



An intelligent machine vision system for automated wear detection in hydraulic lash adjusters

Zahra Norallahi^{1*}, Jafar Hashemi Daryan², Seyed Mohammadreza Sadat Akhavi², Tohid Mirzababayi Mostofi³

1- Mechanical Engineering Department, Malek Ashtar University of Technology, Tehran, Iran

2- Irankhodro Powertrain Company (IPCo), Tehran, Iran

3- Mechanical Engineering Department, Eyvanekey University, Tehran, Iran

ARTICLE INFO

Keywords:

Machine Vision

Classification

Image Segmentation

Internal Combustion Engine

Engine Parts Failure Detection

ABSTRACT

Timely failure detection in critical internal combustion engine (ICE) components is crucial for extending engine service life and minimizing maintenance costs. In this study, we design and implement an intelligent machine vision system for the automated detection of wear in Hydraulic Lash Adjusters (HLAs). The system aims to replace traditional, high-cost metrology methods such as Coordinate Measuring Machines (CMM) with a rapid, accurate, and cost-effective alternative. Utilizing a dataset of color images capturing both nominal and worn components, we apply image preprocessing, including resizing, normalization, and data augmentation. We then employ a ResNet-18 architecture for binary classification (nominal vs. damaged) and a U-Net architecture for defect segmentation. The system's performance is evaluated using accuracy, recall, precision, and overlap-based metrics. The experimental results demonstrate that the proposed model achieves a classification accuracy exceeding 97.6% and a segmentation Dice Score of 0.750, while reducing inspection time by over 70% compared to traditional methods. Furthermore, validation against expert human assessments confirms high consistency, demonstrating the reliability and practical viability of the proposed system for industrial quality control.



© 2026 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: Nouralahizahra82@gmail.com (Z. Nouralahi)

Received 27 February 2026; Accepted 7 July 2026

E-ISSN: 2345-4121/ISSN: 1735-5214

Cite this article: Norallahi Z, Hashemi Daryan J, Akhavi SMS, Mirzababayi Mostofi T. An intelligent machine vision system for automated wear detection in hydraulic lash adjusters. 2026 May 22;73(1):66-80. doi: [10.22034/ER.2026.2076349.1108](https://doi.org/10.22034/ER.2026.2076349.1108)

طراحی سامانه هوشمند مبتنی بر بینایی رایانه‌ای برای تشخیص سایش لقی گیر روغنی

زهره نورالهی^{۱*}، جعفر هاشمی داریان^۲، سید محمدرضا سادات اخوی^۳، توحید میرزابابایی مستوفی^۳

۱- گروه مهندسی مکانیک، دانشگاه صنعتی مالک اشتر، تهران، ایران

۲- شرکت تحقیق، طراحی و تولید موتور ایران خودرو (ایپکو)، تهران، ایران

۳- گروه مهندسی مکانیک، دانشگاه ایوان کی، تهران، ایران

اطلاعات مقاله	چکیده
کلیدواژه‌ها: بینایی رایانه‌ای طبقه‌بندی بخش‌بندی تصویر موتور درونسوز خرابی قطعات موتور	تشخیص به موقع خرابی قطعات حیاتی در موتورهای درونسوز یکی از عوامل کلیدی در افزایش عمر مفید موتور و کاهش هزینه‌های تعمیر و نگهداری است. در این پژوهش، یک سامانه هوشمند مبتنی بر بینایی رایانه‌ای برای تشخیص خرابی (سایش) لقی گیر روغنی طراحی و اجرا شده است. هدف از این سامانه، جایگزین کردن روش‌های سنتی و پرهزینه بازرسی، مانند دستگاه اندازه‌گیری مختصات (CMM) که برای اندازه‌گیری دقیق ابعادی قطعات به کار می‌رود، با روشی سریع‌تر، دقیق‌تر و کم‌هزینه‌تر است. داده‌های مورد استفاده شامل تصاویر رنگی قطعات سالم و معیوب است. پس از مرحله پیش‌پردازش شامل تغییر اندازه، هم‌مرتب‌سازی و افزایش داده، برای طبقه‌بندی سالم/معیوب از شبکه رزنت ۱۸ (ResNet18) و برای بخش‌بندی نواحی خرابی از یونت (U-Net) استفاده شد. سامانه پیشنهادی با استفاده از معیارهای دقت، بازخوانی، دقت مثبت و شاخص‌های هم‌پوشانی ارزیابی گردید. نتایج نشان داد که الگوی پیشنهادی در مقایسه با روش‌های سنتی، ضمن افزایش دقت (بیش از ۹۷.۶٪ در طبقه‌بندی و ضریب دایس ۰.۷۵۰ (در بخش‌بندی)، موجب کاهش زمان بازرسی تا بیش از ۷۰٪ شد. همچنین مقایسه خروجی سامانه با ارزیابی کارشناسان انسانی، همخوانی بالایی را نشان داد، که بیانگر قابلیت اعتماد و دقت عملی سامانه است.



© 2026 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: Nouralahizahra82@gmail.com (زهره نورالهی)

دریافت ۸ اسفند ۱۴۰۴؛ پذیرش ۱۶ تیر ۱۴۰۵

شاپای الکترونیکی: ۴۱۲۱-۳۳۴۵ / شاپای چاپی: ۵۲۱۴-۱۷۳۵

Cite this article: Norallahi Z, Hashemi Daryan J, Akhavi SMS, Mirzababai Mostofi T. An intelligent machine vision system for automated wear detection in hydraulic lash adjusters. 2026 May 22;73(1):66-80. doi: 10.22034/ER.2026.2076349.1108


۱- مقدمه

تشخیص به موقع خرابی قطعات امری حیاتی موتورهای درونسوز است. در میان این قطعات، لقی گیر روغنی^۱ به دلیل نقش مستقیم در تنظیم لقی دریچه‌ها از اهمیت ویژه‌ای برخوردار است؛ به گونه‌ای که خرابی آن می‌تواند منجر به کاهش بازده حجمی موتور، افزایش مصرف سوخت، افزایش صدای موتور و حتی آسیب جدی به مجموعه سازوکار دریچه‌ها گردد. از این رو پایش وضعیت این قطعه به صورت دقیق و سریع، ضرورتی انکارناپذیر در فرآیندهای تعمیرات و نگهداری محسوب می‌شود.

