

هوشمند سازی کنترل کیفیت و تشخیص خرابی در فرآیندهای تولید فولاد با استفاده از یادگیری عمیق و پردازش تصویر به منظور بهینه‌سازی مصرف انرژی

فاطمه سعادت جو^{۱*}، مسلم ملایی^۲

^۱استادیار، گروه مهندسی کامپیوتر، دانشگاه علم و هنر، یزد، ایران

^۲معلم، آموزش و پرورش هرمزگان، گروه کامپیوتر آموزش و پرورش رودان، هرمزگان، ایران

مقاله پژوهشی

چکیده

در سال‌های اخیر، افزایش رقابت در صنعت فولاد و ضرورت کاهش هزینه‌ها در کنار بهبود کیفیت، استفاده از فناوری‌های هوشمند مبتنی بر یادگیری عمیق را بیش‌ازپیش ضروری کرده است. یکی از چالش‌های اصلی در این حوزه، کنترل کیفیت محصولات و شناسایی سریع نواقص سطحی است که مستقیماً بر بهره‌وری خطوط تولید و میزان مصرف انرژی اثر می‌گذارد. در این پژوهش یک چارچوب یکپارچه برای کنترل کیفیت و پیش‌بینی مصرف انرژی در فرآیند تولید فولاد ارائه شده است که از ترکیب پردازش تصویر و تحلیل داده‌های حسگری استفاده می‌کند. برای بخش کنترل کیفیت، تصاویر پایگاه داده NEU Surface Defect به عنوان داده مرجع به کار گرفته شد و برای بخش انرژی نیز یک مجموعه داده فرآیندی شبیه‌سازی شده در محیط صنعتی مورد استفاده قرار گرفت. معماری پیشنهادی شامل یک شبکه چندشاخه‌ای است که در آن شبکه‌ی کانولوشنی (CNN) به عنوان استخراج کننده ویژگی‌های تصویری و شبکه‌ی LSTM برای مدل‌سازی وابستگی‌های زمانی داده‌های انرژی به کار رفته‌اند. نتایج نشان می‌دهد که مدل پیشنهادی در بخش کنترل کیفیت به دقت ۹۸/۷ درصد و امتیاز F1 برابر با ۹۸/۵ درصد رسیده و در پیش‌بینی مصرف انرژی نیز به RMSE برابر ۰/۰۸۲ و MAPE معادل ۲/۱ درصد دست یافته است. این عملکرد نسبت به روش‌های پیشین برتری قابل توجهی داشته و منجر به کاهش ضایعات، بهبود دقت تشخیص عیوب و صرفه‌جویی معنادار در مصرف انرژی شده است. چارچوب پیشنهادی می‌تواند به عنوان گامی عملی در جهت حرکت به سوی تولید سبز و ارتقای پایدار بهره‌وری صنعتی مورد استفاده قرار گیرد.

تاریخ دریافت:

۱۴۰۴/۰۶/۲۴

تاریخ پذیرش:

۱۴۰۴/۰۸/۲۶

کلیدواژه‌ها:

هوش مصنوعی، یادگیری عمیق،
CNN-LSTM، صنعت فولاد

نویسنده مسئول:

saadatjou@sau.ac.ir

doi : 10.22034/ABMIR.2025.23661.1167

۱- مقدمه

صنعت فولاد به‌عنوان یکی از مهم‌ترین صنایع پایه‌ای، نقشی کلیدی در توسعه اقتصادی و صنعتی کشورها ایفا می‌کند [۱]. رشد روزافزون تقاضا برای محصولات فولادی باکیفیت بالا، در کنار فشارهای جهانی برای کاهش مصرف انرژی و حرکت به سمت تولید سبز، موجب شده است که استفاده از فناوری‌های نوین در این صنعت به ضرورتی اجتناب‌ناپذیر تبدیل شود [۲]. یکی از چالش‌های اصلی در فرآیندهای تولید فولاد، کنترل کیفیت محصولات و تشخیص به‌موقع خرابی تجهیزات است [۳]. نقص در این دو حوزه نه‌تنها باعث کاهش بهره‌وری و افزایش هزینه‌های عملیاتی می‌شود، بلکه منجر به اتلاف انرژی قابل‌توجهی نیز خواهد شد [۴]. در سال‌های اخیر، فناوری‌های یادگیری عمیق و پردازش تصویر توانسته‌اند پیشرفت چشمگیری در حوزه‌های تشخیص عیوب صنعتی و پایش وضعیت تجهیزات ایجاد کنند [۱]، [۲]. بااین‌حال، مرور پژوهش‌های موجود نشان می‌دهد که اکثر مطالعات یا صرفاً بر بهبود کیفیت محصول متمرکز بوده‌اند [۳]، یا تنها به پیش‌بینی مصرف انرژی پرداخته‌اند [۴] و کمتر به توسعه سامانه‌های یکپارچه‌ای که بتوانند هم‌زمان کیفیت، خرابی و انرژی را مدیریت کنند توجه شده است [۵]. مشکل اصلی رویکردهای پیشین آن است که این سیستم‌ها به‌صورت مجزا عمل می‌کنند؛ به‌عنوان مثال، مدل‌های تشخیص عیوب سطحی قادر به ارائه برآورد دقیق از تأثیر این عیوب بر مصرف انرژی نیستند و مدل‌های بهینه‌سازی انرژی نیز معمولاً داده‌های مربوط به کیفیت یا خرابی تجهیزات را در نظر نمی‌گیرند [۶]. این جداسازی منجر به تصمیم‌گیری‌های غیر بهینه، افزایش دوباره‌کاری و درنهایت مصرف بالاتر انرژی می‌شود. نوآوری پژوهش حاضر در ارائه یک چارچوب هوشمند و یکپارچه است که با ترکیب داده‌های تصویری خطوط تولید و داده‌های عملیاتی، هم‌زمان عیوب سطحی را

شناسایی، خرابی تجهیزات را پیش‌بینی و تأثیر این موارد بر مصرف انرژی را مدل‌سازی می‌کند. این رویکرد با استفاده از شبکه‌های عصبی کانولوشنی پیشرفته و الگوریتم‌های یادگیری ترکیبی، قادر است در لحظه، تصمیمات بهینه برای کاهش ضایعات و مصرف انرژی اتخاذ کند و گامی عملی در راستای تحقق تولید سبز و بهبود پایدار بهره‌وری در صنعت فولاد بردارد. ساختار این مقاله به این صورت تنظیم شده است، در بخش دوم، مروری بر ادبیات تحقیق ارائه می‌شود و مطالعات مرتبط در دو حوزه کنترل کیفیت سطحی و پیش‌بینی مصرف انرژی با تأکید بر کاربرد تکنیک‌های پردازش تصویر و روش‌های سری زمانی بررسی و مقایسه می‌گردند. بخش سوم چارچوب پیشنهادی را تشریح می‌کند؛ شامل جزئیات معماری شبکه کانولوشنی و LSTM، فرایند هم‌ترازی و یکپارچه‌سازی داده‌های چند منبع و روش بهینه‌سازی چندهدفه مبتنی بر NSGA-II. در بخش چهارم، مجموعه داده‌ها، فرایندهای پیش‌پردازش، پیکربندی پیاده‌سازی و معیارهای ارزیابی معرفی می‌شوند تا شرایط آزمایشی شفاف گردد. بخش پنجم نتایج تجربی را گزارش داده، تحلیل‌های کمی و مقایسه‌ای (شامل مطالعه ablation و مقایسه با روش‌های مرجع) را ارائه می‌دهد و پایداری مدل در سناریوهای مختلف موردبحث قرار می‌گیرد. در بخش پایانی جمع‌بندی یافته‌ها، محدودیت‌های مطالعه و مسیرهای بالقوه برای تحقیقات آینده مطرح خواهد شد.

۲- کارهای مرتبط

در سال‌های اخیر، کاربرد یادگیری عمیق و پردازش تصویر در صنعت فولاد توجه زیادی را به خود جلب کرده است. پژوهش‌های همکاران [۸] با استفاده از شبکه‌های عصبی چندمقیاسی برای تشخیص ترک در سطوح فولاد، دقت بالایی در شناسایی نواقص حاصل کردند، اما مدل آن‌ها تنها بر یک

همکاران [۱۶] نیز فناوری‌های تولید هوشمند در صنعت فولاد چین را مرور کردند و نتیجه گرفتند که ادغام سیستم‌های کنترل کیفیت با بهینه‌سازی انرژی هنوز در مراحل ابتدایی قرار دارد و نیازمند توسعه و تحقیقات بیشتر است. با توجه به شکاف موجود در مطالعات پیشین، پژوهش حاضر باهدف پر کردن این خلأ و ارائه‌ی یک چارچوب هوشمند و یکپارچه طراحی شده است که بتواند کنترل کیفیت سطحی و بهینه‌سازی مصرف انرژی را به‌طور هم‌زمان در فرآیندهای تولید فولاد انجام دهد. برخلاف رویکردهای گذشته که هر یک به‌صورت مجزا به کنترل کیفیت یا مدیریت انرژی می‌پرداختند، مدل پیشنهادی این پژوهش از ترکیب یادگیری عمیق EfficientNet و LSTM و بهینه‌سازی چندهدفه بهره می‌گیرد تا بتواند تصمیم‌های عملیاتی را بر اساس داده‌های واقعی تولید بهینه کند.

