹ متغیر ترکیب شیمیایی و پارامترهای نورد و خنک‌کاری	۱۳۳۵ نمونه؛ ۸۵٪ آموزش و ۱۵٪ آزمون	PICP=0.93؛ PINAW=0.36؛ NCWC=23.36
پیش‌بینی استحکام تسلیم	Cui et al. ((2022b	چین	DNN بهینه‌شده با PSO	خط نورد گرم نواری	۲۲ ویژگی شامل ترکیب، گرمایش، نورد، سرعت خنک‌کاری، دمای کلاف و پارامترهای ریزساختاری	۲۸۰ برچسب‌خورده و ۹۶۴۳ بدون برچسب	RMSE آموزش 17.221 MPa؛ آزمون 11.277 MPa
پیش‌بینی خواص مکانیکی	Cui et al. ((2023	چین	ترکیب متالورژی فیزیکی و ANN	نورد گرم نواری	۵۲ ویژگی ترکیب، عملیات حرارتی، ابعاد، نیرو، سرعت و دمای کلاف همراه با فازها و رسوبات	۳۱۳۳ داده صنعتی؛ ۸۰٪ آموزش و ۲۰٪ آزمون	استحکام تسلیم: R^2=0.945، RMSE=19.004 MPa؛ ازدیاد طول: R^2=0.945، RMSE=2.039%
پیش‌بینی خواص مکانیکی	Li F. F. et al. (2023	چین	جنگل آبشاری چنددانه‌ای gcForest	خط نورد گرم پیوسته	سری زمانی سه‌بعدی دما و ضخامت همراه با ترکیب شیمیایی	۳۹۰ نمونه	دقت گرید Q235B: تسلیم 94.97%، کشش 96.36%؛ گرید 510L: تسلیم 96.22%، ازدیاد طول 94.00%
پیش‌بینی استحکام تسلیم	Shi et al. ((2023	چین	BO–XGBoost	خط نورد گرم گروه Laiwu	۲۰ ویژگی: ترکیب، دماهای گرم‌کردن و نورد، نرخ خنک‌کاری، Ac1 و Ac3 و ضخامت و درصد کاهش	۳۸۵۶ نمونه؛ ۳۰۸۴ آموزش و ۷۷۲ آزمون	Er=93.52%؛ MAE=13.56 MPa؛ RMSE=20.19 MPa
پیش‌بینی ریزساختار و خواص	Li X. et al. ((2023	چین	BPNN	خط تولید نورد گرم	ترکیب و دماهای فرایند، کرنش، فازها، اندازه دانه و خواص مکانیکی	کلان‌داده صنعتی گریدهای مختلف	دقت در خطای ±6% استحکام تسلیم بیش از 90% و کششی بیش از 95%؛ خطای مطلق ازدیاد طول ±4% در بیش از 90%
پیش‌بینی ریزساختار	Idzik et al. ((2024	آلمان	DDPG	نورد گرم آزمایشگاهی برگشتی	ترکیب فولاد، کاهش هر پاس، فاصله پاس‌ها، سرعت، اندازه دانه آستنیت و بازتبلور	شبیه‌سازی و داده آزمایشگاهی	خطای اندازه دانه فریت کمتر از 3 m
پیش‌بینی خواص مکانیکی	Song et al. ((2024	چین	MIC، MSVR، SVR، RF و SHAP	نورد گرم نواری	۱۳۹ پارامتر از ذوب، ریخته‌گری، کوره، نورد خشن و نهایی، کلاف و مشخصات محصول	۹۵۳۱ نمونه؛ ۸۰٪ آموزش و ۲۰٪ آزمون	در منبع اصلی مقدار تجمیعی ارائه نشده است

کاربرد مدل	پژوهش	کشور	روش یادگیری ماشین	خط نورد	ویژگی‌های داده ورودی	داده آموزش و آزمون	شاخص ارزیابی
پیش‌بینی پروفیل و خواص	Zhang R. X. et al. ((2024	چین	شبکه Elman بهینه‌شده با Cuckoo Search	نورد گرم نواری	۴۰ ویژگی از F1–F7، نیروی نورد، سرعت، خم‌کاری، فاصله و جابه‌جایی غلتک و دما و تاج	۵۴۹۰ نمونه؛ ۸۰٪ آموزش و ۲۰٪ آزمون	MAE=1.3693؛ MSE=3.0843؛ MAPE=3.9025%؛ R²=0.95123
پیش‌بینی خواص مکانیکی	Wang K. Y. et al. ((2024	چین	انتخاب ویژگی تجمیعی MIC+SHAP+RF و XGBoost بهینه‌شده با ISOA	نورد گرم	۲۶ ویژگی ترکیب و دماها و ابعاد ورق	۳۷۷۰ نمونه؛ ۸۰٪ آموزش و ۲۰٪ آزمون	تسلیم: R²=0.951، RMSE=25.40 MPa؛ کششی: R²=0.971، RMSE=20.35 MPa؛ ازدیاد طول: R²=0.949، RMSE=1.87%
پیش‌بینی خواص	Liu et al. ((2024	چین	مدل نیمه‌تجربی، ANN، SVM، RF و تلفیق داده‌های چندوجهی	خطوط نورد گرم با مشخصات متفاوت	داده‌های شبیه‌سازی حرارتی، نیرو، پوسته اکسیدی، اصطکاک، فاز و داده‌های واقعی تولید	داده آزمایشگاهی و صنعتی L485M و فولادهای رده ۷۰۰ MPa	بهبود دقت بیش از 40%
پیش‌بینی خواص مکانیکی	Zhao et al. ((2025	چین	شبکه Simple (Recurrent Unit (SRU	نورد گرم نواری	۱۵ عنصر آلیاژی، زمان و دماهای کوره، F1–F7 و دمای کلاف‌پیچی	۵۲۳۹ داده واقعی کلاف	کشش: R²=0.91 و 88.63% در ±5%؛ تسلیم: R²=0.92 و 94.17% در ±5%؛ ازدیاد طول: R²=0.88 و 74.50% در ±5%
پیش‌بینی ریزساختار و خواص	Wu et al. ((2025	چین	هوش ترکیبی انسان–ماشین، رگرسیون نمادین، ML ژنتیکی و یادگیری عمیق چندوجهی	خطوط نورد گرم چندگریدی	داده صنعتی و آزمایشگاهی ترکیب، نیرو، تبلور، رسوب، CCT و تصاویر ریزساختار	داده‌های آزمایشگاهی و صنعتی	در فولاد 700 MPa کاهش نوسان تسلیم 67%، کشش 64%، ازدیاد طول 55%؛ در X80M کاهش Cr/Ni/Cu به‌ترتیب 20%/50%/100%
پیش‌بینی خواص مکانیکی	Li J. D. et al. (2025)	چین	LightGBM بهینه‌شده با PSO	نورد گرم نواری ۱۴۲۲ میلی‌متری	ترکیب شیمیایی، ضخامت و دماهای کوره و نورد و کلاف	۱۹۴۵ نمونه؛ ۷۰٪ آموزش، ۱۰٪ تنظیم و ۲۰٪ آزمون	R²=0.80؛ MAE=10.02 MPa؛ RMSE=13.18 MPa
پیش‌بینی عرض	Ding and (Guo (2021	چین	PCA و Random Forest	خط نورد گرم پیوسته ۲۲۵۰ میلی‌متری	دهانه غلتک عمودی، گسترش عرض، انقباض سرمایشی، عرض و نیرو و فاصله و سرعت قفسه‌ها	۹۸۳ نمونه؛ ۷۰٪ آموزش و ۳۰٪ آزمون	R² نزدیک 0.999–1؛ MSE=8–11؛ خطای ±5 mm در 96% نمونه‌ها
پیش‌بینی انحراف عرض	Ji et al. ((2022	چین	یادگیری ماشین و الگوریتم ژنتیک (MGH)	نورد گرم نواری	۱۶۹ متغیر شامل ۴۱ متغیر اولیه، ۸ ویژگی فیزیکی و ۱۱۹ ویژگی آماری	۱۲۶۸ نمونه صنعتی و ۱۹۹۴ نمونه عمومی؛ هرکدام ۸۰٪ آموزش و ۲۰٪ آزمون	TeMSE صنعتی 3.49؛ عمومی 0.01771
پیش‌بینی تاج ورق	Song et al. ((2022	چین	SVM	نورد گرم ۱۵۸۰ میلی‌متری با هفت قفسه چهارغلتکه CVC	نیرو، خم‌کاری، فاصله و جابه‌جایی غلتک، سرعت، ضخامت و دماهای ورود و خروج	۲۰۰۰ نمونه؛ ۷۰٪ آموزش و ۳۰٪ آزمون	R²=0.9809؛ RMSE=1.5725
پیش‌بینی تاج ورق	Wang Z. H. et al. ((2023	چین	XGBoost	نورد گرم پیوسته ۱۷۸۰ میلی‌متری	۷۹ متغیر از ضخامت، عرض، نیرو، دما، سرعت و وضعیت غلتک‌های F1–F7	۱۸۰۹ نمونه؛ ۷۰٪ آموزش و ۳۰٪ آزمون	R²=0.971؛ MAE=0.632 m؛ MAPE=2.184%؛ RMSE=2.980 m
پیش‌بینی تاج ورق	Wang L. J. et al. ((2023	چین	Deep Forest	نورد گرم	۳۵ ویژگی از تختال میانی، دما، ضخامت، سرعت، نیرو، خم‌کاری، جابه‌جایی و تاج هر قفسه	۱۰۱۳۳ نمونه؛ ۸۰٪ آموزش و ۲۰٪ آزمون	R²=0.985؛ MSE=6.537؛ MAE=1.587؛ MAPE=2.903%؛ خطای کمتر از 5 m در 93.883%

