

بهبود بخش‌بندی عیوب سطح فولاد با بهینه‌سازی ابرپارامترهای فیلتر گابور توسط الگوریتم ژنتیک و

طبقه‌بندی جنگل تصادفی

پریسا فتحیان بروجنی^۱، فریبا نمیرانیان^{۲*}، فهیمه رشیدی^۳

^۱ دانشجوی ارشد دانشکده فنی، دانشگاه FAU، ارلانگن، آلمان

^۲ مهندس ارشد هوش مصنوعی، شرکت نیکورسام ویرا ایساتیس، ایران

^۳ دانشجوی دکتری دانشکده کامپیوتر، دانشگاه یزد، یزد، ایران

چکیده

مقاله پژوهشی

تاریخ دریافت:

۱۴۰۴/۰۸/۱۹

تاریخ پذیرش:

۱۴۰۴/۰۹/۱۱

کلیدواژه‌ها:

بخش‌بندی سطح فولاد، شناسایی عیوب فولاد، الگوریتم ژنتیک، جنگل تصادفی

نویسنده مسئول:

Fariba.namiranian75@gmail.com

کنترل کیفیت سطح محصولات و شناسایی به موقع عیوبی مانند ترک‌ها، حفره‌ها و ناخالصی‌ها در صنعت فولاد از اهمیت بالایی برخوردار است. این عیوب می‌توانند عملکرد مکانیکی، دوام و قابلیت اطمینان فولاد را کاهش دهند. در این پژوهش، رویکردی نوین برای بخش‌بندی و شناسایی هوشمند عیوب سطح فولاد با استفاده از الگوریتم ژنتیک و جنگل تصادفی ارائه شده است. ابتدا ویژگی‌های تصاویر با استفاده از فیلترهای گابور استخراج شده و سپس با الگوریتم جنگل تصادفی، پیکسل‌ها به گروه‌های دارای ویژگی‌های مشابه تقسیم می‌شوند. ابرپارامترهای فیلترهای گابور به عنوان ژن‌های کروموزوم در الگوریتم ژنتیک در نظر گرفته شده و با هدف بهینه‌سازی عملکرد بخش‌بندی تنظیم می‌شوند. تابع برازندگی مبتنی بر F1-score دقت طبقه‌بندی را ارزیابی می‌کند. نتایج نشان می‌دهد که بهینه‌سازی ابرپارامترهای فیلترهای گابور توسط الگوریتم ژنتیک، دقت و کارایی بخش‌بندی عیوب سطح فولاد را افزایش داده است. روش پیشنهادی به F1-score برابر ۰/۹۸۰۷ و دقت ۰/۹۸۱۰ دست یافته و نسبت به روش‌های مرجع بهبود عملکرد نشان می‌دهد. این یافته‌ها نشان می‌دهد که روش پیشنهادی می‌تواند به عنوان یک ابزار برای نظارت خودکار بر کیفیت در خطوط تولید فولاد عمل کند.

doi : 10.22034/ABMIR.2025.23933.1182

۱- مقدمه

انتهایی تقسیم‌بندی می‌کند. الگوریتم آن‌ها با ترکیب فیلترگذاری همومورفیک برای نرمال‌سازی روشنایی، آستانه‌گذاری شدت روشنایی، عملیات مورفولوژیک و روش‌های آماری توانست این بخش‌ها را استخراج کند. این مطالعه با استفاده از ۴۰۰ تصویر صنعتی انجام شد و نشان داد که بخش‌بندی مبتنی بر شدت روشنایی و مرزهای استخراج‌شده می‌تواند مبنایی برای محاسبه شاخص‌های کیفی لبه‌ی برشی و پایش فرآیند در مقیاس صنعتی فراهم کند [۶].

در سال ۲۰۲۲ میلادی اوسامنتیگا و همکاران به بررسی و مقایسه‌ی روش‌های مختلف تشخیص خودکار عیوب سطح فلزات، به‌ویژه فولاد، پرداختند. در این پژوهش از دو معماری مبتنی بر یادگیری عمیق، شامل YOLOv5 برای آشکارسازی اشیاء و U-Net برای بخش‌بندی معنایی تصاویر استفاده شد. داده‌های آزمایش شامل مجموعه‌داده‌های صنعتی NEU-1800 و NEU-900 بود که دارای عیوب متداول سطح فولاد از جمله ترک، پوسته، حفره، اکسید و فرورفتگی هستند. نتایج آزمایش‌ها نشان داد که مدل YOLOv5 در مقایسه با نسخه‌های قبلی خود دقت مناسبی در تشخیص ناحیه‌ی عیوب داشته و مدل U-Net در تعیین دقیق مرز عیوب عملکرد قابل توجهی از خود نشان داد [۷].