۳- چارچوب کلی پژوهش

چارچوب پیشنهادی، یک سیستم یکپارچه برای کنترل کیفیت سطحی و پیش‌بینی/بهینه‌سازی مصرف انرژی در تولید فولاد است. این چارچوب شامل چهار مرحله اصلی است.

۱. جمع‌آوری داده‌های چند منبعی شامل تصاویر سطحی با وضوح بالا + داده‌های IoT مربوط به انرژی و پارامترهای فرآیندی
۲. پیش‌پردازش و هم‌تراز سازی داده‌ها بر اساس شناسه زمانی
۳. مدل یادگیری عمیق چندوظیفه‌ای^۱ برای هم‌زمان تشخیص عیوب سطحی و پیش‌بینی مصرف انرژی.
۴. بهینه‌سازی چندهدفه برای پیشنهاد تنظیمات فرآیندی با حداقل انرژی و حداقل عیب.

نوع عیب متمرکز بود و بهینه‌سازی مصرف انرژی را در نظر نگرفت.

چن و همکاران [۹] یک سیستم نگهداری پیش‌گویانه مبتنی بر اینترنت اشیاء ارائه کردند که توانست نرخ توقف خطوط تولید را کاهش دهد، ولی تمرکز آن‌ها روی داده‌های سنسوری بود و پردازش تصویر برای کنترل کیفیت لحاظ نشد.

پاتل و همکاران [۱۰] با بهره‌گیری از بینایی ماشین به طبقه‌بندی عیوب سطحی فولاد پرداختند، اما مدل پیشنهادی در محیط واقعی و داده‌های چند منبعی آزمایش نشد.

وانگ و همکاران [۱۱] با استفاده از LSTM محدب ورودی رویکردی برای بهینه‌سازی بلد رنگ ارائه دادند که قابلیت پیش‌بینی دقیق پارامترهای تولید را داشت، اما روش آن‌ها فاقد ماژول کنترل کیفیت تصویری بود.

لو و همکاران [۱۲] یک مدل یادگیری تقویتی سلسله‌مراتبی برای زمان‌بندی فرآیند فولادسازی و ریخته‌گری ارائه کردند که بهره‌وری فرآیند را افزایش داد، ولی به تشخیص نواقص محصول توجهی نداشت. لی و همکاران [۱۳] کنترل پیش‌بینی دمای کوره بلند را با شبکه عصبی کوانتومی-عمیق انجام دادند و نتایج امیدوارکننده‌ای به دست آوردند، اما هدف آن‌ها صرفاً دستیابی به پایداری حرارتی بود، درحالی‌که این پژوهش به بهینه‌سازی هم‌زمان کیفیت سطحی و مصرف انرژی می‌پردازد. عباسی و همکاران [۱۴] زیرساخت «هوش مصنوعی اشیاء» را برای کنترل کیفیت در فرآیند ریخته‌گری ارائه کردند که امکان تشخیص سریع عیوب سطحی را فراهم ساخت، اما بهینه‌سازی انرژی در طراحی آن لحاظ نشده بود. در ادامه، وریال و همکاران [۱۵] به تحلیل یکپارچه‌سازی هوش مصنوعی با فناوری‌های نوین تولید پرداختند و چالش‌های پیاده‌سازی صنعتی را شناسایی کردند، با این حال پژوهش آن‌ها ماهیت مروری داشت و فاقد مدل عملیاتی واقعی بود. زوو و

¹ Cnn+Lstm

۱-۳ جمع‌آوری داده‌ها

داده‌های پژوهش از سه منبع به دست آمد:

- تصاویر مرجع: از پایگاه داده‌ی NEU Surface Defect Database شامل ۱۸۰۰ تصویر با وضوح ۲۰۰×۲۰۰ پیکسل در شش کلاس مختلف عیوب سطحی فولاد (Cr, In, Pa, Ps, RS, Sc) استفاده شد. برای شفافیت، تعداد تصاویر در هر کلاس در جدول ۱ ارائه شده است. این توزیع داده‌ها در آموزش مدل تشخیص خرابی نقش تعیین‌کننده‌ای دارد، زیرا توازن کلاس‌ها بر دقت نهایی تأثیر مستقیم می‌گذارد.

- تصاویر شبیه‌سازی‌شده: به منظور بازنمایی شرایط خنثی‌تر، پوشش سناریوهای متنوع‌تر، مجموعه‌ای از تصاویر شبیه‌سازی‌شده با الهام از مشخصات خطوط واقعی تولید فولاد تولید گردید. برای تولید این تصاویر، از مدل‌سازی داده محور و روش‌های تقویت تصویر مبتنی بر شبکه‌های مولد^۱ استفاده شد. در گام نخست، تصاویر پایه از مجموعه داده NEU با استفاده از تبدیلات هندسی (چرخش، برش، تغییر روشنایی و کنتراست) و اعمال فیلترهای صنعتی^۲ گسترش یافتند. سپس برای افزایش تنوع ظاهری، از مدل GAN^۳ ساده‌شده برای تولید بافت‌های جدید سطحی با الگوهای مشابه عیوب واقعی فولاد استفاده شد. این فرایند منجر به تولید ۶۰۰ تصویر مصنوعی جدید با حفظ ویژگی‌های آماری و بصری مشابه داده‌های صنعتی گردید. تصاویر نهایی توسط سه کارشناس کنترل کیفیت فولاد بازبینی و تأیید شدند تا از شباهت ظاهری و فیزیکی به نمونه‌های

واقعی اطمینان حاصل شود. داده‌های انرژی: در این پژوهش دو منبع داده مورد استفاده قرار گرفت. (الف) داده‌های شبیه‌سازی‌شده بر اساس الگوهای مصرف انرژی در خطوط نورد گرم فولاد، شامل ۱۰۰۰۰ رکورد ساعتی از توان مصرفی، دما، فشار و نرخ تولید است. (ب) مجموعه داده منبع باز^۴ که در مقالات معتبر بین‌المللی برای تحلیل و پیش‌بینی انرژی صنعتی به کار می‌رود. ترکیب داده: تصاویر به‌طور کامل از پایگاه مرجع^۵ ۱۸۰۰ تصویر در شش کلاس انتخاب شدند.

جدول (۱): توزیع تعداد تصاویر در هر کلاس از مجموعه داده

NEU Surface Defect			
توضیح مختصر	تعداد تصاویر	نماد کلاس	نوع عیب سطحی
ترک‌های باریک و طولی روی سطح	۳۰۰	Cr	ترک سطحی ^۶
وجود مواد خارجی در سطح	۳۰۰	In	ورقه شدن ^۷
لکه‌های سطحی ناشی از اکسید شدن	۳۰۰	Pa	لکه سطحی ^۸
نقاط تورفته در سطح نورد شده	۳۰۰	Ps	سطح گود ^۹
خطوط و خراش‌های سطحی ناشی از نورد	۳۰۰	RS	پوسته نوردی ^{۱۰}
خطوط یکنواخت سطحی ناشی از تماس ابزار	۳۰۰	Sc	خراش ^{۱۱}
—	۱۸۰۰	—	جمع کل

داده‌های انرژی شامل ۷۰٪ رکوردهای شبیه‌سازی‌شده و ۳۰٪ رکوردهای منبع باز UCI بود.

به منظور اطمینان از یکپارچگی داده‌ها، فرآیند هم‌تراز سازی زمانی^{۱۲} به صورت شبیه‌سازی‌شده انجام شد. از آنجا که مجموعه داده NEU شامل اطلاعات زمانی واقعی نیست، برای

⁷ Inclusion

⁸ Patches

⁹ Pitted Surface

¹⁰ Rolled-In Scale

¹¹ Scratches

¹² Temporal Alignment

¹ Generative Models

² Gaussian, Motion Blur

³ Generative Adversarial Network

⁴ Uci Industrial Energy Consumption

⁵ Neu Surface Defect

⁶ Crack

مصنوعی تولید شد تا تصاویر به صورت منطقی با نوسانات انرژی شبیه‌سازی شده جفت شوند. سپس با استفاده از روش تطبیق میانگین متحرک انرژی^۴، مقادیر انرژی در بازه‌های زمانی نزدیک با داده‌های تصویری هم‌زمان شدند. نتیجه این فرایند، یک پایگاه داده‌ی هم‌تراز شده است که در آن هر تصویر سطحی با مقادیر انرژی متناظر در همان بازه‌ی عملیاتی مرتبط می‌شود و امکان تحلیل هم‌زمان کیفیت سطح و مصرف انرژی فراهم می‌گردد.

