The Journal of Engine Research

Summer 2025, Vol. 72, No. 2, pp. 9-18

Journal Homepage: www.engineresearch.ir

Original Research

Defect detection in piston rings using deep learning-based computer vision

Alireza Ranjbar[1], Alireza Hajalimohammadi[1*], Ashkan Moosavian[2], Zahra Barin[3], Mohammad Reza Rahmani[4]

1- Faculty of Mechanical Engineering, Semnan University, Semnan, Iran
2- Department of Mechanical Engineering, Technical and Vocational University (TVU), Tehran, Iran
3- Research and Development Department, Ring Khodro Pars Company, Takestan, Iran
4- Quality Control Department, Ring Khodro Pars Company, Takestan, Iran

ARTICLE INFO

Keywords:
Piston Ring
Defect Detection
Deep Learning
Convolutional Neural Networks
Image Segmentation
Quality Control

ABSTRACT

This study introduces a novel deep learning-based approach for the automated and accurate detection of surface defects in piston rings, utilizing convolutional neural networks (CNNs). A high-quality dataset of defective and non-defective piston ring images was collected and meticulously annotated. We trained a U-Net model on this dataset, which effectively segments defective regions, achieving an impressive Intersection over Union (IoU) score of 84% and a loss of 0.15. These results demonstrate the model's high precision in identifying various defect types. A comparative analysis with traditional defect detection methods underscores the superiority of our deep learning approach in both accuracy and processing speed. Additionally, the experimental findings align closely with theoretical predictions from prior research, further validating the proposed model. This research represents a significant advancement in automotive quality control, offering the potential to reduce manufacturing costs associated with defective components.

© 2025 Iranian Society of Engine, Tehran, Iran. This article is an open-access article distributed under the terms and conditions of the Creative Commons Attribution Noncommercial 4.0 International (CC BY-NC 4.0 license). (https://creativecommons.org/licenses/by-nc/4.0/).

* Corresponding author
E-mail address: ahajiali@semnan.ac.ir (AR. Hajalimohammadi)

Received 4 April 2025; Accepted 30 May 2025
E-ISSN: 2345-4121/ISSN: 1735-5214

Cite this article: Ranjbar A, Hajalimohammadi A, Moosavian A, Barin Z, Rahmani MR. Defect detection in piston rings using deep learning-based computer vision. The Journal of Engine Research. 2025 Jun 22;72(2):9-18. doi: 10.22034/ER.2025.2056649.1080

نشریه علمی تحقیقات موتور
تابستان ۱٤۰٤، جلد ۷۲، شماره ۲، صفحه ۹-۱۸
تارنمای نشریه: www.engineresearch.ir

مقاله پژوهشی

تشخیص عیوب حلقهٔ سمبه با استفاده از روش‌های یادگیری عمیق در سامانهٔ بینایی رایانه‌ای

علیرضا رنجبر[۱]، علیرضا حاجی علی محمدی[۱*]، سید اشکان موسویان[۲]، زهرا برین[۳]،محمد رضا رحمانی[۴]

۱- دانشکده مهندسی مکانیک، دانشگاه سمنان، سمنان، ایران
۲- گروه مهندسی مکانیک، دانشگاه ملی مهارت، تهران، ایران
۳- واحد تحقیق و توسعه، شرکت رینگ خودرو پارس، تاکستان، ایران
۴- واحد کنترل کیفیت، شرکت رینگ خودرو پارس، تاکستان، ایران

اطلاعات مقاله

کلیدواژه‌ها:
حلقهٔ سمبه
شبکه‌های عصبی پیچشی
کنترل کیفیت
پردازش تصویر
یادگیری عمیق

چکیده

در این پژوهش، روشی نوین برای تشخیص دقیق و خودکار عیوب سطحی در حلقه‌های سمبه با بهره‌گیری از روش‌های یادگیری عمیق و به ویژه شبکه‌های عصبی پیچشی ارائه شده است. با جمع‌آوری داده‌های تصویری با کیفیت از حلقه‌های سالم و معیوب و آموزش یک طرح شبکهٔ یو بر روی این داده‌ها، توانایی تشخیص انواع مختلف عیوب با دقت بالا محقق گردید. نتایج حاصل از ارزیابی طرح نشان‌دهندهٔ عملکرد بسیار خوب آن با مقدار همپوشانی بر اتحاد برابر ۸۴٪ و مقدار تابع هزینه برابر ۰,۱۵ است. مقایسهٔ نتایج حاصل از طرح پیشنهادی با روش‌های سنتی تشخیص عیوب، برتری قابل توجه روش مبتنی بر یادگیری عمیق را در دقت و سرعت تشخیص نشان می‌دهد. همچنین، تطابق نتایج تجربی با نتایج نظری حاصل از مطالعات پیشین، اعتبار طرح پیشنهادی را تأیید می‌کند. این پژوهش گامی مهم برای بهبود کنترل کیفیت در فرآیند تولید حلقهٔ سمبه و کاهش هزینه‌های ناشی از نقص قطعات محسوب می‌شود.

