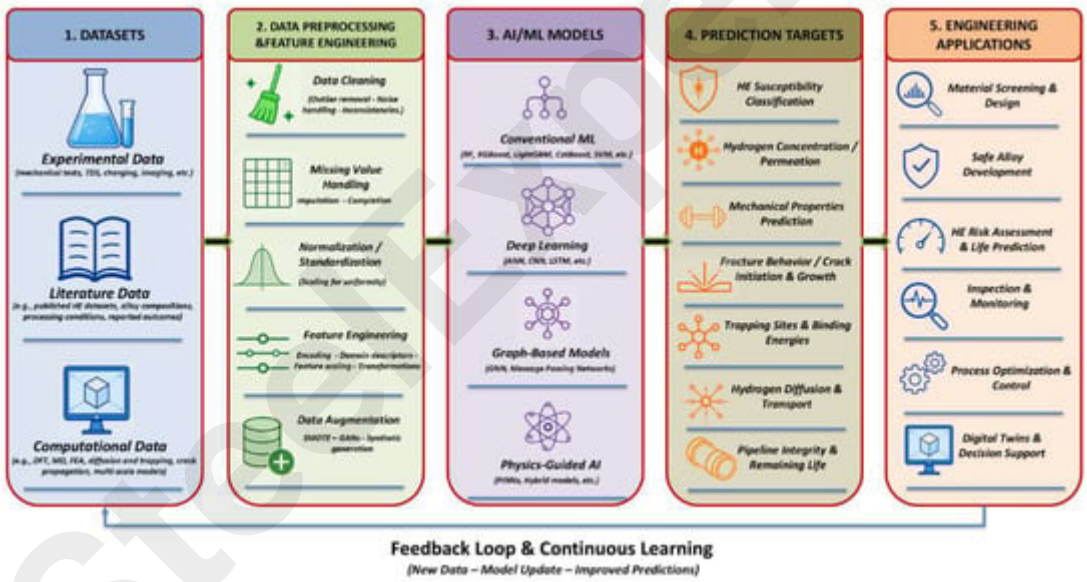
مرکز دانش شبکه خبرگان صنعت فولاد

پیشرفت‌های یادگیری ماشین در بررسی تردی هیدروژنی فولادها: مروری جامع

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

مروری تخصصی بر کاربرد هوش مصنوعی و یادگیری ماشین برای پیش‌بینی تردی هیدروژنی فولاد، تحلیل داده‌های آزمایشگاهی و محاسباتی، ارزیابی ۲۶ مطالعه، روش‌های اعتبارسنجی و کاربردهای صنعتی؛ همراه با شش جدول و چهار تصویر مجاز.



چکیده

تردی هیدروژنی (HE) همچنان یکی از مهم‌ترین موانع استفاده ایمن و قابل‌اعتماد از فولاد در سامانه‌های تولید، ذخیره‌سازی، انتقال و مصرف هیدروژن است. در سال‌های اخیر، هوش مصنوعی (AI) و یادگیری ماشین (ML) به ابزارهایی توانمند برای پیش‌بینی رفتار تردی هیدروژنی، تسریع توسعه و انتخاب مواد و پشتیبانی از تصمیم‌های مهندسی تبدیل شده‌اند. این مقاله با تحلیل ساختاریافته پژوهش‌های منتشرشده از سال ۲۰۱۰ تا

۲۰۲۶، کاربردهای هوش مصنوعی و یادگیری ماشین در بررسی تردی هیدروژنی فولادها را به‌طور نظام‌مند مرور و نقادانه ارزیابی می‌کند. در این بررسی، مجموعه‌داده‌های آزمایشگاهی، داده‌های گردآوری‌شده از منابع علمی و داده‌های محاسباتی، همراه با روش‌های پیش‌پردازش، مهندسی ویژگی، مدل‌های هوش مصنوعی و یادگیری ماشین، راهبردهای اعتبارسنجی و اهداف پیش‌بینی مطالعه شده‌اند. داده‌های آزمایشگاهی همچنان منبع اصلی پیش‌بینی حساسیت به تردی هیدروژنی، غلظت هیدروژن، رفتار شکست و ترک‌خوردگی ناشی از هیدروژن هستند؛ در مقابل، داده‌های محاسباتی شناخت مکملی از سازوکارهای نفوذ و به‌دام‌افتادن هیدروژن، گسترش ترک و برهم‌کنش‌های اتمی در مقیاس‌های مختلف فراهم می‌کنند. داده‌های تصویری و سیگنالیِ موجود در این مجموعه‌ها نیز زمینه بهره‌گیری از بینایی ماشین و شناسایی خودکار عیوب را فراهم کرده‌اند. این مرور، افزون بر جمع‌بندی نظام‌مند پژوهش‌ها، کیفیت داده‌ها، خانواده‌های مدل و کاربردهای پیش‌بینی را با رویکردی تحلیلی و انتقادی ارزیابی می‌کند و چارچوبی کاربردی برای انتخاب روش مناسب هوش مصنوعی بر پایه ویژگی‌های داده و هدف مهندسی به دست می‌دهد. اولویت پژوهش‌های آینده باید ایجاد پایگاه‌های داده استاندارد برای تردی هیدروژنی، اعتبارسنجی مستقل و دقیق، توسعه مدل‌های توضیح‌پذیر و آگاه از عدم‌قطعیت، و پیوند نزدیک‌تر رویکردهای داده‌محور با مدل‌های مبتنی بر فیزیک باشد؛ اقداماتی که قابلیت اعتماد پیش‌بینی‌ها، درک سازوکارهای پدیده و کاربرد ایمن فولادهای سازگار با هیدروژن را بهبود می‌بخشند.

کلیدواژه‌ها: تردی هیدروژنی (HE)؛ هوش مصنوعی (AI)؛ یادگیری ماشین (ML)؛ شبکه عصبی مصنوعی (ANN)؛ فولاد.

۱. مقدمه

هیدروژن بیش از پیش به‌عنوان یکی از ارکان راهبردهای جهانی دستیابی به سامانه‌های انرژی کم‌کربن و انتشار خالص صفر شناخته می‌شود. اقتصادهای بزرگی از جمله ایالات متحده، اتحادیه اروپا، چین، کانادا و ژاپن نقشه‌راه‌های ملی هیدروژن را برای گسترش استفاده از آن در بخش‌های صنعت، حمل‌ونقل و انرژی تدوین کرده‌اند [1، 2]. در خاورمیانه نیز قطر با تولید آمونیاک آبی جایگاه خود را در این عرصه تقویت کرده است؛ مسیری که صادرات هیدروژن و تلاش‌های بین‌المللی برای کربن‌زدایی را پشتیبانی می‌کند [3، 4]. بااین‌حال، توسعه فراگیر فناوری‌های هیدروژنی به عملکرد ایمن و قابل‌اتکای زیرساخت‌های فولادی، از جمله خطوط لوله، مخازن ذخیره، تجهیزات تحت فشار و تأسیسات فرایندی وابسته است. یکی از چالش‌های اصلی در محیط‌های حاوی هیدروژن، تردی هیدروژنی است؛ فرایند تخریبی‌ای که شکل‌پذیری، چقرمگی و مقاومت خستگی فولاد را کاهش می‌دهد. اتم‌های هیدروژن در شبکه بلوری فولاد نفوذ می‌کنند، در ناپیوستگی‌های ریزساختاری مانند مرزدانه‌ها، نابجایی‌ها و آخال‌ها تجمع می‌یابند و زمینه جوانه‌زنی و گسترش ترک را فراهم می‌سازند. شدت این

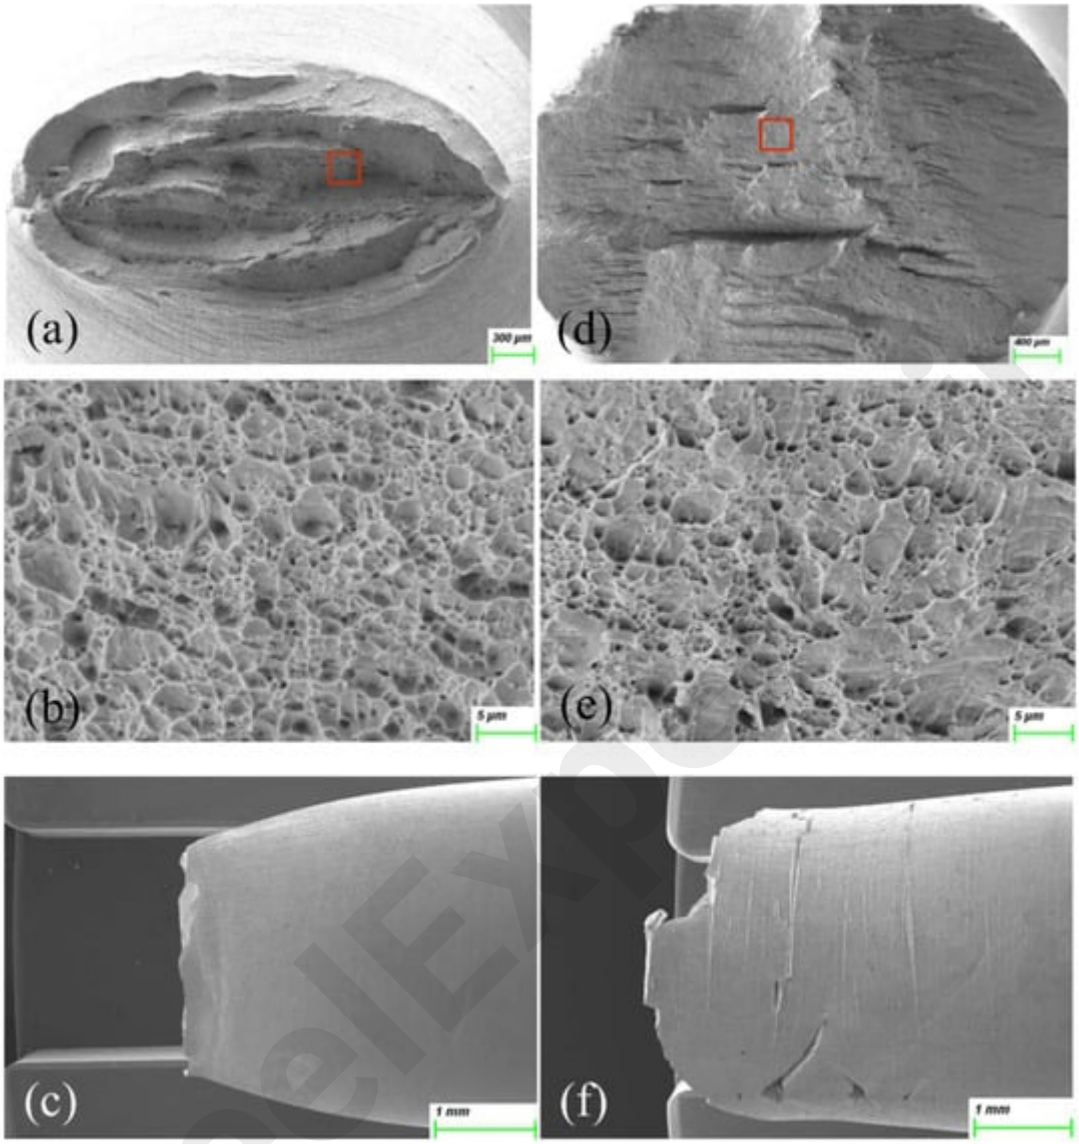
پدیده حاصل برهم‌کنش عواملی متعدد، از جمله ریزساختار و ترکیب آلیاژی فولاد، عملیات حرارتی، فشار هیدروژن و دمای سرویس است [5–7].

شکل ۱ به‌صورت شماتیک ورود هیدروژن به فولاد، نفوذ و به‌دام‌افتادن آن و در ادامه، آسیب موضعی و گسترش ترک را نشان می‌دهد [8]. برهم‌کنش هیدروژن با مرزدانه‌ها، نابجایی‌ها، آخال‌ها و دیگر جایگاه‌های تله‌گذاری، افت شکل‌پذیری و مقاومت به شکست را در پی دارد. چند سازوکار می‌توانند هم‌زمان فعال باشند؛ در میان آن‌ها «پلاستیسیته موضعی تقویت‌شده به‌وسیله هیدروژن» (HELP) و «کاهش چسبندگی اتمی تقویت‌شده به‌وسیله هیدروژن» (HEDE) از شناخته‌شده‌ترین سازوکارها در فولاد هستند. سهم هرکدام به‌شدت به ترکیب آلیاژ، ویژگی‌های ریزساختاری و شرایط بهره‌برداری وابسته است و همین موضوع پیش‌بینی تردی هیدروژنی را پیچیده می‌کند. حتی دو نمونه از یک گرید فولاد ممکن است در محیط‌های آزمایش و سطوح تماس با هیدروژن متفاوت، چقرمگی شکست یا رفتار رشد ترک خستگی متفاوتی نشان دهند [8–10]. اهمیت مهندسی این پدیده به‌ویژه در خطوط لوله هیدروژن، مخازن ذخیره، ظروف تحت فشار و قطعات فولادی در معرض هیدروژن پرفشار یا محیط‌های ترش آشکار است [11، 12]. شکل ۲ نمونه‌هایی از ریخت‌شناسی سطح شکست فولاد خط لوله، پیش و پس از تماس با هیدروژن را نشان می‌دهد. در مقایسه با نمونه‌هایی که در محیط خنثی آزموده شده‌اند، نمونه‌های هیدروژن‌دیده شکست تردتری دارند و تغییرات ریزساختاری ناشی از تخریب به کمک هیدروژن را آشکار می‌کنند [9].

شکل ۱. نمودار شماتیک تردی هیدروژنی فولاد: ورود و نفوذ هیدروژن، به‌دام‌افتادن اتم‌ها و مسیر آغاز و پیشروی ترک. اقتباس از [8 Zhang Zhang].

یادداشت حقوق انتشار: تصویر نخستِ اقتباس‌شده در آرشیو پژوهشی بازنشر نشده است؛ مجوز مستقل تصویر مبدأ تأیید نشده است. متن و عنوان شکل حفظ شده‌اند.

SteelExperts.ir



شکل ۲. ریخت‌شناسی شکست فولاد خط لوله X65: نمونه‌های (a–c) آزمون‌شده در نیتروژن (N) و نمونه‌های (d–f) شارژشده با هیدروژن. تصاویر ویژگی‌های شکست ناشی از تردی هیدروژنی را نشان می‌دهند. اقتباس از Yu و همکاران [9]، با مجوز CC BY 4.0.

هوش مصنوعی و یادگیری ماشین با یکپارچه‌کردن داده‌های آزمایشگاهی، داده‌های مستخرج از منابع و داده‌های محاسباتی ــ از جمله تصویر و سیگنال ــ به ابزارهایی مؤثر در پژوهش‌های تردی هیدروژنی تبدیل شده‌اند. این مدل‌ها برای پیش‌بینی حساسیت به تردی، رفتار شکست، رشد ترک خستگی و تحول عیوب، در عین کاهش وابستگی به آزمایش‌های پرهزینه، ظرفیت بالایی نشان داده‌اند [11]. پیشرفت‌های یادگیری عمیق (DL)، بینایی ماشین و یادگیری ماشینِ آگاه از فیزیک، تحلیل خودکار عیوب و قابلیت اعتماد پیش‌بینی را نیز بهبود داده‌اند. با وجود این، کوچک‌بودن مجموعه‌داده‌های آزمایشگاهی، فرض‌های ساده‌ساز و شرایط مرزی ایدئال‌شده در روش‌های محاسباتی مانند مدل‌سازی اجزای محدود (FEM)، نظریه تابعی چگالی (DFT) و دینامیک مولکولی (MD)، و نیز ناهمگونی داده‌های استخراج‌شده از منابع علمی، همچنان مانع ساخت

مدل‌هایی مقاوم و قابل‌تعمیم می‌شوند [13–17].

با آنکه کاربرد هوش مصنوعی و یادگیری ماشین در پژوهش‌های تردی هیدروژنی رو به افزایش است، مطالعات موجود از نظر نوع داده، مقیاس فیزیکی، هدف پیش‌بینی و خانواده الگوریتم‌ها پراکنده و نسبتاً محدودند. راهنمای نظام‌مند برای اعتبارسنجی مدل‌ها، تفسیرپذیری، قابلیت اعتماد و تناسب مهندسی آن‌ها نیز هنوز کافی نیست. تمرکز این مقاله به‌طور مشخص بر کاربردهای هوش مصنوعی در تردی هیدروژنی فولادهاست؛ زیرا بیشتر پژوهش‌های در دسترس بر مواد فولادی انجام شده و بررسی سایر سامانه‌های فلزی بسیار اندک است. ازاین‌رو، برای حفظ دامنه‌ای همگن و امکان مقایسه معنادار میان مطالعات، دیگر فلزات از بررسی کنار گذاشته شده‌اند. پژوهش‌ها بر پایه منشأ داده‌ها، شیوه نمایش ویژگی‌ها، هدف پیش‌بینی، روش یادگیری ماشین، راهبرد اعتبارسنجی، تفسیرپذیری و قابلیت کاربرد مهندسی تحلیل می‌شوند. بر این اساس، مقاله چارچوبی تحلیلی برای تشخیص قوت‌ها و ضعف‌های روش‌شناختی، مقایسه تناسب مدل‌ها و هدایت انتخاب روش مناسب برای مسائل مختلف تردی هیدروژنی ارائه می‌کند. اگرچه موضوع اصلی روش‌های هوش مصنوعی است و نه شرح جامع سازوکارهای بنیادین تردی هیدروژنی، کنار هم قرار دادن شواهد حاصل از داده‌ها و مقیاس‌های فیزیکی گوناگون، شناختی مکمل از رفتار این پدیده به دست می‌دهد و پژوهش‌های آینده درباره سازوکارها را پشتیبانی می‌کند. مقاله همچنین شکاف‌های اصلی پژوهش را که باید برای افزایش اعتمادپذیری، انتقال‌پذیری و اجرای عملی ارزیابی‌های مبتنی بر هوش مصنوعی برطرف شوند، مشخص می‌سازد.