۳-۳ معماری مدل یادگیری عمیق

مدل پیشنهادی شامل یک معماری ترکیبی CNN-LSTM است که به صورت دوشاخه‌ای عمل می‌کند: شاخه اول برای کنترل کیفیت و طبقه‌بندی عیوب سطحی و شاخه دوم برای پیش‌بینی مصرف انرژی. برای وضوح و تکرارپذیری بیشتر، ساختار کامل شبکه شامل نوع لایه‌ها، ابعاد و توابع فعال‌سازی در جدول ۲ نشان داده شده است. این معماری ترکیبی از قابلیت استخراج ویژگی‌های مکانی تصاویر توسط شبکه‌ی کانولوشنی و توانایی مدل‌سازی وابستگی‌های زمانی داده‌های فرآیندی توسط شبکه‌ی بازگشتی LSTM است. لایه‌های کانولوشنی وظیفه شناسایی الگوهای بافتی و ساختاری عیوب سطحی را بر عهده دارند، در حالی که بخش LSTM روند تغییرات مصرف انرژی را در بازه‌های زمانی متوالی مدل‌سازی می‌کند. در این جدول زیر ساختار دقیق مدل پیشنهادی شامل تعداد لایه‌ها، نوع عملیات در هر مرحله، ابعاد خروجی و توابع فعال‌سازی مورد استفاده را نمایش می‌دهد. این مشخصات می‌تواند برای بازتولید نتایج پژوهش و نیز توسعه‌ی مدل‌های مشابه در کاربردهای صنعتی دیگر مورد استفاده قرار گیرد. برای حفظ استقلال منابع داده، مدل پیشنهادی در نسخه نهایی به صورت چندورودی^۵ طراحی شد. در این ساختار، تصاویر

هر تصویر بر اساس نوع عیب و شدت آن، یک برچسب زمانی مصنوعی^۱ تخصیص داده شد تا بتوان آن را با داده‌های انرژی متناظر در همان بازه‌ی تولید شبیه‌سازی شده جفت کرد. این برچسب‌ها با الگوی زمانی مصرف انرژی در خط نورد (مثلاً افزایش انرژی در بازه‌های دارای نرخ تولید بالا یا افزایش دما) همگام شدند. بدین ترتیب، ارتباط منطقی میان وضعیت سطح محصول (از طریق تصویر) و میزان انرژی مصرفی فرآیند از طریق داده‌های IoT و شبیه‌سازی برقرار شد، بدون آنکه نیاز به داده‌های واقعی هم‌زمان باشد. به منظور اطمینان از یکپارچگی، همه داده‌ها بر اساس برچسب زمانی Timestamp هم‌تراز شدند تا امکان جفت‌سازی هر تصویر سطحی با رکورد انرژی متناظر فراهم گردد.

۳-۲ پیش‌پردازش داده‌ها

۱. تصاویر: افزایش کیفیت با استفاده از فیلترهای فضایی و یک شبکه Super-Resolution مبتنی بر CNN^۲، همراه با Data Augmentation شامل چرخش $\pm 15^\circ$ ، تغییر روشنایی $\pm 20\%$ و برش تصادفی انجام شد.
۲. داده‌های انرژی: نرمال‌سازی به بازه $[0, 1]$ ، حذف نویز با فیلتر میانگین متحرک و افزودن الگوهای نویز تصادفی Random Noise الگوهای دوره‌ای Seasonal Patterns برای بازنمایی شرایط شبه واقعی صورت گرفت.

هم‌ترازسازی زمانی

برای برقراری ارتباط میان داده‌های تصویری و داده‌های انرژی، فرایند هم‌ترازسازی زمانی^۳ به صورت مرحله‌ای انجام شد. ابتدا، هر تصویر بر اساس شناسه‌ی تولید (ID) یا ترتیب مکانی ثبت، به بازه‌های زمانی متناظر در داده‌های انرژی اختصاص یافت. در مواردی که داده‌ی زمانی واقعی وجود نداشت (مانند مجموعه داده‌ی NEU)^۴، برچسب‌های زمانی

⁴ Moving Average Matching

⁵ Multi-Modal

¹ Synthetic Timestamp

² Convolutional Neural Network

³ Temporal Alignment

فولاد هستند و خروجی آن‌ها به دوشاخه‌ی مستقل منتقل می‌شود: در شاخه‌ی کنترل کیفیت، لایه‌های Fully Connected و Softmax برای طبقه‌بندی نوع عیوب به کار می‌روند؛ درحالی‌که در شاخه‌ی انرژی، توالی ویژگی‌ها به یک شبکه‌ی LSTM چندلایه داده می‌شود تا الگوهای زمانی مصرف انرژی استخراج شوند. این طراحی دوشاخه باعث می‌شود مدل بتواند به‌طور هم‌زمان دو وظیفه‌ی مرتبط تشخیص عیوب و پیش‌بینی انرژی را در قالب یک چارچوب واحد انجام دهد.

سطحی فولاد توسط EfficientNet-B4 پردازش و ویژگی‌های مکانی استخراج می‌شوند، درحالی‌که داده‌های حسگرهای انرژی و فرآیند توسط شبکه‌ی LSTM مدل‌سازی می‌گردند. خروجی دو شبکه در یک لایه Fusion ترکیب شده و به الگوریتم بهینه‌سازی NSGA-II برای تحلیل هم‌زمان کیفیت و انرژی منتقل می‌شود. این ساختار امکان یادگیری مشترک و تعامل میان شاخص‌های کیفی و انرژی را فراهم می‌سازد.

همان‌طور که در جدول ۲ مشخص است، لایه‌های CNN همان‌طور که در جدول ۲ مشخص است، لایه‌های CNN مسئول استخراج ویژگی‌های مکانی و بافتی از تصاویر سطح

جدول (۲): مشخصات معماری مدل پیشنهادی (CNN-LSTM)

بخش / شاخه	نوع لایه	ابعاد یا تعداد نوروها	تابع فعال‌سازی	توضیحات / هدف
استخراج ویژگی (CNN)	Conv2D + BatchNorm + ReLU + MaxPool	۴ بلوک تکرارشونده، فیلترهای ۳×۳ و ۵×۵	ReLU	استخراج ویژگی‌های مکانی چندمقیاسی از تصاویر
	Dropout	نرخ ۰/۵	—	کاهش بیش‌برازش در لایه‌های عمیق
شاخه کنترل کیفیت (QC)	Dense (Fully Connected)	۲۵۶ نورون	ReLU	یادگیری ویژگی‌های ترکیبی
	Dropout	نرخ ۰/۵	—	جلوگیری از بیش‌برازش
	لایه خروجی، چگال ^۱	تعداد کلاس‌ها (K) برابر ۶	Softmax	طبقه‌بندی نهایی عیوب سطحی
شاخه پیش‌بینی انرژی (EC)	LSTM دولایه	۶۴ واحد در هر لایه	tanh برای لایه درونی و sigmoid برای دروازه‌ها	مدل‌سازی وابستگی زمانی داده‌های انرژی
	لایه چگال	۶۴ نورون	ReLU	نگاشت ویژگی‌ها به فضای بازنمایی انرژی
	لایه خروجی، چگال	۱	Linear	پیش‌بینی مقدار مصرف انرژی نهایی

استفاده شد. هر آزمایش پنج بار با مقادیر اولیه متفاوت اجرا و نتایج به‌صورت میانگین به همراه انحراف معیار گزارش گردید. برای اطمینان از بازتولید پذیری و نیز شفافیت در گزارش، تمامی هایپرپارامترهای اصلی آموزش مدل به همراه مقادیر انتخابی و دلایل انتخاب آن‌ها در جدول ۳ ارائه شده‌اند. مقادیر ذکرشده بر اساس آزمایش‌های تجربی و بررسی تأثیر هر پارامتر بر عملکرد مدل انتخاب گردیده‌اند. این انتخاب‌ها

- جزئیات آموزش: آموزش مدل با استفاده از الگوریتم AdamW با نرخ یادگیری اولیه یک‌هزارم و ضریب کاهش وزن ده به توان منفی چهار انجام گرفت. اندازه دسته برابر با شصت و چهار و حداکثر دوره آموزشی دویست در نظر گرفته شد.
- برای جلوگیری از بیش‌برازش از مکانیسم توقف زودهنگام با آستانه ده دوره و یک برنامه کاهش نرخ یادگیری کسینوسی همراه با مرحله گرم کردن اولیه

¹ Dense

پیش‌بینی و شاخص‌های کاربردی ارزیابی شدند. جدول ۴ معیارهای ارزیابی و اعتبارسنجی مدل‌ها را نمایش می‌دهد.

جدول (۴): معیارهای ارزیابی و اعتبارسنجی مدل‌ها

دسته‌بندی	معیار	توضیح
QC (کنترل کیفیت)	Accuracy	درصد نمونه‌های درست پیش‌بینی شده
	Precision	نسبت نمونه‌های درست مثبت به کل نمونه‌های پیش‌بینی شده مثبت
	Recall	نسبت نمونه‌های درست مثبت به کل نمونه‌های واقعی مثبت
	F1-score	میانگین هارمونیک Precision و Recall
	AUC-ROC	ROC مساحت زیر منحنی
EC (پیش‌بینی انرژی)	RMSE	ریشه میانگین مربعات خطا
	MAE	میانگین قدر مطلق خطا
	MAPE	میانگین درصد خطای مطلق
	R ²	ضریب تعیین پیش‌بینی مدل
کاربردی	Energy Saving (%)	درصد صرفه‌جویی انرژی در سناریوهای واقعی قبل/بعد

اعتبارسنجی آماری

برای مقایسه مدل‌ها، آزمون Wilcoxon با سطح معنی‌داری α برابر با ۰/۰۵ و فاصله اطمینان ۹۵٪ (CI95%) استفاده شد [۱۷][۱۸]. این روش یک آزمون نا پارامتری برای مقایسه جفتی نمونه‌ها است و به‌ویژه برای داده‌های غیر نرمال مناسب است.

برای بررسی تأثیر هر جزء مدل، یک مطالعه‌ی حذف مرحله‌ای^۱ انجام شد. نسخه‌های مختلف مدل به ترتیب زیر ارزیابی شدند:

۱. مدل پایه CNN
 ۲. مدل پایه به همراه LSTM
 ۳. مدل پایه همراه با LSTM و Fusion
 ۴. مدل پایه ترکیبی با LSTM و Fusion و NSGA-II
- این بررسی به روشن شدن نقش هر مؤلفه در بهبود عملکرد مدل کمک می‌کند.