در سال ۲۰۲۳ میلادی ژانگ و همکاران رویکردی مبتنی بر یادگیری عمیق و تطبیق دامنه چندمنبعی برای شناسایی و بخش‌بندی عیوب سطح فولاد ارائه دادند. در این روش از شبکه‌ی پویا سلسله‌مراتبی استفاده شد که با بهره‌گیری از پولینگ پویا و ادغام ویژگی‌های چندمقیاسی، توانست ویژگی‌های بافتی و ساختاری سطوح فولادی را با دقت بیش‌تری استخراج کند. این مدل با به‌کارگیری مکانیزم‌های یادگیری مقابله‌ای^۱ و انتقال دانش چنددامنه‌ای^۲ قادر بود در داده‌های آزمون عملکرد دقیقی داشته باشد. آن‌ها آزمایش‌های خود را بر روی مجموعه‌داده‌های-NEU Seg و Severstal انجام دادند [۸].

بخش‌بندی تصویر یکی از فناوری‌های کلیدی در پردازش تصویر و بینایی ماشین است و نقش حیاتی در کنترل کیفیت محصولات فولادی ایفا می‌کند. در این فرآیند، تصاویر سطح فولاد به نواحی مجزا بر اساس ویژگی‌هایی مانند بافت، رنگ و شکل هندسی تقسیم می‌شوند، به‌گونه‌ای که مناطق دارای ویژگی‌های مشابه بتوانند برای شناسایی ترک‌ها، حفره‌ها و حباب‌ها مورد استفاده قرار گیرند [۱]. بخش‌بندی دقیق تصاویر، امکان ارزیابی خودکار و سریع کیفیت فولاد در خطوط تولید را فراهم کرده و از ساخت محصول‌های معیوب جلوگیری می‌کند، که این امر به طور مستقیم بر بهره‌وری و کاهش هزینه‌های تولید تأثیرگذار است.

بخش‌بندی تصویر در صنعت فولاد به طور گسترده‌ای در سیستم‌های بازرسی خودکار خطوط نورد و ریخته‌گری، تشخیص عیوب سطحی در ورق‌ها و شمش‌ها و نظارت بر کیفیت محصول‌های نهایی کاربرد دارد [۴-۲]. انتخاب روش مناسب بخش‌بندی تصاویر سطح فولاد به ویژگی‌های تصویر، شرایط تصویربرداری، میزان نویز و بافت سطح فولاد بستگی دارد [۱]. تاکنون تکنیک‌ها و الگوریتم‌های متعددی برای این منظور ارائه شده‌اند که در ادامه به مرور برخی از آن‌ها پرداخته می‌شود.

در سال ۲۰۱۷ میلادی نئوجی و همکاران روشی کلاسیک برای تشخیص عیوب سطح فولاد ارائه کردند که بر پایه تصویر گرادیان و آستانه‌گذاری تطبیقی استوار است. در این روش، به‌جای استفاده از یک آستانه ثابت برای تفکیک نواحی معیوب، مقدار آستانه به‌صورت پویا با توجه به تعداد پیکسل‌هایی که از سطح خاکستری معینی در تصویر گرادیان فراتر رفته‌اند تنظیم می‌شود. نتایج این مطالعه نشان می‌دهد که این روش از روش‌های ساده آستانه‌گذاری ثابت مثل اوتسو و آستانه‌گذاری محلی بهتر عمل می‌کند [۵].

در سال ۲۰۱۹ میلادی زایلر و همکاران رویکردی مبتنی بر بینایی ماشین برای بازرسی خودکار لبه‌های برشی ورق‌های فولادی ارائه کردند. در این پژوهش یک الگوریتم نوین طراحی شد که تصاویر ثبت‌شده توسط دوربین را به چهار ناحیه‌ی اصلی شامل بخش صیقلی، ناحیه‌ی شکست، ناحیه‌ی شکست معیوب و پلیسه‌ی

² Multi-target domain-based knowledge transfer

¹ Adversarial learning

مهم تصویر افزایش یافت. همچنین با ترکیب ویژگی‌های سطح پایین و سطح بالا، دقت تشخیص مرز عیوب بهبود پیدا کرد. نتایج آزمایش‌ها روی مجموعه داده شامل عیوبی مانند خراش، لکه و ناخالصی نشان داد که مدل پیشنهادی نسبت به مدل U-Net عملکرد بهتری داشته و میانگین دقت هم‌پوشانی آن از ۷۶٫۸۷ درصد به ۷۹٫۰۷ درصد افزایش یافته است [۱۱].

در سال ۲۰۲۵ میلادی وانگ و همکاران روشی مبتنی بر سوپریکسل‌ها برای بخش‌بندی عیوب سطح داخلی لوله‌های فولادی ارائه کردند. در این پژوهش، ابتدا تصاویر با در نظر گرفتن اطلاعات لبه به سوپریکسل‌های همگن تجزیه می‌شوند. سپس برای توصیف دقیق‌تر بافت نواحی معیوب و سالم از فیلترهای گابور و تبدیل فوریه به صورت ترکیبی استفاده شده و ویژگی‌های استخراج شده به یک طبقه‌بند ماشین بردار پشتیبان داده می‌شود تا احتمال تعلق هر سوپریکسل به ناحیه‌ی معیوب تخمین زده شود. در گام بعد، خروجی ماشین بردار پشتیبان همراه با مدل آمیخته‌گاوسی و وزن‌دهی مبتنی بر لبه‌ها در قالب یک مدل ادغام می‌شود تا مرزبندی دقیق‌تری از عیوب حاصل شود. این روش بر روی ۱۰۰ تصویر صنعتی آزمایش شد و توانست به مقدار IoU برابر ۸۷٫۹۴٪ دست یابد [۱۲].

