



طراحی سیستم هوشمند مبتنی بر بینایی ماشین برای تشخیص سایش لقی گیر روغنی

زهره نورالهی^{*}، جعفر هاشمی داریان²، سید محمدرضا سادات اخوی³، توحید میرزابابای مستوفی⁴

Nouralahizahra82@gmail.com

j_hashemi@ip-co.com

m_sadatakhavi@ip-co.com

t.m.mostofi@eyc.ac.ir

¹ کارشناس مهندسی مکانیک دانشگاه دانشگاه غیردولتی - غیرانتفاعی ایوانکی

² مسئول اداره توسعه صحنه‌گذاری، شرکت تحقیق، طراحی و تولید موتور ایرانخودرو (ایپکو)

³ کارشناس اداره برق و الکترونیک، شرکت تحقیق، طراحی و تولید موتور ایرانخودرو (ایپکو)

⁴ عضو هیات علمی دانشگاه غیردولتی - غیرانتفاعی ایوانکی

چکیده

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 ماشین برای تشخیص خرابی (سایش) لقی گیر روغنی طراحی و اجرا شده است. هدف از این سامانه، جایگزین کردن روش‌های سنتی و پرهزینه بازرسی، مانند ماشین 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، نرمال‌سازی و افزایش داده، برای طبقه‌بندی سالم/معیوب از شبکه رزنت 18 (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 مدل پیشنهادی در مقایسه با روش‌های سنتی، ضمن افزایش دقت (بیش از 97.6٪ در طبقه‌بندی و ضریب دایس 0.721 در بخش‌بندی)، موجب کاهش زمان بازرسی تا بیش از 70٪ شد. همچنین مقایسه خروجی سامانه با ارزیابی کارشناسان انسانی، همخوانی بالایی را نشان داد، که بیانگر قابلیت اعتماد و دقت عملی سامانه است.

کلیدواژه‌ها: بینایی ماشین، طبقه‌بندی، بخش‌بندی تصویر، موتور درونسوز، خرابی قطعات موتور



Design of an intelligent hydraulic lash adjuster wear detection system based on machine vision

Zahra Norallahi^{1*}, Jafar Hashemi Daryan², Seyed Mohammadreza Sadat Akhavi³, Tohid Mirzababayi Mostofi⁴

^{1*} BSc Mechanical Engineering, Eyvanekey University

² Head of Validation Development Department, Iran Khodro Powertrain Company (IPCO)

³ Electrical and Electronics Department Expert, Iran Khodro Powertrain Company (IPCO)

⁴ Faculty of Mechanical Engineering Department, Eyvanekey University

Nouralahizahra82@gmail.com

j_hashemi@ip-co.com

m_sadatakhavi@ip-co.com

t.m.mostofi@eyc.ac.ir

Abstract

Timely detection of failures in critical components of internal combustion engines is one of the key factors in extending engine lifetime and reducing repair and maintenance costs. In this study, an intelligent machine vision-based system was designed and implemented to detect failures (wear) in Hydraulic Lash Adjusters (HLA). The main objective of this system is to replace traditional and costly inspection methods, such as coordinate measuring machines, with a faster, more accurate, and cost-effective approach. The dataset consisted of color images of normal and defective parts. After a preprocessing stage including resizing, normalization, and data augmentation, **Resnet18** was employed for Normal/Damaged classification, while a U-Net architecture was used for defect segmentation. The proposed system was evaluated using accuracy, recall, precision, and overlap-based metrics. Results demonstrated that the proposed model, compared with traditional methods, not only achieved higher accuracy (over 97.6% in classification and final Dice Score of 0.721) but also reduced inspection time by more than 70%. Furthermore, a comparison between the system's output and expert human evaluation showed high consistency, confirming the reliability and practical applicability of the proposed method.

