



تشخیص و اندازه‌گیری تاب خوردگی در فرایند ساخت افزایشی FDM با استفاده از هوش مصنوعی و بینایی ماشین

علی مقام‌فر، محمد شهبازی*، رامین هاشمی

دانشکده مهندسی مکانیک، دانشگاه علم و صنعت ایران، تهران، ایران

* ایمیل نویسنده مسئول: shahbazi@iust.ac.ir

چکیده

اطلاعات مقاله

فرایند ساخت افزایشی با روش مدل‌سازی رسوب ذوب‌شونده (FDM) در ساخت قطعات با چالش‌هایی از جمله بروز عیوب ساختاری مواجه است. شناسایی به موقع این عیوب می‌تواند از هدر رفت مواد و زمان جلوگیری کرده و در برخی موارد امکان اصلاح فرایند تولید را فراهم کند. در این پژوهش، یک رویکرد نوآورانه برای تشخیص و اندازه‌گیری تاب‌خوردگی قطعات با استفاده از هوش مصنوعی و بینایی ماشین ارائه شده است. این روش قابلیت تشخیص عارضه تاب را با استفاده از هر نوع دوربین (دوربین گوشی هوشمند، لپ‌تاپ و غیره) در شرایط طبیعی و غیرمهندسی به صورت برخط دارا است و همچنین قابلیت تعمیم برای تشخیص سایر عیوب بصری را نیز دارد. در گام نخست، از شبکه‌های یادگیری عمیق نظیر VGG و Xception برای شناسایی عیب استفاده و در مراحل بعد، از الگوریتم‌های کلاسیک مانند Canny و HSV برای اندازه‌گیری میزان تاب بهره گرفته شد. با تحلیل نتایج، فرایند به سمت بهره‌گیری بیشتر از روش‌های هوشمند هدایت شد، به گونه‌ای که تشخیص عیوب و ایجاد ماسک قطعات به طور کامل توسط هوش مصنوعی انجام گرفت. در نهایت، با استفاده از کتابخانه OpenCV و الگوریتم YOLOv8، دقت تشخیص ۹۹ درصد در آستانه ۰.۵ و میانگین دقت ۰.۷۸ در بازه آستانه ۰.۵ تا ۰.۹۵ به دست آمد. به منظور افزایش کاربردپذیری این فرایند، یک برنامه تحت وب با استفاده از زبان HTML و کتابخانه Streamlit توسعه داده شد که امکان بهره‌برداری آسان‌تر از سیستم را فراهم می‌کند. این پژوهش گامی مؤثر در توسعه فناوری‌های هوشمند برای بهبود کیفیت ساخت افزایشی محسوب می‌شود.

مقاله پژوهشی

دریافت: ۲ مهر ۱۴۰۳

پذیرش: ۹ دی ۱۴۰۳

کلیدواژگان:

مدل‌سازی رسوب ذوب‌شونده

تشخیص عیوب ساختاری

هوش مصنوعی

ساخت افزایشی

بینایی ماشین

تاب‌خوردگی قطعات

Detection and measurement of warping in FDM additive manufacturing process using artificial intelligence and machine vision

Ali Maghamfar, Mohammad Shahbazi*, Ramin Hashemi

School of Mechanical Engineering, Iran University of Science and Technology, Tehran, Iran

* Corresponding Author's Email: shahbazi@iust.ac.ir

Article Information

Original Research Paper

Received: 23 September 2024

Accepted: 29 December 2024

Keywords:

Fused Deposition Modeling

Structural Defect Detection

Artificial Intelligence

Additive Manufacturing

Machine Vision

Warping Defects

Abstract

The Fused Deposition Modeling (FDM) additive manufacturing process faces challenges such as structural defects during part fabrication. Timely detection of these defects can prevent material and time waste and, in some cases, enable process correction. This study presents an innovative approach for detecting and measuring warping defects in parts using artificial intelligence and machine vision. The proposed method allows defect detection with any type of camera (e.g., smartphone, laptop camera) under natural, non-engineered conditions in real-time. Furthermore, this approach is extendable to the detection of other visual defects. Initially, deep learning classification networks, such as VGG and Xception, were employed for defect detection. Traditional algorithms like Canny and HSV were subsequently used to measure the degree of warping. Based on the results, the process evolved toward greater reliance on intelligent methods, enabling defect detection and mask generation entirely through artificial intelligence. Ultimately, leveraging the OpenCV library and the YOLOv8 algorithm, the proposed system achieved a detection accuracy of 99% at a 0.5 threshold and an average accuracy of 0.78 in the 0.95–0.5 threshold range. To enhance the process's usability, a web-based application was developed using HTML and the Streamlit library, facilitating easier access to the system. This research represents a significant step toward integrating intelligent technologies for improving the quality of additive manufacturing processes.

Please cite this article using:

برای ارجاع به این مقاله از عبارت ذیل استفاده نمایید:

Maghamfar A, Shahbazi M, Hashemi R. Detection and measurement of warping in FDM additive manufacturing process using artificial intelligence and machine vision. Iranian Journal of Manufacturing Engineering. 2025 Feb 19;11(12):1-15. doi: 10.22034/ijme.2024.479491.2011 [In Persian]

۱- مقدمه

با توجه به پیشرفت روزافزون استفاده از ماشین‌های ساخت افزایشی، یکی از دغدغه‌های اصلی در این حوزه، تولید قطعاتی است که بدون عیب باشند و در صورت بروز خطا در حین تولید، بتوان قبل از هدر رفت مواد و زمان، روند تولید را متوقف کرده یا به رفع ایراد پرداخت. قطعات تولید شده به روش ساخت افزایشی FDM ممکن است دچار عیوبی مانند تاب‌خوردگی، مویی‌شدن، ترک‌خوردگی و غیره شوند. شناسایی سریع این عیوب می‌تواند از اتلاف منابع و هزینه جلوگیری کند. در حالت معمول، عیوب قابل مشاهده توسط اپراتور شناسایی می‌شوند، اما استفاده از بینایی ماشین می‌تواند جایگزینی مؤثر برای اپراتور باشد. بینایی ماشین به عنوان یکی از روش‌های بازرسی غیرتهاجمی، این امکان را فراهم می‌آورد که از راه دور فرایند تولید نظارت و بررسی شود. این ویژگی باعث می‌شود بتوان تمام قطعات را با دقت بالا بازرسی کرد و زمان و هزینه را کاهش داد. مرجع [۱] نشان داده است که کنترل کیفیت با ۲۹ درصد، محبوب‌ترین فعالیت در صنعت نسل ۴،۰ است و این امر به کمک بینایی ماشین تحقق یافته است. بینایی ماشین قادر است تمامی عملیات مرتبط با صنعت از جمله کنترل کیفیت، نظارت، تشخیص، اندازه‌گیری، شناسایی، طبقه‌بندی، ارزیابی و ذخیره‌سازی را پوشش دهد و نقش مهمی در ارتقای کارایی سیستم‌های تولید ایفا کند.

به طور کلی سه دسته روش برای شناسایی خطای یک ماشین ساخت افزایشی وجود دارد که عبارت‌اند از: روش‌های مبتنی بر حسگر، روش‌های مبتنی بر بینایی ماشین و هوش مصنوعی. برخی از تکنیک‌ها سعی می‌کنند مشکلات چاپ را با اندازه‌گیری داده‌های خاص که مربوط به فرایند چاپ بوده و توسط سنسورهای مختلف بدست آمده‌اند، شناسایی کنند. چندین حسگر ارتعاش و دما توسط شغل برای نظارت بر فرایند ساخت افزایشی استفاده شد [۲]. لو و همکاران [۳] یک قانون کنترل مبتنی بر بازخورد برای چاپ سه بعدی پیشنهاد کردند که از یک حسگر لیزری برای اندازه‌گیری ارتفاع پروفایل هر لایه، جهت تعیین الگوهای لایه به لایه استفاده می‌کرد. وو و همکاران [۴] یک چارچوب نظارتی برای مدل‌سازی رسوب ذوب شده در طول تولید با استفاده از حسگرهای انتشار صوتی جهت شناسایی حالت‌های ماشین پیشنهاد کردند. ژانگ و همکاران [۵] به طور همزمان شدت میدان مغناطیسی را با استفاده از یک سنسور ۹ کانالی سرعت زاویه‌ای، شتاب و ارتعاشات را اندازه‌گیری کردند. این آزمایش بر روی یک چاپگر افدی‌ام نوع دلتا انجام شد. برای استفاده از داده‌های حسگرهای نصب شده بر روی پلتفرم موبایل چاپگر، چندین رمزگذار خودکار پراکنده (SAE) جهت آموزش شبکه یادگیری عمیق مد نظر استفاده گردید. یک حسگر بینایی به پلتفرم چاپگر سه بعدی (نوع دلتا) متصل شد تا الگوهای حرکتی را در حین چاپ توسط این حسگر و IMU (ترکیبی از شتاب‌سنج، ژيروسکوپ و مغناطیس‌سنج) شناسایی کند. نتایج نشان می‌دهد که داده‌های کانال‌های مختلف می‌توانند به سطوح مختلفی از دقت در تشخیص خطا منجر شوند. توجه به این نکته مهم است که استفاده از داده‌های یک کانال برای تشخیص خطاهای چاپگر دلتا کافی نیست. از سوی دیگر، یک مدل BPNN^۱ نیز با استفاده از همین داده‌ها ساخته شد. عملکرد مدل‌های BPNN، صرف نظر از اینکه یک کانال بهینه یا همه کانال‌ها را پوشش دهد، نمی‌تواند نیازهای تشخیص خطا را برآورده کند، در نتیجه از داده‌های جمع‌آوری شده برای تشخیص خطا با استفاده از الگوریتم SVM^۲ استفاده شد [۶].