© 2025 Iranian Society of Engine, Tehran, Iran. This article is an open-access article distributed under the terms and conditions of the Creative Commons Attribution Noncommercial 4.0 International (CC BY-NC 4.0 license). (https://creativecommons.org/licenses/by-nc/4.0/).

* نویسنده مسئول
پست الکترونیکی: ahajiali@semnan.ac.ir (علیرضا حاجی علی محمدی)

دریافت ۱۵ فروردین ۱۴۰۴؛ پذیرش ۹ خرداد ۱۴۰۴
شاپای الکترونیکی: ۴۱۲۱-۲۳۴۵ / شاپای چاپی: ۵۲۱۴-۱۷۳۵

Cite this article: Ranjbar A, Hajalimohammadi A, Moosavian A, Barin Z, Rahmani MR. Defect detection in piston rings using deep learning-based computer vision. The Journal of Engine Research. 2025 Jun 22;72(2):9-18. doi: 10.22034/ER.2025.2056649.1080

۱- مقدمه

با توجه به رشد چشمگیر صنعت خودروسازی و افزایش تقاضا برای خودروهای باکیفیت و قابل اعتماد [۱]، اهمیت کنترل کیفیت اجزای موتور، از جمله حلقه‌های سمبه، بیش از پیش احساس می‌شود. حلقه‌های سمبه، به عنوان المان‌های کلیدی در آب‌بندی محفظه احتراق، نقش حیاتی در عملکرد و دوام موتور ایفا می‌کنند [۲]. عیوب سطحی مانند ترک، خراش یا تغییرات ابعادی در این قطعات می‌تواند به طور مستقیم بر عملکرد موتور و عمر مفید آن تأثیرگذار باشد. از این‌رو، توسعه روش‌های دقیق و مؤثر برای تشخیص این عیوب، به منظور تضمین کیفیت و حفظ اعتبار برندهای خودروسازی، امری ضروری است [۳]. روش‌های سنتی تشخیص عیوب در محیط‌های تولیدی، اغلب به بازرسی بصری دستی یا سامانه‌های بینایی رایانه‌ای رایج متکی بوده‌اند [۴]. این روش‌ها نه تنها زمان‌بر و مستعد خطای انسانی هستند، بلکه به شدت به قضاوت فردی بازرس نیز وابسته‌اند. به ویژه در خطوط تولید با حجم بالا، مانند تولید هزاران حلقهٔ سمبه در روز، این مشکلات به طور چشمگیری تشدید می‌شوند [۵].

تحقیقات گسترده‌ای در زمینه تشخیص عیوب حلقهٔ سمبه انجام شده است که منجر به توسعه طیف وسیعی از روش‌ها شده است. در ابتدا، روش‌های پردازش تصویر رایج مانند تشخیص لبه و آستانه‌گذاری برای این منظور به کار گرفته می‌شدند. با این حال، در سال‌های اخیر، رویکردهای یادگیری ماشین به عنوان جایگزینی قدرتمند برای این روش‌های سنتی مطرح شده‌اند [۶]. اگرچه این روش‌ها از نظر محاسباتی کارآمدند، اما در مواجهه با الگوهای پیچیده عیوب، تغییرات نورپردازی و نوفهٔ تصاویر، با محدودیت‌هایی روبرو می‌شوند. برای مثال، لین و همکاران [۷] از ترکیبی از تشخیص لبه و تحلیل بافت استفاده کرد، اما روش آن‌ها به شدت تحت تأثیر بازتاب‌های سطح قرار می‌گرفت که در مقایسه با روش‌های مبتنی بر یادگیری عمیق، دقت کمتری داشت. در پژوهشی از سلیقه و همکاران [۸]، بررسی سایش ابزار و نیروهای برش در تراشکاری پیشانی قطعات دوفلزی ساخته شده از آلومینیوم و چدن پرداخته شد. در این پژوهش، از روش پردازش تصویر مبتنی بر روش نزدیک‌ترین همسایه[1] برای محاسبهٔ سایش ابزار در سطح جانبی آن استفاده شده است. نتایج نشان می‌دهد که سایش برای قطعات دوفلزی نسبت به قطعات چدنی بیشتر است و بین نیروی برش و سایش ابزار همبستگی وجود دارد.