Keywords: Machine Vision, Classification, Image Segmentation, Internal Combustion Engine, Engine Parts Failure Detection




مقدمه

تشخیص به موقع خرابی قطعات امری حیاتی موتورهای درونسوز است. در میان این قطعات، لقی گیر روغنی¹ به دلیل نقش مستقیم در تنظیم لقی درپچه‌ها از اهمیت ویژه‌ای برخوردار است؛ به گونه‌ای که خرابی آن می‌تواند منجر به کاهش راندمان حجمی موتور، افزایش مصرف سوخت، افزایش صدای موتور و حتی آسیب جدی به مجموعه مکانیزم درپچه‌ها 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 مختصات² و بازرسی انسانی تاکنون به طور گسترده در صنعت از جمله در شرکت اپیکو استفاده شده‌اند [1,2,3] با این حال، این روش‌ها با چالش‌های متعددی روبه‌رو هستند:

- هزینه بالا شامل قیمت خرید، تعمیرات و نگهداری
- نیاز به اپراتورهای متخصص و مشکلات کالیبراسیون،
- سرعت پایین بازرسی به‌ویژه در خطوط تولید انبوه،
- و در مورد بازرسی انسانی، وابستگی به تجربه فردی و کاهش دقت³ در شرایط کاری طولانی‌مدت [4].

شکل 1 نمونه‌ای از ماشین اندازه‌گیری مختصات و پروفیل سطح لقی گیر روغنی پس از آزمون شوک حرارتی را نشان می‌دهد و ناحیه فرورفتگی خرابی قطعه در آن قابل مشاهده است.



شکل 1: نمونه خروجی ماشین اندازه‌گیری مختصات و پروفیل سطح لقی گیر روغنی

این محدودیت‌ها موجب شده است که صنعت به دنبال راهکارهای سریع‌تر، کم‌هزینه‌تر و هوشمندتر باشد. در سال‌های اخیر، بینایی ماشین⁴ و شبکه‌های عصبی عمیق در حوزه تشخیص خرابی قطعات صنعتی به طور گسترده مورد توجه قرار گرفته‌اند. برای نمونه، پژوهش‌هایی در زمینه تشخیص خرابی سوپاپ‌ها و پیستون‌ها، با شناسایی عیوب میل‌لنگ و قطعات بدنه خودرو با استفاده از

معماری‌های شبکه‌های عصبی کانولوشنی⁵ و معماری یولو⁶، نشان داده‌اند که این روش‌ها می‌توانند دقت بالاتر و سرعت بسیار بیشتری نسبت به روش‌های سنتی فراهم کنند [5,6,7]. در این زمینه، مرور مطالعات نشان می‌دهد که شبکه‌های یادگیری عمیق به‌ویژه در تشخیص عیوب سطحی قطعات صنعتی عملکرد چشمگیری داشته‌اند. به عنوان مثال، یزدانی و موسویان (۱۴۰۳) 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 [8]؛ اگرچه تمرکز آن‌ها بر روی کاراکترهای حک‌شده بود. همچنین، کاپال و همکاران (۲۰۲۰) مدلی مبتنی بر R-CNN Faster و YOLOv3 برای بازرسی برجسب‌های موتور پیشنهاد کردند که دقت طبقه‌بندی بالای ۹۰٪ را ارائه داد [9]. از منظر بخش‌بندی⁷، روچاسن و کیرچن (۲۰۲۰) با ارائه‌ی یک الگوریتم ویژه برای سیلندر موتور، اثبات کردند که دستیابی به دقت پیکسلی بیش از ۹۰٪ در شرایط نوری متغیر امکان‌پذیر است [10]. علاوه بر این، پژوهش‌هایی مانند کار کیم و پارک (۲۰۲۲) با استفاده از سازوکار توجه⁸ (قابلیت تمرکز بر مهم‌ترین ویژگی‌های تصویر) به دقت مثبت⁹ ۹۴.۵٪ و امتیاز F1 معادل ۰.۹۱ در تشخیص عیوب موضعی سطحی دست یافتند [11]. همچنین، در بخش سرعت بازرسی، حسینی و همکاران (۱۴۰۳) در ردیابی تسمه سفت‌کن به دقت ۹۸٪ رسیدند [12]. و چان و همکاران (۲۰۲۱) با YOLOv4 به سرعت ۵۰ فریم بر ثانیه و میانگین دقت تشخیص ۸۸٪ در بازرسی بلبرینگ‌ها دست یافتند [13]. با وجود این پیشرفت‌های گسترده، تاکنون مطالعه‌ی 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 ماشین برای تشخیص خرابی لقی گیر روغنی است. این سامانه ضمن طبقه‌بندی¹⁰ 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.