با وجود پیشرفت‌های قابل توجه در روش‌های آستانه‌گذاری کلاسیک، الگوریتم‌های مبتنی بر بینایی ماشین و مدل‌های یادگیری عمیق، مرور ادبیات نشان می‌دهد که هر یک از این رویکردها با محدودیت‌هایی همراه هستند. روش‌های کلاسیک آستانه‌گذاری، هرچند ساده و سریع‌اند؛ اما در مواجهه با بافت‌های غیرهمگن، روشنایی غیریک‌نواخت و مرزهای کم‌کنتراست عملکرد مطلوبی ندارند و به سادگی دچار بیش‌تقسیمی یا کم‌تقسیمی می‌شوند. روش‌های مبتنی بر پردازش سنتی تصویر نیز وابستگی زیادی به تنظیم دستی پارامترها و شرایط یک‌نواخت تصویربرداری دارند. از سوی دیگر، مدل‌های یادگیری عمیق مانند U-Net، FR-Net یا DeepLabV3+ برای دستیابی به عملکرد پایدار نیازمند حجم بزرگی از داده‌های برچسب‌خورده هستند و در کاربردهای صنعتی با کمبود نمونه، تنوع محدود داده یا نویز زیاد دچار بیش‌برازش و

در سال ۲۰۲۴ میلادی فنگ و همکاران شبکه‌ای به نام FR-Net^۱ را برای بخش‌بندی سریع عیوب سطح فولاد نواری معرفی کردند. این مدل بر پایه‌ی ساختار رمزگذار- رمزگشا طراحی شد و با بهره‌گیری از سه ماژول اصلی شامل FFM^۲ برای ترکیب ویژگی‌های عمقی و کم‌عمق، FRM^۳ برای بهبود بیان ویژگی‌ها، و RASPP^۴ برای ادغام اطلاعات چندمقیاسی، دقت و سرعت تشخیص عیوب کوچک را افزایش داد. در آزمایش‌ها روی مجموعه داده‌های NEU-Seg و SD-Saliency-900، مدل به ترتیب به دقت‌های ۸۴٫۵۳٪ و ۸۷٫۲۴٪ و سرعت ۵۸ فریم بر ثانیه دست یافت که عملکرد بهتری نسبت به مدل‌های متداول نشان داد [۹].

در سال ۲۰۲۴ میلادی راوات و همکاران رویکردی ترکیبی برای طبقه‌بندی عیوب سطح فولاد ارائه کردند. این روش بر پایه ترکیب شبکه‌ی عصبی کانولوشنی و جنگل تصادفی طراحی شده است. در این روش، ابتدا شبکه کانولوشنی با چهار لایه کانولوشن و چهار لایه بیشینه‌سازی، ویژگی‌های بافتی سطوح معیوب را در سطوح مختلف استخراج می‌کند. سپس خروجی آن به عنوان ورودی به طبقه‌بند جنگل تصادفی داده می‌شود تا دقت دسته‌بندی افزایش یابد. آن‌ها مجموعه داده‌ای شامل ۴۳۴۸ تصویر از پنج نوع عیب متداول شامل ترک ریز، درون‌گیرها، لکه، سطح حفره دار و خراش را مورد استفاده قرار دادند. نتایج نشان داد که مدل پیشنهادی با دستیابی به دقت ۹۷٫۲۸٪ عملکرد پایداری در تشخیص و طبقه‌بندی این عیوب دارد. این پژوهش نشان می‌دهد که ترکیب شبکه کانولوشنی و جنگل تصادفی می‌تواند رویکردی مؤثر برای بهبود دقت سیستم‌های بازرسی خودکار و ارتقای کیفیت تولید در صنایع فولاد باشد [۱۰].

در سال ۲۰۲۴ میلادی گوچلو و همکاران با ارائه مدل deepLabV3+، روشی برای بخش‌بندی عیوب سطح فولاد ارائه کردند. در این پژوهش با بازطراحی ماژول هر می نمونه‌برداری مکانی گسترش یافته و افزودن ماژول فشردگی و تحریک، توانایی مدل در استخراج ویژگی‌های چندمقیاسی و تمرکز بر بخش‌های

^۳ Feature Refinement Module (FRM)


^۴ Residual Atrous Spatial Pyramid Pooling (RASPP)

^۱ Feature Reused Network (FR-Net)

^۲ Feature Fusion Module (FFM)

تصادفی آغاز می‌شود. در این الگوریتم پاسخ‌های نامزد به گونه‌ای کدگذاری می‌شوند که بتوان آن‌ها را توسط تابع برازندگی^۲ ارزیابی و سپس با عملگرهای ژنتیکی مختلف پردازش کرد. هر نامزد توسط یک کروموزوم^۳ نمایش داده می‌شود که شامل رشته‌ای از ژن‌ها^۴ است. به جمعیت در هر زمان نسل گفته می‌شود و در هر تکرار الگوریتم، نسل جدید تولید و برازندگی کروموزوم‌ها محاسبه می‌شود.