در این زمینه، از روش‌های یادگیری رایانه‌ای همچون ماشین بردار پشتیبان[2] و جنگل‌های تصادفی نیز استفاده شده است [۹]. این روش‌ها با یادگیری خودکار ویژگی‌ها از داده‌ها، پتانسیل بهبود عملکرد نسبت به روش‌های سنتی را دارند. با این حال، نیاز به مهندسی دقیق ویژگی‌ها و محدودیت در تعمیم پذیری طرح‌ها به انواع مختلف عیوب، از چالش‌های این روش‌ها است. به‌عنوان مثال، در مطالعه زیدک و همکاران [۱۰]، با وجود استفاده از ماشین بردار پشتیبان و ویژگی‌های مهندسی‌شده، عملکرد طرح به دلیل چالش در طراحی ویژگی‌هایی که بتوانند انواع مختلف عیوب را به خوبی تشخیص دهند، محدود بود. یادگیری عمیق، به ویژه شبکه‌های پیچشی، به دلیل توانایی خود در یادگیری خودکار ویژگی‌های پیچیده از تصاویر خام، تحولی عظیم در تشخیص عیوب مبتنی بر تصویر ایجاد کرده است. مطالعات متعددی مانند پژوهش بات و همکاران [۱۱] اثربخشی شبکه‌های پیچشی را در تشخیص انواع مختلف عیوب سطحی در قطعات صنعتی نشان داده‌اند. با این حال، بسیاری از این پژوهش‌ها عمدتاً بر روی طبقه‌بندی (یعنی تعیین وجود یا عدم وجود نقص) تمرکز کرده‌اند و کمتر به مکان‌یابی دقیق و تقسیم‌بندی عیوب پرداخته‌اند. حسینی و همکاران [۱۲] در این پژوهش یک سامانه بینایی رایانه‌ای مبتنی بر شبکه عصبی عمیق ارائه می‌دهند، این سامانه روشی نوین برای اندازه‌گیری دقیق‌تر و کارآمدتر مشخصات حرکتی تسمه سفت‌کن موتورهای درون‌سوز در آزمون‌های صحه‌گذاری است، که جایگزین مناسبی برای روش‌های سنتی است.

[1] K-Nearest Neighbors (Knn)
[2] Support Vector Machines (SVM)

در مطالعه دیگری تقندیکی و همکاران [۱۳] به کاربرد یادگیری عمیق در تشخیص خرابی سامانهٔ فشار هوای کامیون‌های اسکانیا پرداختند. با استفاده از داده‌های حسگرها و روش‌های یادگیری عمیق، امکان تشخیص دقیق‌تر خرابی‌ها و کاهش هزینه‌های تعمیر فراهم شده است. نتایج نشان می‌دهد که این روش دقت بالایی در تشخیص خرابی‌ها دارد. در پژوهشی دیگر از سوی رحمتی‌نژاد و همکاران [۱۴] به تشخیص عیوب ابعادی و ترک در سوپاپ‌ها با استفاده از بینایی رایانه‌ای و نشرآوایی می‌پردازد. متغیرهای ابعادی دریچه مانند طول، قطر ساق و قطر نشیمنگاه با استفاده از پردازش تصویر اندازه‌گیری و با مقادیر واقعی مقایسه شدند. در این پژوهش، ابتدا با استفاده از روش‌های انتخاب ویژگی، ویژگی‌های مهم از میان داده‌ها استخراج شده و سپس طرح یادگیری عمیق آموزش داده شده است. نتایج نشان می‌دهد که روش یادگیری عمیق با دقت ۹۸٫۶۶٪ قادر به تشخیص خرابی‌ها است.

در این پژوهش، با هدف ارتقای دقت و سرعت تشخیص عیوب سطحی در حلقهٔ سمبه، روشی مبتنی بر یادگیری عمیق و سامانه‌های بینایی رایانه‌ای پیشنهاد شده است. با بهره‌گیری از یک شبکه عصبی پیچشی از نوع شبکه یو، طرحی قدرتمند برای تشخیص دقیق و خودکار انواع مختلف عیوب سطحی در حلقهٔ سمبه آموزش داده شده است. وجه تمایز این پژوهش با مطالعات پیشین، استفاده از معماری شبکهٔ یو برای بخش‌بندی دقیق عیوب و مکان‌یابی دقیق آن‌ها در حلقه همچنین به کارگیری روش‌های افزونگی داده[1] برای بهبود عملکرد طرح است. نتایج ارزیابی طرح نشان‌دهنده عملکرد بسیار خوب آن در تشخیص دقیق عیوب و تفکیک مناطق معیوب از مناطق سالم است.

۲- طراحی و پیاده‌سازی سامانه نورپردازی

نورپردازی مناسب در فرآیند تصویربرداری از نمونه‌های حلقهٔ سمبه نقش بسیار مهمی در کیفیت تصاویر و در نهایت دقت تشخیص عیوب ایفا می‌کند. نورپردازی نامناسب می‌تواند منجر به ایجاد سایه‌های ناخواسته، بازتاب‌های شدید، کاهش تضاد رنگ[2] و در نهایت کاهش دقت طرح یادگیری عمیق شود. در این پژوهش، برای دستیابی به تصاویر با کیفیت از حلقهٔ سمبه‌ها و بهبود دقت تشخیص عیوب، یک سامانه نورپردازی دقیق و کارآمد طراحی و پیاده‌سازی شده است. هدف اصلی از طراحی این سامانه، ایجاد نورپردازی یکنواخت و کاهش سایه‌ها بر روی سطح حلقهٔ سمبه بوده است تا بتوان عیوب سطحی را به وضوح مشاهده کرد.