کاربرد مدل	پژوهش	کشور	روش یادگیری ماشین	خط نورد	ویژگی‌های داده ورودی	داده آموزش و آزمون	شاخص ارزیابی
پیش‌بینی تاج ورق	Zhang H. K. et al. ((2024	چین	SVM–SMOTE و LightGBM	نورد گرم پیوسته ۲۱۶۰ میلی‌متری	۳۵ ویژگی فرایندی، تختال میانی و نیروی خم‌کاری، سرعت و تاج قفسه‌های F1–F6	۴۸۳۰ نمونه؛ ۸۰٪ آموزش و ۲۰٪ آزمون	G-Mean=0.992؛ F1-Macro=0.992؛ MCC=0.987
کنترل شکل و تاج	Sun et al. ((2024	چین	مدل مکانیزمی مبتنی بر دوقلوی دیجیتال	نورد گرم نواری ۲۲۵۰ میلی‌متری	ضخامت، دما، نیرو، سرعت، خم‌کاری و جابه‌جایی غلتک، مدول الاستیسیته	۱۰۰ کلاف تاریخی	R^2=0.83–0.97؛ خطای تاج کمتر از 5 m و تختی کمتر از 5 I-unit؛ RMSE=1.78–2.18 mm
پیش‌بینی عدم‌تعادل تاج	Zhang D. H. et al. ((2024	چین	SMOTE و مدل تجمیعی Stacking	نورد گرم ۲۱۶۰ میلی‌متری	۳۴ متغیر عرض، ضخامت، دما، تختال میانی و مشخصات F1–F6	۶۸۸۴ نمونه	Accuracy=0.9580؛ Recall=0.9595؛ F-score=0.9573؛ AUC=0.9579
بهینه‌سازی تاج نسبی	Wang X. J. et al. ((2024	چین	الگوریتم Spotted Hyena Optimizer اصلاح‌شده	نورد گرم ۱۲۸۰ میلی‌متری	تختال 160×1200×7000 mm؛ محصول 4.4×1200 mm؛ دمای اولیه 1050°C و نهایی 870°C؛ تاج هدف 0.01 mm	داده شبیه‌سازی/فرایندی	کاهش انحراف تاج نسبی از 0.0008345 به 0.00001483
تشخیص عیوب تاج	Ding et al. ((2024	چین	مدل تجمیعی چندمرحله‌ای HMSEN با ADASYN–RENN	نورد گرم SPHC با ضخامت ۲ تا ۳ و عرض ۹۰۰ تا ۱۵۰۰ میلی‌متر	۳۵ متغیر ورودی و تنظیمات F1–F6	۲۵۸۵ کلاف؛ ۷۵٪ آموزش و ۲۵٪ آزمون	MAUC=0.754؛ G-Mean=0.669؛ F1-Macro=0.583
پیش‌بینی پروفیل فولاد سیلیسی	Cui et al. ((2025	چین	CAHA–CatBoost	نورد گرم فولاد سیلیسی ۱۷۸۰ میلی‌متری	۴۳ ویژگی ضخامت و دما، سرعت، نیرو، خم‌کاری، سایش، انبساط و ترکیب شیمیایی	۸۴۵۲ نمونه؛ ۸۰٪ آموزش و ۲۰٪ آزمون	R^2=0.7932
تشخیص عیوب سطحی	Wang D. C. et al. ((2021	چین	رگرسیون لجستیک و DNN بهینه‌شده با GA	نورد گرم نواری	۱۲ پارامتر دماهای کوره، زمان‌های پیش‌گرمایش و همگن‌سازی و دمای R2	۴۲۰۰ نمونه؛ ۳۶۰۰ آموزش/اعتبارسنجی و ۶۰۰ آزمون	دقت آموزش 94.06%؛ آزمون 91.33%
تشخیص عیوب سطحی	Latham and Giannetti ((2023	ولز	CNN (GoogLeNet) و یادگیری انتقالی	نورد گرم با نورد خشن، نهایی و کلاف‌پیچ	سری‌های زمانی انحراف عرض به‌صورت تصویر، دما، خطای مدل عرض، زمان AFC/ANC و مشخصات گرید	۴۹۲ نمونه نورد خشن و ۴۴۸ نمونه نورد نهایی	F1 نورد خشن 91.1؛ نهایی 99.5؛ کلاف‌پیچ 100
تشخیص عیوب سطحی	Huang et al. ((2023	چین	RKD–SARSN مبتنی بر تقطیر دانش	نورد گرم صنعتی	تصاویر RGB عیوب سطحی با اندازه 64×64	۱۶۰۰ تصویر؛ ۱۴۰۰ آموزش و ۶۰۰ آزمون، مطابق داده اعلام‌شده در منبع	دقت مدل معلم 97.83%؛ شاگرد 94.40%؛ F1 کلاس‌ها تقریباً 90%
تشخیص عیوب سطحی	Subburaj et al. (2024	هند و عربستان	DBCW–YOLO اصلاح‌شده از YOLOv5	خط تولید فولاد	تصاویر 220×220 از مجموعه NEU-DET با شش کلاس عیب	۴۵۲ نمونه برای هر کلاس	mAP@0.5=84.66%؛ FPS=78.58؛ AP ترک 70.25% و حفره‌دار 92.36%
تشخیص عیوب سطحی	Zhang S. F. et al. ((2024	چین	YOLOv5 بهبودیافته	نورد گرم	تصاویر عیوب از NEU-DET، GC10-DET و APDDD	تقسیم ۷۰٪ آموزش و ۳۰٪ آزمون	mAP برای NEU-DET=78.5%؛ GC10-DET=67.3%؛ APDDD=59.2%

کاربرد مدل	پژوهش	کشور	روش یادگیری ماشین	خط نورد	ویژگی‌های داده ورودی	داده آموزش و آزمون	شاخص ارزیابی
تشخیص عیوب سطحی	Ma et al. ((2024	چین	YOLOv3 بهبودیافته	نورد گرم	۹ گروه عیب شامل ناخالصی سرباره، پوسته‌شدن، آلودگی صفحه‌ای، چین، خراش، اثر غلتک، فرورفتگی، ترک و پوسته اکسیدی	چند هزار تصویر برچسب‌خورده، با تعداد متفاوت در هر کلاس	دقت و بازخوانی کلی هرکدام 94%؛ برای ناخالصی سرباره دقت 98% و بازخوانی 96%
تشخیص عیوب سطحی	Madhavan et al. ((2025	هند و سوئد	CNN ازپیش‌آموزش‌دیده و درخت تصمیم J48	نورد گرم	۶ نوع عیب سطحی در تصاویر خاکستری NEU-DET	۱۸۰۰ تصویر (۳۰۰ تصویر در هر کلاس)؛ ۸۰٪ آموزش و ۲۰٪ آزمون	Accuracy=99.72%
عیب‌یابی فرایند	Ma et al. ((2023	چین	PCA/PLS/CCA، SVM، kNN، ANN و DBN/AE/CNN	نورد گرم	داده ساختاریافته حسگر و فرایند، سوابق نیمه‌ساختاریافته تعمیرات، تصاویر غیرساختاریافته	شرایط عملیاتی مختلف	شاخص عددی یکپارچه گزارش نشده است
عیب‌یابی و پیش‌هشدار کیفیت	Liu et al. ((2025	چین	A–HPF و SVMSMOTE	نورد گرم ۲۱۶۰ میلی‌متری	۲۹ ویژگی شامل دما و ضخامت ورود/خروج، نیروی نورد و خم‌کاری و جابه‌جایی F1–F6	۲۷۹۶ نمونه اولیه و ۸۸۷۲ نمونه اعتبارسنجی صنعتی	Accuracy>0.93؛ ACC=0.9857؛ AUC=0.9143؛ G-Mean=0.9082؛ F1-Macro=0.9241
پایش سلامت غلتک	Lu et al. ((2024	چین	APSO–RF	نورد گرم پیوسته	۷ پارامتر سرعت، دما، کاهش، زمان، عرض، دبی مایع خنک‌کننده و بیکاری	۸۵۷۱ نمونه؛ ۷۰٪ آموزش و ۳۰٪ آزمون	R^2=0.9813؛ RMSE=5.88 m؛ MAE=4.32 m
طبقه‌بندی سایش غلتک	Huang et al. ((2025	چین	بینایی ماشین و MobileNetV2–WDC	نورد گرم ۲۲۵۰ میلی‌متری	تصاویر 512×512 سایش غلتک در ۷ رده	۱۷۵۰ تصویر (۲۵۰ برای هر رده)؛ ۶۰٪ آموزش، ۲۰٪ اعتبارسنجی، ۲۰٪ آزمون	Accuracy=96.86%
پیش‌بینی ضخامت پوسته اکسیدی	Cui et al. ((2021	چین	BPNN و SVM و بهینه‌سازی GA	نورد گرم نواری	ترکیب شیمیایی، دماهای فرایند، ارتفاع و فشار پاشش پوسته‌زدا	۱۰۶ مجموعه داده سینتیک اکسیداسیون	آموزش: R^2=0.9297، RMSE=0.7702 m؛ آزمون: R^2=0.9409، RMSE=1.1052 m
پیش‌بینی ضخامت	Park et al. ((2020	کره جنوبی و آمریکا	یادگیری ماشین مبتنی بر خوشه‌بندی داده DC–ML	نورد برگشتی چهارغلتکه ورق ضخیم	۱۶ پارامتر ضخامت، مدول قفسه، نیرو، فاصله غلتک، دما، مقاومت ماده، سرعت و نسبت کاهش	۴۳۳۴ داده پاس؛ ۹۰٪ آموزش و ۱۰٪ آزمون	R^2 نیروی نورد 0.8828؛ R^2 ضخامت 0.9999959
پیش‌بینی ضخامت سر نوار	Yu et al. ((2021	چین	DNN	گروه نورد نهایی هشت‌قفسه‌ای	گرید فولاد، دمای ورود، عرض هدف، فاصله، نیروی نورد، سرعت و ضخامت تنظیمی هر قفسه	بیش از ۵۰۰۰ نمونه؛ ۲۰۰ نمونه آزمون	دقت برای ضخامت هدف 3 mm برابر 84%؛ 4 mm برابر 87.2%؛ 6 mm برابر 92.5%
راهبرد خنک‌کاری کلاف	Cao et al. ((2025	چین	بهینه‌سازی چندهدفه ازدحام ذرات	نورد گرم	ترکیب C،Si،Mn،N،Nb،Ti ؛ دمای همگن‌سازی، ضخامت و دمای نهایی، سرعت و نیرو و دمای خنک‌کاری	۶۶۰ داده صنعتی و ۱۳۷ داده آزمایشگاهی CCT	شاخص عددی در جدول گزارش نشده است
جانمایی و خنک‌کاری کلاف	Lee et al. ((2025	کره جنوبی	شبیه‌سازی FEM و دو ANN	محوطه خنک‌کاری کلاف نوردگرم	دمای کلاف‌پیچی، زمان انتقال، دمای کلاف‌های مجاور در شبکه 3×3، زمان خنک‌کاری و دمای ۱۲ نقطه	۴۴۰۰۰ داده خنک‌کاری انتقال و ۴۷۷۳۲ داده محوطه	MAE=3.44؛ MAPE=0.24%

