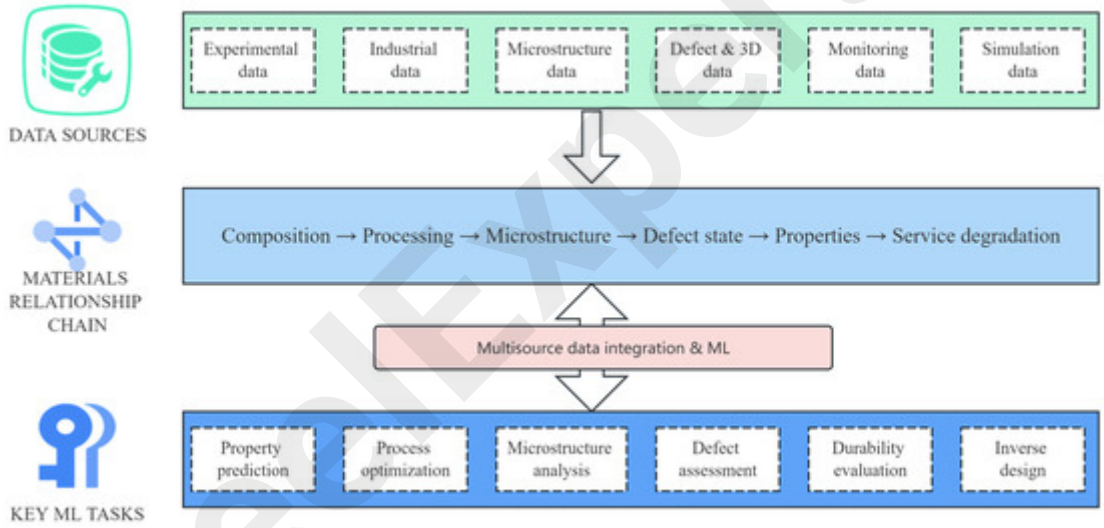
مرکز دانش شبکه خبرگان صنعت فولاد

یادگیری ماشین در فولادهای سازه‌ای: طراحی مواد، پیش‌بینی خواص، دوام و چشم‌انداز آینده

مقالات تخصصی | شبکه خبرگان صنعت فولاد | ۱۴۰۵/۰۸/۰۴

مرور انتقادی کاربرد یادگیری ماشین در طراحی ترکیب و ریزساختار فولادهای سازه‌ای، پیش‌بینی خواص مکانیکی، خوردگی، آتش‌سوزی، خستگی و عمر باقی‌مانده، با تمرکز بر اعتبارسنجی مستقل و اعتمادپذیری مهندسی.



چکیده

یادگیری ماشین (Machine Learning یا ML) امکان تازه‌ای برای مدل‌سازی روابط غیرخطی میان ترکیب شیمیایی، فرایند تولید، ریزساختار، عیوب، خواص و تخریب فولادهای سازه‌ای در دوره بهره‌برداری فراهم کرده است. این مقاله مروری انتقادی و ساختارمند بر کاربردهای یادگیری ماشین در طراحی مواد و فرایند، شناسایی و تحلیل ریزساختار، پیش‌بینی خواص مکانیکی، خوردگی، رفتار در آتش و دماهای بالا، خستگی، شکست و ارزیابی عمر باقی‌مانده ارائه می‌کند.

پژوهش‌های منتشرشده تا ۳۱ ژوئیه ۲۰۲۶ عمدتاً در دو پایگاه Web of Science Core Collection و Scopus

جست‌وجو شدند. در نهایت، ۱۱۰ مطالعه بر اساس ارتباط با فولادهای سازه‌ای، شفافیت داده‌ها و روش مدل‌سازی و وجود اطلاعات مربوط به اعتبارسنجی یا کاربردپذیری مهندسی انتخاب شدند. بررسی‌ها نشان می‌دهد تناسب مدل بیش از آنکه به خانواده الگوریتم وابسته باشد، به نوع داده، استقلال نمونه‌ها، شیوه تعریف ویژگی‌ها و راهبرد اعتبارسنجی بستگی دارد.

کاربرد یادگیری ماشین از پیش‌بینی ساده خواص فراتر رفته و به بهینه‌سازی فرایند، طراحی معکوس مواد، ارزیابی تخریب محیطی و پیش‌آگاهی خستگی و رشد ترک رسیده است. با این حال، آزمون مستقل مدل‌ها میان سازندگان و آزمایشگاه‌های مختلف و نیز اعتبارسنجی در مقیاس تولید یا شرایط واقعی خدمت همچنان محدود است؛ گزارش عدم‌قطعیت و تعیین محدوده اعتبار مدل نیز هنوز رویه‌ای یکدست ندارد. اهمیت این ضعف‌ها در کاربردهای حساس به ایمنی، از جمله خوردگی، آتش، خستگی و عمر باقی‌مانده، بیشتر است: مدلی که فقط در داده‌های داخلی عملکرد خوبی داشته، جایگزین مدل‌های فیزیکی و ضوابط معتبر طراحی سازه نمی‌شود. اولویت‌های آینده عبارت‌اند از داده‌های استاندارد و چندوجهی، مدل‌های آگاه از فیزیک و عدم‌قطعیت، اعتبارسنجی آینده‌نگر و ارزیابی دقیق سامانه‌های پایش حلقه‌بسته و دوقلوی دیجیتال در سراسر چرخه عمر فولاد سازه‌ای.

واژگان کلیدی: فولاد سازه‌ای؛ یادگیری ماشین؛ یادگیری ماشین آگاه از فیزیک؛ طراحی معکوس مواد؛ پیش‌بینی عمر خدمت.

۱. مقدمه

فولاد سازه‌ای به دلیل ظرفیت بالای تحمل بار، شکل‌پذیری و چقرمگی مناسب، روش‌های جاافتاده ساخت و جوشکاری و قابلیت بازیافت چشمگیر، از اصلی‌ترین مصالح باربر ساختمان‌ها، پل‌ها، تأسیسات صنعتی، سازه‌های دهانه‌بلند، سکوهای فراساحلی و زیرساخت‌های حمل‌ونقل است. با افزایش ارتفاع و دهانه سازه‌ها، گسترش پیش‌ساختگی و انتظار عمر بهره‌برداری طولانی‌تر، انتخاب فولاد دیگر صرفاً به مقاومت محدود نمی‌شود. مقاومت، شکل‌پذیری، چقرمگی، جوش‌پذیری، مقاومت در برابر خوردگی و آتش، دوام خستگی و هزینه باید هم‌زمان کنترل شوند؛ هدف‌هایی که گاه با یکدیگر تعارض دارند و طراحی را به مسئله‌ای چندمتغیره و چندهدفه تبدیل می‌کنند.

منظور این مقاله از فولادهای سازه‌ای، عمدتاً فولادهای کربنی ساختمانی، فولادهای کم‌آلیاژ پراستحکام (HSLA)، فولادهای هوازدگی‌مقاوم، فولادهای مقاوم در برابر آتش، فولادهای پل و خطوط لوله، فولادهای زنگ‌نزن سازه‌ای و محصولات جوش‌شده آن‌ها در زیرساخت‌های عمرانی است. برای فهم عملکرد این مواد،

شناخت یک «گرید فولاد» به‌تنهایی کافی نیست؛ باید سرگذشت تولید و شرایط بهره‌برداری آن نیز معلوم باشد.

خواص مهندسی فولاد از برهم‌کنش ترکیب شیمیایی، تاریخچه ساخت، ریزساختار، عیوب و شرایط سرویس پدید می‌آید. افزودن عناصر آلیاژی، پاکیزگی فولاد، ریخته‌گری پیوسته، برنامه نورد و خنک‌کاری، عملیات حرارتی و چرخه حرارتی جوشکاری، بر نوع و نسبت فازها، ساختار دانه، رسوبات، نابجایی‌ها، بافت بلوری، آخال‌ها و عیوب موضعی اثر می‌گذارند. مجموعه این تغییرات، مقاومت و شکل‌پذیری و چقرمگی و نیز رفتار خستگی و تخریب محیطی را تعیین می‌کند [۱–۳].

متالورژی فیزیکی، تجربه آلیاژسازی، محاسبات ترمودینامیکی و سینتیکی و شبیه‌سازی عددی همچنان برای توضیح سازوکارهای رفتار مواد ضروری‌اند، اما بررسی هم‌زمان فضای بزرگ ترکیب‌ها، مسیرهای متعدد تولید، چند هدف عملکردی و شرایط محیطی وابسته به یکدیگر با این روش‌ها پرهزینه و گاه محدودکننده است [۴–۸]. یادگیری ماشین می‌تواند با استفاده از داده‌های آزمایشگاهی، محاسباتی، صنعتی، تصویری و پایش میدانی روابط غیرخطی را بیاموزد و در صورت طراحی مناسب، دانش فیزیکی را نیز در مدل دخیل کند.

کاربردهای این فناوری اکنون پیش‌بینی تبدیل فاز، بهینه‌سازی عملیات تولید، طبقه‌بندی و قطعه‌بندی ریزساختار، شناسایی عیب، پیش‌بینی خواص مکانیکی، طراحی چندهدفه آلیاژ، طراحی معکوس ریزساختار، مدل‌سازی خوردگی، تحلیل عملکرد در دمای بالا، پیش‌بینی خستگی و شکست و برآورد عمر باقی‌مانده را در بر می‌گیرند [۳، ۹–۱۷]. داده‌ها نیز از جدول‌های ترکیب و فرایند تا ریزنگاره‌ها، نقشه‌های سه‌بعدی عیوب، سیگنال‌های حسگر و شبیه‌سازی‌های فیزیکی تنوع دارند. بنابراین مقایسه مدل‌ها فقط با نام الگوریتم یا یک شاخص دقت، از نظر مهندسی گمراه‌کننده است؛ نمایش درست داده ورودی، استقلال داده آزمون، سازگاری با فیزیک و قابلیت انتقال مدل به محیطی خارج از مجموعه آموزش اهمیت یکسان دارند.

مرورهای پیشین اغلب به بخشی از این مسئله پرداخته‌اند. برخی بر داده‌های آلیاژها، پیش‌بینی خواص و طراحی معکوس تمرکز داشته‌اند [۴–۶]؛ برخی دیگر بر تصویرشناسی ریزساختار، آخال‌های غیرفلزی، رفتار ساختاری ماده یا خستگی [۲، ۱۳–۱۶]. مرورهای مرتبط با هوش مصنوعی در سازه‌های فولادی بیشتر به تیر، ستون، اتصال، ظرفیت باربری، پاسخ لرزه‌ای و پایش سلامت سازه پرداخته‌اند، نه سرچشمه متالورژیکی خواص ماده [۱۸]. مطالعات نزدیک‌تر به تولید فولاد نیز معمولاً پیوند طراحی ماده با تخریب محیطی و ارزیابی عمر خدمت را به‌صورت یکپارچه بررسی نکرده‌اند [۱۹–۲۲].

جدول ۱. مقایسه این مرور با مرورهای منتخب پیشین در یادگیری ماشین مواد و مهندسی سازه

نوع مقاله مروری	دامنه ماده یا سازه	نوع اصلی داده	طراحی ماده و پیش‌بینی خواص	تخریب در دوره خدمت و ارزیابی عمر	اعتمادپذیری و اعتبارسنجی مهندسی
مرورهای یادگیری ماشین درباره آلیاژها و مواد فلزی [4–6]	انواع گسترده آلیاژها و سامانه‌های فلزی	ترکیب شیمیایی، محاسبات و داده‌های جدولی	گسترده	محدود	تا حدی بررسی شده
مرورهای ریزساختار و آخال‌ها [2,13]	فولادها و مواد فلزی	داده‌های میکروسکوپی و تصویری	تخصصی	محدود	محدود
مرورهای رفتار مکانیکی و خستگی [14–16]	مواد فلزی و فولادها	داده‌های مکانیکی و خستگی	متمرکز بر خاصیت مشخص	عمدتاً محدود به خستگی	تا حدی بررسی شده
مرورهای یادگیری ماشین در مصالح ساختمانی [17]	بتن و مصالح ساختمانی عملکردی	داده‌های متنوع	گسترده	تا حدی	محدود
مرورهای هوش مصنوعی در سازه‌های فولادی [18]	اعضا و سامانه‌های سازه‌ای	داده‌های سازه‌ای، عددی و پایش	محدود در مقیاس ماده	متمرکز بر عملکرد سازه	تا حدی بررسی شده
مرورهای ساخت و عملکرد فولاد [19–22]	تولید فولاد و مواد فولادی	داده‌های صنعتی و فرایندی	گسترده	محدود	تا حدی بررسی شده
مرور حاضر	فولادهای سازه‌ای زیرساخت‌های عمرانی؛ همراه با تفکیک شواهد مجاور و موارد انتقال روش	داده‌های جدولی، تصویری، سه‌بعدی، شبیه‌سازی، حسگری و دوره خدمت	پیوند یکپارچه طراحی ترکیب و فرایند با ریزساختار و پیش‌بینی خواص	خوردگی، آتش، خستگی، شکست و عمر باقی‌مانده	استقلال داده‌ها، سازگاری فیزیکی، تفسیرپذیری، عدم‌قطعیت، محدوده اعتبار و اعتبارسنجی بیرونی

نوآوری این مرور، فهرست‌کردن الگوریتم‌ها نیست؛ بلکه برقراری پیوندی روشن میان «طراحی ماده، تولید، خواص، تخریب در خدمت و قوت شواهد مهندسی» است. برای پرهیز از تعمیم نابجای نتایج، نویسندگان شواهد را در سه گروه تفکیک می‌کنند: **شواهد مستقیم** مربوط به فولادهای سازه‌ای و جوش‌های کاربردی در زیرساخت؛ **شواهد مجاور** از فولادهای مهندسی نزدیک از نظر سازوکار متالورژیکی؛ و **موارد انتقال روش** از موادی مانند فولادهای فریتی–مارتنزیتی کم‌فعال‌شونده، فولادهای TWIP، فولادهای هسته‌ای و آرماتورها که روش مطالعه‌شان می‌تواند قابل استفاده باشد، نه لزوماً نتایج عددی‌شان.

مقیاس پیش‌بینی نیز تفکیک می‌شود. محور اصلی مقاله، خود ماده است؛ پژوهش‌های سطح نمونه و اتصال، عضو یا کل سازه فقط زمانی وارد تحلیل می‌شوند که مشخص کنند متغیرهای حالت ماده یا روند تخریب آن چگونه به عملکرد مهندسی و عمر سازه منتقل می‌شود. این مرزبندی به‌ویژه برای آتش‌سوزی، خستگی و دوام اهمیت دارد، زیرا آسیب از ماده تا عضو و سامانه سازه‌ای گسترش می‌یابد.

سه پرسش اصلی پژوهش عبارت‌اند از: نخست، چه وظایفی در طراحی، ساخت، مشخصه‌یابی و بهره‌برداری فولادهای سازه‌ای با یادگیری ماشین بررسی شده‌اند؟ دوم، چه داده‌ها و شیوه‌های تعریف ویژگی و اعتبارسنجی به کار رفته و تا چه اندازه تعمیم‌پذیری را پشتیبانی می‌کنند؟ سوم، کدام رویکردها اعتبارسنجی مهندسی معناداری ارائه کرده‌اند و چه موانعی استقرار صنعتی را دشوار می‌کند؟ فصل‌های بعد به روش مرور، داده‌ها و ارزیابی معتبر، طراحی و خواص ماده، دوام و عمر خدمت و در نهایت چالش‌ها و مسیر آینده می‌پردازند.

۲. روش‌شناسی مرور پژوهش‌ها

جست‌وجوی ساختارمند برای یافتن پژوهش‌های یادگیری ماشین مرتبط با طراحی، ساخت، شناسایی، پیش‌بینی خواص، دوام و عمر خدمت فولادهای سازه‌ای انجام شد. دو پایگاه Web of Science Core Collection و Scopus منابع اصلی بودند؛ جست‌وجوی هدفمند و بررسی ارجاعات رو به عقب و جلو در مقاله‌های مروری و پژوهش‌های اصلی نیز آن‌ها را تکمیل کرد. مقالات موجود تا ۳۱ ژوئیه ۲۰۲۶ پوشش داده شدند و محدودیتی برای سال آغاز جست‌وجو تعیین نشد.

تنها آثار انگلیسی‌زبانی بررسی شدند که اطلاعات کافی درباره سامانه ماده، مجموعه داده، روش مدل‌سازی یا اعتبارسنجی داشتند. ترکیب‌های جست‌وجو شامل یادگیری ماشین، یادگیری عمیق، هوش مصنوعی، روش‌های داده‌محور، فولاد سازه‌ای، فولاد پراستحکام، فولاد هوازدگی‌مقاوم، فولاد خطوط لوله، ریزساختار، پیش‌بینی خواص، خوردگی، آتش، خستگی، شکست و عمر باقی‌مانده بود.

برای آنکه دقت‌های گزارش‌شده به‌اشتباه هم‌ارز تلقی نشوند، شواهد اعتبارسنجی در چهار سطح طبقه‌بندی شدند. **V1:** تقسیم تصادفی داده آموزش و آزمون یا اعتبارسنجی متقاطع متعارف؛ **V2:** اعتبارسنجی گروه‌بندی‌شده بر پایه ذوب‌ها، نمونه‌ها، منابع ادبیات یا دوره‌های تولید مستقل؛ **V3:** آزمون بیرونی با داده آزمایشگاه، خط تولید، سازنده، گرید یا ذوب مستقل؛ و **V4:** ارزیابی در مقیاس مهندسی، شامل تولید صنعتی، آزمون تمام‌مقیاس، پایش میدانی یا زیرساخت عملیاتی.

با توجه به تفاوت اساسی در ماده، متغیر هدف، ساختار مجموعه‌داده و شاخص عملکرد، نویسندگان از تجمیع آماری دقت‌ها خودداری کرده‌اند. شواهد به‌صورت انتقادی و برحسب ارتباط متالورژیکی، نوع داده، نمایش فیزیکی، اعتبار اعتبارسنجی، لحاظ‌کردن عدم‌قطعیت و آزمون واقعی یا مهندسی تحلیل شده‌اند.

۳. مبانی فولادهای سازه‌ای و یادگیری ماشین

۳.۱. ویژگی‌های ماده و منابع داده

داده‌های یادگیری ماشین در این حوزه از آزمایش‌های مواد، مقالات و پایگاه‌های داده باز، تولید صنعتی، ریزساختارشناسی، پایش در دوره خدمت و شبیه‌سازی عددی به دست می‌آیند. تفاوت این منابع فقط در حجم یا شکل داده نیست؛ **استقلال آماری و میزان انطباق با واقعیت فیزیکی** نیز تعیین‌کننده‌اند. هزاران ردیف داده لزوماً به معنای هزاران حالت مستقل ماده نیست. نمونه‌های متعدد از یک ذوب، تکه‌های بریده‌شده از یک ریزنگاره، قرائت‌های متراکم یک دوره تولید یا اندازه‌گیری‌های تکراری در یک وضعیت محیطی می‌توانند به‌شدت هم‌بسته باشند. بنابراین همراه شمار رکوردها باید تعداد ذوب‌ها، نمونه‌ها، شرایط آزمون و دوره‌های تولید مستقل نیز گزارش شود [۱۹–۲۱].