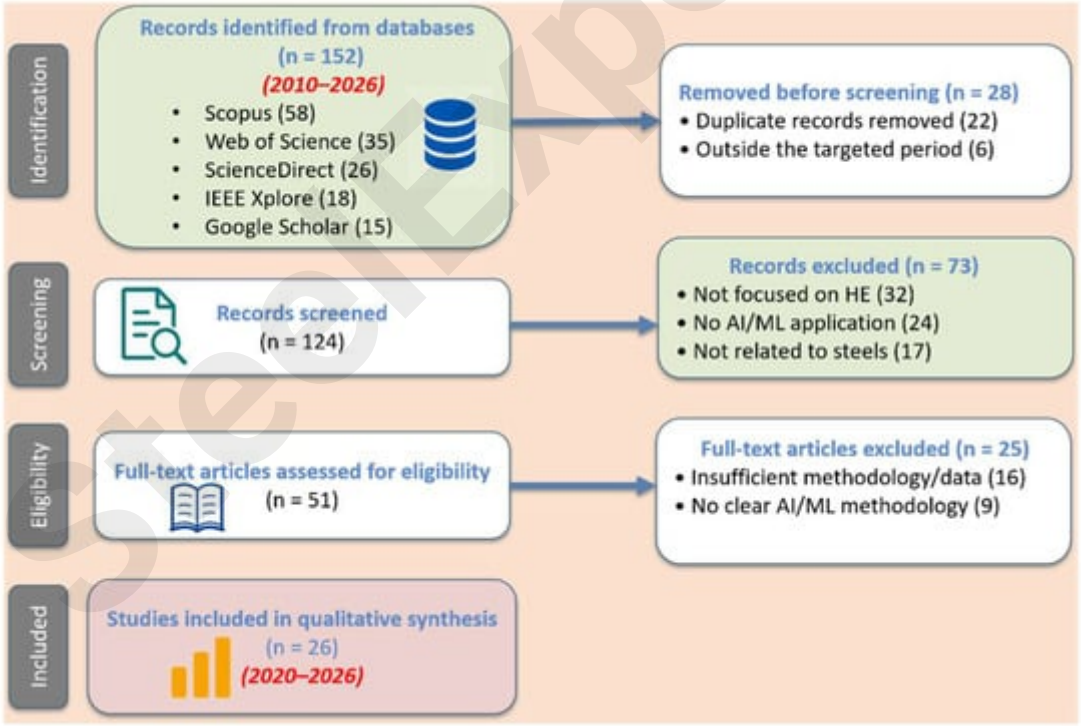
۲. روش مرور منابع علمی

۲٫۱. راهبرد جست‌وجوی منابع و انتخاب مطالعات

برای شناسایی پژوهش‌های داوری‌شده درباره کاربردهای هوش مصنوعی و یادگیری ماشین در تردی هیدروژنی فولاد، جست‌وجویی نظام‌مند در پایگاه‌های Scopus، Web of Science، ScienceDirect، IEEE Xplore و Google Scholar انجام شد. در راهبرد جست‌وجو، عبارت «تردی هیدروژنی» با اصطلاح‌های عمومی هوش مصنوعی ــ مانند هوش مصنوعی، یادگیری ماشین و یادگیری عمیق ــ و نام الگوریتم‌های مشخص، از جمله شبکه عصبی مصنوعی، جنگل تصادفی، رگرسیون بردار پشتیبان، گرادیان بوستینگ، CatBoost، LightGBM و شبکه عصبی آگاه از فیزیک (PINN) ترکیب شد. کلیدواژه‌های مرتبط دیگری نیز بررسی شدند، اما مطالعه واجد شرایط جدیدی به دست نیاوردند. بازه جست‌وجو سال‌های ۲۰۱۰ تا ۲۰۲۶ را در بر می‌گرفت و بر مواد فولادی، از جمله فولادهای خطوط لوله، زنگ‌نزن، جوشکاری‌شده و پرمقاومت متمرکز بود. شناسایی و انتخاب مطالعات با پیروی از اصول کلی راهنمای «اقلام گزارش‌دهی ترجیحی برای مرورهای نظام‌مند و فراتحلیل‌ها» (PRISMA)

انجام شد؛ فرایند آن در شکل ۳ آمده است. جست‌وجوی اولیه ۱۵۲ رکورد به دست داد. پیش از غربالگری، ۲۲ رکورد تکراری و ۶ رکورد خارج از دوره ۲۰۱۰ تا ۲۰۲۶ حذف شد و ۱۲۴ رکورد برای غربالگری باقی ماند. برای حفظ امکان مقایسه همگن کاربردهای هوش مصنوعی در سامانه‌های فولادی، مطالعات مربوط به آلیاژهای نیکل، آلومینیوم، تیتانیوم و آلیاژهای با آنتروپی بالا کنار گذاشته شدند. همچنین مطالعاتی که صرفاً به هوش مصنوعی اشاره کرده بودند یا سهم مشخص و قابل‌ارزیابی در تحلیل تردی هیدروژنی نداشتند، حذف شدند؛ در نتیجه ۵۱ مقاله تمام‌متن برای ارزیابی شایستگی باقی ماند. شرط پذیرش، گزارش روشی روشن از هوش مصنوعی یا یادگیری ماشین و ارائه اطلاعات روش‌شناختی و داده‌های کافی بود. در نهایت، ۲۶ مطالعه منتشرشده در سال‌های ۲۰۲۰ تا ۲۰۲۶ برای تحلیل تفصیلی انتخاب شدند. اندک‌بودن مطالعات واجد شرایط نشان می‌دهد که کاربرد هوش مصنوعی در تردی هیدروژنی فولاد هنوز حوزه‌ای نوظهور و دارای ظرفیت رشد چشمگیر است.

جست‌وجوی اولیه و گزینش مطالعات را یک نویسنده انجام داد و سپس هم‌نویسندگان با معیارهای ورود و خروج ازپیش‌تعیین‌شده تطبیق دادند. اختلاف‌نظرها با گفت‌وگو و رسیدن به توافق رفع شد. برای این مرور، پروتکل رسمی ازپیش‌ثبت‌شده‌ای وجود نداشت.



شکل ۳. نمودار جریان به سبک PRISMA برای شناسایی، غربالگری، ارزیابی واجد شرایط بودن و گزینش مطالعات این مرور.

۲٫۲. پرسش‌های پژوهشی

برای هدایت مرور نظام‌مند و ارزیابی انتقادی کاربردهای جدید هوش مصنوعی و یادگیری ماشین در تردی هیدروژنی فولاد، مجموعه‌ای از پرسش‌های پژوهشی (RQ) تعریف شد. این پرسش‌ها بر شیوه استفاده از

روش‌های یادگیری ماشین در مجموعه‌داده‌ها، مقیاس‌های فیزیکی و کاربردهای مهندسی متفاوت تمرکز دارند. هدف این مرور، شرح کامل سازوکارهای بنیادین تردی هیدروژنی نیست؛ بااین‌حال، تحلیل یکپارچه این مطالعات مکمل، درک ارزشمندی از وجوه مختلف رفتار تردی هیدروژنی فراهم می‌کند و می‌تواند مبنای پژوهش‌های آینده درباره سازوکارهای آن باشد.

- RQ1: در مطالعات یادگیری ماشین درباره تردی هیدروژنی فولاد از چه نوع مجموعه‌داده‌هایی استفاده می‌شود و ویژگی‌های اصلی آن‌ها چیست؟
- RQ2: کدام خانواده‌های مدل هوش مصنوعی و یادگیری ماشین بیشترین کاربرد را دارند و برای چه نوع داده‌هایی بهتر عمل می‌کنند؟
- RQ3: برای نمایش رفتار تردی هیدروژنی از چه راهبردهای مهندسی ویژگی و چه توصیفگرهایی استفاده شده است؟
- RQ4: برای تبدیل داده‌های خام تردی هیدروژنی به داده‌های آماده مدل‌سازی، چه روش‌های پیش‌پردازش و افزایش داده به کار می‌رود؟
- RQ5: چه روش‌هایی برای بهینه‌سازی ابرپارامترها و تنظیم مدل‌ها استفاده شده است؟
- RQ6: برای سنجش عملکرد مدل‌ها از چه راهبردهای اعتبارسنجی و چه معیارهایی استفاده می‌شود؟
- RQ7: چالش‌ها و محدودیت‌های فنی اصلی در پژوهش‌های تردی هیدروژنی مبتنی بر هوش مصنوعی چیست؟
- RQ8: چارچوب‌های هوش مصنوعی آگاه از فیزیک و چندمقیاسی چگونه با شبیه‌سازی‌های FEM/CFD/DFT/MD برای پیش‌بینی تردی هیدروژنی تلفیق می‌شوند؟
- RQ9: مدل‌های هوش مصنوعی در پژوهش‌های تردی هیدروژنی بیشتر چه کمیت‌ها و کاربردهایی را پیش‌بینی می‌کنند؟

این پرسش‌ها چارچوب تحلیلی مرور حاضر را تشکیل می‌دهند و پاسخ آن‌ها در بخش‌های ۴/۱ و ۴/۳ پیگیری

می‌شود.

۲٫۳. ارزیابی کیفیت روش‌شناختی (QA)

کیفیت روش‌شناختی و شفافیت گزارش‌دهی مطالعات منتخب با چارچوب ارزیابی کیفیت (QA) که برای همین مرور تدوین شده بود، سنجیده شد. این چارچوب به بررسی جنبه‌های کلیدی کاربرد هوش مصنوعی در تردی هیدروژنی فولاد می‌پردازد: کیفیت داده، پیش‌پردازش، توسعه مدل، شیوه اعتبارسنجی، تفسیرپذیری فیزیکی، تکرارپذیری و شفافیت گزارش. علت طراحی این چارچوب اختصاصی آن بود که ابزار ارزیابی موجودی، هم‌زمان همه ابعاد روش‌شناسی هوش مصنوعی و گزارش‌دهی علم مواد را پوشش نمی‌داد. همان‌گونه که در بخش ۲٫۱ بیان شد، جست‌وجوی منابع و گزینش مطالعات از اصول عمومی PRISMA (شکل ۳) پیروی می‌کرد؛ بنابراین چارچوبی اختصاصی برای ارزیابی کیفیت به کار گرفته شد.

هر معیار ارزیابی در مقیاسی سه‌سطحی امتیاز گرفت: صفر برای «برآورده نشده»، ۰٫۵ برای «تا حدی برآورده شده» و یک برای «برآورده شده». بر اساس مجموع امتیاز، مطالعات در سه سطح کیفیت بالا (۷۵ درصد و بیشتر)، متوسط (۵۰ تا ۷۴ درصد) و پایین (کمتر از ۵۰ درصد) طبقه‌بندی شدند. این آستانه‌ها صرفاً دسته‌بندی‌هایی کاربردی برای مقایسه در همین مرور هستند و نباید آن‌ها را مرزهای اعتبارسنجی‌شده و جهان‌شمولِ خطر سوگیری دانست. ارزیابی اولیه را یک نویسنده انجام داد و هم‌نویسندگان آن را بازبینی کردند؛ اختلاف‌ها با بحث و توافق حل شد. پانزده معیار ارزیابی در جدول ۱ و نتیجه کلی ارزیابی‌ها در جدول ۲ آمده است. امتیازهای تفصیلی هر ۲۶ مطالعه نیز در جدول تکمیلی S1 ارائه شده‌اند. در مجموع، ۲۵ مطالعه کیفیت بالا و یک مطالعه کیفیت متوسط داشتند؛ نتیجه‌ای که از وضعیت عموماً مطلوب روش‌شناسی در پژوهش‌های بررسی‌شده حکایت دارد. بااین‌حال، این دسته‌ها حاصل جمع امتیاز پانزده معیارند و به معنای برآورده‌شدن همه معیارها در تک‌تک مطالعات نیستند. حتی مطالعات با کیفیت بالا ممکن است در معیارهای مشخصی ضعف داشته باشند. محدودیت‌های تکرارشونده بیشتر به دسترس‌پذیری داده‌ها، اعتبارسنجی بیرونی، سنجش عدم‌قطعیت و کامل‌بودن گزارش روش‌ها مربوط بودند. یافته‌ها ضرورت بهبود شفافیت، تکرارپذیری، گزارش‌دهی استاندارد و اشتراک‌گذاری داده را برای افزایش اعتمادپذیری، تعمیم‌پذیری و کاربرد عملی پژوهش‌های آینده نشان می‌دهند.

جدول 1. معیارهای ارزیابی کیفیت روش‌شناختی پژوهش‌های هوش مصنوعی و یادگیری ماشین

شناسه	پرسش ارزیابی کیفیت	معیار
QA1	آیا هدف پژوهش برای کاربرد هوش مصنوعی/یادگیری ماشین در تردی هیدروژنی فولاد روشن تعریف شده است؟	شفافیت هدف

شناسه	پرسش ارزیابی کیفیت	معیار
QA2	آیا منشأ مجموعه‌داده به‌روشنی شرح داده شده است؟	منشأ داده
QA3	آیا حجم و ترکیب داده و متغیرهای ورودی/خروجی گزارش شده‌اند؟	گزارش مجموعه‌داده
QA4	آیا ویژگی‌ها یا توصیفگرها به‌روشنی تعریف شده‌اند؟	توصیف ویژگی‌ها
QA5	آیا روش‌های پیش‌پردازش داده به‌اندازه کافی توضیح داده شده‌اند؟	پیش‌پردازش داده
QA6	آیا راهبرد تقسیم داده به‌روشنی گزارش شده است؟	تقسیم داده
QA7	آیا مدل یا معماری هوش مصنوعی/یادگیری ماشین به‌روشنی مشخص شده است؟	مشخصات مدل
QA8	آیا روش آموزش و بهینه‌سازی ابرپارامترها توضیح داده شده است؟	آموزش و تنظیم مدل
QA9	آیا مدل‌های مبنا یا معیارهای مرجع برای مقایسه وجود دارند؟	مقایسه با مدل مبنا
QA10	آیا شاخص‌های عملکرد مناسب گزارش شده‌اند؟	ارزیابی عملکرد
QA11	آیا اعتبارسنجی مدل با روش‌های مناسب انجام شده است؟	اعتبارسنجی مدل
QA12	آیا نتایج همراه با اندازه‌گیری‌های کمیِ عملکرد روشن ارائه شده‌اند؟	گزارش نتایج
QA13	آیا پیش‌بینی‌ها در چارچوب سازوکارهای تردی هیدروژنی تفسیر شده‌اند؟	تفسیرپذیری فیزیکی
QA14	آیا وضعیت دسترس‌پذیری مجموعه‌داده گزارش شده است؟	دسترسی به داده
QA15	آیا محدودیت‌ها و عدم‌قطعیت‌های مطالعه به‌روشنی بررسی شده‌اند؟	محدودیت‌ها و عدم‌قطعیت

جدول 2. خلاصه نتایج ارزیابی کیفیت روش‌شناختی مطالعات هوش مصنوعی و یادگیری ماشین

دسته مطالعه	تعداد مطالعات	کیفیت بالا	متوسط	پایین	میانگین امتیاز از ۱۵	منابع
آزمایشگاهی	10	9	1	0	13.2	[18–27]
برگرفته از منابع علمی	9	9	0	0	13.3	[28–36]
محاسباتی	7	7	0	0	13.6	[37–43]
مجموع	26	25	1	0	13.4	[18–43]