⁶ You Only Look Once - YOLO

⁷ Segmentation

⁸ Attention Mechanism

⁹ Precision

¹⁰ classification

¹ HLA (Hydraulic Lash Adjuster)

² Coordinate Measuring Machine (CMM)

³ Accuracy


⁴ Computer vision

⁵ Convolutional Neural Network (CNN)



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

1. نوع اول: قطعه چرخش مناسبی دارد اما سایش^۴ 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.
2. نوع دوم: قطعه چرخش مناسبی ندارد و سایش روی سطح به صورت غیر دایروی دیده می‌شود که عمدتاً ناشی از مشکلات هندسی است.
3. نوع سوم: از بین رفتن پوشش‌های کربن شبه‌الماسی^۴ 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

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 فلش ثبت شدند. در حالت فلش، نور محیطی تا حد زیادی حذف و تنها نور لحظه‌ای فلش (معادل حدود ۱۰ لوکس) روی سطح قطعه اعمال گردید. این تنوع شرایط نوری به بررسی عملکرد مدل در سناریوهای متفاوت کمک نمود.


پیش‌پردازش داده‌ها

در این پژوهش، ۱۶۹ تصویر از قطعات لقی‌گیر 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^۵ تصاویر با دقت بالا توسط کارشناسان فنی انجام شد. برای قطعات معیوب، نواحی آسیب‌دیده با استفاده از ابزار لیبیل استدیو^۶ به صورت ماسک‌های دودویی

ادامه این مقاله به‌صورت زیر سازمان‌دهی شده است: در بخش دوم، داده‌های مورد استفاده شامل تعداد نمونه‌ها، شرایط اخذ تصاویر در آزمایشگاه، مشخصات دوربین و شرایط نوری تشریح می‌شود. در بخش سوم، روش‌های پیش‌پردازش^۱، آماده‌سازی داده و بهبود کیفیت تصاویر توضیح داده شده و سپس مدل‌های مورد استفاده و معماری آن‌ها معرفی می‌گردند. در بخش چهارم، عملکرد مدل‌ها در وظایف طبقه‌بندی و بخش‌بندی بیان شده و اقدامات انجام‌شده برای بهبود دقت تشریح می‌شود. در بخش پنجم، نتایج آزمایش‌ها همراه با تحلیل و مقایسه با روش‌های سنتی ارائه خواهد شد. در بخش ششم، جمع‌بندی پژوهش و چشم‌اندازهای آتی شامل امکان گسترش سامانه برای تشخیص خرابی سایر قطعات موتور مطرح می‌گردد.

داده‌ها و شرایط آزمایشگاه

در این پژوهش، مجموعه داده شامل تعدادی تصاویر قطعات لقی‌گیر روغنی بود که پس از اعمال تکنیک‌های داده‌افزایی^۲ (مانند تغییر روشنایی، کنتراست 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 مدل انجام شد. محدودیت‌های آزمایشگاهی و تغییرات نوری مانع از گردآوری داده‌های بیشتر شد، اما تنوع نسبی حاصل از داده‌افزایی به مدل 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 بالا، امکان تکرارپذیری آن‌ها وجود نداشت. به منظور نمایش محل قرارگیری لقی‌گیر روغنی در موتور، از یک تصویر شماتیک استفاده شده است (شکل ۲) این تصویر، موقعیت تقریبی قطعه و ارتباط آن با اجزای اطراف نظیر بادامک را نشان می‌دهد. لقی‌گیر روغنی بین بادامک و دريچه قرار گرفته و همواره لقی بین این دو قطعه را صفر می‌کند. این امر باعث کاهش صدای این ناحیه و افزایش عمر دريچه و نشیمنگاه آن بر روی سرسیلندر می‌شود.



