مجله مهندسی ساخت و تولید ایران، مرداد ۱۴۰۱، دوره ۹، شماره ۵، ص‌ص. ۱- ۱۲

ماهنامه علمی پژوهشی

مهندسی ساخت و تولید ایران

www.smeir.org

10.22034/IJME.2022.160054

تولید سامانه هوش مصنوعی پیشرفته برای شناسایی فیچرهای ماشین‌کاری

ناصر محمدی[۱]، محمد جواد ناطق[۲*]

۱- دانشجوی دکتری، دانشکده مهندسی مکانیک، دانشگاه تربیت مدرس، تهران، ایران

۲- استاد، دانشکده مهندسی مکانیک، دانشگاه تربیت مدرس، تهران، ایران

* تهران، صندوق پستی ۱۱۱-۱۴۱۱۵، nategh@modares.ac.ir

اطلاعات مقاله

مقاله پژوهشی کامل

دریافت: ۳۱ فروردین ۱۴۰۱

داوری اولیه: ۱۸ خرداد ۱۴۰۱

پذیرش: ۲۸ شهریور ۱۴۰۱

کلیدواژگان:

طرح‌ریزی فرایند به کمک کامپیوتر

فیچرهای ماشین‌کاری

یادگیری عمیق

شبکه‌های کانولوشنی

چکیده

در فرآیند تولید یک قطعه به کمک کامپیوتر، اطلاعات مورد نیاز ماشین‌آلات ساخت برای قطعه‌ایی که مدل طراحی آن مشخص شده است، ایجاد می‌شود. برای تهیه دستورالعمل‌های ماشین‌کاری قطعات، اطلاعات طراحی بر حسب الگویی به نام فیچر بیان می‌گردد. در این تحقیق با کمک روش یادگیری عمیق، یک سامانه هوش مصنوعی برای شناسایی فیچرهای ماشین‌کاری معرفی شده است. روش معرفی شده در این تحقیق با کمک شبکه‌های کانولوشنی دو بعدی در یادگیری عمیق تولید شده است و قادر به شناسایی فیچرهای ماشین‌کاری در تصویر یک قطعه‌کار می‌باشد. نوآوری این تحقیق علاوه بر معرفی یک روش قدرتمند کاربردی و جدید در شناسایی فیچرهای ماشین‌کاری در حوزه طرح‌ریزی فرایند به کمک کامپیوتر، شناسایی فیچرهایی است که در یک قطعه‌کار دارای تداخل هندسی می‌باشند که روش‌هایی قبلی شناسایی فیچرهای ماشین‌کاری قادر به حل این مشکل نبوده‌اند. همچنین بی نیازی از فایل‌های مختلف اطلاعات خروجی طراحی به کمک کامپیوتر و استفاده از تصویر یک قطعه‌کار برای شناسایی فیچرهای ماشین‌کاری از قابلیت‌های روش معرفی شده در این تحقیق می‌باشد. توانمندی دیگر سامانه تولید شده قابلیت شناسایی فیچرهای ماشین‌کاری با فرمت‌های مختلف تصویر از قبیل تصویر با خطوط مرزی، نمایش هندسه جامد، تصویر قطعه‌کار با متریال مختلف و نیز تصویر گرفته شده با دوربین‌های عکاسی معمولی از طریق دوربین تلفن همراه و غیره از قطعه‌کارهای مکانیکی می‌باشد. دقت تشخیص فیچرهای ماشین‌کاری در تصویر یک قطعه‌کار با استفاده از روش پیشنهادی ۸۸ درصد و خطای تشخیص ۰/۱ اندازه‌گیری شده است.

Development an advanced neural network for recognition of machining feature

Naser Mohammadi, Mohammad Javad Nategh*

Mechanical Engineering Department, Tarbiat Modares University, Tehran, Iran

* P.O.B. 14115-111Tehran, Iran, nategh@modares.ac.ir

Article Information

Original Research Paper

Received: 20 April 2022

First Decision: 8 June 2022

Accepted: 19 September 2022

Keywords:

Computer aided Process planning

Machining features

Deep learning

Convolutional neural networks

Abstract

In the process of producing a part with the help of computer aided manufacturing, the required information is created for the workpieces whose design model is specified. To prepare machining instructions, the design information is expressed in a pattern called a feature. In this research an advanced artificial intelligence system has been introduced to identify machining features with the help of deep learning method. The proposed method has been prepared with the help of two-dimensional convolutional networks in deep learning. It can identify machining features from the image of a workpiece. The innovations of this research, in addition to introducing a powerful practical and new method for automatic machining features recognition in the field of computer aided process planning, is identifying features that have geometric interference in a workpiece. The previous methods of automatic machining features recognitions have not been able to solve this problem. Furthermore, the lack of need for different CAD output files and the use of an image of a workpiece to identify machining features are the capabilities of the system introduced in this research. Other capabilities of the proposed method are the ability to identify machining features with different image formats such as image with wire frame format, constructive solid geometry format, image of workpiece with different materials and taken with ordinary cameras such as mobile cellphone camera and other imaging devices. The accuracy of detecting machining features in the image of a workpiece is measured %88 and detection error is measured 0.1 using proposed method.

۱- مقدمه

تولید یک قطعه مکانیکی از طراحی تا ساخت طی یک سلسله فرآیندهای به هم پیوسته صورت می‌گیرد که این فرآیندهای به‌هم پیوسته، هرکدام یک حوزه کاملاً تخصصی و گسترده است. استفاده از کامپیوتر در کلیه این فرآیندها همزمان با پیشرفت‌های شگرف کامپیوتر در کلیه زمینه‌ها، سبب تخصصی‌تر شدن هر یک از این مراحل در حوزه‌های تخصصی طراحی به

برای ارجاع به این مقاله از عبارت ذیل استفاده نمایید:

Please cite this article using:

N. Mohammadi, M. J. Nategh, Development an advanced neural network for recognition of machining feature, Iranian Journal of Manufacturing Engineering, Vol. 9, No. 5, pp. 1- 12, 2022 (in Persian). https://www.doi.org/10.22034/IJME.2022.160054

کمک کامپیوتر[1]، ساخت به کمک کامپیوتر[2] و طرح‌ریزی فرآیند به کمک کامپیوتر[3] شده است. در طرح‌ریزی فرآیند به کمک کامپیوتر چگونگی تولید یک قطعه مکانیکی مورد بررسی قرار می‌گیرد و اطلاعات مورد نیاز برای ساخت قطعه توسط ماشین‌آلات و تجهیزات حوزه ساخت به کمک کامپیوتر مهیا می‌گردد. در این مرحله، اطلاعات از مرحله طراحی به کمک کامپیوتر اخذ و اطلاعات مورد نیاز برای مرحله ساخت به کمک کامپیوتر تولید می‌شود، لذا به مرحله طرح‌ریزی فرآیند به کمک کامپیوتر پل بین مراحل طراحی و ساخت به کمک کامپیوتر گفته می‌شود. به دلیل استفاده وسیع از اصطلاح فیچر[4]، این کلمه دارای گستره وسیعی از معانی مختلف است و یک اجماع و تعریف عمومی از این اصطلاح در مجامع تحقیقی و علمی نمی‌توان یافت[۱]. فیچر در واقع به عملیات اجرایی مشخصی برای ساخت یک قطعه اطلاق می‌شود که ابزار و فرآیند مشخصی برای تولید آن استاندارد سازی شده است[۲]. این فیچرها که اطلاعات سطح بالا از یک قطعه مکانیکی نامیده می‌شوند، از یک سری اطلاعات سطح پایین مانند لبه، گوشه و سطح تولید می‌شوند[۳] و تحقیقات زیادی برای استخراج فیچرهای ماشین‌کاری از اطلاعات موجود در یک فایل طراحی صورت پذیرفته است. هدف از یک سیستم شناسایی فیچرهای ماشین‌کاری، استخراج اطلاعات هندسی و توپولوژیکی و تعریف یک الگوی مناسب برای شناسایی یک فیچر ماشین‌کاری از اطلاعات طراحی قطعه می‌باشد. اغلب روش‌های شناسایی فیچرهای ماشین‌کاری، اطلاعات ساختاری یک فایل طراحی قطعه را استخراج و این اطلاعات ساختاری را با یک مجموعه از قواعد و الگوها برای شناسایی فیچرهای ماشین‌کاری تطبیق می‌دهند[۴].