در سال‌های اخیر، روش‌های داده‌محور برای حل مسائل گوناگون نورد گرم به‌طور گسترده به کار گرفته شده‌اند. برای نمونه، ادغام مدل‌های تحلیلی نورد با یادگیری تقویتی، طراحی توالی پاس‌ها را با هدف دستیابی به خواص مشخص ممکن کرده است (Idzik et al., 2024). همچنین، ترکیب یادگیری ماشین و الگوریتم ژنتیک در پیش‌بینی انحراف عرض مؤثر بوده است (Ji et al., 2022). مدل‌های پیش‌بینی هوشمند برای عیوب لبه (Wang et al., 2021)، روش‌های خوشه‌بندی برای پیش‌بینی عوامل مؤثر بر نورد ورق ضخیم (Park et al., 2020) و ترکیب استخراج ویژگیِ یادگیری عمیق با دسته‌بندهای متعارف برای تشخیص عیوب سطحی (Madhavan et al., 2025)، تنوع کاربرد این ابزارها را نشان می‌دهند.

مطالعات جدید، موفقیت یادگیری ماشین و یادگیری عمیق را در طیفی گسترده از مسائل پیش‌بینی در نورد گرم گزارش می‌کنند. برای مقایسه منظم، می‌توان این پژوهش‌ها را بر پایه متغیر هدف در چهار گروه قرار داد: پیش‌بینی پارامترهای فرایند، کنترل کیفیت ابعادی، پیش‌بینی خواص مکانیکی و شناسایی عیوب سطحی. هر گروه از نظر الگوریتم، ویژگی داده و عملکرد گزارش‌شده تفاوت‌هایی دارد.

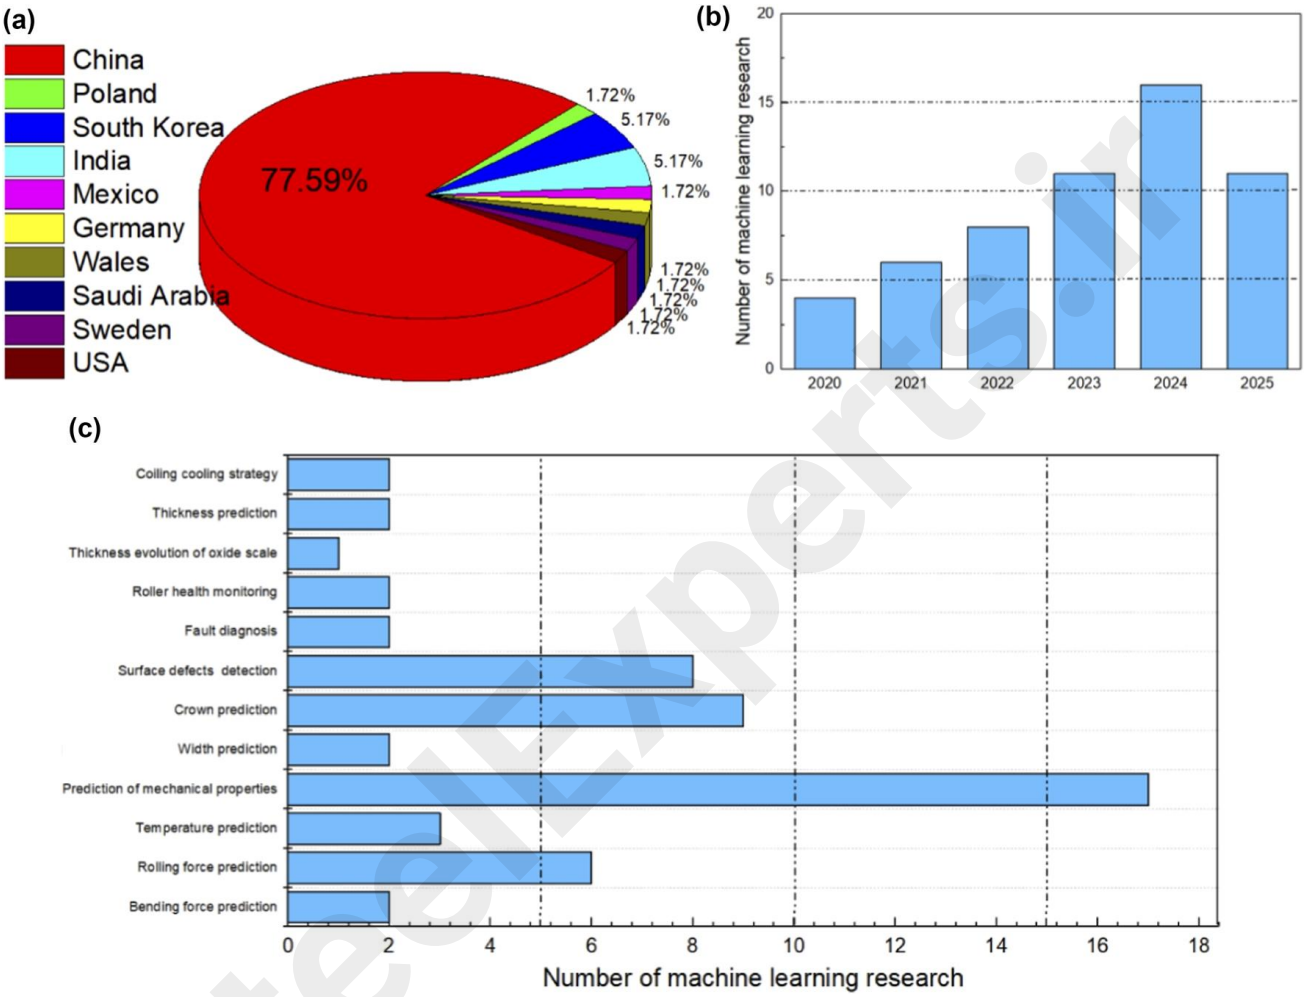
در پیش‌بینی پارامترهای فرایند، مانند نیروی خم‌کاری، نیروی نورد و دما، الگوهای متنوعی از یادگیری ماشین استفاده شده است. برای نمونه، در پیش‌بینی نیروی خم‌کاری مقدار $R^2 = 0.9735$ برای مدل‌های رگرسیونی روی داده‌های صنعتی گزارش شده است (Li W. G. et al., 2020) و (Svyetlichny 2025) امکان استفاده از مدل‌های مرتبه‌کاهش‌یافته مبتنی بر داده شبیه‌سازی اجزای محدود را نشان داده است. پیش‌بینی نیروی نورد یکی از پرتکرارترین موضوعات پژوهشی است و روش‌های تجمیعی و مدل‌های ترکیبی فیزیکی–داده‌محور اغلب از یک الگوریتم منفرد بهتر عمل می‌کنند.

برای نمونه، Liu و همکاران (۲۰۲۱) با روش PCA-IPSO-SVR به $R^2 = 0.9821$ رسیدند؛ Thakur و همکاران (۲۰۲۳) با یادگیری تجمیعی، دقت 98.45% را گزارش کردند؛ و Zhang و همکاران (۲۰۲۵) نشان دادند هموارسازی آگاه از فیزیک می‌تواند میانگین خطا را به 2.83% کاهش دهد. در پیش‌بینی دما، که برای کنترل ریزساختار اهمیت فراوان دارد، مدل‌های فازی ترکیبی و BO-XGBoost به خطای RMSE در حدود 5.35 °C و 2.91 °C رسیده‌اند (Barrios et al., 2020; Du et al., 2022).