شکل ۱ الگوی سامانهٔ نورپردازی طراحی شده است که متشکل از چند دیود نوری[3] با دما و رنگ ثابت و یکنواخت است که با هدف بهینه‌سازی شرایط نورپردازی، به گونه‌ای قرار گرفته‌اند که روشنایی یکنواختی را بر روی سطح نمونه ایجاد کند. با استفاده از بازتابنده‌های مناسب، نور ساطع شده از منابع نوری به سمت سطح نمونه هدایت شده و با کمک یک پخش کنندهٔ نور[4]، شدت نور یکنواخت شده و از ایجاد سایه‌های ناخواسته جلوگیری می‌شود. این پیکربندی نورپردازی، شرایط آرمانی را برای تصویربرداری از نمونه فراهم کرده و به بهبود دقت تشخیص عیوب کمک شایانی می‌کند.

در این پژوهش، برای تصویربرداری از حلقهٔ سمبه و بررسی دقیق عیوب سطحی، از یک دوربین گوشی همراه مجهز به عدسی بزرگ[5] با دقت ۵ مگاپیکسل و پردهٔ[6] f/۲,۴ استفاده شده است. این دوربین با توجه به ویژگی‌های خاص خود، امکان ثبت تصاویر با کیفیت و جزئیات کافی را برای تحلیل‌های بعدی فراهم می‌کند. شکل ۲ نمونه‌ای از تصاویر ثبت شده توسط دوربین مورد استفاده در سامانه را نشان می‌دهد.

[1] Data Augmentation
[2] Contrast
[3] LED
[4] Diffuser
[5] Macro lens
[6] Diaphragm

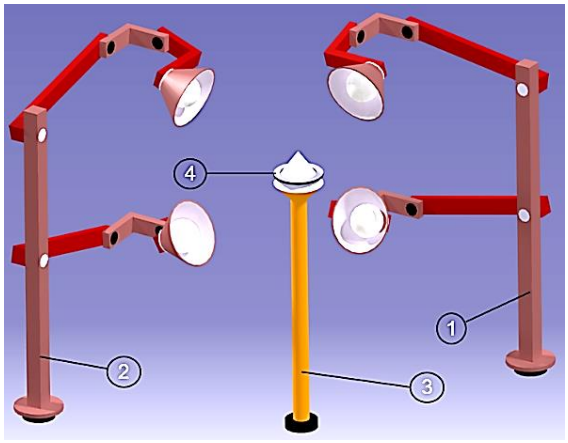

شکل ۱ سامانه نورپردازی: (۱ و ۲) منبع نور، (۳) ابزار نگهدارندهٔ حلقهٔ سمبه، (۴) حلقهٔ سمبه

شکل ۲ نمونه حلقهٔ معیوب

۳- طراحی و آموزش طرح شبکهٔ یو

در این پژوهش، از معماری شبکهٔ یو به عنوان یک ابزار قدرتمند برای تقسیم‌بندی تصاویر حلقهٔ سمبه استفاده شده است. ساختار متقارن شبکه یو، که نموداری از آن در شکل ۳ قابل مشاهده است، این امکان را می‌دهد تا هم ویژگی‌های محلی مانند لبه‌ها و بافت‌ها و هم ویژگی‌های سطح بالا مانند شکل کلی حلقهٔ سمبه را به طور همزمان استخراج کند. به طور خلاصه، شبکهٔ یو از یک بخش رمزگذار برای کاهش ابعاد تصویر و استخراج ویژگی‌های سلسله مراتبی و یک بخش رمزگشا برای بازسازی دقیق تصویر تقسیم‌بندی شده تشکیل شده است. اتصالات بین لایه‌های متناظر در بخش رمزگذار و رمزگشا، امکان انتقال اطلاعات مکانی دقیق را فراهم می‌کنند که برای تقسیم‌بندی دقیق نواحی معیوب بسیار حیاتی است. این ویژگی‌ها، شبکهٔ یو را به یک انتخاب مناسب برای تشخیص دقیق نواحی معیوب در تصاویر حلقهٔ سمبه تبدیل کرده است.

برای آموزش طرح، از مجموعه داده‌ای شامل حدود ۱۲۰۰ تصویر پس از انجام افزونگی داده استفاده شد. نسبت تقسیم داده‌ها برای آموزش و اعتبارسنجی به ترتیب ۸۰ به ۲۰ درصد در نظر گرفته شد. در خصوص توازن مجموعه داده، تلاش شد تا حد امکان تعداد تصاویر مربوط به هر نوع عیب به یکدیگر نزدیک باشد. به طور دقیق‌تر، انواع عیوب موجود در تصاویر شامل حفره، خراش و خوردگی بودند. پس از بررسی اولیه، مشخص شد که تعداد تصاویر مربوط به حفره و خراش نسبتاً بالا و نزدیک به هم است، اما تعداد تصاویر مربوط به خوردگی کمتر بود. برای رفع این عدم توازن، از روش‌های افزونگی داده به صورت هدفمند بر روی تصاویر خوردگی استفاده شد.