برخی محققان برای سهولت و رهایی از مشکلات استخراج اطلاعات هندسی و توپولوژیکی و انطباق الگویی مناسب برای شناسایی یک فیچر ماشین‌کاری پیشنهاد داده‌اند طراحی مدل قطعه از ابتدا بر اساس فیچرهای ماشین‌کاری باشد که در این صورت فیچر ماشین‌کاری مستقیماً در مدل طراحی قطعه معرفی می‌شود. به این روش شناسایی فیچرهای ماشین‌کاری، روش طراحی بر اساس فیچر[5] گفته می‌شود[۵]. با توجه به برخی از معایب این روش از جمله ایجاد محدودیت برای طراحان و عدم امکان تعریف کلیه فیچرهای ماشین‌کاری در یک لیست از قبل تعیین شده، این روش موفقیت چندانی در میان مراجع تحقیقاتی و علمی کسب ننموده است.

روش دیگری که کاربردی وسیع در شناسایی فیچرهای ماشین‌کاری داشته است و محققین زیادی برای توسعه این روش دستاوردهای قابل توجهی داشته‌اند، روش شناسایی اتوماتیک فیچرهای ماشین‌کاری می‌باشد. اطلاعات ساختاری موجود در یک فایل طراحی که به عنوان اطلاعات ورودی به یک سیستم شناسایی اتوماتیک فیچر[6] مورد استفاده قرار می‌گیرد و اساس معرفی یک فیچر است شامل اطلاعات توپولوژیکی، اطلاعات هندسی و اطلاعات سلسله مراتبی از عناصر یک فایل طراحی می‌باشد. اطلاعات توپولوژیکی، نحوه وابستگی اطلاعات ساختار یک فیچر را بیان می‌کند. اطلاعات هندسی ابعاد و موقعیت هر یک از عناصر اطلاعات توپولوژیکی را بیان می‌کند. سلسله مراتب اطلاعات ساختاری را می‌توان به اطلاعاتی در خصوص همسایگی بین لبه‌ها، گوشه‌ها و سطوح، اطلاعات ویژگی‌های خاص عناصر لبه، گوشه و سطح مانند واگرایی و همگرایی سطوح و اطلاعات هندسی خالص مانند زوایا، ابعاد و تلرانس‌ها دسته‌بندی کرد. الگوی معرفی این اطلاعات در یک فایل طراحی را الگویی معرفی اطلاعات یک فیچر در شناسایی اتوماتیک فیچرهای ماشین‌کاری گویند و از نظر یک فایل طراحی سه نوع الگو برای معرفی اطلاعات یک فیچر در فایل طراحی وجود دارد که عبارتند از مدل معرفی به صورت وایرفریم، مدل معرفی به صورت سطوح و مدل معرفی به صورت احجام[۶]. روش‌های متنوع و زیادی طی چند دهه گذشته برای شناسایی اتوماتیک فیچرهای ماشین‌کاری ارایه شده است که در بیشتر این روش‌ها اطلاعات استخراج شده برای شناسایی فیچر، اطلاعات اولیه و ورودی به سیستم شناسایی را از یکی از سه الگوی مذکور معرفی اطلاعات از یک فایل طراحی دریافت می‌کنند. شبکه‌های عصبی مصنوعی برای شناسایی فیچرهای ماشین‌کاری از سال ۱۹۹۲ توسط پاراباکر و همکاران[۷] شروع شد لیکن با معرفی شبکه‌های یادگیری عمیق و شبکه‌های کانولوشنی[7] در سال ۲۰۱۲ توسط لیکان و همکاران[۸]، این شبکه‌ها در اغلب زمینه‌های کاربردی و علمی توسعه یافته و با توجه به قابلیت‌های منحصر به فرد آنها، پیشرفت‌های زیادی در زمینه‌های مختلف حاصل گردید. استفاده از روش یادگیری عمیق برای شناسایی فیچرهای ماشین‌کاری از حوزه‌های علمی و کاربردی جدیدی است که تحقیقات انگشت شماری در این زمینه صورت گرفته است. ژانگ و همکاران [۲]

[1] CAD
[2] CAM
[3] CAPP
[4] Feature
[5] DBF
[6] AFR
[7] Convolutional

یک سیستم شناسایی فیچرهای ماشین‌کاری به‌کمک روش یادگیری عمیق به نام فیچرنت ارائه دادند که در آن از یک شبکه کانولوشنی سه بعدی برای یادگیری فیچرهای ماشین‌کاری با استفاده از اطلاعات خروجی یک فایل طراحی استفاده شده است. این شبکه برای شناسایی یک مجموعه ۲۴ تایی از فیچرهای ماشین‌کاری طراحی شده است. اطلاعات این فیچرها در یک بانک اطلاعاتی ذخیره و در یک شبکه کانولوشنی سه بعدی برای آموزش شبکه توسط این داده‌ها استفاده شده است. شی پی و همکاران [۹] در تکمیل شبکه فیچرنت، یک شبکه یادگیری عمیق به نام ام اس وی نت برای شناسایی فیچرهای ماشین‌کاری با استفاده از چند نمای برش خورده از یک فیچر یک سامانه جدید برای شناسایی فیچرهای ماشین‌کاری ارایه دادند. در روش پیشنهادی این محققان، نماهای مختلف از چند وجه یک مدل سه بعدی به عنوان ورودی به شبکه، جمع آوری و به عنوان ورودی به شبکه یادگیری عمیق داده می‌شود. بانک اطلاعاتی مورد استفاده در این تحقیق همان بانک اطلاعاتی شبکه فیچرنت[۲] می‌باشد که در آن از ۲۴ فیجر ماشین‌کاری استفاده شده است. هر دو شبکه ام اس وی نت[۹] و فیچرنت [۲]برای شناسایی فیچر، نیاز به اطلاعات سه بعدی سلول‌های مکعبی یا وکسل[1] در یک لیست کتابخانه‌ای دارند.

اغلب روش‌های شناسایی فیچرهای ماشین‌کاری بر اساس تکنیک یادگیری عمیق از داده‌های سیستم طراحی به کمک کامپیوتر که در قالب مدل معرفی مرزها ذخیره شده است، استفاده می‌کنند. از آنجایی که استفاده از داده‌های مدل معرفی مرزها به طور مستقیم به عنوان داده‌های ورودی شبکه عصبی مصنوعی دشوار است، این مدل ذخیره سازی داده‌ها به مدل‌های دیگر ذخیره‌سازی سه بعدی داده‌ها مانند مدل وکسل ، مش یا نقاط ابری تبدیل می‌شود و به عنوان داده‌های ورودی شبکه یادگیری عمیق استفاده می‌شود. [۱۰].

یکی دیگر از تحقیقاتی که در زمینه استفاده از شبکه‌های یادگیری عمیق در ماشین‌کاری قطعات مکانیکی استفاده شده است تحقیقی است که بالو و همکاران[۱۱] در سال ۲۰۱۷ میلادی با استفاده از یک شبکه کانولوشنی سه بعدی برای تحلیل قابلیت ماشین‌کاری در یک قطعه مکانیکی انجام دادند. در این تحقیق نیز اطلاعات ورودی به شبکه، اطلاعات سه بعدی یک فایل طراحی با فرمت وکسل می‌باشد که با کمک یک شبکه کانولوشنی سه بعدی برای تجزیه و تحلیل امکان ماشین‌کاری یک سوراخ توسط عملیات دریل‌کاری و تصمیم‌گیری برای ادامه فرایند ماشین‌کاری بصورت خودکار توسط یک شبکه یادگیری عمیق می‌باشد.