سارانی و همکاران [۷] از دو دوربین و یک الگوریتم متن‌باز مبتنی بر پایتون استفاده کردند که بر روی یک کامپیوتر Raspberry Pi 3 برای تشخیص جدا شدن، از دست دادن مواد، و تغییر شکل در چاپ سه‌بعدی پیاده‌سازی شد. این رویکرد موفقیت ۸۰ درصدی را به همراه داشت. فنگ و همکاران [۸] تکنیک‌های نظارت آنلاین مبتنی بر بینایی ماشین را در فرایندهای FDM و روش‌های مشابه بررسی کردند. این روش بر اساس تصویربرداری نوری از هر لایه، عیوب را تشخیص می‌دهد و با مقایسه هندسه ساختار تولیدی با داده‌های تصویر برداری نوری و طرح سه‌بعدی اصلی، عیوب را ارزیابی می‌کند. اگرچه این رویکرد امیدوارکننده به نظر می‌رسد، اما نیازمند تجهیزات خاصی است. در مطالعه‌ای دیگر [۹]، از دو میکروسکوپ دیجیتال استفاده شد که در مقابل نقطه اکستروژن قرار گرفتند تا از ایجاد نقاط کور جلوگیری شود. همچنین از یک سیستم کنترل حلقه بسته برای نظارت و کنترل فرایند استفاده شد. با این حال، استفاده از میکروسکوپ چالش‌های مختلفی را در پایش وضعیت به همراه دارد؛ از جمله نیاز به حسگرهای متعدد و جمع‌آوری اطلاعات کافی، نبود الگوریتم‌های مناسب برای تحلیل داده‌های سنسورها، و چالش‌های مرتبط با استفاده از یادگیری ماشین برای کنترل کیفیت.

¹ Back Propagation Neural Network

² Support Vector Machine

وو و همکاران [۱۰] با استفاده از تکنیک‌های یادگیری ماشین، الگوریتم KNN را برای طبقه‌بندی سیگنال‌های صوتی^۱ (AE) در فرایند FDM به کار گرفتند. این الگوریتم برای تفکیک قطعات سالم و معیوب آموزش داده شده و قادر است ناهنجاری‌ها را در زمانی که شرایط چاپ از مسیر تولید صحیح منحرف می‌شود، شناسایی کند. در مطالعه دیگری [۱۱]، از شبکه‌های عصبی کانولوشنال طیفی^۲ (SCNN) برای طبقه‌بندی تخریب‌های ساخته‌شده با مواد افزودنی در فرایند همجوشی بستر پودری استفاده شد. داده‌های فرکانس بالا از حسگرهای انتشار صوتی، پس از پردازش اولیه با تبدیل موجک (فیلترهای بالاگذر و پایین‌گذر)، به عنوان ورودی به SCNN برای ارزیابی کیفیت خروجی چاپگر ارسال شدند [۱۲]. لی و همکاران [۱۳] از حسگرهای ارتعاشی برای نظارت و تشخیص عیوب در فرایندهای چاپ سه‌بعدی مبتنی بر رشته بهره بردند و عملکرد ماشین بردار پشتیبان (SVM) و شبکه عصبی پس‌انتشار (BPNN) را در تشخیص انواع عیوب مقایسه کردند.

ونگ و همکاران [۱۴]، طراحی یک سیستم بازرسی کیفیت سطح برای پرینترهای FDM با استفاده از یک دوربین دوار و ساختار CNN جهت طبقه‌بندی مؤثر عیوب سطح را پیشنهاد داده‌اند. کارنا و همکاران [۱۵] یک مدل بهبود یافته از YOLOv8 را با افزودن لایه‌های استخراج ویژگی به معماری اصلی این مدل ارائه کرده‌اند که بهبود قابل توجهی در تشخیص عیوب چاپگرهای سه‌بعدی FDM داشته است. در تحقیقی که توسط لو و همکاران [۱۶] انجام شد، سیستمی طراحی شد که در زمان واقعی، عیوب ایجاد شده توسط ماشین‌های ساخت افزایشی مبتنی بر ربات را شناسایی کند. همچنین، سیاهوشی و همکاران [۱۷] با استفاده از الگوریتم‌های فراابتکاری، زبری سطح در عملیات فرزکاری را اندازه‌گیری کرده و پیشنهاد داده‌اند که از این روش می‌توان برای پیش‌بینی عیوب در ساخت افزایشی نیز استفاده کرد. در نهایت، محمدی و ناطقی [۱۸] با بهره‌گیری از یادگیری عمیق، ویژگی‌های ایجاد شده در قطعات را با دقت ۸۸ درصد برای کاربردهای ماشین‌کاری شناسایی کرده‌اند.

با توجه به پژوهش‌های انجام شده در حوزه پیش‌بینی تولید، این مطالعه تلاش کرده است تا ابتدا با استفاده از الگوریتم‌های دسته‌بندی تصاویر، قطعات دارای عیب تاب را شناسایی کند و سپس با بهره‌گیری از روش‌های سنتی که از سرعت بالایی برخوردارند، اندازه عیب تاب را تعیین نماید. برای این منظور، چندین رویکرد سنتی مورد بررسی و مقایسه قرار گرفته است. در ادامه، فرایند به سمت هوشمند سازی کامل تمامی مراحل توسعه داده شده است تا تشخیص و اندازه‌گیری عیوب به‌طور کامل با استفاده از هوش مصنوعی انجام گیرد. از نقاط قوت و نوآوری‌های این پژوهش می‌توان به طراحی یک نرم‌افزار اینترنتی اشاره کرد که امکان استفاده از دوربین‌های معمولی، از جمله دوربین موبایل شخصی، را فراهم می‌آورد. این نرم‌افزار قابلیت تشخیص بلادرنگ عیوب و ارزیابی میزان آن‌ها را به سادگی و با تجهیزاتی در دسترس ارائه می‌دهد. نظارت بلادرنگ با استفاده از تجهیزاتی ساده نظیر دوربین موبایل، به‌ویژه در فرایندهای تولید افزایشی، اهمیت ویژه‌ای دارد و مزیتی قابل توجه برای این پژوهش محسوب می‌شود.

۲- آزمایش و مدل‌سازی

برای اینکه بتوان یک سیستم جهت تشخیص عیب تاب پیشنهاد کرد، باید این عیب را در قطعات تولیدی به وجود آورد. به همین منظور، به چند مورد از روش‌هایی که برای ایجاد عیب تاب در این پژوهش انجام شده است، اشاره می‌گردد:


۱. تغییر ارتفاع نازل به صورت افزایشی (۰.۰۵ میلی‌متر نازل از میز دورتر شود).
۲. داشتن ضخامت قطعه حداقل ۱۰ میلی‌متر (ظاهراً در قطعات کم‌ضخامت، تاب کمتر اتفاق می‌افتد).
۳. استفاده از روکش شیشه‌ای برای میز ماشین.
۴. تغییر دما به گونه‌ای که قطعه زودتر سرد گردد.