روش‌های سنتی تشخیص خرابی نظیر ماشین اندازه‌گیری مختصات^۲ و بازرسی انسانی تاکنون به طور گسترده در صنعت از جمله در شرکت اپکو استفاده شده‌اند [۱-۳]. با این حال، این روش‌ها با چالش‌های متعددی روبه‌رو هستند:

- هزینه گران شامل قیمت خرید، تعمیرات و نگهداری
 - نیاز به کاربرهای متخصص و مشکلات تنظیم دستگاه
 - سرعت کند بازرسی بویژه در خطوط تولید انبوه
 - و در مورد بازرسی انسانی، وابستگی به تجربه فردی و کاهش دقت^۳ در شرایط کاری طولانی مدت
- در سال‌های اخیر، سامانه‌های هوشمند مبتنی بر بینایی رایانه‌ای توانسته‌اند با جایگزینی بازرسی انسانی، دقت و سرعت بیشتری ارائه دهند [۴].

شکل ۱ نمونه‌ای از دستگاه اندازه‌گیری مختصات و شکل سطح لقی گیر روغنی پس از آزمون ضربه حرارتی را نشان می‌دهد و ناحیه فرورفتگی خرابی قطعه در آن قابل مشاهده است.



شکل ۱ نمونه خروجی دستگاه اندازه‌گیری مختصات و شکل سطح لقی گیر روغنی

این محدودیت‌ها موجب شده است که صنعت به دنبال راهکارهای سریع‌تر، کم‌هزینه‌تر و هوشمندتر باشد. در سال‌های اخیر، بینایی رایانه‌ای^۴ و شبکه‌های عصبی عمیق در حوزه تشخیص خرابی قطعات صنعتی به طور گسترده مورد توجه قرار گرفته‌اند. برای نمونه، پژوهش‌هایی در زمینه تشخیص خرابی دریچه‌ها و سمبه‌ها، یا شناسایی عیوب میل‌لنگ و قطعات

¹ HLA (Hydraulic Lash Adjuster)

² Coordinate Measuring Machine (CMM)

³ Accuracy

⁴ Computer Vision

بدنه خودرو با استفاده از معماری‌های شبکه‌های عصبی پیچشی^۱ و معماری یولو^۲، نشان داده‌اند که این روش‌ها می‌توانند دقت بالاتر و سرعت بسیار بیشتری نسبت به روش‌های سنتی فراهم کنند [۵-۷]. در این زمینه، مرور مطالعات نشان می‌دهد که شبکه‌های یادگیری عمیق بویژه در تشخیص عیوب سطحی قطعات صنعتی عملکرد چشمگیری داشته‌اند. به عنوان مثال، یزدانی‌جو و موسویان [۸] با استفاده از شبکه‌های موبایل‌نت و VGG19، توانستند دقت (با استفاده از شاخص‌های هم‌پوشانی IoU) حدود ۸۵٪ را در تشخیص درجه خرابی میل‌لنگ به دست آورند؛ مشابهاً، مطالعه دیگری بر روی حلقه سببه نشان داد که شبکه‌های بینایی رایانه‌ای می‌توانند دقت بالای ۸۶٪ در شناسایی عیوب سطحی قطعات صنعتی ارائه دهند [۹]. اگرچه تمرکز آن‌ها بر روی مشخصات حک‌شده بود. همچنین، کاپال و همکاران [۱۰] الگویی مبتنی بر R-CNN Faster و YOLOv3 برای بازرسی برچسب‌های موتور پیشنهاد کردند که دقت طبقه‌بندی بزرگتر از ۹۰٪ را ارائه داد. از منظر بخش‌بندی^۳، روچاسن و کیرچن [۱۱] با ارائه یک روش ویژه برای استوانه موتور، اثبات کردند که دستیابی به دقت خانه بیش از ۹۰٪ در شرایط نوری متغیر امکان‌پذیر است. علاوه بر این، پژوهش‌هایی مانند کار کیم و همکاران [۱۲] با استفاده از سازوکار توجه^۴ (قابلیت تمرکز بر مهم‌ترین ویژگی‌های تصویر) به دقت ۹۴.۵٪ و امتیاز F1 معادل ۰.۹۱ در تشخیص عیوب موضعی سطحی دست یافتند. همچنین، در بخش سرعت بازرسی، حسینی و همکاران [۱۳] در ردیابی تسمه سفت‌کن به دقت ۹۸٪ رسیدند. لین و همکاران [۱۴] با YOLOv4 به سرعت ۵۰ تصویر در ثانیه و میانگین دقت تشخیص ۸۸٪ در بازرسی یاتاقان‌های غلتشی دست یافتند. با وجود این پیشرفت‌های گسترده، تاکنون مطالعه مستقیمی بر روی تشخیص خرابی لقی گیر روغنی انجام نشده است؛ لذا، این پژوهش به عنوان یک نوآوری کلیدی، به طراحی سامانه‌ای دقیق برای طبقه‌بندی و بخش‌بندی نواحی خرابی این قطعه می‌پردازد.

هدف اصلی این پژوهش طراحی و پیاده‌سازی یک سامانه هوشمند مبتنی بر بینایی رایانه‌ای برای تشخیص خرابی لقی گیر روغنی است. این سامانه ضمن طبقه‌بندی^۵ قطعات به دو گروه سالم و معیوب، قادر است نواحی خرابی را نیز بخش‌بندی کند و در مقایسه با روش‌های سنتی، دقت بالاتر و زمان بازرسی بسیار کمتری ارائه دهد. از سوی دیگر، چشم‌انداز بلندمدت پژوهش گسترش این سامانه به عنوان یک چارچوب پایه برای تشخیص خرابی سایر قطعات موتور است؛ به گونه‌ای که در آینده قابلیت توسعه به شکل یک نرم‌افزار کاربردی عملیاتی در خطوط تولید صنعتی را دارد.