یکی از مشکلات اصلی روش‌های مبتنی بر تبدیل داده‌های طراحی سه بعدی به فرمت وکسل این است که به دلیل تبدیل مکرر داده‌ها، وضوح آنها کاهش می‌یابد و در فرآیند شناسایی ویژگی‌های ماشین‌کاری مشکل ایجاد می‌کند. برای حل این مشکل، برخی از محققان از داده‌های ذخیره شده با فرمت معرفی مرزها به طور مستقیم و بدون تبدیل آنها به مدل‌های وکسل یا ابر نقاط به عنوان ورودی شبکه یادگیری عمیق استفاده کرده‌اند.

لمبورن و همکاران [۱۲] از یک شبکه یادگیری عمیق به نام بی رپ نت[2] برای شناسایی فیچرهای ماشین‌کاری استفاده کردند. داده‌های ورودی این شبکه مستقیماً از داده‌های ذخیره شده با فرمت معرفی مرزها بدون تبدیل آنها به نقاط ابری یا به فرم وکسل است. شبکه یادگیری عمیق دیگر برای شناسایی فیچرهای ماشین‌کاری به نام "کدنت[3]" سلسله مراتبی است که توسط کالیگن و همکاران [۱۳] معرفی شد. در "کدنت" سلسله مراتبی، داده‌های مدل معرفی مرزها ابتدا به عنوان یک نمودار از داده‌های هندسی و توپولوژیکی سطوح ویژگی استخراج می‌شود و سپس از داده‌های نمودار سلسله مراتبی تولید شده به عنوان داده‌های ورودی به "کدنت" سلسله مراتبی استفاده می‌شود.

از شبکه‌های کانولوشنی ۲ بعدی یادگیری عمیق در حوزه‌های شناسایی تصویر و بینایی ماشین استفاده زیادی شده است لیکن در حوزه‌های صنعتی خصوصاً در حوزه شناسایی فیچرهای ماشین‌کاری استفاده چندانی نشده است. مورینو گارسیا و همکاران [۱۴] از شبکه‌های کانولوشنی دو بعدی برای شناسایی قطعات الکتریکی در یک نقشه مهندسی استفاده کردند. سیستم پیشنهاد داده شده علاوه بر شناسایی علایم قطعات الکتریکی، قادر به شناسایی مبدل‌ها و متن‌های مرتبط در یک نقشه مهندسی الکتریکی می‌باشد. کار مشابه دیگری که توسط ژاو و همکاران [۱۵] در سال ۲۰۲۰ انجام شده است، استفاده از شبکه‌های یادگیری عمیق برای شناسایی اجزای ساختمانی از نقشه‌های اسکن شده سازه یک ساختمان می‌باشد. در این تحقیق با استفاده از ۱۵۰۰ نقشه ساختمانی دو بعدی اسکن شده، یک شبکه یادگیری عمیق آموزش داده شده است. با کمک شبکه آموزش داده شده، این سیستم قادر است با موفقیت عناصر ساختمانی نظیر ستونها، بیم‌ها و شبکه بندی را با دقت حدود ۸۰ درصد استخراج نموده و تشخیص دهد.

اصطلاح فیچر علاوه بر کاربرد در طرح‌ریزی فرایند و ساخت

[1] Voxle

[2] B-repNET
[3] CADNet

قطعات مکانیکی، در حوزه علوم کامپیوتر، خصوصاً در حوزه بینایی کامپیوتر و پردازش تصویر کاربردهای فراوانی دارد. در حوزه علوم کامپیوتر، اصطلاح فیچر به معنی قطعه‌ایی از اطلاعات مانند نقاط یا اشیاء موجود در محتوای یک تصویر است[۱۶]. در این تحقیق از ترکیب اصطلاح فیچر در هر دو حوزه طرح‌ریزی فرآیند به کمک کامپیوتر و بینایی کامپیوتر، برای معرفی یک روش جدید شناسایی فیچرهای ماشین‌کاری با کمک تصویر یک فیچر استفاده شده است.

۲- روش شناسایی فیچرهای ماشین با استفاده از تصویر قطعه

کلیه روش‌های شناسایی اتوماتیک فیچرهای ماشین‌کاری که تاکنون معرفی و بکارگیری شده است مبتنی بر داده‌های ورودی از یک فایل طراحی به کمک کامپیوتر می‌باشند. در این تحقیق، روشی ارایه شده است که با استفاده از هوش مصنوعی و یادگیری عمیق، فیچرهای ماشین‌کاری مستقیماً از تصویر یک قطعه شناسایی شناسایی می‌شوند. اساس روش بکارگیری شده در این تحقیق تبدیل عناصر تصویر یک قطعه (پیکسل‌های تشکیل دهنده تصویر) به مقادیر عددی ارزش هر پیکسل و استخراج ویژگی‌های تصویر هر فیچر ماشین‌کاری با استفاده از هوش مصنوعی و یادگیری ماشین می‌باشد. کارایی یک سیستم یادگیری ماشین تا حد زیادی وابسته به تعداد تصاویر بکارگیری شده برای آموزش شبکه می‌باشد و در این تحقیق یک بانک داده قوی متشکل از حدود ۲۱۴۰۰ تصویر فیچر ماشین‌کاری بکارگیری شده است. در این تحقیق با توجه به اینکه اطلاعات ورودی به شبکه، اطلاعات یک تصویر دو بعدی می‌باشد از یک شبکه کانولوشنی دو بعدی بر اساس شبکه یادگیری عمیق یولو[1] [۱۷] برای شناسایی فیچرهای ماشین‌کاری استفاده می‌گردد. در اینگونه شبکه‌ها، تعداد عملیات ریاضی ساده و یکسانی که برروی داده‌ها صورت می‌گیرد زیاد می‌باشد لیکن بدلیل سادگی محاسبات و عدم وجود معادلات پیچیده و عدم نیاز به حل چندین معادله پیچیده برای پیدا کردن پارامترهای مجهول، نیاز به پردازشگرهای قوی سخت افزاری برای انجام محاسبات وجود ندارد و لذا در این شبکه‌ها غالبا با کمک پردازشگرهای گرافیکی کامپیوتری، این حجم از عملیات محاسبات ریاضی به سهولت و در کمترین زمان صورت می‌گیرد. در مرحله آموزش سامانه یادگیری عمیق شناسایی فیچرهای ماشین‌کاری در این تحقیق، در حدود ۳۴ میلیون پارامتر (وزن‌های شبکه و سایر متغیرها) با استفاده از ۲۱۴۰۰ تصویر فیچر در بانک داده، به شبکه آموزش داده شد. در این تحقیق از کارت گرافیکی مجازی گوگل به نام کولب[2] برای مرحله آموزش شبکه استفاده شده است. برای برنامه‌نویسی شبکه طراحی شده از زبان برنامه نویسی پایتون و با استفاده از کتابخانه‌های تنسور فلو و کراس استفاده گردیده است. دقت شناسایی فیچرهای ماشین‌کاری در قطعات شامل تنها یک فیچر ماشین‌کاری و در قطعات شامل بیش از یک فیچر ماشین‌کاری در حدود ۸۸ درصد توسط شبکه اندازه گیری شد.

۲-۱- آماده سازی داده‌ها

قطعات مکانیکی در صنعت، دارای تنوع و گستردگی زیادی در شکل و ابعاد می‌باشند و محققان انواع قطعات را با استفاده از مفهوم فیچر ماشین‌کاری دسته‌بندی و استانداردسازی کرده‌اند. دامنه کاربرد و محدوده شناسایی در سامانه تولید شده در این تحقیق، قطعات مکانیکی است که شامل هر یک از فیچرهای بیست گانه معرفی شده در استاندارد STEP AP224 می‌باشد. در شکل ۱ تعداد ۲۰ فیچر ماشین‌کاری معرفی شده در این استاندارد نشان داده شده است.