در آزمایشگاه، یک آزمایش طراحی شد که در آن سیزده پارامتر متمایز با دقت انتخاب شدند تا فرایند چاپ را بهینه کنند. هر پارامتر سه سطح منحصر به فرد را نشان می‌داد. به دنبال آن، روش تاگوچی برای هماهنگی آزمایش‌ها اجرا شد و منجر به تولید ۲۷ آزمایش گردید. روش تاگوچی از آرایه‌های متعامد برای طراحی آزمایش‌ها استفاده می‌کند که باعث می‌شود تعداد آزمایش‌های لازم به شدت کاهش یابد. این موضوع به‌ویژه در مواردی که تعداد عوامل و سطوح آن‌ها زیاد است، بسیار مفید است و به همین دلیل از این روش استفاده گردید. سپس از هر آزمایش یک فیلم تهیه شد که تعداد آن‌ها در مجموع ۲۷ فیلم بود. نقطه کانونی آزمایش طراحی

¹ Acoustic Emission Sensors

² Sequential Convolutional Neural Network

شده، ایجاد یک سیستم پیش‌بینی با هدف پیش‌بینی ویژگی‌های متنوع اشیاء چاپی، از جمله خواصی مانند استحکام کششی و زبری سطح می‌باشد. این ویژگی‌ها تحت تأثیر طیفی از عوامل هستند که شامل ضخامت لایه، ضخامت دیوار، الگوی پرکردن و درصد آن، دمای نازل و بستر، سرعت چاپ، شتاب چاپ، فاصله، سرعت فن و غیره است. ارزیابی سیستماتیک این پارامترها در سه سطح مجزا انجام شد. در طی انجام آزمایش، در برخی از قطعات، عیب تاب به وجود آمد. تجهیزاتی که برای این پژوهش در نظر گرفته شده است شامل یک دستگاه لپ‌تاپ و یک دوربین جهت فیلم‌برداری می‌باشد. دوربین می‌تواند هر دوربینی با هر کیفیتی، مانند انواع موبایل، در نظر گرفته شود. در آزمایش طراحی شده، دو قطعه به صورت همزمان پرینت می‌شوند که از یکی از آن‌ها فیلم گرفته می‌شود (شکل ۱).



شکل ۱ تجهیزات مورد استفاده برای انجام تست‌ها

برای پرینت از دستگاه پرینتر Creality Ender 3 Pro و برای مواد نیز از فیلامنت PLA شرکت APEX با رنگ آبی فیروزه‌ای استفاده شد. در جدول ۱، قطعاتی که تاب در آن‌ها به وجود آمده به همراه پارامترهای تأثیرگذار بر عیب تاب آورده شده است. این پارامترها به گونه‌ای انتخاب شدند که اولاً بادستگاه پرینتر استفاده شده سازگار باشند و ثانیاً امکان بروز عیب تاب را فراهم کنند.


جدول ۱ قطعات دارای تاب خوردگی به همراه پارامترهای تولید آن‌ها

شماره قطعه پرینت شده	ضخامت لایه‌ها (میلی‌متر)	ضخامت دیواره (میلی‌متر)	دمای نازل (°C)	دمای میز (°C)
1	0.1	1	200	50
2	0.1	1	230	70
3	0.1	2	200	50
4	0.1	3	200	50
16	0.2	3	200	60
25	0.3	3	200	70

۲-۱- دسته‌بندی داده‌ها

در ابتدا برای تشخیص اینکه آیا قطعه دارای عیب تاب می‌باشد یا خیر، از یادگیری عمیق استفاده شده است. زمان هر فیلم تقریباً یک ساعت و سی و پنج دقیقه بوده که منجر به ایجاد تعداد زیادی تصویر شد. فیلم‌ها دارای مشکلاتی از جمله عدم کیفیت مناسب، تغییر مداوم زوم دوربین، تار شدن و تغییر عمق دائمی تصویر به دلیل حرکت میز پرینتر بودند. هر فیلم حدوداً شامل ۵۸۰۰۰ تصویر بود و باید تصاویری که به دوربین نزدیک می‌شوند، جهت تشخیص عیب بررسی گردند. برای آموزش شبکه عصبی خود، داده‌ها دسته‌بندی


شده و به سه کلاس متفاوت تقسیم شدند. برای دقیق‌تر شدن کلاس‌ها جهت آموزش به شبکه‌های عصبی، می‌بایست داده‌های جمع‌آوری شده را طبق یک معیار مناسب دسته‌بندی نمود. به همین منظور، پس از اندازه‌گیری میزان تاب، عدد به دست آمده را به طول قطعه تقسیم کرده و متناسب با اندازه نسبت‌های به دست آمده، دسته‌بندی انجام شد. برای اینکار در پایتون یک کد نوشته شد که از طریق ماوس، روی تصویر سه نقطه را انتخاب کرده و سپس به صورت اتوماتیک مقدار نسبت را گزارش می‌دهد. ابتدا دو نقطه لبه قطعه که تاب در آن به وجود آمده و سطح میز انتخاب شده و سپس نقطه انتهایی قطعه انتخاب می‌شود. در نهایت نسبت مد نظر به دست می‌آید و با توجه به ابعاد به دست آمده، عکس‌ها به سه دسته دارای تاب، بدون عیب و تاب کم تقسیم‌بندی گردیدند و در پوشه مخصوص خود ذخیره شدند. مراحل اندازه‌گیری نسبت مورد استفاده در شکل ۲ نشان داده شده است.



شکل ۲ الف) نقطه تاب، ب) نقطه مماس روی میز، و ج) نقطه چپ

۲-۲- آماده‌سازی شبکه عمیق جهت تشخیص تاب

پس از دسته‌بندی داده‌ها، از الگوریتم‌های یادگیری عمیق موجود در کتابخانه‌های تانسورفلوو کراس برای تشخیص عیب استفاده شد. لایه‌های مدل به صورت متوالی انتخاب شدند. برای این پروژه، سه نوع شبکه مورد آزمایش قرار گرفت و در نهایت، مدل نهایی که دقت خوبی از خود نشان داد، شامل شش لایه کانولوشن^۱، سه لایه مکس پولینگ^۲، چهار لایه متراکم، یک لایه مسطح^۳ و سه لایه حذفی^۴ بود (شکل ۳).