۲- مواد و روش‌ها

۲-۱- داده‌ها و شرایط آزمایشگاه

در این پژوهش، مجموعه داده شامل تعدادی تصاویر قطعات لقی گیر روغنی بود که پس از اعمال روش‌های داده‌افزایی^۶ (مانند تغییر روشنایی، وضوح و چرخش)، به تعداد نهایی ۱۶۹ تصویر رسید. تصاویر اولیه شامل نمونه‌های سالم و معیوب بودند، و داده‌افزایی با هدف افزایش تنوع و بهبود آموزش الگو انجام شد. محدودیت‌های آزمایشگاهی و تغییرات نوری مانع از گردآوری داده‌های بیشتر شد، اما تنوع نسبی حاصل از داده‌افزایی به الگو کمک کرد تا عملکرد قابل قبولی در شرایط مختلف داشته باشد. این تصاویر حاصل هزاران ساعت آزمون دوام بوده و به دلیل سختی و هزینه بسیار گران، امکان تکرارپذیری آن‌ها وجود نداشت. به منظور نمایش محل قرارگیری لقی گیر روغنی در موتور، از یک طرح استفاده شده است (شکل ۲). این تصویر، موقعیت تقریبی قطعه و ارتباط آن با اجزای اطراف نظیر بادامک را نشان می‌دهد. لقی گیر روغنی

¹ Convolutional Neural Network (CNN)

² You Only Look Once (YOLO)


³ Segmentation

⁴ Attention Mechanism

⁵ Classification

⁶ Data Augmentation


بین بادامک و دریچه قرار گرفته و همواره لقی بین این دو قطعه را صفر می‌کند. این امر باعث کاهش صدای این ناحیه و افزایش عمر دریچه و نشیمنگاه آن بر روی بستار^۱ می‌شود.



شکل ۲ طرح محل قرارگیری لقی گیر روغنی در موتور

قطعات معیوب به سه نوع خرابی دسته‌بندی شدند (شکل ۳):

- نوع اول: قطعه چرخش مناسبی دارد اما سایش روی سطح لقی گیر مشاهده می‌شود. دلایل احتمالی شامل کمبود روغن، تنش زیاد بین لقی گیر و بادامک و سختی سطح پایین لقی گیر است.
- نوع دوم: قطعه چرخش مناسبی ندارد و سایش روی سطح به صورت غیر دایروی دیده می‌شود که عمدتاً ناشی از مشکلات هندسی است.
- نوع سوم: از بین رفتن پوشش‌های کربن شبه‌الماسی^۲ روی سطح لقی گیر که بیشتر به دلیل مشکلات کیفی پوشش رخ داده است.



شکل ۳ به ترتیب از سمت راست خرابی نوع اول، خرابی نوع دوم و خرابی نوع سوم

¹ Cylinder Head

² Diamond-Like Carbon Coatings (DLC)

لازم به ذکر است که الگوی طبقه‌بندی طراحی شده در این پژوهش برای تشخیص دو رده (سالم/معیوب) بهینه شده است و تفکیک سه نوع خرابی به صورت جداگانه در محدوده این پژوهش قرار نمی‌گیرد. توسعه الگوی چندتایی برای جداسازی انواع خرابی به عنوان چشم‌انداز آتی پژوهش مطرح می‌گردد.

۲-۲- مشخصات تجهیزات و شرایط تصویربرداری

- دوربین: Canon G12
- زاویه دوربین با افق: ۲۰-۳۰ درجه
- دمای محیط: ۲۰-۳۰ درجه سانتی‌گراد
- نور محیط: تصاویر هم در حالت بدون فلش (با نور محیطی حدود ۱۴۰۰ لوکس) و هم در حالت با پخش نور ثبت شدند. در حالت پخش نور، نور محیطی تا حد زیادی حذف و تنها نور لحظه‌ای دوربین (معادل حدود ۱۰ شمع) روی سطح قطعه اعمال گردید. این تنوع شرایط نوری به بررسی عملکرد الگو در طرح‌های متفاوت کمک نمود.

۲-۳- پیش‌پردازش داده‌ها

در این پژوهش، ۱۶۹ تصویر از قطعات لقی گیر روغنی گردآوری و بررسی شد، که از این میان ۸۴ تصویر مربوط به قطعات سالم و ۸۵ تصویر مربوط به قطعات معیوب بود. فرآیند برچسب‌گذاری^۱ تصاویر با دقت بالا توسط کارشناسان فنی انجام شد. برای قطعات معیوب، نواحی آسیب‌دیده با استفاده از ابزار برچسب‌استدیو^۲ به صورت پیش‌طرح‌های دودویی مشخص گردید^۳. در این پیش‌طرح‌ها، نواحی آسیب‌دیده با رنگ سفید و نواحی سالم با رنگ سیاه نمایش داده شدند.

با توجه به اهمیت حیاتی صحت داده‌های آموزشی، فرآیند برچسب‌گذاری و تأیید نهایی پیش‌طرح‌های دودویی به صورت مشترک توسط دو نفر انجام پذیرفت: محقق اصلی پژوهش (به عنوان متخصص پردازش تصویر) و مسئول اداره توسعه صحنه‌گذاری شرکت ایپکو به عنوان خبره فنی و تأییدکننده نهایی صحت ارزیابی. این فرآیند دو مرحله‌ای، شامل برچسب‌گذاری اولیه و سپس بررسی و اجماع نهایی توسط هر دو متخصص، تضمین می‌کند که داده‌های آموزشی از بالاترین سطح اعتبار فنی برخوردار بوده و هرگونه ابهام یا خطای فردی در تشخیص اولیه برطرف شده است.