موجب دستیابی به تعادل میان دقت، سرعت همگرایی و جلوگیری از بیش برآزش شدند.

جدول (۳): پیکربندی هایپرپارامترهای آموزش مدل پیشنهادی و دلایل انتخاب آن‌ها

دلیل انتخاب	مقدار انتخابی	هایپرپارامتر
تعادل میان سرعت آموزش و پایداری گرادینان	۶۴	اندازه دسته (Batch size)
اطمینان از همگرایی کامل شبکه	۲۰۰	تعداد دوره (Epochs)
مقدار متداول برای AdamW: پس از آزمون بهترین تعادل سرعت و دقت	۰/۰۰۱	نرخ یادگیری اولیه
کنترل بیش برآزش و بهبود تعمیم‌پذیری	۱۰ به توان منفی ۴ (۰/۰۰۰۱)	کاهش وزن
جلوگیری از بیش برآزش	۰/۵	Dropout
کافی برای مدل‌سازی وابستگی‌های زمانی بدون پیچیدگی بیش‌ازحد	۲	تعداد لایه‌های LSTM
انتخاب تجربی	۶۴	تعداد واحدهای LSTM
جلوگیری از ادامه آموزش در صورت عدم بهبود	patience برابر با ۱۰	توقف زودهنگام (Early stopping)
بهبود همگرایی و جلوگیری از نوسانات شدید	Cosine decay with warmup	کاهش نرخ یادگیری
اطمینان از پایداری نتایج، میانگین و انحراف معیار	۵ بار	تعداد تکرار آزمایش

۳-۴ ارزیابی و اعتبارسنجی مدل

برای سنجش عملکرد مدل‌ها، مجموعه داده‌ها ابتدا به‌صورت ۷۰٪ آموزش، ۱۵٪ اعتبارسنجی و ۱۵٪ آزمون تفکیک شدند، به‌گونه‌ای که هیچ همپوشانی بین خطوط تولید وجود نداشت. سپس مدل‌ها با استفاده از معیارهای مختلف کیفیت، خطای

¹ Ablation Study

۳-۵ الگوریتم بهینه‌سازی انرژی (NSGA-II)

برای تنظیمات بهینه فرآیندی، خروجی‌های مدل پیش‌بینی به الگوریتم NSGA-II داده شدند [۸].

این الگوریتم چندهدفه انتخاب شد زیرا قادر است مجموعه‌ای از راه‌حل‌های بهینه پارتو را برای مسائل با اهداف متضاد پیدا کند و به‌ویژه در مسائل صنعتی با اهداف هم‌زمان مانند کمینه‌سازی نرخ عیب سطحی و مصرف انرژی عملکرد مناسبی دارد.

• متغیرهای تصمیم:

○ سرعت نورد [m/s]

○ دمای کوره [°C]

○ فشار هیدرولیک [bar]

• توابع هدف:

○ کمینه‌سازی نرخ عیب سطحی

○ کمینه‌سازی مصرف انرژی پیش‌بینی‌شده

• پارامترهای NSGA-II:

• اندازه‌ی جمعیت = ۱۰۰

• تعداد نسل‌ها = ۲۰۰

• نرخ تقاطع^۱ = ۰٫۹

• نرخ جهش^۲ = ۰٫۱

• خروجی:

الگوریتم مجموعه‌ای از راه‌حل‌های پارتو تولید کرد. برای انتخاب نهایی، نقطه‌ای با بهترین تعادل بین اهداف knee-point مشخص و به‌عنوان تنظیمات پیشنهادی عملیاتی گزارش شد. الگوریتم NSGA-II به دلیل توانایی بالای آن تابع هدف مورد استفاده در الگوریتم NSGA-II در جدول ۵ نمایش داده شده است.

جدول (۵): تابع هدف مورد استفاده در الگوریتم NSGA-II

عنوان	توضیحات مربوط به مدل بهینه‌سازی NSGA-II
هدف کلی	بهینه‌سازی هم‌زمان دو معیار متضاد شامل کاهش نرخ عیب سطحی و کاهش مصرف انرژی فرآیند نورد گرم فولاد
متغیرهای تصمیم	- دمای کوره (T) - سرعت نورد (v) - فشار غلتک (P)
دامنه مقادیر مجاز	$1000 \leq T \leq 1300 \text{ } ^\circ\text{C}$ و $0.8 \leq v \leq 2.5 \text{ m/s}$ و $8 \leq P \leq 15 \text{ MPa}$
توابع هدف	۱: (کاهش عیوب سطحی) $f_1 = 1 - \text{Accuracy}_{\text{QC}}$ ۲: (کاهش انرژی مصرفی) $f_2 = \text{Epred}$
توضیح توابع هدف	f_1 : نرخ خطای کنترل کیفیت را بر اساس خروجی CNN نشان می‌دهد. f_2 : انرژی پیش‌بینی‌شده فرآیند را بر اساس خروجی LSTM نمایش می‌دهد.
پارامترهای الگوریتم NSGA-II	اندازه جمعیت: ۱۰۰، تعداد نسل‌ها: ۲۰۰، نرخ تقاطع: ۰٫۹، نرخ جهش: ۰٫۱
خروجی نهایی	مجموعه‌ای از راه‌حل‌های بهینه پارتو ^۳ برای تعیین تنظیمات فرآیندی با بهترین توازن میان کیفیت سطحی و مصرف انرژی.

معماری مدل یادگیری عمیق

برای بخش استخراج ویژگی تصویری، از معماری EfficientNet-B4 به‌عنوان هسته‌ی شبکه‌ی CNN استفاده شد. این معماری به دلیل بهره‌گیری از تکنیک مقیاس‌گذاری

هم‌زمان عمق، عرض و وضوح ورودی^۴ و کارایی بالا در استخراج ویژگی‌های چندمقیاسی با تعداد پارامتر کمتر انتخاب گردید. EfficientNet-B4 توانایی تشخیص جزئیات دقیق عیوب سطحی را در تصاویر با وضوح بالا دارد و در

^۴ Compound Scaling

^۱ Crossover Rate

^۲ Mutation Rate

^۳ Pareto Optimal Solutions

وضوح بالا از سطح محصولات فولادی و داده‌های حسگرهای IoT شامل دما، فشار، سرعت نورد و توان مصرفی. پس از مرحله‌ی پیش‌پردازش و پاک‌سازی، داده‌ها در مرحله هم‌تراز سازی زمانی و ادغام داده‌ها^۱ ترکیب می‌شوند. خروجی استخراج ویژگی چندمقیاسی CNN به دوشاخه تقسیم می‌شود.

۱. شاخه‌ی تشخیص عیوب سطحی که کیفیت محصول را تعیین می‌کند.

۲. شاخه‌ی پیش‌بینی مصرف انرژی که روند انرژی فرآیند را مدل می‌کند.

هر دو خروجی وارد بهینه‌ساز چندهدفه می‌شوند تا تنظیمات بهینه‌ی فرآیند (دمای کوره، فشار، سرعت نورد) باهدف کاهش هم‌زمان نرخ عیب و مصرف انرژی تعیین گردد. درنهایت، این تنظیمات در قالب بازخورد بلادرنگ به خط تولید ارسال می‌شوند تا فرآیند تولید به‌صورت خودکار اصلاح و بهینه شود.

۴- پیاده‌سازی مدل

پیاده‌سازی چارچوب پیشنهادی مطابق شکل (۱) و مراحل روش تحقیق انجام شد. محیط توسعه شامل زبان Python 3.10 و کتابخانه‌های تخصصی PyTorch 2.2 برای مدل‌سازی شبکه‌های عصبی، OpenCV برای پردازش تصویر، Scikit-learn جهت ارزیابی مدل‌ها و Pandas و NumPy برای مدیریت داده‌ها بود. برای بخش‌های مربوط به الگوریتم بهینه‌سازی چندهدفه، از نرم‌افزار MATLAB 2023 استفاده گردید. زیرساخت سخت‌افزاری مورد استفاده شامل یک سرور مجهز به کارت گرافیک NVIDIA RTX4050 6 GB پردازنده Intel Core i 12700H و حافظه RAM با ظرفیت ۳۲ گیگا بایت بود. این پیکربندی امکان آموزش شبکه‌های عمیق بر روی داده‌های

پژوهش‌های اخیر در حوزه‌ی بینایی ماشین صنعتی عملکرد برتری نسبت به مدل‌های ResNet و VGG نشان داده است. افزون بر این، انتخاب EfficientNet-B4 با هدف دستیابی به تعادل میان دقت، سرعت و مصرف انرژی محاسباتی انجام شد تا مدل پیشنهادی بتواند در محیط‌های صنعتی واقعی، ضمن حفظ دقت بالا، از نظر کارایی زمانی و منابع سخت‌افزاری نیز بهینه عمل کند. این ویژگی به‌ویژه در چارچوب ترکیبی پیشنهادی CNN-LSTM-NSGA-II موجب شده است استخراج ویژگی‌های بصری به‌صورت کارآمد و مؤثر انجام گیرد و در نهایت، به بهبود هم‌زمان کنترل کیفیت سطحی و پیش‌بینی انرژی کمک نماید.