در تولید نسل بعد، عملگرهای ژنتیک مانند تقاطع^۵ و جهش^۶ با احتمال مشخص اعمال می‌شوند و نوزادان^۷ جدید تولید می‌شوند. برازندگی نوزادان محاسبه شده و کروموزوم‌های بهتر با روش‌های انتخاب به نسل بعد منتقل می‌شوند. اجرای الگوریتم به این صورت است که کروموزوم‌ها با عملگرهای ژنتیک سعی می‌کنند فضای جستجو را بهتر کاوش و برازندگی خود را افزایش دهند تا بهترین راه‌حل‌ها پیدا شوند. برای درک بهتر الگوریتم ژنتیک در شکل ۱ آورده شده است.



شکل (۱): روندنمای الگوریتم ژنتیک

افت دقت در مرزبندی عیوب می‌شوند. علاوه بر این، بسیاری از مدل‌ها در شناسایی عیوب کوچک، ناپیوسته یا با مرزهای مبهم ضعف دارند. بنابراین نیاز به روشی سبک، کم‌داده‌محور و مقاوم وجود دارد که بتواند مرزبندی دقیق عیوب را انجام دهد. روش این پژوهش با هدف رفع این محدودیت‌ها ارائه شده است.

در این پژوهش با هدف بهبود دقت در شناسایی عیوب سطح فولاد، روشی ترکیبی مبتنی بر الگوریتم ژنتیک و جنگل تصادفی ارائه شده است. در این روش، ویژگی‌های بافتی تصاویر با استفاده از فیلترهای گابور استخراج می‌شوند و سپس به وسیله الگوریتم جنگل تصادفی، پیکسل‌ها بر اساس شباهت ویژگی‌ها گروه‌بندی می‌گردند. به منظور دستیابی به بهترین کارایی در بخش‌بندی پارامترهای فیلتر گابور با استفاده از الگوریتم ژنتیک بهینه‌سازی شده‌اند. نتایج به دست آمده نشان می‌دهد که این روش موجب افزایش دقت شده است و می‌تواند به عنوان رویکردی هوشمند برای کنترل کیفیت خودکار در صنایع فولاد به کار گرفته شود.

ساختار مقاله به این صورت تنظیم شده است: در بخش دوم، مفاهیم پایه‌ای مرتبط با الگوریتم ژنتیک، جنگل تصادفی و فیلتر گابور تشریح می‌شود. در بخش سوم، روش پیشنهادی برای بخش‌بندی و شناسایی عیوب سطح فولاد معرفی می‌گردد. بخش چهارم به تشریح و تحلیل نتایج حاصل از پیاده‌سازی و ارزیابی روش پیشنهادی اختصاص دارد و در نهایت، در بخش پنجم جمع‌بندی و نتیجه‌گیری کلی از پژوهش ارائه می‌شود.

۲- مفاهیم پایه

در این قسمت به معرفی مختصر الگوریتم ژنتیک، الگوریتم جنگل تصادفی و فیلتر گابور که در رویکرد پیشنهادی استفاده شده است، پرداخته می‌شود.

۲-۱- الگوریتم ژنتیک

الگوریتم ژنتیک اولین بار توسط جان هلند^۱ در سال ۱۹۸۹ مطرح شد و با ایجاد یک مجموعه جواب ابتدایی به عنوان جمعیت اولیه

^۵ Cross Over

^۶ Mutation

^۷ Offspring

^۱ John Holland

^۲ Fitness Function

^۳ Chromosome

^۴ Gene

رابطه فیلتر گابور دارای دو جزء حقیقی و موهومی است. فیلتر گابور در رابطه ۱ نشان داده شده است.

$$g(x,y;\lambda,\square,\Psi,\sigma,\gamma) = \exp\left(\frac{x^2 + \gamma^2 y^2}{2\sigma^2}\right) \exp\left(i\left(2\pi\frac{x}{\lambda} + \Psi\right)\right) \quad (1)$$

در این رابطه λ طول موج سینوسی را نشان می‌دهد. $\square$ نشان‌دهنده جهت‌گیری در تابع گابور می‌باشد. Ψ نشان‌دهنده انحراف فاز است. σ انحراف معیار گاوسی و γ نسبت ابعاد و بیضی بودن تابع گابور را مشخص می‌کند.

۳- روش پیشنهادی

هدف اصلی در بخش‌بندی تصاویر سطح فولاد تمایز نواحی مختلف سطح شامل بخش‌های سالم، ترک‌دار، زنگ‌زده و سایر عیوب سطحی است. الگوریتم پیشنهادی این مطالعه در شکل ۲ نمایش داده شده است.

در این روش، تصاویر ورودی ابتدا با مجموعه‌ای از فیلترهای تصویر شامل فیلترهای گابور، کنی، روبرتر، سوبل، اسپر، پریویت^۵ و گاوسی کانولوشن می‌شوند تا ویژگی‌های مهم برای بخش‌بندی استخراج گردد. سپس خروجی هر فیلتر به صورت بردار ستونی در نظر گرفته شده و به عنوان ورودی الگوریتم طبقه‌بندی ارائه می‌شود.