برای استخراج ویژگی‌های قوی از تصاویر، از طرح شبکهٔ کارای بی پنج[1] به عنوان ستون فقرات طرح شبکهٔ یو استفاده شده است. شبکهٔ کارای بی پنج یک طرح پیش‌آموزش دیده شده روی مجموعه داده شبکه تصویر[2] است که به

[1] EfficientNetB5
[2] ImageNet

دلیل کارایی و توانایی در استخراج ویژگی‌های پیچیده، انتخاب مناسبی برای این کاربرد است. در ابتدای پژوهش، ستون‌های فقرات مختلفی نظیر شبکهٔ رِز[1]، شبکهٔ دِنس[2] و وی جی جی[3] نیز بررسی شدند. طرح‌های وی جی جی به دلیل ساختار ساده‌تر، دقت پایین‌تری در مقایسه با سایر طرح‌ها داشت. از طرفی، طرح‌های شبکهٔ رِز و دِنس به دلیل پیچیدگی بیشتر، به سرعت دچار پدیدهٔ بیش‌برازش می‌شدند. در نهایت، شبکهٔ کارای بی پنج به دلیل ارائه تعادل مناسب بین دقت و پیچیدگی، به عنوان ستون فقرات نهایی انتخاب شد. استفاده از ستون فقرات‌های پیش‌آموزش دیده باعث می‌شود که طرح سریع‌تر همگرا شود و به داده‌های آموزشی کمتری نیاز داشته باشد.

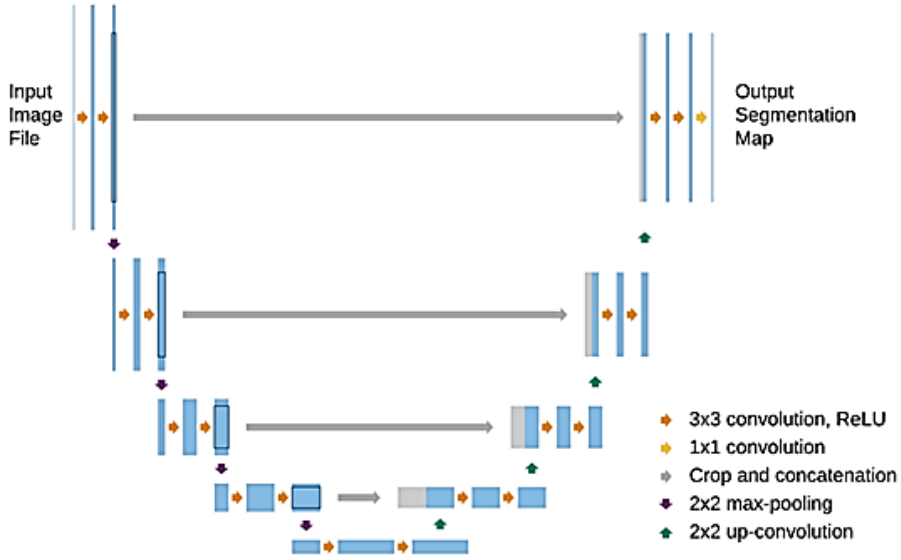

شکل ۳ شبکه یو [۱۵]

۴- ارزیابی عملکرد طرح

برای ارزیابی عملکرد طرح شبکهٔ یو آموزش داده شده در تشخیص عیوب سطحی حلقهٔ سمبه، از دو معیار اصلی ای او یو[4] و افت کانونی طبقه‌بندی[5] استفاده شده است. این معیارها به دلیل توانایی آن‌ها در ارزیابی دقیق طرح‌های بخش بندی، به طور گسترده در این حوزه استفاده می‌شوند.

ای او یو یا همپوشانی بر اتحاد، یک معیار رایج برای ارزیابی عملکرد طرح‌های بخش بندی است. این معیار میزان همپوشانی بین پیش‌بینی‌های طرح و برچسب‌های واقعی را اندازه‌گیری می‌کند. به عبارت دیگر، ای او یو نشان می‌دهد که چه مقدار از پیش‌بینی‌های طرح با واقعیت مطابقت دارد. مقدار ای او یو بین ۰ تا ۱ متغیر است، به طوری که مقدار ۱ نشان‌دهنده همپوشانی کامل بین پیش‌بینی و واقعیت است [۱۶].

$$IoU = \frac{TP}{TP + FP + FN} \quad (۱)$$

افت کانونی طبقه‌بندی شده یک تابع هزینه است که برای مشکلات طبقه‌بندی چند سطحی[6] با عدم تعادل سطح استفاده می‌شود. در مسئله تشخیص عیوب سطحی، معمولاً تعداد پیکسل‌های سالم بسیار بیشتر از پیکسل‌های معیوب

[1] ResNet
[2] DenseNet
[3] VGG
[4] IoU Score
[5] Categorical Focal Loss
[6] Class

است. این عدم تعادل می‌تواند باعث شود که طرح به طور عمده به طبقه اکثریت (پیکسل‌های سالم) توجه کند و در شناسایی سطح اقلیت (پیکسل‌های معیوب) عملکرد ضعیفی داشته باشد.این تابع با اعمال یک وزن به هر نمونه، این مشکل را برطرف میکند. وزن اعمالی به گونه‌ای انتخاب می‌شود که به نمونه‌های سخت‌تر (نمونه‌هایی که به سختی قابل طبقه‌بندی هستند) وزن بیشتری داده شود. در نتیجه، طرح به طور موثرتر بر روی نمونه‌های سخت تمرکز می‌کند و عملکرد کلی را بهبود می‌بخشد.