۳. فولادهای بررسی‌شده در مطالعات تردی هیدروژنی با هوش مصنوعی

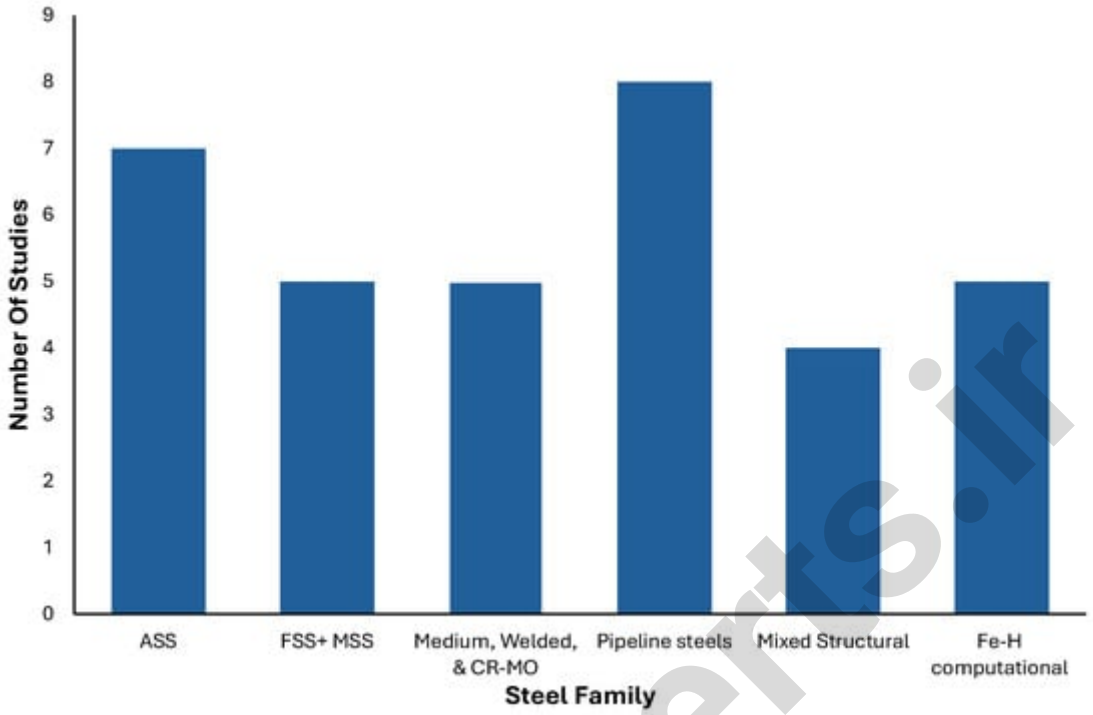
جدول ۳ و شکل ۴ خانواده‌های فولاد بررسی‌شده در مطالعات تردی هیدروژنی مبتنی بر هوش مصنوعی را خلاصه می‌کنند. محور عمده پژوهش‌ها فولادهای مهندسی، مانند فولادهای خطوط لوله، فولادهای زنگ‌نزن، فولادهای مارتنزیتی، فولادهای جوشکاری‌شده و فولادهای کروم‌مولیبدن است؛ موادی که کاربرد گسترده‌ای در

تولید، انتقال و ذخیره‌سازی هیدروژن و واحدهای فرایندی صنعتی دارند. افزون بر آن، استفاده از سامانه‌های محاسباتی آهن–هیدروژن (Fe–H)، شامل آهن آلفای با شبکه مکعبی مرکزپر (BCC -Fe)، مدل‌های اتمی Fe–H، ساختارهای مرزدانه و داده‌های تولیدشده با DFT و MD، برای مطالعه نفوذ، به‌دام‌افتادن هیدروژن و آغاز ترک در مقیاس اتمی رو به افزایش است. مطالعات خطوط لوله در مقیاس سامانه نیز دیدگاهی عملیاتی فراهم می‌کنند، هرچند لزوماً یک خانواده مشخص از فولاد را بررسی نمی‌کنند [38]. در مجموع، نیازهای کاربردی فولادهای صنعتی محرک اصلی پژوهش‌ها هستند و مطالعات محاسباتی و سامانه‌ای با ارائه شناخت سازوکاری و عملیاتی مکمل، به ساخت مدل‌های مقاوم‌تر و تفسیرپذیرتر کمک می‌کنند.

جدول 3. مواد و خانواده‌های فولادی بررسی‌شده در مطالعات تردی هیدروژنی با هوش مصنوعی

ردیف	ماده / خانواده فولاد	کاربرد	منابع
1	فولادهای زنگ‌نزن آستنیتی (ASS)	سامانه‌های هیدروژن، قطعات جوشکاری‌شده، خطوط لوله و مخازن ذخیره	[18، 19، 26، 27، 31، 32، 35]
2	فولادهای فریتی، فریتی–مارتنزیتی و مارتنزیتی (FSS–MSS)	قطعات سازه‌ای، خطوط لوله، ظروف تحت فشار و کاربردهای پرمقاومت	[18–21، 41]
3	فولادهای کربن متوسط، جوشکاری‌شده و کروم–مولیبدن (4130X، گریدهای API، AISI 1040، اتصالات جوشی)	خطوط لوله جوشکاری‌شده، ظروف تحت فشار، ارزیابی خستگی و سلامت جوش	[22–25، 36]
4	فولادهای خطوط لوله (API X42–X100، X65)	انتقال هیدروژن، ارزیابی شکست و پیش‌بینی یکپارچگی سازه‌ای	[26، 29، 30، 32–34، 36، 40، 43]
5	فولادهای سازه‌ای متنوع (۴۷ گرید)	پژوهش‌های سازه‌ای، هوافضا، راکتور و غربالگری مواد	[28، 30، 32، 35]
6	سامانه‌های محاسباتی آهن–هیدروژن (BCC -Fe و مدل‌های مرزدانه)	مدل‌سازی اتمی نفوذ، تله‌گذاری، کاهش چسبندگی و گسترش ترک	[37، 39، 42]

SteelExperts.ir

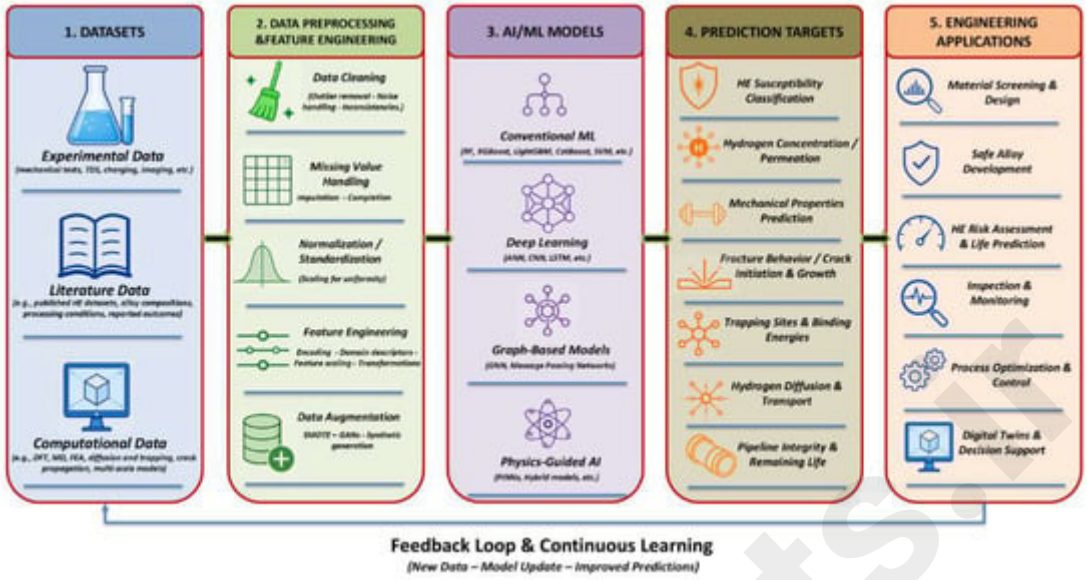


شکل ۴. توزیع خانواده‌های فولاد بررسی‌شده در مطالعات یادگیری ماشین درباره تردی هیدروژنی. بعضی مطالعات بیش از یک خانواده فولاد یا حوزه کاربرد را بررسی کرده‌اند؛ بنابراین تعداد دسته‌ها الزاماً مستقل از یکدیگر نیست.

۴. کاربردهای هوش مصنوعی و یادگیری ماشین در تردی هیدروژنی فولاد

مطالعات هوش مصنوعی در تردی هیدروژنی معمولاً از چرخه‌ای تکرارشونده پیروی می‌کنند: داده‌های آزمایشگاهی، منابع علمی و شبیه‌سازی وارد مراحل آماده‌سازی داده، مهندسی ویژگی، توسعه مدل، اعتبارسنجی و پیش‌بینی می‌شوند [29، 39]. هرچند هدف‌ها، داده‌ها و الگوریتم‌ها در این مطالعات یکسان نیست، چارچوب کلی کار مشابه است. شکل ۵ چارچوب مفهومی استخراج‌شده از منابع را نشان می‌دهد که منشأ داده را به توسعه مدل، هدف پیش‌بینی، تفسیر نتیجه و تصمیم‌گیری مهندسی درباره تردی هیدروژنی فولاد پیوند می‌دهد. با اتکا به این چارچوب، ۲۶ مطالعه منتخب از سه منظر مکمل بررسی انتقادی می‌شوند: نخست، مجموعه‌داده‌ها و شیوه‌های آماده‌سازی آن‌ها (بخش ۴/۱)؛ دوم، کاربردهای هوش مصنوعی، عملکرد و قابلیت اعتماد مدل و انتخاب الگوریتم (بخش ۴/۲)؛ و سوم، چالش‌های کنونی، شکاف‌های پژوهشی و مسیرهای آینده (بخش ۴/۳). این چیدمان امکان ارزیابی نظام‌مند روندها، قوت‌ها و محدودیت‌های روش‌شناختی و فرصت‌های توسعه پژوهش‌های معتبر و دارای معنای فیزیکی را فراهم می‌کند [44].

SteelExperts.ir



شکل ۵. چارچوب مفهومی هوش مصنوعی و یادگیری ماشین برآمده از منابع: پیوند منشأ مجموعه‌داده، توسعه مدل، هدف پیش‌بینی و کاربرد مهندسی در تردی هیدروژنی فولاد.

۴٫۱. مجموعه‌داده‌های پژوهش‌های تردی هیدروژنی

کیفیت، تنوع و نمایندگی داده‌ها از شرایط واقعی، به‌طور بنیادی توان پیش‌بینی، پایداری و تعمیم‌پذیری مدل‌های هوش مصنوعی برای تردی هیدروژنی فولاد را تعیین می‌کنند. بااین‌حال، ساخت مجموعه‌داده‌های بزرگ و استاندارد دشوار است؛ زیرا آزمون هیدروژن پرهزینه و از نظر اجرایی پیچیده است و الزامات ایمنی سخت‌گیرانه‌ای دارد [5–7]. ازاین‌رو، مطالعات عمدتاً به سه منبع مکمل متکی‌اند: داده‌های آزمایشگاهی، داده‌های گردآوری‌شده از منابع علمی و داده‌های محاسباتی. تصویر و سیگنال در این دسته‌بندی، شیوه‌های ویژه نمایش داده به شمار می‌روند، نه نوعی منبع مستقل. جدول تکمیلی S2 جزئیات گردآوری و آماده‌سازی داده‌ها را شامل منشأ و اندازه مجموعه‌داده، نوع فولاد، متغیرهای ورودی و هدف، تقسیم داده، جلوگیری از نشت اطلاعات، پاک‌سازی، مهندسی ویژگی، مقیاس‌بندی، تبدیل و افزایش داده گزارش می‌کند.

داده‌های آزمایشگاهی از آزمون کشش، طیف‌سنجی واجذب حرارتی (TDS)، آزمون‌های مکانیک شکست، اندازه‌گیری‌های الکتروشیمیایی و روش‌های ارزیابی غیرمخرب، مانند نشر آکوستیک (AE)، میکروسکوپی آکوستیک روبشی (SAM)، میکروسکوپی الکترونی روبشی (SEM) و تصویربرداری نوری تولید می‌شوند [18–27]. این داده‌ها تخریب ناشی از هیدروژن، تحول ترک و تغییرات ریزساختاری را مستقیماً اندازه می‌گیرند و ازاین‌رو، از نظر انطباق با واقعیت فیزیکی، مناسب‌ترین منبع توسعه مدل به شمار می‌آیند. برای نمونه، داده‌های TDS و کشش برای پیش‌بینی حساسیت به تردی هیدروژنی و غلظت بحرانی هیدروژنِ عامل شکست مکانیکی به کار رفته‌اند [21–23]؛ درحالی‌که داده‌های تصویر و سیگنال امکان طبقه‌بندی خودکار سطوح شکست، تشخیص حباب هیدروژن، بخش‌بندی ترک‌خوردگی القاشده با هیدروژن (HIC)، شناسایی سیگنال‌های نشر آکوستیک و

شکست‌نگاری با کمک هوش مصنوعی را فراهم کرده‌اند [21، 22، 24–27]. با وجود این، حجم داده‌های آزمایشگاهی معمولاً محدود است؛ زیرا شارژ هیدروژن و آزمون مکانیکی به امکانات تخصصی، تجهیزات سازگار با هیدروژن و مقررات ایمنی دقیق نیاز دارند [7، 45، 46]. استانداردهای ASTM F519 و ASTM F1624 و راهنماهای سازگاری مواد با هیدروژن، روش‌های آزمون نسبتاً هماهنگی فراهم کرده‌اند [47–49]؛ اما تفاوت در آماده‌سازی نمونه، روش شارژ، شرایط بارگذاری و شیوه گزارش نتایج، همچنان تکرارپذیری و تلفیق داده‌های مطالعات مختلف را دشوار می‌کند.

مجموعه‌داده‌های برگرفته از منابع علمی، نتایج آزمایش‌های منتشرشده در مقاله‌ها، گزارش‌های فنی و پایگاه‌های اطلاعات مواد را کنار هم قرار می‌دهند تا تنوع گریدهای فولاد، شرایط محیطی، فشارهای هیدروژن و خواص مکانیکی قابل‌استفاده برای توسعه مدل افزایش یابد [28–36]. در مقایسه با یک مجموعه‌داده آزمایشگاهی منفرد، این منابع پوشش مواد گسترده‌تری دارند و نیاز به آزمایش‌های تازه را به میزان چشمگیری کاهش می‌دهند. از این داده‌ها برای پیش‌بینی طراحی آلیاژهای مقاوم به هیدروژن، حساسیت به تردی، چقرمگی شکست، کاهش سطح مقطع در ناحیه گلویی‌شدن، نرخ رشد ترک خستگی و احتمال خرابی خط لوله استفاده شده است [28–36]. بااین‌حال، ناهمگونی روش‌های آزمون، یکسان‌نبودن واحدهای اندازه‌گیری، ناقص‌بودن فراداده‌ها و تفاوت کیفیت گزارش‌ها در این مجموعه‌ها رایج است. بنابراین، پیش از ترکیب رکوردهایی که در شرایط آزمایشی متفاوت به دست آمده‌اند، باید پیش‌پردازش گسترده شامل پاک‌سازی داده، هماهنگ‌سازی ویژگی‌ها، تبدیل واحدها و ارزیابی کیفیت انجام شود.

داده‌های محاسباتی با استفاده از روش اجزای محدود (FEM)، دینامیک سیالات محاسباتی (CFD)، نظریه تابعی چگالی (DFT)، دینامیک مولکولی (MD) و دیگر روش‌های شبیه‌سازی چندمقیاسی، اطلاعاتی تکرارپذیر در شرایط کنترل‌شده تولید می‌کنند و مکمل مشاهده‌های آزمایشگاهی هستند [37–43]. این رویکردها امکان بررسی نظام‌مند جذب سطحی هیدروژن، نفوذ، تله‌گذاری، برهم‌کنش با مرزدانه، رفتار شکست، گسترش ترک و عملکرد خطوط لوله را در شرایطی فراهم می‌کنند که بازآفرینی آزمایشگاهی آن‌ها دشوار، زمان‌بر یا ناایمن است. شبیه‌سازی‌های اتمی همراه با یادگیری ماشین، پیش‌بینی پیوند هیدروژن، نفوذ و رشد ترک در سامانه‌های Fe–H را شتاب داده‌اند [37، 39، 42]؛ در مقیاس پیوسته نیز شبیه‌سازی‌ها داده‌های جانشین برای چقرمگی شکست، نرخ رشد ترک، فشار ترکیدگی و عملکرد خطوط لوله هیدروژن ایجاد کرده‌اند [38، 40، 41، 43]. این داده‌ها تکرارپذیری بالا و امکان مطالعه پارامتری منظم دارند، اما دقت پیش‌بینی آن‌ها در نهایت به اعتبار مدل فیزیکی مبنا وابسته است و ازاین‌رو به راستی‌آزمایی آزمایشگاهی نیاز دارند.

راهبردهای مهندسی ویژگی با منشأ مجموعه‌داده و مقیاس فیزیکی مسئله تغییر می‌کنند. در مطالعات آزمایشگاهی و داده‌های گردآوری‌شده از منابع، متغیرهایی مانند ترکیب آلیاژی، ریزساختار، عملیات حرارتی، خواص مکانیکی، شرایط شارژ هیدروژن، فشار هیدروژن، نرخ کرنش، غلظت هیدروژن و توصیفگرهای طیفی

استخراج‌شده از TDS، ورودی پیش‌بینی قرار می‌گیرند [20، 36]. پژوهش‌های مکانیک شکست افزون بر این‌ها از ضرایب شدت تنش، هندسه ترک، شرایط بارگذاری و پارامترهای چقرمگی شکست استفاده می‌کنند [23، 29، 41]. در پژوهش‌های مبتنی بر تصویر و سیگنال، ویژگی‌های ریخت‌شناختی، بافتی، طیفی و کانولوشنی از تصاویر SEM، سطوح شکست، ویدئوهای خوردگی، تصاویر SAM و سیگنال‌های نشر آکوستیک استخراج می‌شوند تا شناسایی خودکار عیب ممکن شود [21، 26، 27]. در مقیاس اتمی نیز مدل‌ها از محیط موضعی اتم‌ها، توصیفگرهای مرزدانه، انرژی‌های برهم‌کنش هیدروژن و پارامترهای مرتبط با نفوذ که از شبیه‌سازی‌های DFT و MD به دست می‌آیند، بهره می‌گیرند [37، 39، 42]. این نتایج نشان می‌دهند نمایش ویژگی‌ها به‌گونه‌ای که معنای فیزیکی داشته باشند، اغلب به‌اندازه حجم داده یا انتخاب الگوریتم اهمیت دارد؛ هرچند نبود توصیفگرهای استاندارد، مقایسه مستقیم پژوهش‌ها و انتقال مدل میان آن‌ها را دشوار می‌سازد.