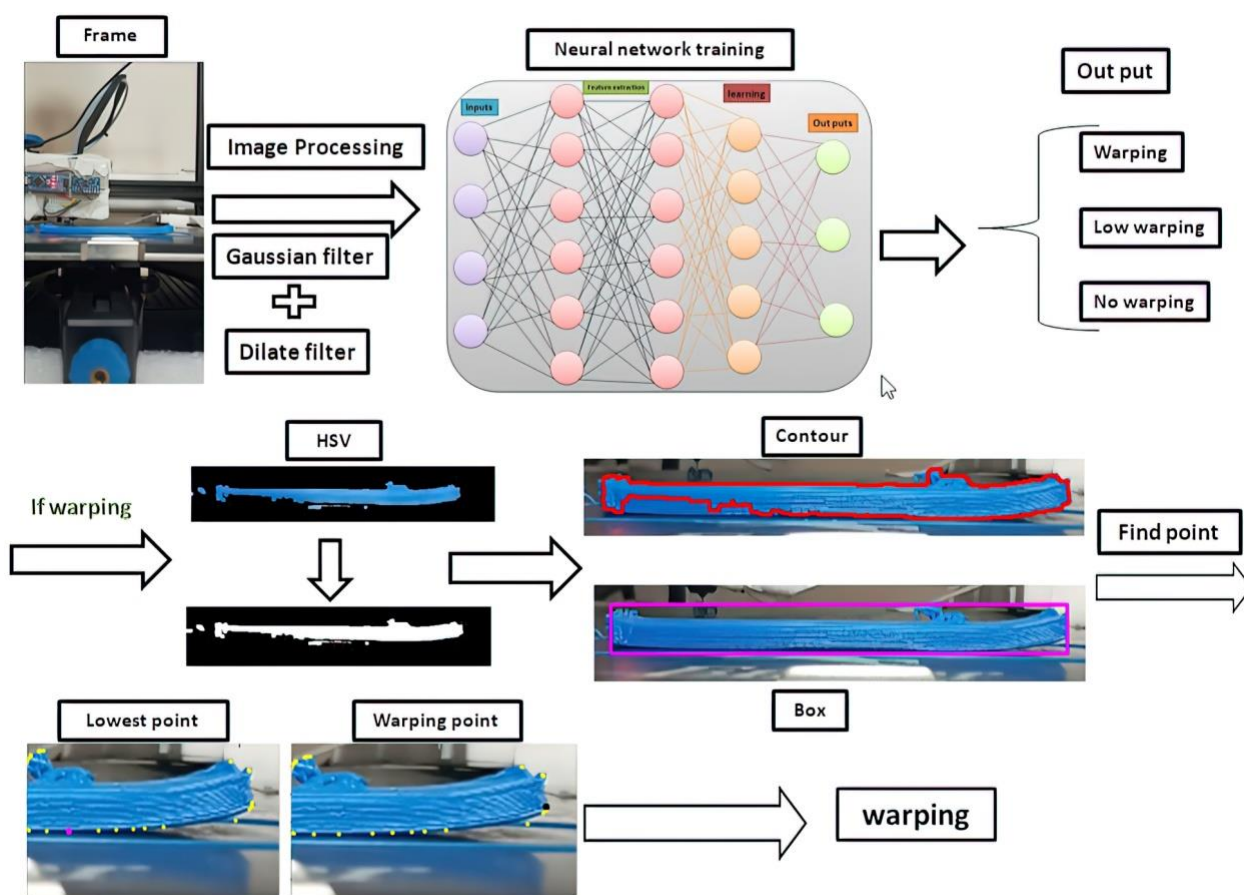


شکل ۳ ترسیم لایه‌های شبکه اولیه

1 Convolutional Layers
2 Max-pooling
3 Flattening Layer
4 Dropout Layers

برای بهبود و توسعه شبکه، مدل شبکه عصبی طراحی شده به مدل شبکه‌های عصبی استاندارد تغییر یافت. به گزارش سایت کراس، یکی از بهترین شبکه‌ها برای طبقه‌بندی، شبکه «اکسپشن»^۱ است. در صورتی که عیب تاب توسط این شبکه به درستی تشخیص داده شود، باید قطعه در هر تصویرشناسایی شده و مقدار تاب آن گزارش گردد. برای این منظور، در ابتدا از روش‌های سنتی بینایی ماشین به خاطر سرعت بالایشان استفاده شد. قبل از هرگونه اقدامی باید پردازش‌هایی روی تصویر انجام شود تا اعوجاجات و نویزهای آن گرفته شود. به طور معمول برای یافتن مرز یک قطعه، پس از اعمال فیلتر روی تصویر اصلی، تصویر را سیاه و سفید کرده و سپس آن را به فضای باینری تبدیل می‌کنند. در صورت نیاز، فیلترهایی روی این فضا اعمال شده و لبه‌ها با استفاده از الگوریتم تشخیص لبه کارآمد کنی^۲ پیدا می‌شوند. در این پروژه، علاوه بر الگوریتم کنی، از تبدیل هاف، تبدیل اسپیلاین، الگوریتم داگلاس-پوکر و فضای رنگی اچ‌اس‌وی^۳ استفاده گردید. پس از تشخیص ماسک قطعه توسط هر یک از الگوریتم‌های ذکر شده، جهت اندازه‌گیری مقدار تاب، قسمت تاب قطعه از تصویر جدا شده و به طور کامل شناسایی می‌گردد. برای برش قسمت تاب، می‌بایست مختصات قطعه را بدست آورد تا با استفاده از این مختصات، منطقه تاب بریده شود. در این زمینه الگوریتم ConvexHull مورد استفاده قرار گرفت که با استفاده از آن می‌توان به صورت محدب، کانتور شکل را شناسایی نموده و نقاط کلیدی آن را رسم کرد و اندازه‌گیری را انجام داد.

پس از یافتن مقدار تاب برحسب پیکسل، باید مرجعی را در تصویر پیدا نمود تا اندازه حقیقی و پیکسلی آن حساب شود و در نتیجه مقدار حقیقی تاب بر اساس مرجع بدست آید. در این آزمایش، دو مرجع در نظر گرفته شد: یک مرجع لبه میز و دیگری پیچ اسپیسر میز. دلیل انتخاب این دو قسمت، قرار داشتن این دو نقطه روی میز متحرک است تا بتوان در هر فریم، مقیاس مناسبی به دست آورد. شکل ۴ خلاصه‌ای از مراحل انجام شده را به تصویر می‌کشد.



شکل ۴ نمودار مراحل روش متمرکز سنتی

¹ Xception

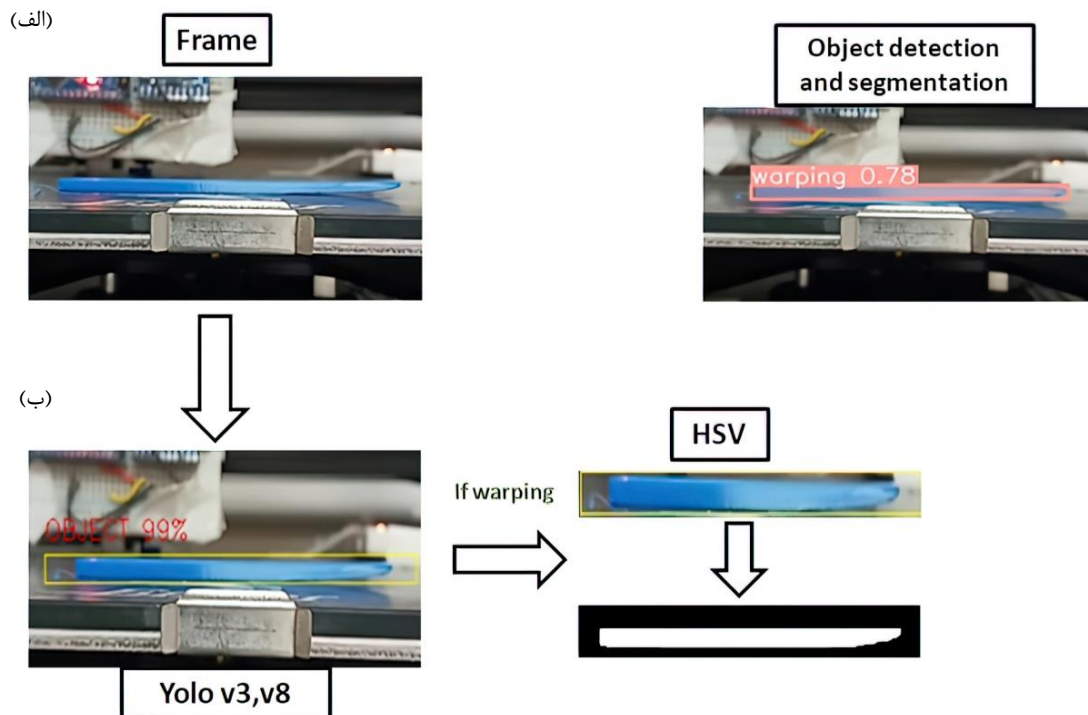
² Canny

³ Hue, Saturation, and Value color model

۲-۳- استفاده از الگوریتم یولو

در ادامه به جای استفاده از شبکه‌های عصبی، از روش تشخیص اشیا برای دسته‌بندی استفاده شد. برای تشخیص اشیا روش‌های گوناگونی وجود دارد که می‌توان از میان آن‌ها به ماسک آرسی‌ان‌ان^۱، فسترآرسی‌ان‌ان^۲، موبایل‌نت^۳ و غیره اشاره نمود؛ هرچند امروزه یکی از بهترین و سریع‌ترین روش‌ها، استفاده از شبکه‌های یولو^۴ است که نسخه‌های مختلفی از آن تولید شده است. در این پروژه نیز از این الگوریتم بهره برده شد. ابتدا تشخیص قطعه دارای عیب توسط یولو نسخه ۳ صورت پذیرفت و سپس ماسک قطعه با استفاده از فضای رنگی اچ‌اس‌وی ایجاد گردید و در نهایت مقدار تاب اندازه‌گیری شد (شکل ۵-الف).

جهت بهبود و توسعه فرایند تشخیص ماسک قطعه، این عمل به وسیله هوش مصنوعی نیز انجام شد. برای این کار از یولو نسخه ۸، به دلیل سرعت و دقت بالای آن، استفاده گردید. یولو نسخه ۸ دارای پنج مدل است که عبارت‌اند از: نانو^۵، کوچک^۶، متوسط^۷، بزرگ^۸ و خیلی بزرگ^۹. با سنگین‌تر شدن شبکه، دقت افزایش و سرعت کاهش می‌یابد. در این پروژه، برای افزایش سرعت و استفاده روی سی‌پی‌یو به جای جی‌پی‌یو که نیاز به سخت افزار قوی دارد، از نسخه نانو استفاده گردید. بنابراین، برای تشخیص قطعه از یولونسخه ۳ بهره گرفته شد و برای تشخیص ماسک، به جای محیط رنگی اچ‌اس‌وی، از یولونسخه ۸ مدل نانو استفاده گردید. در نهایت، جهت هوشمندسازی کامل، تشخیص و ساخت ماسک قطعه توسط یولو نسخه ۸ انجام گردید (شکل ۵-ب).