در پیش‌بینی خواص مکانیکی، ترکیب شیمیایی و پارامترهای فرایند ورودی‌های پرتعداد و پُربعدی به مدل تحمیل می‌کنند. یادگیری عمیق و روش‌های تجمیعی برای پیش‌بینی استحکام تسلیم، استحکام کششی و ازدیاد طول به کار رفته‌اند. مقدار R^2 گزارش‌شده در این مطالعات معمولاً در بازه 0.80–0.95 قرار دارد و در بسیاری از آن‌ها، درصد نمونه‌های دارای خطای نسبی قابل قبول، مثلاً ±۵٪ برای استحکام کششی، بیش از ۹۰٪ است (Li X. et al., 2023; Zhao et al., 2025).

ترکیب اصول متالورژی فیزیکی با شبکه عصبی مصنوعی (Cui et al., 2023) و یادگیری عمیق چندوجهی (Wu

et al., 2025) قابلیت اعتماد پیش‌بینی را افزایش داده است. در مطالعه اخیر، نوسان استحکام تسلیم فولاد رده ۷۰۰ مگاپاسکال ۶۷٪ کاهش یافت. البته نبود معیارهای آزمون استاندارد و تفاوت زیاد مجموعه ویژگی‌ها، که در مطالعات مختلف از ۲۰ تا بیش از ۵۰ ورودی متغیر است، مقایسه مستقیم مدل‌ها را دشوار می‌کند.



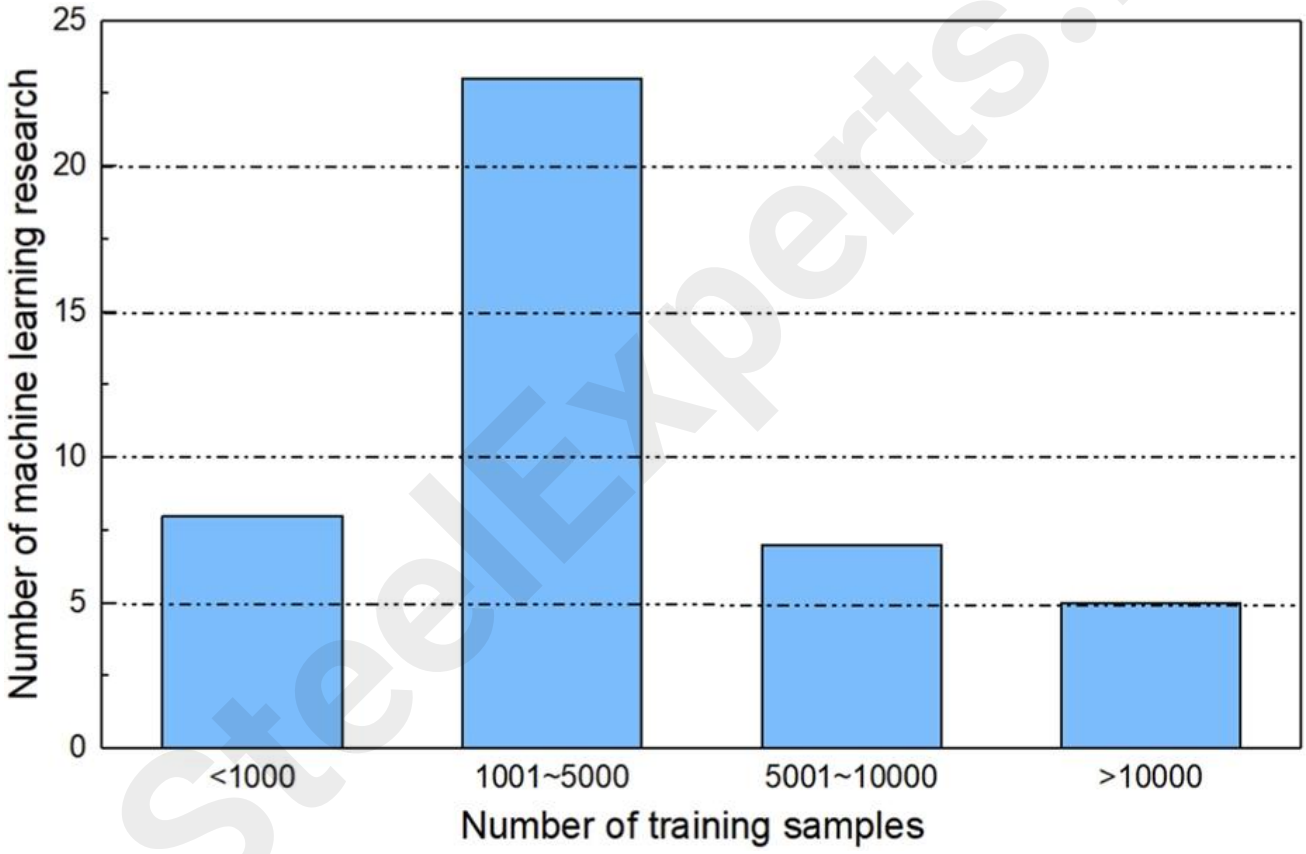
شکل ۳. توزیع آماری مطالعات یادگیری ماشین در نورد گرم: (الف) سهم کشورها؛ (ب) تعداد مطالعات به تفکیک سال؛ (ج) توزیع زمینه‌های کاربردی. منبع: Zong (2026)، CC BY 4.0.

شکل ۳، توزیع آماری کاربردهای یادگیری ماشین در نورد گرم را در سه نمودار نشان می‌دهد. نمودار ۳-الف سهم کشورها را مقایسه می‌کند. چین با 77.59% بیشترین سهم را دارد؛ هند و کره جنوبی هرکدام با 5.17% در رتبه بعد قرار می‌گیرند و سهم دیگر کشورها بسیار کمتر و پراکنده‌تر است. برای نمونه، سهم لهستان حدود 2.17% گزارش شده است. این فاصله، گستردگی فعالیت پژوهشی چین در این حوزه را نشان می‌دهد.

نمودار ۳-ب تغییر تعداد تحقیقات مربوط به هوش مصنوعی در نورد گرم را از سال ۲۰۲۰ تا ۲۰۲۵ دنبال می‌کند. روند کلی افزایشی است و از رشد پیوسته توجه پژوهشگران و صنعت به به‌کارگیری این فناوری حکایت دارد. نمودار ۳-ج تمرکز موضوعی پژوهش‌ها را نشان می‌دهد: پیش‌بینی خواص مکانیکی با ۱۷ مطالعه، پیش‌بینی

تاج ورق با ۱۰ مطالعه و تشخیص عیوب سطحی با ۸ مطالعه بیشترین سهم را دارند. این تمرکز با اهمیت کیفیت محصول نهایی برای صنعت سازگار است.

در عین حال، کم‌بودن تعداد مطالعات مربوط به تنظیم برخط پارامترها و پایش هوشمند وضعیت فرایند یک خلأ مهم را آشکار می‌کند. محیط نورد گرم ذاتاً گذرا و ناپایا است: دما، تغییرشکل و شرایط خنک‌کاری پیوسته تغییر می‌کنند. ازاین‌رو، چنین کاربردهایی فقط به دقت پیش‌بینی بالا نیاز ندارند؛ مدل باید در شرایط متفاوت تجهیزات و رژیم‌های بهره‌برداری نیز تعمیم‌پذیر و پایدار بماند. کم‌توجهی به این مسائل، آمادگی واقعی حوزه را برای استقرار برخط زیر سؤال می‌برد و ضرورت پیوند عمیق‌تر مدل‌سازی داده‌محور و کنترل تطبیقی را نشان می‌دهد.



شکل ۴. توزیع اندازه مجموعه‌داده‌ها در مطالعات کاربرد یادگیری ماشین برای نورد گرم. منبع: Zong (2026)، CC BY 4.0.