پیش‌پردازش داده در هر سه گروه، برای دستیابی به عملکرد قابل‌اعتماد مدل نقش تعیین‌کننده دارد. بیشتر مطالعات پیش از توسعه مدل، پاک‌سازی داده، نرمال‌سازی، مقیاس‌بندی و انتخاب ویژگی و تقسیم داده به بخش‌های آموزش، اعتبارسنجی و آزمون را انجام داده‌اند. شرح روش‌های پیش‌پردازش، مهندسی ویژگی و تقسیم داده در مطالعات بررسی‌شده در جدول تکمیلی S2 آمده است. برای جبران کمبود داده، بعضی پژوهش‌ها از نمونه‌سازی مصنوعی، میان‌یابی طیفی، افزایش داده تصویری با تبدیل‌های هندسی و گسترش تکرارشونده مجموعه‌داده استفاده کرده‌اند [22، 24، 28]. نوع پیش‌پردازش به ماهیت داده وابسته بوده است. در داده‌های آزمایشگاهی، طیف‌های TDS با برازش گاوسی، نرمال‌سازی و افزایش مصنوعی داده پردازش شدند تا توصیفگرهای آماده یادگیری ماشین برای پیش‌بینی حساسیت به تردی هیدروژنی حاصل شود [18]. در پژوهش‌های تصویری نیز پیش از طبقه‌بندی شکست با یادگیری انتقالی، اندازه تصاویر SEM تغییر داده شد و تصاویر نرمال‌سازی و از نظر هندسی غنی‌سازی شدند [21]. در مطالعه‌ای متکی بر منابع علمی، داده‌های کشش ۴۷ گرید فولاد غربال شد، ۲۲ متغیر ورودی اولیه به ۱۰ توصیفگر کلیدی کاهش یافت و پیش از آموزش مدل، متغیرهای طبقه‌ای کدگذاری شدند [35]. در نمونه‌ای دیگر، برای داده‌های مربوط به ترکیب فولاد، محیط هیدروژنی و خواص مکانیکی، مقادیر گمشده مدیریت، متغیرهای عددی استاندارد، ویژگی‌های مؤثر انتخاب و برای کاهش نامتوازنی کلاس‌ها از نمونه‌برداری افزایشی استفاده شد [34].

در مجموعه‌داده‌های محاسباتی، پیش‌پردازش شامل ساخت ویژگی‌های برگرفته از فیزیک، کاهش بُعد، تبدیل لگاریتمی و نمایش گرافی ساختار اتمی بوده است. برای مثال، برای کاهش متغیرهای جریان حاصل از CFD از تحلیل مؤلفه‌های اصلی (PCA) استفاده شد [38] و برای پردازش داده‌های نفوذ هیدروژنِ حاصل از MD، توصیفگرهای ساختاری و تبدیل لگاریتمی به کار رفت [39]. این روش‌ها کارایی آموزش و پایداری مدل را بهبود می‌دهند، اما جای مجموعه‌داده‌های آزمایشگاهی بزرگ‌تر و نماینده‌تر را به‌طور کامل نمی‌گیرند. افزون بر این، پیش‌پردازش یا افزایش داده نادرست می‌تواند بیش‌برازش یا «نشت داده» ایجاد کند؛ به‌خصوص زمانی که

نمونه‌های مصنوعی پیش از جداسازی مستقل داده‌ها تولید شوند یا مشاهده‌های بسیار همبسته هم‌زمان در بخش آموزش و آزمون قرار گیرند. خطر نشت داده با تکیه بر روش‌های تقسیم، پیش‌پردازش و افزایش داده‌ای ارزیابی شد که هر مطالعه صریحاً گزارش کرده بود؛ خلاصه آن‌ها در جدول تکمیلی S2 آمده است. چون این مرور فقط بر اطلاعات روش‌شناختی منتشرشده در مقاله‌های اصلی اتکا داشت، در مواردی که داده خام یا کد منبع در دسترس نبود، امکان تأیید مستقلِ جلوگیری از نشت داده وجود نداشت. به‌ویژه بررسی شد که افزایش داده پیش از تقسیم انجام شده است یا پس از آن؛ آیا پیش‌پردازش وابسته به داده صرفاً بر داده آموزشی برازش شده است؛ و آیا مشاهده‌های مرتبط، متناسب با نوع داده، در سطح مستقل مناسبی ــ مانند گرید فولاد، نمونه، تصویر اصلی، رکورد آزمایش، منبع علمی یا پیکربندی محاسباتی ــ جدا شده‌اند یا نه. در داده‌های مبتنی بر TDS، در مرجع [18] احتمال نشت داده ناشی از افزایش نمونه تشخیص داده شد؛ در مقابل، مرجع [20] ابتدا داده‌های اصلی را تقسیم کرد و افزایش داده را به بخش‌های آموزش و اعتبارسنجی محدود ساخت، به‌طوری‌که مجموعه آزمون بدون افزایش داده باقی ماند. در مطالعات تصویری، مرجع [21] تقسیم آموزش و آزمون را پس از افزایش داده انجام داد، بی‌آنکه جداسازی در سطح تصویر اصلی را روشن گزارش کند؛ بنابراین امکان نشت داده رد نشد. مرجع [24] از ارزیابی میان‌نمونه‌ای استفاده کرد و یک نمونه فیزیکی مجزا از فولاد را برای آزمون کنار گذاشت. درباره داده‌های برگرفته از منابع علمی نیز تقسیم تصادفی در سطح رکورد، در نبود گزارش جداسازی بر اساس منبع، فولاد یا کارزار آزمایشی، شاهد کافی برای جلوگیری از نشت تلقی نشد. هرجا ترتیب پیش‌پردازش، افزایش داده و تقسیم یا استقلال مشاهده‌های مرتبط روشن نبود، پیشگیری از نشت داده «تأییدنشده» در نظر گرفته شد، نه مفروض. این یافته‌ها نشان می‌دهند که پیش‌پردازش منضبط و اعتبارسنجی درست برای ساخت مدل‌های قابل‌اعتماد و قابل‌انتقال ضروری‌اند.

در مجموع، این سه منبع داده مکمل یکدیگرند. داده‌های آزمایشگاهی بیشترین انطباق با واقعیت فیزیکی را دارند، اما از نظر حجم و تنوع محدودند. داده‌های حاصل از منابع علمی، گستره مواد و شرایط محیطی را افزایش می‌دهند، ولی به هماهنگ‌سازی و کنترل کیفیت فراوان نیاز دارند. داده‌های محاسباتی تحلیل‌های چندمقیاسیِ تکرارپذیر و مطالعات پارامتری نظام‌مند را ممکن می‌کنند، هرچند اعتبارشان به فرض‌ها و صحت‌سنجی مدل فیزیکی مبنا وابسته است. بررسی مجموعه مطالعات نشان می‌دهد کیفیت، نمایندگی و شیوه پیش‌پردازش داده، مهندسی ویژگی و راهبرد اعتبارسنجی دست‌کم به‌اندازه انتخاب الگوریتم اهمیت دارند؛ عواملی که مستقیماً بر پایداری، تفسیرپذیری و انتقال‌پذیری مدل‌های یادگیری ماشین در مسئله تردی هیدروژنی اثر می‌گذارند.

جدول ۴ مطالعات منتخب را بر اساس حوزه اصلی کاربرد در تردی هیدروژنی، کمیت‌های هدف، مبنای داده، مدل‌های شاخص هوش مصنوعی، دستاوردهای علمی و محدودیت‌های کلیدی جمع‌بندی می‌کند. در بخش ۴٫۲ نیز خانواده‌های مدل از منظر عملکرد، راهبرد اعتبارسنجی، نقاط قوت و ضعف و تناسب آن‌ها با کاربردهای

مختلف تردی هیدروژنی به‌طور انتقادی ارزیابی می‌شوند.

جدول 4. تحلیل مطالعات یادگیری ماشین بر اساس حوزه تردی هیدروژنی، خروجی پیش‌بینی، دستاورد و محدودیت

حوزه مطالعه	هدف و خروجی پیش‌بینی	مبنای داده و ورودی‌ها	مدل‌های شاخص	دستاورد علمی یا مهندسی	نکته انتقادی / محدودیت	منابع
حساسیت به تردی هیدروژنی و غلظت هیدروژن	پیش‌بینی حساسیت به تردی، غلظت هیدروژن در لحظه شکست و حساسیت به هیدروژن	طیف‌های TDS، توصیفگرهای گاوسی، خواص مکانیکی، شرایط شارژ و پارامترهای مواجهه با هیدروژن	ANN، DANN، CANN، LR	غربالگری سریع حساسیت فولاد و پیوند ویژگی‌های آزادشدن هیدروژن با رفتار تخریب	اتکا به داده‌های آزمایشگاهی محدود؛ نیاز به اعتبارسنجی گسترده‌تر در گریدهای فولادی	[18–20]
خواص مکانیکی تحت تأثیر هیدروژن	پیش‌بینی استحکام کششی، افت شکل‌پذیری، ازدیاد طول، کاهش سطح مقطع و شاخص‌های تردی هیدروژنی	ترکیب آلیاژ، ریزساختار، عملیات حرارتی، خواص کششی، فشار هیدروژن، دما و نرخ کرنش	RF، SVM، GBM، CatBoost، AdaBoost، ANN، بهینه‌سازی بیزی	شناسایی متغیرهای مؤثر ماده، ریزساختار و محیط و کمک به انتخاب فولاد سازگار با هیدروژن	عملکرد مدل شدیداً وابسته به تنوع داده؛ اعتبارسنجی بیرونی همچنان محدود است	[28، 31، 32، 34، 35]
چقرمگی شکست و رفتار رشد ترک	پیش‌بینی چقرمگی شکست، نرخ رشد ترک خستگی و گسترش ترک به کمک هیدروژن	ضریب شدت تنش، هندسه ترک، فشار هیدروژن، خواص ماده و غلظت هیدروژن	RF، GB، CatBoost، KNN، BDNN، SVR، Bagged Trees	پشتیبانی از ارزیابی مکانیک شکست و آشکارکردن روابط غیرخطی هیدروژن، بارگذاری و ویژگی‌های ماده	تفاوت روش آزمون، متغیر هدف و اعتبارسنجی مانع مقایسه مستقیم مطالعات است	[23، 29، 30، 36، 41]
تصویربرداری و ارزیابی غیرمخرب عیوب	تشخیص ترک، حباب، ویژگی سطح شکست، عیوب ناحیه جوش و وضعیت آسیب بر پایه نشر آکوستیک	تصاویر SEM و سطح جوش، ویدئوی خوردگی، تصاویر SAM، سیگنال‌های نشر آکوستیک و طیف‌نگاره	CNN، ResNet50، YOLO، U-Net، Mask R-CNN، 1D-CNN، ANN	شناسایی خودکار عیب و ظرفیت پایش برخط آسیب هیدروژنی، از جمله در قطعات زنگ‌نزن جوشکاری‌شده	وابستگی عملکرد به کیفیت تصویر و برچسب، تنوع نمونه و نمایندگی داده آموزشی	[21، 22، 24–27]
نفوذ، تله‌گذاری و رفتار اتمی هیدروژن	پیش‌بینی جذب سطحی، نفوذ، تله‌گذاری، برهم‌کنش مرزدانه، انرژی اتمی و نیرو	شبیه‌سازی DFT، MD و kMC؛ مختصات اتمی، محیط موضعی، توصیفگر SOAP و ساختار مرزدانه	GNN، SchNet، SANNP، RF، میدان نیروی یادگیری ماشین، رگرسیون چندجمله‌ای	شناخت سازوکار انتقال و تله‌گذاری هیدروژن همراه با شتاب‌دهی شبیه‌سازی اتمی	تعمیم معمولاً به سامانه فولادی شبیه‌سازی‌شده و پیکربندی‌های نمونه‌برداری‌شده محدود است	[37، 39، 42]

حوزه مطالعه	هدف و خروجی پیش‌بینی	مبنای داده و ورودی‌ها	مدل‌های شاخص	دستاورد علمی یا مهندسی	نکته انتقادی / محدودیت	منابع
سلامت خط لوله و ارزیابی خرابی	پیش‌بینی احتمال خرابی، فشار ترکیدگی، عمر مفید باقی‌مانده و تخریب سازه‌ای	هندسه ترک و خوردگی، فشار هیدروژن، میدان تنش، نتایج FEM و دانش خبرگی	IFFTA، RFR، GA-BP-NN	پشتیبانی از مدیریت یکپارچگی سازه و ارزیابی ریسک خطوط لوله هیدروژن	بیشتر مطالعات شبیه‌سازی‌محور یا خبره‌محورند و اعتبارسنجی با داده‌های میدانی محدود است	[33، 40، 43]
پیش‌بینی جریان هیدروژن در مقیاس سامانه	پیش‌بینی میدان فشار گذرا و رفتار جریان در خطوط لوله مخلوط H₂/گاز طبیعی	داده‌های فشار، سرعت، آشفتگی و سری زمانی تولیدشده با CFD	OpInf، FNO، Transformer، TFT	ساخت مدل‌های جانشین کم‌هزینه برای تحلیل سریع انتقال هیدروژن در مقیاس سامانه	تمرکز بر بهره‌برداری و پایش خط لوله است، نه پیش‌بینی مستقیم تخریب فولاد	[38]
طراحی فولاد مقاوم به هیدروژن	بهینه‌سازی ترکیب فولاد و مسیر فرایندی برای مقاومت بیشتر در برابر هیدروژن	ترکیب فولاد، عملیات حرارتی، متغیرهای فرایندی، خواص مکانیکی و اهداف عملکرد	بهینه‌سازی بیزی، RF، ANN، SVR، GBR، رگرسیون Ridge	تسریع طراحی چندهدفه و غربالگری فولادهای مقاوم به هیدروژن	محدودیت حجم داده و کمبود پایگاه‌های استاندارد فولاد مانع پیشرفت است	[28]

۴٫۲. مدل‌های هوش مصنوعی: عملکرد، قابلیت اعتماد و انتخاب روش

انتخاب مدل هوش مصنوعی با منشأ داده‌ها، چگونگی نمایش ویژگی‌ها، هدف پیش‌بینی و کاربرد مهندسی پیوند نزدیکی دارد (شکل ۵). ابتدا مطالعات از منظر کاربرد اصلی در تردی هیدروژنی، خروجی‌های پیش‌بینی، مبنای داده، نوع مدل، دستاورد علمی و محدودیت‌ها تحلیل می‌شوند (جدول ۴). سپس خانواده‌های اصلی مدل از دیدگاه روش‌شناختی مقایسه می‌شوند (جدول ۵) و بر پایه تحلیل تفصیلی هر مطالعه در جدول‌های تکمیلی S2 و S3، راهنمای انتخاب مدل مناسب ارائه می‌شود. این منابع کمک می‌کنند روش موردنظر را متناسب با هدف مطالعه تردی هیدروژنی، ساختار و حجم داده، نیاز به تفسیرپذیری و توان پیش‌بینی مورد انتظار انتخاب کنیم.

۴٫۲٫۱. مدل‌های به‌کاررفته در پژوهش‌ها

پژوهش‌های مرورشده از طیف گسترده‌ای از مدل‌ها استفاده کرده‌اند: مدل‌های خطی و آماری مانند LR، RR و BR [18، 19، 31]؛ روش‌های مبتنی بر کرنل مانند SVR، SVM و KNN [30، 31]؛ الگوریتم‌های تجمیعی درختی مانند AdaBoost، CatBoost، GBM، RFR، RF و LightGBM [23، 28–32، 34–36]؛ معماری‌های شبکه عصبی CANN، DANN، ANN و BDNN؛ مدل‌های بینایی ماشین مانند U-Net، YOLO، ResNet50، CNN و Mask R-CNN [21، 22، 24، 25]؛ مدل‌های گرافی و اتمی مانند SchNet، GNN و MLFF؛ روش‌های یادگیری عملگر مانند Transformer، FNO، OpInf و TFT؛ و سامانه‌های خبره فازی مانند IFFTA. انتخاب مدل با

هدف ویژه پژوهش و پارامترهای تردی هیدروژنیِ مورد بررسی رابطه مستقیم دارد. روش‌های متعارف یادگیری ماشین و الگوریتم‌های تجمیعی عمدتاً روی داده‌های جدولی و ساختاریافته آزمایشگاهی یا برگرفته از منابع علمی برای پیش‌بینی حساسیت به تردی، غلظت هیدروژن، خواص مکانیکی تحت تأثیر هیدروژن، چقرمگی شکست، رفتار رشد ترک و طراحی فولاد مقاوم به هیدروژن به کار می‌روند. در مقابل، شبکه‌های یادگیری عمیق، به‌ویژه معماری‌های CNN، بیشتر مناسب تصویر و سیگنال هستند؛ مانند توصیف سطح شکست، تشخیص عیوب جوش و پایش نشر آکوستیک. مدل‌های گرافی، یادگیری عملگر و رویکردهای هدایت‌شده با فیزیک نیز عمدتاً با داده‌های محاسباتی حاصل از DFT، MD، تحلیل اجزای محدود (FEA) و CFD پیوند دارند و رفتار هیدروژن را در مقیاس اتمی، پیوسته یا چندمقیاسی نشان می‌دهند. جزئیات داده‌ها، پیش‌پردازش، ورودی‌ها، خروجی‌ها و پیاده‌سازی مدل‌ها در جدول تکمیلی S2 آمده است.