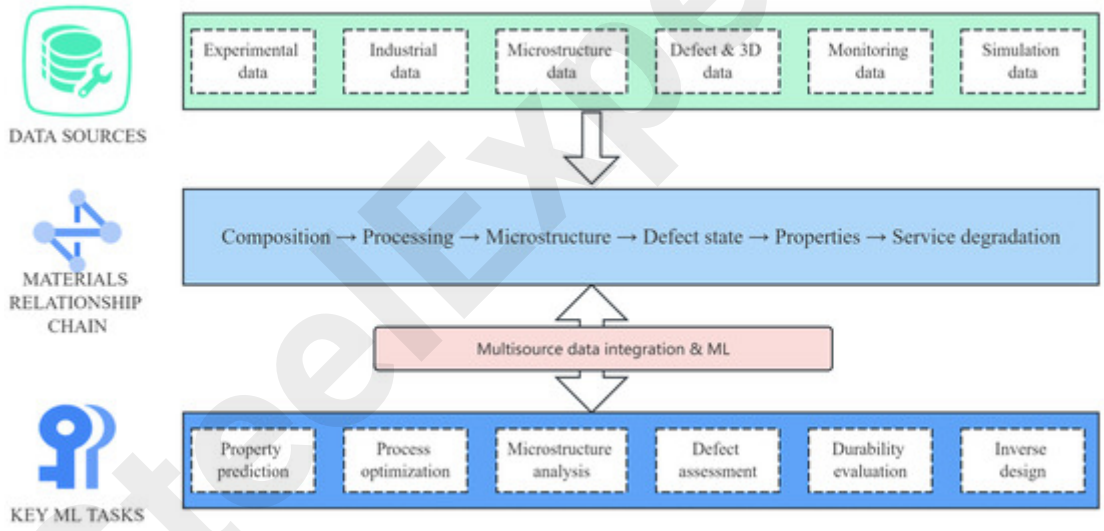
داده‌های آزمایشگاهی مستقیم‌ترین پیوند را با رفتار ماده دارند، اما تولید داده برای چقرمگی شکست، خوردگی بلندمدت، خزش و خستگی با تعداد سیکل بسیار زیاد، گران و زمان‌بر است. گردآوری داده از مقالات دامنه گریدها و فرایندها را گسترش می‌دهد، ولی ناهمگونی ناشی از نام‌گذاری فولادها، هندسه نمونه، جهت نمونه‌برداری، دمای آزمون، نرخ بارگذاری، استاندارد آزمون و دقت گزارش‌دهی را هم وارد می‌کند. داده‌های کارخانه‌ای، با وجود تعداد بالای رکوردها، اغلب ذوب‌ها و کارزارهای تولید مستقل کمتری دارند و از رانش حسگر، تعمیرات تجهیزات، تغییر فرایند، شرایط غیرعادی و خطاهای ثبت دستی اثر می‌پذیرند.

در تولید فولاد متغیرهای جدولی و سری زمانی فراوانی ثبت می‌شود: آنالیز شیمیایی، دما، زمان، دبی، فشار، نیروی نورد، فاصله غلتک‌ها و دبی آب خنک‌کننده. این داده‌ها برای پیش‌بینی کیفیت نهایی، بهینه‌سازی فرایند، تشخیص ناهنجاری و هشدار زودهنگام مناسب‌اند؛ با این وجود، تقسیم تصادفی رکوردهایی که از یک ذوب یا دوره تولید آمده‌اند می‌تواند باعث نشت اطلاعات شود. برای پیش‌بینی تولیدهای آینده باید داده‌ها را بر حسب شماره ذوب، کارزار تولید یا دوره زمانی مستقل جدا کرد.

داده‌های ریزساختار و عیب، حلقه واسط تاریخچه ساخت و عملکرد کلان ماده‌اند. میکروسکوپ نوری (OM)، میکروسکوپ الکترونی روبشی (SEM)، پراش الکترون‌های بازپراکندگی (EBSD) و میکروسکوپ الکترونی عبوری (TEM) برای شناسایی فازها، ساختار دانه، بافت بلوری، رسوبات و آخال‌ها به کار می‌روند. توموگرافی رایانه‌ای با پرتو ایکس (X-CT) نیز حفره‌ها، آخال‌ها و ترک‌های درونی را به شکل سه‌بعدی آشکار می‌کند. در یادگیری مبتنی بر تصویر، تعداد وصله‌های استخراج‌شده از تصویر باید از تعداد نمونه‌های واقعی یا میدان‌های دید مستقل تفکیک شود؛ قرارگرفتن وصله‌های یک تصویر در هر دو مجموعه آموزش و آزمون می‌تواند دقت ظاهری مدل را به‌شدت افزایش دهد، بدون آنکه واقعاً قدرت تعمیم بهتری ایجاد شده باشد.

چند مجموعه‌داده باز ظرفیت و محدودیت روش‌های تصویری را نشان می‌دهند. مجموعه Aachen–Heerlen دارای ۱۷۰۵ تصویر SEM و ۸۹۰۹ ناحیه چندضلعی حاشیه‌نویسی‌شده توسط متخصصان برای جزایر مارتنزیت–آستنیت است [۲۳]. پایگاه ریزنگاره‌های فولاد فوق‌پرکربن (UHCSDB) تصاویر در مقیاس‌های گوناگون را به اطلاعات عملیات حرارتی و ریزساختاری پیوند می‌دهد [۲۴]. داده‌های توموگرافی X-CT فولاد فریتی نیز ساختار سه‌بعدی عیوب نمونه‌های تغییرشکل‌یافته را نشان می‌دهند. هر یک از این مجموعه‌ها برای وظایف خاصی مفید است، ولی کاربرد خارج از دامنه آن‌ها نیازمند آزمون مستقل است.

داده‌های شبیه‌سازی‌شده می‌توانند شکاف داده‌های تجربی را کاهش دهند، به‌ویژه زمانی که آزمایش‌های خستگی، خوردگی یا آتش گران یا خطرناک‌اند. با این حال، برچسبی که از یک مدل عددی تولید شده حقیقت تجربی مستقل نیست. اگر همان فرض‌ها و خطاهای فیزیکی مدل شبیه‌سازی به یادگیری منتقل شود، دقت زیاد روی داده مصنوعی الزاماً به عملکرد بهتر در میدان منتهی نخواهد شد. در مجموعه‌داده‌های چندوجهی باید منشأ، مقیاس، دقت و عدم‌قطعیت هر منبع داده ثبت و سازگاری میان آن‌ها سنجیده شود.



شکل ۱. چارچوب مفهومی ادغام داده‌های چندمنبعی و کاربردهای یادگیری ماشین در فولادهای سازه‌ای. منبع: Wei و همکاران، Materials، ۲۰۲۶، شکل ۱، با مجوز CC BY 4.0.

جدول ۲. انواع اصلی داده در یادگیری ماشین برای فولادهای سازه‌ای

نوع داده	مقیاس داده و واحد مستقل	فرادادهٔ ضروری	میزان دسترسی	واحد مناسب تفکیک آموزش/آزمون	محدودیت اصلی	منابع

نوع داده	مقیاس داده و واحد مستقل	فرادادهٔ ضروری	میزان دسترسی	واحد مناسب تفکیک آموزش/آزمون	محدودیت اصلی	منابع
داده‌های ترکیب و فرایند	تعداد بسیار زیاد رکورد ممکن است فقط از تعداد به‌مراتب کمتری ذوب یا دوره تولید مستقل حاصل شده باشد	گرید، شماره ذوب، شکل محصول، ضخامت، مسیر کامل تولید و وضعیت تجهیزات	عمدتاً اختصاصی؛ بخشی در مقالات و پایگاه‌های عمومی	ذوب، گرید، دوره تولید یا بازه زمانی	هم‌خطی شدید، رانش فرایند و ثبت ناقص تاریخچه تولید	[19–22]
داده‌های مکانیکی و دوام	معمولاً محدود به شمار نمونه‌ها، شرایط یا سری‌های مواجهه مستقلِ آزمایش‌شده	هندسه و جهت نمونه‌برداری، استاندارد آزمون، دما، نرخ بارگذاری/کرنش، محیط، وضعیت عدم‌شکست یا داده سانسورشده	مقالات، پایگاه‌های آزمایشگاهی و مخازن عمومی منتخب	نمونه، ذوب، آزمایشگاه یا شرایط مواجهه	هزینه بالای آزمون، داده‌های سانسورشده و کمبود داده شکست یا شرایط مرزی	[19,20]
تصاویر ریزساختاری	شمار تصاویر و تکه‌تصاویر می‌تواند بسیار بیشتر از شمار نمونه‌های اصلی باشد؛ مثلاً 1705 تصویر SEM و 8909 ناحیه برچسب‌خورده در Aachen–Heerlen	شناسه نمونه، روش تصویربرداری، بزرگ‌نمایی، اندازه پیکسل، آماده‌سازی، میدان دید و شیوه برچسب‌گذاری	چندین مخزن داده باز	نمونه اصلی یا میدان دید مستقل	عدم‌قطعیت برچسب، وابستگی به مقیاس تصویربرداری و نشت اطلاعات میان تکه‌تصاویر	[2,23,24]
داده‌های عیوب و داده‌های سه‌بعدی	چندین عیب ممکن است از تعداد کمی حجم یا نمونه مستقل آزمایش‌شده استخراج شده باشد	شناسه نمونه، اندازه وکسل، تنظیمات بازسازی، آستانه آشکارسازی، تاریخچه بارگذاری و تعریف عیب	دسترسی آزاد محدود ولی رو به افزایش	نمونه اصلی یا حجم اسکن‌شده	هزینه زیاد گردآوری و حساسیت به بازسازی و انتخاب آستانه	[13,25]
سری زمانی و حسگرهای صنعتی	نقاط زمانی بسیار زیاد ممکن است از تعداد اندکی دوره تولید به دست آمده باشد	نوع حسگر، نرخ نمونه‌برداری، کالیبراسیون، وضعیت تجهیزات، شناسه ذوب/دوره تولید و تعمیرات	عمدتاً اختصاصی	دوره تولید، ذوب یا بلوک زمانی	خودهم‌بستگی، رانش حسگر، تغییر شرایط کار و نشت داده	[20–22]
داده‌های شبیه‌سازی عددی	امکان پوشش گسترده فضای پارامتر؛ واحد مستقل یک حالت فیزیکی شبیه‌سازی‌شده است، نه نمونه آزمایشگاهی	اعتبار مدل، معادلات حاکم، پارامترهای ماده، شرایط مرزی، شبکه/تفکیک‌پذیری، کالیبراسیون و عدم‌قطعیت	اگر مدل‌ها و ورودی‌ها موجود باشند غالباً بازتولیدپذیر	ناحیه فضای پارامتر یا سناریوی فیزیکی	اختلاف شکل مدل با واقعیت، عدم‌قطعیت پارامتر و سوگیری شبیه‌سازی نسبت به آزمایش	[3,20,28]

۳.۲. گردش کار یادگیری ماشین و ارزیابی مدل

در یک پروژه معتبر، ابتدا باید مسئله مهندسی و دامنه کاربرد مشخص شود؛ سپس داده همراه فراداده کافی گردآوری، پاک‌سازی و هم‌تراز گردد. ویژگی‌های مبتنی بر دانش فیزیکی استخراج و مدل‌های مناسب آموزش داده

می‌شوند. تنظیم ابرپارامترها تنها باید با داده آموزش انجام شود؛ مجموعه آزمون مستقل نباید ناخواسته در انتخاب ویژگی یا تنظیم مدل دخالت کند. پس از آن، ارزیابی گروه‌بندی‌شده، تفسیرپذیری، سنجش محدوده کاربرد، کمی‌سازی عدم‌قطعیت و اعتبارسنجی بیرونی ضروری است [۷–۹، ۳۱–۳۵].

نویسندگان به‌طور مشخص هشدار می‌دهند که اگر نمونه‌های یک ذوب، گرید، سازنده یا دوره تولید به‌صورت تصادفی میان آموزش و آزمون پخش شوند، مدل ممکن است بیش از آنکه رابطه متالورژیکی را یاد بگیرد، ویژگی همان منبع داده را بازشناسد. در گزارش مدل باید واحد استقلال نمونه و روش تقسیم داده روشن باشد. تفاوت میان «پیش‌بینی یک رکورد جدید از همان آزمایش» و «پیش‌بینی یک گرید یا کارخانه ناشناخته» برای کاربرد صنعتی تعیین‌کننده است.

شاخص‌هایی مانند RMSE، MAE و R^2، یا شاخص‌های طبقه‌بندی و قطعه‌بندی تصویر، فقط بخشی از ارزیابی‌اند. اعتبار مهندسی همچنین به خطاهای غیرمحافظه‌کارانه، کالیبراسیون بازه‌های پیش‌بینی، رفتار مدل خارج از دامنه داده آموزش، حساسیت به نویز حسگر و تغییر شرایط سرویس بستگی دارد. روش‌های توضیح‌پذیری از جمله SHAP می‌توانند عوامل مؤثر بر خروجی را آشکار کنند، اما اهمیت آماری یک ویژگی را نباید بی‌واسطه رابطه علّی یا قانون متالورژی دانست. چارچوب اعتمادپذیری مقاله بر تفکیک صریح این لایه‌ها استوار است.

جدول ۳. چارچوب ارزیابی اعتمادپذیری مدل‌های یادگیری ماشین فولادهای سازه‌ای

بُعد ارزیابی	پرسش اصلی	روش ارزیابی توصیه‌شده	منابع
دقت پیش‌بینی	آیا مدل نمونه‌های شناخته‌شده را با دقت توصیف می‌کند؟	RMSE، MAE، R^2، امتیاز F1، AUC و خطا در ناحیه‌های مختلف	[19,35]
سازگاری فیزیکی	آیا روند پیش‌بینی با اصول متالورژی و مکانیک سازگار است؟	بررسی شرایط مرزی، روند متغیرها و تطبیق با مدل‌های فیزیکی	[3,31,39]
تعمیم‌پذیری	آیا مدل به ذوب‌ها، گریدها و شرایط خدمت جدید منتقل می‌شود؟	آزمون کنارگذاشتن یک ذوب/گرید، آزمون میان سازندگان و اعتبارسنجی بیرونی	[36,37]
عدم‌قطعیت	آیا می‌توان به یک پیش‌بینی منفرد اتکا کرد؟	بازه پیش‌بینی، احتمال پوشش و خطای کالیبراسیون	[38]
تفسیرپذیری	آیا مدل عوامل کنترل‌کننده معقول از نظر فیزیکی را نشان می‌دهد؟	تحلیل SHAP، تحلیل حساسیت و نمودار وابستگی جزئی	[39]
بازتولیدپذیری	آیا داده‌ها، مدل و نتایج مستقلاً بازتولید می‌شوند؟	انتشار داده، کد، فراداده و پروتکل تفکیک داده	[29,30,35]

یادداشت شکل ۲: نمودار گردش کار یادگیری ماشین و ارزیابی اعتمادپذیر [۳۱] در نسخه اصلی قابل مشاهده است؛ به دلیل روشن‌نبودن حق بازنشر تصویر اقتباسی، اینجا بازتولید نشده است.

۴. کاربردهای یادگیری ماشین در طراحی و پیش‌بینی خواص فولادهای سازه‌ای

نویسندگان کاربردها را نه بر اساس اسم الگوریتم، بلکه بر مبنای جایگاه آن‌ها در زنجیره طراحی و ارزیابی ماده دسته‌بندی می‌کنند. در مرحله نخست، مدل‌ها رابطه ترکیب شیمیایی، فرایند تولید و تبدیل فاز با ریزساختار را می‌آموزند؛ در مرحله بعد، ویژگی‌های ماده از این داده‌ها پیش‌بینی می‌شود و نهایتاً نتایج پیش‌بینی در طراحی معکوس و انتخاب ماده با چند هدف عملکردی به کار می‌رود. همه این مراحل باید علاوه بر دقت، از نظر استقلال داده، روش اعتبارسنجی، عدم‌قطعیت و محدوده کاربرد نیز ارزیابی شوند.

در رویکرد معمول، ابتدا مدلی «رو به جلو» ساخته می‌شود: ترکیب، مسیر فرایند و توصیف ریزساختار وارد مدل و خواص پیش‌بینی می‌شوند. سپس دانش متالورژی فیزیکی و روش‌های بهینه‌سازی به کار می‌رود تا ترکیب، برنامه تولید یا ریزساختاری پیدا شود که هدف‌های از پیش تعیین‌شده را تأمین کند. تفاوت طراحی واقعی با پیش‌بینی صرف در این است که جواب پیشنهادی باید از نظر فیزیکی ممکن، در کارخانه ساختنی و با آزمایش مستقل قابل راستی‌آزمایی باشد.

۴.۱. طراحی ترکیب، فرایند، تبدیل فاز و ریزساختار

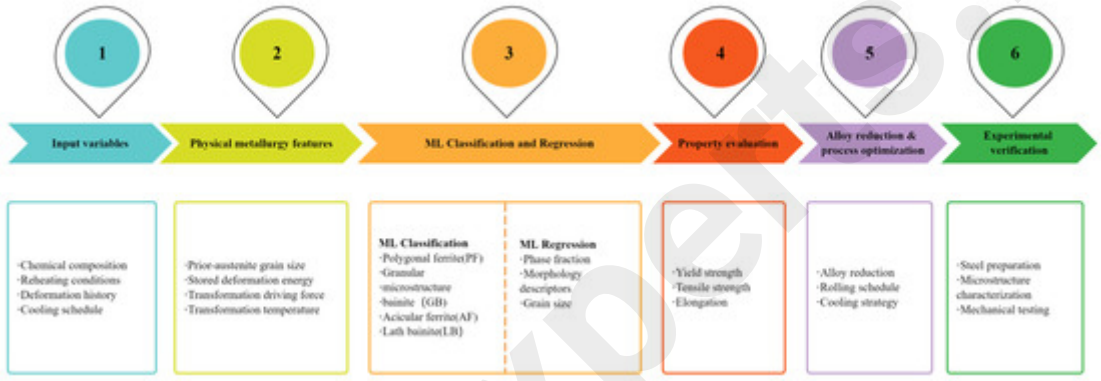
در تحلیل این بخش نیز شواهد مستقیم فولادهای زیرساختی از نتایج فولادهای مهندسی مجاور و مطالعاتی که فقط روش آن‌ها قابل انتقال است جدا شده‌اند. مثلاً یک مدل آموزش‌دیده بر فولاد زنگ‌نزن فوق‌مستحکم می‌تواند نمونه خوبی از استفاده از ویژگی‌های فیزیکی و بهینه‌سازی ژنتیک باشد، اما موفقیت آن به معنای اثبات قابلیت اجرا روی فولاد ساختمانی کربنی نیست.

طراحی آلیاژ و سختی‌پذیری. یادگیری ماشین به جست‌وجوی ترکیب‌های مناسب در فضای چندعنصری کمک می‌کند. در برخی مطالعات، متغیرهای مربوط به رسوب‌گذاری و شرایط پیرسازی با مدل‌های ماشین بردار پشتیبان (SVM)، طبقه‌بندها و الگوریتم ژنتیک (GA) ترکیب شده‌اند تا ترکیب‌های ناممکن از نظر متالورژیکی پیش از آزمون حذف شوند [۴۰]. در مطالعات سختی‌پذیری فولادهای بوردار و بدون بور، داده‌های آزمون جامینی، ترکیب و فاصله از انتهای سردشده برای پیش‌بینی منحنی سختی به کار رفته است؛ جنگل تصادفی (RF)، نزدیک‌ترین همسایه‌ها (kNN) و روش‌های ترکیبی از جمله الگوریتم‌های بررسی‌شده‌اند [۴۳، ۴۴]. اعتبار چنین نتایجی به پوشش کافی گریدها و ترکیب‌های نزدیک به نامزدهای پیشنهادی وابسته است.