در این تحقیق قطعاتی که شامل یکی از این فیچرهای ۲۰گانه و یا یک قطعه مرکب از دو یا چند فیچر است قابل شناسایی می‌باشد. برای تهیه بانک اطلاعاتی تعداد ۱۲۰۰۰ تصویر (هر تصویر بطور متوسط شامل ۲ فیچر ماشین‌کاری) با فرمت‌های وایرفریم، ایزومتریک، دی‌متریک و تصویر معمولی (عکس) قطعه و ترکیبات مختلف این فیچرها با یکدیگر توسط نرم افزار سالید ورکزتهیه گردید. در شکل ۲ تصاویر نمونه‌ای از بانک اطلاعاتی تصاویر فیچرها مشاهده می‌شود. در مخزن نگهداری داده‌های این تحقیق در فضای مجازی به آدرس https://github.com/resan-m/Feature-Recognitin-Data بانک داده تهیه شده برای استفاده سایر محققان قابل مشاهده و دسترسی می‌باشد. با توجه به اینکه در یک محدوده خاص از هر تصویر ممکن است یک یا چند فیچر ماشین‌کاری وجود داشته باشد، برای تعیین پیکسل‌های متعلق به هر فیچر، محدوده‌ایی از تصویر که یک فیچر ماشین‌کاری وجود دارد، بایستی تعیین گردد. برای این کار با کمک زبان برنامه نویسی پایتون و با استفاده از بسته کاربردی لیبل مپ[3] اطلاعات تصاویر بانک اطلاعاتی فیچرها برچسب‌گذاری[4] گردید. در عملیات برچسب‌گذاری تصویر، هر فیچر در هر تصویر، بصورت دستی با رسم یک کادر اطراف آن مشخص گردید و سپس ۴ پارامتر ازهر برچسب شامل طول و عرض و مختصات ابتدا و انتهای کادر هر فیچر در تصویر مشخص گردید.

[1] YOLO

[2] Colab
[3] Labelmap
[4] Labeling

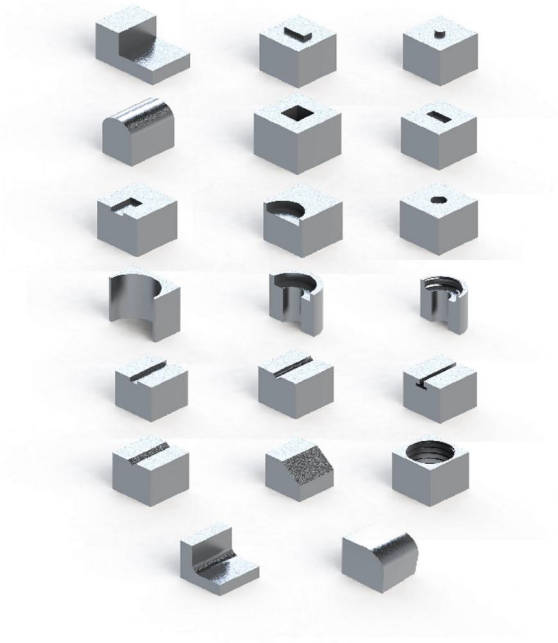

(الف)

۱	Step		۸	Rectangular Opend pocket		۱۵	Round Slot	
۲	Rectangular Boss		۹	Round pocket		۱۶	Tee Slot	
۳	Circular Boss		۱۰	Circular pocket		۱۷	Vee Slot	
۴	Round end		۱۱	Round hole		۱۸	Chamfer	
۵	Planer face		۱۲	Counterbore hole		۱۹	Fillet	
۶	Thread		۱۳	Countersunk hole		۲۰	Edge round	
7	Rectangular Closed Pocket		۱۴	Squre Slot				

(ب)

Fig. 1 20 machining features that can be identified in this research; a) Images of machining features produced by Solid Works software b) Specifications of identifiable features in STEP AP224 standard

شکل ۱ ۲۰ فیچر ماشین‌کاری قابل شناسایی در این تحقیق؛ الف) تصاویر فیچرهای ماشین‌کاری تولید شده توسط نرم افزار سالید ورکز ب) مشخصات فیچرهای قابل شناسایی در استاندارد STEP AP224

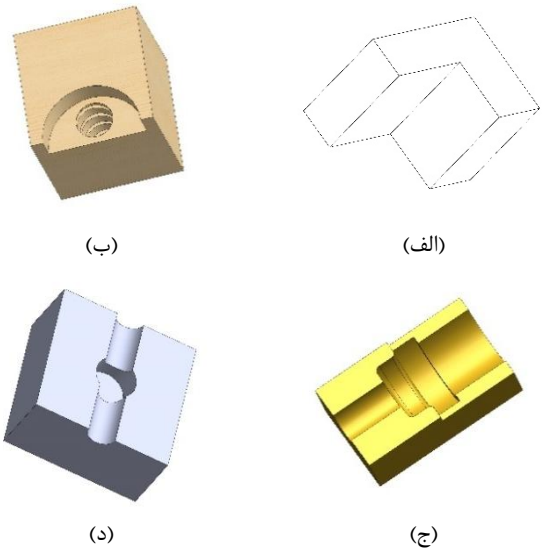

(الف) (ب) (ج) (د)

Fig. 2 Examples of data bank images produced by Solid Works software; a) step feature with B-Rep format; b) A piece composed of two features, a Round Pocket and a Thread with wood material; c) A piece composed of two features, Countersunk Hole and Counterbore Hole with brass metal; d) A piece composed of two features, a Circular Pocket and a Round Slot with a CGS format

شکل ۲ نمونه‌هایی از تصاویر تولید شده بانک داده توسط نرم افزار سالید ورکز؛ الف) فیچر پله با فرمت نمایش خطوط مرزی ب) قطعه مرکب از دو فیچر تورفتگی (جیب) گرد و رزوه با جنس متریال چوب؛ ج) قطعه مرکب از دو فیچرسوراخ خزینه بیضوی و سوراخ خزینه استوانه‌ایی با جنس فلز برنج؛ د) قطعه مرکب از دو فیچر جیب دایره‌ایی و شکاف گرد با فرمت جسم جامد

اطلاعات مذکوردر یک فایل متنی با فرمت زبان نشانه‌گذاری گسترش‌پذیر[1] برای هر فیچر ذخیره شد. اطلاعات ذخیره شده سبب می‌شود که شبکه هوش مصنوعی، ویژگی‌های مورد نیاز برای شناسایی هر فیچر و یا سایر اطلاعات مانند ابعاد و مختصات و غیره را با استفاده از کادر مشخص شده که حاوی اطلاعات منحصر به فرد هر فیچر می‌باشد، با استفاده از پیکسل‌های تشکیل دهنده آن را برای مرحله آموزش شبکه بدست بیاورد. در مرحله بعدی آماده سازی داده‌ها، کلیه فایل‌های متنی مربوط به هر یک از تصاویر، تجمیع و در یک فایل اکسل با فرمت مقادیر جدا شده با کاما[2] تبدیل می‌گردد. سپس اطلاعات تجمیع شده این فایل به فرمت قابل شناسایی توسط کامپیوتر (فرمت دودویی) تبدیل و آماده استفاده در مرحله آموزش شبکه می‌گردد. نمونه ایی از بر چسب گذاری دو فیچر ماشین‌کاری در بانک داده تحقیق در شکل ۳ مشاهده می‌گردد.

در جدول ۱ مقادیر پیکسل‌های طول و عرض فیچرهای نشان داده شده در شکل ۳ و مرکز مختصات هر کدام (با مبدا

[1] Extensible Markup Language (XML)
[2] Coma Separated Value (CSV)

گوشه سمت چپ بالای تصویر) ذکر گردیده است. جهت بکارگیری اطلاعات مقادیر پیکسل‌های هر فیچر ماشین‌کاری بانک داده در فرایند آموزش شبکه کلیه اطلاعات برچسب گذاری در یک فایل اکسل با فرمت داده‌های جدا شده با کاما ذخیره و سپس با استفاده از یک قطعه کد در زبان برنامه نویسی پایتون به داده‌های دیجیتالی (به زبان ماشین) تبدیل گردید.