به منظور افزایش تنوع داده‌ها و بهبود عملکرد الگو، از روش‌های داده‌افزایی^۴ استفاده شد. این فرآیند با بهره‌گیری از پلتفرم روبوفلو^۵ انجام پذیرفت و شامل تغییراتی نظیر چرخش، تغییر مقیاس، برش تصادفی، تغییر روشنایی و کنتراست بود. این روش‌های داده‌افزایی موجب شدند الگو توانایی شناسایی و تعمیم ویژگی‌های تصویری مختلف را در شرایط متنوع محیطی و نوری بهبود بخشد.

تصاویر به اندازه ۲۲۴×۲۲۴ پیکسل تغییر اندازه داده شدند تا با ورودی‌های الگوهای پیش‌آموزش‌دیده تطابق داشته باشند. لازم به ذکر است که فرآیند داده‌افزایی پس از تقسیم‌بندی مجموعه داده انجام شد تا از هرگونه نشت داده بین مجموعه‌های آموزش و آزمون جلوگیری گردد. همچنین، ارزیابی نهایی سامانه روی ۱۳ تصویر کاملاً جدید که در هیچ مرحله‌ای از آموزش مورد استفاده قرار نگرفته بودند انجام پذیرفت و دقت ۱۰۰٪ حاصل شد. همچنین، برای هم‌مرتبه‌سازی، مقادیر خانه‌ها به دامنه [۰ و ۱] مقیاس‌بندی شدند و میانگین و انحراف معیار داده‌ها تنظیم گردید تا فرآیند آموزش بهینه‌تری حاصل شود.

¹ Labeling

² Label Studio

³ Annotation

⁴ Data Augmentation

⁵ Roboflow

۲-۴- الگو و معماری

این پژوهش به‌طور همزمان وظایف طبقه‌بندی و بخش‌بندی را دنبال می‌کند؛ لذا دو معماری مجزا به کار گرفته شد. شبکه رزنت ۱۸^۱ به دلیل ساختار عمقی و توانایی در استخراج ویژگی‌های سلسله مراتبی با سرعت مناسب، به‌عنوان الگوی طبقه‌بندی انتخاب شد. از سوی دیگر، برای انجام وظیفه بخش‌بندی نواحی خرابی، از معماری U-Net (شامل یک مسیر فشرده‌سازی و یک مسیر گسترش با اتصالات پرشی) استفاده شده است. این انتخاب به دلیل توانایی U-Net در حفظ اطلاعات مکانی^۲ و بازبازی جزئیات دقیق مرزهای خرابی است که برای تشخیص عیوب موضعی و تعیین موقعیت سایش ضروری است.

۲-۴-۱- الگوی طبقه‌بندی

برای تشخیص قطعات سالم و معیوب از شبکه رزنت از پیش‌آموزش دیده استفاده شد. شبکه ResNet18 با وزن‌های از پیش‌آموزش دیده روی پایگاه داده ImageNet مقداردهی اولیه شد (انتقال یادگیری) که در مجموعه داده‌های محدود نقش کلیدی در جلوگیری از بیش‌برازش دارد. انتخاب ResNet18 به دلیل توانایی آن در جلوگیری از مشکل گرادیان محوشونده از طریق اتصالات پسماند، سرعت آموزش مناسب برای مجموعه داده‌های محدود، و توازن بهینه بین دقت و زمان استنتاج بود. در مقایسه با معماری‌های سبک‌تر مانند MobileNetV3 (با حدود ۲.۵ میلیون متغیر و دقت تخمینی حدود ۹۴٪) و EfficientNet-B0 (با حدود ۵.۳ میلیون متغیر و دقت تخمینی حدود ۹۶.۸٪)، ResNet18 با ۱۱.۷ میلیون متغیر و دقت بالاتری ارائه داد که برای کاربرد تنظیم کیفیت صنعتی مناسب‌تر است. ورودی الگوی تصاویر رنگی با ابعاد ۲۲۴×۲۲۴ خانه بودند. لایه نهایی متناسب با مسئله بازطراحی شد و شامل:

- یک لایه حذف تصادفی^۳ با احتمال ۰.۶

- یک لایه تمام‌متصل^۴ با دو عصب خروجی (سالم/معیوب)^۵

برای آموزش، داده‌ها ابتدا از فایل‌های فشرده^۶ استخراج و سپس در قالب یک چارچوب داده^۷ سازمان‌دهی شدند. برچسب‌گذاری به صورت (۱ = سالم، ۰ = معیوب) انجام شد. مجموعه داده با روش تقسیم لایه‌ای^۸ به سه بخش (آموزش ۷۰٪، اعتبارسنجی ۱۵٪ و آزمون ۱۵٪) تقسیم گردید تا نسبت دسته‌ها حفظ شود. پیاده‌سازی تمامی الگوها و مراحل آموزش با استفاده از زبان برنامه‌نویسی پایتون و کتابخانه‌های یادگیری عمیق و در محیط گوگل کولب^۹ انجام گرفت. الگو با بهینه‌ساز آدام^{۱۰} (نرخ یادگیری ۰.۰۰۱، منظم‌سازی L2 با ضریب 0.0001) λ و با توقف زود هنگام با شکست‌یابی = ۵ و تابع هزینه بی‌نظمی متقاطع^{۱۱} آموزش داده شد. فرآیند آموزش با (اندازه دسته = ۱۶) اجرا گردید. علاوه بر دقت و خطا، الگو با معیارهای منحنی ارزیابی تفکیک‌پذیری الگو، منحنی دقت-بازخوانی، آرایه اغتشاش و گزارش طبقه‌بندی ارزیابی شد.