۳-۶ نوآوری پژوهش

نوآوری این کار در چند سطح مشخص می‌شود:

۱. **نوآوری اصلی:** یکپارچه‌سازی کنترل کیفیت با استفاده از داده‌های تصویری و پیش‌بینی مصرف انرژی با استفاده از داده‌های سری زمانی در یک مدل مشترک CNN و LSTM و اتصال مستقیم خروجی‌های مدل به الگوریتم NSGA-II

۲. **بهبود افزایشی:** استفاده از داده‌های چند منبعی شامل داده‌های تصویری و داده‌های IoT همراه با هم‌تراز سازی زمانی که دقت مدل را نسبت به کارهای مبتنی صرفاً بر تصویر یا صرفاً بر انرژی بهبود می‌دهد.

۳. **نوآوری کاربردی:** تعریف شاخص Energy Saving (%) و آزمون بر روی داده‌های صنعتی برای سناریوهای بهینه‌سازی فرآیند. برای جمع‌بندی و مقایسه‌ی ویژگی‌های مدل پیشنهادی با پژوهش‌های گذشته، جدول ۶ نوآوری‌ها و تفاوت‌های کلیدی چارچوب حاضر را نسبت به کارهای مشابه نشان می‌دهد.

ساختار کلی مدل ترکیبی مبتنی بر CNN-LSTM می‌باشد. ورودی‌های مدل شامل دو منبع داده هستند: تصاویر با

¹ Data Fusion

تصویری و سنسوری را بدون افت عملکرد فراهم کرد. به‌طور میانگین، زمان آموزش هر epoch حدود ۴۵ ثانیه و زمان استنتاج^۱ برای هر تصویر ۱۲ میلی‌ثانیه اندازه‌گیری شد. این مقادیر نشان می‌دهد که مدل قابلیت اجرا در شرایط نزدیک به بلادرنگ^۲ در خطوط تولید صنعتی را دارد.

جدول (۶): جدول چارچوب کلی پژوهش

شماره مرحله	عنوان مرحله	توضیح و دلیل تفکیک
۱	جمع‌آوری داده‌ها – تصاویر صنعتی	دریافت تصاویر با وضوح بالا از سطح محصولات توسط سیستم بینایی ماشین
۲	جمع‌آوری داده‌ها – داده‌های IoT یا سنسور	ثبت هم‌زمان داده‌های انرژی و فرآیندی (توان، دما، فشار، سرعت نورد)
۳	پیش‌پردازش و هم‌تراز سازی	پاک‌سازی نویز، نرمال‌سازی مقیاس‌ها و هم‌تراز سازی زمانی تصویر → داده انرژی
۴	استخراج ویژگی‌ها (CNN)	استخراج ویژگی‌های چندمقیاسی از تصاویر برای شناسایی جزئیات ریزودرشت
۵	ادغام ویژگی‌ها (Fusion)	ترکیب ویژگی‌های تصویری با داده‌های سنسوری در فضای مشترک برای یادگیری چندوظیفه‌ای
۶	شاخه کنترل کیفیت (QC)	CNN → Dense → Softmax برای تشخیص و طبقه‌بندی عیوب سطحی
۷	شاخه پیش‌بینی انرژی (EC)	CNN → LSTM → Dense برای پیش‌بینی مصرف انرژی
۸	ارزیابی و اعتبارسنجی	محاسبه معیارهای (Accuracy, Precision, Recall, F1, AUC) و QC و EC و (RMSE, MAE, MAPE, R ²) آزمون Wilcoxon و ablation study
۹	بهینه‌سازی چندهدفه	الگوریتم NSGA-II برای حداقل سازی هم‌زمان نرخ عیوب و مصرف انرژی؛ تولید جبهه پارتو
۱۰	پیشنهاد تنظیمات فرآیند	انتخاب knee-point از جبهه پارتو و ارائه مقادیر بهینه برای دما، فشار و سرعت نورد
۱۱	استقرار و بازخورد بلادرنگ	اعمال تنظیمات پیشنهادی روی خط تولید، مانیتورینگ نتایج و یادگیری مستمر برای بهبود مداوم

۴-۱ معرفی مجموعه داده‌ها

برای این مطالعه، از سه منبع داده‌ی اصلی استفاده شد که شامل تصاویر صنعتی واقعی، پایگاه داده‌ی NEU Surface Defect و داده‌های انرژی صنعتی می‌باشد. جدول ۷

جدول (۷): مشخصات مجموعه داده‌های مورد استفاده در پژوهش

نوع داده	منبع	تعداد تصویر	توضیحات
تصاویر صنعتی واقعی	خط‌نورد گرم فولاد کربنی کارخانه فولاد مبارکه	۱۲۰۰ تصویر	ثبت‌شده با سیستم بینایی ماشین صنعتی، شامل نمونه‌های مختلف عیوب سطحی
پایگاه NEU Surface Defect	NEU	۱۸۰۰ تصویر	شامل شش کلاس عیوب سطحی Sc, RS, Pa, Ps, In, Cr وضوح ۲۰۰×۲۰۰
داده انرژی صنعتی IoT	کارخانه فولاد واقعی	۵۰۰۰ رکورد زمانی	شامل توان، دما، فشار و سرعت نورد
داده انرژی	شبیه‌سازی بر اساس الگوهای مصرف واقعی	۱۰۰۰۰ رکورد ساعتی ۱۲،۰۰۰ پس از اعمال نویز	برای افزایش واقع‌نمایی، حدود ۲۰٪ رکوردها با نویز گوسی و الگوهای فصلی تقویت شدند

¹ Inference

² Near Real-Time

جدول ۸ فهرست شده‌اند. تنها معیاری که نیاز به توضیح دارد معیار $\text{Energy Saving (\%)}$ است. این معیار شاخصی تعریف شده در این پژوهش برای سنجش میزان صرفه‌جویی انرژی نسبت به سناریوهای پایه است. این معیار نشان‌دهنده تأثیر عملی مدل در بهبود بهره‌وری انرژی خطوط تولید فولاد می‌باشد.

۴-۳ اعتبارسنجی آماری

برای جلوگیری از نتایج تصادفی و اطمینان از پایداری مدل، تمامی آزمایش‌ها پنج بار با Seed متفاوت اجرا شدند و مقادیر میانگین $\pm$ انحراف معیار گزارش شد. تفاوت عملکرد مدل پیشنهادی با بهترین مدل‌های پایه با استفاده از آزمون Wilcoxon signed-rank در سطح معنی‌داری α برابر با ۰/۰۵ بررسی شد [۱۷]، [۱۸].

Seed متفاوت باعث می‌شود تا نتایج آزمایش‌ها با مقادیر تصادفی کنترل شده، قابل بازتولید و پایدار باشند.

آزمون Wilcoxon یک آزمون نا پارامتری برای مقایسه زوجی داده‌ها است که برای مقایسه مدل‌های یادگیری ماشین کاربردی و مصطلح می‌باشد.

جدول (۸): معیارهای ارزیابی عملکرد مدل پیشنهادی در دوشاخه‌ی

کنترل کیفیت و پیش‌بینی مصرف انرژی

معیار	فرمول
Accuracy	$\text{Accuracy} = (\text{TP} + \text{TN}) \div (\text{TP} + \text{TN} + \text{FP} + \text{FN})$
Precision	$\text{Precision} = \text{TP} \div (\text{TP} + \text{FP})$
Recall	$\text{Recall} = \text{TP} \div (\text{TP} + \text{FN})$
F1-score	$\text{F1} = 2 \times (\text{Precision} \times \text{Recall}) \div (\text{Precision} + \text{Recall})$
RMSE	$\text{RMSE} = \sqrt{[(1/n) \times \sum (y_i - \hat{y}_i)^2]}$
MAE	$\text{MAE} = (1/n) \times \sum$
MAPE	$\text{MAPE}(\%) = (100/n) \times \sum$
R ²	$\text{R}^2 = 1 - [\sum (y_i - \hat{y}_i)^2 \div \sum (y_i - \bar{y})^2]$
Energy Saving (%)	$\text{Energy Saving}(\%) = ((E_{\text{baseline}} - E_{\text{optimized}}) \div E_{\text{baseline}}) \times 100$

در این پژوهش از یک مجموعه داده‌ی ترکیبی شامل تصاویر مرجع NEU، تصاویر شبیه‌سازی شده صنعتی و داده‌های انرژی استفاده شد. از آنجاکه دیتاست NEU فاقد اطلاعات انرژی است، داده‌های انرژی از منابع صنعتی و شبیه‌سازی شده تولید گردید. سپس با در نظر گرفتن برجسب‌های زمانی ساختگی برای هر تصویر، فرآیند هم‌تراز سازی زمانی انجام شد تا امکان آموزش مدل چندوظیفه‌ای فراهم گردد. این هم‌ترازی در محیط کنترل شده شبیه‌سازی انجام شد و هدف از آن بررسی کارایی مدل در شرایط شبه واقعی بوده است.


لازم به ذکر است که تقسیم ۷۰٪ آموزش، ۱۵٪ اعتبارسنجی و ۱۵٪ آزمون مربوط به کل مجموعه داده‌ی ترکیبی شامل تصاویر مرجع NEU و تصاویر شبیه‌سازی شده است، نه تنها مجموعه‌ی NEU برای بخش NEU از ۳۰۰ داده برای Test و ۱۵۰۰ داده جهت Training استفاده شده است تا سازگاری با پژوهش‌های پیشین حفظ گردد.