پیش‌بینی تبدیل فاز. نمودارهای زمان–دما–تبدیل (TTT) و سردشدن پیوسته (CCT) معمولاً با آزمایش‌های زمان‌بر و مدل‌های تبدیل فاز تعیین می‌شوند. مدل‌های رگرسیونی تجمیعی، پرسپترون چندلایه (MLP)، جنگل تصادفی و رگرسیون نمادین با ترکیب شیمیایی و شرایط سردشدن آموزش داده شده‌اند تا دمای تبدیل،

محصولات فازی و سختی را برآورد کنند [۴۱، ۴۲]. این روش‌ها ساخت نمودارهای تبدیل را سریع‌تر می‌کنند، اما ناهمگونی مجموعه‌داده‌ها و تفاوت شرایط اندازه‌گیری هنوز مانع انتقال مطمئن بین پایگاه‌های اطلاعاتی است.

از دیدگاه فیزیکی، مسیر دقیق‌تر آن است که متغیرهای تولید ابتدا به توصیفگرهای حالت تبدیل شوند: اندازه دانه آستنیت اولیه، انرژی تغییرشکل ذخیره‌شده، پارامترهای ترمودینامیکی و سینتیکی، نرخ خنک‌کاری و تاریخچه دما. سپس کسر فازها و نوع ریزساختار برآورد شود و در نهایت خواص مکانیکی پیش‌بینی گردد. شکل ۳ زنجیره‌ای از پیش‌بینی تبدیل فاز، طراحی کم‌آلیاژ و بهینه‌سازی فرایند را نشان می‌دهد؛ نتیجه مدل دوباره برای اصلاح ترکیب یا شرایط تولید به کار می‌رود.



شکل ۳. چارچوب مبتنی بر یادگیری ماشین برای پیش‌بینی تبدیل فاز، طراحی فولاد کم‌آلیاژ و بهینه‌سازی فرایند. منبع: Wei و همکاران، Materials، ۲۰۲۶، شکل ۳، مجوز CC BY 4.0.

شناسایی و اندازه‌گیری ریزساختار. روش‌های تصویری از استخراج دستی شاخص‌هایی مانند اندازه متوسط دانه به یادگیری خودکار ویژگی‌ها حرکت کرده‌اند. شبکه‌های پیچشی تمام‌همبند (FCNN)، معماری U-Net و مدل‌های قطعه‌بندی دیگر برای تعیین مرز فازها، اندازه دانه، کسر فازی و شناسایی عیوب روی تصاویر SEM یا EBSD به کار رفته‌اند [۴۶–۴۹]. برچسب‌های مبتنی بر EBSD می‌توانند مبنای فیزیکی بهتری برای آموزش فراهم کنند، اما کیفیت آماده‌سازی سطح، بزرگنمایی، شرایط تصویربرداری و تعداد نمونه‌های مستقل همچنان بر دقت تأثیر جدی دارد.

در داده‌های تصویری کوچک، یادگیری انتقالی (Transfer Learning) برای استفاده از دانش آموخته‌شده در دامنه‌ای دیگر به کار می‌رود؛ با این همه، موفقیت آن بستگی دارد که الگوهای تصویر مبدأ با ریزساختار مقصد همخوانی داشته باشند. مدل باید در برابر بزرگنمایی، کنتراست، دستگاه و آماده‌سازی متفاوت آزمایش شود. به‌خصوص نباید وصله‌هایی از یک تصویر مادر به دو دسته آموزش و آزمون راه یابند. *شکل ۴ مقاله اصلی* فرایند یادگیری انتقالی و قطعه‌بندی ریزساختار را توضیح می‌دهد؛ تصویر اقتباسی به دلیل ابهام در مجوز بازنشر در این نسخه ارائه نشده است.

هدف نهایی ریزساختارشناسی صرفاً ایجاد یک نقشه قطعه‌بندی‌شده زیبا نیست؛ باید نمایش دقیق‌تری از سازوکارهای استحکام و تغییرشکل به دست آید. در یکی از پژوهش‌های مرورشده، Liu و همکاران، قطعه‌بندی مبتنی بر یادگیری عمیق را با مدل پیش‌بینی خواص جنگل تصادفی ترکیب کردند و افزون بر اندازه دانه و کسر فاز، طول مرزدانه‌ها و طول فصل مشترک فاز دوم را نیز وارد مدل فولادهای نورد گرم کردند. در مقایسه با مدل مبتنی بر اندازه متوسط دانه و کسر فاز، خطای جذر میانگین مربعات (RMSE) برای تنش تسلیم، استحکام کششی نهایی و ازدیاد طول به ترتیب **۷۱٫۵۳٪، ۶۷٫۵۱٪ و ۵۳٫۴۰٪** کمتر گزارش شد [۴۹]. این نتیجه اهمیت هندسه مرزها و توزیع مکانی ریزساختار را نشان می‌دهد؛ البته اعتبار آن برای دیگر گریدها و آزمایشگاه‌ها به آزمون مستقل نیاز دارد.

سه مسیر فنی اصلی از این مطالعات برداشت می‌شود: نخست، پیش‌بینی مستقیم تبدیل فاز یا ریزساختار با داده‌های ترکیب و فرایند؛ دوم، افزودن متغیرهای میانی فیزیکی مانند اندازه آستنیت اولیه یا کمیت‌های ترمودینامیکی؛ سوم، استخراج خودکار ویژگی ریزساختار از تصویر و انتقال آن به مدل خواص. روش نخست محاسبات ساده‌تری دارد ولی در برون‌یابی به پوشش داده وابسته است؛ روش دوم با فیزیک سازگارتر است ولی خطای مدل‌های میانی به آن منتقل می‌شود؛ روش سوم ناهمگونی فضایی را بهتر ثبت می‌کند اما محدودیت داده برچسب‌خورده و تغییر شرایط تصویربرداری را دارد. ترکیب این سه مسیر همراه با آزمون صنعتی مستقل، بیشترین ظرفیت را برای کاربرد مهندسی نشان می‌دهد.

جدول ۴. کاربردهای منتخب یادگیری ماشین در طراحی ترکیب، فرایند و ریزساختار فولادهای سازه‌ای

دامنه ماده یا کاربرد	داده‌ها و متغیرها	مدل‌ها و اعتبارسنجی	یافته کلیدی و محدودیت کاربرد	منابع
فولاد زنگ‌نزن فوق‌پراستحکام به‌عنوان مورد انتقال روش	داده‌های اندک از منابع و آزمایش؛ ترکیب، شرایط پیرسازی و متغیرهای فیزیکی مربوط به رسوب‌گذاری برای پیش‌بینی سختی و امکان‌پذیری	SVM آگاه از فیزیک، طبقه‌بند و الگوریتم ژنتیک (GA)؛ اعتبارسنجی متقاطع و ساخت آلیاژ مستقل	ویژگی‌های فیزیکی نامزدهای ناممکن را حذف کردند؛ اما ماده از فولادهای سازه‌ای متداول عمرانی نیست	[40]
تبدیل فاز در فولادهای پرآلیاژ و کم‌آلیاژ	داده‌های TTT و CCT از مقالات و آزمایش؛ ترکیب و شرایط سردکردن برای پیش‌بینی فاز، دما و سختی	رگرسیون تجمیعی، پرسپترون چندلایه (MLP)، جنگل تصادفی (RF) و رگرسیون نمادین؛ آزمون و مقایسه با روش‌های مرسوم	پیش‌بینی سریع‌تر نمودارهای تبدیل؛ ناسازگاری میان پایگاه‌های داده همچنان محدودیت دارد	[41,42]
سختی‌پذیری فولادهای بوردار و بدون بور	داده آزمون جومینی؛ ترکیب و فاصله از انتهای سردشونده برای پیش‌بینی منحنی سختی و بهینه‌سازی ترکیب	RF، نزدیک‌ترین همسایه‌ها (kNN) و مدل‌های ترکیبی؛ اعتبارسنجی متقاطع و آزمون فولادهای نامزد	برای خروجی به‌شکل منحنی مناسب است؛ کیفیت نتیجه به پوشش فولادهای مشابه از نظر ترکیب وابسته است	[43,44]

دامنه ماده یا کاربرد	داده‌ها و متغیرها	مدل‌ها و اعتبارسنجی	یافته کلیدی و محدودیت کاربرد	منابع
ریزساختارهای پیچیده فولاد	تصاویر SEM و EBSD با شمار محدود نمونه مستقل؛ طبقه‌بندی، قطعه‌بندی و کمی‌سازی فازها	شبکه تمام‌کانولوشنی (FCNN)، U-Net و مدل‌های عمیق قطعه‌بندی؛ تفکیک در سطح نمونه و آزمون میان گریدها	برچسب‌های برگرفته از EBSD سازگاری فیزیکی را بهتر کردند؛ نتیجه به آماده‌سازی نمونه و بزرگ‌نمایی حساس است	[46–49]

۴.۲. پیش‌بینی خواص مکانیکی

پیش‌بینی تنش تسلیم، استحکام کششی، ازدیاد طول، چقرمگی، سختی و پاسخ تنش–کرنش از متداول‌ترین کاربردهای یادگیری ماشین در فولادهاست. در مدل‌های جدولی معمولاً عناصر آلیاژی، شرایط ریخته‌گری و نورد، سرعت سردشدن و متغیرهای عملیات حرارتی ورودی‌اند. هنگامی که داده‌های ریزساختاری و اطلاعات عیب نیز موجود باشند، مدل می‌تواند فراتر از ارتباط ساده ترکیب با خواص حرکت کند و به سازوکارهای استحکام‌بخشی، کارسختی و شکست نزدیک‌تر شود.

جنگل تصادفی، درخت‌های تقویتی، گرادیان‌بوستینگ، ماشین بردار پشتیبان و شبکه‌های عصبی از ابزارهای تکرارشونده‌اند. در مجموعه‌داده‌های جدولی کوچک و متوسط، مدل‌های درخت‌مبنا غالباً نقطه شروع مناسبی هستند؛ اما برتری آن‌ها همگانی نیست و نمی‌توان آن را بدون آزمون در همان مسئله و مجموعه‌داده به فولادها تعمیم داد. برای داده‌های تصویری یا زمانی، شبکه‌های یادگیری عمیق انعطاف بیشتری در یادگیری نمایش داده دارند، در مقابل به حجم و تنوع داده و تنظیم اعتبارسنجی حساس‌ترند.

پیش‌بینی خواص مکانیکی به نوع هدف و شرایط آزمون نیز وابسته است. استحکام تسلیم و کششی، ازدیاد طول، سختی و چقرمگی شکست رفتارهای یکسانی نیستند؛ جهت نمونه، ضخامت ورق، سرعت بارگذاری، دما و استاندارد آزمون می‌تواند رابطه ورودی و خروجی را تغییر دهد. مدلی که از داده چند مطالعه گردآوری شده باید تفاوت آزمون‌ها را ثبت کند، در غیر این صورت بخشی از تغییرپذیری ناشی از روش اندازه‌گیری، با تغییر واقعی رفتار فولاد اشتباه گرفته می‌شود.

در مسئله پیش‌بینی منحنی تنش–کرنش و رفتار ساختاری ماده، استفاده از توصیفگرهای فیزیکی و مدل‌های ترکیبی اهمیت بیشتری دارد. تنها برآورد یک عدد مانند تنش تسلیم برای شبیه‌سازی عضو سازه‌ای کافی نیست؛ شکل منحنی، کارسختی، اثر دما و روند نرم‌شدن نیز ممکن است تعیین‌کننده باشد. ترکیب متالورژی فیزیکی، روابط ساختاری ماده و یادگیری ماشین می‌تواند تخمین‌هایی بسازد که هم از داده بیاموزند و هم قیود پذیرفته‌شده را نقض نکنند.

مدل‌های پیش‌بینی خواص نباید صرفاً بر تقسیم تصادفی رکوردها قضاوت شوند. نتیجه بهتر در مجموعه آزمون

داخلی ممکن است به همپوشانی نزدیک ترکیب‌ها، نمونه‌های یک ذوب یا تکرار یک شرایط فرایندی وابسته باشد. برای استفاده در تصمیم‌های انتخاب گرید و تأیید مواد، لازم است عملکرد مدل روی ذوب‌ها و گریدهای ناشناخته و در صورت امکان کارخانه‌ها و آزمایشگاه‌های مستقل اندازه‌گیری شود. همچنین باید روشن باشد در چه محدوده ترکیب، عملیات و خواص پیش‌بینی معتبر است.

نمونه صنعتی: داده‌های پرتعداد، ذوب‌های مستقل کمتر. Guo و همکاران با پاک‌سازی پایگاه داده تولید صنعتی به ۶۳,۱۳۷ رکورد و ۲۷ متغیر مرتبط با ترکیب و فرایند رسیدند و برای تنش تسلیم، استحکام کششی و ازدیاد طول مدل پیش‌بینی هم‌زمان ساختند. سپس خروجی مدل‌ها را در چارچوب برنامه‌ریزی غیرخطی مقید برای یافتن ناحیه قابل قبول چند خاصیت به کار بردند [۵۰]. با این همه، مقاله شمار ذوب‌ها و کارزارهای تولید مستقل را گزارش نمی‌کند؛ بنابراین ۶۳,۱۳۷ رکورد را نباید معادل همین تعداد مشاهده متالورژیکی مستقل دانست. ارزیابی داخلی آن مطالعه، مدرک تعمیم موفق مدل به کارخانه‌ای دیگر نیست.

نمونه ویژگی‌سازی فیزیکی: Jiang و همکاران برای مفتول فولادی پرلیتی SGLX82A حدود ۱۰۰ پارامتر تولید را با محاسبات ترمودینامیکی، سینتیکی و اجزای محدود به توصیفگرهایی مانند کسر فریت پیش‌اوتکتوئیدی، کسر پرلیت و فاصله بین‌لایه‌ای تبدیل کردند. مجموعه نهایی پس از پاک‌سازی ۱۵۰ نمونه داشت. روش‌های Gradient Tree Boosting و رگرسیون فرایند گاوسی در اعتبارسنجی متقاطع ده‌بخشی تکرارشده، میانگین خطای نسبی کمتر از ۰٫۷٪ و بیشینه خطای نسبی کمتر از ۲٪ گزارش کردند و ۱۰ نمونه دیده‌نشده دیگر نیز ارزیابی شدند [۵۱]. این اعداد در همان خط و همان گرید به دست آمده‌اند و نباید به‌عنوان دقت عمومی در خطوط دیگر معرفی شوند.

خواص دمای بالا: برخلاف مقاومت کششی در دمای اتاق، خواص در زمان آتش‌سوزی به نرخ گرم‌شدن، زمان ماند، نرخ کرنش، مسیر بارگذاری و تاریخچه حرارتی وابسته‌اند. نتایج آزمون دمای بالا در حین آتش‌سوزی با خواص باقی‌مانده پس از آتش یکسان نیست. Peng و همکاران در یک نمونه انتقال روش، برای پیش‌بینی تنش تسلیم دمای بالای فولادهای ۹ تا ۱۲ درصد کروم، دماهای تبدیل و کسر فازها و رسوبات به‌دست‌آمده از CALPHAD را کنار ترکیب، دما و اطلاعات آستنیت اولیه قرار دادند [۵۶]. این کار اهمیت توصیفگرهای فیزیکی را نشان می‌دهد، اما گستره محدود گریدها مانع تعمیم مستقیم به فولادهای ساختمانی است.

یادداشت شکل ۵: نمونه‌ای از ویژگی‌های تجربی و مصنوعیِ مبتنی بر فیزیک برای پیش‌بینی تنش تسلیم فولادهای ۹ تا ۱۲ درصد کروم [۵۶] در نسخه ناشر دیده می‌شود. تصویر به علت وضعیت نامشخص حق بازنشر مجدد نشده است.

جدول ۵. مطالعات منتخب پیش‌بینی خواص مکانیکی فولادهای سازه‌ای

خاصیت	مبنای داده	روش یادگیری ماشین و اعتبارسنجی	محدودیت اصلی	منابع
خواص کششی	داده‌های تولید صنعتی	مدل‌های درختی/تجمیعی و اعتبارسنجی گروهی	تعداد ذوب‌های مستقل باید روشن باشد	[51,52]
خواص کششی	63,137 رکورد	جنگل تصادفی/رگرسیون؛ اعتبارسنجی داخلی	رکوردها لزوماً نماینده ذوب‌های مستقل نیستند	[50]
انرژی ضربه شارپی	داده‌های مقالات و صنعت	رگرسیون/مدل تجمیعی؛ آزمون روی مجموعه مستقل داخلی	دما و شرایط نمونه متفاوت است	[53,54]
خواص در دمای بالا	آزمایش‌های دمای بالا	رگرسیون/مدل تجمیعی؛ اعتبارسنجی آزمایشگاهی	تاریخچه گرمایش و بارگذاری متغیر است	[55,56]

۴.۳. بهینه‌سازی چندخاصیتی و طراحی معکوس مواد

در پیش‌بینی رو به جلو، ترکیب و شرایط تولید مشخص‌اند و مدل خواص را برآورد می‌کند. در طراحی معکوس، مسئله برعکس مطرح می‌شود: با داشتن هدف‌هایی مانند حداقل تنش تسلیم، چقرمگی، ازدیاد طول یا مقاومت خوردگی، چه ترکیب و مسیر تولیدی انتخاب شود؟ این مسئله به‌ندرت پاسخ یکتایی دارد و عموماً محدودیت‌های هم‌زمان ساخت‌پذیری، جوش‌پذیری، هزینه، دسترس‌پذیری عناصر و پایداری عملکرد باید رعایت شوند.

برای حل آن می‌توان یک مدل پیش‌بینی را با جست‌وجوی تکاملی، الگوریتم ژنتیک، بهینه‌سازی چندهدفه، الگوریتم‌های بیزی یا یادگیری فعال ترکیب کرد. ولی تبدیل خروجی یک مدل رگرسیون به دستور آلیاژسازی کافی نیست. اگر نامزد پیشنهادی بیرون از دامنه داده‌های معتبر باشد، مدل ممکن است مقدار ظاهراً مطلوبی نشان دهد که امکان تحقق فیزیکی یا تولیدی ندارد. اعمال قیدهای متالورژیکی، تعیین عدم‌قطعیت و ساخت و آزمایش مستقل نمونه منتخب باید بخشی از چرخه طراحی باشد.

در مطالعه‌ای روی فولادهای دوقلویی القاشده با پلاستیسیته (TWIP)، Zhou و همکاران از **۲۷۳ رکورد** شامل ترکیب، ریزساختار، شرایط آزمون و خواص مکانیکی برای ساخت مدل‌های تنش تسلیم، استحکام کششی نهایی و ازدیاد طول استفاده کردند. سپس با تحلیل SHAP عوامل اثرگذار را شناسایی کرده، بهینه‌سازی چندهدفه انجام دادند و فولادهای پیشنهادی را به‌صورت تجربی راستی‌آزمایی کردند [۶۸]. چنین مطالعه‌ای ارزش روش را نشان می‌دهد، اما فولاد TWIP در اینجا نمونه انتقال روش است؛ نتیجه آزمایش آن نباید بی‌واسطه معادل تأیید یک فولاد ساختمانی متعارف دانسته شود.