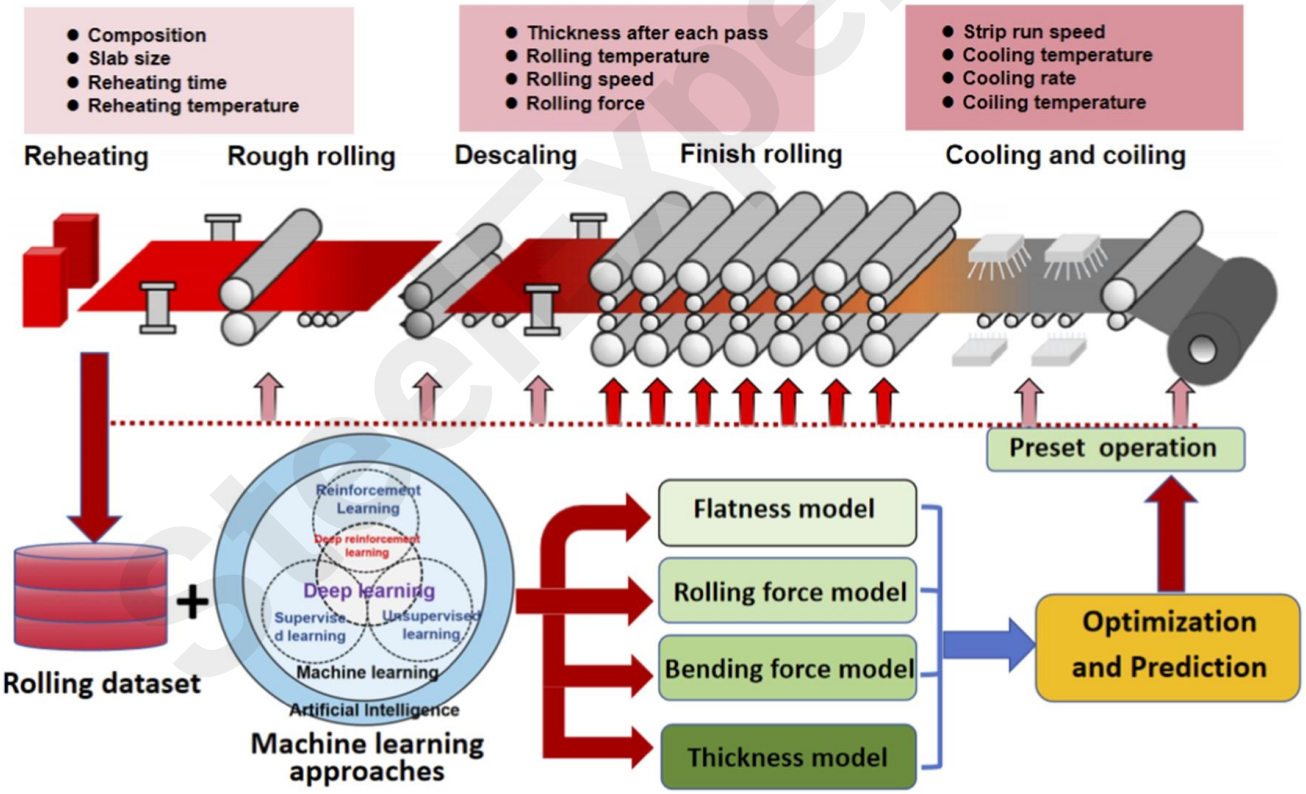
شکل ۴ نشان می‌دهد بیشتر پژوهش‌های یادگیری ماشین در نورد گرم از مجموعه‌داده‌هایی با اندازه متوسط، یعنی ۱۰۰۱ تا ۵۰۰۰ نمونه، استفاده کرده‌اند؛ مطالعاتی که بیش از ۱۰هزار نمونه دارند بسیار کمترند. این توزیع را نمی‌توان صرفاً با ملاحظات محاسباتی توضیح داد. در نورد گرم، گردآوری حجم زیادی از داده‌های برچسب‌خورده که واقعیت ریزساختاری یا خواص مکانیکی محصول را بازتاب دهند، پرهزینه و مستعد خطاست.

مهم‌تر آنکه بزرگی مجموعه‌داده لزوماً به معنای تعمیم‌پذیری بیشتر نیست. ناپایایی شرایط نورد، تفاوت کیفیت تختال‌ها، سایش غلتک و تغییر بازده خنک‌کاری، توزیع داده‌ها را به‌مرور جابه‌جا می‌کند و انتقال‌پذیری مدل از

یک وضعیت تولید به وضعیت دیگر را کاهش می‌دهد. بنابراین، تأکید بر مجموعه‌داده‌های متوسط شاید نشان دهد نمایندگی مناسب شرایط عملیاتی و سازگاری با فیزیک فرایند دست‌کم به اندازه تعداد نمونه اهمیت دارد. پژوهش‌های آینده باید به‌جای تمرکز صرف بر افزایش حجم داده، به طراحی آزمایش‌های متنوع از نظر شرایط عملیاتی و مبتنی بر دانش فیزیکی توجه بیشتری کنند.

۳. روش‌های یادگیری ماشین: فرصت‌ها و محدودیت‌ها

یادگیری ماشین به‌تدریج به یکی از ابزارهای اصلی نورد گرم تبدیل می‌شود. مهم‌ترین کاربردهای آن افزایش بهره‌وری فرایند و کیفیت محصول است، به‌ویژه در پیش‌بینی تختی ورق، کنترل نیروی نورد و مدل‌سازی مقاومت در برابر تغییرشکل. شکل ۵ فرصت‌ها و محدودیت‌های این رویکردها را در مراحل مختلف نورد گرم جمع‌بندی می‌کند.



شکل ۵. فرصت‌ها و محدودیت‌های کاربرد روش‌های یادگیری ماشین در نورد گرم. منبع: Zong (2026)، CC BY 4.0.

مدل‌های پیش‌بینی مبتنی بر هوش مصنوعی می‌توانند تنظیم نیروی نورد را دقیق‌تر کنند، پارامترهای فرایندی را پویا تغییر دهند و رفتار ماده را به‌صورت برخط بهینه سازند. برای مثال، مدل‌هایی که سوابق نورد، قرائت لحظه‌ای حسگرها و مشخصات ماده را هم‌زمان دریافت می‌کنند، مقاومت تغییرشکل را دقیق‌تر برآورد می‌کنند؛ نتیجه این کار، یکنواختی بیشتر محصول و کاهش عیوب خواهد بود. انتظار می‌رود هوش مصنوعی در آینده به

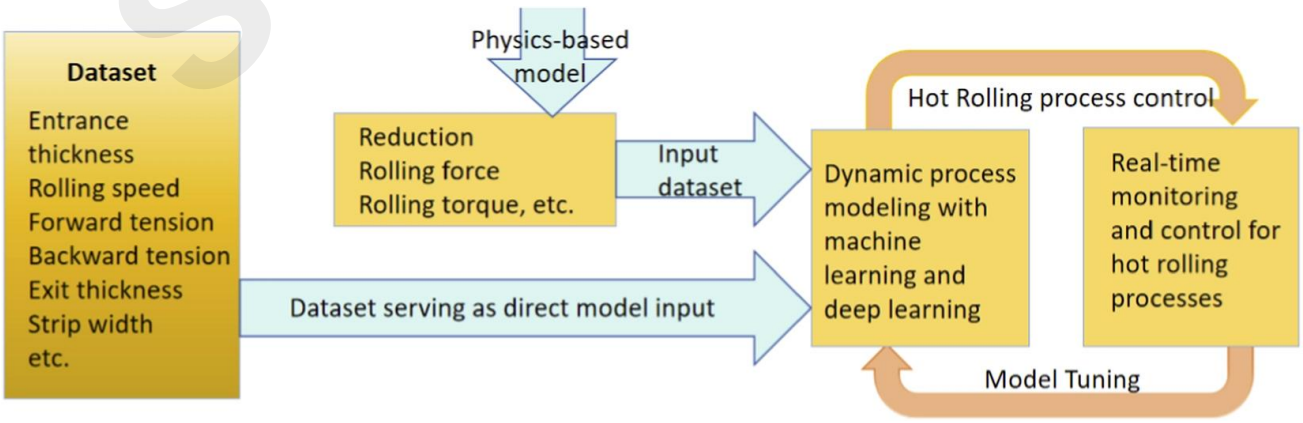
ابزاری اثرگذارتر برای دستیابی به دقت و بهره‌وری بالاتر تبدیل شود، هرچند محدودیت‌های عملی مهمی همچنان وجود دارند.

کیفیت و دسترس‌پذیری داده نخستین گلوگاه است. خطوط نورد، داده فراوانی از حسگرها و وقایع تولید جمع‌آوری می‌کنند، اما این داده‌ها اغلب با نویز اندازه‌گیری، مقادیر گمشده ناشی از رانش حسگر یا توقف تعمیراتی و نبود برچسب‌گذاری یکسان در گریدهای فولادی و برنامه‌های نورد همراه‌اند. چنین ضعف‌هایی آموزش مدلی را که در شرایط مختلف قابل استفاده باشد، به‌شدت دشوار می‌کنند.

پیچیدگی فرایند مانع دوم است. در نورد گرم، پدیده‌های حرارتی و مکانیکی به‌شدت درهم‌تنیده‌اند؛ دما، نرخ کرنش و اصطکاک رابطه‌ای غیرخطی دارند و تفکیک یا مدل‌سازی مستقل آن‌ها ساده نیست. تحول سریع ریزساختار ماده در نورد چندپاسه نیز رفتاری وابسته به زمان ایجاد می‌کند که با گرید فولاد تغییر می‌یابد. در نتیجه، ساخت مدلی که با تغییر شرایط تولید همچنان قابل‌اعتماد بماند، دشوارتر می‌شود.

این موانع ویژه نورد گرم، استقرار مدل‌های یادگیری ماشین را در محیط واقعی کارخانه محدود می‌کنند. برای غلبه بر آن‌ها دو جهت‌گیری اصلی مطرح است: نخست، توسعه مدل‌های پیش‌بینی پیشرفته بر پایه دستاوردهای موفقی مانند مدل‌های مقاومت تغییرشکل و ادغام داده‌های چندمنبعی برای بهبود تنظیم نیروی نورد و درنظرگرفتن رفتار پویای ماده و اثر محیط؛ دوم، ایجاد بسترهای داده‌ای مشترک میان فرایندها تا اطلاعات نورد گرم و مراحل پایین‌دستی در چارچوبی یکپارچه تجمیع شوند. چنین بستری تبادل و تحلیل برخط داده را ممکن می‌کند و به ارتقای پیش‌بینی تختی و حل مسائل ناشی از شرایط گذرا کمک می‌رساند.

شکل ۶ چارچوب کاربردی یک مدل ترکیبی یادگیری ماشین را در نورد گرم ترسیم می‌کند. ایده اصلی، کنار هم قرار دادن سازوکارهای فیزیکی و روش‌های داده‌محور برای پیش‌بینی دقیق و کنترل هوشمند کل فرایند است. این چارچوب سه لایه دارد: لایه داده ورودی، لایه مدل ترکیبی و لایه خروجی و بازخورد.



شکل ۶. مدل‌های ترکیبی برای کاربرد یادگیری ماشین در نورد گرم. منبع: Zong (2026)، CC BY 4.0.