در نمودار تغییرات خطا و دقت (شکل ۴)، خطای آموزش از حدود ۱.۱ در دوره اول به حدود ۰.۲۵ در دوره‌های پایانی کاهش یافته است. خطای اعتبارسنجی نوسان داشته که به دلیل محدودیت حجم داده طبیعی است. همچنین دقت اعتبارسنجی در برخی دوره‌ها بالاتر از دقت آموزش مشاهده می‌شود که نشان‌دهنده اثربخشی روش‌های منظم‌سازی مانند

¹ ResNet18

² Spatial Information

³ Dropout

⁴ Fully Connected

⁵ Normal/Damaged

⁶ ZIP, RAR

⁷ DataFrame


⁸ Stratified Split

⁹ Google Colab

¹⁰ ADAM

¹¹ Cross-Entropy Loss

لایه حذف تصادفی است که تنها در مرحله آموزش، فعال بوده و از بیش‌برازش جلوگیری می‌کند. دقت اعتبارسنجی در بهترین دوره به ۹۲٪ رسید و توقف زود هنگام با شکیبایی = ۵ از ادامه آموزش غیرضروری جلوگیری کرد. در ادامه این بخش، برای تکمیل فرآیند ارزیابی، نتایج کمی حاصل از معیارهای ذکر شده (شامل ماتریس اغتشاش و گزارش طبقه‌بندی) در قالب جدول ۱ ارائه شده است.



شکل ۴ نمودار تغییرات خطا و دقت الگوی طبقه‌بندی رزنت ۱۸ در طول دوره‌های آموزش و اعتبارسنجی

جدول ۱ خلاصه نتایج ارزیابی الگوی طبقه‌بندی ResNet18 بر روی مجموعه آزمون

معیار	درصد دسته سالم (۱)	درصد دسته معیوب (۰)	درصد میانگین وزنی
صحت	۱۰۰	۹۵.۱	۹۸.۸
بازخوانی	۹۸.۱	۹۵.۷	۹۷.۳
امتیاز	۹۹.۰	۹۵.۴	۹۷.۹
دقت کلی			۹۷.۶

شایان ذکر است که بازخوانی ۹۸.۱٪ برای دسته سالم به معنای آن است که ۱.۹٪ از قطعات سالم به اشتباه معیوب تشخیص داده شده‌اند. این خطا عمدتاً ناشی از حساسیت شدید الگو نسبت به خراش‌های سطحی جزئی است که در جدول ۶ نمونه آن نشان داده شده است. از منظر تنظیم کیفیت صنعتی، این رفتار مزیت محسوب می‌شود؛ زیرا هزینه ارجاع یک قطعه سالم برای بازبینی مجدد بسیار کمتر از هزینه خروج یک قطعه معیوب از خط تولید است. در مرحله پیش‌بینی، الگوی تصویر ورودی را تحلیل کرده و علاوه بر تعیین برچسب نهایی (سالم یا معیوب)، احتمال تعلق تصویر به هر دسته را نیز ارائه می‌دهد. به عنوان مثال، در شکل ۵، الگو با اطمینان ۹۹.۵٪ قطعه را معیوب تشخیص داده است. این خروجی ترکیبی از تصویر و پیش‌بینی عددی، امکان بررسی دقیق‌تر و تصمیم‌گیری آگاهانه‌تر را فراهم می‌سازد (شکل ۵).




شکل ۵ نمونه خروجی الگوی طبقه‌بندی (قطعه با احتمال ۹۹.۵ درصد معیوب است)

۲-۴-۲- الگوی بخش بندی

برای شناسایی دقیق نواحی آسیب‌دیده، از معماری یونت (U-Net) استفاده شد که جزئیات کامل آن در (جدول ۲) ارائه شده است. برای این منظور، تصاویر قطعات معیوب همراه با پیش‌طرح‌های متناظر آن‌ها استخراج و سازمان‌دهی شدند تا انطباق کامل میان داده‌ها و برچسب‌ها برقرار باشد. خروجی الگو یک نقشه دودویی^۱ با ابعاد برابر با تصویر ورودی (۲۲۴×۲۲۴) بود که نواحی معیوب را با رنگ سفید و بخش‌های سالم را با رنگ مشکی مشخص می‌کرد. (شکل ۶). به منظور کاهش پدیده بیش‌برازش، از لایه‌های حذف تصادفی و منظم‌سازی L2 استفاده شد (شکل ۷). فرآیند آموزش الگو با بهینه‌ساز آدام (با نرخ یادگیری ۰.۰۰۰۱، منظم‌سازی L2 با ضریب $\lambda = 0.0001$) و اندازه دسته = ۱۶ و تابع هزینه دایس^۲ در طی ۱۵ دوره اجرا گردید.

جدول ۲ معماری یونت مورد استفاده


شرح	نوع لایه	مرحله
داده ورودی	تصویر ۲۲۴×۲۲۴	ورودی
استخراج ویژگی اولیه	Conv2D + ReLU → Conv2D + ReLU	Down1
کاهش ابعاد	MaxPooling2D	Pool1
ویژگی‌های عمیق‌تر	Conv2D + ReLU → Conv2D + ReLU	Down2
کاهش ابعاد	MaxPooling2D	Pool2
نمایش فشرده ویژگی‌ها	Conv2D + ReLU → Conv2D + ReLU	Bottleneck
ادغام با Down2	UpSampling + Concatenate	Up1
بازسازی ویژگی‌ها	Conv2D + ReLU → Conv2D + ReLU	Conv Up1
ادغام با Down1	UpSampling + Concatenate	Up2
بازسازی جزئیات	Conv2D + ReLU → Conv2D + ReLU	Conv Up2
پیش‌طرح دودویی نهایی	(Conv2D (sigmoid	خروجی



شکل ۶ نمونه خروجی الگوی بخش‌بندی از چپ به راست: تصویر اصلی، پیش‌طرح پیش‌بینی‌شده و تصویر Overlay ناحیه قرمز نشان‌دهنده ۶.۵٪ از سطح قطعه به‌عنوان ناحیه معیوب است


¹ Binary mask

² Dice Loss



شکل ۷ تأثیر لایه‌های حذف تصادفی در کاهش بیش برآزش

در نمودار تغییرات خطا و ضریب دایس (شکل ۸)، خطای آموزش از حدود ۰.۸۲ در دوره اول به حدود ۰.۴۵ در دوره پانزدهم کاهش یافته است. خطای اعتبارسنجی از حدود ۰.۷۶ به حدود ۰.۳۷ کاهش یافته و روند نزولی پایداری داشته است. ضریب دایس اعتبارسنجی از ۰.۳۴ در دوره اول به حدود ۰.۷۰ در دوره‌های پایانی رسیده که نشان‌دهنده همگرایی مناسب و عدم بیش‌برآزش الگو است.