همچنین رویکردهای تصویرمحور و مدل‌های مولد، از جمله خودرمزگذارهای تغییراتی (VAE)، می‌توانند به جست‌وجوی ریزساختارهایی با خواص مطلوب کمک کنند. با این حال، تصویر مصنوعی ریزساختار به‌تنهایی دستورالعمل تولید آن نیست. لازم است زنجیره معکوس از تصویر یا هدف مکانیکی، به ترکیب و برنامه واقعی

نورد، عملیات حرارتی و تولید نمونه آزمایشی متصل شود. *شکل‌های ۶ و ۷* نمونه‌هایی از طراحی تصویرمحور و ترکیب بهینه فولاد TWIP را نشان می‌دهند؛ تصاویر اقتباسی آن‌ها در این ترجمه بازنشر نشده‌اند.

اعتبارسنجی آینده‌نگر در طراحی معکوس اهمیت ویژه دارد: مدل باید پیش از انجام آزمایش، نامزدهایی را انتخاب کند که در مجموعه آموزش نبوده‌اند؛ سپس ماده واقعاً ساخته، فرایند تولید اجرا، ریزساختار مشخص و خواص اندازه‌گیری شود. بازیابی ترکیب‌های شناخته‌شده یا اعتبارسنجی داخلی فقط نشان می‌دهد مدل داده‌های قبلی را تا چه حد بازتولید می‌کند. طراحی معکوس قابل اعتماد، فرایند تصمیم‌گیری مقید و آگاه از عدم‌قطعیت است، نه وارونه‌سازی مکانیکی یک مدل خواص.

۵. کاربردهای یادگیری ماشین در دوام و ارزیابی عمر خدمت فولادهای سازه‌ای

کاربرد یادگیری ماشین در فولادهای سازه‌ای از پیش‌بینی خواص در آغاز تولید به ارزیابی تخریب در زمان بهره‌برداری رسیده است. دوام، برخلاف رابطه نسبتاً ایستای ترکیب و خواص، با گذر زمان، تغییر شرایط محیطی، آسیب تجمعی و انتقال اثر در مقیاس‌های مختلف همراه است. بنابراین نویسندگان مطالعات را برحسب سازوکار تخریب، متغیر هدف، افق زمانی و سطح شواهد مهندسی مقایسه می‌کنند، نه بر اساس یک رتبه‌بندی سراسری از «بهترین الگوریتم».

پیش‌بینی نرخ خوردگی، برآورد آسیب موضعی، افت خواص در دمای بالا، مقاومت عضو در آتش، استحکام و عمر خستگی، پایش گسترش ترک و برآورد عمر باقی‌مانده، وظایف جداگانه‌ای هستند. در سطح ماده، معمولاً نرخ خوردگی، خواص باقیمانده و استحکام خستگی پیش‌بینی می‌شود؛ در سطح عضو، ظرفیت باربری و تکامل ترک؛ و در سطح بهره‌برداری، سیر آسیب، احتمال خرابی یا عمر باقی‌مانده. برای قضاوت درباره اعتبار هر مدل باید معلوم باشد دقیقاً کدام کمیت را برای چه دوره‌ای و با چه سطح استقلالی پیش‌بینی کرده است.

برای نمونه، کاهش جرم، چگالی جریان خوردگی و میانگین سرعت نفوذ خوردگی، بیانگر تخریب کلی‌اند؛ اما بیشینه عمق حفره و شکل حفره‌های خوردگی ارتباط مستقیم‌تری با تمرکز تنش و قابلیت اطمینان سازه دارند و قابل جایگزینی با میانگین نرخ خوردگی نیستند. به همین ترتیب، خوردگی شیمیایی در نمک مذاب یا محیط داغ، مسئله‌ای متفاوت از افت مقاومت مکانیکی سازه در آتش‌سوزی است.

جدول ۶. وظایف اصلی یادگیری ماشین در ارزیابی دوام و عمر خدمت فولادهای سازه‌ای

وظیفه یادگیری ماشین	متغیر هدف	مقیاس معمول
پیش‌بینی نرخ خوردگی	نرخ یا جریان خوردگی	ماده

وظیفه یادگیری ماشین	متغیر هدف	مقیاس معمول
پیش‌بینی آسیب موضعی	عمق یا شکل حفره خوردگی	سطح موضعی
پیش‌بینی تخریب در دمای بالا	خواص مکانیکی باقی‌مانده	ماده
پیش‌بینی مقاومت در برابر آتش	مقاومت عضو سازه‌ای	عضو
پیش‌بینی مقاومت خستگی	مقاومت خستگی	ماده/اتصال
پیش‌بینی عمر کل	عمر خستگی	ماده/عضو
پایش رشد ترک	طول یا نرخ رشد ترک	ناحیه موضعی/عضو
تخمین عمر باقی‌مانده	عمر خدمت باقی‌مانده	عضو/سازه

۵.۱. خوردگی و تخریب محیطی

خوردگی فولادهای سازه‌ای تحت تأثیر هم‌زمان ترکیب و ریزساختار ماده، وضعیت سطح، پوشش محافظ، محیط و مدت قرارگیری است. یادگیری ماشین برای تحلیل اثرات غیرخطی این متغیرها مفید است، اما مطالعه‌ای که «جریان لحظه‌ای خوردگی» را پیش‌بینی می‌کند با مطالعه‌ای که «عمق خوردگی پس از ده سال» یا «عمر باقی‌مانده شمع فولادی» را برآورد می‌کند، حتی با داشتن R^2 مشابه، شواهد مهندسی یکسانی ارائه نمی‌دهد.

پایش کوتاه‌مدت جوّی. Pei و همکاران فولاد کربنی را به مدت **۳۴ روز** با حسگر گالوانیکی Fe/Cu پایش کردند. رطوبت نسبی، دما، بارندگی، ذرات معلق و آلاینده‌های گازی ورودی پیش‌بینی رفتار آنی خوردگی بودند. جنگل تصادفی بهتر از شبکه عصبی مصنوعی و رگرسیون بردار پشتیبان عمل کرد؛ در نظر گرفتن تشکیل زنگ نیز نتیجه را بهبود داد [۶۹]. این پژوهش ارزش داده‌های حسگر و پاسخ زمانی را نشان می‌دهد، اما از آزمونی ۳۴ روزه نمی‌توان به‌تنهایی اتلاف ضخامت سازه در دوره‌های طولانی را نتیجه گرفت.

خوردگی بلندمدت در اقلیم دریایی. Yan و همکاران **۳۰۶ رکورد** خوردگی مربوط به **۱۸ فولاد آلیاژی** در سه محل مواجهه با جو دریایی گردآوری کردند. دوره‌های مواجهه ۱، ۲، ۳، ۵، ۷ و ۱۰ سال بود و نرخ خوردگی بر حسب عمق سالانه (µm/year) گزارش می‌شد. مدل جنگل تصادفی بهینه‌شده برای داده آموزش R^2 برابر ۰٫۹۴ و برای داده آزمون ۰٫۷۳ داشت [۷۰]. نتیجه نشان می‌دهد افزودن شرایط محیطی و زمان قرارگیری در کنار ترکیب اهمیت دارد؛ با این حال، تعداد نمونه‌های آلیاژی مستقل کمتر از تعداد کل رکوردهاست.

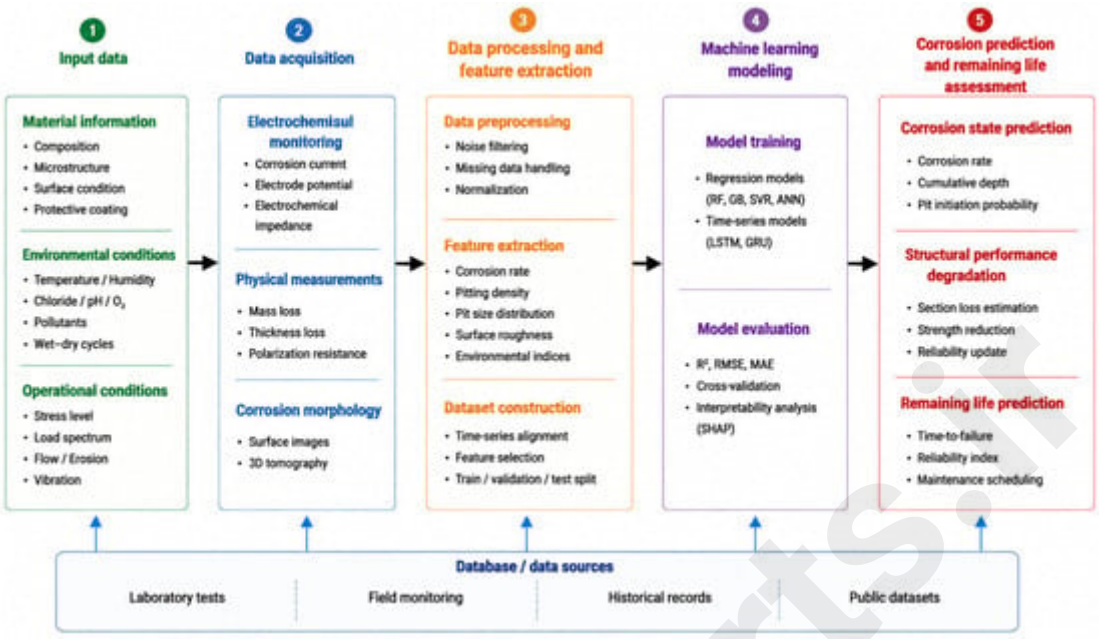
محیط‌های متغیر و پویا. Song و همکاران خوردگی جوی در شرایط حرکت خودرو را با داده‌های هواشناسی، آلودگی و پارامترهای عملیاتی، از جمله متوسط سرعت و نسبت زمان حرکت به توقف، بررسی کردند. با وزن‌دهی زمانی، متغیرهایی با بسامد ثبت متفاوت هم‌تراز شدند. رگرسیون بردار پشتیبان بهینه‌شده با الگوریتم ژنتیک

(GA-SVR) مقدار R^2 برابر **۰٫۹۷۷۱** گزارش کرد و از مدل‌های مقایسه‌شده بهتر بود [۷۱]. Liu و Li نیز برای فولاد 3C در آب دریا از دما، pH، اکسیژن محلول، شوری و پتانسیل اکسایش–کاهش برای پیش‌بینی نرخ خوردگی استفاده کردند؛ تحلیل SHAP پتانسیل اکسایش–کاهش را مهم‌ترین پیش‌بین تشخیص داد [۷۲]. چنین تبیینی به شناخت مدل کمک می‌کند، اما به‌تنهایی دلیل علیت نیست.

خاک و سامانه‌های فولاد–بتن. Dong و همکاران با استفاده از **۱۴۲۸ رکورد آزمایشگاهی**، چگالی جریان خوردگی فولاد مدفون در خاک را از مدت مواجهه، رطوبت، pH، مقاومت ویژه الکتریکی، کلرید، سولفات و کربن آلی کل پیش‌بینی کردند. جنگل تصادفی R^2 برابر **۰٫۹۸۷** داشت و ترکیب مقاومت ویژه خاک، زمان مواجهه و کربن آلی کل، مجموعه‌ای سه‌متغیره و مؤثر تشخیص داده شد [۷۳]. مطالعه Ji و Ye روی میلگرد مدفون در مواد سیمانی کربناته، اهمیت مقاومت ویژه، نسبت یون کلرید به هیدروکسید، سهم سیمان و پتانسیل خوردگی را نشان داد [۷۴]؛ اما نتیجه این سامانه نباید مستقیماً به فولاد سازه‌ای بدون پوشش یا بتن غیرکربناته تعمیم یابد.

شکل ۸ زنجیره منطقی «اطلاعات ماده و پوشش، شرایط محیطی و عملیاتی، پایش خوردگی، مدل‌سازی وضعیت خوردگی، افت ظرفیت سازه و برآورد عمر خدمت» را نشان می‌دهد. ترکیب شیمیایی، ریزساختار، وضعیت سطح و پوشش‌ها در کنار دما، رطوبت، رسوب کلرید، آلاینده‌ها و چرخه تر و خشک وارد تحلیل می‌شوند. داده‌های پایش نیز می‌تواند کاهش جرم، جریان خوردگی، مقاومت الکتریکی، ضخامت دیواره یا شکل آسیب باشد. خروجی مورد استفاده در مدیریت دارایی باید از نرخ آنی خوردگی فراتر رفته و با اتلاف مقطع و کاهش ظرفیت باربری مرتبط شود.

SteelExperts.ir



شکل ۸. چارچوب یادگیری ماشین برای ارزیابی تخریب ناشی از خوردگی و عمر خدمت فولادهای سازه‌ای. منبع: Wei و همکاران، Materials، ۲۰۲۶، شکل ۸، مجوز CC BY 4.0.

محیط‌های خورنده دمای بالا. در نمک مذاب، اکسایش و شرایط ترموشیمیایی، دما، مدت مواجهه، ترکیب آلیاژ و محیط خورنده به شکل پیچیده‌ای اثر می‌گذارند. Muthukrishnan و همکاران داده‌های خوردگی دمای بالای مواد سازه‌ای و پوشش‌های محافظ را گردآوری و مدل‌های رگرسیونی را مقایسه کردند؛ جنگل تصادفی عموماً عملکرد مناسبی نشان داد. نویسندگان تأکید کردند که داده‌های فعلی دامنه ترکیبات نمک مذاب، دماها و حالت‌های مختلف ماده را به‌طور کافی پوشش نمی‌دهد؛ بنابراین مدل برای غربال اولیه مواد مناسب‌تر از جایگزینی با آزمون بلندمدت خوردگی است [۷۵].

برآورد عمر خدمت. کاربرد عملی پیش‌بینی خوردگی آن است که شرایط محیطی و اندازه آسیب به اتلاف مقطع، قابلیت اطمینان و زمان‌بندی بازرسی و نگهداری تبدیل شود. مدل‌های تجمیعی متکی بر سوابق حوادث خطوط لوله [۷۶] و شبکه عصبی آگاه از فیزیک (PINN) برای شمع‌های لوله‌ای فولادی در محیط دریایی [۷۷] دو مسیر متفاوت‌اند. اولی به نمایندگی داده‌های تاریخی حوادث وابسته است و دومی به مفروضات مدل فیزیکی و مرزهای محیطی. هیچ‌یک هنوز همه آثار ترکیبی خوردگی حفره‌ای شدید، آب‌شستگی و خستگی–خوردگی را در بر نمی‌گیرد.

Feng و همکاران نفوذ کلرید، عمق خوردگی، کاهش ضخامت دیواره و افت خواص مکانیکی را در مدل PINN مربوط به شمع فولادی دریایی به کار بردند. پس از بهینه‌سازی ازدحام ذرات، انحراف ضریب نفوذ شناسایی‌شده به روش معکوس از مقدار تجربی **۴٫۳٪** بود [۷۷]. ولی جبهه نفوذ کلرید در آن مدل تقریباً یکنواخت فرض شده و پیش‌بینی بیشتر نماینده کاهش متوسط ضخامت است تا حفره‌زایی موضعی، خوردگی شکافی یا برهم‌کنش

خوردگی و آب‌شستگی.

یادداشت شکل ۹: نمودار اندازه‌گیری و پیش‌بینی نرخ خوردگی فولادهای کم‌آلیاژ SMA490، SPA-H و SM490A پس از یک و ده سال قرارگیری در سه محیط دریایی [۷۰] در مقاله اصلی موجود است. این تصویرِ برگرفته از پژوهشی دیگر به دلیل وضعیت نامشخص حق بازنشر، در بسته فارسی تکثیر نشده است.

در مجموع، مقایسه مستقیم دقت خوردگی کوتاه‌مدت حسگر، کاهش ضخامت بلندمدت، جریان الکتروشیمیایی و عمر باقی‌مانده صحیح نیست. اعتبار هر مدل باید بر اساس کمیت فیزیکی هدف، افق زمانی، استقلال داده اعتبارسنجی، محدوده کاربری و پیامد مهندسی خطا بررسی شود.

جدول ۷. پژوهش‌های منتخب یادگیری ماشین در خوردگی و تخریب محیطی فولادهای سازه‌ای

محیط مواجهه	مورد مطالعه	متغیر هدف و واحد	دوره/شرایط مواجهه	مدل و اعتبارسنجی	آسیب موضعی	منبع
اتمسفر	حسگر فولاد کربنی	جریان گالوانیکی لحظه‌ای (μA)	34 روز	RF؛ آزمون سری زمانی	خیر	[69]
اتمسفر دریایی	فولادهای کم‌آلیاژ	نرخ خوردگی (μm·year ⁻¹)	1 تا 10 سال	RF؛ تقسیم آموزش/آزمون	خیر	[70]
اتمسفر پویا	فولاد کربنی	نرخ خوردگی (μm·year ⁻¹)	مواجهه پویا روی خودرو	GA-SVR؛ آزمون کنارگذاشته‌شده	خیر	[71]
آب دریا	فولاد 3C	چگالی جریان خوردگی (μA·cm ⁻²)	شرایط گوناگون آب دریا	ANN؛ داده آزمون دیده‌نشده	خیر	[71]
خاک/زیرزمین	فولاد	چگالی جریان خوردگی (A·m ⁻²)	0 تا 415 روز	RF؛ تقسیم تصادفی 80/20	خیر	[73]
فولاد–بتن	فولاد در ملات	چگالی جریان خوردگی (μA·cm ⁻²)	مواجهه آزمایشگاهی	SVR؛ اعتبارسنجی متقاطع	خیر	[74]
خوردگی دمای بالا	مواد سازه‌ای/پوشش‌ها	نرخ خوردگی (واحد مختص مطالعه)	داده‌های ناهمگون مقالات	RF؛ اعتبارسنجی داخلی	تعیین نشده	[75]
خط لوله/عمر خدمت	سامانه‌های خط لوله	زمان تا خرابی (واحد زمانی منبع)	سوابق تاریخی خرابی	Extra Trees؛ اعتبارسنجی متقاطع و مجموعه آزمون	تعیین نشده	[76]
شمع‌های لوله‌ای دریایی	شمع‌های فولادی لوله‌ای	عمق خوردگی (mm)؛ عمر خدمت (سال)	آزمون شتاب‌یافته و برون‌یابی بلندمدت	شبکه عصبی آگاه از فیزیک (PINN)؛ آزمون آزمایشگاهی	خیر؛ فرض خوردگی یکنواخت	[77]

«آسیب موضعی» به آن معناست که مدل صریحاً حداکثر عمق حفره یا شکل حفره را پیش‌بینی کند. «خیر»

یعنی خروجی عمدتاً میانگین یا کمیت الکتروشیمیایی است؛ «تعیین نشده» یعنی این موضوع در مدل صریحاً لحاظ نشده است.

۵.۲. عملکرد در آتش و دماهای بسیار بالا

رفتار فولاد سازه‌ای در آتش مسئله‌ای چندمقیاسی است. در سطح ماده، هدایت گرمایی، گرمای ویژه، مدول الاستیسیته، تنش تسلیم و منحنی تنش–کرنش تابع دما تغییر می‌کنند؛ در سطح عضو، این افت خواص همراه با هندسه، بارگذاری، گرادیان حرارتی و شرایط تکیه‌گاهی، پایداری و مقاومت را تعیین می‌کند؛ و در سطح کل سازه، شکست عضو ممکن است پیامدهایی مانند بازتوزیع بار یا خرابی پیشرونده ایجاد کند. بنابراین پژوهش‌های عضو و سازه در این مرور فقط زمانی بررسی شده‌اند که پیوند آن‌ها با افت خواص ماده مشخص باشد. دقت پیش‌بینی در این مقیاس‌ها را نمی‌توان مستقیماً با دقت پیش‌بینی تنش تسلیم یک نمونه فولادی مقایسه کرد.