لایه ورودی، پارامترهای مهمی مانند ضخامت ورودی و سرعت نورد و نیز خروجی مدل‌های متالورژی فیزیکی، از جمله نیروی نورد و مقاومت تغییرشکل، را دربر می‌گیرد. در لایه میانی، مدل‌های سازوکار فیزیکی با یادگیری ماشین و یادگیری عمیق ترکیب می‌شوند. این ترکیب با اصلاح پویای پارامترها و ادغام داده‌ها در مقیاس‌های مختلف، از یک سو محدودیت فرض‌های ساده‌ساز مدل‌های فیزیکی سنتی و از سوی دیگر ضعف توضیح‌پذیری مدل‌های صرفاً داده‌محور را کاهش می‌دهد.

لایه خروجی و بازخورد مستقیماً به کنترل نورد گرم متصل می‌شود و پایش لحظه‌ای و تنظیم حلقه‌بسته، مانند کنترل تختی و بهینه‌سازی نیروی نورد، را پشتیبانی می‌کند. همچنین، نتایج عملیاتی دوباره وارد چرخه بهینه‌سازی مدل می‌شوند تا دقت پیش‌بینی در تکرارهای بعدی افزایش یابد.

برای عبور از محدودیت روش‌های سنتی در شرایط ناپایای نورد، توسعه کنترل تطبیقی پویا ضروری است. به‌عنوان نمونه، الگوریتم‌های کنترل سازگارشونده مبتنی بر هوش مصنوعی می‌توانند در دوره‌های گذرا مانند شتاب‌گیری و کاهش سرعت خط، پارامترهایی نظیر فاصله غلتک، کشش و سرعت را لحظه‌به‌لحظه تنظیم کنند و تختی نوار، یکنواختی ضخامت و مهار ارتعاشات خودتحریک (Chatter) را بهینه سازند.

با وجود دقت امیدبخش بسیاری از مدل‌ها در شرایط پژوهشی، انتقال آن‌ها از توسعه آفلاین به بهره‌برداری برخط با موانع جدی روبه‌رو است. نخست، هزینه محاسباتی است: آموزش معماری‌های عمیق به GPUهای قدرتمند نیاز دارد، در حالی که استنتاج آنی روی تجهیزات لبه شبکه باید با مدل‌های سبک انجام شود؛ بنابراین، فشرده‌سازی مدل یا تقطیر دانش اهمیت می‌یابد. دوم، دسترسی به داده مناسب است؛ برچسب‌گذاری صنعتی پرهزینه، رانش حسگرها و کمیاب‌بودن رخدادهای غیرعادی، یادگیری کاملاً نظارت‌شده را دشوار می‌کند. سوم، حفظ اعتبار مدل در طول زمان است؛ مدل ایستا با تغییر تدریجی شرایط فرایند، مانند سایش غلتک و تغییر رژیم خنک‌کاری، سازگار نمی‌شود و دقت آن کاهش می‌یابد.

کاربرد هوش مصنوعی در نورد گرم باید پایداری محیطی را نیز هدف بگیرد: کاهش مصرف انرژی، کاهش ضایعات ناشی از خطای ضخامت و تاج، و مصرف بهینه منابع. برای نمونه، مدل‌های پیش‌بینی می‌توانند برنامه خنک‌کاری را طوری تنظیم کنند که مصرف آب کاهش یابد و در عین حال الزامات متالورژیکی محصول برآورده شود.
بهینه‌سازی دما و زمان‌بندی کوره، امکان صرفه‌جویی سوخت را به همراه دارد؛ کنترل دقیق‌تر احتراق و پرهیز از عملیات ثانویه انرژی‌بر به کاهش انتشار کمک می‌کند؛ و پیش‌بینی دقیق‌تر ضخامت و تاج، ضایعات ماده را کم می‌کند. خنک‌کاری تطبیقی نیز مصرف آب را با نیازمندی‌های تحول فازی متعادل می‌سازد. به این ترتیب، «پایداری» از مفهومی کلی به نتیجه‌ای مهندسی و اندازه‌پذیر تبدیل می‌شود.

اتصال حلقه‌های بازخورد برخط به سازوکارهای یادگیری تطبیقی، به‌تدریج عملکرد مدل‌ها را در شرایط متنوع و پویای نورد بهبود می‌دهد. چنین راهبردی می‌تواند بهره‌وری فرایند، دقت ابعادی و یکنواختی کیفیت را افزایش

دهد (Toscano et al., 2025; Meng et al., 2025) و پاسخ به تغییرات شرایط ناپایای تولید را امکان‌پذیرتر کند. البته جلب اعتماد اپراتورها و مهندسان تنها با دقت عددی حاصل نمی‌شود؛ مدل باید قابل‌اعتماد و توضیح‌پذیر باشد و روشن کند پارامترهایی مانند نیروی نورد و دما چگونه بر نتیجه پیش‌بینی اثر گذاشته‌اند تا ارزیابی و عیب‌یابی صنعتی آسان‌تر شود.

۴. نتیجه‌گیری

استفاده از یادگیری ماشین در نورد گرم فرصت مهمی برای ارتقای کیفیت محصول و گسترش نوآوری در صنعت نورد فولاد ایجاد کرده است. با این حال، میان توانمندی اثبات‌شده مدل‌ها در پژوهش و پذیرش آن‌ها در کارخانه همچنان فاصله وجود دارد.

تنوع مدل‌ها در برابر محدودیت‌های عملی: از الگوریتم‌های ساده‌تر تا شبکه‌های عمیق و مدل‌های ترکیبی، روش‌های یادگیری ماشین در کنترل ابعادی، پیش‌بینی خواص و بازرسی سطح عملکرد مطلوبی نشان داده‌اند؛ اما کمیابی داده‌های برچسب‌خورده باکیفیت و پیچیدگی ذاتی فیزیک نورد گرم، شامل غیرخطی‌بودن، اندرکنش چندفیزیکی و گذراهای فرایندی، اعتمادپذیری مدل‌های صرفاً داده‌محور را در شرایط ناشناخته محدود می‌کند.

دو گذار بنیادین: صنعت نورد گرم هم‌زمان در حال عبور از هوشمندسازی تجهیزات منفرد به هوشمندی یکپارچه سراسر زنجیره تولید و از برازش‌های جعبه‌سیاه به هوش مصنوعی ترکیبیِ متکی بر اصول متالورژی است. این دو تحول، زمینه شکل‌گیری صنعتی منظم‌تر، پایدارتر و برخوردار از استقلال هوشمندانه بیشتر را فراهم می‌کنند.

اطلاعات پژوهش و حقوق انتشار

نویسنده: Nanfu Zong (نانفو زونگ). **وابستگی سازمانی:** مرکز فناوری گروه Ben Gang، پژوهشگاه هوش دیجیتال، بنشی، چین.

مشارکت نویسنده: طراحی مفهوم پژوهش، روش‌شناسی، نگارش پیش‌نویس اولیه، بازبینی و ویرایش علمی.

حمایت مالی: طرح عمومی بنیاد علوم طبیعی استان لیائونینگ با شماره MS-391-2026.

تعارض منافع: نویسنده در زمان اجرای پژوهش کارمند مرکز فناوری گروه Ben Gang و پژوهشگاه هوش دیجیتال بوده است. در متن اصلی، روابط مالی یا تجاری دیگری که تعارض منافع تلقی شود گزارش نشده است.

اظهارنامه استفاده از هوش مصنوعی در مقاله اصلی: نویسنده اعلام کرده در تهیه دست‌نوشته اصلی از هوش

مصنوعی مولد استفاده نشده است. ناشر توضیح داده متن جایگزین تصاویر با پشتیبانی هوش مصنوعی تولید شده و برای صحت آن اقدامات کنترلی انجام شده است. این اظهارنامه مربوط به **متن اصلی انگلیسی** است، نه این ترجمه فارسی.

یادداشت ناشر: ادعاهای مقاله متعلق به نویسنده است و لزوماً نظر ناشر، سردبیران یا داوران را منعکس نمی‌کند؛ ناشر محصولات یا ادعاهای تولیدکنندگان مورد اشاره را تضمین یا تأیید نمی‌کند.

اطلاعات کتاب‌شناختی: Zong N. (2026). *Hot rolling in the age of artificial intelligence: towards enhanced efficiency, quality and sustainability in steel industry*. *Frontiers in Materials*, 13:1910968. DOI: 10.3389/fmats.2026.1910968. دریافت: ۱۶ ژوئن ۲۰۲۶؛ اصلاح: ۲۸ ژوئن؛ پذیرش: ۲۹ ژوئن؛ انتشار: ۲۲ ژوئیه ۲۰۲۶.

اعتبار و مجوز: ترجمه فارسی از متن منتشرشده در Frontiers in Materials تهیه شده است. تمامی شش شکل از مقاله اصلی Zong (2026) گرفته شده‌اند. اثر و تصاویر مشمول Creative Commons Attribution (CC BY 4.0) هستند. تغییر انجام‌شده: ترجمه متن و زیرنویس تصاویر به فارسی و تنظیم ساختار HTML برای وب؛ خود تصاویر اصلی بازطراحی نشده‌اند. مشاهده مقاله اصلی.