۴٫۲٫۲. مقایسه خانواده‌های مدل یادگیری ماشین

جدول ۵ خانواده‌های اصلی مدل هوش مصنوعی و یادگیری ماشین را از نظر تناسب با حجم داده به‌صورت انتقادی مقایسه می‌کند. مدل‌های خطی و مبتنی بر کرنل، به‌دلیل سادگی و شفافیت، برای داده‌های ساختاریافته و نسبتاً کوچک مناسب‌اند [50]. مدل KNN در پیش‌بینی چقرمگی شکست ــ کمیتی با روابط نسبتاً غیرخطی ــ عملکرد نسبتاً ضعیفی در حد $R^2 = 0.84$ داشته است که محدودیت آن را در روابط پیچیده نشان می‌دهد [30، 31]. وقتی خواص مکانیکی تحت تأثیر هیدروژن، از جمله استحکام کششی، افت شکل‌پذیری و رشد ترک، حاصل برهم‌کنش پیچیده ترکیب فولاد، فشار هیدروژن، نرخ کرنش و ریزساختار باشند، کارایی این روش‌ها کاهش می‌یابد [31، 51، 52]. مدل‌های تجمیعی برای روابط بسیار غیرخطی در داده‌های محدود، به‌ویژه هنگامی که ویژگی‌های برگرفته از فیزیک برای کاهش بیش‌برازش به آن‌ها افزوده شود، عملکرد بهتری دارند [29].

الگوریتم‌های تجمیعی با ترکیب چند یادگیرنده ضعیف، پایداری پیش‌بینی را افزایش می‌دهند و سوگیری و واریانس را کاهش می‌دهند. این روش‌ها برای داده‌های ناهمگن و رتبه‌بندی اهمیت ویژگی‌ها بسیار به کار می‌روند. در مدل‌های تردی هیدروژنی، درخت‌های تجمیعی با ترکیب توصیفگرهای مکانیکی و الکتروشیمیایی، تخریب ناشی از هیدروژن را پیش‌بینی کرده‌اند. Sun و همکاران (۲۰۲۴) مدل رگرسیون جنگل تصادفی (RFR) را با $R^2 = 0.97$ دقیق‌ترین روش برای ترک‌خوردگی به کمک هیدروژن گزارش کردند؛ نتیجه‌ای که به کنترل واریانس از طریق تجمیع نمونه‌برداری‌شده (Bagging) نسبت داده شد [28]. در مرجع [29] نیز CatBoost با $R^2 = 0.987$ و سازوکار بوستینگ ترتیبی، بهترین مدل تجمیعی شناخته شد. Alikhani Darabi و همکاران (۲۰۲۳) مدل GBM را برای داده‌های ترکیبی با دقت کلی ۸۸٫۶ درصد و دقت مثبت ۸۶ درصد اعتبارسنجی کردند [32]. توازن مناسب میان دقت، تفسیرپذیری و بازده محاسباتی، این مدل‌ها را به مبناهای مقایسه قابل‌اعتماد برای داده‌های جدولی تردی هیدروژنی تبدیل می‌کند.

مدل‌های مبتنی بر شبکه عصبی مصنوعی، نمایش روابط غیرخطی پیچیده میان متغیرهای ماده، محیط و مکانیک را بهبود می‌دهند. در پژوهش Fangnon و همکاران (۲۰۲۰)، شبکه ANN با برقرارکردن رابطه میان غلظت هیدروژن و استحکام مکانیکی به ضریب همبستگی R = 0.99 رسید [18]. شبکه عصبی عمیق بیزی (BDNN) در مطالعه Sari و همکاران (۲۰۲۴) با استفاده از منظم‌سازی بیزی برای مدیریت عدم‌قطعیت شبیه‌سازی‌های اجزای محدود، به $R^2 = 0.945$ دست یافت [41]. همچنین شبکه DANN در پژوهش Malitckii و همکاران (۲۰۲۰) هنگام پیوند دادن توصیفگرهای طیفی و ریزساختاری به R = 0.99 رسید [19]. این نتایج نشان می‌دهند شبکه‌های عصبی می‌توانند داده‌های آزمایشگاهی و محاسباتی متنوع را با یکدیگر تلفیق کنند؛ اما اعتمادپذیری آن‌ها، به‌ویژه در مجموعه‌داده‌های کوچک تردی هیدروژنی، به طراحی معماری، تنظیم ابرپارامترها، منظم‌سازی و اعتبارسنجی دقیق برای جلوگیری از بیش‌برازش وابسته است.

مدل‌های بینایی ماشین و یادگیری از سیگنال، از جمله معماری‌های CNN، ResNet50، U-Net، YOLO، Mask R-CNN و 1D-CNN، برای مسائلی همچون طبقه‌بندی سطح شکست، تشخیص و بخش‌بندی ترک ناشی از هیدروژن، شناسایی عیوب جوش و ارزیابی آسیب با نشر آکوستیک به کار گرفته شده‌اند. Vu و همکاران (۲۰۲۴) مدل‌های U-Net، YOLOv5، YOLOv7، YOLOv8 و Mask R-CNN را برای شناسایی و بخش‌بندی ترک‌های ناشی از هیدروژن در تصاویر میکروسکوپی آکوستیک روبشی مقایسه کردند [24]. در مطالعه [22]، مدل YOLOv8 به دقت آشکارسازی بالایی در حدود mAP@0.50 ≈ 95% دست یافت و توانایی خود را در تشخیص سریع عیوب HIC نشان داد. در مطالعه مستقلی درباره تشخیص حباب در سطح شکست، مدل‌های یادگیری انتقالی مبتنی بر ResNet50 هنگام تفکیک ریخت‌شناسی شکست ناشی از هیدروژن در تصاویر SEM، دقت حدود ۹۶ تا ۹۷٫۶ درصد داشتند [21]. مدل‌های CNN و 1D-CNN برای طبقه‌بندی وضعیت آسیب هیدروژنی از روی سیگنال‌های نشر آکوستیک نیز به‌ترتیب به دقت ۹۸٫۳۷ و ۹۵٫۷ درصد رسیدند [25]. این مطالعات نشان می‌دهند یادگیری عمیق مبتنی بر تصویر و سیگنال می‌تواند توصیفی خودکار و عینی از آسیب هیدروژنی به دست دهد؛ اما تعمیم عملکرد آن همچنان به تنوع داده‌ها، کیفیت برچسب‌گذاری، کیفیت تصویر یا سیگنال و اعتبارسنجی روی فولادها و شرایط هیدروژنی متفاوت وابسته است.

دانش فیزیکی در مطالعات بررسی‌شده، در سطوح متفاوتی وارد مدل‌های یادگیری ماشین شده است (جدول ۵). از میان ۲۶ مطالعه، دو پژوهش دانش فیزیک را عمدتاً با ساخت ویژگی‌های مبتنی بر فیزیک وارد کردند [23، 29] و هفت مطالعه از چارچوب‌های ترکیبی یا کوپل‌شده با فیزیک بهره گرفتند که مدل داده‌محور را با محاسبات یا شبیه‌سازی‌های فیزیکی، مانند روابط مکانیک شکست، DFT، FEM یا MD پیوند می‌دادند [21، 37، 40–43]. یک مطالعه نیز از صورت‌بندی قوی‌تری در یادگیری عملگرِ آگاه از فیزیک استفاده کرد که قیود فیزیکی را مستقیم‌تر در چارچوب یادگیری دخالت می‌داد [38]. نکته مهم آن است که صرفِ استفاده از متغیرهای ورودی دارای معنای فیزیکی معادل «یادگیری آگاه از فیزیک» محسوب نشده است. در رویکردهای

مبتنی بر ویژگی، دانش فیزیکی از طریق توصیفگرهای ساخته‌شده بر اساس فیزیک وارد می‌شود، اما خود الگوریتم یادگیری همچنان داده‌محور می‌ماند. در رویکرد ترکیبی یا کوپل‌شده، یادگیری ماشین به محاسبات و شبیه‌سازی‌های فیزیکی متصل می‌شود. رویکردهای قوی‌ترِ «فیزیک‌تعبیه‌شده» روابط حاکم یا قیود فیزیکی را مستقیماً در صورت‌بندی یادگیری وارد می‌کنند. در میان پژوهش‌های بررسی‌شده، هیچ پیاده‌سازی متعارفی از نوع PINN شناسایی نشد. این تمایز اهمیت دارد؛ زیرا میزان ادغام فیزیک بر تفسیرپذیری مدل، توان برون‌یابی و امکان استفاده فراتر از محدوده داده‌های آموزشی اثر می‌گذارد. ادغام هوش مصنوعی با مکانیک شکست، FEM، روابط انتقال هیدروژن و مدل‌های یکپارچگی سازه‌ای، سازگاری فیزیکی نتایج را تقویت می‌کند. این رویکردها یا شبکه عصبی را با الگوریتم بهینه‌سازی ترکیب می‌کنند یا روابط فیزیکی را در فرایند یادگیری قرار می‌دهند تا همگرایی بهبود یابد، بیش‌برازش محدود شود و وفاداری به سازوکارهای فیزیکی حفظ گردد. برای نمونه، مدل GA-BP-NN در مرجع [43] با بهینه‌سازی وزن‌ها و ابرپارامترهای شبکه، برای پیش‌بینی تخریب ناشی از هیدروژن در خط لوله به $R^2 = 0.989$ رسید. در مقیاس اتمی، مدل‌های SANNP به‌کاررفته در مطالعات Asta و همکاران (۲۰۲۲) و Yuan و همکاران (۲۰۲۵) انرژی کل سامانه را به‌صورت مجموع سهم انرژی اتم‌ها بیان کردند و میانگین خطای پیش‌بینی نیرو در حدود $0.16\ \text{eV Å}^{-1}$ داشتند [39، 42]. بنابراین این مدل‌ها پلی مؤثر میان یادگیری داده‌محور و شبیه‌سازی فیزیکی می‌سازند و در مقیاس‌های مختلف تردی هیدروژنی، پیش‌بینی‌های دقیق و دارای معنای فیزیکی فراهم می‌کنند [29، 40، 41، 43].

چارچوب‌های یادگیری عملگر، از جمله Transformer، FNO، OpInf و TFT، روابط حاکم بر انتقال هیدروژن و جریان را با یادگرفتن نگاشت میان فضاهای جوابِ پُربُعد تقریب می‌زنند؛ به همین دلیل می‌توانند جانشین‌هایی کم‌هزینه برای شبیه‌سازی‌های تکراری CFD یا معادلات دیفرانسیل جزئی (PDE) باشند. بسته به صورت‌بندی، این روش‌ها از مدل‌های جانشینِ عمدتاً داده‌محور تا چارچوب‌های پیشرفته‌تر آگاه از فیزیک تغییر می‌کنند. Almeida و همکاران (۲۰۲۳) نشان دادند OpInf می‌تواند انتقال گذرای گاز هیدروژن را با ریشه میانگین مربعات خطا (RMSE) برابر 34.8 Pa پیش‌بینی کند و در مقایسه با شبیه‌سازی‌های مرتبه‌کامل، هزینه محاسباتی را به‌شدت کاهش دهد [38]. منطق فازی و سامانه‌های خبره رویکردی مکمل برای مسئله‌هایی هستند که در آن‌ها داده کم، اطلاعات ناقص یا مسیر خرابی نامطمئن است. این روش‌ها با بازنمایی دانش مهندسی به‌صورت قواعد زبانی و روابط فازی، به‌جای تکیه صرف بر پیش‌بینی عددی، ارزیابی ریسکِ قابل‌تفسیر را پشتیبانی می‌کنند. برای نمونه، Qin و همکاران (۲۰۲۴) از IFFTA برای مدل‌سازی عدم‌قطعیت و انتشار خرابی در ترک‌خوردگی به کمک هیدروژن استفاده کردند و ارزش این رویکرد را در ارزیابی یکپارچگی خط لوله بر مبنای ریسک، به‌ویژه در محدودیت داده‌های متعارف، نشان دادند [33].

نتیجه کلی این مقایسه آن است که هیچ خانواده‌ای از مدل‌های هوش مصنوعی در همه کاربردهای تردی هیدروژنی، به‌طور ثابت از دیگر خانواده‌ها بهتر نیست. انتخاب مدل باید از هدف پژوهش، پارامترهای مورد

مطالعه، مقیاس فیزیکی تحلیل، ویژگی‌های مجموعه‌داده، نیاز محاسباتی، تفسیرپذیری و نحوه مواجهه با عدم‌قطعیت آغاز شود. روش‌هایی که دانش فیزیکی را در سطح ویژگی‌ها، اتصال مدل‌ها یا صورت‌بندی خود یادگیری وارد می‌کنند، ظرفیت ویژه‌ای برای افزایش سازگاری فیزیکی و برون‌یابی فراتر از گستره آماری داده‌های آموزش دارند؛ اما قابلیت اعتماد آن‌ها باید با اعتبارسنجی بیرونیِ دقیق روی گریدهای فولادی و شرایط سرویس هیدروژنی متنوع تأیید شود.

جدول 5. ارزیابی عملکرد خانواده‌های مدل یادگیری ماشین در مطالعات تردی هیدروژنی فولاد

خانواده مدل	الگوریتم‌های شاخص	کاربردهای معمول	تناسب با حجم داده	پایداری و قابلیت اتکا	تفسیرپذیری و عدم‌قطعیت	منابع
مدل‌های خطی و آماری	LR، RR، BR	پیش‌بینی مبنای حساسیت به تردی، رشد ترک و افت خواص مکانیکی	مناسب‌تر برای داده‌های ساختاریافته کم‌حجم	مقاوم به بیش‌برازش در روابط ساده، اما ضعیف در رفتار بسیار غیرخطی	تفسیرپذیری بالا؛ رگرسیون بیزی می‌تواند عدم‌قطعیت را برآورد کند	[18، 23، 31]
مدل‌های مبتنی بر کرنل	KNN، SVM، SVR	چقرمگی شکست، شاخص‌های تردی و پیش‌بینی حساسیت	داده‌های کوچک تا متوسط	مناسب در کمبود داده، اما حساس به کرنل، مقیاس‌بندی و ابرپارامتر	تفسیرپذیری متوسط؛ سنجش عدم‌قطعیت معمولاً محدود	[30، 31]
مدل‌های تجمیعی درختی	RF، RFR، GB، GBM، CatBoost، AdaBoost، LightGBM، Bagged Trees	پیش‌بینی خواص مکانیکی، چقرمگی شکست، رشد ترک خستگی و طبقه‌بندی تردی	داده‌های جدولی ناهمگن کوچک تا متوسط	عموماً پایدار در برابر روابط غیرخطی، ورودی مخلوط، نویز و کمبود نسبی داده	تفسیرپذیری متوسط تا بالا از اهمیت ویژگی و SHAP؛ عدم‌قطعیت با تجمیع یا بازه پیش‌بینی قابل‌تقریب است	[23، 28–32، 34–36]
شبکه‌های عصبی مصنوعی و مدل‌های عصبی عمیق	ANN، DANN، CANN، BDNN، BP-NN	پیش‌بینی تردی از TDS، غلظت هیدروژن، رفتار شکست و پاسخ سازه	داده متوسط یا داده کوچکِ تقویت‌شده با افزایش داده یا شبیه‌سازی	توان غیرخطی بالا، اما حساس به معماری، تنظیم و بیش‌برازش	تفسیرپذیری کم تا متوسط؛ شبکه بیزی می‌تواند عدم‌قطعیت را نمایش دهد	[18–20، 41، 43]
مدل‌های بینایی ماشین و یادگیری سیگنال	ResNet50، YOLO، U-Net، Mask R-CNN، 1D-CNN	تشخیص ترک، حباب، سطح شکست، عیب جوش و آسیب صوتی	عموماً نیازمند داده تصویری/سیگنالی برچسب‌خورده متوسط تا زیاد	در تصویر و تنوع عیوبِ نماینده قوی، اما نسبت به جابه‌جایی دامنه داده حساس	تفسیرپذیری متوسط با نقشه برجستگی و توضیح بصری؛ عدم‌قطعیت به‌ندرت محاسبه می‌شود	[21، 22، 24–27]

خانواده مدل	الگوریتم‌های شاخص	کاربردهای معمول	تناسب با حجم داده	پایداری و قابلیت اتکا	تفسیرپذیری و عدم‌قطعیت	منابع
شبکه‌های عصبی گرافی و میدان‌های نیروی یادگیری ماشین	SchNet، M-SchNet، SANNP، MLFF	جذب، نفوذ و تله‌گذاری هیدروژن، رفتار مرزدانه و گسترش ترک	نیازمند داده اتمی گسترده از DFT یا MD	دقت بالا در محدوده پیکربندی‌های نمونه‌برداری‌شده	نمایش ساختاری معنادار از نظر فیزیکی، اما استدلال درونی پیچیده؛ عدم‌قطعیت وابسته به پوشش پیکربندی‌ها	[37، 39، 42]
مدل‌های دارای ویژگی فیزیکی و مدل‌های کوپل‌شده/ترکیبی با فیزیک	مدل‌های تجمیعی با ویژگی‌های مبتنی بر فیزیک؛ یادگیری ماشین همراه با مکانیک شکست، FEM، MD و DFT، محاسبات یا شبیه‌سازی فیزیکی	پیش‌بینی شکست و خستگی، فشار ترکیدگی، انتقال و نفوذ هیدروژن، رفتار اتمی و تحلیل چندمقیاسی	داده‌های آزمایشگاهی یا شبیه‌سازی فیزیکی کوچک تا متوسط	تلفیق فیزیک می‌تواند واقع‌گرایی و برون‌یابی را بهبود دهد؛ پایداری به کیفیت داده و اعتبار دانش/مدل فیزیکی وابسته است	روش مبتنی بر ویژگی تناسب فیزیکی را بدون اعمال مستقیم قوانین حاکم بیشتر می‌کند؛ روش ترکیبی یادگیری ماشین را با محاسبات فیزیکی ادغام می‌کند	[21، 23، 29، 37، 40–43]
مدل‌های یادگیری عملگر و جانشین	OpInf، FNO، Transformer، TFT	پیش‌بینی سریع میدان‌های گذرای فشار و جریان خطوط لوله H/گاز طبیعی	داده مکانی–زمانی بزرگ CFD	مناسب برای پیش‌بینی تکراری میدان، اما حساس به پیچیدگی آشفتگی و پوشش داده	از مدل جانشین داده‌محور تا صورت‌بندی آگاه از فیزیک؛ سازگاری فیزیکی تابع شیوه درج قیود و روابط حاکم است	[38]
سامانه‌های فازی و خبره	IFFTA	احتمال خرابی و ارزیابی ریسک در داده‌های کم یا نامطمئن	داده کوچک، ناقص یا استخراج‌شده از نظر خبرگان	مناسب هنگام کمبود داده عددی؛ وابسته به کیفیت قواعد خبرگی	تفسیرپذیری کیفی بالا و برخورد صریح با عدم‌قطعیت زبانی	[33]

انتخاب مدل باید بر اساس هدف مهندسی، ویژگی‌های مجموعه‌داده و الزامات اعتبارسنجی انجام شود، نه بر پایه فرض برتری همیشگی یک الگوریتم.