پیش‌بینی خواص وابسته به دما، نخستین سطح کاربرد ML است. Naser با ترکیب شبکه عصبی و الگوریتم ژنتیک، داده‌های تجربی و مدل‌های موجود در ASCE، یوروکد و استانداردهای بریتانیا را برای استخراج رابطه‌های هدایت گرمایی، گرمای ویژه، تنش تسلیم، مدول الاستیسیته یا ضریب کاهش آن‌ها تحلیل کرد [۷۸]. این کار نشان می‌دهد که یادگیری ماشین می‌تواند داده‌های ناهمگون را یکپارچه کند؛ با این حال اختلاف در تعریف خواص، شیوه آزمون و مفروضات منابع به مدل منتقل می‌شود.

تفاوت آزمون دمای بالا در حالت پایا و گذرا اهمیت دارد. نرخ افزایش دما، نرخ کرنش، مدت مواجهه، مسیر سردشدن و وضعیت آزمایش بعد از آتش، رفتار را تغییر می‌دهد. بنابراین پیش‌بینی خواص حین آتش، پاسخ به گرم‌شدن گذرا و خواص باقی‌مانده پس از آتش سه وظیفه متمایزند. مدلی که یکی از این وظایف را انجام داده، خودبه‌خود برای دو وظیفه دیگر تأیید نشده است [۷۸، ۷۹].

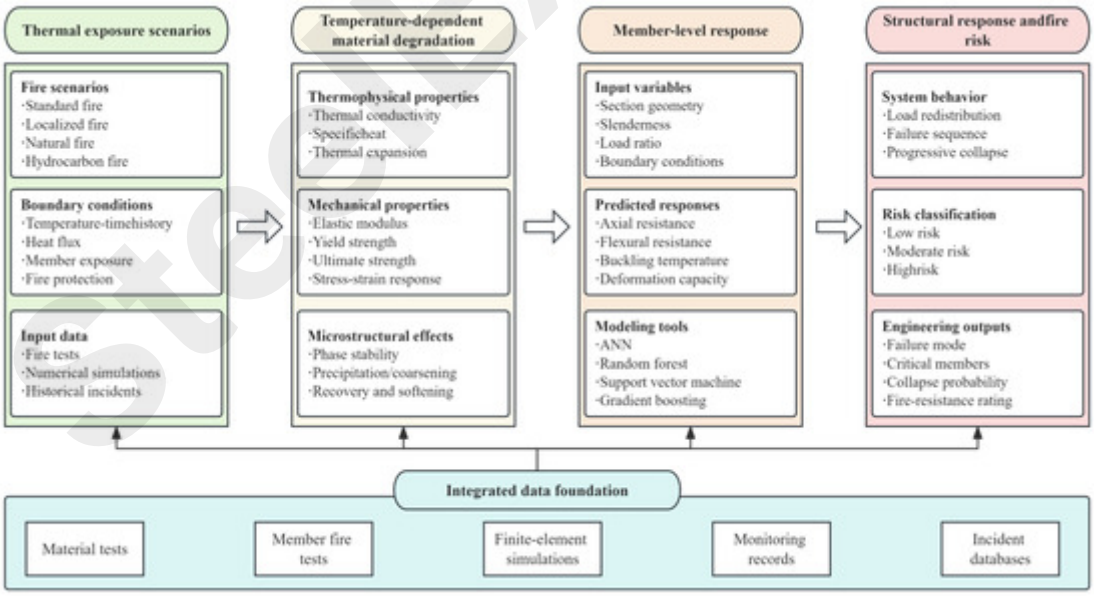
در یکی از مطالعات خواص دمای بالا، بیش از **۴۵۰ رکورد گسترش‌یافته** با متغیرهای دما و ضخامت ورق برای برآورد رفتار تنش–کرنش استفاده شدند. الگوریتم‌های گرادیان‌بوستینگ، جنگل تصادفی، XGBoost و SVR مقایسه شدند و برای مدل گرادیان‌بوستینگ، R^2 تعدیل‌شده بالاتر از ۰٫۹۸ گزارش شد [۷۹]. هرچند عملکرد در محدوده آزمون خوب بود، برون‌یابی به دماهای بالاتر یا شرایط حرارتی جدید همچنان نیازمند احتیاط است.

مدل‌های سریع در مقیاس عضو نیز توسعه یافته‌اند. برخی مطالعات با داده‌های تجربی و تحلیلی ستون فولادی، دما، نسبت لاغری، بار و هندسه را به مقاومت فشاری مرتبط کرده‌اند [۸۰]. در نمونه‌ای دیگر، **۲۱,۸۷۹ نمونه تحلیل هندسی و مادی غیرخطی با ناکاملی (GMNIA)** برای ایجاد مدل جانشین مقاومت در آتش

استفاده شدند و شبکه عصبی، جنگل تصادفی و ماشین بردار پشتیبان همراه با تحلیل SHAP مقایسه شدند [۸۱]. چنین مدل‌هایی می‌توانند محاسبات مکرر و پرهزینه را سریع کنند، ولی خطا و مفروضات تحلیل عددی مرجع را نیز به ارث می‌برند؛ تأیید مستقل با آزمایش عضو ضروری است.

در مقیاس سازه، Fu از شبیه‌سازی مونت‌کارلو و نمونه‌گیری تصادفی برای تولید سناریوهای آتش و حالت‌های بارگذاری استفاده کرد، سپس درخت تصمیم، kNN و شبکه عصبی را برای طبقه‌بندی شکست اعضای قاب فولادی مقایسه نمود. شکست‌های پیش‌بینی‌شده برای حذف عضو آسیب‌دیده از مدل سازه و ارزیابی احتمال خرابی پیشرونده به کار رفتند [۸۲]. این مسیر، انتقال نتیجه پیش‌بینی ماده و عضو به پیامد سیستمی را نشان می‌دهد، اما اعتبارسنجی آزمایشی تمام‌مقیاس هنوز محدود است.

در ارزیابی خطر آتش پل‌ها، داده‌های مربوط به **۱۱۸ پل** و ویژگی‌های سازه‌ای و آتش در مدل‌های RF، SVM و مدل افزایشی تعمیم‌یافته (GAM) استفاده شدند و دقت طبقه‌بندی حدود **۷۰٪** گزارش شد [۸۳]. ناهمگونی سوابق و شمار کم رخدادها محدودیت مهم این نتیجه است. نویسندگان همچنین به نیاز به مجموعه داده معیار و روش ارزیابی یکسان برای مقایسه مدل‌های این حوزه اشاره می‌کنند [۸۴]. روش‌های مولد مانند GAN و VAE ممکن است به افزایش داده کمک کنند [۸۵]، اما قادر نیستند از هیچ، سازوکار شکست ندیده‌شده در آزمایش یا شبیه‌سازی معتبر را خلق و تأیید کنند.



شکل ۱۰. چارچوب چندمقیاسی مبتنی بر یادگیری ماشین برای بررسی عملکرد فولاد سازه‌ای در آتش و دماهای بسیار بالا. منبع: Wei و همکاران، Materials، ۲۰۲۶، شکل ۱۰، مجوز CC BY 4.0.

شکل ۱۰ پیوند سناریوی آتش و تاریخچه دما با افت خواص گرمایی و مکانیکی، پایداری عضو، حالت‌های شکست و ارزیابی خطر را ترسیم می‌کند. داده در این سطوح از آزمایش ماده در دمای بالا، مدل اجزای محدود،

آزمون آتش عضو و سوابق رخدادها به دست می‌آید. *شکل ۱۱* پژوهش اصلی، روش رتبه‌بندی ریسک آتش پل‌ها [۸۳] را نشان می‌دهد، اما حقوق بازنشر تصویر اقتباسی روشن نیست و در نسخه فارسی تکثیر نشده است.

محدودیت مشترک مدل‌های این بخش، گسست میان مقیاس‌هاست: مدل ماده ممکن است گرادیان دمای عضو را نادیده بگیرد؛ مدل عضو ممکن است تقریباً فقط بر شبیه‌سازی تکیه کند؛ و مدل خطر سازه ممکن است اطلاعات دقیقی از گرید فولاد یا سامانه حفاظت در برابر آتش نداشته باشد. جهت منطقی توسعه، اتصال میدان دما، رفتار ساختاری ماده، شکست عضو و پاسخ سازه‌ای در یک چارچوب سلسله‌مراتبی همراه با انتشار عدم‌قطعیت بین سطوح است، نه ساخت مدل‌های جعبه‌سیاه مستقل برای هر مرحله.

جدول ۸. کاربردهای منتخب یادگیری ماشین در ارزیابی دمای بالا و عملکرد فولادهای سازه‌ای در آتش

مقیاس یا دامنه کاربرد	داده‌ها و متغیرها	مدل و اعتبارسنجی	یافته و محدودیت	منبع
ماده	داده‌های چندمنبعی دمای بالا؛ دما و پارامترهای ماده برای پیش‌بینی کاهش خواص حرارتی و مکانیکی	شبکه عصبی (ANN) همراه الگوریتم ژنتیک (GA)؛ مقایسه با آیین‌نامه و آزمایش	داده‌های ناهمگون ادغام شدند؛ اختلاف تعریف‌ها به محاسبات عضو منتقل شد	[78]
ماده	بیش از 450 رکورد توسعه‌یافته؛ دما و ضخامت ورق برای پیش‌بینی رفتار تنش–کرنش در دمای بالا	Gradient Boosting، RF، XGBoost و SVR؛ اعتبارسنجی آزمایشگاهی	Gradient Boosting به R^2 تعدیل‌شده بیش از 0.98 رسید؛ برون‌یابی خارج از دامنه دمای کالیبره‌شده نیازمند احتیاط است	[79]
عضو سازه‌ای	داده‌های آزمایشگاهی و تحلیلی ستون فولادی؛ دما، هندسه و بارگذاری برای پیش‌بینی مقاومت فشاری	شبکه عصبی ترکیبی؛ مقایسه با معادلات تحلیلی و آزمایش	چند متغیر وابسته را پوشش داد؛ پوشش داده‌های اولیه محدود بود	[80]
عضو سازه‌ای	21,879 نمونه GMNIA؛ هندسه مقطع، دما و لاغری برای پیش‌بینی مقاومت در آتش	شبکه عصبی، RF و SVM با تحلیل SHAP؛ مجموعه آزمون مستقل	مدل جانشین سریع مناسب است، اما سوگیری ناشی از شبیه‌سازی عددی رفع نشده	[81]
سامانه سازه‌ای	سناریوهای آتش تولیدشده با مونت‌کارلو؛ دما و بار برای پیش‌بینی خرابی عضو و فروریزش سازه	درخت تصمیم، KNN و ANN؛ اعتبارسنجی با مطالعات موردی عددی	خرابی عضو به پاسخ کل سامانه پیوند یافت؛ شواهد آزمایشگاهی تمام‌مقیاس محدود ماند	[82]
خطر زیرساخت	سوابق آتش‌سوزی 118 پل؛ ویژگی‌های سازه و آتش برای طبقه‌بندی خطر	SVM، RF و GAM؛ اعتبارسنجی متقاطع	دقت طبقه‌بندی حدود 70٪ بود؛ داده‌ها ناهمگون و محدود بودند	[83]
بنچمارک و افزایش داده	FireNet و داده‌های آزمون مصنوعی؛ ورودی‌های متنوع برای پیش‌بینی عملکرد در آتش	مدل‌های معیار، GAN و VAE؛ بنچمارک یکسان و اعتبارسنجی داخلی	مقایسه‌پذیری مدل‌ها بهتر شد؛ داده مصنوعی سازوکار خرابی مشاهده‌نشده را ایجاد نمی‌کند	[84,85]

۵.۳. خستگی، شکست و ارزیابی عمر باقی‌مانده

پیش‌بینی استحکام خستگی، ترسیم منحنی S–N، عمر کلی خستگی، خستگی کم‌چرخه، خستگی اتصال جوشی، خستگی–خوردگی، نرخ رشد ترک، آشکارسازی ترک و تخمین عمر باقی‌مانده، وظایفی متفاوت‌اند. ورودی، خروجی، مقیاس زمانی و معیار اعتبار هر یک باید مشخص باشد. پیش‌بینی منحنی تنش–عمر عموماً رابطه تنش و تعداد چرخه تا شکست را مدل می‌کند؛ در مقابل، مدل رشد ترک کمیتی مانند da/dN را برآورد می‌کند. سامانه بینایی یا آزمون غیرمخرب (NDE) آسیب موجود را می‌یابد و مدل عمر باقی‌مانده، افق شکست آینده را تخمین می‌زند. یکسان‌دانستن این وظایف و مقایسه آن‌ها با یک معیار خطای مشترک نادرست است.

مطالعات اولیه مبتنی بر داده‌های خستگی مؤسسه ملی علوم مواد ژاپن (NIMS) نشان دادند ترکیب شیمیایی و پارامترهای ساخت در پیش‌بینی استحکام خستگی و شناسایی عوامل اثرگذار مفیدند [۸۶، ۸۷]. Arvanitis و همکاران داده‌های NIMS را با آزمایش‌های تکمیلی ترکیب کردند و رگرسیون چندجمله‌ای، XGBoost، SVR و شبکه عصبی را برای پیش‌بینی عمر خستگی فولاد سازه‌ای مقایسه کردند. XGBoost کمترین خطای مربعی میانگین داشت، ولی رگرسیون چندجمله‌ای نیز با هزینه محاسباتی کمتر رقابت‌پذیر بود [۸۸]. پیچیده‌ترکردن مدل در مجموعه‌داده ساختارمند و متوسط لزوماً دقت مهندسی بالاتری ایجاد نمی‌کند.

نمونه‌های بدون شکست یا Run-out. اگر نمونه در تعداد چرخه تعیین‌شده همچنان سالم باشد، عمر شکست دقیق آن معلوم نشده است؛ این مشاهده از نظر آماری «سانسورشده از راست» است. کنارگذاشتن چنین نمونه‌هایی می‌تواند عمر خستگی در ناحیه چرخه‌های بالا را تحریف کند و ثبت تعداد چرخه آزمون به‌عنوان زمان شکست نیز توزیع عمر را به خطا می‌برد. مقالات یادگیری ماشین باید تعداد این نمونه‌ها و روش برخورد با سانسورشدگی را گزارش کنند؛ رگرسیون متناسب با داده سانسورشده یا مفاهیم تحلیل بقا در این موارد می‌تواند ضروری باشد.

اتصالات جوشی. هندسه گرده و پای جوش، شعاع پنجه، نوع و اندازه عیب، تنش پسماند، عملیات پس از جوش، ضخامت، نوع بارگذاری، نسبت تنش، تنش میانگین و طیف دامنه متغیر، بر عمر خستگی اثر می‌گذارند. Feng و همکاران پارامترهای فیزیکی پایگاه داده خستگی جوش را تبدیل کردند، با XGBoost وزن ویژگی‌ها را برآورد کردند و آن‌ها را در شبکه عصبی پیچشی عمیق برای پیش‌بینی منحنی S–N به کار بردند [۸۹]. Schubnell و همکاران نیز با یادگیری انتقالی از نمونه‌های غیرجوشی به اتصال جوشی، عملکرد مدل را با یادگیری ماشین متعارف و روش‌های مبتنی بر مکانیک شکست مقایسه کردند [۹۰]. چنین انتقالی تنها زمانی قابل اتکاست که دامنه مبدأ و مقصد از نظر متغیرهای فیزیکی مؤثر بر خستگی هم‌پوشانی معنادار داشته باشند.

در ارزیابی مهندسی باید مدل یادگیری ماشین نه فقط با مدل‌های رقیب، بلکه با مبناهای فیزیکی و طراحی شناخته‌شده مقایسه شود؛ برای مثال منحنی‌های S–N آیین‌نامه‌ای، روش‌های تنش و کرنش موضعی،

رابطه‌های تجربی خستگی، قانون پاریس و تحلیل عمر مبتنی بر مکانیک شکست. ارزش افزوده یادگیری ماشین باید در بهبود پیش‌بینی، دامنه قابل استفاده گسترده‌تر، کاهش هزینه آزمون یا به‌روزرسانی بهتر در مواجهه با بارگذاری جدید نشان داده شود.

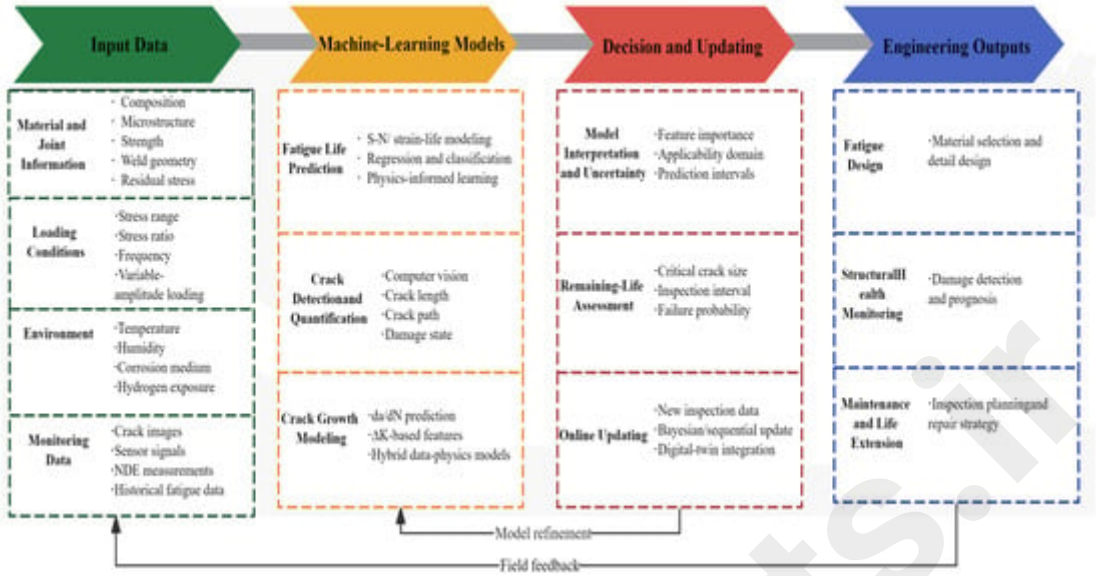
نمونه‌هایی از مدل‌سازی مقید به فیزیک در فولاد زنگ‌نزن 316 برای پیش‌بینی عمر خستگی کم‌چرخه نیز گزارش شده‌اند [۹۲]. این مورد نمونه انتقال روش است و نباید تغییرات چرخه‌ای، خزش–خستگی و اثر دمای آن مستقیماً به فولادهای سازه‌ای تعمیم داده شود؛ مزیت اصلی، نشان‌دادن امکان منظم‌کردن مدل با قیود فیزیکی است، مشروط بر آنکه قید برای ماده و بارگذاری مقصد از نو ساخته شود.

پیش‌بینی رشد ترک. Kamble و همکاران داده‌های نمونه فشرده کشش فولاد کربنی را برای مقایسه روش‌های رگرسیونی و نزدیک‌ترین همسایه در پیش‌بینی رشد ترک، از ناحیه پایدار تا رشد سریع، به کار بردند [۹۳]. این مدل‌ها می‌توانند فراتر از رابطه کلاسیک پاریس در محدوده رشد پایدار اطلاعات بدهند، اما استفاده مهندسی همچنان به تعریف بازه اندازه ترک، حالت بارگذاری، پارامترهای مکانیک شکست و آزمون بیرونی وابسته است.