شکل ۲: نمای شماتیک محل قرارگیری لقی‌گیر روغنی در موتور

⁴ Diamond-Like Carbon Coatings (DLC)

⁵ labeling

⁶ Label Studio

¹ Preprocessing

² Data Augmentation

³ Wear



مکانی⁵ و بازیابی جزئیات دقیق مرزهای خرابی است که برای تشخیص عیوب موضعی و تعیین موقعیت سایش ضروری است.

مدل طبقه‌بندی: برای تشخیص قطعات سالم و معیوب از شبکه رزنت⁶ از پیش‌آموزش‌دیده استفاده شد. ورودی مدل تصاویر رنگی با ابعاد ۲۲۴×۲۲۴ پیکسل بودند. لایه نهایی متناسب با مسئله بازطراحی شد و شامل:

1. یک لایه حذف تصادفی^۷ با احتمال ۰.۵
2. یک لایه تمام‌متصل^۸ با دو نورون خروجی (سالم/معیوب)^۹

برای آموزش، داده‌ها ابتدا از فایل‌های فشرده¹⁰ استخراج و سپس در قالب یک چارچوب داده^{۱۱} سازمان‌دهی شدند. برچسب‌گذاری به صورت (1 = سالم، 0 = معیوب) انجام شد. مجموعه داده با روش تقسیم لایه‌ای^{۱۲} به سه بخش (آموزش ۷۰٪، اعتبارسنجی ۱۵٪ و آزمون ۱۵٪) تقسیم گردید تا نسبت کلاس‌ها حفظ شود. پیاده‌سازی تمامی مدل‌ها و مراحل آموزش با استفاده از زبان برنامه‌نویسی پایتون¹³ و کتابخانه‌های یادگیری عمیق¹⁴ و در محیط گوگل کولب¹⁵ انجام گرفت. مدل با بهینه‌ساز آدام^{۱۶} (نرخ یادگیری 0.001) و تابع هزینه آنتروپی متقاطع^{۱۷} آموزش داده شد. فرآیند آموزش با (اندازه دسته^{۱۸} = 20) اجرا گردید. علاوه بر دقت و خطا، مدل با معیارهای منحنی ارزیابی تفکیک‌پذیری مدل^{۱۹}، منحنی دقت-بازخوانی^{۲۰}، ماتریس اغتشاش^{۲۱} و گزارش طبقه‌بندی^{۲۲} ارزیابی شد. (شکل ۴). در نمودار تغییرات دقت (شکل ۴)، دقت اعتبارسنجی²³ در برخی دوره‌ها بالاتر از دقت آموزش²⁴ مشاهده می‌شود. این امر نشان‌دهنده اثربخشی تکنیک‌های منظم‌سازی²⁵ مانند لایه حذف تصادفی (Dropout)، که تنها در فاز آموزش فعال است) در جلوگیری از بیش‌برازش²⁶ است. در نتیجه، مدل در فاز اعتبارسنجی که لایه حذف تصادفی غیرفعال است، عملکرد بهتری از خود نشان می‌دهد.

مشخص گردید^۱. در این ماسک‌ها، 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 ماسک‌های دودویی به‌صورت مشترک توسط دو نفر انجام پذیرفت: محقق اصلی پژوهش (به‌عنوان متخصص پردازش تصویر) و مسئول اداره توسعه صحنه‌گذاری شرکت اپیکو به‌عنوان 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 مدل، از تکنیک‌های داده افزایی^۲ استفاده شد. این فرآیند با بهره‌گیری از پلتفرم روبوفلو³ انجام پذیرفت و شامل تغییراتی نظیر چرخش، تغییر مقیاس، برش تصادفی، تغییر روشنایی و کنتراست بود. این تکنیک‌های داده افزایی موجب شدند مدل توانایی شناسایی و تعمیم ویژگی‌های تصویری مختلف را در شرایط متنوع محیطی و نوری بهبود بخشد.