شکل ۵ الف) تشخیص ماسک با تغییر فضای رنگی، و ب) تشخیص ماسک با استفاده از یولو

با نگاه به امکان پیاده‌سازی ساده، با استفاده از کتابخانه استریم‌لایت یک برنامه تحت وب طراحی شد که به وسیله آن می‌توان روی شبکه داخلی محل مورد استفاده، با استفاده از گوشی هوشمند، تاب را تشخیص داده و مقدار آن را مشاهده کرد. البته این برنامه

1 RCNN
2 FRCNN
3 MOBILENET
4 YOLO
5 NANO
6 SMAL
7 MEDIUM
8 LARGE
9 XLARGE

می‌تواند روی فضای ابری نیز قرار داده شود و از راه دور نیز به محلی که پرینتر سه بعدی قرار دارد، اتصال پیدا کند و تمام فرایند به صورت برخط صورت پذیرد. جزئیات بیشتر در مورد این پیاده‌سازی در بخش بعدی ارائه شده است.

۳- نتایج و بحث

در این بخش ابتدا نتایج مربوط به تشخیص عیب تاب به روش‌های سنتی ارائه شده و میزان آن مورد اندازه‌گیری قرار می‌گیرد. شبکه یادگیری عمیق استفاده شده برای طبقه‌بندی اولیه در این روش با در نظر گرفتن ۸۰ درصد داده‌ها برای آموزش و ۲۰ درصد برای آزمایش شبکه، به دقت حدود ۹۳ رسید. هنگامی به جای شبکه آموزش‌یافته، از مدل قبلی از شبکه‌ی استاندارد اکسپشن استفاده شد، دقت آن تا حدود ۹۷ درصد افزایش یافت. از شبکه‌های دیگری مانند موبایل‌نت، رزنت و وی‌جی‌جی نیز استفاده شد، ولی همچنان بهترین نتیجه با شبکه اکسپشن بدست آمد. در نتیجه، با استانداردسازی شبکه، دقت تشخیص نیز ۴ درصد افزایش یافت که نتیجه مطلوب‌تری است. برای تعداد ۲۰ بار یادگیری^۱ و با تعداد نمونه‌های^۲ ۱۶ عدد، مقایسه چند شبکه مورد آزمایش در جدول ۲ آمده است و همانطور که مشاهده می‌شود، شبکه اکسپشن بالاترین دقت را به خود اختصاص داده است و پس از آن دو شبکه رزنت ۵۰ و موبایل‌نت قرار دارند.

جدول ۲ مقایسه نتایج شبکه‌های استفاده شده برای طبقه‌بندی

نوع شبکه	دقت (%)
Xception	97.345
ResNet50	94.690
ResNet50V2	67.25
MobileNet	94.690
MobileNetV2	87.611
VGG19	57.22
VGG16	57.522


جهت اندازه‌گیری میزان تاب، باید مرز قطعه شناسایی می‌شد که برای این منظور از الگوریتم‌های متعددی استفاده شد. تلاش شد با استفاده از تبدیل هاف، مرز قطعه شناسایی شود، اما با توجه به اینکه فرم تاب از معادله مشخصی تبعیت نمی‌کرد، این روش نتوانست مرز قطعه را تشخیص دهد. در ادامه، از الگوریتم داگلاس-پوکر استفاده شد که با حذف تعداد نقاط اضافی، شکل اصلی قطعه را پیدا کند، اما به دلیل وجود خطوط بسیار، موفق عمل نکرد. الگوریتم کنی نیز خطوط اطراف قطعه را تشخیص می‌داد، اما گاهی خطوط خود قطعه در تصویر حذف شده و سایر خطوط نزدیک قطعه شناسایی می‌شد و علی‌رغم تغییرات متعدد در آستانه‌های الگوریتم کنی و تغییر فیلترهای مختلف، این الگوریتم نتوانست مرز قطعه را شناسایی نماید (شکل ۶).

در نهایت، از فضای رنگی اچ‌اس‌وی بهره برداری شد، چرا که رنگ آبی قطعه برای یافتن آن در تصویر بسیار کمک کننده بود. با تبدیل هر فریم به فضای رنگی اچ‌اس‌وی و تنظیم سه پارامتر اصلی این محیط، نتیجه مطلوبی بدست آمد و این روش در مقایسه با روش کنی موفقیت چشم‌گیری داشت. پارامتر روشنایی (V) فضای اچ‌اس‌وی در کل تصویر روی ۲۴۰ تنظیم شد و سپس با استفاده از حد آستانه پایین [۰-۱۱۰-۸۰] و حد آستانه بالای [۲۵۵-۲۵۵-۱۷۹]، ماسک قطعه به خوبی تشخیص داده شد. بعد از یافتن ماسک مناسب، کانتور قطعه شناسایی گردید. همچنین از آنجایی که فقط کانتور قطعه مهم است و بزرگ‌ترین کانتور نیز در ماسک می‌باشد، کانتور قطعه شناسایی و رسم می‌گردد. هنگامی که کانتور قطعه پیدا شد، کادر اطراف آن رسم و نشان داده می‌شود (شکل ۷). همچنین جدول ۳ خلاصه‌ای از روش‌های انجام شده برای تشخیص ماسک و نتیجه مربوطه را ارائه می‌دهد.


با استفاده از الگوریتم ConvexHull، نقاط کلیدی کانتور قطعه پیدا شد. پایین‌ترین نقطه کانتور قطعه که روی میز قرار دارد و راست‌ترین نقطه که نزدیک‌ترین نقطه به لبه تاب است، انتخاب شده و اختلاف ارتفاع پیکسلی این دو نقطه، مقدار تاب مد نظر را نشان می‌دهد. به طور تجربی اثبات شد که دو نقطه بعد از راست‌ترین نقطه، لبه تاب می‌باشد (شکل ۸).

¹ Epochs

² Batch Size




شکل ۶ دو نمونه از اعمال آستانه‌های مختلف با الگوریتم کنی



شکل ۷ فرایند یافتن قطعه: (الف) یافتن ماسک، (ب) یافتن مرز قطعه، و (ج) مشخص کردن قطعه

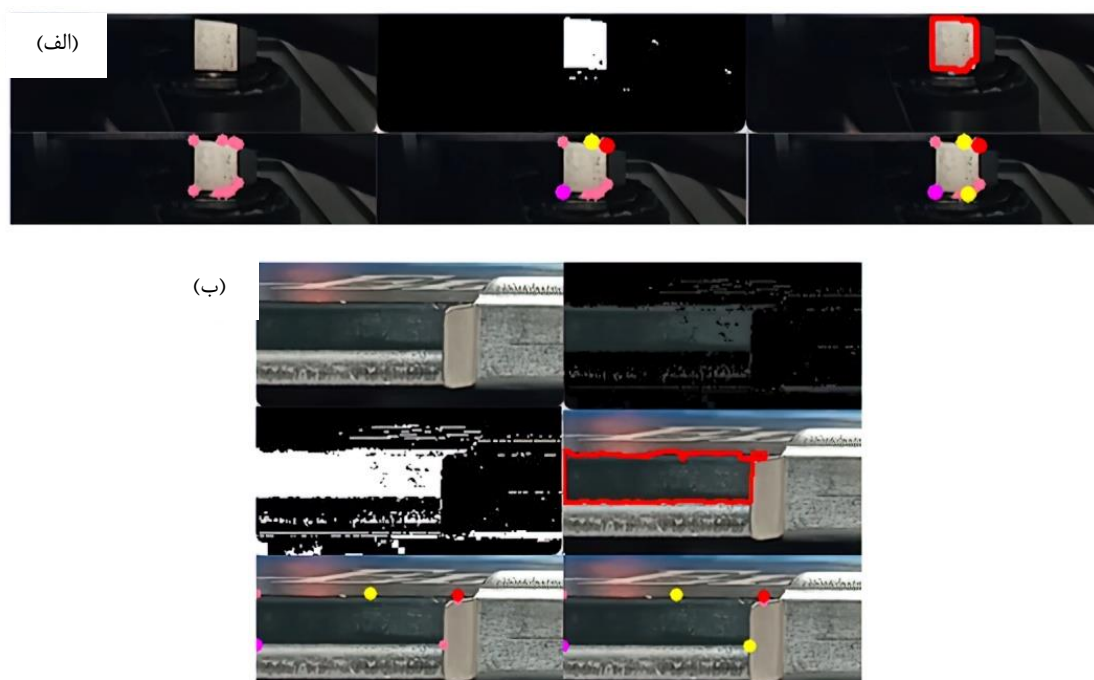
جدول ۳ خلاصه‌ای از روش‌های انجام شده برای تشخیص ماسک و نتایج آن