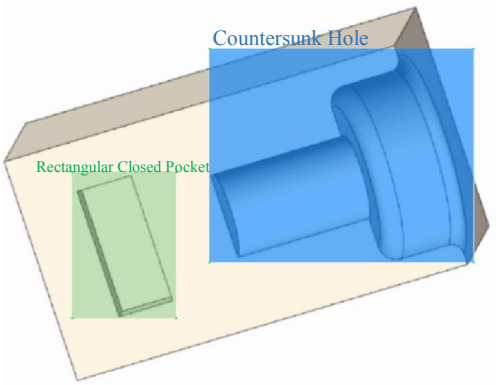

Fig. 3 Labeling of a piece composed of features of a Rectangular Closed Pocket and Countersunk Hole

شکل ۳ برچسب گذاری یک قطعه مرکب از فیچر جیب مستطیلی بسته و سوراخ خزینه بیضوی

جدول ۱ مشخصات ابعادی و موقعیت فیچرهای نشان داده شده در شکل ۳ بر اساس تعداد پیکسل‌های تصویر

Table 1 Dimensional characteristics and position of the features shown in Fig. 3 based on the number of pixels in the image

filename	width	height	class	xmin	ymin	xmax	ymax
Fig3.jpg	۱۳۶۱	۱۰۷۱	Countersunk Hole	۵۸۴	۱۵۹	۱۲۷۱	۷۱۳
Fig3.jpg	۱۳۶۱	۱۰۷۱	Rectangular Closed Pocket	۲۲۸	۴۷۹	۴۹۸	۸۵۸

۲-۲- طراحی و آموزش شبکه یادگیری عمیق برای شناسایی فیچرهای ماشین‌کاری

هر شبکه یادگیری عمیق، یک ساختار محاسباتی ریاضی دارد و برای استخراج ویژگی‌های مختص تصویر هر فیچر ماشین‌کاری، مقادیر عددی هریک از پیکسل‌های تصویر در ضرایبی بنام وزن‌های شبکه ضرب می‌گردد. شناسایی فیچرهای ماشین‌کاری در این روش طی سه مرحله اصلی عملیات ریاضی بر روی مقادیر عددی پیکسل‌های تصویر حاوی فیچر ماشین‌کاری صورت می‌پذیرد. در شبکه‌های یادگیری عمیق به هر مرحله عملیات ریاضی مشابه بر روی داده‌ها، یک لایه گفته می‌شود. این سه لایه عبارتند از لایه کانولوشن[1]، لایه کاهش اندازه یا پولینگ[2] و لایه تمام متصل[3]. در یک شبکه کانولوشنی بر اساس طراحی ممکن است هر یک از این لایه‌ها چندین بار در یک شبکه تکرار شود. استخراج ویژگی‌های مختص هر یک از فیچرهای ماشین‌کاری در لایه‌های کانولوشن صورت می‌گیرد و در لایه تمام متصل، این ویژگی‌ها با ویژگی‌های تصویر فیچر مورد انتظار تطبیق داده می‌شود و چنانچه ویژگی‌های استخراج شده تا یک دقت قابل قبول با ویژگی‌های تصویر فیچر تطابق نداشته باشد، از طریق توابع بهینه‌ساز، ویژگی‌های مشخصه هر فیچر بهبود پیدا می‌کند تا به دقت قابل قبول برسد. لایه کانولوشن، اصلی ترین لایه یک شبکه یادگیری عمیق می‌باشد. در لایه کانولوشن برای استخراج ویژگی‌های هر فیچر، از تعدادی آرایه دو بعدی که به هر آرایه یک هسته، فیلتر و یا کرنل گفته می‌شود، استفاده می‌گردد. هر کرنل در واقع آشکار کننده یک یا چند ویژگی منحصر به فرد از هر فیچر مشخص در یک تصویر است. تعیین تعداد و ابعاد آرایه کرنل یکی از موضوعات مهم در شبکه‌های کانولوشنی می‌باشد که در واقع با تعیین عناصر این آرایه، بخشی از وزن‌های شبکه عصبی یادگیری عمیق به نحوی تعیین و آموزش داده می‌شود که بتواند فیچرهای موجود در تصویر را با کمترین مقدار خطا تشخیص دهد. با توجه به وجود چندین ضرب کانولوشن در هر لایه و چندین لایه پشت سرهم در شبکه‌های یادگیری عمیق، حجم محاسبات شبکه افزایش قابل ملاحظه‌ایی خواهد یافت که منجر به کند شدن شبکه و افزایش هزینه‌های محاسباتی می‌شود و لذا در لایه کاهش اندازه، حجم داده‌ها بدون از دست رفتن اطلاعات مفید موجود در آنها تا حد قابل توجهی کاهش می‌یابد.

در لایه کاهش اندازه (لایه پولینگ) ابعاد هر یک از آرایه‌های حاصل از ضرب کانولوشن از طریق میانگین‌گیری عناصر مجاور و یا انتخاب بزرگترین عدد از عناصر موجود در میان چند عنصر مجاور در یک آرایه و یا سایر روش‌ها کاهش داده می‌شود.

در لایه تمام متصل، کلیه عناصر آرایه‌های نقشه ویژگی که کاهش اندازه داده شده‌اند، در آخرین لایه قبل از لایه تمام متصل که بعد از چندین بار کانولوشن و کاهش اندازه به تعداد قابل توجهی آرایه مجزا تبدیل شده‌اند، در یک ردیف بصورت یک ستون واحد از همه عناصر آرایه‌ها تبدیل می‌شود. در شکل ۴ یک نمونه از عناصر و نحوه ارتباط لایه تمام متصل مشاهده می‌گردد.

چنانچه مقدار عناصر هر یک از سلول‌های لایه تمام متصل

[1] Convolution layer

[2] Pooling layer
[3] Fully connected layer

h_m نامیده شوند و m شمارنده تعداد سلول‌های لایه تمام متصل باشد، هر یک از این عناصر حاوی مقداری است که یک تأثیر مشخص و قابل محاسبه برای شناسایی هر یک از فیچرهای ماشین‌کاری دارد.

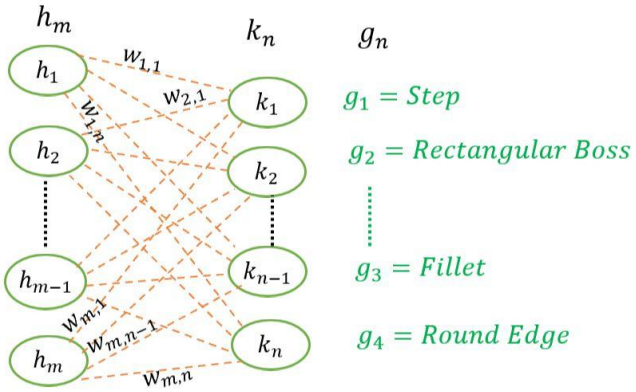

Fig. 4 An example of the elements and how to connect the Fully connected layer of the machining features identification network

شکل ۴ یک نمونه از عناصر و نحوه ارتباط لایه تمام متصل شبکه شناسایی فیچرهای ماشین‌کاری

درصد تأثیر هر یک از مقادیر سلول‌های لایه تمام متصل (h_m)، وزن‌های لایه تمام متصل نامیده می‌شوند و چنانچه تعداد فیچرهای قابل شناسایی در خروجی شبکه با شمارنده n نشان داده شوند و وزن‌های لایه آخر برای شناسایی فیچرها با متغیر $w_{m,n}$ نشان داده شوند، مقادیر عددی هر یک فیچرهای قابل شناسایی با رابطه (۱) نشان داده می‌شود.

$$k_n = \sum_m h_m w_{m,n} \qquad (۱)$$

در این رابطه k_n مقدار عددی مربوط به هر یک از n فیچر قابل شناسایی توسط سامانه می‌باشد. برای تعیین احتمال تعلق هر یک از مقادیر محاسبه شده به هر یک از فیچرهای ماشین‌کاری، در این تحقیق از تابع سافت مکس با ضابطه زیر که یکی از توابع قدرتمند در این خصوص می‌باشد، استفاده شده است:

$$g_n = \frac{e^{k_n}}{\sum_c^n e^{k_c}} \qquad (۲)$$

در این تابع g_n مقدار احتمال تعلق تصویر فیچر ورودی به شبکه به هر یک از فیچرهای قابل تشخیص می‌باشد و n تعداد فیچرهای قابل شناسایی توسط شبکه می‌باشد که در این تحقیق برابر با ۲۰ می‌باشد.