لازم به تأکید است که داده‌های انرژی مورد استفاده ترکیبی از داده‌های واقعی (۳۰٪) و داده‌های شبیه‌سازی شده (۷۰٪) بوده‌اند. استفاده از داده‌های شبیه‌سازی شده به منظور ارزیابی مفهومی چارچوب پیشنهادی و بررسی امکان ادغام هم‌زمان کنترل کیفیت و مدیریت انرژی انجام شده است. در گام‌های آینده، اعتبارسنجی مدل با داده‌های صنعتی واقعی و خطوط تولید فعال در دستور کار قرار دارد.

۴-۲ معیارهای ارزیابی

در این پژوهش، برای ارزیابی عملکرد مدل پیشنهادی در دوشاخه‌ی «کنترل کیفیت» و «پیش‌بینی مصرف انرژی»، از مجموعه‌ای از معیارهای کمی استفاده شده است. این معیارها در

¹ Synthetic Timestamps



شکل (۱): شماتیک کلی چارچوب پیشنهادی برای کنترل کیفیت و پیش‌بینی انرژی در فرآیند تولید فولاد

ارزیابی هم‌زمان کنترل کیفیت سطحی و پیش‌بینی مصرف انرژی را فراهم می‌سازد.

۵-۱ ارزیابی کنترل کیفیت و تشخیص خرابی

برای ارزیابی دقت مدل پیشنهادی در بخش کنترل کیفیت سطحی، عملکرد آن با چند پژوهش شاخص پیشین مقایسه شد. جدول ۱۰ نتایج کمی مربوط به معیارهای دقت^۱، امتیاز F1 و نرخ خطای طبقه‌بندی را با توجه به انتخاب روش‌ها و الگوریتم‌های متفاوت نشان می‌دهد. همان‌طور که مشاهده می‌شود، مدل پیشنهادی با استفاده از ترکیب شبکه‌ی CNN چندمقیاسی و لایه‌های LSTM توانسته است عملکرد بهتری نسبت به مدل‌های صرفاً مبتنی بر CNN یا روش‌های سنتی ارائه دهد. این ارزیابی تأییدی بر کارایی بالای چارچوب پیشنهادی در شناسایی دقیق‌تر الگوهای

۵- نتایج و تحلیل

برای ارزیابی دقت و کارایی مدل پیشنهادی در بخش کنترل کیفیت، نتایج حاصل از روش ارائه‌شده با پژوهش‌های مرجع پیشین مقایسه شده‌اند. همان‌طور که در جدول ۹ مشاهده می‌شود، مدل ترکیبی پیشنهادی (CNN-LSTM-NSGA-II) توانسته است در مقایسه با سایر روش‌ها مانند ResNet50، VGG16 و EfficientNet، دقت و F1-score بالاتری در شناسایی عیوب سطحی فولاد به دست آورد. این نتایج تأیید می‌کند که ادغام شبکه‌های کانولوشنی با مدل‌های بازگشتی و بهینه‌سازی چندهدفه، موجب افزایش توان مدل در شناسایی دقیق‌تر و سریع‌تر عیوب سطحی شده است. این ساختار دوگانه امکان

¹ Accuracy

نتایج جدول ۱۰ نشان می‌دهد که ترکیب کامل LSTM و CNN به همراه بهینه‌سازی چندهدفه NSGA-II عملکرد بهینه را فراهم کرده است. هر ردیف جدول بیانگر پیکربندی متفاوت معماری است و مقادیر Accuracy، F1-Score و RMSE بخش انرژی برای هر حالت ارائه شده است. هر ردیف جدول نشان‌دهنده عملکرد مدل با یک ترکیب متفاوت از اجزای معماری است.

برای بررسی اثر هر بخش از معماری پیشنهادی بر عملکرد مدل، یک تحلیل ablation انجام شد. در این تحلیل، ابتدا فقط بخش CNN برای تشخیص عیوب و پیش‌بینی انرژی استفاده شد. سپس CNN با LSTM ترکیب شد تا تأثیر مدل‌سازی ویژگی‌های زمانی بر پیش‌بینی انرژی بررسی شود. در نهایت، کل معماری پیشنهادی شامل LSTM، CNN و الگوریتم بهینه‌سازی چندهدفه NSGA-II ارزیابی شد. این سناریو به ما امکان می‌دهد تا تأثیر هر مؤلفه به صورت تکی و ترکیبی بر معیارهای Accuracy، F1-Score و RMSE برای پیش‌بینی انرژی مشاهده کنیم.

به طور کلی نتایج جدول ۱۰ بیانگر اهمیت طراحی معماری پیشنهادی است:

استفاده از فقط CNN توانسته دقت ۹۵/۳٪ ایجاد کند اما خطای RMSE در بخش پیش‌بینی انرژی نسبتاً بالا (۶/۴) بوده است. اضافه کردن LSTM به CNN باعث شد دقت به ۹۷/۵٪ افزایش یابد و RMSE به ۳/۲ کاهش یابد. این نشان می‌دهد که افزودن قابلیت یادگیری وابستگی‌های زمانی تأثیر مثبتی بر هر دوشاخه (تشخیص عیب و پیش‌بینی انرژی) داشته است.

جدول (۹): مقایسه عملکرد مدل پیشنهادی با پژوهش‌های پیشین در

تشخیص عیوب سطح فولاد مربوط به مجموعه داده NEU

منبع	AUC	F1-Score	Accuracy	روش
[۱۹]	۰/۹۵	۰/۹۴	۹۵/۲٪	Zhang et al. (۲۰۲۳)
[۹]	۰/۹۷	۰/۹۶	۹۶/۸٪	Chen et al. (۲۰۲۴)
این پژوهش	۰/۹۹	۰/۹۸	۹۸/۷٪	مدل پیشنهادی (CNN+LSTM+NSGA-II)

عیب و ارتقای قابلیت اطمینان سیستم کنترل کیفیت بوده و نشان می‌دهد که مدل طراحی شده توانسته است به طور مؤثر در بهبود فرآیند کنترل کیفیت عملکرد مطلوبی از خود نشان دهد.

به طور کلی با توجه به نتایج جدول ۹ می‌توان دید که مدل پیشنهادی توانسته است عملکرد بهتری نسبت به پژوهش‌های اخیر ارائه دهد. به طور مشخص:

- دقت مدل پیشنهادی به ۹۸/۷٪ رسیده است که نسبت به کار زانگ و همکاران ۲۰۲۳ حدود ۳/۵٪ و نسبت به کار چن و همکاران ۲۰۲۴ حدود ۲٪ بهبود دارد.
- شاخص F1-Score برابر ۰/۹۸ است که نشان‌دهنده توازن مطلوب میان Precision و Recall بوده و بیانگر توانایی مدل در شناسایی هم‌زمان عیوب واقعی و کاهش خطاهای مثبت/منفی کاذب است.
- مقدار AUC-ROC برابر ۰/۹۹ به دست آمد که نشان می‌دهد مدل پیشنهادی حتی در شرایط تغییر آستانه تصمیم‌گیری نیز قدرت تفکیک بسیار بالایی دارد.

این برتری‌ها نشان می‌دهد که ترکیب معماری چندمقیاسی CNN با LSTM برای استخراج هم‌زمان ویژگی‌های مکانی و زمانی، به همراه به کارگیری الگوریتم NSGA-II جهت تنظیم بهینه پارامترهای فرآیند، موجب بهبود قابل توجه عملکرد نسبت به مدل‌های صرفاً مبتنی بر CNN یا روش‌های کلاسیک‌تر شده است. برای بررسی اثر هر بخش از معماری پیشنهادی بر عملکرد مدل، یک تحلیل ablation^۱ انجام شد. در این تحلیل، ابتدا فقط بخش CNN برای تشخیص عیوب و پیش‌بینی انرژی استفاده شد. سپس CNN با LSTM ترکیب شد تا تأثیر مدل‌سازی ویژگی‌های زمانی بر پیش‌بینی انرژی بررسی شود. در نهایت، کل معماری پیشنهادی شامل LSTM، CNN و الگوریتم بهینه‌سازی چندهدفه NSGA-II ارزیابی شد. این سناریو به ما امکان می‌دهد تا تأثیر هر مؤلفه به صورت تکی و ترکیبی بر معیارهای Accuracy، F1-Score و RMSE برای پیش‌بینی انرژی مشاهده کنیم. از طرفی

^۱ یعنی «حذف موقت بخشی از معماری» برای سنجش اثر آن

مقدار بالاتر R^2 در مدل پیشنهادی نشان می‌دهد که این مدل توانسته است تغییرات واقعی مصرف انرژی را با دقت بیشتری توضیح دهد و نسبت به روش‌های قبلی، همبستگی قوی‌تری با داده‌های واقعی داشته باشد.

- میزان RMSE در روش پیشنهادی بیانگر کاهش محسوس خطای پیش‌بینی نسبت به مدل‌های قبلی است.
- مقدار $\%MAPE$ نسبت به بهترین کار پیشین کاهش داشته است. این اختلاف هرچند کوچک به نظر می‌رسد، اما در کاربردهای صنعتی فولاد که مصرف انرژی در مقیاس مگاوات-ساعت محاسبه می‌شود، می‌تواند صرفه‌جویی قابل توجهی ایجاد کند.

به این ترتیب، جدول ۱۱ تأیید می‌کند که چارچوب پیشنهادی نه تنها در کنترل کیفیت، بلکه در پیش‌بینی انرژی هم عملکرد پایدار و برتری معنادار نسبت به پژوهش‌های پیشین دارد.