نتایج	روش
عدم یافتن منحنی پارامتریک	تبدیل هاف
عدم یافتن قطعه	الگوریتم کنی
نیاز به یافتن مکان قطعه	منحنی اسپیلاین
عدم یافتن لبه تاب	الگوریتم داگلاس-پوکر
موفق	فضای رنگی HSV



شکل ۸ ترتیب یافتن نقطه تاب و نقطه مماس بر میز

پیچ اسپیسر^۱ به عرض ۲ سانتی‌متر به عنوان مرجع اول و لبه میز به عنوان مرجع دوم انتخاب شدند. تمام مراحل که برای شناسایی ماسک قطعه لازم است، در اینجا نیز انجام شد؛ با این تفاوت که در این قسمت مقیاس رنگ تغییر کرده و به جای نقطه سمت راست، نقطه بالا انتخاب شده است. مقیاس بندی طبق کانتور بدست آمده - که همان کانتور پیچ اسپیسر یا لبه میز است - انجام می‌گیرد. برای یافتن پیچ، از حد آستانه پایین [۸۰-۱۰۰] و حد آستانه بالای [۲۵۵-۵۰-۱۸۰] استفاده شد که نتیجه مطلوب شکل ۹- الف ایجاد شد. همچنین با تنظیم حد آستانه پایین [۵-۱۰-۱۰] و حد آستانه بالای [۸۰-۱۰۰-۱۰۰]، لبه میز شناسایی شده و اندازه‌ی آن بر حسب پیکسل بدست می‌آید که نتیجه آن در شکل ۹- ب قابل مشاهده می‌باشد. همانطور که پیش‌تر اشاره شد، با توجه به تغییرات مختلف و مداوم تصویر، اندازه‌گیری دچار خطا می‌باشد. به طور میانگین، مقدار تاب در پنج تصویر به عنوان نمونه با مرجع‌دهی لبه میز، برابر با ۱,۹۲ میلی‌متر و در مورد مرجع با پیچ، برابر با ۱,۸۸ میلی‌متر می‌باشد. اختلاف این دو اندازه‌گیری با مرجع متفاوت برابر با ۰,۰۴ است که اختلاف اندکی محسوب می‌شود. از طرفی، در این قسمت نیز فضای رنگی اچ‌اس‌وی بسیار موفق عمل نمود. این فرایند برای تمامی فیلم‌ها انجام شد.




شکل ۹ فرایند شناسایی نقاط بالایی و پایینی جهت اندازه‌گیری در الف) پیچ اسپیسر، و ب) لبه میز


علی‌رغم موفقیت نسبی این روش، ولی همچنان این روش روی تمام فیلم‌های موجود پاسخگو نبوده و در برخی از آن‌ها، قطعه را تشخیص نداد، یا مشکلاتی در تشخیص آن به وجود آمد. در روش فوق، تمرکز بر روی رنگ بوده و اگر رنگ تغییر کند، باید پارامترهای مربوط به فضای رنگی اچ‌اس‌وی نیز تغییر کند. حتی ممکن است رنگ قطعه با بعضی از قسمت‌های دستگاه هم‌رنگ باشد و در فرایند تشخیص اختلال ایجاد کند. به عنوان مثال، چنانچه قطعه سیاه رنگ باشد، تشخیص آن دشوار خواهد شد، زیرا میز نیز به رنگ سیاه است. در ادامه، نتایج مربوط به الگوریتم‌های یولو نسخه ۳ و یولو نسخه ۸ ارائه می‌شود. ابتدا تشخیص قطعه توسط الگوریتم یولو نسخه ۳ تائینی انجام شد و سپس مراحل که برای تشخیص قطعه از روش سنتی استفاده شده بود، روی مختصاتی که یولو تشخیص داده است، پیاده‌سازی گردید (شکل ۱۰).

این روش به نتایج نسبتاً خوبی دست یافت. یولو نسخه ۳ تائینی با دقت و سرعت بالایی قطعه را شناسایی می‌کرد، با این حال همچنان مشکلاتی در تشخیص ماسک قطعه وجود داشت و در برخی از فیلم‌ها تشخیص ماسک به درستی انجام نشد. همین امر سبب شد تا جهت ایجاد ماسک نیز از یولو نسخه ۸ استفاده شود (شکل‌های ۱۱ و ۱۲).

¹ Spacer Screw



شکل ۱۰ ایجاد ماسک به وسیله شبکه یولو نسخه ۳



شکل ۱۱ ایجاد ماسک به وسیله شبکه یولو نسخه ۸



شکل ۱۲ ایجاد کانتور به وسیله شبکه یولو نسخه ۸

برای آموزش شبکه، همان دسته‌بندی شبکه‌های قبلی استفاده شد و در فرایند آموزش، از تکنیک افزایش داده با برعکس کردن تصاویر^۱ نیز استفاده شد تا عیب در هر جهتی تشخیص داده شود. در این مرحله از آموزش، دقت شبکه به ۹۹ درصد روی آستانه^۲ ۰,۵ و میانگین دقت ۰,۷۸ روی آستانه ۰,۵ تا ۰,۹۵ رسید. در ادامه، نتیجه آموزش یولو نسخه ۸ نانو در جدول ۴ آورده شده است. شایان ذکر است که شبکه بادسته‌بندی جدیدی شامل نقص راست، نقص چپ، نقص جزئی راست و نقص جزئی چپ نیز آموزش داده شد. بخشی از داده‌های این دسته بندی جدید به صورت مصنوعیت ولید شده است. نتیجه آموزش روی این داده‌های جدید، دقت ۷۵ درصد بود که نشان می‌دهد داده‌های مصنوعی دقت شبکه را کاهش می‌دهد. این ممکن است به دلیل شباهت زیاد بین داده‌های مصنوعی و داده‌های اصلی باشد، در حالیکه در دسته بندی اولیه، دقت بالا بوده و همه داده‌ها به طور طبیعی تولید شده‌اند، در نتیجه داده‌های مصنوعی از دسته‌بندی حذف گردید. همچنین در برخی از دسته بندی‌ها، وجود تاب در دو طرف قطعه نیز اعمال شد که به دلیل رنگ‌های مختلف، دقت را به میزان قابل توجهی کاهش داد. برای رفع این مشکل، لازم بود شبکه با رنگ‌های متنوع آموزش داده شود.

¹ Flip

² Iou

جدول ۴ نتیجه آموزش یولو نسخه ۸ نانو

Images	Instances	Box	R	Map50	Map50-95	mask	R	Map50	Map50-95	دسته‌بندی
213	213	0.966	0.982	0.991	0.806	0.966	0.982	0.991	0.709	تمام داده‌ها
213	135	0.97	0.985	0.992	0.812	0.97	0.985	0.992	0.789	تاب
213	78	0.962	0.98	0.99	0.8	0.962	0.98	0.99	0.63	تاب کم

پس از همگام‌سازی مراحل، تمامی فرایندهای تشخیص و ایجاد ماسک به صورت هوشمند انجام شد. ولی اندازه‌گیری میزان عیب به روش‌های سنتی صورت گرفت؛ ماسک انتخابی مشخص گردید و نقاط شناسایی‌شده، مشابه مراحل قبلی، اندازه‌گیری شدند. با بهره‌گیری از YOLOv8، مشکلات موجود در مراحل پیشین به طور مؤثری برطرف شد. تشخیص قطعه و ایجاد ماسک آن توسط YOLO انجام گرفت و با استفاده از کتابخانه OpenCV، کانتور قطعه رسم و نقاط مورد نیاز برای اندازه‌گیری عیب تاب شناسایی شدند. با این وجود، دقت روش تنها با استفاده از YOLOv8 نسبت به ترکیب همزمان نسخه‌های YOLOv3 و YOLOv8 کمتر بود. افزایش حجم داده‌های آموزشی می‌تواند دقت این شبکه را به شکل قابل توجهی بهبود بخشد. از آنجا که یکی از اهداف اصلی این پژوهش، استفاده از تجهیزات ساده و مقرون به صرفه برای پایش فرایند است، از نسخه بزرگ YOLOv8 که نیاز به GPU قدرتمند دارد، استفاده نشد. این رویکرد امکان طراحی سیستمی ساده، در دسترس و کاربردی را برای تشخیص بلادرنگ عیوب فراهم می‌آورد. جدول ۵ مقایسه‌ای از عملکرد رویکردهای مبتنی بر هوش مصنوعی و سنتی را بر مبنای برخی از پارامترها ارائه می‌دهد.