۵– نتایج و بحث

در شکل‌های ۴ و ۵ نتایج حاصل از ارزیابی طرح پیشنهادی نشان‌داده شده است.با توجه به نمودار شکل ۴، طرح توانسته است به ای او یو بالایی دست یابد که نشان‌دهنده دقت بالای آن در تشخیص صحیح اشیاء در تصاویر است. علاوه بر این، افزایش تدریجی مقدار ای او یو در طول مراحل آموزش، حاکی از آن است که طرح به تدریج و به طور موثر الگوهای موجود در داده‌های آموزشی را یاد گرفته و توانایی تعمیم این الگوها به داده‌های جدید و دیده نشده را پیدا کرده است.

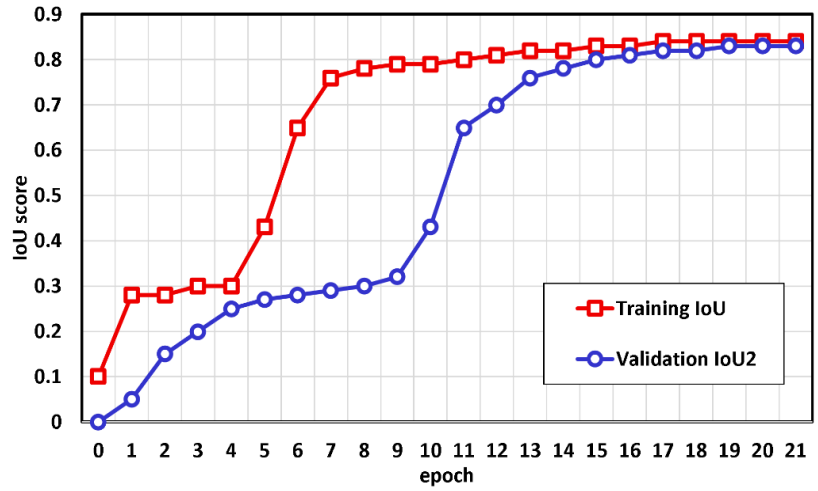

شکل ٤ نمودار تغییرات ای او یو

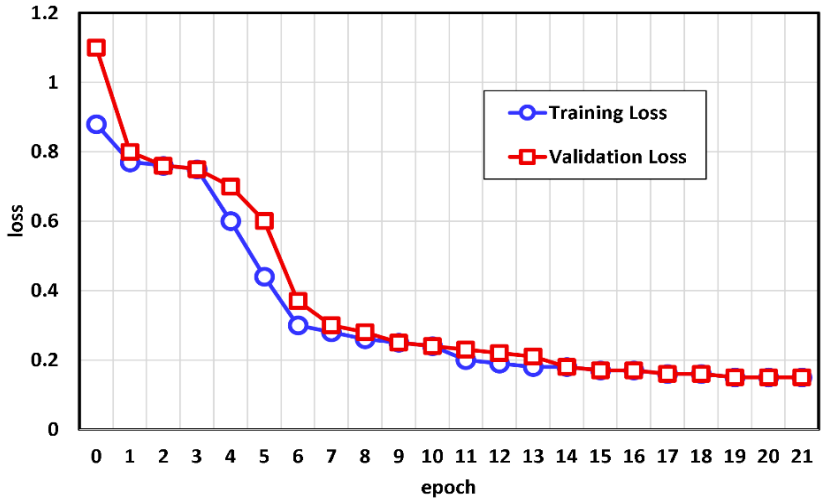

شکل ٥ تغییرات تابع هزینه

همچنین تفاوت ناچیز بین ای او یو در مجموعه داده‌های آموزش و اعتبارسنجی نشان‌دهنده آن است که طرح دچار مشکل بیش‌برازش[1] نشده است. بیش‌برازش به معنای آن است که طرح بیش از حد به ویژگی‌های خاص داده‌های آموزشی وابسته شده و در نتیجه در تشخیص اشیاء در داده‌های جدید با مشکل مواجه می‌شود.

همانطور که در شکل ۵ مشاهده می‌شود، کاهش قابل توجه تابع هزینه در طول فرایند آموزش نیز مؤید این نکته است که طرح به تدریج به سمت یک جواب بهینه همگرا شده است.

نتایج حاصل از ارزیابی طرح نشان می‌دهد که این طرح قادر است انواع مختلف عیوب سطحی از جمله ترک‌ها، خراش‌ها و حفره‌ها را با حساسیت و ویژگی بالا تشخیص دهد. همچنین نمونهٔ پیش بینی شده توسط طرح در شکل ۶ نشان‌دهنده عملکرد بسیار خوب طرح در تشخیص دقیق و قابل اعتماد عیوب حلقهٔ سمبه است که می‌تواند در بهبود فرآیندهای کنترل کیفیت در صنعت خودروسازی بسیار مفید باشد.