تحلیل ارزیابی پیش‌بینی مصرف انرژی

به منظور ارزیابی کارایی محاسباتی، زمان اجرای الگوریتم پیشنهادی با سه روش مرجع شامل CNN تنها، CNN+LSTM بدون بهینه‌سازی و مدل مبتنی بر الگوریتم ژنتیک کلاسیک مقایسه شد. نتایج نشان داد که با وجود افزایش جزئی در پیچیدگی محاسباتی به دلیل استفاده از الگوریتم NSGA-II، زمان اجرای هر تکرار آموزشی تنها حدود ۱/۲ برابر بیشتر از مدل CNN ساده بوده است میانگین ۴۵ ثانیه در هر epoch در مقابل دقت مدل پیشنهادی در تشخیص عیوب و پیش‌بینی انرژی به ترتیب ۲/۲٪ و ۲/۵٪ بهبود داشته است که این افزایش دقت نسبت به هزینه محاسباتی می‌تواند قابل توجه باشد. از منظر کاربرد صنعتی، زمان استنتاج مدل برای هر تصویر تنها ۱۲ میلی‌ثانیه اندازه‌گیری شد که این مقدار برای سامانه‌های کنترل بلادرنگ^۱ در خطوط تولید فولاد مناسب است. علاوه بر این، مدل در یک محیط آزمایشی صنعتی با داده‌های IoT واقعی تست شد و نتایج پایدار و سازگار

جدول (۱۰): تحلیل ablation معماری پیشنهادی بر روی مجموعه NEU

پیکربندی مدل	Accuracy	F1-Score	RMSE (انرژی)
CNN فقط	۹۵/۳٪	۰/۹۴	۶/۴
CNN + LSTM	۹۷/۵٪	۰/۹۶	۳/۲
CNN + LSTM + NSGA-II (پیشنهادی)	۹۸/۷٪	۰/۹۸	۲/۱

- مدل نهایی یعنی CNN + LSTM + NSGA-II بهترین عملکرد را ثبت کرده است: دقت ۹۸/۷٪، $F1$ برابر ۰/۹۸ و RMSE برابر ۲/۱ باشد. این نشان می‌دهد که علاوه بر قدرت معماری دوشاخه، بهینه‌سازی چندهدفه NSGA-II نقش کلیدی در هم‌زمان‌سازی شاخه‌ها و بهبود نتایج نهایی ایفا کرده است.

به طور خلاصه، ablation study تأیید می‌کند که هر بخش از معماری پیشنهادی CNN، LSTM، NSGA-II سهم مستقلی در بهبود عملکرد داشته و حذف هر بخش موجب افت معنادار نتایج خواهد شد.

۵-۲ ارزیابی پیش‌بینی مصرف انرژی

در بخش پیش‌بینی مصرف انرژی، عملکرد مدل پیشنهادی با سه پژوهش شاخص مقایسه شد.

جدول ۱۱ مقادیر خطاهای RMSE، MAE، MAPE و همچنین ضریب تعیین R^2 را برای مدل پیشنهادی و سه روش مرجع ارائه می‌کند. افزودن معیار R^2 امکان تحلیل دقیق‌تر انطباق مدل با داده‌های واقعی را فراهم می‌سازد.

جدول (۱۱): ارزیابی پیش‌بینی مصرف انرژی

مدل / پژوهش	RMSE	MAE	MAPE (%)	R^2
Chen et al. (۲۰۲۴)	۰/۱۲	۰/۱۰	۳/۴	۰/۹۲
Li et al. (۲۰۲۳)	۰/۱۰	۰/۰۸	۲/۹	۰/۹۴
Wang et al. (۲۰۲۴)	۰/۰۹	۰/۰۷	۲/۶	۰/۹۵
مدل پیشنهادی (CNN-LSTM + NSGA-II)	۰/۰۸۲	۰/۰۶	۲/۱	۰/۹۸

^۱ Near Real-Time

۶- بحث و نتیجه‌گیری

صنعت فولاد به‌عنوان یکی از صنایع انرژی بر و راهبردی، نیازمند به‌کارگیری رویکردهای هوشمند برای ارتقای کیفیت محصولات و کاهش مصرف انرژی است. در این پژوهش، یک چارچوب یادگیری عمیق یکپارچه مبتنی بر پردازش تصویر و داده‌های سنسوری ارائه شد که کنترل کیفیت سطحی و پیش‌بینی و بهینه‌سازی مصرف انرژی را به‌طور هم‌زمان هدف قرار می‌دهد. در روش پیشنهادی، از معماری EfficientNet-B4 برای استخراج ویژگی‌های تصویری چندمقیاسی و از LSTM برای مدل‌سازی وابستگی‌های زمانی داده‌های انرژی استفاده گردید و الگوریتم چندهدف NSGA-II نیز جهت تنظیم بهینه پارامترهای فرآیندی نظیر دمای کوره، سرعت نورد و فشار به کار گرفته شد. نتایج تجربی نشان داد که مدل پیشنهادی در بخش کنترل کیفیت به دقت ۹۸/۷٪ و امتیاز F1 برابر با ۹۸/۵٪ دست‌یافت و عملکردی برتر نسبت به پژوهش‌های مرجع گزارش شده ارائه کرد. در بخش پیش‌بینی مصرف انرژی نیز مقادیر RMSE برابر با ۰/۰۸۲ و MAPE٪ برابر با ۲/۱ و مقدار R^2 برابر با ۰/۹۸ به دست آمد که بیانگر دقت بالا و پایداری مناسب مدل در مواجهه با شرایط عملیاتی مختلف است. برتری روش پیشنهادی در ترکیب هم‌زمان استخراج ویژگی‌های مکانی مبتنی بر CNN و مدل‌سازی وابستگی زمانی با LSTM نهفته است. ترکیبی که امکان شناسایی الگوهای پیچیده بین کیفیت سطح محصول و مصرف انرژی را فراهم کرده و نسبت به روش‌های تک‌بعدی عملکرد بهتری ارائه داده است. این چارچوب از منظر صنعتی می‌تواند در خطوط نورد و ریخته‌گری فولاد برای پایش بلادرنگ کیفیت سطح و ارائه پیشنهادها خودکار جهت تنظیم بهینه فرآیند مورد استفاده قرار گیرد. چنین رویکردی علاوه بر کاهش نرخ ضایعات و دوباره‌کاری، موجب کاهش محسوس مصرف انرژی و هزینه‌های تولید شده و با اهداف تولید سبز و اصول صنعت ۴/۰

با شرایط عملیاتی گزارش گردید. این موضوع نشان می‌دهد که چارچوب پیشنهادی نه تنها از نظر دقت بلکه از نظر کارایی زمانی و قابلیت استقرار عملیاتی نیز پاسخگوی نیازهای صنعت فولاد می‌باشد. این نتایج نشان‌دهنده برتری مدل پیشنهادی نسبت به روش‌های مرجع است. عملکرد برتر مدل پیشنهادی در مقایسه با روش‌های مرجع را می‌توان به سه عامل کلیدی نسبت داد. نخست، استفاده از معماری EfficientNet-B4 در بخش استخراج ویژگی‌های تصویری باعث شد تا مدل بتواند جزئیات ریز عیوب سطحی را با دقت بالاتری نسبت به شبکه‌های مرسوم مانند ResNet یا VGG شناسایی نماید. دوم، ترکیب این ویژگی‌های غنی با مدل LSTM موجب شد تا وابستگی‌های زمانی میان پارامترهای فرآیندی و مصرف انرژی نیز به‌درستی مدل‌سازی شود و خطای پیش‌بینی کاهش یابد. سوم، به‌کارگیری الگوریتم بهینه‌سازی NSGA-II نقش مهمی در تنظیم هم‌زمان پارامترهای فرآیند (دمای کوره، سرعت نورد و فشار) ایفا کرده است. این ویژگی باعث دستیابی به تعادل بین کیفیت سطحی و بهره‌وری انرژی گردید. افزون بر این، NSGA-II با حفظ تنوع جمعیت راه‌حل‌ها و اجتناب از بهینه‌های محلی، توانسته است راه‌حل‌های پارتو-بهینه‌ای ارائه دهد که در عمل نیز پایدار و قابل پیاده‌سازی در محیط صنعتی است. در مقایسه با روش‌های صرفاً مبتنی بر CNN یا مدل‌های کلاسیک، چارچوب حاضر به دلیل یادگیری چندمنبعی^۱ و ادغام بهینه‌سازی چندهدفه توانسته است رفتار غیرخطی فرآیند فولادسازی را بهتر شبیه‌سازی کرده و بهبود معناداری در شاخص‌های Accuracy، F1-score و صرفه‌جویی انرژی ایجاد کند. این نتایج نشان می‌دهد که قدرت مدل پیشنهادی صرفاً ناشی از افزایش پارامترها نیست، بلکه از طراحی هدفمند ساختار شبکه و منطق بهینه‌سازی آن سرچشمه می‌گیرد.