برای پایش میزان درست بودن تشخیص هر یک از فیچرهای ۲۰ گانه توسط شبکه، از تابعی بنام تابع ضرر (خطا) استفاده می‌گردد. در این تحقیق از تابع حداقل میانگین مربعات (رابطه ۳) استفاده شده است:

$$l_n = {}^1\!/_2 \sum_{k=1}^{k} (g_n - t_k)^2 \qquad (۳)$$

که در این رابطه، l_n مقدار خطای تشخیص شکل فیچر n ام؛ g_n مقدار عددی محاسبه شده برای فیچر n ام که مقداری بین صفر و یک می‌باشد؛ t_k مقدار این متغییر برای فیچر n ام موجود در تصویر ورودی به شبکه برابر ۱ در نظر گرفته می‌شود.

در صورت بالا بودن خطای تشخیص لازم است مقادیر ضرایب وزن‌های شبکه به روز رسانی شوند تا مقدار خطای تشخیص تا حد مطلوب کاهش یابد. برای به روز رسانی وزن‌های شبکه در این تحقیق از تابع بهینه ساز (رابطه ۴) استفاده گردیده است:

$$(w_{m,n})_i = (w_{m,n})_{i-1} - \mu \frac{\partial l_n}{\partial w_{m,n}} \qquad (۴)$$

در این رابطه μ پارامتر نرخ آموزش است که در هنگام آموزش شبکه در آزمایشگاه با توجه به نرخ همگرایی آموزش شبکه بدست می‌آید و $\frac{\partial l_n}{\partial w_{m,n}}$ شیب خطای تشخیص فیچر n ام نسبت به هر یک از وزن‌های شبکه می‌باشد. همچنین $(w_{m,n})_i$ مقدار هر یک از ضرایب وزن‌های شبکه در بروزرسانی مرحله i ام و $(w_{m,n})_{i-1}$ مقدار همان ضریب قبل از آخرین به روزرسانی مقادیر وزن‌ها در هنگام آموزش شبکه می‌باشد. سایر پارامترهای طراحی شبکه تشخیص فیچرهای ماشین کاری با استفاده از معماری شبکه یادگیری عمیق یولو [۱۷] و تغییر برخی از پارامترها پس از بررسی و انطباق با مسئله شناسایی فیچرهای ماشین‌کاری انتخاب و بکارگیری شده است.

پس از کد نویسی پارامترها با زبان برنامه نویسی پایتون و تنظیم پارامترها، سامانه شناسایی فیچرهای ماشین‌کاری با

استفاده از کارت گرافیکی مجازی گوگل در سایت گوگل بنام گوگل کولب و اصلاح پارامترها در جهت کاهش خطا و افزایش دقت تشخیص شبکه آموزش داده شد. در مرحله اول برای آموزش شبکه تعداد ۸۰۰۰ تصویر فیچر ماشین‌کاری پس از آماده‌سازی داده‌ها برای مرحله آموزش استفاده گردید. در فرایند آموزش شبکه، منحنی‌های کاهش خطا (رابطه ۳) و افزایش دقت شناسایی شبکه (تعداد تشخیص صحیح به کل تشخیص‌های شبکه) مورد بررسی قرار گرفت. همان‌طور که در شکل‌های ۵- الف و ب مشاهده می‌شود پس از ۶۵۰۰ بار به روزرسانی وزن‌های شبکه، خطای تشخیص فیچرها توسط شبکه به حدود ۰/۱۶ کاهش یافت و دقت تشخیص فقط تا ۸ درصد افزایش یافت.

با توجه به عدم تغییر در کاهش مؤثر نرخ خطا و عدم افزایش دقت تشخیص با ادامه آموزش، فرایند آموزش شبکه متوقف گردید. پس از بررسی و اعمال اصلاحات لازم در پارامترهای طراحی شبکه و نیز داده‌های موجود در بانک داده تحقیق، مشخص گردید که با توجه به تعداد فیچرهای قابل شناسایی (۲۰ فیچر ماشین‌کاری در این تحقیق) لازم است تعداد تصاویر موجود در بانک داده افزایش داده شود. لذا مجدداً تعداد ۱۳۴۰۰ تصویر فیچر ماشین‌کاری تهیه و به بانک داده اضافه گردید. با استفاده از مقادیر وزن‌های بدست آمده از آموزش شبکه با تعداد ۸۰۰۰ تصویر در مرحله قبل و انتخاب این وزن‌ها به عنوان مقادیر پیش فرض وزن‌های اولیه، پس از شروع مجدد فرایند آموزش و ۷۵۰۰ بار به روز رسانی وزن‌های شبکه (شکل ۵)، خطای تشخیص به حدود ۰/۱ (شکل ۵- د) کاهش و دقت شبکه در شناسایی فیچرهای ماشین‌کاری به حدود ۸۸ درصد (شکل ۵- ج) افزایش یافت.

۳- بررسی و تحلیل نتایج

پس از ارزیابی دقت سامانهدر شناسایی فیچرهای ماشین‌کاری و دست یابی به حدود دقت قابل قبول، تصاویر مختلف فیچرهای ماشین‌کاری به سامانه وارد گردید و نتایج خروجی مورد بررسی قرار گرفت. در ادامه به برخی از قابلیت‌های سامانه تولید شده برای شناسایی فیچرهای ماشین‌کاری از طریق تصویر فیچرها اشاره می‌گردد.

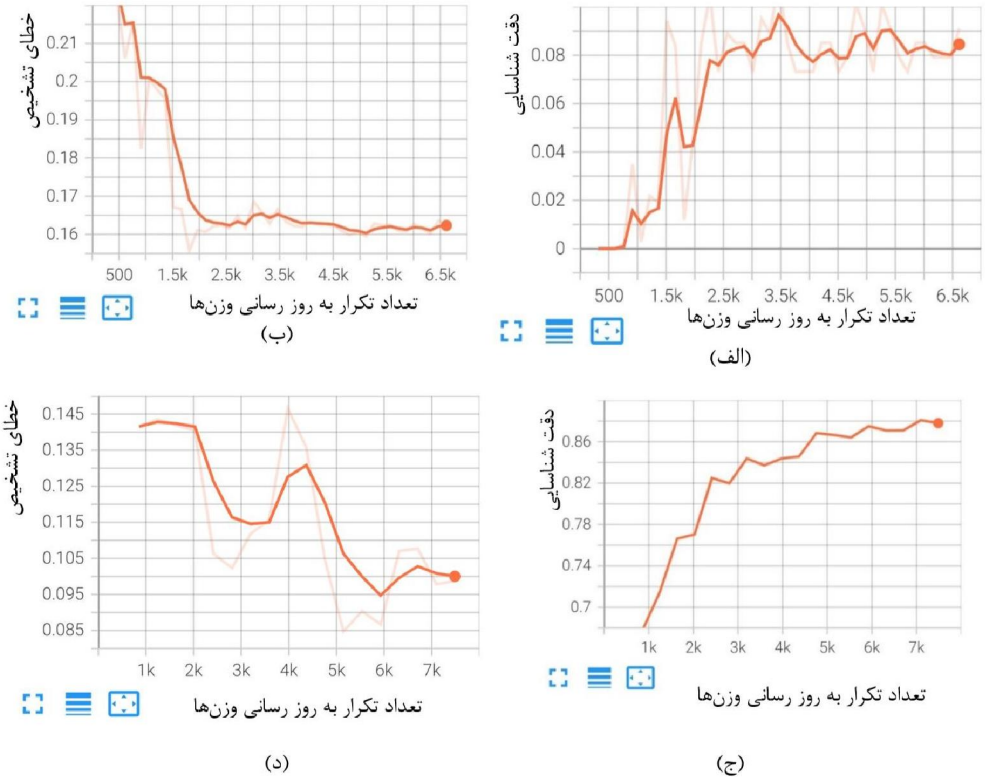

Fig. 5 network training curves a) recognition accuracy with the number of 8000 feature images in the research data bank; b) detection error with 8000 feature images in the data bank; c) identification accuracy with 21400 feature images in the data bank; d) Detection error with 21400 feature images in the data bank