تصاویر به اندازه ۲۲۴×۲۲۴ پیکسل تغییر اندازه⁴ داده شدند تا با ورودی‌های مدل‌های پیش‌آموزش‌دیده تطابق داشته باشند. همچنین، برای نرمال‌سازی، مقادیر پیکسل‌ها به دامنه [0, 1] مقیاس‌بندی شدند و میانگین و انحراف معیار داده‌ها تنظیم گردید تا فرآیند آموزش بهینه‌تری حاصل شود.

مدل و معماری

این پژوهش به‌طور همزمان وظایف طبقه‌بندی و بخش‌بندی را دنبال می‌کند؛ لذا دو معماری مجزا به‌کار گرفته شد. شبکه‌ی رزنت 18 به دلیل ساختار عمقی و توانایی در استخراج ویژگی‌های سلسله‌مراتبی با سرعت مناسب، به‌عنوان مدل 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

¹⁴ PyTorch

¹⁵ Google Colab

¹⁶ Adam

¹⁷ Cross-Entropy Loss

¹⁸ Batch size

¹⁹ Receiver Operating Characteristic (ROC) Curve

²⁰ Precision-Recall Curve

²¹ Confusion Matrix

²² Classification Report

²³ Validation Accuracy

²⁴ Training Accuracy

²⁵ Regularization

²⁶ Overfitting

¹ Annotation

² Data Augmentation

³ Roboflow

⁴ Resizing

⁵ Spatial Information

⁶ ResNet18

⁷ Dropout

⁸ Fully Connected

⁹ Normal/Damaged

¹⁰ ZIP, RAR


¹¹ DataFrame

¹² Stratified Split


¹³ Python




مدل 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 ماسک‌های متناظر آن‌ها استخراج و سازمان‌دهی شدند تا انطباق کامل میان داده‌ها و برچسب‌ها برقرار باشد. خروجی مدل یک نقشه دودویی^۱ با ابعاد برابر با تصویر ورودی (۲۲۴×۲۲۴ پیکسل) بود که نواحی معیوب را با رنگ سفید و بخش‌های سالم را با رنگ مشکی مشخص می‌کرد. (شکل ۷). به‌منظور کاهش پدیده‌ی بیش‌برازش، از لایه‌های حذف تصادفی و منظم‌سازی L2 استفاده شد. (شکل ۶) فرآیند آموزش مدل با بهینه‌ساز آدام (با نرخ یادگیری ۰/۰۰۰۱) و اندازه دسته = ۱۶ و تابع هزینه دایس^۲ در طی ۱۵ دوره اجرا گردید.



شکل ۶: تاثیر لایه‌های حذف تصادفی در کاهش بیش‌برازش



شکل ۷: نمونه خروجی مدل بخش بندی



شکل ۴: نمودار تغییرات دقت مدل در طول دوره‌های آموزش و اعتبارسنجی

در ادامه‌ی 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.

جدول ۱: خلاصه‌ی نتایج ارزیابی مدل طبقه‌بندی ResNet18 بر روی مجموعه آزمون

میانگین وزنی	کلاس معیوب (0)	کلاس سالم (1)	معیار
۹۸.۸٪	۹۵.۱٪	۱۰۰٪	صحت (Precision)
۹۷.۳٪	۹۵.۷٪	۹۸.۱٪	بازخوانی (Recall)
۹۷.۹٪	۹۵.۴٪	۹۹.۰٪	امتیاز (F1 Score)
۹۷٪			دقت کلی