^۱ Multi-Source Learning

هم‌تراز سازی مفهومی^۱ استفاده شد. هدف از این هم‌تراز سازی، ایجاد یک چارچوب آزمایشگاهی برای بررسی امکان ترکیب داده‌های تصویری و انرژی در یک مدل واحد بوده است. در این فرآیند، برجسب‌های زمانی به صورت مصنوعی و صرفاً برای منطبق سازی نمونه‌های تصویری با داده‌های شبیه سازی شده انرژی تولید شدند. لازم به ذکر است که این هم‌تراز سازی معادل شرایط واقعی صنعتی نیست و نتایج مربوط به پیش‌بینی انرژی را باید در دسته نتایج آزمایشگاهی و مفهومی طبقه بندی کرد؛ بنابراین، دقت‌های گزارش شده در بخش انرژی مانند RMSE تنها بیانگر عملکرد مدل در یک محیط کنترل شده شبیه سازی هستند و قابل تعمیم مستقیم به خطوط تولید واقعی نمی‌باشند. در حال حاضر هیچ پایگاه داده صنعتی که داده‌های تصویری سطوح فولادی و داده‌های انرژی را با برجسب زمانی مشترک و واقعی ترکیب کرده باشد منتشر نشده است و پژوهش حاضر نیز مدعی ارائه چنین داده‌ای نیست. هدف اصلی از این چارچوب، ارزیابی امکان پذیری ترکیب چند منبعی داده‌ها و ارائه یک مدل مفهومی قابل توسعه برای کاربردهای صنعتی آتی بوده است.

References

- [1] X. Zhang, Y. Chen, and S. Wang, "Surface defect detection in hot-rolled steel strips using improved YOLOv5," *Sci. Rep.*, vol. 14, p. 1225, 2024. doi: 10.1038/s41598-024-67891-2.
- [2] J. Li, Y. Wang, and Z. Liu, "Deep learning for industrial fault detection: A review," *IEEE Trans. Ind. Informat.*, vol. 19, no. 6, pp. 5678–5690, 2023. doi: 10.1109/TII.2022.3214567.
- [3] R. Kumar and A. Singh, "Machine learning models for energy consumption prediction in the steel industry," *Energy Rep.*, vol. 9, pp. 1234–1247, 2023. doi: 10.1016/j.egy.2023.01.045.
- [4] W. Sun, Y. Zhao, and L. Ma, "Hybrid deep learning frameworks for energy-efficient manufacturing," *J. Clean. Prod.*, vol. 453, p. 141237, 2025. doi: 10.1016/j.jclepro.2025.141237.
- [5] Q. Yao, J. Chen, and Z. Li, "Integrated quality control and energy optimization in steel production using AI," *J. Manuf. Syst.*, vol. 69, pp. 451–463, 2023. doi: 10.1016/j.jmsy.2023.07.012.

همسو است. با این حال، پژوهش حاضر همچنان با محدودیت‌هایی همراه است. از جمله وابستگی بخشی از داده‌های انرژی به نمونه‌های شبیه سازی شده، نیاز به ارزیابی چارچوب در خطوط تولید واقعی و شرایط غیرایستا دارد. آزمون مدل در سایر محیط‌های صنعتی و محصولات فلزی متفاوت برای سنجش تعمیم پذیری آن ضروری است. افزون بر این، مسیرهای متعددی برای توسعه و تکمیل این پژوهش وجود دارد. بهره‌گیری از داده‌های کاملاً واقعی و گسترده تر می‌تواند به ارتقای دقت و پایداری مدل کمک کند. همچنین توسعه معماری‌های چندوجهی پیشرفته تر مبتنی بر سازوکار توجه (Attention) می‌تواند امکان استخراج روابط پیچیده تر میان داده‌های سنسوری و تصویری را فراهم آورد. بررسی قابلیت‌های یادگیری انتقالی جهت کاهش نیاز به داده‌های آموزشی و در نهایت ترکیب مدل با سامانه‌های کنترل بلادرنگ و تحلیل اقتصادی-زیست محیطی از دیگر مسیرهای ارزشمند برای مطالعات آینده محسوب می‌شوند. با توجه به این که پایگاه داده NEU Surface Defect فاقد هرگونه اطلاعات زمانی یا داده‌های انرژی است، در این پژوهش از یک سازوکار

- [6] H. Wang and Y. Xu, "Limitations of separate AI models for defect detection and energy prediction in industrial manufacturing," *IEEE Access*, vol. 12, pp. 15532–15545, 2024. doi: 10.1109/ACCESS.2024.3356712.
- [7] S. Kim, J. Park, and D. Lee, "Unified deep learning framework for defect detection, predictive maintenance, and energy optimization in steel manufacturing," *Appl. Energy*, vol. 353, p. 121945, 2025. doi: 10.1016/j.apenergy.2025.121945.
- [8] H. Liu, Y. Zhang, and M. Zhou, "Crack detection in steel surfaces using multi-scale CNN," *Mater. Today Commun.*, vol. 36, p. 107469, 2023. doi: 10.1016/j.mtcomm.2023.107469.
- [9] F. Chen, W. Li, and Q. Zhao, "IoT-based predictive maintenance system for steel manufacturing," *IEEE Internet Things J.*, vol. 11, no. 8, pp. 13567–13578, 2024. doi: 10.1109/JIOT.2024.3345678.
- [10] R. Patel, S. Kumar, and A. Mehta, "Machine vision-based defect classification in steel manufacturing," *J. Manuf. Process.*, vol. 80, pp. 345–355, 2022. doi: 10.1016/j.jmapro.2022.07.013.

¹ Conceptual Time Alignment



- [11] Z. Wang, D. Yu, and Z. Wu, "Real-time machine-learning-based optimization using input convex LSTM," arXiv, 2023. [Online]. Available: <https://arxiv.org/abs/2311.07202>
- [12] Y. Lv, R. Hu, B. Qian, and J. B. Yang, "Q-learning-based hierarchical cooperative local search for steelmaking-continuous casting scheduling," arXiv, 2025. [Online]. Available: <https://arxiv.org/abs/2506.08608>
- [13] N. Lee, M. Shin, A. Sagingalieva, A. J. Tripathi, K. Pinto, and A. Melnikov, "Predictive control of blast furnace temperature in steelmaking with hybrid depth-infused quantum neural networks," arXiv, 2025. [Online]. Available: <https://arxiv.org/abs/2504.12389>
- [14] M. Abbasi, M. Plaza-Hernandez, J. Prieto, and J. M. Corchado, "Artificial intelligence of things infrastructure for quality control in cast manufacturing," Appl. Sci., vol. 15, no. 4, p. 2068, 2023. [Online]. Available: <https://www.mdpi.com/2076-3417/15/4/2068>
- [15] V. Varriale, A. Cammarano, F. Michelino, and M. Caputo, "Critical analysis of AI integration with cutting-edge technologies for production systems," J. Intell. Manuf., 2023. doi: 10.1007/s10845-023-02244-8.
- [16] D. Zhou, K. Xu, Z. Lv, J. Yang, M. Li, F. He, and G. Xu, "Intelligent manufacturing technology in the steel industry of China: A review," Sensors, vol. 22, no. 21, p. 8194, 2022. doi: 10.3390/s22218194.
- [17] M. Hollander, D. A. Wolfe, and E. Chicken, Nonparametric Statistical Methods, 3rd ed. Hoboken, NJ, USA: Wiley, 2015.
- [18] P. R. Rosenbaum, "Exact confidence intervals for nonconstant effects by inverting the signed-rank test," J. Amer. Stat. Assoc., 2012. doi: 10.1198/0003130031405.
- [19] Y. Zhang, S. Wang, Z. Jiang, J. Wang, and Y. Ma, "Strip steel surface defect detection based on lightweight YOLOv5 with feature fusion," Front. Neurorobot., vol. 17, p. 1154214, 2023. doi: 10.3389/fnbot.2023.1154214.

Intelligent Quality Control and Defect Detection in Steel Manufacturing Processes Using Deep Learning and Image Processing for Energy Optimization

Fatemeh Saadatjou^{1*}, Moslem Molalie²

¹Assistant Professor, Department of Computer Engineering, Science and Arts University, Yazd, Iran

²Teacher, Hormozgan Education, Rudan Education Computer Group, Hormozgan, Iran

Article Information

Original Research Paper

Received:
2025 September 15

Accepted:
2025 November 17

Keywords:
Artificial Intelligence, Deep Learning, CNN-LSTM, Steel Industry

Corresponding Author*:
saadatjou@sau.ac.ir

Abstract

In recent years, the increasing competition in the steel industry and the urgent demand for reducing costs while improving quality have accelerated the adoption of artificial intelligence technologies. One of the major challenges in this domain is ensuring accurate product quality control and efficient energy management, both of which directly affect productivity and sustainability. This study proposes an integrated deep learning framework for simultaneous quality inspection and energy optimization in steel manufacturing. High-resolution surface images from the NEU surface defect dataset, combined with simulated energy consumption records, were pre-processed through filtering, normalization, and temporal alignment techniques. A hybrid multi-branch architecture, combining convolutional neural networks (CNN) for defect detection and CNN-LSTM for energy prediction, was implemented and optimized using the NSGA-II multi-objective algorithm. Experimental results demonstrate that the proposed approach achieved 98.7% accuracy and an F1-score of 98.5% in defect detection, while reducing the prediction error of energy consumption to an RMSE of 0.082 and MAPE of 2.1%. These improvements not only outperform recent state-of-the-art methods but also contribute to reducing rework, minimizing scrap rates, and achieving measurable energy savings. The proposed methodology offers a practical step toward green steel production and the realization of Industry 4.0 in heavy industries.

 : 10.22034/ABMIR.2025.23661.1167

E-ISSN: [2821-2037](#)

/© 2025. Published by Yazd University This is an open access article under the CC BY 4.0 License (<https://creativecommons.org/licenses/by/4.0/>).