پایش آسیب و بینایی ماشین. Long و همکاران با چارچوب Faster R-CNN سراسری–موضعی، از تصاویر حین بارگذاری چرخه‌ای برای تشخیص ترک‌های کوچک و برآورد طول و نرخ رشد آن‌ها استفاده کردند [۹۴]. Zhang و همکاران نیز مواد مکانولومینسانس، بینایی رایانه‌ای و یادگیری ماشین را برای پایش بلادرنگ ترک خستگی ترکیب کردند [۹۵]. این سامانه‌ها امکان تشخیص و سنجش کمی ترک سطحی را نشان می‌دهند، اما آشکارسازی ترک مساوی پیش‌بینی عمر نیست. روش نوری ممکن است شکل ترک درونی را نبیند؛ برای تکمیل وضعیت آسیب باید بنا بر نیاز از فراصوت، نشر آکوستیک، روش‌های مغناطیسی یا توموگرافی X-CT کمک گرفت.

در یکی از موارد انتقال روش، مدل‌های گرادیان‌بوستینگ همراه با SHAP برای مطالعه نرخ رشد ترک خستگی تحت اثر هیدروژن در فولاد Cr–Mo به کار رفته‌اند؛ دامنه ضریب شدت تنش، فشار هیدروژن، مقاومت ماده، نسبت تنش، فرکانس و ترکیب شیمیایی از متغیرهای بررسی‌شده هستند [۹۶]. اهمیت ویژگی‌ها در همان دامنه فشار، گرید و بارگذاری معتبر است و نباید رتبه‌بندی عمومی برای همه فولادهای سازه‌ای تلقی شود.

نکته اعتبارسنجی مهم دیگر، **نشت اطلاعات نمونه یا توالی** است. در آزمایش خستگی معمولاً از یک نمونه در چرخه‌های مختلف داده گرفته می‌شود یا تصاویر پیاپی از همان ترک ثبت می‌گردد. اگر اندازه‌گیری‌های وابسته به یک نمونه میان آموزش و آزمون پخش شوند، مدل ممکن است ویژگی نمونه و آزمون را به خاطر بسپارد. تمام رکوردها و تصاویر یک آزمون باید در یک بخش از تقسیم داده بمانند و آزمون واقعی تعمیم روی نمونه یا بارگذاری دیگری صورت گیرد.



شکل ۱۳. چارچوب یکپارچه یادگیری ماشین برای پیش‌بینی عمر خستگی، پایش رشد ترک و ارزیابی عمر باقی‌مانده فولادهای سازه‌ای. منبع: Wei و همکاران، ۲۰۲۶، Materials، شکل ۱۳، مجوز CC BY 4.0.

یادداشت شکل ۱۲: طرح کلی پیش‌بینی عمر خستگی مبتنی بر یادگیری ماشین [۸۸] در نسخه اصلی منتشر شده، ولی حق بازنشر طرح اقتباسی مستقل احراز نشده است.

جمع‌بندی این بخش آن است که کاربردهای یادگیری ماشین از رابطه‌های استحکام و عمر خستگی به تحلیل جوش، خستگی محیطی، رشد ترک، تشخیص آسیب و تخمین عمر باقی‌مانده گسترش یافته‌اند. مهم‌ترین مانع، فقط کاهش خطای پیش‌بینی نیست؛ بلکه اثبات این موضوع است که مدل در نمونه‌های ناشناخته، تاریخچه‌های بارگذاری جدید، محیط‌های متفاوت و وضعیت‌های آسیب دیده‌نشده برآوردی ایمن و قابل دفاع ارائه می‌کند. اتصال پایگاه‌های خستگی، متغیرهای مکانیک شکست، مشاهده‌های چندوجهی آزمون غیرمخرب و داده‌های پایش زمانی برای ساخت مدل عمر باقی‌مانده قابل به‌روزرسانی ضروری است.

جدول ۹. کاربردهای منتخب یادگیری ماشین در خستگی، شکست و عمر باقی‌مانده فولادهای سازه‌ای

وظیفه/دامنه	مشخصات داده	روش یادگیری ماشین	اعتبارسنجی و نحوه برخورد با داده	محدودیت اصلی	منبع
پیش‌بینی مقاومت خستگی	داده خستگی فولاد در NIMS؛ ترکیب و پارامترهای فرایند	رگرسیون و مدل‌های تجمیعی	اعتبارسنجی متقاطع؛ تعداد نمونه مستقل و نحوه برخورد با آزمون‌های بدون شکست گزارش نشده	کاربردپذیری به پوشش پایگاه داده محدود است	[86,87]
پیش‌بینی عمر کل خستگی	داده‌های NIMS و آزمون‌های خستگی تکمیلی	رگرسیون چندجمله‌ای، SVR، XGBoost و ANN	آزمون آموزش/آزمون؛ استقلال نمونه و برخورد با داده‌های سانسورشده کامل گزارش نشده	اعتبارسنجی بیرونی همچنان محدود است	[88]

وظیفه/دامنه	مشخصات داده	روش یادگیری ماشین	اعتبارسنجی و نحوه برخورد با داده	محدودیت اصلی	منبع
پیش‌بینی منحنی S–N اتصال جوشی	هندسه جوش، شرایط بارگذاری و توصیفگرهای فیزیکی	XGBoost و شبکه عمیق کانولوشنی (DCNN)	اعتبارسنجی متقاطع؛ عدم‌قطعیت صریحاً کمی‌سازی نشده	انتقال میان انواع اتصال و طیف بارگذاری محدود است	[89]
انتقال مدل خستگی اتصال جوشی	22 مجموعه داده اتصال جوشی از دامنه هدف	یادگیری انتقالی	اعتبارسنجی در دامنه هدف و مقایسه با مدل مرسوم	به شباهت دامنه مبدأ و مقصد وابسته است	[90]
عمر خستگی–خوردگی	داده چندمنبعی شامل نسبت تنش، فرکانس، دما و محیط	XGBoost و DCNN مبتنی بر توجه	آزمون میان شرایط؛ بازه‌های پیش‌بینی گزارش نشده	آزمون در بارگذاری واقعی با دامنه متغیر کافی نیست	[91]
خستگی کم‌چرخه؛ نمونه انتقال روش	فولاد زنگ‌نزن 316 در دماها و نرخ‌های کرنش مختلف	شبکه عصبی آگاه از فیزیک	ارزیابی در نوار خطای ضریب دو	قیود فیزیکی برای فولادهای سازه‌ای باید دوباره تدوین شود	[92]
پیش‌بینی رشد ترک خستگی	داده آزمون نمونه کامپکت کشش از فولاد کربنی؛ متغیرهای مکانیک شکست	رگرسیون و KNN	آزمون با داده آزمایشگاهی؛ عدم‌قطعیت گزارش نشده	برون‌یابی خارج از دامنه آزمون رشد ترک نامطمئن است	[93]
آشکارسازی و پایش ترک	توالی تصاویر زیر بارگذاری چرخه‌ای؛ طول و نرخ رشد ترک سطحی	Faster R-CNN و یادگیری ماشین بینایی‌محور	آزمون توالی آزمایشگاهی؛ استقلال نمونه‌ها باید حفظ شود	عمدتاً محدود به ترک‌های سطحی قابل رؤیت است	[94,95]
رشد ترک کمک‌گرفته از هیدروژن؛ مورد انتقال روش	فولاد Cr–Mo؛ فشار هیدروژن، بارگذاری و متغیرهای ماده	Gradient Boosting و SHAP	آزمون در محدوده ماده و بارگذاری مطالعه‌شده	نباید به فولادهای خارج از Cr–Mo و شرایط هیدروژن همین مطالعه تعمیم داد	[96]

NIMS: مؤسسه ملی علوم مواد ژاپن؛ SVR: رگرسیون بردار پشتیبان؛ ANN: شبکه عصبی مصنوعی؛ DCNN: شبکه عصبی عمیق کانولوشنی؛ KNN: نزدیک‌ترین همسایه‌ها؛ R-CNN: شبکه کانولوشنی ناحیه‌محور؛ SHAP: توضیح پیش‌بینی با مقادیر شاپلی. نبود اطلاعات درباره شمار نمونه مستقل، آزمون‌های بدون شکست و عدم‌قطعیت به‌صورت محدودیت گزارش شده است.

۶. چالش‌های کنونی و مسیرهای آینده

نتیجه مشترک مطالعات آن است که یادگیری ماشین از رگرسیون ترکیب–خواص به بهینه‌سازی فرایند، شناسایی ریزساختار، طراحی معکوس و مدیریت دوام و عمر خدمت رسیده است. با این حال، پرسش محوری دیگر فقط این نیست که آیا روی یک مجموعه‌داده می‌توان دقت بالایی به دست آورد یا خیر؛ پرسش اصلی آن

است که آیا مدل هنگام تغییر گرید، مسیر تولید، آزمایشگاه، کارخانه یا محیط بهره‌برداری همچنان معتبر می‌ماند. برای فولادهای سازه‌ای که خرابی آن‌ها پیامد ایمنی دارد، استقلال داده، سازگاری فیزیکی، عدم‌قطعیت کالیبره و عملکرد بیرون از دامنه آموزش، شواهد ضروری است.

۶.۱. چالش‌های فعلی

کیفیت و استقلال داده. ممکن است یک پایگاه صنعتی میلیون‌ها قرائت یا هزاران رکورد داشته باشد، اما شمار ذوب‌ها، نمونه‌ها، کارزارهای تولید، مکان‌های مواجهه یا آزمون‌های خستگی مستقل بسیار کمتر باشد. تقسیم تصادفی داده هنوز در بسیاری از مقالات رایج است و آزمون واقعی بین کارخانه‌ها، آزمایشگاه‌ها و شرایط میدانی به‌ندرت ارائه می‌شود. بنابراین دقت گزارش‌شده بیشتر بیانگر درون‌یابی در دامنه آشناست تا تضمین تعمیم مهندسی. کمبود داده در مواردی مانند شکست ترد، خوردگی موضعی شدید، آتش، خستگی–خوردگی، ترک ناشی از هیدروژن و پایش بلندمدت، حادتر است؛ درست همان حالت‌هایی که برای ایمنی اهمیت بیشتری دارند [۹۷، ۹۸].

فقدان فراداده قابل پیگیری. اگر شماره ذوب، شکل و ضخامت محصول، جهت و محل نمونه‌برداری، تاریخچه نورد و جوش، هندسه نمونه، استاندارد آزمایش، شرایط محیطی، سانسورشدگی داده و عدم‌قطعیت اندازه‌گیری ثبت نشود، ادغام داده‌ها از منابع مختلف می‌تواند نتیجه گمراه‌کننده تولید کند. داده باید قابل ردگیری باشد؛ ضروری است بتوان مشخص کرد هر مقدار از چه آزمایش، تجهیز، دوره تولید یا مقاله‌ای آمده و چه پاک‌سازی و تبدیلی روی آن انجام شده است [۹۹–۱۰۱].

پیوند ضعیف با فیزیک ماده. ترکیب شیمیایی و پارامتر تولید در محدوده گریدهای شناخته‌شده گاهی برای پیش‌بینی کافی‌اند، اما وضعیت ریزساختار، عیوب، تنش پسماند، ترک و آسیب محیطی را به‌طور یکتا توصیف نمی‌کنند. صرف افزودن لایه‌های شبکه عصبی این کمبود را برطرف نمی‌کند. لازم است دانش فیزیکی به‌صورت توصیفگر، رابطه بقایی، قید ترمودینامیکی، مدل سینتیکی یا ترکیب شبیه‌سازی و داده در مدل وارد شود و اثر واقعی آن در اعتبارسنجی بیرونی سنجیده شود [۱۰۲–۱۰۶].

عدم‌قطعیت و خطاهای ناایمن. گزارش R^2 یا RMSE متوسط کافی نیست. باید مشخص باشد مدل در ناحیه‌های کم‌داده، گریدهای ناشناخته، بارگذاری‌های حدی و حالت‌هایی که شکست زودرس محتمل است، چه می‌کند. بازه پیش‌بینی، کالیبراسیون آن، تشخیص داده خارج از توزیع (Out of Distribution یا OOD)، سهم پیش‌بینی‌های غیرمحافظه‌کارانه و سازوکار توقف یا ارجاع به روش مهندسی معتبر باید جزو ارزیابی باشد. مدل دارای دقت آماری بالا می‌تواند در پیش‌بینی عمر خستگی بیش‌برآوردی خطرناک داشته باشد.

گسست بین توسعه مدل و بهره‌برداری صنعتی. مدل آزمایشگاهی یا مقاله‌ای معمولاً پیش‌فرض‌هایی درباره

کیفیت حسگر، یکسانی فرایند و ثبات شرایط دارد که در کارخانه یا سازه در حال خدمت برقرار نمی‌ماند. رانش حسگر، تغییر تأمین‌کننده، تعمیرات، تغییر کنترل‌کننده، کالیبراسیون مجدد و فرسودگی تجهیز، رفتار داده را تغییر می‌دهند. نگهداری نسخه مدل، ثبت تصمیم‌ها، مسئولیت تأیید و به‌روزرسانی، امنیت سایبری داده صنعتی، سازگاری با استانداردهای مواد و سازه و قواعد بازگشت محافظه‌کارانه باید بخشی از اعتمادپذیری مدل باشند، نه کاری که صرفاً پس از تولید نرم‌افزار به آن فکر شود.

۶.۲. مسیرهای پژوهشی آینده

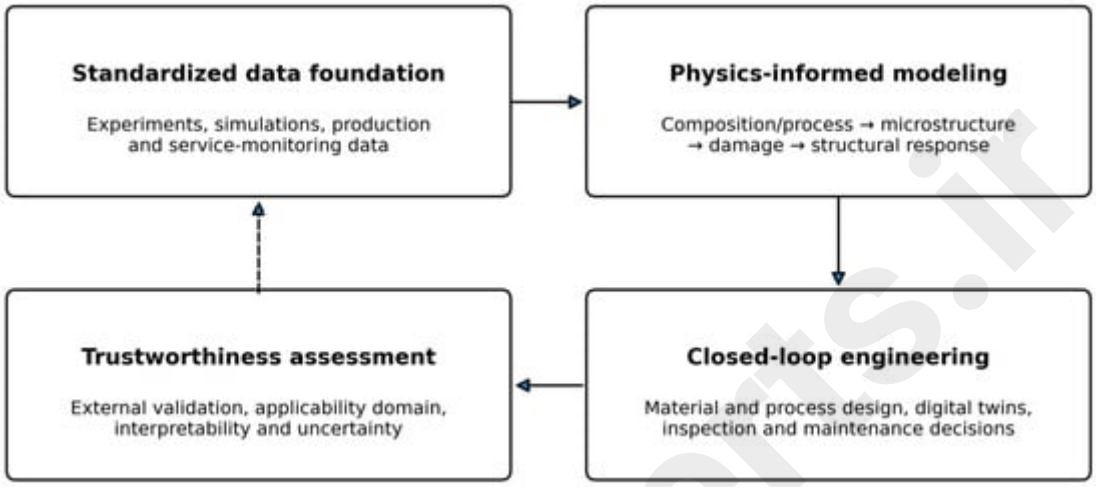
گام نزدیک: استانداردکردن داده و اعتبارسنجی. مجموعه‌داده‌های فولاد سازه‌ای باید شماره ذوب، گرید، محصول، ضخامت، محل و راستای نمونه‌برداری، تاریخچه تولید و جوشکاری، هندسه نمونه، استاندارد آزمون، شرایط محیطی، داده‌های سانسورشده، خطای اندازه‌گیری و سابقه پاک‌سازی داده را حفظ کنند. شمار رکورد خام باید از شمار واحدهای مستقل ماده متمایز گزارش شود. اعتبارسنجی از تقسیم تصادفی به تقسیم گروهی برحسب ذوب، نمونه، منبع، سایت و دوره تولید حرکت کند و در صورت امکان آزمایشگاه و تولیدکننده دیگری نیز مدل را آزمایش کند.

گام میانی: مدل‌های آگاه از فیزیک و عدم‌قطعیت. پیوند مدل‌های ترمودینامیکی، سینتیکی و مکانیک شکست با یادگیری داده‌محور، استفاده از داده با سطوح مختلف دقت (Multi-Fidelity)، یادگیری انتقالی و یادگیری فعال می‌تواند نیاز به آزمایش‌های گران را کمتر کند. اما مزیت هر روش باید با داده بیرونی و نامزدهای واقعاً ساخته‌شده نشان داده شود. بهینه‌سازی ترکیب و فرایند باید محدودیت جوش‌پذیری، قابلیت ساخت، هزینه، الزامات استاندارد و احتمال خروج از دامنه معتبر مدل را رعایت کند.

گام بلندمدت: دوقلوهای دیجیتال عملیاتی. دوقلوی دیجیتال مفید صرفاً شبیه‌سازی سه‌بعدی یا نمودار وضعیت نیست؛ باید وضعیت واقعی ماده و عضو را با داده حسگر، آزمون غیرمخرب، بازرسی و مدل فیزیکی به‌روز کند. متغیرهای حالت می‌توانند ریزساختار، تنش پسماند، اتلاف ضخامت، عمق حفره خوردگی، اندازه ترک و آسیب خستگی تجمعی باشند. دما، کرنش، داده خوردگی، سیگنال فراصوت یا نشر آکوستیک نیز مشاهدات ورودی‌اند. لازم است تعیین شود مدل چه زمان به‌روز می‌شود، چگونه پس از هر بازرسی دوباره کالیبره می‌شود، عدم‌قطعیت چگونه به برآورد عمر منتقل می‌گردد و کدام تصمیم را پشتیبانی می‌کند: ادامه بهره‌برداری، بازرسی، تعمیر یا تعویض [۱۱۰].

برای مدیریت خطر هوش مصنوعی، اصول چارچوب NIST AI RMF [۱۱۱] به کنترل‌های مشخص مهندسی مواد تبدیل می‌شوند: «حاکمیت» یعنی مالکیت مدل، نسخه‌بندی و ممیزی؛ «شناخت موقعیت» یعنی تعریف گرید، فرایند، محیط و پیامد شکست؛ «اندازه‌گیری» یعنی اعتبارسنجی مستقل، کالیبراسیون، تعیین دامنه اعتبار و

بررسی خطاهای غیرمحافظه‌کارانه؛ و «مدیریت» یعنی به‌روزرسانی، تشخیص شرایط خارج از دامنه، بازگشت به روش محافظه‌کارانه و از رده خارج کردن مدل. پذیرش مقرراتی نیز باید با قواعد موجود تأیید ماده و طراحی سازه پیوند داشته باشد، نه جایگزین یک استاندارد پذیرفته‌شده با مدلی عمومی شود.



شکل ۱۴. نقشه راه یادگیری ماشین اعتمادپذیر در طراحی، ساخت و مدیریت فولادهای سازه‌ای در دوره خدمت. منبع: Wei و همکاران، Materials، ۲۰۲۶، شکل ۱۴، مجوز CC BY 4.0.

مسیر پیشرفت از داده‌های استاندارد و آزمون بیرونی در کوتاه‌مدت به مدل‌های فیزیک‌محور و دارای عدم‌قطعیت و آزمایش آینده‌نگر در میان‌مدت، و سپس به طراحی حلقه‌بسته مواد، دوقلوهای دیجیتال عملیاتی و حاکمیت مدل سازگار با آیین‌نامه در بلندمدت می‌رسد. ملاک اصلی پیشرفت باید از «دقت روی یک مجموعه داده» به «کاهش واقعی عدم‌قطعیت، کاهش هزینه آزمایش، کاستن از برآوردهای ناایمن و بهبود تصمیم‌های چرخه عمر» تغییر کند.