در مرحله‌ی پیش‌بینی، مدل تصویر ورودی را تحلیل کرده و علاوه بر تعیین برچسب نهایی (سالم یا معیوب)، احتمال تعلق تصویر به هر کلاس را نیز ارائه می‌دهد. به‌عنوان مثال، در شکل ۵، مدل با اطمینان ۹۵٪ 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 مدل طبقه بندی (قطعه با احتمال ۹۵ درصد معیوب است)

² Dice Loss

¹ binary mask



جدول 2 - معماری یونت (U-Net) مورد استفاده

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

در عملکرد مدل، حساسیت بالای آن نسبت به جزئیات ظاهری قطعات است؛ به‌طوری‌که حتی تغییرات سطحی مانند یک خراش کوچک یا نویز جزئی در داده‌ها می‌تواند در خروجی مدل تأثیرگذار باشد. این ویژگی، اگرچه نیازمند دقت بیشتر در جمع‌آوری داده‌هاست، اما در محیط‌های صنعتی که کیفیت و سلامت قطعه اهمیت حیاتی دارد، می‌تواند به‌عنوان یک مزیت در تشخیص دقیق‌تر تلقی شود.

عملکرد مدل بخش‌بندی (U-Net) پس از ۱۵ دوره آموزش در داده‌های اعتبارسنجی به دقت پیکسلی ۹۵.۳٪ و ضریب دایس معادل ۰.۷۲۱ رسید. اگرچه دقت پیکسلی بالاست، اما ضریب Dice معیار دقیق‌تر و مناسب‌تری برای سنجش عملکرد مدل در شناسایی خرابی‌های موضعی (به دلیل عدم توازن کلاس‌ها) محسوب می‌شود [14, 15]. ثبات این شاخص‌ها در طول آموزش و نزدیکی نتایج به داده‌های آموزشی (نمودار شکل ۶ نشان می‌دهد که مدل دچار بیش‌برازش نشده و قابلیت تعمیم‌پذیری خوبی دارد.

مقایسه با کارشناسان خبره

- در بخش طبقه‌بندی، کارشناسان هر تصویر را به‌صورت «1 = سالم» یا «0 = معیوب» برچسب‌گذاری کردند.
- در بخش بخش‌بندی، کارشناسان نقشه خرابی را مشخص کرده و با ماسک خروجی مدل مقایسه شد.

نتایج نشان داد که در بخش طبقه‌بندی، مدل در شناسایی قطعات معیوب عملکردی مشابه یا حتی دقیق‌تر از کارشناسان داشت، در حالی‌که در تشخیص قطعات سالم تمایل به سخت‌گیری بیشتری نشان داد. این موضوع اگرچه موجب کاهش دقت در کلاس سالم شد، اما از دیدگاه صنعتی مزیت محسوب می‌شود زیرا هیچ قطعه معیوبی از چرخه کنترل کیفیت عبور نمی‌کند. در بخش بخش‌بندی نیز، نقشه‌های خرابی تولیدشده توسط مدل با ماسک‌های کارشناسان همپوشانی قابل قبولی داشت و عمده اختلاف‌ها مربوط به مرزهای نواحی آسیب‌دیده بود. این نتایج بیانگر آن است که مدل می‌تواند در کنار نیروی انسانی به‌عنوان 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 مدل و کارشناسان خبره به‌صورت 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

تحلیل نتایج

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

1. استفاده از مجموعه‌ی داده‌ی آزمون مستقل شامل تصاویر جدید که در فرآیند آموزش به کار نرفته بودند.
2. مقایسه‌ی نتایج مدل‌ها با پیش‌بینی کارشناسان خبره (6 نفر از متخصصان حوزه تولید و کنترل کیفیت)

مدل طبقه‌بندی (ResNet18) توانست به دقت کلی ۹۷.۶٪ دست یابد. نکته حائز اهمیت، کسب دقت مثبت (Precision) ۱۰۰٪ در تشخیص کلاس معیوب بود. این نتیجه به معنای عدم وجود خطای مثبت کاذب است؛ یعنی مدل هرگز قطعه سالمی را به اشتباه معیوب تشخیص نداده است. این ویژگی، همراه با بازخوانی¹ ۹۸.۱٪، تضمین می‌کند که سیستم پیشنهادی بالاترین سطح کنترل 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). نکته قابل توجه