شکل ۸ نمودار تغییرات خطا (Dice Loss) و ضریب دایس الگوی بخش‌بندی یونت در طول دوره‌های آموزش و اعتبارسنجی

۳- نتایج و بحث

برای ارزیابی عملکرد الگوهای توسعه‌داده‌شده، دو رویکرد اصلی مورد استفاده قرار گرفت:

- استفاده از مجموعه داده آزمون مستقل شامل تصاویر جدید که در فرآیند آموزش به کار نرفته بودند.
- مقایسه نتایج الگوها با پیش‌بینی کارشناسان خبره (۶ نفر از متخصصان حوزه تولید و تنظیم کیفیت)

الگوی طبقه‌بندی ResNet18 توانست به دقت کلی ۹۷.۶٪ دست یابد. نکته حائز اهمیت، کسب دقت ۱۰۰٪ در تشخیص دسته معیوب بود. این نتیجه به معنای عدم وجود خطای مثبت کاذب است؛ یعنی الگو هرگز قطعه سالمی را به اشتباه معیوب تشخیص نداده است. این ویژگی، همراه با بازخوانی ۹۸.۱٪، تضمین می‌کند که سامانه پیشنهادی بالاترین سطح تنظیم کیفیت را فراهم کرده و برای محیط‌های صنعتی که جلوگیری از خروج قطعات معیوب از خط تولید اهمیت حیاتی دارد، بهینه‌سازی شده است (نتایج کامل در جدول ۱). این خطا عمدتاً ناشی از حساسیت بالای الگو نسبت به خراش‌های سطحی جزئی است. از منظر تنظیم کیفیت صنعتی، این رفتار مزیت محسوب می‌شود؛ زیرا هزینه ارجاع یک

قطعه سالم برای بازبینی مجدد بسیار کمتر از هزینه خروج یک قطعه معیوب از خط تولید است. نکته قابل توجه در عملکرد الگو، حساسیت بالای آن نسبت به جزئیات ظاهری قطعات است؛ به طوری که حتی تغییرات سطحی مانند یک خراش کوچک یا نویز جزئی در داده‌ها می‌تواند در خروجی الگو تأثیرگذار باشد. این ویژگی، اگرچه نیازمند دقت بیشتر در جمع‌آوری داده‌هاست، اما در محیط‌های صنعتی که کیفیت و سلامت قطعه اهمیت حیاتی دارد، می‌تواند به عنوان یک مزیت در تشخیص دقیق‌تر تلقی شود.

به منظور مستندسازی کمی کاهش زمان بازرسی، مقایسه‌ای بین روش سنتی و سامانه پیشنهادی انجام شد. زمان‌های اندازه‌گیری شده در شرکت ایپکو در جدول ۳ ارائه شده است. همان‌طور که مشاهده می‌شود، سامانه پیشنهادی زمان بازرسی را از ۶-۱۰ دقیقه به حدود ۱۱-۲۰ ثانیه کاهش داده که معادل کاهش حداقل ۷۰٪ و در شرایط بهینه تا ۹۵٪ است.

جدول ۳ مقایسه زمان بازرسی روش سنتی (CMM) و سامانه پیشنهادی


مرحله	سامانه پیشنهادی (ثانیه/قطعه)	روش سنتی (ثانیه/قطعه)
تنظیم و آماده‌سازی	۵-۱۰	۱۲۰-۱۸۰
اسکن / تصویربرداری	۳-۵	۱۸۰-۳۰۰
پردازش و استنتاج	۲-۳	داخل تصویربرداری
نمایش نتیجه	۱-۲	۶۰-۱۲۰
جمع کل	~۲۰-۱۱ ثانیه	۶۰۰-۳۶۰ ثانیه
نسبت کاهش	حداقل ۷۰٪ (۹۵٪)	—

عملکرد الگوی بخش‌بندی یونت پس از ۱۵ دوره آموزش در داده‌های اعتبارسنجی به دقت خانه ۸۹.۹٪ و ضریب دایس معادل ۰.۷۵۰ و شاخص IoU معادل ۰.۶۳۶ رسید. اگرچه دقت خانه بالاست، اما ضریب دایس معیار دقیق‌تر و مناسب‌تری برای سنجش عملکرد الگو در شناسایی خرابی‌های موضعی (به دلیل عدم توازن رده‌ها) محسوب می‌شود [۱۵-۱۶]. ثبات این شاخص‌ها در طول آموزش و نزدیکی نتایج به داده‌های آموزشی (نمودار شکل ۶) نشان می‌دهد که الگو دچار بیش‌برازش نشده و قابلیت تعمیم‌پذیری خوبی دارد.

علاوه بر این، فاصله هاسدورف در صدک ۹۵ معادل ۳۴.۱ خانه نیز محاسبه گردید. بررسی سه نمونه با بدترین عملکرد (شکل ۹) نشان داد که خطاها عمدتاً در سه دسته قرار می‌گیرند: عدم تشخیص صحیح شکل نامنظم ناحیه خرابی، کم‌برآورد ناحیه در خرابی‌های حلقه‌ای گسترده، و بیش‌برآورد ناحیه در خرابی‌های با مرز مبهم. این سه نوع خطا همگی مربوط به مرزهای ناحیه هستند نه تشخیص کل ناحیه که نشان می‌دهد الگوی محل کلی خرابی را شناسایی می‌کند ولی مرزهای دقیق را به طور کامل بازتولید نمی‌کند. این محدودیت به ماهیت گرادیانی مرزهای سایش در لقی گیر روغنی و حجم محدود داده‌های برچسب‌دار نسبت داده می‌شود.