جدول ۱۰. شکاف‌های پژوهشی اولویت‌دار و میزان آمادگی یادگیری ماشین برای فولادهای سازه‌ای

شکاف پژوهشی	اقدام اولویت‌دار	افق زمانی	میزان آمادگی فعلی	مبنای شواهد
داده‌های ناهمگون	استانداردسازی فراداده و ردیابی منشأ	کوتاه‌مدت	در حال توسعه	ناسازگاری مجموعه‌داده‌ها
تعمیم‌پذیری محدود	اعتبارسنجی گروه‌بندی‌شده و بیرونی	کوتاه‌مدت	در حال توسعه	غلبه اعتبارسنجی داخلی
عدم‌قطعیت / خارج از دامنه آموزش (OOD)	بازه‌های کالیبره و تشخیص OOD	کوتاه‌مدت تا میان‌مدت	ابتدایی	گزارش محدود عدم‌قطعیت
سازگاری فیزیکی	مدل‌های آگاه از فیزیک و چندسطح اعتبار	میان‌مدت	در حال توسعه	ادغام فیزیک در محدوده محدود

شکاف پژوهشی	اقدام اولویت‌دار	افق زمانی	میزان آمادگی فعلی	مبنای شواهد
هزینه آزمایش	یادگیری فعال و یادگیری انتقالی	میان‌مدت	ابتدایی تا در حال توسعه	مجموعه‌داده‌های کوچک و پرهزینه
طراحی معکوس	اعتبارسنجی آینده‌نگر مواد نامزد	میان‌مدت	ابتدایی	شواهد آزمایشگاهی محدود
ارزیابی پویای عمر	دوقلوهای دیجیتال عملیاتی	بلندمدت	ابتدایی	به‌روزرسانی ضعیف میان مقیاس‌ها
استقرار مهندسی	حاکمیت مدل و اتصال به آیین‌نامه‌ها	بلندمدت	ابتدایی	شواهد اندک استقرار

۷. نتیجه‌گیری

این مرور نشان می‌دهد یادگیری ماشین به ابزاری مکمل و ارزشمند در پژوهش فولادهای سازه‌ای تبدیل شده است؛ از مدل‌سازی ترکیب و فرایند و ریزساختار تا پیش‌بینی خواص، طراحی معکوس و ارزیابی دوام. مدل‌های درخت‌مبنا در داده‌های جدولی کوچک و متوسط اغلب نتایج خوبی دارند و شبکه‌های عمیق برای تصاویر و توالی‌های زمانی رایج‌تر شده‌اند، اما هیچ خانواده الگوریتمی برای همه مسائل فولاد سازه‌ای برتر نیست. نمایندگی داده، نحوه تعریف ویژگی‌ها و روش اعتبارسنجی بر نتیجه اثر اساسی دارند.

بلوغ شواهد در حوزه‌های مختلف یکسان نیست. پیش‌بینی ترکیب، فرایند و خواص مکانیکی نسبتاً پیشرفته‌تر است و برخی مطالعه‌ها به ساخت و آزمایش ترکیب‌های جدید یا آزمون نمونه‌های تولیدی ندیده‌شده رسیده‌اند. در مقابل، بخش بزرگی از مدل‌های خوردگی، آتش، خستگی، رشد ترک و عمر باقی‌مانده هنوز بر داده‌های داخلی، نمونه‌های آزمایشگاهی، مقالات پیشین یا شبیه‌سازی متکی است. آزمون مستقل بین کارخانه‌ها، آزمایشگاه‌ها، خط‌های تولید و در مقیاس میدانی همچنان کم‌تعداد است.

نقطه ضعف پایدار این حوزه بیشتر به **قدرت شواهد پشتیبان** مربوط می‌شود تا امکان دستیابی به دقت زیاد. رکوردهای متعدد لزوماً ذوب‌ها یا نمونه‌های مستقل متعدد نیستند؛ اعتبارسنجی تصادفی ممکن است این تفاوت را پنهان کند. در کاربرد حساس به ایمنی، مدل باید با اعتبارسنجی بیرونی، عدم‌قطعیت کالیبره، کنترل محدوده اعتبار، مبنای فیزیکی روشن و اندازه‌گیری خطای غیرمحافظه‌کارانه سنجیده شود، نه فقط با RMSE، R^2 یا دقت طبقه‌بندی.

این مرور نیز محدودیت‌هایی دارد: سوگیری انتشار و انتخاب منابع، ناهمگونی هدف‌ها و شاخص‌ها، و گزارش ناقص تعداد نمونه‌های مستقل و شرایط آزمون یا عدم‌قطعیت در بسیاری از منابع. همچنین بعضی مطالعات روی فولادهای مجاور یا نمونه‌های انتقال روش انجام شده‌اند؛ این موارد نشان‌دهنده ظرفیت یک روش هستند

و به معنای آمادگی تأییدشده برای فولادهای سازه‌ای متعارف نیستند. مسیر استقرار فراگیر، حرکت از «برازش موفق روی داده موجود» به مدل‌هایی است که در شرایط تازه، از نظر فیزیکی قابل دفاع، آگاه از عدم‌قطعیت و مستقل از داده آموزش اعتبارسنجی شده‌اند.

مشخصات مقاله اصلی و حقوق انتشار

عنوان اصلی: Machine Learning for Structural Steels: Materials Design, Property Prediction, Durability, and Future Directions

نویسندگان: Asmawan Mohd Sarman و Guomin Wei، Minghe Li، Bo Cui، Wencui Xiu.

نشریه و مشخصات: Materials, 2026, 19(17), 3612؛ تاریخ انتشار: ۲۵ اوت ۲۰۲۶؛ DOI: 10.3390/ma19173612.

نوع محتوا: ترجمه و بازپرداخت فارسی با ذکر منبع. متن اصلی و شکل‌های دارای مجوز، تحت Creative Commons Attribution 4.0 منتشر شده‌اند. شکل‌های اقتباسی با وضعیت نامشخص بازنشر نشده‌اند. تصاویر اصلیِ بازنشرشده بدون تغییر تصویری، با عنوان فارسی و ذکر صاحب اثر درج می‌شوند.

نسخه اصلی: صفحه مقاله نزد ناشر.

منابع علمی

فهرست کامل ۱۱۱ منبع کتاب‌شناختی مقاله با مشخصات لاتین اصلی حفظ شده است.

1. Hkdh, B. Neural networks in materials science. ISIJ Int. **1999**, 39, 966–979. [[Google Scholar] [CrossRef] [Scilit
2. Müller, M.; Stiefel, M.; Bachmann, B.I.; Britz, D.; Mücklich, F. Overview: Machine Learning for Segmentation and Classification of Complex Steel Microstructures. [Metals **2024**, 14, 553. [Google Scholar] [CrossRef] [Scilit
3. Miao, B.; Lin, G.Q.; Zhang, Y.; Cheng, Y.W.; Yang, H. Machine learning applications in metallic materials: Recent advances and future perspectives. J. Alloys Compd. [**2026**, 1062, 187486. [Google Scholar] [CrossRef] [Scilit

4. Hart, G.L.; Mueller, T.; Toher, C.; Curtarolo, S. Machine learning for alloys. Nat. Rev. [Mater. **2021**, 6, 730–755. [Google Scholar] [CrossRef] [Scilit

5. Hu, M.; Tan, Q.; Knibbe, R.; Xu, M.; Jiang, B.; Wang, S.; Li, X.; Zhang, M.X. Recent applications of machine learning in alloy design: A review. Mater. Sci. Eng. R Rep. [**2023**, 155, 100746. [Google Scholar] [CrossRef] [Scilit

6. Pourrahimi, S.; Hakimian, S. Machine Learning for Alloy Design: A Property- [Oriented Review. Alloys **2026**, 5, 7. [Google Scholar] [CrossRef] [Scilit

7. Butler, K.T.; Davies, D.W.; Cartwright, H.; Isayev, O.; Walsh, A. Machine learning for molecular and materials science. Nature **2018**, 559, 547–555. [Google Scholar] [[CrossRef] [Scilit] [PubMed

8. Ramprasad, R.; Batra, R.; Pilania, G.; Mannodi-Kanakkithodi, A.; Kim, C. Machine learning in materials informatics: Recent applications and prospects. npj Comput. [Mater. **2017**, 3, 54. [Google Scholar] [CrossRef] [Scilit

9. Schmidt, J.; Marques, M.R.; Botti, S.; Marques, M.A. Recent advances and applications of machine learning in solid-state materials science. npj Comput. [Mater. **2019**, 5, 83. [Google Scholar] [CrossRef] [Scilit

10. Jha, D.; Ward, L.; Paul, A.; Liao, W.K.; Choudhary, A.; Wolverton, C.; Agrawal, A. Elemnet: Deep learning the chemistry of materials from only elemental composition. Sci. Rep. **2018**, 8, 17593. [Google Scholar] [CrossRef] [Scilit] [[PubMed

11. Xie, T.; Grossman, J.C. Crystal graph convolutional neural networks for an accurate and interpretable prediction of material properties. Phys. Rev. Lett. **2018**, 120, [145301. [Google Scholar] [CrossRef] [Scilit] [PubMed

12. Choudhary, K.; DeCost, B.; Chen, C.; Jain, A.; Tavazza, F.; Cohn, R.; Park, C.W.; Choudhary, A.; Agrawal, A.; Billinge, S.J.L.; et al. Recent advances and applications of deep learning methods in materials science. npj Comput. Mater. **2022**, 8, 59. [[Google Scholar] [CrossRef] [Scilit

13. Lian, G.; Liu, X.; Wang, Q.; Shen, C.; Wang, Y.; Mu, W. Artificial intelligence-assisted

non-metallic inclusion particle analysis in advanced steels using machine learning: A review. Int. J. Miner. Metall. Mater. **2026**, 33, 401–416. [Google Scholar] [[CrossRef] [Scilit

14. Voulgaris, S.; Chandrinos, S.; Chamatidis, I.; Kazakis, G.; Tsakalis, P.; Mitropoulou, C.C.; Georgantzinos, S.K.; Istrati, D.; Lagaros, N.D. Machine learning and data-driven methods for steel constitutive modeling: A state-of-the-art review and [validation. Discov. Civ. Eng. **2025**, 2, 228. [Google Scholar] [CrossRef] [Scilit

15. Wang, H.; Li, B.; Gong, J.; Xuan, F.Z. Machine learning-based fatigue life prediction of metal materials: Perspectives of physics-informed and data-driven hybrid [methods. Eng. Fract. Mech. **2023**, 284, 109242. [Google Scholar] [CrossRef] [Scilit

16. Hamada, A.; Elyamny, S.; Abd-Elaziem, W.; Elkatatny, S.; Darwish, M.A.; Sebaey, T.A.; Järvenpää, A.; Vineesh, K.; Elsheikh, A.H. Advancing fatigue life prediction with machine learning: A review. Mater. Today Commun. **2025**, 43, 111525. [Google [Scholar] [CrossRef] [Scilit

17. Stergiou, K.; Ntakolia, C.; Varytis, P.; Koumoulos, E.; Karlsson, P.; Moustakidis, S. Enhancing property prediction and process optimization in building materials through machine learning: A review. Comput. Mater. Sci. **2023**, 220, 112031. [[Google Scholar] [CrossRef] [Scilit

18. Sarfarazi, S.; Mascolo, I.; Modano, M.; Guarracino, F. Application of artificial intelligence to support design and analysis of steel structures. Metals **2025**, 15, [408. [Google Scholar] [CrossRef] [Scilit

19. Fang, W.; Huang, J.X.; Peng, T.X.; Long, Y.; Yin, F.X. Machine learning-based performance predictions for steels considering manufacturing process parameters: A review. J. Iron Steel Res. Int. **2024**, 31, 1555–1581. [Google Scholar] [CrossRef] [[Scilit

20. Geng, X.; Wang, F.; Wu, H.H.; Wang, S.; Wu, G.; Gao, J.; Zhao, H.; Zhang, C.; Mao, X. Data-driven and artificial intelligence accelerated steel material research and intelligent manufacturing technology. Mater. Genome Eng. Adv. **2023**, 1, e10.

[[Google Scholar] [CrossRef] [Scilit

.21 Zhang, R.; Yang, J. State of the art in applications of machine learning in steelmaking process modeling. Int. J. Miner. Metall. Mater. **2023**, 30, 2055–2075. [[Google Scholar] [CrossRef] [Scilit

.22 Tsutsui, K.; Namba, T.; Kihara, K.; Hirata, J.; Matsuo, S.; Ito, K. Current trends on deep learning techniques applied in iron and steel making field: A review. ISIJ Int. [**2024**, 64, 1619–1640. [Google Scholar] [CrossRef] [Scilit

.23 Iren, D.; Ackermann, M.; Gorfer, J.; Pujar, G.; Wesselmecking, S.; Krupp, U.; Bromuri, S. Aachen-Heerlen annotated steel microstructure dataset. Sci. Data **2021**, 8, 140. [[Google Scholar] [CrossRef] [Scilit] [PubMed

.24 DeCost, B.L.; Hecht, M.D.; Francis, T.; Webler, B.A.; Picard, Y.N.; Holm, E.A. UHCSDB: Ultrahigh carbon steel micrograph database: Tools for exploring large heterogeneous microstructure datasets. Integr. Mater. Manuf. Innov. **2017**, 6, [197–205. [Google Scholar

.25 Lee, G.; Yi, G.H.; Tiong, L.C.O.; Sohn, S.S.; Kim, D. Internal defect database of mechanically deformed ferritic steel via X-ray computed tomography. Sci. Data [**2025**, 12, 1871. [Google Scholar] [CrossRef] [Scilit] [PubMed

.26 DeCost, B.L.; Holm, E.A. A computer vision approach for automated analysis and classification of microstructural image data. Comput. Mater. Sci. **2015**, 110, [126–133. [Google Scholar] [CrossRef] [Scilit

.27 Bostanabad, R.; Zhang, Y.; Li, X.; Kearney, T.; Brinson, L.C.; Apley, D.W.; Liu, W.K.; Chen, W. Computational microstructure characterization and reconstruction: Review of the state-of-the-art techniques. Prog. Mater. Sci. **2018**, 95, 1–41. [[Google Scholar] [CrossRef] [Scilit

.28 Jha, D.; Choudhary, K.; Tavazza, F.; Liao, W.K.; Choudhary, A.; Campbell, C.; Agrawal, A. Enhancing materials property prediction by leveraging computational and experimental data using deep transfer learning. Nat. Commun. **2019**, 10, 5316. [[Google Scholar] [CrossRef] [Scilit] [PubMed

.29 Wilkinson, M.D.; Dumontier, M.; Aalbersberg, I.J.; Appleton, G.; Axton, M.; Baak, A.; Blomberg, N.; Boiten, J.W.; da Silva Santos, L.B.; Bourne, P.E.; et al. The FAIR Guiding Principles for scientific data management and stewardship. Sci. Data **2016**, [3, 160018. [Google Scholar] [CrossRef] [Scilit] [PubMed

.30 Soedarmadji, E.; Stein, H.S.; Suram, S.K.; Guevarra, D.; Gregoire, J.M. Tracking materials science data lineage to manage millions of materials experiments and [analyses. npj Comput. Mater. **2019**, 5, 79. [Google Scholar] [CrossRef] [Scilit

.31 Ma, Y.; Xu, P.; Li, M.; Ji, X.; Zhao, W.; Lu, W. The mastery of details in the workflow of materials machine learning. npj Comput. Mater. **2024**, 10, 141. [Google Scholar] [[CrossRef] [Scilit

.32 Ward, L.; Agrawal, A.; Choudhary, A.; Wolverton, C. A general-purpose machine learning framework for predicting properties of inorganic materials. npj Comput. [Mater. **2016**, 2, 16028. [Google Scholar] [CrossRef] [Scilit

.33 Ward, L.; Dunn, A.; Faghaninia, A.; Zimmermann, N.E.; Bajaj, S.; Wang, Q.; Montoya, J.; Chen, J.; Bystrom, K.; Dylla, M.; et al. Matminer: An open source toolkit for materials data mining. Comput. Mater. Sci. **2018**, 152, 60–69. [Google Scholar] [[CrossRef] [Scilit

.34 Xu, P.; Ji, X.; Li, M.; Lu, W. Small data machine learning in materials science. npj [Comput. Mater. **2023**, 9, 42. [Google Scholar] [CrossRef] [Scilit

.35 Dunn, A.; Wang, Q.; Ganose, A.; Dopp, D.; Jain, A. Benchmarking materials property prediction methods: The Matbench test set and Automatminer reference algorithm. [npj Comput. Mater. **2020**, 6, 138. [Google Scholar] [CrossRef] [Scilit

.36 Sutton, C.; Boley, M.; Ghiringhelli, L.M.; Rupp, M.; Vreeken, J.; Scheffler, M. Identifying domains of applicability of machine learning models for materials science. Nat. Commun. **2020**, 11, 4428. [Google Scholar] [CrossRef] [Scilit] [[PubMed

.37 Li, K.; DeCost, B.; Choudhary, K.; Greenwood, M.; Hattrick-Simpers, J. A critical examination of robustness and generalizability of machine learning prediction of

materials properties. npj Comput. Mater. **2023**, 9, 55. [Google Scholar] [CrossRef] [[Scilit

.38 Tavazza, F.; DeCost, B.; Choudhary, K. Uncertainty prediction for machine learning models of material properties. ACS Omega **2021**, 6, 32431–32440. [Google [Scholar] [CrossRef] [Scilit] [PubMed

.39 Zhong, X.; Gallagher, B.; Liu, S.; Kailkhura, B.; Hiszpanski, A.; Han, T.Y.J. Explainable machine learning in materials science. npj Comput. Mater. **2022**, 8, 204. [Google [Scholar] [CrossRef] [Scilit

.40 Shen, C.; Wang, C.; Wei, X.; Li, Y.; van der Zwaag, S.; Xu, W. Physical metallurgy-guided machine learning and artificial intelligent design of ultrahigh-strength stainless steel. Acta Mater. **2019**, 179, 201–214. [Google Scholar] [CrossRef] [[Scilit

.41 Huang, X.; Wang, H.; Xue, W.; Ullah, A.; Xiang, S.; Huang, H.; Meng, L.; Ma, G.; Zhang, G. A combined machine learning model for the prediction of time-temperature-transformation diagrams of high-alloy steels. J. Alloys Compd. **2020**, [823, 153694. [Google Scholar] [CrossRef] [Scilit

.42 Geng, X.; Mao, X.; Wu, H.H.; Wang, S.; Xue, W.; Zhang, G.; Ullah, A.; Wang, H. A hybrid machine learning model for predicting continuous cooling transformation diagrams in welding heat-affected zone of low alloy steels. J. Mater. Sci. Technol. [**2022**, 107, 207–215. [Google Scholar] [CrossRef] [Scilit

.43 Geng, X.; Wang, S.; Ullah, A.; Wu, G.; Wang, H. Prediction of hardenability curves for non-boron steels via a combined machine learning model. Materials **2022**, 15, [3127. [Google Scholar] [CrossRef] [Scilit] [PubMed

.44 Geng, X.; Cheng, Z.; Wang, S.; Peng, C.; Ullah, A.; Wang, H.; Wu, G. A data-driven machine learning approach to predict the hardenability curve of boron steels and assist alloy design. J. Mater. Sci. **2022**, 57, 10755–10768. [Google Scholar] [[CrossRef] [Scilit

.45 Cao, Y.; Zhang, C.; Tang, S.; Wu, S.; Zhou, X.; Cao, G.; Luo, D.; Wang, H.; Hedström,