شکل ۵ منحنی‌های آموزش شبکه الف) دقت شناسایی با تعداد ۸۰۰۰ تصویر فیچر در بانک داده تحقیق؛ ب) خطای تشخیص با ۸۰۰۰ تصویر فیچر در بانک داده؛ ج) دقت شناسایی با ۲۱۴۰۰ تصویر فیچر در بانک داده؛ د) خطای تشخیص با ۲۱۴۰۰ تصویر فیچر در بانک داده

۳-۱- قابلیت شناسایی فیچر ماشین‌کاری در تصویر حاوی فقط یک فیچر ماشین‌کاری با فرمت‌های مختلف تصویر

تصویر هر یک از فیچرهای ماشین‌کاری ۲۰ گانه بصورت جداگانه و با فرمت‌های مختلف از قبیل فرمت جسم جامد، فرمت نمایش خطوط مرزی، فرمت تصویر واقعی از جسم با متریال مختلف به سامانه وارد گردید، سامانه با موفقیت قادر به تشخیص فیچرهای موجود در تصویر با انواع فرمت‌های ذکر شده گردید. در شکل ۶- الف تصویر یک فیچر رزوه با فرمت جسم جامد، در شکل ۶- ب تصویر یک فیچر جیب مستطیلی بسته با فرمت نمایش خطوط مرزی و در شکل ۶- ج تصویر فیچر جیب دایره‌ایی با جنس متریال چوب مشاهده می‌شود که با موفقیت فیچرهای مربوط به هر تصویر توسط سامانه شناسایی شده‌اند.

۳-۲- تصاویر قطعات مرکب از دو یا چند فیچر ماشین‌کاری

جهت پایش توانایی سامانه در شناسایی فیچرهای ماشین‌کاری در قطعات مرکب از چند فیچر، چندین تصویر از قطعات مختلف مرکب از دو یا چند فیچر ماشین‌کاری به سامانه وارد شد و سامانه با موفقیت قادر به شناسایی کلیه فیچرهای موجود در تصاویر قطعات مرکب گردید. در شکل ۷- الف یک قطعه مرکب از سه فیچر ماشین‌کاری گوشه گرد، شکاف وی و سطح شیبدار و در شکل ۷- ب یک قطعه مرکب از دو فیچر ماشین‌کاری سوراخ خزینه استوانه‌ایی و برجستگی دایره‌ایی مشاهده می‌گردد که سامانه کلیه فیچرهای موجود در تصویر این دو قطعه مرکب را به درستی تشخیص داده است.

۳-۳- شناسایی قطعات شامل فیچرهای تداخلی

یکی از مشکلات اصلی روش‌های قبلی شناسایی فیچرهای ماشین‌کاری، عدم توانایی شناسایی فیچرهای تداخلی به‌دلیل حذف برخی از داده‌های اینگونه فیچرها در فایل خروجی طراحی به کمک کامپیوتر می‌باشد. سامانه طراحی شده در این تحقیق با موفقیت قادر به شناسایی فیچرهای تداخلی می‌باشد. در شکل ۸- الف یک قطعه مرکب از دو فیچر تداخلی شکاف تی و تورفتگی (جیب) گرد مشاهده می‌گردد که در سطح تماس دو فیچر با هم تداخل دارند و در فایل خروجی طراحی به کمک کامپیوتر بخشی از اطلاعات سطح مشترک بین دو فیچر به‌علت این تداخل حذف می‌گردد و سبب بروز مشکل در روش‌های قبلی شناسایی فیچرهای ماشین‌کاری می‌گردد، لیکن همان‌طور که در این شکل مشاهده می‌گردد، سامانه معرفی شده در این تحقیق با سهولت قادر به تشخیص این دو فیچر در قطعه می‌باشد.

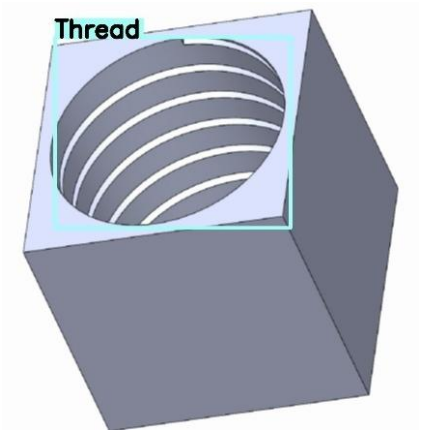

(الف)

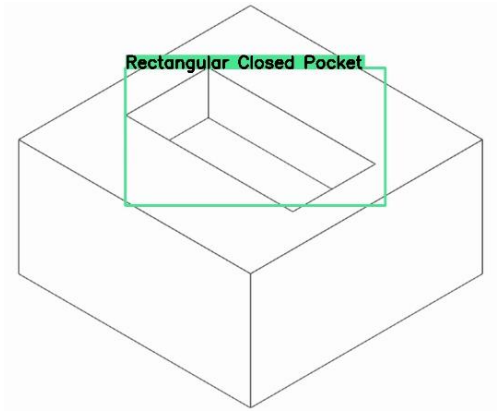

(ب)

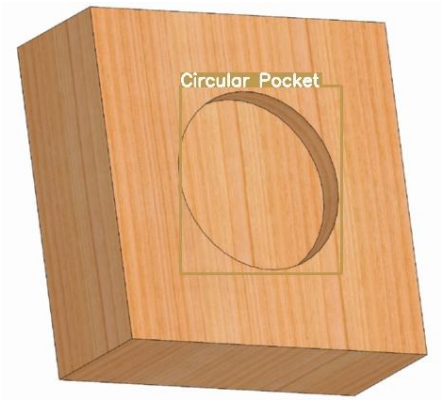

(ج)

Fig. 6 Features identified by the network with different formats a) Thread feature image with CGS format, b) Rectangular Closed Pocket feature image with B-Rep format, c) Circular Pocket feature with normal image format of a piece of wood

شکل ۶ فیچرهای شناسایی‌شده توسط شبکه با فرمت‌های مختلف الف) تصویر فیچر رزوه با فرمت جسم جامد، ب) تصویر فیچر جیب مستطیلی بسته با فرمت نمایش خطوط مرزی، ج) فیچر جیب دایره‌ایی با فرمت تصویر معمولی از یک قطعه از جنس چوب

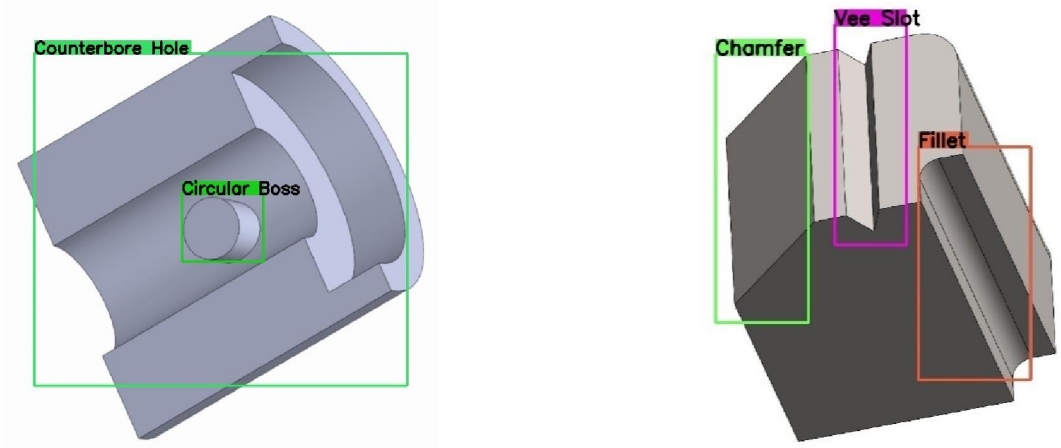

(ب) (الف)