جدول ۴ معیارهای ارزیابی الگوی بخش‌بندی یونت روی مجموعه آزمون

معیار	مقدار
ضریب دایس	۰.۷۵۰
شاخص IoU	۰.۶۳۶
دقت خانه	۸۹.۹٪
فاصله هاسدورف (صدک ۹۵)	۳۴.۱ خانه



شکل ۹ سه نمونه از بدترین نتایج بخش‌بندی از چپ به راست: تصویر اصلی، پیش‌طرح واقعی و پیش‌طرح پیش‌بینی شده

۳-۱- مقایسه با کارشناسان خبره

- در بخش طبقه‌بندی، کارشناسان هر تصویر را به صورت ۱ = سالم یا ۰ = معیوب برچسب‌گذاری کردند.
 - در بخش بخش‌بندی، کارشناسان نقشه خرابی را مشخص کرده و با پیش‌طرح خروجی الگو مقایسه شد.
- نتایج نشان داد که در بخش طبقه‌بندی، الگو در شناسایی قطعات معیوب عملکردی مشابه یا حتی دقیق‌تر از کارشناسان داشت، در حالی که در تشخیص قطعات سالم تمایل به سخت‌گیری بیشتری نشان داد. این موضوع اگرچه موجب کاهش دقت در رده سالم شد، اما از دیدگاه صنعتی مزیت محسوب می‌شود زیرا هیچ قطعه معیوبی از چرخه تنظیم کیفیت عبور نمی‌کند. در بخش بخش‌بندی نیز، نقشه‌های خرابی تولیدشده توسط الگو با پیش‌طرح‌های کارشناسان همپوشانی قابل قبولی داشت و عمده اختلاف‌ها مربوط به مرزهای نواحی آسیب‌دیده بود. این نتایج بیانگر آن است که الگو می‌تواند در کنار نیروی انسانی به عنوان یک ابزار کمکی عمل کند و حتی در برخی وظایف جایگزین مناسبی برای بازرسی دستی باشد.

در ادامه، سه نمونه از تصاویر قطعات نمایش داده شده‌اند که در آن‌ها برچسب‌گذاری الگو و کارشناسان خبره به صورت عددی (۰ یا ۱) مقایسه شده است. این تصاویر صرفاً مربوط به بخش طبقه‌بندی هستند و نقشه‌های خرابی در آن‌ها لحاظ نشده‌اند. مقایسه عددی نشان می‌دهد که الگو در تشخیص قطعات معیوب دقت بالایی داشته و در مواردی با سخت‌گیری بیشتر نسبت به کارشناسان عمل کرده است، که از منظر تنظیم کیفیت صنعتی یک مزیت محسوب می‌شود، زیرا هزینه ارجاع یک قطعه سالم برای بازیابی مجدد بسیار کمتر از هزینه خروج یک قطعه معیوب از خط تولید است. رویکرد پیشنهادی، استفاده ترکیبی از سامانه در مرحله غربالگری سریع و ارجاع موارد مرزی (اطمینان ۵۰-۶۵٪) به بازیابی انسانی است. (جداول ۵ تا ۷).

به منظور ارزیابی آماری میزان توافق الگو با کارشناسان خبره، ضریب کاپا و درصد توافق کلی برای هر سه جدول محاسبه گردید. در جدول ۵ که اتفاق نظر کامل کارشناسان وجود داشت، الگو با اطمینان ۱۰۰٪ همان تشخیص را ارائه داد ($\kappa = 1.00$). در جدول ۶ که کارشناسان اختلاف نظر داشتند، الگو با اکثریت موافق بود ($\kappa = 0.33$) و اختلاف بین کارشناسان از نظر آماری معنادار نیست. در جدول ۷، الگو به دلیل حساسیت بالا قطعه سالم را معیوب تشخیص داده که رفتار قابل پذیرش در تنظیم کیفیت صنعتی است.

جدول ۵ نمونه مقایسه پیش بینی الگو با کارشناسان

تشخیص الگو	تشخیص	کارشناس
	0	A
	0	B
	0	C
	0	D
	0	E
	0	F

جدول ۶ نمونه مقایسه پیش بینی الگو با کارشناسان

تشخیص الگو	تشخیص	کارشناس
	1	A
	0	B
	1	C
	0	D
	0	E
	0	F

جدول ۷ نمونه مقایسه پیش بینی الگو با کارشناسان

تشخیص الگو	تشخیص	کارشناس
	1	A
	1	B
	1	C
	1	D
	1	E
	1	F

۴- نتیجه گیری

در این پژوهش، یک سامانه هوشمند مبتنی بر بینایی رایانه‌ای برای شناسایی و بخش بندی خرابی در لقی گیر روغنی موتور طراحی و پیاده سازی شد. نتایج نشان داد که الگوی طبقه بندی توانست به دقت کلی ۹۷.۶٪ دست یابد و با کسب دقت ۱۰۰٪ در تشخیص قطعات معیوب، هدف اصلی تنظیم کیفیت صنعتی را محقق سازد. هرچند در تفکیک قطعات سالم محدودیت داشت. در الگوی بخش بندی یونت، دقت خانه ۸۹.۹٪ و ضریب دایس ۰.۷۵۰ و شاخص IoU معادل ۰.۶۳۶ به دست آمد که بیانگر تعمیم پذیری مناسب الگو در شناسایی دقیق نواحی خرابی است. به طور کلی، سامانه پیشنهادی بالاترین سطح اطمینان را برای بازرسی قطعات موتور فراهم کرده و می تواند به عنوان ابزار کمکی مؤثر در فرآیند بازرسی به کار گرفته شود. توسعه مجموعه داده های گسترده تر، تنوع شرایط نوری و استفاده از الگوهای پیشرفته تر می تواند زمینه ارتقای عملکرد و کاربرد پذیری صنعتی این سامانه را فراهم سازد. در گام بعدی، قابلیت توسعه یک نرم افزار کاربردی برای تلفن های همراه وجود دارد؛ نرم افزاری که بتواند با دریافت تصویر قطعه از طریق دوربین گوشی، وضعیت سلامت آن را تشخیص داده و در صورت وجود خرابی، نوع آسیب یا ناحیه معیوب را مشخص کند. این سامانه می تواند برای طیف وسیعی از قطعات موتور تعمیم یابد و با فراهم سازی امکان بازرسی سریع و قابل حمل، نقش مؤثری در افزایش بهره وری خطوط تولید و کاهش خطای انسانی ایفا کند. چنین ابزاری، گامی مهم در جهت صنعتی سازی و تجاری سازی این فناوری خواهد بود. شایان ذکر است که سامانه پیشنهادی در شرایط آزمایشگاهی تنظیم شده ارزیابی شده است. برای عملیاتی سازی در خط تولید واقعی، سه چالش اصلی شامل نویز نوری و ارتعاش، تغییر زاویه قطعه و سرعت بالای خط تولید باید مرتفع گردد که به عنوان چشم انداز آتی پژوهش مطرح می شود.