¹ Recall



جدول 5: نمونه مقایسه پیش بینی مدل با کارشناسان

کارشناس	تشخیص	تشخیص مدل
A	1	True: Normal: Damaged (0.55) 
B	1	
C	1	
D	1	
E	1	
F	1	

نتیجه‌گیری

در این پژوهش، یک سامانه‌ی هوشمند مبتنی بر بینایی ماشین برای شناسایی و بخش‌بندی خرابی در لقی گیر روغنی موتور طراحی و پیاده‌سازی شد. نتایج نشان داد که مدل طبقه‌بندی توانست به دقت کلی ۹۷.۶٪ دست یابد و با کسب دقت مثبت (Precision) ۱۰۰٪ در تشخیص قطعات معیوب، هدف اصلی کنترل کیفیت صنعتی را محقق سازد. هرچند در تفکیک قطعات سالم محدودیت داشت. در مدل بخش‌بندی (U-Net) نیز دقت پیکسلی ۹۵.۳٪ و ضریب دایس ۰.۷۲۱ به دست آمد که بیانگر تعمیم‌پذیری مناسب مدل در شناسایی دقیق نواحی خرابی است. به طور کلی، سیستم پیشنهادی بالاترین سطح اطمینان را برای بازرسی قطعات موتور فراهم کرده و می‌تواند به‌عنوان ابزار کمکی مؤثر در فرآیند بازرسی به کار گرفته شود. توسعه‌ی مجموعه داده‌های گسترده‌تر، تنوع شرایط نوری و استفاده از مدل‌های پیشرفته‌تر می‌تواند زمینه‌ی ارتقای عملکرد و کاربرد پذیری صنعتی این سامانه را فراهم سازد. در گام بعدی، قابلیت توسعه‌ی یک نرم‌افزار کاربردی برای تلفن‌های همراه وجود دارد؛ نرم‌افزاری که بتواند با دریافت تصویر قطعه از طریق دوربین گوشی، وضعیت سلامت آن را تشخیص داده و در صورت وجود خرابی، نوع آسیب یا ناحیه‌ی معیوب را مشخص کند. این سامانه می‌تواند برای طیف وسیعی از قطعات موتور تعمیم یابد و با فراهم‌سازی امکان بازرسی سریع و قابل حمل، نقش مؤثری در افزایش بهره‌وری خطوط تولید و کاهش خطای انسانی ایفا کند. چنین ابزاری، گامی مهم در جهت صنعتی‌سازی و تجاری‌سازی این فناوری خواهد بود.

تشکر و قدردانی

تصاویر مربوط به قطعات از آرشیو 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.

که مدل در تشخیص قطعات معیوب دقت بالایی داشته و در مواردی با سخت‌گیری بیشتر نسبت به کارشناسان عمل کرده است، که از منظر کنترل کیفیت صنعتی یک مزیت محسوب می‌شود (جدول 3 تا 5). لازم به بیان است که در مرحله آموزش شبکه از تصاویری استفاده شده است که در آن نظر کارشناسان یکسان بوده و در مورد تشخیص خرابی از روی تصویر، تردیدی وجود ندارد که نمونه آن در جدول 3 آورده شده است. اما در مرحله صحنه‌گذاری، تصاویری نیز وجود دارد که در آن بین کارشناسان اتفاق نظر وجود نداشته و بنابراین صددرصد در مورد آن قضاوت نمیتوان کرد. مدل نیز در این مورد با اطمینان ۵۹ درصد پیش-بینی انجام داده است (جدول 4). در مورد جدول 5 نیز نمونه‌ای از قطعه سالم (تأییدشده توسط کارشناسان) که مدل به دلیل حساسیت بالا نسبت به خراش‌های سطحی آن را با احتمال ۵۵ درصد به اشتباه در گروه معیوب طبقه‌بندی کرده است.