منابع علمی

1. Barrios J. A., Méndez G. M., Cavazos A. (2020). *Hybrid-learning Type-2 Takagi-Sugeno-Kang fuzzy systems for temperature estimation in hot-rolling*. Metals, 10(6), 742. DOI: 10.3390/met10060742.
2. Cao Y., Zhang C. D., Wu S. W., Cao G. M., Liu Z. Y. (2025). *Flexible cooling strategy for hot-rolled steel based on physical theories coupled with machine learning*. JOM, 77, 91–105. DOI: 10.1007/s11837-024-07065-9.
3. Cui C., Wang H., Gao X., Cao G. M., Liu Z. Y. (2021). *Machine learning model for thickness evolution of oxide scale during hot strip rolling of steels*. Metallurgical and Materials Transactions A, 52, 3227–3239. DOI: 10.1007/s11661-021-06285-7.
4. Cui C. Y., Cao G. M., Li X., Gao Z. W., Zhou X. G., Liu Z. Y. (2022a). *The coupling machine learning for microstructural evolution and rolling force during hot strip*

rolling of steels. Journal of Materials Processing Technology, 309, 117736. DOI: .10.1016/j.jmatprotec.2022.117736

5. Cui C. Y., Cao G. M., Cao Y., Liu J. J., Dong Z. S., Wu S. W. et al. (2022b). *Physical metallurgy guided deep learning for yield strength of hot-rolled steel based on the small labeled dataset*. Materials & Design, 223, 111269. DOI: .10.1016/j.matdes.2022.111269

6. Cui C. Y., Cao G. M., Li X., Gao Z. W., Zhou X. G., Liu Z. Y. (2023). *A strategy combining machine learning and physical metallurgical principles to predict mechanical properties for hot rolled Ti micro-alloyed steels*. Journal of Materials .Processing Technology, 311, 117810. DOI: 10.1016/j.jmatprotec.2022.117810

7. Cui H., Wang X. C., Song J. (2025). *Collaborative prediction for profiles and edge reducings of hot-rolled silicon steels based on CAHA-CatBoost*. Angang .Technology, 1, 23–28. DOI: 10.3969/j.issn.1006-4613.2025.01.005

8. Ding J. G., Guo J. H. (2021). *Prediction of rough rolling width based on principal component analysis collaborated with random forest algorithm*. Journal of Northeastern University, 42(09), 1268–1274. DOI: .10.12068/j.issn.1005-3026.2021.09.009

9. Ding C. Y., Sun J., Li X. J., Peng W., Zhang D. H. (2024). *Intelligent diagnosis for hot-rolled strip crown with unbalanced data using a hybrid multi-stage ensemble model*. Journal of Central South University, 31(3), 762–782. DOI: .10.1007/s11771-024-5607-6

10. Du Y., Wang Y. M., Zhang T., Tian Y., Wang B. X. (2022). *Prediction of final cooling temperature for hot rolled medium and heavy plate based on Bayesian optimization XGBoost model*. Steel Rolling, 39(06), 91–98. DOI: .10.13228/j.boyuan.issn1003-9996.20220356

11. Durmaz A. R., Lamb J. D., Echlin M. P., Pollock T. M. (2026). *Foundation models for multimodal image data fusion in materials science*. Frontiers in Materials, 13, .1815017. DOI: 10.3389/fmats.2026.1815017

12. Hu D. Y., Gao Z. W., Wang X. D., Lu F. H., Liu J. J., Cui C. Y. (2021). *Development and application of on-line prediction model for mechanical properties of hot rolled strips*. Steel Rolling, 38(03), 9–14. DOI: 10.13228/j.boyuan.issn1003-9996.20210120.

13. Huang X. B., Song Z. W., Ji C., Zhang Y., Yang L. Y. (2023). *Research on a classification method for strip steel surface defects based on knowledge distillation and a self-adaptive residual shrinkage network*. Algorithms, 16(12), 560. DOI: 10.3390/a16120560.

14. Huang H. G., Hu Q. W., Xu B., Zheng J. L., Xu S. M., Ren X. Y. (2025). *Machine vision and deep learning for enhanced grading and classification of surface wear on hot-rolling work rolls*. Chinese Journal of Mechanical Engineering, 38, 177. DOI: 10.1186/s10033-025-01187-2.

15. Hwang R., Jo H., Kim K. S., Hwang H. J. (2020). *Hybrid model of mathematical and neural network formulations for rolling force and temperature prediction in hot rolling processes*. IEEE Access, 8, 173747–173758. DOI: 10.1109/ACCESS.2020.3016725.

16. Idzik C., Krämer A., Hirt G., Lohmar J. (2024). *Coupling of an analytical rolling model and reinforcement learning to design pass schedules: towards properties controlled hot rolling*. Journal of Intelligent Manufacturing, 35, 1469–1490. DOI: 10.1007/s10845-023-02118-z.

17. Ji Y. J., Liu S. X., Zhou M. C., Zhao Z. Y., Guo X. W., Qi L. (2022). *A machine learning and genetic algorithm-based method for predicting width deviation of hot-rolled strip in steel production systems*. Information Sciences, 589, 360–375. DOI: 10.1016/j.ins.2021.12.098.

18. Latham S., Giannetti C. (2023). *A tool to combine expert knowledge and machine learning for defect detection and root cause analysis in a hot strip mill*. SN Computer Science, 4(5), 525. DOI: 10.1007/s42979-023-01991-y.

19. Lee C., Shin D. S., Kang Y. H., Choi K., Park D. Y., Rho J. (2025). *Real-time hot-*

rolled coil placement recommendation system with data-driven model. Advanced .Intelligent Systems, 7(8), 2500097. DOI: 10.1002/aisy.202500097

.20 Li X., Luan F., Wu Y. (2020). *A comparative assessment of six machine learning models for prediction of bending force in hot strip rolling process*. Metals, 10, 685. .DOI: 10.3390/met10050685

.21 Li W. G., Xie L., Zhao Y. T., Li Z. X., Wang W. B. (2020). *Prediction model for mechanical properties of hot-rolled strips by deep learning*. Journal of Iron and Steel Research, 27(9), 1045–1053. DOI: .10.13228/j.boyuan.issn1001-0963.20200189

.22 Li F. F., He A. R., Song Y., Wang Z., Xu X. Q., Zhang S. W. et al. (2023). *Deep learning for predictive mechanical properties of hot-rolled strip in complex manufacturing system*. International Journal of Minerals, Metallurgy and Materials, .30(6), 1093–1103. DOI: 10.1007/s12613-022-2569-2

.23 Li X., Zhou X. G., Cao G. M., Cui C. Y., Wu S. W., Liu Z. Y. (2023). *Prediction of microstructure and properties and optimization of hot rolling process based on physical metallurgy and machine learning*. Metallurgical Industry Automation, .47(02), 16–26. DOI: 10.3969/j.issn.1000-7059.2023.02.003

.24 Li J. D., Wang X. C., Li F. X., Sun Y. M., Sun Y. Z., Yang Q. et al. (2025). *Interpretable machine learning modeling of alloy composition-process-property relationships based on industrial big data in hot strip rolling*. Journal of .Manufacturing Processes, 150, 299–316. DOI: 10.1016/j.jmapro.2025.03.065

.25 Liu M. H., Zhang Q., Liu Y. H., Wang W. L. (2021). *Prediction of rolling force in hot rolling based on machine learning*. Forging & Stamping Technology, 46(10), .233–241. DOI: 10.13330/j.issn.1000-3940.2021.10.032

.26 Liu Z. Y., Wu S. W., Cong J. G., Liang L., Zhou X. G., Cao G. M. (2024). *Development of the technology to predict microstructural evolution and changes of mechanical properties for hot rolled steels-the path from semi-empirical models through machine learning to industrial foundation models*. Steel Rolling, 41(05),

.24–37. DOI: 10.13228/j.boyuan.issn1003-9996.20240198

.27 Liu Y., Peng W., Li X. M., Wu W. T., Zhu B. Q., Li X. D. et al. (2025). *An interpretable industrial digital platform based on dempster-shafer theory for pre-diagnosis the quality of hot-rolled strip*. Journal of Manufacturing Systems, 83, 878–903. DOI: .10.1016/j.jmsy.2024.11.009

.28 Lu J., Wang P. F., Huang H. G., Hao L. H., Li X., Peng Q. M. et al. (2024). *Novel online prediction model for thermal convexity of work rolls during hot steel rolling based on machine learning algorithms*. Expert Systems with Applications, 254, .124384. DOI: 10.1016/j.eswa.2024.124384

.29 Ma L., Shi F. Z., Peng K. X. (2023). *Status and prospects in data-driven fault diagnosis for hot rolling process*. China Metallurgy, 33(12), 12–17. DOI: .10.13228/j.boyuan.issn1006-9356.20230726

.30 Ma Y., Li Y. L., Zhang L., Lei D. W., Xu H. T. (2024). *Research on hot-rolled coil surface defects detection technology based on improved YOLOv3 model*. Metallurgical Industry Automation, 48(03), 83–91. DOI: .10.3969/j.issn.1000-7059.2024.03.012

.31 Madhavan S., Sridharan N. V., Mahanta T. K., Vaithiyanathan S. (2025). *Diagnosis of surface defects in hot-rolled steel from deep learning features using machine learning algorithms*. Arabian Journal for Science and Engineering, 50(7), .4613–4624. DOI: 10.1007/s13369-024-09117-z

.32 Meng L. M., Ding J. G., Dong Z. S., Zhang C., Peng W., Zhang D. H. (2025). *A novel modelling method for rolling force prediction based on deep stochastic configuration networks fused with physical knowledge*. Information Sciences, 711, .122097. DOI: 10.1016/j.ins.2025.122097

.33 Muntin A. V. (2019). *Advanced technology of combined thin slab continuous casting and steel strip hot rolling*. Metallurgist, 62, 900–910. DOI: .10.1007/s11015-019-00747-5