جدول ۵ مقایسه روش هوشمند و سنتی

روش سنتی	روش هوشمند	پارامتر
موفق	روی ورژن نانو با استفاده از GPU	سرعت بالا
فقط در شرایط تنظیم شده	وابسته به داده‌ها و پارامترهای آموزش	دقت بالا
ناموفق	وابسته به داده‌های آموزش	مقاومت در برابر تغییر شرایط
به سختی	دارای قابلیت بالقوه	قابلیت توسعه
موفقیت نسبی	موفق	ایجاد ماسک در فیلم‌ها

۳-۱- ایجاد برنامه تحت وب

یک برنامه کاربردی با استفاده از کتابخانه Streamlit و زبان برنامه‌نویسی HTML طراحی شد تا پژوهش انجام‌شده را هرچه بیشتر به عمل نزدیک کند. این برنامه شامل یک صفحه ورود است که با فشردن دکمه "شروع"، صفحه فرایند را فراخوانی می‌کند. برنامه از چهار بخش اصلی تشکیل شده است که امکان دریافت تصویر به روش‌های مختلف، پردازش آن، و نمایش نتایج را فراهم می‌سازد.

در بخش اول (شکل ۱۳-الف)، با نصب نرم‌افزار IPWebcam بر روی گوشی همراه، یک آدرس آی‌پی تولید می‌شود که به عنوان ورودی به نرم‌افزار داده شده و به پسوند ویدیو اضافه می‌گردد. با وارد کردن این آی‌پی و فشردن دکمه "تشخیص"، تصاویر از طریق OpenCV خوانده شده و پردازش‌ها روی آن‌ها انجام می‌گیرد. IPWebcam یک نرم‌افزار است که گوشی همراه را به یک وب‌کم تبدیل می‌کند و امکان تنظیمات مختلفی نظیر انتخاب دوربین (جلو یا پشت)، تنظیم نور، کیفیت و ابعاد را فراهم می‌آورد.

در بخش دوم (شکل ۱۳-ب)، کاربر می‌تواند یک فایل ویدیویی را بارگذاری کرده و پردازش را به صورت آفلاین انجام دهد. این قابلیت برای تحلیل داده‌های از پیش ضبط‌شده بسیار مناسب است.

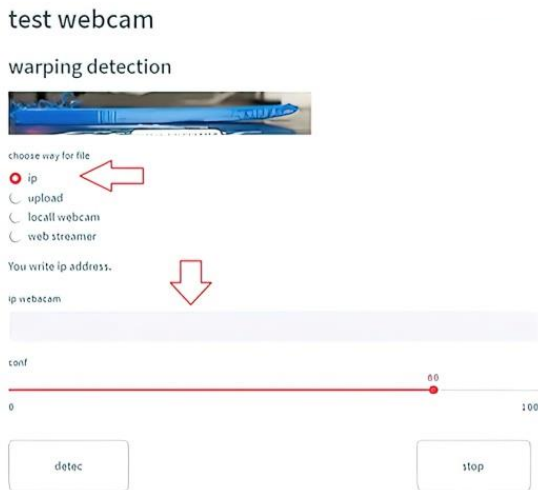
در بخش سوم (شکل ۱۴)، اتصال به دوربین‌های نصب‌شده روی پرینتر سه‌بعدی از طریق رایانه مرکزی انجام می‌شود. تصاویر توسط این دوربین‌ها ضبط و پردازش شده و نتایج بلادرنگ روی گوشی یا هر دستگاه دیگر نمایش داده می‌شود. شماره دوربین‌ها از رقم صفر شروع می‌شود و انتخاب آن‌ها توسط کاربر امکان‌پذیر است.

بخش چهارم (شکل ۱۴) شامل استفاده از دستور WebStreamer است که سرعت بالاتری در خواندن تصاویر و انجام پردازش‌ها نسبت به روش‌های دیگر دارد. با انتخاب این گزینه، کاربر به صفحه‌ای جدید هدایت می‌شود که می‌تواند دوربین مدنظر را انتخاب کرده

و با فشردن دکمه "شروع"، فرایند پردازش را آغاز کند. در این بخش، محاسبات به طور کامل روی رایانه مرکزی انجام شده و تنها تصاویر ارسال و نتایج در دستگاه کاربر مشاهده می‌شوند. در این برنامه، یک نوار پیشرفت نیز تعبیه شده است که درصد موفقیت در تشخیص عیب را به صورت بلادرنگ نمایش می‌دهد (شکل ۱۴-ب). این ویژگی به همراه طراحی ساده و رابط کاربری کاربرپسند، کارایی برنامه را برای نظارت بر فرایند تولید و شناسایی عیوب افزایش داده است.

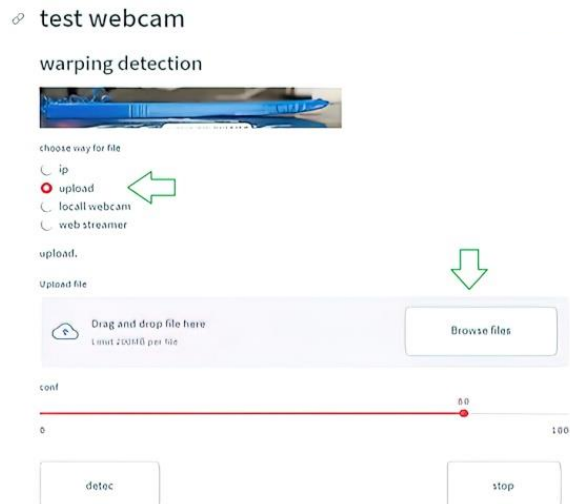
in the name of god

(الف)



in the name of god

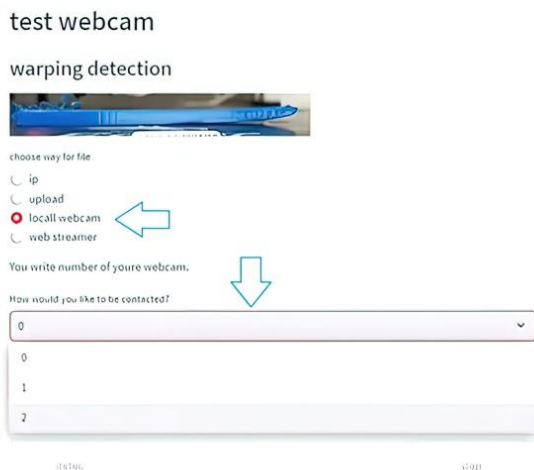
(ب)



شکل ۱۳ قسمت‌های نرم‌افزار طراحی شده: (الف) استفاده از آدرس دوربین از راه دور، و (ب) بارگذاری فیلم به صورت آفلاین

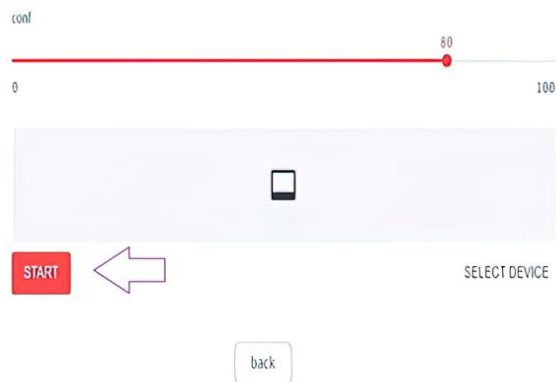
in the name of god

(الف)



webrtc_streamer

(ب)



شکل ۱۴ قسمت‌های نرم‌افزار طراحی شده: (الف) استفاده از دوربین موجود، و (ب) وب‌استریم

۴- نتیجه‌گیری

این مقاله سیستمی کاربردی را برای تشخیص بصری عیوب به صورت برخط در ماشین‌های ساخت افزایشی FDM پیشنهاد می‌دهد. هدف اصلی، دستیابی به روشی قابل اعتماد برای تشخیص و اندازه‌گیری عیب تاب از طریق ترکیب روش‌های هوشمند و سنتی بود. در این راستا، ۲۷ ویدیو تهیه شد و از هر ویدیو حدود ۵۸۰۰۰ تصویر تولید و برای آموزش شبکه استفاده گردید. با آموزش شبکه‌های

دسته‌بندی، دقت تشخیص اولیه حدود ۹۳ درصد و با استفاده از شبکه‌های پیشرفته‌تر، دقت نهایی به ۹۷ درصد رسید. نتایج نشان داد که روش سنتی، هر چند سرعت و دقت مناسبی دارد، اما برای همه شرایط قابل استفاده نیست و نیازمند تنظیم مداوم پارامترها برای شرایط جدید است. از سوی دیگر، روش‌های هوشمند انعطاف‌پذیری بیشتری داشته و به دلیل وابستگی به داده‌های آموزشی، توانایی تطبیق با شرایط مختلف را دارند. با این حال، همچنان مشکلاتی از نظر سرعت و برخی خطاهای جزئی وجود دارد که نیازمند بهبود است. با افزایش داده‌های آموزشی، می‌توان عملکرد سیستم را به حد مطلوب‌تری رساند. در پژوهش حاضر، دقت شبکه در آستانه ۰,۵ به ۹۹ درصد و میانگین دقت در آستانه ۰,۵ تا ۰,۹۵ به ۰,۷۸ رسید.