۴٫۲٫۳. معیارهای عملکرد و اعتبارسنجی مدل

عملکرد مدل‌های رگرسیونی معمولاً با ضریب تعیین (R^2)، میانگین قدرمطلق خطا (MAE)، میانگین مربعات خطا (MSE) و ریشه میانگین مربعات خطا (RMSE) ارزیابی می‌شود [18، 23، 29]. در مطالعات طبقه‌بندی و بینایی ماشین نیز معیارهایی مانند صحت طبقه‌بندی (Accuracy)، دقت مثبت (Precision)، بازخوانی

(Recall)، مساحت زیر منحنی ROC یا ROC-AUC، نسبت اشتراک به اجتماع (IoU) و میانگین دقت متوسط (mAP) گزارش می‌شوند [24، 26]. چون هر معیار وجه متفاوتی از عملکرد را نشان می‌دهد، ارزیابی معتبر باید بر چند شاخص مکمل تکیه کند، نه فقط یک عدد [53–55].

اعتبارسنجی مدل برای سنجش اعتمادپذیری به همان اندازه اهمیت دارد. در مطالعات بررسی‌شده از تقسیم آموزش–اعتبارسنجی–آزمون، اعتبارسنجی متقاطع، بهینه‌سازی بیزی، الگوریتم‌های ژنتیک، توقف زودهنگام و منظم‌سازی برای بهبود پیش‌بینی استفاده شده است [23، 43]. بااین‌حال، شیوه‌های اعتبارسنجی و تنظیم ابرپارامترها همواره یکسان یا کامل گزارش نشده‌اند؛ در نتیجه مقایسه مستقیم و بازتولید مستقل دشوار است. جزئیات این روش‌ها در جدول تکمیلی S3 گردآوری شده است. بررسی دقیق نشان داد فقط ۲ مطالعه از ۲۶ مطالعه، به‌روشنی داده‌های مستقل و بیرونی برای اعتبارسنجی به کار برده‌اند [31، 40]. پنج پژوهش دیگر [18، 19، 26، 28، 36] از روش‌های نسبتاً قوی‌تر، از جمله آزمون روی گریدهای فولادی دیده‌نشده، تأیید آزمایشگاهیِ آینده‌نگر یا ارزیابی در شرایط آزمایشی تازه استفاده کرده‌اند، اما این آزمون‌ها از نظر آزمایشگاه یا محیط سرویس کاملاً مستقل نبوده‌اند. دیگر مطالعات عمدتاً به تقسیم کنارگذاری‌شده آموزش/آزمون، اعتبارسنجی متقاطع یا آزمون در همان چارچوب آزمایشگاهی یا محاسباتی تکیه داشتند. اعتبارسنجی مستقل در گریدهای مختلف، شرایط شارژ هیدروژن و محیط‌های واقعی سرویس هنوز رایج نیست؛ زیرا مجموعه‌داده‌های استاندارد و عمومی برای تردی هیدروژنی کمیاب‌اند. بنابراین، عملکرد بالای گزارش‌شده برای بسیاری از مدل‌ها بیشتر نشان‌دهنده موفقیت آن‌ها در محدوده داده‌های بررسی‌شده است، نه تأیید توان کاربرد گسترده در صنعت. برای اعتماد بیشتر به پیش‌بینی‌های آینده باید از داده‌های بیرونی استفاده شود و توسعه مدل، برآورد عدم‌قطعیت و مقایسه با روش‌های تجربی یا مبتنی بر فیزیکِ معتبر به‌صورت شفاف گزارش شود.

مدل‌های شبکه عصبی مصنوعی برای پیش‌بینی حساسیت به هیدروژن از داده‌های TDS، ضرایب همبستگی نزدیک ۰٫۹۹ به دست آوردند [18، 19]. مدل‌های CatBoost و گرادیان بوستینگ نیز در پیش‌بینی کمیت‌های مرتبط با شکست و رشد ترک خستگی، R^2 نزدیک ۰٫۹۹ گزارش کردند [23، 29]. در کاربردهای تصویری، مدل‌های یادگیری عمیق برای آشکارسازی ترک به mAP بالاتر از ۰٫۹۵ و برای تشخیص نشر آکوستیک به صحت طبقه‌بندی بیش از ۹۸ درصد دست یافته‌اند [24، 25]. بااین‌حال، ناهمگونی متغیرهای هدف، مقایسه مستقیم دقت مدل‌ها در مطالعات متفاوت را محدود می‌کند. حتی در کاربردهای مشابه، تعریف متغیر هدف، واحد اندازه‌گیری، شرایط آزمایش، روش سنجش و نمایش داده با هم تفاوت دارند. در نتیجه اعداد عملکرد باید با توجه به هدف پیش‌بینی و شرایط همان مطالعه تفسیر شوند، نه اینکه میان خروجی‌های اساساً متفاوت به‌صورت مستقیم رتبه‌بندی شوند. به همین دلیل، مقایسه این مرور بیشتر بر تناسب روش‌های هوش مصنوعی با کاربرد موردنظر در تردی هیدروژنی، ویژگی‌های داده، اعتبارسنجی و هدف مهندسی متمرکز است. کیفیت داده، نمایش ویژگی‌ها، پیش‌پردازش و اعتبارسنجی دقیق نیز مستقیماً بر عملکرد پیش‌بینی اثر دارند.

۴/۲/۴. راهنمای انتخاب مدل

جدول‌های ۴ و ۵ به همراه جدول‌های تکمیلی S2 و S3، چارچوبی عملی برای انتخاب روش هوش مصنوعی بر پایه هدف مهندسی، ویژگی‌های داده و نیازهای پیش‌بینی فراهم می‌کنند.

برای داده‌های ساختاریافته آزمایشگاهی و برگرفته از منابع علمی، مدل‌های یادگیری تجمیعی مانند RF، AdaBoost، Gradient Boosting، CatBoost و Bagged Trees عموماً توازن مناسبی میان دقت پیش‌بینی، پایداری و امکان تفسیر ویژگی‌ها برقرار می‌کنند. این روش‌ها با موفقیت برای پیش‌بینی خواص مکانیکی تحت تأثیر هیدروژن، چقرمگی شکست، حساسیت به تردی هیدروژنی، کاهش سطح مقطع و رشد ترک خستگی به کار رفته‌اند [23، 28، 31]. روش‌های مبتنی بر کرنل برای داده‌های نسبتاً کوچک مناسب‌اند، به‌ویژه زمانی که باید بدون معماری‌های بسیار پیچیده، روابط غیرخطی نمایش داده شوند [30، 36]. در مقابل، مدل‌های شبکه عصبی مصنوعی در حالتی مناسب‌ترند که رفتار تردی هیدروژنی حاصل برهم‌کنش غیرخطی و به‌شدت وابسته میان غلظت هیدروژن، ترکیب فولاد، ریزساختار، شرایط بارگذاری و پارامترهای شارژ هیدروژن باشد [35، 41].

برای شناسایی و توصیف آسیب هیدروژنی از روی تصویر و سیگنال، معماری‌های مبتنی بر CNN انتخاب مناسبی هستند؛ زیرا ویژگی‌های شکست، ترک، عیب و نشر آکوستیک را مستقیماً از تصویر و سیگنال استخراج می‌کنند. مدل‌های CNN، AlexNet، Mask R-CNN، U-Net، YOLO، ResNet50 و 1D-CNN برای طبقه‌بندی سطوح شکست، بخش‌بندی ترک ناشی از هیدروژن، تشخیص حباب هیدروژن، شناسایی نقص جوش و طبقه‌بندی آسیب هیدروژنی از روی سیگنال‌های نشر آکوستیک استفاده شده‌اند [22، 24، 27]. ازاین‌رو، این مدل‌ها برای ارزیابی خودکار و عینی آسیب‌های سطحی و زیرسطحی ناشی از هیدروژن ارزش ویژه‌ای دارند.

برای مطالعات محاسباتی و چندمقیاسیِ تردی هیدروژنی، شبکه‌های عصبی گرافی (GNN)، میدان‌های نیروی یادگیری ماشین، چارچوب‌های یادگیری عملگر و مدل‌های هدایت‌شده با فیزیک مناسب‌ترند؛ زیرا می‌توانند داده‌های حاصل از FEM، MD، DFT یا CFD و مکانیک شکست را برای مطالعه جذب سطحی هیدروژن، نفوذ، تله‌گذاری، رشد ترک، فشار ترکیدگی خط لوله و عمر مفید باقی‌مانده به کار گیرند [37، 40]. مدل‌های مبتنی بر SchNet برای برهم‌کنش‌های اتمی Fe–H و نفوذ هیدروژن به‌ویژه مناسب‌اند؛ درحالی‌که مدل‌های جنگل تصادفیِ هدایت‌شده با فیزیک، BDNN و GA-BP-NN برای پیش‌بینی چقرمگی شکست، رشد ترک، فشار ترکیدگی و تخریب خط لوله مناسب‌ترند [40]. وقتی تقریب سریع شبیه‌سازی انتقال یا جریان گاز هیدروژن موردنیاز باشد، روش‌های یادگیری عملگر و مدل مرتبه‌کاهش‌یافته، مانند Transformer، FNO، OpInf و TFT، تناسب بیشتری دارند [38].

منابع سخت‌افزاری و زمان محاسبه نیز ملاحظاتی عملی و مهم در انتخاب مدل‌اند. گزارش کمی این دو عامل در مطالعات بررسی‌شده محدود بود و عمدتاً به بینایی ماشین برای طبقه‌بندی تصویر، شناسایی شیء یا

بخش‌بندی مربوط می‌شد؛ فقط یک کاربرد GNN غیرتصویری نیز آمار محاسباتی کمی ارائه کرده بود (جدول ۶). در کاربردهای بینایی ماشین، سخت‌افزار از رایانه‌ای معمولی با ۱۶ گیگابایت RAM و کارت NVIDIA RTX 3060 تا ایستگاه کاری دارای ۲۵۶ گیگابایت RAM و چهار کارت NVIDIA RTX 6000 متفاوت بود [22، 27]. یک مطالعه چهار معماری CNN ازپیش‌آموزش‌دیده DenseNet-121، ResNet-50، VGG-19 و EfficientNet-B4 را برای طبقه‌بندی دوکلاسه شکست ترد/چکش‌خوار مقایسه کرد. زمان آموزش و دقت آن‌ها به‌ترتیب ۱۶۸ دقیقه/۹۸٫۸۰ درصد، ۳۶ دقیقه/۹۹٫۱۰ درصد، ۱۵ دقیقه/۹۸٫۸۰ درصد و ۶۵ دقیقه/۹۸٫۹۵ درصد بود؛ یعنی آموزش طولانی‌تر الزاماً پیش‌بینی دقیق‌تری نداشت [26]. در مقابل، مدل جانشین مبتنی بر GNN روی تنها یک هسته پردازنده Intel i5-13600KF زمان استنتاج حدود ۱٫۷ ثانیه داشت، درحالی‌که محاسبه فیزیکی متناظر ۱۷,۲۸۰ ثانیه یا ۴٫۸ ساعت طول می‌کشید [37]. بیشتر مطالعات الگوریتم‌های متعارف، مانند رگرسیون خطی، GB، RF، KNN، SVM و CatBoost، نوع سخت‌افزار و زمان واقعی اجرا را گزارش نکرده‌اند. این پژوهش‌ها عموماً از داده‌های ساختاریافته‌ای با چند ده تا چند هزار مشاهده استفاده کرده‌اند. با توجه به حجم نسبتاً کم داده‌ها و نبود گزارش نیاز به سخت‌افزار ویژه، چنین کاربردهایی ممکن است روی رایانه‌های اداری متعارف نیز اجراشدنی باشند؛ البته زمان اجرا به اندازه داده، جست‌وجوی ابرپارامتر، اعتبارسنجی متقاطع و شیوه پیاده‌سازی نرم‌افزار وابسته است. کاربردهای سنگین‌تر، شامل پردازش تصویر، شبکه عصبی عمیق یا تولید داده مبتنی بر شبیه‌سازی فیزیکی، ممکن است به GPU مستقل یا منابع پردازشی پرقدرت‌تری نیاز داشته باشند. اعداد جدول ۶ باید نمونه‌هایی وابسته به هر مطالعه تلقی شوند، نه الزام سخت‌افزاری جهان‌شمول برای خانواده‌ای از مدل‌ها.

جدول 6. منابع محاسباتی و زمان‌های گزارش‌شده در نمونه‌هایی از مطالعات یادگیری ماشین در تردی هیدروژنی فولاد

مطالعه	رویکرد و کاربرد	سخت‌افزار گزارش‌شده	زمان محاسبه یا آموزش	برداشت کاربردی
[37]	SchNet/GNN؛ پیش‌بینی اتمی یا خواص، بدون تصویر	یک هسته CPU مدل Intel i5-13600KF	استنتاج حدود ۱٫۷ ثانیه، در برابر ۱۷,۲۸۰ ثانیه (۴٫۸ ساعت) برای محاسبه فیزیکی متناظر	کفایت پردازنده مصرفی برای استنتاج؛ شتاب‌دهی در مرتبه 10^4 برابر
[27]	شبکه AlexNet CNN برای طبقه‌بندی تصاویر SEM	Intel Xeon W-2295؛ رم ۲۵۶ گیگابایت؛ ۴ عدد NVIDIA Quadro RTX 6000 با حافظه ۲۴ گیگابایت برای هرکدام	حداکثر ۱۵۰ دوره آموزش؛ زمان گزارش نشده است	استفاده از ایستگاه کاری چند GPU
[22]	YOLOv4 برای آشکارسازی مبتنی بر تصویر	AMD Ryzen 7 5800H؛ رم ۱۶ گیگابایت؛ NVIDIA RTX 3060 با حافظه ۶ گیگابایت	حداکثر ۶۰۰۰ دسته (Batch)؛ زمان گزارش نشده است	استفاده از GPU مستقل در رده مصرفی

مطالعه	رویکرد و کاربرد	سخت‌افزار گزارش‌شده	زمان محاسبه یا آموزش	برداشت کاربردی
[26]	CNN: VGG-19، ResNet-50، و DenseNet-121 و EfficientNet-B4؛ طبقه‌بندی تصویر شکست	گزارش نشده است	به‌ترتیب زمان آموزش (دقیقه)/دقت: ۱۶۸/۹۸/۸۰٪؛ ۳۶/۹۹/۱۰٪؛ ۱۵/۹۸/۸۰٪؛ ۶۵/۹۸/۹۵٪	زمان آموزش متناسب با معماری از ۱۵ تا ۱۶۸ دقیقه تغییر کرده است
[24]	YOLOv8-seg؛ بخش‌بندی عیب HIC در تصاویر B-scan	Intel Core i7-12700؛ رم ۶۴ گیگابایت؛ NVIDIA RTX 3090	حداکثر ۵۰۰ دوره آموزش؛ زمان گزارش نشده است	استفاده از GPU مستقل پرقدرت

تنها مطالعاتی در جدول آمده‌اند که اطلاعات کمی درباره منابع محاسباتی یا زمان پردازش گزارش کرده‌اند. تعداد دوره‌ها و دسته‌های آموزشی، حجم کار محاسباتی را بیان می‌کند و معادل زمان واقعی اجرا نیست.