با توجه به این که روش مورد استفاده در این تحقیق مبتنی بر یادگیری با نظارت است، تصاویر آموزشی پیش از اجرای الگوریتم توسط کارشناسان خبره بخش‌بندی شده‌اند. این تصاویر مشابه داده‌های ورودی، به بردارهای ستونی تبدیل شده و مراحل پردازش و بخش‌بندی مطابق شکل ۳ قابل مشاهده است.

با توجه به اینکه فیلتر گابور یکی از فیلترهای مؤثر برای استخراج ویژگی‌های مرتبط با بخش‌بندی تصاویر است، در این مطالعه از فیلتر گابور با مقادیر متفاوت ابرپارامترها برای پردازش تصاویر

در الگوریتم ژنتیک با توجه به کدگذاری مسئله عمل‌گرهای تقاطع و جهش متفاوتی انجام می‌شود. هنگامی که عمل‌گر تقاطع بر روی دو کروموزم اعمال می‌شود، با جابه‌جایی مقادیر به مرور زمان اطلاعات مفید نسل‌های گذشته به کروموزم‌های جدید منتقل می‌شوند.

در عمل جهش هر ژن با احتمال از پیش تعریف شده، تغییر می‌کند و موجب حذف ژنی از مجموعه ژن‌های جمعیت می‌شود یا ژنی که تا به حال وجود نداشته است به آن اضافه خواهد شد. توسط جهش می‌توان انتظار داشت که کروموزوم‌های خوبی که در مراحل انتخاب و یا تکثیر حذف شده‌اند، دوباره احیا شوند. استفاده از جهش باعث می‌شود عمل کاوش در فضای جواب بهتر صورت گیرد. باید دقت شود فرزندان جدیدی که در هر نسل با استفاده از تقاطع و جهش تولید می‌شوند، بررسی شوند تا محدودیت‌های مسئله را ارضا کنند [۱۳].

۲-۲- الگوریتم جنگل تصادفی

جنگل تصادفی یکی از الگوریتم‌های یادگیری نظارت شده است که برای مسائل رگرسیون^۱ و طبقه‌بندی کاربرد دارد. اساس کار این الگوریتم درخت تصمیم است. اگر درخت تصمیم بیش از حد عمیق باشد، ممکن است دچار بیش‌برازش^۲ شود. برای حل این مشکل جنگل تصادفی پیشنهاد شده است [۱۴].

جنگل تصادفی روشی است برای میانگین‌گیری از درخت‌های تصمیم عمیقی که از قسمت‌های مختلف داده آموزشی ایجاد شده باشند. هدف از این روش کاهش واریانس و افزایش عملکرد مدل می‌باشد [۱۵].

۲-۳- فیلتر گابور

فیلترها در پردازش تصویر نقش مهمی دارند و یکی از آن‌ها فیلتر گابور است که به نام دنیس گابور^۳ نام‌گذاری شده و یک فیلتر خطی است. این فیلتر برای استخراج ویژگی و تحلیل بافت استفاده می‌شود [۱۶].

⁵ Roberts

⁶ Sobel

⁷ Scharr

⁸ Prewitt

¹ Regression

² Overfitting

³ Dennis Gabor

⁴ Canny

گابور است و از آن جا که این پارامترها مقادیر پیوسته دارند، از الگوریتم ژنتیک پیوسته برای بهینه‌سازی استفاده می‌شود. تعداد ژن‌های هر کروموزوم برابر حاصل ضرب تعداد فیلترها در تعداد ابرپارامترهای فیلتر گابور است. یک نمونه از کروموزوم در شکل ۴ نشان داده شده است.



ابرپارامترهای فیلتر گابور اول

شکل (۴): نمونه‌ای از کروموزوم

پس از استخراج ویژگی‌ها، دقت بخش‌بندی تصویر با استفاده از الگوریتم جنگل تصادفی ارزیابی می‌شود و میانگین F1-score به عنوان تابع برازندگی کروموزوم در نظر گرفته می‌شود. فرآیند الگوریتم تا رسیدن به معیار همگرایی از پیش تعیین‌شده ادامه می‌یابد.

۴- شبیه‌سازی و ارزیابی


در این قسمت به توضیح مجموعه دادگان و مراحل پیاده‌سازی و ارزیابی پرداخته خواهد شد.

۴-۱- مجموعه دادگان

در این پژوهش، برای ارزیابی عملکرد الگوریتم بخش‌بندی تصاویر فولادی، از مجموعه‌دادگان Kolektor Surface-Defect (KolektorSDD) استفاده شده است [۱۷]. این مجموعه‌دادگان توسط شرکت Kolektor Group برای شناسایی و تحلیل عیوب سطحی در قطعات فولادی صنعتی تهیه شده و یکی از منابع معتبر در زمینه بازرسی بصری خودکار محسوب می‌شود.