تشکر و قدردانی

تصاویر مربوط به قطعات از بایگانی آزمایشگاه موتور شرکت تحقیق، طراحی و تولید موتور ایرانخودرو (ایپکو) انتخاب شده است. لازم است از مدیریت و کارشناسان آزمایشگاه موتور ایپکو به جهت همکاری تشکر نمایم.

References

- [1] Keyence Corporation. CMM for the automotive industry. Keyence; [cited 2025]. Available from: <https://www.keyence.com/products/3d-measure/cmm/industries/automotive.jsp>
- [2] Nel Pretech. CMM inspection service and its application. Nel Pretech; 2024 [cited 2025]. Available from: <https://www.nelpretech.com/blog/cmm-inspection-service-and-its-application>

- [3] Averroes AI. Automated quality control vs manual inspection. Averroes AI; 2024 [cited 2025]. Available from: <https://averroes.ai/blog/automated-quality-control-vs-manual-inspection>
- [4] Shahbazi M, Torabi Moghaddar R. Deep learning in machine vision as a replacement for human labor in visual inspection of casting parts. In: Proceedings of the 18th National Conference and 7th International Conference on Manufacturing Engineering; 2024 Mar 2; Tehran, Iran. Tehran: Technical and Vocational University (TVU); 2024. [In Persian]
- [5] Molina J, Solanes JE, Arnal L, Tornero J. On the detection of defects on specular car body surfaces. Robotics and Computer-Integrated Manufacturing. 2017 Dec 1;48:263-78. doi: [10.1016/j.rcim.2017.04.009](https://doi.org/10.1016/j.rcim.2017.04.009)
- [6] Palma-Ramírez D, Ross-Veitia BD, Font-Arriosa P, Espinel-Hernández A, Sanchez-Roca A, Carvajal-Fals H, Nuñez-Alvarez JR, Hernández-Herrera H. Deep convolutional neural network for weld defect classification in radiographic images. Heliyon. 2024 May 15;10(9). doi: [10.1016/j.heliyon.2024.e30590](https://doi.org/10.1016/j.heliyon.2024.e30590)
- [7] Qu Z, Shen J, Li R, Liu J, Guan Q. Partsnet: A unified deep network for automotive engine precision parts defect detection. In: Proceedings of the 2018 2nd International Conference on Computer Science and Artificial Intelligence 2018 Dec 8 (pp. 594-599).
- [8] Yazdani Jo A, Moosavian A. Automatic intelligent inspection system for crankshaft grade detection based on machine vision and deep learning. The Journal of Engine Research. 2025 Feb 19;71(4):33-43. doi: [10.22034/er.2024.2003707.1006](https://doi.org/10.22034/er.2024.2003707.1006) [In Persian]
- [9] 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 Aug 23;72(2):9-18. doi: [10.22034/er.2025.2056649.1080](https://doi.org/10.22034/er.2025.2056649.1080) [In Persian]
- [10] Capela S, Silva R, Khanal SR, Campaniço AT, Barroso J, Filipe V. Engine labels detection for vehicle quality verification in the assembly line: a machine vision approach. In: APCA International Conference on Automatic Control and Soft Computing 2020 Jul 1 (pp. 740-751). Cham: Springer International Publishing.
- [11] Rochussen J, Kirchen P. Robust image segmentation for feature extraction from internal combustion engine in-cylinder images. Measurement Science and Technology. 2020 Jan 1;32(1):015302. doi: [10.1088/1361-6501/abae8f](https://doi.org/10.1088/1361-6501/abae8f)
- [12] Kim KS, Park JY, Kwak SY. Attention mechanism-based lightweight defect detection method for small components. In: Proceedings of the 2022 International Conference on Electronics, Information and Communication (ICEIC); 2022 Feb 6-9; Jeju, South Korea. Piscataway, NJ: IEEE; 2022.
- [13] Hosseini AR, Moosavian A, Javan S, Baradaran-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](https://doi.org/10.22034/er.2022.697916) [In Persian]
- [14] Lin T, Wu X, Qiu Z, Chen Y. Research on a defect detection method of rolling bearing based on an improved YOLOv4. In: Proceedings of the 2021 IEEE International Conference on Robotics and Automation (ICRA); 2021 May 30-Jun 5; Xi'an, China. Piscataway, NJ: IEEE; 2021. p. 2480-2487.
- [15] Huynh N. Understanding evaluation metrics in medical image segmentation. Medium: Where good ideas find you. 2023 Mar 1.
- [16] Yeung M, Rundo L, Nan Y, Sala E, Schönlieb CB, Yang G. Calibrating the dice loss to handle neural network overconfidence for biomedical image segmentation. Journal of Digital Imaging. 2023 Apr;36(2):739-52. doi: [10.1007/s10278-022-00735-3](https://doi.org/10.1007/s10278-022-00735-3)