۴٫۳. چالش‌ها، شکاف‌های پژوهشی و چشم‌انداز آینده

با وجود پیشرفت‌های امیدوارکننده هوش مصنوعی در تردی هیدروژنی فولاد، چالش‌هایی همچنان قابلیت اعتماد، تکرارپذیری و کاربرد وسیع‌تر مهندسی را محدود می‌کنند. پژوهش‌های کنونی بیشتر بر پیش‌بینی حساسیت به تردی هیدروژنی، ارزیابی خواص مکانیکی و تحلیل شکست با مجموعه‌داده‌های نسبتاً کوچک آزمایشگاهی یا برگرفته از منابع تمرکز دارند؛ در مقابل، مطالعات کمتری انتقال چندمقیاسی هیدروژن، یکپارچگی سازه‌ایِ تلفیقی، پایش در مقیاس میدان یا یادگیری هدایت‌شده با فیزیک را بررسی کرده‌اند [28، 31، 35]. ازاین‌رو، پیشبرد پیش‌بینی تردی هیدروژنی با هوش مصنوعی نه‌تنها به توسعه مدل، بلکه به بهبود کیفیت داده، اعتبارسنجی و ادغام دانش فیزیکی نیز نیاز دارد.

یکی از محدودیت‌های اصلی، کمبود مجموعه‌داده‌های استاندارد، نماینده شرایط واقعی و در دسترس عموم است. مطالعات از نظر گرید فولاد، روش شارژ هیدروژن، شیوه آزمایش، ویژگی‌های ورودی، تعریف متغیر هدف و معیار ارزیابی بسیار متفاوت‌اند؛ مسئله‌ای که مقایسه مستقیم و اعتبارسنجی مستقل را دشوار می‌کند. کمبود داده‌های آزمایشگاهی شدیدتر است، زیرا آزمون هیدروژن به تجهیزات گران، تخصصی و دارای الزامات ایمنی بالا نیاز دارد. اجرای چنین آزمایش‌هایی مستلزم محفظه‌های فشار بالا تا ۱۰۰۰ بار، دستگاه‌های آزمون سروهیدرولیک، تجهیزات پیشرفته مدیریت گاز و آزمایشگاه‌های ضدانفجار است. هزینه ایجاد و بهره‌برداری این تأسیسات به سرمایه‌گذاری قابل‌توجهی نیاز دارد که در منابع معمولاً بین ۱۵۰ هزار تا ۵۰۰ هزار دلار آمریکا گزارش شده است؛ هزینه‌های جاری رعایت ایمنی، مصرف هیدروژن و نگهداری تجهیزات نیز به آن افزوده می‌شود [56–58]. آزمون با هیدروژن خالص دشواری‌های دیگری دارد: این گاز بسیار آتش‌گیر است، محدوده اشتعال آن در هوا تقریباً ۴ تا ۷۵ درصد است و با انرژی بسیار اندکی مشتعل می‌شود. بنابراین، آزمایش باید در تأسیسات محافظت‌شده در برابر انفجار، مجهز به تشخیص نشت، تهویه کنترل‌شده و رویه‌های ایمنی سخت‌گیرانه انجام شود. تجهیزات آزمون و اتوکلاوها نیز باید از مواد سازگار با هیدروژن ساخته شوند تا از نشت و تخریب به کمک

هیدروژن جلوگیری شود؛ خلوص گاز و شرایط مواجهه هم باید برای تکرارپذیری دقیق کنترل شوند [57، 59]. این محدودیت‌های فنی و ایمنی، آزمون با هیدروژن خالص را بسیار گران‌تر از آزمون در اتمسفرهای مخلوط هیدروژنی می‌کنند. ازاین‌رو بسیاری از مطالعات، بسته به شرایط سرویس مورد بررسی، مخلوط‌هایی با حدود ۵ تا ۳۰ درصد هیدروژن و گاه تا ۵۰ درصد به کار می‌برند [11، 59]. این تفاوت‌ها در غلظت هیدروژن، روش شارژ و شرایط آزمون، ناهمگونی مجموعه‌داده‌ها را بیشتر می‌کند.

استانداردهای تثبیت‌شده آزمون و راهنماهای سازگاری مواد با هیدروژن، مبنایی برای آزمایش‌های هماهنگ‌تر فراهم می‌کنند [47، 48، 60–62]، اما هنوز در روش‌های آزمون مکانیک شکست و گزارش نتایج شکاف‌های مهمی وجود دارد. استانداردهایی مانند ISO 11114-4:2017 [60] و ASTM STP 962 [62] روش‌های رسمی ارزیابی سازگاری با هیدروژن و حساسیت به تردی هیدروژنی را ارائه می‌کنند. بااین‌حال، ناهمسانی پروتکل‌های آزمایش و گزارش‌دهی، مقایسه نتایج آزمایشگاه‌های مختلف و ساخت پایگاه‌های داده بزرگ و استاندارد برای آموزش و مقایسه مدل‌ها را دشوار می‌سازد [47، 48، 60–62]. دسترس‌پذیری داده‌ها هم یکنواخت نیست: برخی مطالعات داده‌های تکمیلی، مخزن عمومی یا کد منبع ارائه می‌کنند، اما مجموعه‌داده‌های بسیاری در دسترس نیستند یا فقط بخشی از آن‌ها را می‌توان از شکل‌ها و جدول‌های منتشرشده بازسازی کرد. این محدودیت‌ها بازتولید نتایج، مقایسه مدل‌ها، آموزش مجدد و اعتبارسنجی روی فولادها و محیط‌های سرویس دیده‌نشده را دشوار می‌کنند و با چالش‌های گسترده‌تر حوزه یادگیری ماشین هم‌راستا هستند [56، 57]. پیشرفت آینده به ایجاد پایگاه‌های باز و استاندارد تردی هیدروژنی وابسته خواهد بود که داده‌های آزمایشگاهی، منابع علمی، محاسباتی، تصویری و پایش میدانی را همراه با فراداده و پروتکل‌های گزارش‌دهی هماهنگ یکپارچه کنند.

چالش مهم دیگر، کاربرد محدود اعتبارسنجی بیرونیِ سخت‌گیرانه و سنجش کمی عدم‌قطعیت است. بیشتر مطالعات از تقسیم تصادفی آموزش/آزمون یا اعتبارسنجی متقاطع داخلی استفاده کرده‌اند، درحالی‌که اعتبارسنجی مستقل بین آزمایشگاه‌ها، گریدهای فولاد، شرایط شارژ هیدروژن و محیط‌های عملیاتی مختلف به‌ندرت انجام شده است. ازاین‌رو، ضریب تعیین یا دقت بالا و خطای پیش‌بینی پایین، به‌ویژه برای داده‌های کم‌حجم یا ناهمگن، لزوماً به معنای تعمیم‌پذیری مدل نیست [53، 54]. پژوهش‌های آینده باید مجموعه‌داده‌های مستقل بیرونی، اعتبارسنجی بر اساس گرید فولاد، تحلیل حساسیت، برآورد عدم‌قطعیت و مقایسه نظام‌مند با مدل‌های تجربی و فیزیکی معتبر را در برنامه خود بگنجانند [29، 40، 41].

تلفیق دانش فیزیکی با مدل‌های هوش مصنوعی نیز هنوز در آغاز راه است. شبکه‌های عصبی گرافی، میدان‌های نیروی یادگیری ماشین و روش‌های ترکیبی یا هدایت‌شده با فیزیک، توان امیدوارکننده‌ای در مدل‌سازی جذب سطحی، نفوذ و تله‌گذاری هیدروژن، شکست و رفتار خط لوله نشان داده‌اند [37، 39، 42]، اما هنوز سهم کوچکی از ادبیات موجود را تشکیل می‌دهند. ادغام نزدیک‌تر مکانیک شکست، نظریه نفوذ هیدروژن، شبیه‌سازی

اتمی و مشاهده‌های آزمایشگاهی می‌تواند واقع‌گرایی فیزیکی، تفسیرپذیری و برون‌یابی فراتر از داده‌های آموزش را به‌طور چشمگیری بهبود دهد [16، 17]. این مسیر همچنین امکان ایجاد چارچوب‌های چندمقیاسی را فراهم می‌کند که رفتار اتمی هیدروژن، تحول ریزساختار، انتقال در محیط پیوسته، فرایند شکست و عملکرد سازه در مقیاس صنعتی را به هم پیوند دهند. موضوع مهم دیگر تفسیرپذیری مدل است. تحلیل اهمیت ویژگی‌ها، روش‌های SHAP و ابزارهای تصویری مانند Grad-CAM می‌توانند عناصر آلیاژی مؤثر، متغیرهای محیطی و ویژگی‌های شکست را شناسایی کنند [21، 23، 55]. بااین‌حال، اهمیت آماری الزاماً رابطه علت و معلولیِ فیزیکی را نشان نمی‌دهد؛ توضیحات مدل باید نظام‌مند ارزیابی شوند و در کنار دانش متالورژی و اصول مکانیک شکست تفسیر گردند [63].

در مجموع، پیشرفت آینده به داده‌های باز و استاندارد، اعتبارسنجی بیرونی دقیق، سنجش عدم‌قطعیت، هوش مصنوعی توضیح‌پذیر، مقایسه میان مطالعات و ادغام قوی‌تر دانش فیزیکی در چارچوب‌های یادگیری ماشین وابسته است. باید به‌ویژه بر رویکردهای چندمقیاسی و فیزیک‌تعبیه‌شده تمرکز کرد؛ رویکردهایی که یادگیری داده‌محور را با سازوکارهای حاکم بر انتقال و تله‌گذاری هیدروژن، آغاز آسیب و شکست ترکیب می‌کنند. پرداختن به این اولویت‌ها پایداری، انتقال‌پذیری و قابلیت کاربرد مهندسی مدل‌ها را افزایش می‌دهد و گذار آن‌ها را از ابزارهای پژوهشیِ دارای عملکرد بالا به سامانه‌های پشتیبان تصمیمِ قابل‌اعتماد برای زیرساخت هیدروژن و طراحی فولاد تسهیل می‌کند.

۵. نتیجه‌گیری

این مرور نشان می‌دهد هوش مصنوعی با تلفیق داده‌های آزمایشگاهی، برگرفته از منابع علمی، محاسباتی و تصویری، به ابزاری مؤثر برای پیشبرد پژوهش‌های تردی هیدروژنی در فولاد تبدیل شده است. مقاله ارزیابی جامعی از کاربردهای هوش مصنوعی و یادگیری ماشین، از ویژگی‌های مجموعه‌داده و اهداف پیش‌بینی تا خانواده مدل، روش اعتبارسنجی و کاربرد مهندسی ارائه می‌دهد. همچنین نقشه‌راهی برای انتخاب روش مناسب بر اساس هدف پژوهش، ماهیت داده و نوع مسئله پیش‌بینی ترسیم می‌کند. تحلیل مطالعات در مجموعه‌داده‌ها و مقیاس‌های فیزیکی گوناگون، بینشی مکمل از جنبه‌های متفاوت تردی هیدروژنی فراهم می‌آورد و می‌تواند مبنای پژوهش‌های آتی درباره سازوکارهای آن باشد.

نتایج، پیوند روشنی میان ویژگی‌های داده، انتخاب مدل یادگیری ماشین و پدیده هدف در تردی هیدروژنی آشکار می‌کنند. داده‌های آزمایشگاهی همچنان منبع اصلی پیش‌بینی حساسیت به تردی، غلظت هیدروژن هنگام شکست، رفتار شکست و ترک‌خوردگی به کمک هیدروژن هستند؛ درحالی‌که داده‌های محاسباتی تولیدشده با

DFT، CFD، FEM و MD شناخت سازوکاری مکملی از نفوذ و تله‌گذاری هیدروژن، برهم‌کنش با مرزدانه و گسترش ترک در مقیاس‌های مختلف به دست می‌دهند. روش‌های متعارف یادگیری ماشین و یادگیری تجمیعی عموماً بهترین توازن را میان دقت، پایداری و تفسیرپذیری برای داده‌های ساختاریافته مهندسی دارند؛ در مقابل، شبکه‌های عصبی مصنوعی، مدل‌های بینایی ماشین، شبکه‌های عصبی گرافی و روش‌هایی که در سطوح مختلف دانش فیزیکی را وارد می‌کنند، توان هوش مصنوعی را به پیش‌بینی غیرخطی، شناسایی خودکار عیوب، مدل‌سازی اتمی و انتقال چندمقیاسی هیدروژن گسترش می‌دهند. بنابراین، پیشرفت بعدی به ساخت پایگاه‌های داده استاندارد و آزاد برای تردی هیدروژنی، ادغام داده‌های آزمایشگاهی و محاسباتی در چارچوب‌های یادگیری چندمقیاسی و حرکت از ویژگی‌های مبتنی بر فیزیک و مدل‌های ترکیبی/کوپل‌شده به سوی چارچوب‌های عمیق‌ترِ آگاه از فیزیک و فیزیک‌تعبیه‌شده نیاز دارد. چنین پیشرفتی هم درک سازوکارهای پدیده و پیش‌بینی مبتنی بر هوش مصنوعی را تقویت می‌کند و هم به طراحی فولادهای مقاوم به هیدروژن و بهره‌برداری ایمن از زیرساخت‌های هیدروژنی کمک می‌کند.

اطلاعات و جدول‌های تکمیلی

اطلاعات تکمیلی این مقاله از نشانی https://www.mdpi.com/article/10.3390/hydrogen7030125/s1 قابل دریافت است. جدول S1: امتیازهای تفصیلی ارزیابی کیفیت روش‌شناختی ۲۶ مطالعه یادگیری ماشین واردشده در این مرور. جدول S2: ویژگی‌های تفصیلی مجموعه‌داده‌های به‌کاررفته در مطالعات تردی هیدروژنی فولاد، شامل منشأ داده، حجم مجموعه‌داده، پیش‌پردازش، مهندسی ویژگی، متغیرهای ورودی، اهداف پیش‌بینی و راهبردهای تقسیم داده. جدول S3: مقایسه تفصیلی مدل‌های هوش مصنوعی و یادگیری ماشین، شامل پیکربندی الگوریتم، راهبرد اعتبارسنجی، تنظیم ابرپارامتر، پالایش ویژگی‌ها، کنترل بیش‌برازش، مقایسه با مبنا و شاخص‌های عملکرد گزارش‌شده. جدول S4: وضعیت دسترس‌پذیری عمومی مجموعه‌داده‌های پژوهش‌های منتخب. جدول S5: فهرست اختصارات استفاده‌شده در مقاله.

سهم نویسندگان

طرح مفهومی پژوهش: A.G.T. و F.E.؛ روش‌شناسی: F.E.، A.G.T. و S.K.؛ اجرای بررسی: A.G.T.؛ تحلیل رسمی: F.E.، A.G.T. و S.K.؛ گردآوری و سامان‌دهی داده‌ها: F.E.، A.G.T. و S.K.؛ مصورسازی: A.G.T.؛ اعتبارسنجی: F.E.، A.G.T. و S.K.؛ تهیه پیش‌نویس اولیه: A.G.T.؛ بازبینی و ویرایش مقاله: F.E. و S.K.؛ سرپرستی: F.E. و S.K.؛ مدیریت پروژه: F.E.؛ تأمین اعتبار مالی: F.E. همه نویسندگان نسخه منتشرشده مقاله

را خوانده و تأیید کرده‌اند.

تأمین مالی

این پژوهش با حمایت مالی برنامه دستیار پژوهشی دانشجویان تحصیلات تکمیلی دانشگاه قطر امکان‌پذیر شده است.

بیانیه کمیته اخلاق پژوهش

موضوعیت ندارد.

بیانیه رضایت آگاهانه

موضوعیت ندارد.

بیانیه دسترس‌پذیری داده‌ها

در این پژوهش داده جدیدی تولید یا تحلیل نشده است. یادآوری: جدول تکمیلی S3 وضعیت دسترس‌پذیری گزارش‌شده مجموعه‌داده‌های مطالعات مرورشده را خلاصه می‌کند.

سپاسگزاری

نویسندگان از دانشگاه قطر بابت حمایت در قالب برنامه دستیار پژوهشی تحصیلات تکمیلی، که انجام این کار را ممکن ساخت، قدردانی می‌کنند. مسئولیت تمام اظهارنظرهای این مقاله صرفاً بر عهده نویسندگان است.
نویسندگان در زمان آماده‌سازی دست‌نوشته، برای بهبود زبان، دستور نگارش و خوانایی متن از فناوری‌های کمک‌گرفته از هوش مصنوعی، از جمله مدل‌های زبانی بزرگ، استفاده کرده‌اند. همه محتوای تولیدشده با کمک هوش مصنوعی را با دقت بازبینی و ویرایش کرده‌اند و مسئولیت کامل صحت و یکپارچگی نسخه نهایی

منتشرشده را می‌پذیرند.

تعارض منافع

نویسندگان اعلام کرده‌اند که هیچ تعارض منافعی ندارند.

اختصارات

تمام اختصارات در جدول S5 از اطلاعات تکمیلی مقاله آمده‌اند.