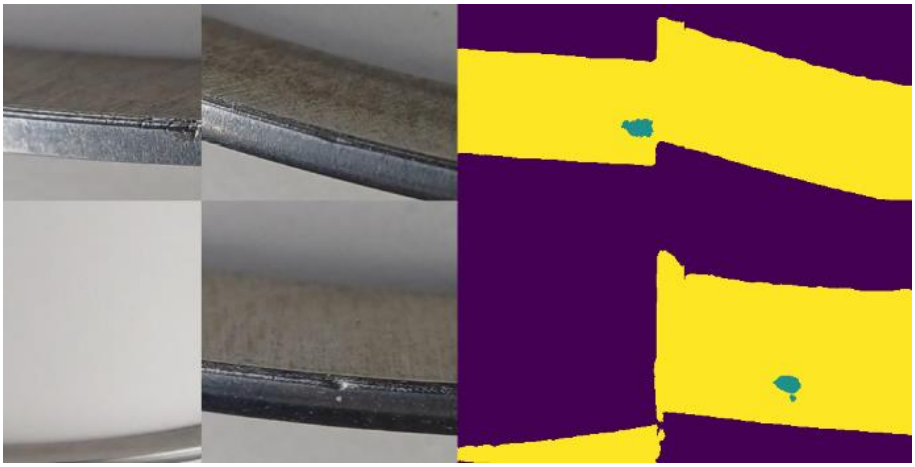

شکل ٦ نمونه تصویر پیش‌بینی شده توسط طرح (شکل سمت چپ تصویر واقعی و شکل سمت راست تصویر تولید شده)

طرح پیشنهادی در مقایسه با روش‌های سنتی تشخیص عیوب سطحی، تحولی شگرف ایجاد کرده است. برخلاف روش‌های سنتی که به مهندسی دستی ویژگی‌ها متکی بودند، این طرح قادر است به طور خودکار ویژگی‌های پیچیده و ظریف تصاویر را استخراج و یاد بگیرد. این قابلیت باعث می‌شود تا طرح پیشنهادی نسبت به تغییرات در شرایط نورپردازی، بافت سطح و انواع مختلف عیوب، مقاوم‌تر باشد. علاوه بر این، طرح پیشنهادی قادر است انواع مختلف عیوب را با دقت بسیار بالایی تشخیص دهد، در حالی که روش‌های سنتی اغلب در تشخیص عیوب مشابه با مشکل مواجه بودند. همچنین، طرح پیشنهادی از قابلیت تعمیم‌پذیری بالایی برخوردار است و می‌تواند با داده‌های جدید به خوبی سازگار شود. این ویژگی باعث می‌شود تا طرح پیشنهادی برای استفاده در خطوط تولید با تنوع محصولات مختلف مناسب باشد. به طور خلاصه، طرح پیشنهادی نه تنها دقت تشخیص عیوب را به طور قابل توجهی بهبود بخشیده است، بلکه انعطاف‌پذیری و کارایی آن را نیز افزایش داده است.

۶- نتیجه‌گیری

در این پژوهش، یک روش نوین برای تشخیص خودکار عیوب سطحی در حلقهٔ سمبه با استفاده از یادگیری عمیق ارائه شده است. نتایج حاصل از ارزیابی طرح پیشنهادی نشان دهنده عملکرد قابل قبول آن در تشخیص انواع مختلف عیوب از

[1] Overfitting

جمله ترک‌ها، خراش‌ها و حفره‌ها است. به طور خاص، طرح به مقدار همپوشانی بر اتحاد برابر ۸۴٪ و مقدار خطا برابر ۰٫۱۵ دست یافت. این نتایج نشان دهنده دقت بالای طرح در تشخیص صحیح نواحی معیوب و تفکیک آنها از مناطق سالم است.

مقایسه طرح پیشنهادی با روش‌های سنتی تشخیص عیوب سطحی، برتری قابل توجه روش مبتنی بر یادگیری عمیق را در دقت و سرعت تشخیص نشان می‌دهد. در حالی که روش‌های سنتی به مهندسی دستی ویژگی‌ها متکی هستند و در نتیجه به تغییرات نورپردازی، بافت سطح و انواع مختلف عیوب حساس‌اند، طرح پیشنهادی قادر است به طور خودکار ویژگی‌های پیچیده و ظریف تصاویر را استخراج و یاد بگیرد و در نتیجه نسبت به این تغییرات مقاوم‌تر است. همچنین، طرح پیشنهادی از قابلیت تعمیم‌پذیری بالایی برخوردار است و می‌تواند با داده‌های جدید به خوبی سازگار شود که این امر آن را برای استفاده در خطوط تولید با تنوع محصولات مختلف مناسب می‌سازد.

با این حال، همچنان فرصت‌هایی برای بهبود عملکرد طرح و گسترش کاربردهای آن وجود دارد. توسعه بیشتر این طرح می‌تواند به بهبود فرآیند تولید و کاهش هزینه‌ها در صنایع مختلف کمک کند.

تشکر و قدردانی

نویسندگان مراتب تشکر و قدردانی خود را از شرکت حلقه خودرو پارس به خاطر ارائه نمونه‌های باکیفیت و مشارکت ارزشمند در فرآیند بررسی و همچنین از شرکت ایپکو به خاطر همکاری‌های سازنده و حمایت‌هایشان در این طرح اعلام می‌دارند.