مجموعه KolektorSDD شامل ۳۹۹ تصویر رنگی از سطوح فولادی واقعی است که در شرایط نوری و صنعتی کنترل‌شده ثبت شده است. در این تصاویر، بخشی از نمونه‌ها دارای عیوب سطحی نظیر خراش، ترک‌های ریز، حفره و لکه‌های غیرطبیعی هستند، در حالی که سایر تصاویر مربوط به سطوح سالم و بدون نقص می‌باشند. برای هر تصویر، ماسک دودویی فراهم شده است که ناحیه‌ی دقیق عیب را مشخص می‌کند و به عنوان برچسب برای آموزش و ارزیابی مدل‌های بخش‌بندی مورد استفاده قرار می‌گیرد.

استفاده شده است. فیلتر گابور دارای ابرپارامترهای σ ، λ و θ است که تنظیم بهینه آن‌ها نقش مهمی در دقت بخش‌بندی دارد.



شکل (۲): روندنمای رویکرد پیشنهادی

در روش پیشنهادی ابرپارامترها با استفاده از الگوریتم ژنتیک به گونه‌ای تعیین می‌شوند که عملکرد بخش‌بندی بهینه گردد. در این الگوریتم، هر کروموزوم نمایانگر مجموعه‌ای از ابرپارامترهای فیلتر



شکل (۳): رویکرد پیشنهادی جهت اعمال فیلتر بر روی تصاویر

۲-۴- پیاده‌سازی و ارزیابی

شبیه‌سازی روش پیشنهادی بر روی یک رابانه با مشخصات حافظه‌ی ۸ گیگابایت، پردازنده‌ی ۷ هسته‌ای و سیستم عامل ویندوز ۱۰ انجام شد. پیاده‌سازی الگوریتم‌ها با زبان برنامه‌نویسی پایتون و در محیط توسعه‌ی اسپایدر^۱ صورت گرفت.

در شبیه‌سازی روش پیشنهادی از ۴ فیلتر گابور استفاده شد. علاوه بر فیلترهای گابور از فیلترهای کنی، روبرتز، سوبل، اسپر، پریویت، گاوسی و میانه نیز برای استخراج بهتر ویژگی تصاویر استفاده گردید. پارامترهای استفاده شده برای الگوریتم ژنتیک در جدول ۱ آورده شده است.

جدول (۱): پارامترهای الگوریتم ژنتیک در بخش بندی تصویر

اندازه جمعیت	۳۰
احتمال تقاطع	۰/۸
احتمال جهش	۰/۰۹
روش انتخاب	چرخ رولت
روش تقاطع	تقاطع یکنواخت
تعداد تکرارها	۵۰

برای عملگر انتخاب در الگوریتم ژنتیک، از چرخ رولت استفاده شده است. در این روش هر کروموزوم معادل با یک قطاع از چرخ

استفاده از این مجموعه دادگان به دلیل تنوع نوع و شدت عیوب، کیفیت بالای تصاویر و برچسب‌گذاری دقیق، امکان بررسی عملکرد الگوریتم پیشنهادی در تفکیک نواحی معیوب و سالم فولاد را با دقت بالا فراهم می‌سازد. مجموعه دادگان به نسبت ۸۰٪ برای آموزش و ۲۰٪ برای آزمون تقسیم شد. نمونه‌ای از تصاویر این مجموعه به همراه برچسب مربوطه در شکل ۵ نمایش داده شده است.



الف) تصویر اصلی
ب) برچسب تصویر
شکل (۵): نمونه‌ای از مجموعه دادگان

^۱ Spyder

بهترین F1-score به دست آمده برابر با ۰/۹۸۰۷ است که نسبت به مراجع [۱۰] و [۱۲] بهبود قابل توجهی داشته است. مقادیر مناسب به دست آمده برای ابرپارامترهای فیلتر گابور در جدول ۲ آورده شده است.

جدول (۲): مقادیر به دست آمده برای ابرپارامترهای فیلتر گابور

فیلتر گابور	σ	θ	λ	γ
فیلتر گابور ۱	۳/۲۰۷۱۶۴	۱/۶۵۱۲۸	۱/۸۰۲۷۵۴	۰/۶۲۲۴۸۷
فیلتر گابور ۲	۳/۴۵۳۳۳۲	۰/۰۶۸۱۴	۲/۰۳۳۱۵۴	۰/۴۶۸۹۱۴
فیلتر گابور ۳	۳/۰۱۴۷۵۱	۱/۷۷۲۲۵	۲/۰۴۶۷۸۱	۰/۳۳۴۱۸۲
فیلتر گابور ۴	۴/۰۱۳۴۹۱	۲/۱۴۶۹۲	۰/۹۵۴۶۳۱	۰/۴۲۴۵۴۹

به طور خلاصه مقایسه‌ای بین دقت حاصل از روش پیشنهادی و دو روش مراجع [۱۰] و [۱۲] در جدول ۳ آمده است.

جدول (۳): مقایسه رویکرد پیشنهادی با رویکردهای پیشین

رویکرد	F1-score	precision	recall	accuracy
رویکرد پیشنهادی	۰/۹۸۰۷	۰/۹۸۲۵	۰/۹۷۹۱	۰/۹۸۱۰
رویکرد مرجع [۱۰]	۰/۹۷۱	۰/۹۷۵	۰/۹۶۹	۰/۹۶۶
رویکرد مرجع [۱۲]	۰/۹۳۴	۰/۹۱۸	۰/۹۵۲	۰/۹۷۳

با توجه به مقایسه انجام گرفته رویکرد پیشنهادی در بخش‌بندی تصویر و شناسایی عیوب فولاد نسبت به دو رویکرد پیشین، نتیجه بهتری را داده است.