نتایج این تحقیق نشان می‌دهد که روش‌های هوشمند، نه تنها امیدوارکننده‌تر از روش‌های سنتی هستند، بلکه می‌توانند نقش مهمی در اتوماسیون تولید ایفا کرده و با شرایط مختلف صنعتی سازگار شوند. علاوه بر این، فرایند طراحی شده در این پژوهش، پتانسیل استفاده برای تشخیص هر نوع عیبی که قابل مشاهده باشد را دارد. برای افزایش کاربرد پذیری و تسهیل استفاده از این فرایند، یک برنامه تحت وب طراحی و پیاده‌سازی شد که امکان اجرای آن در محیط‌های آزمایشگاهی و صنعتی را فراهم می‌کند. این رویکرد، گامی مؤثر در جهت هوشمندسازی فرایندهای تولید و نظارت صنعتی به شمار می‌آید.

References

- [1] Tzampazaki M, Zografos C, Vrochidou E, Papakostas GA. Machine Vision—Moving from Industry 4.0 to Industry 5.0. *Applied Sciences*. 2024 Feb 11;14(4):1471. doi: [10.3390/app14041471](https://doi.org/10.3390/app14041471)
- [2] Scheffel RM, Fröhlich AA, Silvestri M. Automated fault detection for additive manufacturing using vibration sensors. *International Journal of Computer Integrated Manufacturing*. 2021 May 4;34(5):500–14. doi: [10.1080/0951192X.2021.19013](https://doi.org/10.1080/0951192X.2021.19013)
- [3] Lu L, Zheng J, Mishra S. A model-based layer-to-layer control algorithm for ink-jet 3d printing. In *Dynamic systems and control conference 2014 Oct 22 (Vol. 46193, p. V002T35A001)*. American Society of Mechanical Engineers. doi: [10.1115/DSCC2014-5914](https://doi.org/10.1115/DSCC2014-5914)
- [4] Wu H, Wang Y, Yu Z. In situ monitoring of FDM machine condition via acoustic emission. *International Journal of Advanced Manufacturing Technology*. 2015 Sep 17. doi: [10.1007/s00170-015-7809-4](https://doi.org/10.1007/s00170-015-7809-4)
- [5] Zhang S, Sun Z, Long J, Li C, Bai Y. Dynamic condition monitoring for 3D printers by using error fusion of multiple sparse auto-encoders. *Computers in Industry*. 2019 Feb 105:164–76. doi: [10.1016/j.compind.2018.12.004](https://doi.org/10.1016/j.compind.2018.12.004)
- [6] Meng L, McWilliams B, Jarosinski W, Park HY, Jung YG, Lee J, et al. Machine Learning in Additive Manufacturing: A Review. *Journal of The Minerals, Metals & Materials Society*. 2020 Jun 1;72(6):2363–77. doi: [10.1007/s11837-020-04155-y](https://doi.org/10.1007/s11837-020-04155-y)
- [7] Nuchitprasitchai S, Roggemann M, Pearce J. Three Hundred and Sixty Degree Real-Time Monitoring of 3-D Printing Using Computer Analysis of Two Camera Views. *Journal of Manufacturing and Materials Processing*. 2017 Jul 4;1(1):2. doi: [10.3390/jmmp1010002](https://doi.org/10.3390/jmmp1010002)
- [8] Fang T, Bakhadyrov I, Jafari MA, Alpan G. Online detection of defects in layered manufacturing. In *Proceedings. 1998 IEEE international conference on robotics and automation (Cat. No. 98CH36146) 1998 May 20 (Vol. 1, pp. 254-259)*. IEEE. doi: [10.1109/ROBOT.1998.676386](https://doi.org/10.1109/ROBOT.1998.676386)
- [9] Liu C, Law ACC, Roberson D, Kong Z (James). Image analysis-based closed loop quality control for additive manufacturing with fused filament fabrication. *Journal of Manufacturing Systems*. 2019 Apr 51:75–86. doi: [10.1016/j.jmsy.2019.04.002](https://doi.org/10.1016/j.jmsy.2019.04.002)
- [10] Wu H, Yu Z, Wang Y. A new approach for online monitoring of additive manufacturing based on acoustic emission. In *International Manufacturing Science and Engineering Conference 2016 Jun 27 (Vol. 49910, p. V003T08A013)*. American Society of Mechanical Engineers. doi: [10.1115/MSEC2016-8551](https://doi.org/10.1115/MSEC2016-8551)
- [11] Shevchik SA, Masinelli G, Kenel C, Leinenbach C, Wasmer K. Deep Learning for In Situ and Real-Time Quality Monitoring in Additive Manufacturing Using Acoustic Emission. *Institute of Electrical and Electronics Engineers Transactions on Industrial Informatics*. 2019 Sep 15(9):5194–203. doi: [10.1109/TII.2019.2910524](https://doi.org/10.1109/TII.2019.2910524)
- [12] Liu C, Le Roux L, Ji Z, Kerfriden P, Lacan F, Bigot S. Machine Learning-enabled feedback loops for metal powder bed fusion additive manufacturing. *Procedia Computer Science*. 2020 Jan 1;176:2586–95. doi: [10.1016/j.procs.2020.09.314](https://doi.org/10.1016/j.procs.2020.09.314)
- [13] Li Y, Zhao W, Li Q, Wang T, Wang G. In-Situ Monitoring and Diagnosing for Fused Filament Fabrication Process Based on Vibration Sensors. *Sensors*. 2019 Jun 6;19(11):2589. doi: [10.3390/s19112589](https://doi.org/10.3390/s19112589)
- [14] Wang Y, Huang J, Wang Y, Feng S, Peng T, Yang H, et al. A CNN-Based Adaptive Surface Monitoring System for Fused Deposition Modeling. *Institute of Electrical and Electronics Engineers/American Society of*

- Mechanical Engineers Transactions on Mechatronics. 2020 Oct 25(5):2287-96. doi: [10.1109/TMECH.2020.2996223](https://doi.org/10.1109/TMECH.2020.2996223)
- [15] Karna NB, Putra MA, Rachmawati SM, Abisado M, Sampedro GA. Toward accurate fused deposition modeling 3d printer fault detection using improved YOLOv8 with hyperparameter optimization. IEEE Access. 2023 Jul 7;11:74251-62. doi: [10.1109/ACCESS.2023.3293056](https://doi.org/10.1109/ACCESS.2023.3293056)
- [16] Lu L, Hou J, Yuan S, Yao X, Li Y, Zhu J. Deep learning-assisted real-time defect detection and closed-loop adjustment for additive manufacturing of continuous fiber-reinforced polymer composites. Robotics and Computer-Integrated Manufacturing. 2023 Feb 1;79:102431. doi: [10.1016/j.rcim.2022.102431](https://doi.org/10.1016/j.rcim.2022.102431)
- [17] Siahvashi A, Shahbazi M, Niknam SA. The use of a neuro-fuzzy network coupled with meta-heuristic learning methods to predict surface roughness in the machining of aluminum alloys. Iranian Journal of Manufacturing Engineering. 2024 Jan 21;10(11):49-60. doi: [10.22034/IJME.2024.412021.1816](https://doi.org/10.22034/IJME.2024.412021.1816) [In Persian]
- [18] Mohammadi N, Nategh MJ. Development an advanced neural network for recognition of machining feature. Iranian Journal of Manufacturing Engineering. 2022 Jul 23;9(5):1-2. doi: [10.22034/IJME.2022.160054](https://doi.org/10.22034/IJME.2022.160054) [In Persian]