فهرست علائم

تعداد پیکسل‌هایی که هم در پیش‌بینی و هم در برچسب واقعی به عنوان مثبت (عیوب) طبقه‌بندی شده‌اند.	TP
تعداد پیکسل‌هایی که در پیش‌بینی به عنوان مثبت طبقه‌بندی شده‌اند اما در واقع منفی هستند.	FP
تعداد پیکسل‌هایی که در پیش‌بینی به عنوان منفی طبقه‌بندی شده‌اند اما در واقع مثبت هستند.	FN

References

[1] Liang JC. An integrated product development process in the automotive industry. International Journal of Product Development. 2009 Jan 1;8(1):80-105. doi: 10.1504/IJPD.2009.02375

[2] Czerwińska K, Dwornicka R, Pacana A. Improvement of the surface of the combustion chamber of a piston using selected techniques of production organization. Materials Research Proceedings. 2020 Nov 15;17:270-5. doi: 10.21741/9781644901038-40

[3] Qu Z, Shen J, Li R, Liu J, Guan Q. Partsnet: A unified deep network for automotive engine precision parts defect detection. InProceedings of the 2018 2nd International Conference on Computer Science and Artificial Intelligence 2018 Dec 8 (pp. 594-599). doi: 10.48550/arXiv.1810.12061

[4] Islam MR, Zamil MZ, Rayed ME, Kabir MM, Mridha MF, Nishimura S, Shin J. Deep Learning and Computer Vision Techniques for Enhanced Quality Control in Manufacturing Processes. IEEE Access. 2024 Sep 2. doi: 10.1109/ACCESS.2024.3453664

[5] Abagiu MM, Cojocaru D, Manta F, Mariniuc A. Detecting machining defects inside engine piston chamber with computer vision and machine learning. Sensors. 2023 Jan 10;23(2):785. doi: 10.3390/s23020785

[6] Zheng B, Li Y, Zhang J, Wen C, Zhu S, Xu D. Detection of Piston Surface Defects Based on Machine Vision. In2022 IEEE 6th Information Technology and Mechatronics Engineering Conference (ITOEC) 2022 Mar 4 (Vol. 6, pp. 852-857). IEEE. doi: 10.1109/ITOEC53115.2022.9734579

[7] Lin J, Wang D, Tian H, Liu Z. Surface defect detection of machined parts based on machining texture direction. Measurement Science and Technology. 2020 Dec 2;32(2):025204. doi: 10.1088/1361-6501/abb485

[8] Saligheh, A., Hajialimohammadi, A., Abedini, V. Cutting Forces and Tool Wear Investigation for Face Milling of Bimetallic Composite Parts Made of Aluminum and Cast Iron Alloys. International Journal of Engineering, 2020; 33(6): 1142-1148. doi: 10.5829/ije.2020.33.06c.12
[9] Mercy KG, Rao SK. A framework for rail surface defect prediction using machine learning algorithms. In2018 International Conference on Inventive Research in Computing Applications (ICIRCA) 2018 Jul 11 (pp. 972-977). IEEE. doi: 10.1109/ICIRCA.2018.8597394
[10] Židek K, Hošovský A, Dubják J. Diagnostics of surface errors by embedded vision system and its classification by machine learning algorithms. Key Engineering Materials. 2016 Feb 8;669:459-66. doi: 10.4028/www.scientific.net/KEM.669.459
[11] Bhatt PM, Malhan RK, Rajendran P, Shah BC, Thakar S, Yoon YJ, Gupta SK. Image-based surface defect detection using deep learning: A review. Journal of Computing and Information Science in Engineering. 2021 Aug 1;21(4):040801. doi: 10.1115/1.4049535
[12] Hosseini AR, Moosavian A, Javan S, B Shokouhi S. Development of Machine Vision System to Track Movement of an Engine Timing Belt Tensioner Based on Deep Neural Network. The Journal of Engine Research. 2022 Jun 22;67(67):16-23. doi: 10.22034/er.2022.697916
[13] Taghandiki K, Dallakehnejad M, Rahimi Asiabaraki H. Reducing Air Pressure System Repair Costs in Scania Trucks through Deep Learning. Journal of Engineering and Applied Research. 2024 May 7;1(1):183-96. doi: 10.48301/jear.2024.447671.1022
[14] Rahmatinejad B, Rahimi Asiabaraki H, Azimpour Shishevan F. Diagnosing Dimensional Defects and Valve Cracks Using Machine Vision and Acoustic Emission. Karafan Journal. 2023 Nov 22;20(3):149-68. doi: 10.48301/kssa.2023.391572.2501
[15] Siddique N, Paheding S, Elkin CP, Devabhaktuni V. U-net and its variants for medical image segmentation: A review of theory and applications. IEEE access. 2021 Jun 3;9:82031-57. doi: 10.1109/ACCESS.2021.3086020
[16] Rezatofighi H, Tsoi N, Gwak J, Sadeghian A, Reid I, Savarese S. Generalized intersection over union: A metric and a loss for bounding box regression. InProceedings of the IEEE/CVF conference on computer vision and pattern recognition 2019 (pp. 658-666). doi: 10.1109/CVPR.2019.00075