۵- نتیجه‌گیری

در این مقاله رویکردی برای بخش‌بندی و شناسایی عیوب سطح فولاد ارائه شد که بر پایه‌ی ترکیب الگوریتم جنگل تصادفی و بهینه‌سازی پارامترهای فیلتر گابور با استفاده از الگوریتم ژنتیک بنا شده است. در روش پیشنهادی، ویژگی‌های بافتی و لبه‌ای تصاویر فولاد با بهره‌گیری از چهار فیلتر گابور و فیلترهای کلاسیکی مانند کنی، روبرتز، سوبل، اسپر، پریویت و گاوسی استخراج گردید. الگوریتم ژنتیک برای تنظیم بهینه‌ی ابرپارامترهای فیلترهای گابور به‌کار گرفته شد، به‌گونه‌ای که هر کروموزوم بیان‌گر مجموعه‌ای از این پارامترها بوده و تابع برازندگی بر اساس میانگین معیار F1

دایره‌ای است. اندازه‌ی این قطاع متناسب با برازندگی نرمالیزه هر کروموزوم است. این شیوه‌ی انتخاب بیش‌تر تمایل به انتخاب کروموزوم‌هایی با مقدار برازندگی بالا دارد [۱۸]. مقدار برازندگی مطابق رابطه ۲ از F1-score حاصل از اجرای الگوریتم جنگل تصادفی به دست آمده است.

$$F1\text{-score} = 2 \times \frac{(\text{precision} \times \text{recall})}{(\text{precision} + \text{recall})} \quad (۲)$$

در این رابطه مقدار F1-score از ترکیبی از صحت^۱ و پوشش به دست می‌آید. رابطه ۳ و ۴ به ترتیب نشان‌دهنده معیارهای صحت و پوشش است.


$$\text{precision} = \frac{TP}{TP + FP} \quad (۳)$$

$$\text{recall} = \frac{TP}{TP + FN} \quad (۴)$$

TP نشان‌دهنده پیکسل‌های صحیح بخش‌بندی شده و FP و FN نشان‌دهنده پیکسل‌هایی با بخش‌بندی نادرست هستند. TN نشان‌دهنده پیکسل‌های صحیح بخش‌بندی شده است. دقت از دیگر معیارهایی است که برای ارزیابی استفاده می‌شود. در رابطه ۵ مقدار دقت آورده شده است.

$$\text{Accuracy} = \frac{TP + TN}{TP + FN + TN + FP} \quad (۵)$$

در این رابطه دقت برابر است با نسبت بخش‌بندی‌های درست به کل بخش‌بندی‌هایی که انجام شده است. نمودار همگرایی در شکل ۶ نشان داده شده است. در این نمودار محور افقی تعداد تکرار و محور عمودی بهترین F1-score به دست آمده است.



شکل (۶): نمودار همگرایی الگوریتم ژنتیک بر اساس بهترین مقدار F1-score در طول ۵۰ تکرار

^۱ Precision

افزایش توانایی مدل در شناسایی عیوب پیچیده مؤثر باشد. دوم، استفاده از روش‌های یادگیری انتقالی و تکنیک‌های افزایش داده می‌تواند چالش کمبود داده‌های برچسب‌خورده صنعتی را تا حدی رفع کند. هم‌چنین توسعه نسخه بلادرنگ الگوریتم جهت کاربرد در خطوط تولید واقعی، ادغام سیستم با سخت‌افزارهای صنعتی و بررسی مقاومت مدل در برابر شرایط متغیر نوری و نویز محیطی از دیگر زمینه‌های مهم پژوهش‌های آتی محسوب می‌شود. در نهایت، پیشنهاد می‌شود عملکرد الگوریتم بر روی مجموعه‌داده‌گان متنوع‌تر شامل عیوب ریز، ناپیوسته و یا چندکلاسه ارزیابی شود تا قابلیت تعمیم‌پذیری روش در کاربردهای صنعتی گسترده‌تر مورد سنجش قرار گیرد.