منابع علمی

1. Iida, S.; Sakata, K. Hydrogen technologies and developments in Japan. Clean Energy 2019 , 3 , 105–113. — DOI
2. Field, R.; Derwent, R. Global warming consequences of replacing natural gas with hydrogen in the domestic energy sectors of future low-carbon economies in the United Kingdom and the United States of America. Int. J. Hydrogen Energy 2021 , 46 , 30190–30203. — DOI
3. Al-Shamari, M.; Khodary, A.; Han, D.S.; Mujtaba, I.M.; Rahmanian, N. Production of blue ammonia as a clean fuel in Qatar. Chem. Eng. Trans. 2023 , 99 , 421–426.
4. Hjeij, D. Development and Computational Modeling of a Hydrogen Strategy for the Economic Transformation of Qatar. Ph.D. Thesis, Hamad Bin Khalifa University, Al-Rayyan, Qatar, 2024.
5. Zhang, H.; Zhao, J.; Li, J.; Yu, B.; Wang, J.; Lyu, R.; Xi, Q. Research progress on corrosion and hydrogen embrittlement in hydrogen–natural gas pipeline transportation. Nat. Gas Ind. B 2023 , 10 , 570–582. — DOI
6. Lamari, F.; Weinberger, B.; Langlois, P.; Fruchart, D. Instances of Safety-Related

Advances in Hydrogen as Regards Its Gaseous Transport and Buffer Storage and Its Solid-State Storage. Hydrogen 2024 , 5 , 387–402. — DOI

7. Ilyushechkin, A.; Schoeman, L.; Carter, L.; Hla, S.S. Material challenges and hydrogen embrittlement assessment for hydrogen utilisation in industrial scale. Hydrogen 2023 , 4 , 599–619. — DOI

8. Zhang, W. Evaluation of susceptibility to hydrogen embrittlement—A rising step load testing method. Mater. Sci. Appl. 2016 , 7 , 389–395.

9. Yu, L.; Feng, H.; Li, S.; Guo, Z.; Chi, Q. Study on Hydrogen Embrittlement Behavior of X65 Pipeline Steel in Gaseous Hydrogen Environment. Metals 2025 , 15 , 596. — DOI

10. Sobola, D.; Dallaev, R. Exploring hydrogen embrittlement: Mechanisms, consequences, and advances in metal science. Energies 2024 , 17 , 2972. — DOI

11. Yu, H.; Díaz, A.; Lu, X.; Sun, B.; Ding, Y.; Koyama, M.; He, Y.; Zhoy, X.; Oudriss, A.; Feaugas, X.; et al. Hydrogen embrittlement as a conspicuous material challenge comprehensive review and future directions. Chem. Rev. 2024 , 124 , 6271–6392. — DOI

12. Wang, Y.; Hu, S.; Li, Y.; Cheng, G. Improved hydrogen embrittlement resistance after quenching–tempering treatment for a Cr-Mo-V high strength steel. Int. J. Hydrogen Energy 2019 , 44 , 29017–29026. — DOI

13. Tao, P.; Zhou, W.; Miao, X.; Peng, J.; Liu, W. Review of characterization on hydrogen embrittlement by micro-sample testing methods. Metals 2023 , 13 , 1753. — DOI

14. Lee, J.A.; Woods, S. Hydrogen Embrittlement ; NASA Marshall Space Flight Center: Huntsville, AL, USA, 2016.

15. Gavriljuk, V.; Shivanyuk, V.; Foct, J. Diagnostic experimental results on the hydrogen embrittlement of austenitic steels. Acta Mater. 2003 , 51 , 1293–1305. — DOI

16. Devi, A.A.S.; Javaheri, V.; Pallaspuro, S.; Komi, J. The role of density functional theory in decoding the complexities of hydrogen embrittlement in steels. Phys. Chem. Chem. Phys. 2024 , 26 , 26222–26237. — DOI

17. Nazar, S.; Lipiec, S.; Proverbio, E. FEM modelling of hydrogen embrittlement in API 5L X65 steel for safe hydrogen transportation. J. Mater. Sci. Mater. Eng. 2025 , 20 , 2025. — DOI

18. Malitckii, E.; Fangnon, E.; Vilaça, P. Evaluation of steels susceptibility to hydrogen embrittlement: A thermal desorption spectroscopy-based approach coupled with artificial neural network. Materials 2020 , 13 , 5500. — DOI

19. Malitckii, E.; Fangnon, E.; Vilaça, P. Study of correlation between the steels susceptibility to hydrogen embrittlement and hydrogen thermal desorption spectroscopy using artificial neural network. Neural Comput. Appl. 2020 , 32 , 14995–15006. — DOI

20. Fangnon, E.; Malitckii, E.; Latypova, R.; Vilaça, P. Prediction of hydrogen concentration responsible for hydrogen-induced mechanical failure in martensitic high-strength steels. Int. J. Hydrogen Energy 2023 , 48 , 5718–5730. — DOI

21. Guo, C.; Liu, S.; Gu, T.; Feng, Z.; Zhao, D.; Dong, L.; Li, X.; Zairi, F. Deep learning-based identification of hydrogen embrittlement-affected fracture surfaces and estimation of hydrogen diffusivity. Int. J. Hydrogen Energy 2025 , 111 , 767–780. — DOI

22. Alamsyah, F.A.; Cheng, C.-C.; Gapsari, F. Detection of hydrogen bubbles produced by corrosion inhibition of metal weldment using machine learning. Appl. Sci. 2023 , 14 , 266. — DOI

23. 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. — DOI

24. Vu, T.T.H.; Vo, T.H.; Tran, L.H.; Choi, J.; Vo, T.T.; Ly, C.D.; Nguyen, T.P.; Mondal, S.; Oh, J. Segmenting hydrogen-induced cracking defects in steel through scanning acoustic microscopy and deep neural networks. Eng. Rep. 2024 , 6 , e12933. — DOI

25. Qiu, F.; Shen, Z.; Bai, Y.; Shan, G.; Qu, D.; Chen, W. Hydrogen defect acoustic emission recognition by deep learning neural network. Int. J. Hydrogen Energy

2024 , 54 , 878–893. — DOI

.26 Campari, A.; Konert, F.; Razavi, N.; Sobol, O.; Alvaro, A. Hydrogen-assisted cracking: A deep learning approach for fractographic analysis. Comput. Mater. Sci. 2026 , 262 , 114366. — DOI

.27 Anbalagan, A.; Graves, J.E.; Curnick, O.J.; Rostohar, D.; Anouncia, S.M.; Michael, A.X.; Soundarapandiyan, R.; Paulchamy, J.; Thirugnanam, M. SEM images data set development of ML models to Predict hydrogen embrittlement in welded 316 L/304 L stainless steels. Manuf. Lett. 2026 , 47 , 51–57. — DOI

.28 Gong, X.; Sun, R.; Lei, R.; Jiang, X.; Su, Y.; Yan, Y. Iterative multi-objective design of hydrogen embrittlement resistant high-strength steels using Bayesian optimization. Corros. Sci. 2024 , 231 , 111953. — DOI

.29 Yingjie, Z.; Yibo, A.; Weidong, Z. Physics informed ensemble learning used for interval prediction of fracture toughness of pipeline steels in hydrogen environments. Theor. Appl. Fract. Mech. 2024 , 130 , 104302. — DOI

.30 Gyaabeng, M.; Ahmed, R.; Ahmed, N.; Teodoriu, C.; Devegowda, D. Modeling the Impact of Hydrogen Embrittlement on the Fracture Toughness of Low-Carbon Steel Using a Machine Learning Approach. Metals 2025 , 15 , 588. — DOI

.31 Kim, S.-G.; Shin, S.-H.; Hwang, B. Machine learning approach for prediction of hydrogen environment embrittlement in austenitic steels. J. Mater. Res. Technol. 2022 , 19 , 2794–2798. — DOI

.32 Campari, A.; Darabi, M.A.; Alvaro, A.; Ustolin, F.; Paltrinieri, N. A Machine Learning Approach to Predict the Materials' Susceptibility to Hydrogen Embrittlement. Chem. .Eng. Trans. 2023 , 99 , 193–198

.33 Qin, G.; Li, R.; Yang, M.; Wang, B.; Ni, P.; Wang, Y. Failure probability estimation of natural gas pipelines due to hydrogen embrittlement using an improved fuzzy fault tree approach. J. Clean. Prod. 2024 , 448 , 141601. — DOI

.34 da Silvaa, S.P.; Maiora, C.S.; Linsa, I.D.; Chagas, M.D. A Machine Learning Approach for Predicting Hydrogen Embrittlement in Storage and Transportation

Steels. In Proceedings of the 17th International Conference on Probabilistic Safety Assessment and Management & Asian Symposium on Risk Assessment and .Management (PSAM17&ASRAM2024), Sendai, Japan, 7–11 October 2024

.35 Ahmed, N.; Aldaw, M.; Ahmed, R.; Teodoriu, C. Modeling of necking area reduction of carbon steel in hydrogen environment using machine learning approach. Eng. Fail. Anal. 2024 , 156 , 107864. — DOI

.36 Raftar, H.R.; Safyari, M.; Moshtaghi, M. Hydrogen-assisted fatigue crack growth in pipeline steels: A machine learning approach. Procedia Struct. Integr. 2025 , 68 , 1066–1073. — DOI

.37 Li, X.; Xu, M.; Zheng, T.; Sun, C.; Lan, X.; Hu, J.; Yu, Z. Fast probe of hydrogen molecules binding on alpha-iron surface via a machine-learning method and high-throughput molecular dynamics simulations. Mater. Today Commun. 2025 , 47 , 113019. — DOI

.38 Chau, M.T.; Almeida, J.L.D.S.; Alhajjar, E.; Junior, A.C.N. A Machine Learning .Pressure Emulator for Hydrogen Embrittlement. arXiv 2023 , arXiv:2306.13116

.39 Sun, C.; Yuan, Y.; Xu, M.; Li, X.; Li, M.; Zhou, C. A high-throughput molecular dynamics study with a machine-learning method on predicting diffusion coefficient of hydrogen in -iron grain boundaries. Mater. Today Commun. 2025 , 44 , 111997. — DOI

.40 Phan, H.C.; Le-Thanh, L.; Nguyen-Xuan, H. A semi-empirical approach and uncertainty analysis to pipes under hydrogen embrittlement degradation. Int. J. Hydrogen Energy 2022 , 47 , 5677–5691. — DOI

.41 Al-Hawary, S.I.S.; Sari, A.; Askar, S.; Pallathadka, H.; Asaad, R.R.; Sharma, M. Guided analysis of fracture toughness and hydrogen-induced embrittlement crack growth rate in quenched-and-tempered steels using machine learning. Int. J. Press. Vessels Pip. 2024 , 210 , 105247. — DOI

.42 Zhang, B.; Asta, M.; Wang, L.-W. Machine learning force field for Fe-H system and investigation on role of hydrogen on the crack propagation in -Fe. Comput. Mater.

Sci. 2022 , 214 , 111709. — DOI

.43 Xie, M.; Wei, Z.; Zhao, J.; Chen, Y. Failure analysis of corroded hydrogen-blended natural gas pipelines based on finite element analysis and genetic algorithm-back propagation neural network. Reliab. Eng. Syst. Saf. 2025 , 262 , 111174. — DOI

.44 Bishop, C.M.; Nasrabadi, N.M. Pattern Recognition and Machine Learning ; No. 4; .Springer: New York, NY, USA, 2006

.45 Li, X.; Ma, X.; Zhang, J.; Akiyama, E.; Wang, Y.; Song, X. Review of Hydrogen Embrittlement in Metals: Hydrogen Diffusion, Hydrogen Characterization, Hydrogen Embrittlement Mechanism and Prevention: X. Li et al. Acta Metall. Sin. (Engl. Lett.) .2020 , 33 , 759–773

.46 Ingle, R.; Ilyushechkin, A.; Gray, V.; Schoeman, L. Reliability and Representativeness of Hydrogen Charging Methods for Assessing Hydrogen Embrittlement in Metals. Hydrogen 2026 , 7 , 87. — DOI

.47 ASTM F519-18 ; Standard Test Method for Mechanical Hydrogen Embrittlement Evaluation of Plating/Coating Processes and Service Environments. ASTM: West .Conshohocken, PA, USA, 2024

.48 ASTM F1624-12(2018) ; Standard Test Method for Measurement of Hydrogen Embrittlement Threshold in Steel by the Incremental Step Loading Technique. .ASTM: West Conshohocken, PA, USA, 2024

.49 San Marchi, C.; Somerday, B.P. Technical Reference for Hydrogen Compatibility of Materials ; Sandia National Laboratories (SNL): Albuquerque, NM, USA; Livermore, .CA, USA, 2012

.50 Scandella, M.; Bin, M.; Parisini, T. Kernel-based learning of stable nonlinear systems. IEEE Trans. Autom. Control 2026 , 1–16. — DOI

.51 Braspenning, P.J. Artificial Neural Networks: An Introduction to ANN Theory and .Practice ; Springer Science & Business Media: Berlin/Heidelberg, Germany, 1995

.52 Chauhan, V.K.; Dahiya, K.; Sharma, A. Problem formulations and solvers in linear SVM: A review. Artif. Intell. Rev. 2019 , 52 , 803–855. — DOI

53. Hodson, T.O.; Over, T.M.; Foks, S.S. Mean squared error, deconstructed. J. Adv. Model. Earth Syst. 2021 , 13 , e2021MS002681. — DOI

54. Gao, J. R-Squared (R2)—How much variation is explained? Res. Methods Med. Health Sci. 2024 , 5 , 104–109. — DOI

55. Malerbi, F.K.; Nakayama, L.F.; Prado, P.; Yamanaka, F.; Melo, G.B.; Regatieri, C.V.; Stuchi, J.A. Heatmap analysis for artificial intelligence explainability in diabetic retinopathy detection: Illuminating the rationale of deep learning decisions. Ann. Transl. Med. 2024 , 12 , 89. — DOI

56. Hydrogen Influence on Metals: Hydrogen Embrittlement. ZwickRoell. Available online: https://www.zwickroell.com/industries/energy/hydrogen-influence-on-metals-hydrogen-embrittlement/?utm_source=chatgpt.com (accessed on 22 April 2026).

57. San Marchi, C.; Somerday, B.P.; Nibur, K. Development of standards for evaluating materials compatibility with high-pressure gaseous hydrogen. In Proceedings of the International Conference on Hydrogen Safety, Brussels, Belgium, 9–11 September 2013.

58. EIGA. Hydrogen Cylinders and Transport Vessels ; European Industrial Gases Association AISBL: Brussels, Belgium, 2020; Volume IGC Doc 100/20.

59. Walallawita, R.; Hinchliff, M.C.; Sediako, D.; Quinn, J.; Chou, V.; Walker, K.; Hill, M. Evaluating the effect of blended and pure hydrogen in X60 pipeline steel for low-pressure transmission using hollow-specimen slow-strain-rate tensile testing. Metals 2024 , 14 , 1132. — DOI

60. ISO 11114-4:2017 ; Test Methods for Selecting Steels Resistant to Hydrogen Embrittlement. ISO: Geneva, Switzerland, 2017.

61. ASTM G142-98(2022) ; Standard Test Method for Determination of Susceptibility of Metals to Embrittlement in Hydrogen Containing Environments at High Pressure, High Temperature, or Both. ASTM: West Conshohocken, PA, USA, 2022.

62. ASTM STP962-EB ; Hydrogen Embrittlement: Prevention and Control. ASTM: West

.Conshohocken, PA, USA, 1988

.63 Zhou, J.; Gandomi, A.H.; Chen, F.; Holzinger, A. Evaluating the quality of machine learning explanations: A survey on methods and metrics. Electronics 2021 , 10 , 593. – DOI

یادداشت ناشر: مطالب، دیدگاه‌ها و داده‌های هر اثر منتشرشده صرفاً متعلق به نویسندگان و مشارکت‌کنندگان همان اثر است و الزاماً بیانگر دیدگاه MDPI یا ویراستاران آن نیست. MDPI و ویراستاران مسئولیتی در قبال آسیب احتمالی به اشخاص یا اموال ناشی از ایده‌ها، روش‌ها، دستورالعمل‌ها یا محصولات مطرح‌شده در محتوای منتشرشده نمی‌پذیرند.

© ۲۰۲۶، نویسندگان مقاله. دارنده حق بهره‌برداری: MDPI، بازل، سوئیس. این اثر دسترسی آزاد است و بر اساس مجوز Creative Commons Attribution (CC BY 4.0) منتشر شده است.

مشخصات منبع اصلی و حقوق انتشار

عنوان اصلی: Machine Learning-Driven Advances in Hydrogen Embrittlement of Steels: A Comprehensive Review

نویسندگان: Ahmed G. Talkhan؛ Fadwa Eljack؛ Seckin Karagoz.

نشریه: Hydrogen، جلد ۷، شماره ۳، مقاله ۱۲۵، منتشرشده در ۲۵ اوت ۲۰۲۶؛ ناشر: MDPI.

شناسه DOI: 10.3390/hydrogen7030125؛ **منبع اصلی:** صفحه مقاله در وب‌سایت ناشر.

مجوز متن و تصاویر مجاز: Creative Commons Attribution 4.0 International (CC BY 4.0). متن به فارسی ترجمه شده و چیدمان برای انتشار در مرکز دانش SteelExperts بازآرایی شده است. حقوق معنوی نویسندگان و منبع اصلی محفوظ است.

شکل اول به دلیل تأیید نشدن مجوز مستقل تصویر اقتباس‌شده بازنشر نشده است. چهار شکل دیگر مطابق اطلاعات حقوقی آرشیو پژوهشی منتشر می‌شوند؛ اعتبارنامه اختصاصی شکل دوم در زیرنویس آن آمده است.