.34 Park C. Y., Jin W. K., Kim B. S., Lee J. (2020). *Prediction for manufacturing factors*

in a steel plate rolling smart factory using data clustering-based machine learning. .IEEE Access, 8, 60890–60905. DOI: 10.1109/ACCESS.2020.2982926

35. Peng G. Z., Cheng Y. L., Zhang Y. F., Shao J., Wang H. W., Shen W. M. (2022). *Industrial big data-driven mechanical performance prediction for hot-rolling steel using lower upper bound estimation method*. Journal of Manufacturing Systems, .65, 104–114. DOI: 10.1016/j.jmsy.2022.09.007

36. Shi Z. X., Du L. X., He X., Gao X. H., Wu H. Y., Liu Y. et al. (2023). *Prediction model of yield strength of V-N steel hot-rolled plate based on machine learning algorithm*. .JOM, 75, 1726–1737. DOI: 10.1007/s11837-023-05809-3

37. Song L. B., Xu D., Wang X. C., Yang Q., Ji Y. F. (2022). *Application of machine learning to predict and diagnose for hot-rolled strip crown*. International Journal of Advanced Manufacturing Technology, 120, 881–890. DOI: .10.1007/s00170-022-08831-y

38. Song J., Wu W. T., Wang K. Y., Sun J., Peng W., Cao Z. H. (2023). *Integrated modeling of finishing delivery temperature during hot rolling process based on data-mechanism fusion method*. Metallurgical Industry Automation, 47(05), 55–62. .DOI: 10.3969/j.issn.1000-7059.2023.05.008

39. Song J., Gao L., Wang K. Y., Cao Z. H., Ma C. Y., Ma X. G. (2024). *Mechanical properties optimization method of hot strip based on SHAP framework*. Metallurgical Industry Automation, 48(04), 21–32. DOI: .10.3969/j.issn.1000-7059.2024.04.004

40. Subburaj K., Mazroa A., Alotaibi F. A., Alnfiai M. M. (2024). *DBCW-YOLO: an advanced YOLOv5 framework for precision detection of surface defects in steel*. .Matéria, 29(4), 121. DOI: 10.1590/1517-7076-RMAT-2024-0095

41. Sun Y. Z., Li J. D., Sun Y. M., Song L. B., Yang Q., Wang X. C. (2024). *Modeling and simulation of shape control based on digital twin technology in hot strip rolling*. .Sensors, 24(2), 641. DOI: 10.3390/s24020641

42. Svyetlichnyy D. (2025). *Reduced-order model based on neural network of roll*

.*bending*. Applied Sciences, 15, 8418. DOI: 10.3390/app15188418

43. Thakur S. K., Das A. K., Jha B. K. (2023). *Application of machine learning methods for the prediction of roll force and torque during plate rolling of micro-alloyed steel*. Journal of Alloys and Metallurgical Systems, 4, 100044. DOI: .10.1016/j.jalmes.2023.100044

44. Toscano J. D., Oommen V., Varghese A. J., Zou Z. G., Daryakenari N. A., Wu C. X. et al. (2025). *From PINNs to PIKANs: recent advances in physics-informed machine learning*. Machine Learning: Computational Science and Engineering, 1, .15. DOI: 10.1007/s44379-025-00015-1

45. Wang D. C., Xu Y. H., Duan B. W., Wang Y. M., Liu H. M. (2021). *Data-driven intelligent prediction model of edge seam defects for hot rolling strip*. Iron and .Steel, 55(11), 82–90. DOI: 10.13228/j.boyuan.issn0449-749x.20200356

46. Wang H. Y., Fang K., Dong L. J., Guo L. W., Sun L. J., Li L. J. (2024). *Study and application of data-driven rolling force prediction model for hot strip mills*. China .Metallurgy, 34(11), 93–99. DOI: 10.13228/j.boyuan.issn1006-9356.20240456

47. Wang K. Y., Gao L., Song J., Cao Z. H., He J. T. (2024). *Intelligent optimization of load distribution on hot rolled strip steel based on improved spotted hyena algorithm*. Angang Technology, 1, 26–32. DOI: .10.3969/j.issn.1006-4613.2024.01.005

48. Wang L. J., Ding C. Y., Fan Y. C., Sun J., Peng W., Zhang D. H. (2023). *Hot rolled strip crown prediction model based on deep forest*. Steel Rolling, 40(01), 90–96. .DOI: 10.13228/j.boyuan.issn1003-9996.20220789

49. Wang X. J., Li X., Yuan H., Zhou N., Wang H. S., Zhang W. J. et al. (2024). *Prediction and analysis of mechanical properties of hot-rolled strip steel based on an interpretable machine learning*. Materials Today Communications, 40, 109997. .DOI: 10.1016/j.mtcomm.2024.109997

50. Wang Z. H., Huang Y., Liu Y. M., Wang T. (2023). *Prediction model of strip crown in hot rolling process based on machine learning and industrial data*. Metals, 13(2),

.278. DOI: 10.3390/met13020278

.51 Wu S. W., Zhou X. G., Liu Z. Y., Wang G. D. (2025). *Microstructure and property prediction of hot-rolled steel: development and prospects from physical models to human-machine hybrid intelligence*. Journal of Northeastern University, 46(08), .11–19. DOI: 10.12068/j.issn.1005-3026.2025.08.002

.52 Xie X. Q., Suvarna M., Li J. L., Zhu X. Z., Cai J. J., Wang X. N. (2021). *Online prediction of mechanical properties of hot rolled steel plate using machine learning*. .Materials & Design, 197, 109201. DOI: 10.1016/j.matdes.2020.109201

.53 Yu J. X., Sun J., Zhang D. H. (2021). *Accurate prediction of head thickness of hot-rolled strip based on deep learning*. Iron and Steel, 56(09), 19–25. DOI: .10.13228/j.boyuan.issn0449-749x.20210287

.54 Zhang D. H., Li H., Wu W. T., Huo G. F., Sun J., Peng W. (2024). *Diagnosis model of hot-rolled strip crown based on stacking ensemble learning*. Journal of Central South University, 55(10), 3673–3682. DOI: .10.11817/j.issn.1672-7207.2024.10.014

.55 Zhang S. H., Ge M. K., Wan L. W., Chen W. J., Luo X. L. (2025). *Modeling and optimization of thick plate rolling force based on mechanism and data*. Metallurgical Industry Automation, 49(05), 155–163. DOI: .10.3969/j.issn.1000-7059.2025.05.020

.56 Zhang H. K., Li S. Q., Miao Q. Q., Fang R. D., Xue S., Hu Q. C. et al. (2024). *Surface defect detection of hot rolled steel based on multi-scale feature fusion and attention mechanism residual block*. Scientific Reports, 14, 7671. DOI: .10.1038/s41598-024-58288-0

.57 Zhang R. X., Qi Y. S., Kong S. S., Wang X. D., Li M. D. (2024). *A hybrid artificial intelligence algorithm for fault diagnosis of hot rolled strip crown imbalance*. Engineering Applications of Artificial Intelligence, 130, 107763. DOI: .10.1016/j.engappai.2023.107763

.58 Zhang S. F., Wang X. C., Zhao J., He J. T., Song J., Ma X. G. (2024). *Profile-*

predicting for hot-rolled steel sheets based on neural network algorithms. Angang .Technology, 449(5), 18–25. DOI: 10.3969/j.issn.1006-4613.2024.05.004

.59 Zhao J. T., Zhou Z. J., Liu B., Zou H. (2025). *Performance Prediction of Ti-containing high-strength Steel in Hot Rolling Based on Machine Learning*. Baosteel .Technology, 50–56. DOI: 10.3969/j.issn.1008-0716.2025.01.008

.60 Zong N. F., Huang J., Liu J., Ma S., Jing T. (2021). *Analysis of internal cracks in high carbon casting bloom induced by soft reduction process and its improvement using numerical simulations and industrial experiments*. Metallurgical Research & .Technology, 118(8), 102–110. DOI: 10.1051/metal/2020079

.61 Zong N. F., Jing T., Liu Y. (2022). *Comparative studies on a chamfer technology and a convex roll technology during the soft reduction process*. Archives of .Metallurgy and Materials, 66(3), 819–829. DOI: 10.24425/amm.2021.136386

.62 Zong N. F., Jing T., Gebelin J. C. (2025a). *Machine learning for tandem cold rolling: exploring innovations, challenges, and industrial applications*. International Journal of Advanced Manufacturing Technology, 140, 5967–5985. DOI: .10.1007/s00170-025-16652-y

.63 Zong N. F., Jing T., Gebelin J. C. (2025b). *Machine learning techniques for the comprehensive analysis of the continuous casting processes: Slab defects*. .Ironmaking & Steelmaking. DOI: 10.1177/03019233251318492

.64 Zong N. F., Jing T., Gebelin J. C. (2026a). *Editorial: digital technology for materials science and processes modelling*. Frontiers in Materials, 13, 1846730. DOI: .10.3389/fmats.2026.1846730

.65 Zong N. F., Jing T., Gebelin J. C. (2026b). *Steelmaking in the age of artificial intelligence*. Journal of the Brazilian Society of Mechanical Sciences and .Engineering, 48, 467. DOI: 10.1007/s40430-026-06465-9

.66 Zong N. F., Jing T., Gebelin J. C. (2026c). *Artificial intelligence for smarter steelmaking processes: towards enhanced efficiency, quality and sustainability*. International Journal of Minerals, Metallurgy and Materials. DOI:

.10.1007/s12613-026-3445-2

نسخه آنلاین مقاله: https://landing.steelexperts.ir/2026/10/26/sx-r003-ai-hot-rolling/

SteelExperts.ir