References

- [1] R. Neven and T. Goedemé, "A multi-branch U-Net for steel surface defect type and severity segmentation," *Metals*, vol. 11, no. 6, 2021.
- [2] D. Sime, G. Wang, Z. Zeng and B. Peng, "Deep learning-based automated steel surface defect segmentation: a comparative experimental study," *Multimedia Tools Application*, vol. 83, no. 1, pp. 2995–3018, 2024.
- [3] M. Sharma, L. Jongtae and L. Hansung, "The amalgamation of the object detection and semantic segmentation for steel surface defect detection," *Application Science*, vol. 12, no. 12, 2022.
- [4] A. Ibrahim and T. Jules, "A survey of vision-based methods for surface defects' detection and classification in steel products," *Informatics*, vol. 11, no. 2, 2024.
- [5] N. Neogi, D. Mohanta, P. Dutta, "Defect detection of steel surfaces with global adaptive percentile thresholding of gradient image", *Journal of the Institution of Engineers*, vol. 98, no. 6, pp. 557-565, 2017.
- [6] A. Zeiler, A. Steinboeck, M. Vincze, M. Jochum, "Vision-based inspection and segmentation of trimmed steel edges", *IFAC-PapersOnLine*, vol. 52, no.14, pp. 165-170, 2019.
- [7] R. Usamentiaga, D. Lema, O. Pedrayes and D. Garcia, "Automated surface defect detection in metals: a comparative review of object detection and semantic segmentation using deep learning,"
- IEEE Transaction Industrial Application, vol. 58, no. 3, pp. 4203–4213, 2022.
- [8] C. Zhang and X. Zhang, "Multi-target domain-based hierarchical dynamic instance segmentation method for steel defects detection," *Neural Computing Application*, vol. 35, no. 10, pp. 7389–7406, 2023.
- [9] Q. Feng, F. Li, H. Li and X. Liu, "Feature reused network: a fast segmentation network model for strip steel surfaces defects based on feature reused," *Visual Computer*, vol. 40, no. 5, pp. 3633–3648, 2024.
- [10] S. Rawat, D. Banerjee, P. Aggarwal and M. Singh, "CNN and random forest fusion for enhanced steel defect classification", *International Conference on Advances in Modern Age Technologies for Health and Engineering Science*, pp. 1-6, 2024.
- [11] E. Güçlü, İ. Aydın and E. Akin, "Improved deeplabv3+ based steel surface defect segmentation," in *2024 ASU International Conference in Emerging Technologies for Sustainability and Intelligent Systems*, pp. 609–613, 2024.
- [12] H. Wang, Y. Xie, Y. Wang, C. Zhang, P. Ni, Y. Lu and Y. Wang, "Surface defect segmentation of steel pipes based on superpixel prior knowledge", *Engineering Research Express*, vol. 7, no. 3, 2025.
- [13] Z. Shahidi Zandi and A. Latif, "Developing a modern method in circle detection in digital images by using genetic algorithm," *Machine*



- Vision Image Processing, vol. 8, no. 1, pp. 35–44, 2021.
- [14] S. Pirayonesi and T. El-Diraby, “Data analytics in asset management: cost-effective prediction of the pavement condition index,” *Infrastructure System*, vol. 26, no. 1, p. 04019036, 2020.
- [15] V. Rodriguez-Galiano, M. Sanchez-Castillo, M. Chica-Olmo and M. Chica-Rivas, “Machine learning predictive models for mineral prospectivity: An evaluation of neural networks, random forest, regression trees and support vector machines,” *Ore Geology Reviews*, vol. 71, pp. 804–818, 2015.
- [16] T. Vijayan, M. Sangeetha and A. Kumaravel, “WITHDRAWN: Gabor filter and machine learning based diabetic retinopathy analysis and detection,” *Microprocessors and Microsystems*, 2020.
- [17] “Kolektor Surface-Defect Dataset (KolektorSDD/KSDD).” Accessed: Nov. 04, 2025. [Online]. Available: <https://www.vicos.si/resources/kolektorsdd/>
- [18] A. Lipowski and D. Lipowska, “Roulette-wheel selection via stochastic acceptance,” *Physica A: Statistical Mechanics and its Applications*, vol. 391, no. 6, pp. 2193–2196, 2012.

Improving Steel Surface Defect Segmentation by Optimizing Gabor Filter Hyperparameters Using a Genetic Algorithm and Random Forest Classification

Parisa Fathian Broujeni¹, Fariba Namiranian^{2*}, Fahimeh Rashidy³

¹ Master Student, Technische Faculty, FAU University, Erlangen, Germany

² AI Engineer, Nikoo Rassam Vira Isatis Company, Iran

³ PhD student, Faculty of Computer Engineering, Yazd University, Yazd, Iran

Article Information

Original Research Paper

Received:

2025 November 10

Accepted:

2025 December 01

Keywords:

Steel Surface Segmentation, Steel Defect Detection, Genetic Algorithm, Random Forest

Corresponding Author*:

Fariba.namiranian75@gmail.com

Abstract

In the steel industry, it is crucial to control surface quality and to promptly detect defects such as cracks, pores, and impurities, as these flaws can compromise the mechanical performance, durability, and reliability of steel. In this study, a novel approach for image segmentation and intelligent detection of steel surface defects is presented using a combination of the Genetic Algorithm and Random Forest. In the proposed method, image features are extracted using Gabor filters, and then the pixels are classified into groups with similar characteristics through the Random Forest algorithm. The hyperparameters of the Gabor filters are considered as the genes of chromosomes in the Genetic Algorithm and are optimized to enhance the segmentation performance. The fitness function, based on the F1-score, measures the classification performance. The results indicate that optimizing the Gabor filter hyperparameters with the Genetic Algorithm enhances both the accuracy and efficiency of steel surface defect segmentation, achieving an F1-score of 0.9807 and an accuracy of 0.9810, and demonstrating that this method is an effective and reliable tool for automated quality control in steel production lines.



: 10.22034/ABMIR.2025.23933.1182

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/>).