P.; Liu, Z. Machine learning to predict phase transformation products and their morphologies–application in design of lean high strength steel. Mater. Des. **2025**, [258, 114642. [Google Scholar] [CrossRef] [Scilit

46. Azimi, S.M.; Britz, D.; Engstler, M.; Fritz, M.; Mücklich, F. Advanced steel microstructural classification by deep learning methods. Sci. Rep. **2018**, 8, 2128. [[Google Scholar] [CrossRef] [Scilit] [PubMed

47. Shen, C.; Wang, C.; Huang, M.; Xu, N.; van der Zwaag, S.; Xu, W. A generic high-throughput microstructure classification and quantification method for regular SEM images of complex steel microstructures combining EBSD labeling and deep learning. J. Mater. Sci. Technol. **2021**, 93, 191–204. [Google Scholar] [CrossRef] [[Scilit

48. Stuckner, J.; Harder, B.; Smith, T.M. Microstructure segmentation with deep learning encoders pre-trained on a large microscopy dataset. npj Comput. Mater. [**2022**, 8, 200. [Google Scholar] [CrossRef] [Scilit

49. Liu, J.; Cao, G.; Wang, H.; Cui, C.; Liu, Z. Development of intelligent methodologies perceiving microstructure and mechanical properties of hot rolled steels. [Measurement **2023**, 221, 113526. [Google Scholar] [CrossRef] [Scilit

50. Guo, S.; Yu, J.; Liu, X.; Wang, C.; Jiang, Q. A predicting model for properties of steel using the industrial big data based on machine learning. Comput. Mater. Sci. **2019**, [160, 95–104. [Google Scholar] [CrossRef] [Scilit

51. Jiang, X.; Jia, B.; Zhang, G.; Zhang, C.; Wang, X.; Zhang, R.; Yin, H.; Qu, X.; Song, Y.; Su, L.; et al. A strategy combining machine learning and multiscale calculation to predict tensile strength for pearlitic steel wires with industrial data. Scr. Mater. [**2020**, 186, 272–277. [Google Scholar] [CrossRef] [Scilit

52. Cui, C.; Cao, G.; Cao, Y.; Liu, J.; Dong, Z.; Wu, S.; Liu, Z. Physical metallurgy guided deep learning for yield strength of hot-rolled steel based on the small labeled [dataset. Mater. Des. **2022**, 223, 111269. [Google Scholar] [CrossRef] [Scilit

53. Wu, S.W.; Yang, J.; Cao, G.M. Prediction of the Charpy V-notch impact energy of

low carbon steel using a shallow neural network and deep learning. Int. J. Miner. [Metall. Mater. **2021**, 28, 1309–1320. [Google Scholar] [CrossRef] [Scilit

.54 Shang, C.; Wang, C.; Wu, H.; Liu, W.; Chen, Y.; Pan, G.; Wang, S.; Wu, G.; Gao, J.; Zhao, H.; et al. Improved data-driven performance of Charpy impact toughness via literature-assisted production data in pipeline steel. Sci. China Technol. Sci. **2023**, [66, 2069–2079. [Google Scholar] [CrossRef] [Scilit

.55 Shaheen, M.A.; Presswood, R.; Afshan, S. Application of Machine Learning to predict the mechanical properties of high strength steel at elevated temperatures based on the chemical composition. In Structures; Elsevier: Amsterdam, The [Netherlands, 2023; Volume 52, pp. 17–29. [Google Scholar

.56 Peng, J.; Yamamoto, Y.; Hawk, J.A.; Lara-Curzio, E.; Shin, D. Coupling physics in machine learning to predict properties of high-temperatures alloys. npj Comput. [Mater. **2020**, 6, 141. [Google Scholar] [CrossRef] [Scilit

.57 Diao, Y.; Yan, L.; Gao, K. A strategy assisted machine learning to process multi-objective optimization for improving mechanical properties of carbon steels. J. [Mater. Sci. Technol. **2022**, 109, 86–93. [Google Scholar] [CrossRef] [Scilit

.58 Lee, J.Y.; Kim, M.; Lee, Y.K. Design of high strength medium-Mn steel using machine learning. Mater. Sci. Eng. A **2022**, 843, 143148. [Google Scholar] [[CrossRef] [Scilit

.59 Lee, J.Y.; Kim, S.H.; Jeong, H.B.; Lee, K.; Cho, K.; Lee, Y.K. Inverse design of high-strength medium-Mn steel using a machine learning–aided genetic algorithm approach. J. Mater. Res. Technol. **2024**, 33, 2672–2682. [Google Scholar] [[CrossRef] [Scilit

.60 Wang, Z.L.; Adachi, Y. Property prediction and properties-to-microstructure inverse analysis of steels by a machine-learning approach. Mater. Sci. Eng. A **2019**, 744, [661–670. [Google Scholar] [CrossRef] [Scilit

.61 Pei, Z.; Rozman, K.A.; Doğan, Ö.N.; Wen, Y.; Gao, N.; Holm, E.A.; Hawk, J.A.; Alman, D.E.; Gao, M.C. Machine-learning microstructure for inverse material design. Adv.

[Sci. **2021**, 8, 2101207. [Google Scholar] [CrossRef] [Scilit] [PubMed

.62 Kusampudi, N.; Diehl, M. Inverse design of dual-phase steel microstructures using generative machine learning model and Bayesian optimization. Int. J. Plast. **2023**, [171, 103776. [Google Scholar] [CrossRef] [Scilit

.63 Lertkiatpeeti, K.; Janya-Anurak, C.; Uthaisangsuk, V. Effects of spatial microstructure characteristics on mechanical properties of dual phase steel by inverse analysis and machine learning approach. Comput. Mater. Sci. **2024**, 245, [113311. [Google Scholar] [CrossRef] [Scilit

.64 Allen, L.; Gill, A.; Smith, A.; Hill, D.; Moghadam, P.Z.; Cordiner, J. Development of a machine learning framework to determine optimal alloy composition based on steel hardenability prediction. Digit. Chem. Eng. **2023**, 9, 100118. [Google Scholar] [[CrossRef] [Scilit

.65 Li, X.; Zheng, M.; Yang, X.; Chen, P.; Ding, W. A property-oriented design strategy of high-strength ductile RAFM steels based on machine learning. Mater. Sci. Eng. A [**2022**, 840, 142891. [Google Scholar] [CrossRef] [Scilit

.66 Liu, C.; Wang, X.; Cai, W.; Yang, J.; Su, H. Optimal design of the austenitic stainless-steel composition based on machine learning and genetic algorithm. Materials [**2023**, 16, 5633. [Google Scholar] [CrossRef] [Scilit] [PubMed

.67 Wang, J.; Lu, Y.; Wang, X.; Liang, S.; Xiong, J.; Zhen, L.; Liu, L. Target-driven design of high strength yet corrosion resistant medium Mn steel via interpretable machine-[learning. Mater. Des. **2025**, 260, 115217. [Google Scholar] [CrossRef] [Scilit

.68 Zhou, X.; Xu, J.; Meng, L.; Wang, W.; Zhang, N.; Jiang, L. Machine-Learning-Assisted Composition Design for High-Yield-Strength TWIP Steel. Metals **2024**, [14, 952. [Google Scholar] [CrossRef] [Scilit

.69 Pei, Z.; Zhang, D.; Zhi, Y.; Yang, T.; Jin, L.; Fu, D.; Cheng, X.; Terryn, H.A.; Mol, J.M.; Li, X. Towards understanding and prediction of atmospheric corrosion of an Fe/Cu corrosion sensor via machine learning. Corros. Sci. **2020**, 170, 108697. [Google [Scholar] [CrossRef] [Scilit

70. Yan, L.; Diao, Y.; Lang, Z.; Gao, K. Corrosion rate prediction and influencing factors evaluation of low-alloy steels in marine atmosphere using machine learning approach. Sci. Technol. Adv. Mater. **2020**, 21, 359–370. [Google Scholar] [[CrossRef] [Scilit] [PubMed

71. Song, X.; Wang, K.; Zhou, L.; Chen, Y.; Ren, K.; Wang, J.; Zhang, C. Multi-factor mining and corrosion rate prediction model construction of carbon steel under dynamic atmospheric corrosion environment. Eng. Fail. Anal. **2022**, 134, 105987. [[Google Scholar] [CrossRef] [Scilit

72. Liu, M.; Li, W. Prediction and analysis of corrosion rate of 3C steel using interpretable machine learning methods. Mater. Today Commun. **2023**, 35, [106408. [Google Scholar] [CrossRef] [Scilit

73. Dong, Z.; Ding, L.; Meng, Z.; Xu, K.; Mao, Y.; Chen, X.; Ye, H.; Poursaee, A. Machine learning-based corrosion rate prediction of steel embedded in soil. Sci. Rep. **2024**, [14, 18194. [Google Scholar] [CrossRef] [Scilit] [PubMed

74. Ji, H.; Ye, H. Machine learning prediction of corrosion rate of steel in carbonated cementitious mortars. Cem. Concr. Compos. **2023**, 143, 105256. [Google Scholar] [[CrossRef] [Scilit

75. Muthukrishnan, R.; Balogun, Y.; Rajendran, V.; Prathuru, A.; Hossain, M.; Faisal, N.H. Machine learning approach to investigate high temperature corrosion of critical infrastructure materials. High Temp. Corros. Mater. **2024**, 101, 309–331. [Google [Scholar] [CrossRef] [Scilit

76. Tawk, M.; Mustapha, S.; Trad, F.; Saad, G. Service Life Prediction in Pipelines Using Machine Learning Techniques. Int. J. Comput. Intell. Syst. **2025**, 18, 319. [Google [Scholar] [CrossRef] [Scilit

77. Feng, Z.; Jiang, Z.; Yan, C. Prediction of corrosion lifetime of marine environment steel pipe piles based on physics-informed neural network. Discov. Appl. Sci. **2026**, [8, 136. [Google Scholar] [CrossRef] [Scilit

78. Naser, M.Z. Deriving temperature-dependent material models for structural steel

through artificial intelligence. Constr. Build. Mater. **2018**, 191, 56–68. [Google [Scholar] [CrossRef] [Scilit

.79 Yazici, C.; Domínguez-Gutiérrez, F.J. Machine learning techniques for estimating high–temperature mechanical behavior of high strength steels. Results Eng. **2025**, [25, 104242. [Google Scholar] [CrossRef] [Scilit

.80 Zhao, Z. Steel columns under fire—A neural network based strength model. Adv. [Eng. Softw. **2006**, 37, 97–105. [Google Scholar] [CrossRef] [Scilit

.81 Possidente, L.; Couto, C. Explained fire resistance machine learning models for compressed steel members of trusses and bracing systems. Eng. Appl. Artif. Intell. [**2025**, 139, 109571. [Google Scholar] [CrossRef] [Scilit

.82 Fu, F. Fire induced progressive collapse potential assessment of steel framed buildings using machine learning. J. Constr. Steel Res. **2020**, 166, 105918. [Google [Scholar] [CrossRef] [Scilit

.83 Kodur, V.K.; Naser, M.Z. Classifying bridges for the risk of fire hazard via competitive machine learning. Adv. Bridge Eng. **2021**, 2, 2. [Google Scholar] [[CrossRef] [Scilit

.84 Naser, M.Z.; Kodur, V.; Thai, H.T.; Hawileh, R.; Abdalla, J.; Degtyarev, V.V. StructuresNet and FireNet: Benchmarking databases and machine learning algorithms in structural and fire engineering domains. J. Build. Eng. **2021**, 44, [102977. [Google Scholar] [CrossRef] [Scilit

.85 Çiftçioğlu, A.Ö.; Naser, M.Z. Fire resistance evaluation through synthetic fire tests and generative adversarial networks. Front. Struct. Civ. Eng. **2024**, 18, 587–614. [[Google Scholar] [CrossRef] [Scilit

.86 Agrawal, A.; Deshpande, P.D.; Cecen, A.; Basavarsu, G.P.; Choudhary, A.N.; Kalidindi, S.R. Exploration of data science techniques to predict fatigue strength of steel from composition and processing parameters. Integr. Mater. Manuf. Innov. [**2014**, 3, 90–108. [Google Scholar] [CrossRef] [Scilit

.87 Agrawal, A.; Choudhary, A. An online tool for predicting fatigue strength of steel

alloys based on ensemble data mining. Int. J. Fatigue **2018**, 113, 389–400. [[Google Scholar] [CrossRef] [Scilit

88. Arvanitis, K.; Nikolakopoulos, P.; Pavlou, D.; Farmanbar, M. Machine learning-based fatigue lifetime prediction of structural steels. Alex. Eng. J. **2025**, 125, 55–66. [[Google Scholar] [CrossRef] [Scilit

89. Feng, C.; Su, M.; Xu, L.; Zhao, L.; Han, Y. Estimation of fatigue life of welded structures incorporating importance analysis of influence factors: A data-driven approach. Eng. Fract. Mech. **2023**, 281, 109103. [Google Scholar] [CrossRef] [[Scilit

90. Schubnell, J.; Fliegener, S.; Rosenberger, J.; Feth, S.; Braun, M.; Beiler, M.; Baumgartner, J. Data-driven fatigue assessment of welded steel joints based on transfer learning. Weld. World **2025**, 69, 2223–2238. [Google Scholar] [CrossRef] [[Scilit

91. Feng, C.; Su, M.; Xu, L.; Zhao, L.; Han, Y.; Peng, C. A novel generalization ability-enhanced approach for corrosion fatigue life prediction of marine welded [structures. Int. J. Fatigue **2023**, 166, 107222. [Google Scholar] [CrossRef] [Scilit

92. Jiang, L.; Hu, Y.; Liu, Y.; Zhang, X.; Kang, G.; Kan, Q. Physics-informed machine learning for low-cycle fatigue life prediction of 316 stainless steels. Int. J. Fatigue [**2024**, 182, 108187. [Google Scholar] [CrossRef] [Scilit

93. Kamble, R.G.; Raykar, N.R.; Jadhav, D.N. Machine learning approach to predict fatigue crack growth. Mater. Today Proc. **2021**, 38, 2506–2511. [Google Scholar] [[CrossRef] [Scilit

94. Long, X.; Yu, M.; Liao, W.; Jiang, C. A deep learning-based fatigue crack growth rate measurement method using mobile phones. Int. J. Fatigue **2023**, 167, 107327. [[Google Scholar] [CrossRef] [Scilit

95. Zhang, L.; Wang, Z.; Wang, L.; Zhang, Z.; Chen, X.; Meng, L. Machine learning-based real-time visible fatigue crack growth detection. Digit. Commun. Netw. **2021**, 7, [551–558. [Google Scholar] [CrossRef] [Scilit

96. Hu, J.; Ma, K.; Zhang, Z.; Zhang, R.; Zheng, J. Machine learning-based prediction of hydrogen-assisted fatigue crack growth rate in Cr–Mo steel. Int. J. Hydrogen [Energy **2025**, 122, 1–11. [Google Scholar] [CrossRef] [Scilit

97. Himanen, L.; Geurts, A.; Foster, A.S.; Rinke, P. Data-driven materials science: Status, challenges, and perspectives. Adv. Sci. **2019**, 6, 1900808. [Google Scholar] [[CrossRef] [Scilit] [PubMed

98. Raccuglia, P.; Elbert, K.C.; Adler, P.D.; Falk, C.; Wenny, M.B.; Mollo, A.; Zeller, M.; Friedler, S.A.; Schrier, J.; Norquist, A.J. Machine-learning-assisted materials discovery using failed experiments. Nature **2016**, 533, 73–76. [Google Scholar] [[CrossRef] [Scilit] [PubMed

99. Butler, K.T.; Choudhary, K.; Csanyi, G.; Ganose, A.M.; Kalinin, S.V.; Morgan, D. Setting standards for data driven materials science. npj Comput. Mater. **2024**, 10, [231. [Google Scholar] [CrossRef] [Scilit

100. Scheffler, M.; Aeschlimann, M.; Albrecht, M.; Bereau, T.; Bungartz, H.J.; Felser, C.; Greiner, M.; Groß, A.; Koch, C.T.; Kremer, K.; et al. FAIR data enabling new horizons for materials research. Nature **2022**, 604, 635–642. [Google Scholar] [CrossRef] [[Scilit] [PubMed

101. Ward, L.; Aykol, M.; Blaiszik, B.; Foster, I.; Meredig, B.; Saal, J.; Suram, S. Strategies for accelerating the adoption of materials informatics. MRS Bull. **2018**, 43, [683–689. [Google Scholar] [CrossRef] [Scilit

102. Vasudevan, R.K.; Choudhary, K.; Mehta, A.; Smith, R.; Kusne, G.; Tavazza, F.; Vlcek, L.; Ziatdinov, M.; Kalinin, S.V.; Hattrick-Simpers, J. Materials science in the artificial intelligence age: High-throughput library generation, machine learning, and a pathway from correlations to the underpinning physics. MRS Commun. **2019**, 9, [821–838. [Google Scholar] [CrossRef] [Scilit] [PubMed

103. Tran, K.; Neiswanger, W.; Yoon, J.; Zhang, Q.; Xing, E.; Ulissi, Z.W. Methods for comparing uncertainty quantifications for material property predictions. Mach. [Learn. Sci. Technol. **2020**, 1, 025006. [Google Scholar] [CrossRef] [Scilit

104. Karniadakis, G.E.; Kevrekidis, I.G.; Lu, L.; Perdikaris, P.; Wang, S.; Yang, L. Physics-informed machine learning. Nat. Rev. Phys. **2021**, 3, 422–440. [Google Scholar] [[CrossRef] [Scilit

105. Willard, J.; Jia, X.; Xu, S.; Steinbach, M.; Kumar, V. Integrating scientific knowledge with machine learning for engineering and environmental systems. ACM Comput. [Surv. **2022**, 55, 66. [Google Scholar] [CrossRef] [Scilit

106. Gubernatis, J.E.; Lookman, T.J.P.R.M. Machine learning in materials design and discovery: Examples from the present and suggestions for the future. Phys. Rev. [Mater. **2018**, 2, 120301. [Google Scholar] [CrossRef] [Scilit

107. Lookman, T.; Balachandran, P.V.; Xue, D.; Yuan, R. Active learning in materials science with emphasis on adaptive sampling using uncertainties for targeted [design. npj Comput. Mater. **2019**, 5, 21. [Google Scholar] [CrossRef] [Scilit

108. Xue, D.; Balachandran, P.V.; Hogden, J.; Theiler, J.; Xue, D.; Lookman, T. Accelerated search for materials with targeted properties by adaptive design. Nat. [Commun. **2016**, 7, 11241. [Google Scholar] [CrossRef] [Scilit] [PubMed

109. Kusne, A.G.; Yu, H.; Wu, C.; Zhang, H.; Hattrick-Simpers, J.; DeCost, B.; Sarker, S.; Oses, C.; Toher, C.; Curtarolo, S.; et al. On-the-fly closed-loop materials discovery via Bayesian active learning. Nat. Commun. **2020**, 11, 5966. [Google Scholar] [[CrossRef] [Scilit] [PubMed

110. Kalidindi, S.R.; Buzzy, M.; Boyce, B.L.; Dingreville, R. Digital twins for materials. [Front. Mater. **2022**, 9, 818535. [Google Scholar] [CrossRef] [Scilit

111. Artificial Intelligence Risk Management Framework (AI RMF 1.0). 2023. Available online: https://nvlpubs.nist.gov/nistpubs/ai/NIST.AI.100-1.pdf (accessed on 19 .(August 2026