جدول 3: نمونه مقایسه پیش بینی مدل با کارشناسان

کارشناس	تشخیص	تشخیص مدل
A	0	True: damaged: Damaged (1.00) 
B	0	
C	0	
D	0	
E	0	
F	0	

جدول 4: نمونه مقایسه پیش بینی مدل با کارشناسان

کارشناس	تشخیص	تشخیص مدل
A	1	True: damaged: Normal (0.59) 
B	0	
C	1	
D	0	
E	0	
F	0	



مراجع و منابع

یادگیری عمیق، نشریه تحقیقات موتور، 1403، دوره 71، شماره 4، صفحات 43-33.

[9] S. Capela, R. Silva, S. R. Khanal, A.T. Campaniço, J. Barroso, V. Filipe, Engine Labels Detection for Vehicle Quality Verification in the Assembly Line: A Machine Vision Approach, Portuguese Conference on Automatic Control, Springer, pp. 740-751, 2020.

[10] J. Rochussen, P. Kirchen, Robust image segmentation for feature extraction from internal combustion engine in-cylinder images, Measurement Science and Technology, Vol. 32 (2020) pp. 015302.

[11] K. S. Kim, J. Y. Park, and S. Y. Kwak, Attention Mechanism-Based Lightweight Defect Detection Method for Small Components, Proc. of the 2022 Int. Conf. on Electronics, Information and Communication (ICEIC), Barcelona, Spain, 2022.

[12] علیرضا حسینی، سید اشکان موسویان، سعید جوان، شهریار برادران شکوهی، توسعه سامانه بینایی ماشین برای ردیابی حرکت تسمه سفت‌کن سامانه زمان‌بندی موتور بر پایه شبکه عصبی عمیق، همایش موتورهای درونسوز و نفت، ایران، 1403.

[13] T. Lin et al., Research on a Defect Detection Method of Rolling Bearing Based on an Improved YOLOv4, Proc. of the 2021 IEEE International Conference on Robotics and Automation (ICRA), Xi'an, China, 2021, pp. 2480-2487.

[14] N. Huynh, Understanding Evaluation Metrics in Medical Image Segmentation, Mastering Data Science, 4 Sep 2024.

[15] M. Yeung, Calibrating the Dice Loss to Handle Neural Network overconfidence, Journal of Digital Imaging, 2023.

[1] Keyence.com, CMM in Automotive Industry. Available at: <https://www.keyence.com/products/3d-measure/cmm/industries/automotive.jsp>

[2] Nel Pretech, CMM Inspection Service & Its Application, 2024. Available at: <https://www.nelpretech.com/blog/cmm-inspection-service-and-its-application>

[3] Averroes AI, Automated Quality Control vs Manual Inspection, 2024. Available at: <https://averroes.ai/blog/automated-quality-control-vs-manual-inspection>

[4] محمد شهبازی، رضا ترابی مقتدر، یادگیری عمیق در بینایی ماشین جهت جایگزینی نیروی انسانی در بازرسی بصری قطعات ریخته‌گری، هجدهمین همایش ملی و هفتمین کنفرانس بین‌المللی مهندسی ساخت و تولید، دانشگاه علم و صنعت ایران، 1403

[5] J. Molina, J.E. Solanes, L. Arnal, J. Tornero, On the Detection of Defects on Specular Car Body Surfaces, Universitat Politècnica de València, Spain, 2018

[6] D. Palma-Ramírez et al., Deep convolutional neural network for weld defect classification in radiographic images, 2019

[7] Z. Qu et al., PartsNet: A Unified Deep Network for Automotive Engine Precision Parts Defect Detection, Harbin Institute of Technology, 2020

[8] علیرضا یزدانی‌جو، سید اشکان موسویان، سامانه هوشمند بازرسی خودکار برای تشخیص و رتبه‌بندی میل‌لنگ مبتنی بر بینایی ماشین و