Fig. 7 Identification of machining features in parts composed of two or more features a) a part composed of three features, Fillet, Vee Slot and Chamfer b) a part composed of two features, Counterbore Hole and Circular Boss

شکل ۷ شناسایی فیچرهای ماشین‌کاری در قطعات مرکب از دو یا چند فیچر الف) قطعه مرکب از سه فیچر گوشه گرد، شکاف وی و سطح شیبدار ب) قطعه مرکب از دو فیچر سوراخ خزینه استوانه‌ایی و برجستگی دایره‌ایی

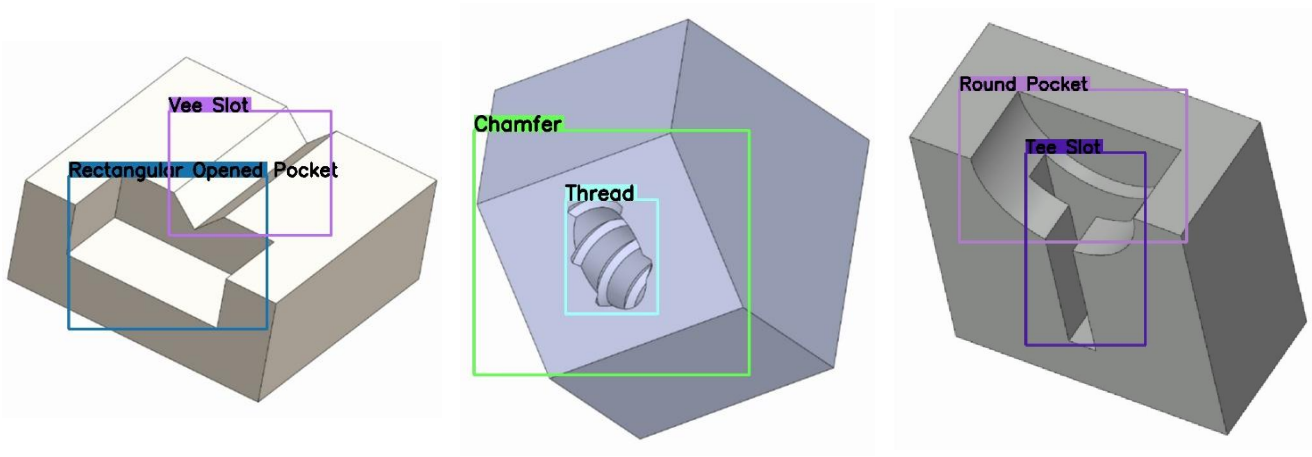

(ج) (ب) (الف)

Fig. 8 Identification of features with geometric interference detected by the network, a) Geometric interference of two features, Tee Slot and Round Pocket, b) Geometric interference of two features of Chamfer and thread, c) Geometric interference of two features of Rectangular Opened Pocket and Vee Slot

شکل ۸ شناسایی فیچرهای دارای تداخل هندسی شناسایی شده توسط شبکه، الف) تداخل هندسی دو فیچر شکاف تی و تورفتگی (جیب) گرد، ب) تداخل هندسی دو فیچر سطح شیبدار و رزوه ج) تداخل هندسی دو فیچر جیب مستطیلی باز و شکاف وی

در شکل ۸- ب فیچر رزوه علاوه بر تداخل تکنیکی (لغزیدن ابزار بر روی سطح شیبدار در صورت ماشین‌کاری سطح شیبدار قبل از ماشین‌کاری فیچر رزوه دارای تداخل هندسی (حذف بخشی از داده‌های سطح شیبدار در فایل طراحی به کمک کامپیوتر) نیز می‌باشد. سامانه معرفی شده در این تحقیق قادر به شناسایی تداخل هندسی این دو فیچر بوده و هر دو فیچر را به درستی شناسایی نموده است. در شکل ۸- ج نیز تداخل هندسی دو فیچر شکاف وی و جیب مستطیلی باز در مرز بین دو فیچر مذکور وجود دارد که سامانه تولید شده با موفقیت قادر به شناسایی هر دو فیچر ماشین‌کاری در این تصویر می‌باشد.

۳-۴- شناسایی تصاویر فیچرهای ماشین‌کاری در قطعات ساخته شده قبلی

یکی دیگر از محدودیت روش‌های قبلی شناسایی فیچرهای ماشین‌کاری، متکی بودن آنها به صرفاً به فایل خروجی سیستم‌های طراحی به کمک کامپیوتر می‌باشد. در روش معرفی

شده در این تحقیق این محدودیت برطرف گردیده است و برای کاربردهایی همچون مهندسی معکوس قطعات ساخته شده قبلی و یا نمونه‌برداری از برخی قطعات که فایل طراحی به کمک کامپیوتر آنها در دسترس نمی‌باشد کاربرد دارد.

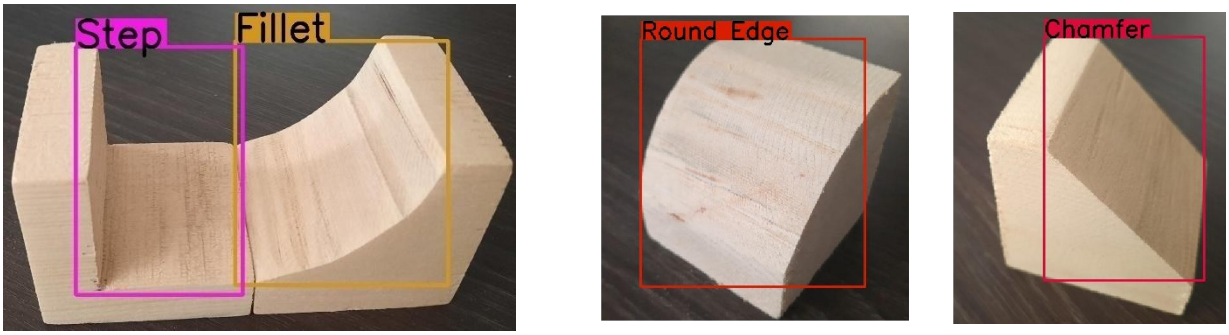

(ج) (ب) (الف)

Fig. 9 Images of wooden models of machining features by mobile phone camera, a) Chamfer feature b) Round Edge feature c) Fillet and step features in one image

شکل ۹ تصاویر ماکت‌های چوبی فیچرهای ماشین‌کاری توسط دوربین تلفن همراه، الف) فیچر سطح شیبدار ب) فیچر لبه گرد ج) فیچرهای گوشه داخلی و پله در یک تصویر

برای ارزیابی دقت شبکه در شناسایی قطعات ساخته شده از طریق تصاویر این قطعات، ماکت چوبی ۴ فیچر ماشین‌کاری لبه گرد، پله، گوشه داخلی و سطح شیبدار ساخته شد و پس از تصویر برداری با دوربین معمولی گوشی تلفن همراه، تصاویر این قطعات به سامانه وارد گردید و سامانه با موفقیت قادر به تشخیص فیچرهای ماشین‌کاری مذکور گردید. در شکل‌های ۹- الف و ب تصایر فیچرهای سطح شیبدار و لبه گرد بصورت جداگانه و در شکل ۹- ج دو فیچر پله و گوشه داخلی در یک تصویر وجود دارد که توسط دوربین گوشی همراه معمولی تصویر برداری شده است و نتایج تشخیص فیچرهای مذکور در تصاویر توسط شبکه مشاهده می‌گردد.

با بررسی نتایج تشخیص سامانه معرفی شده در این تحقیق، مشاهده می‌گردد برخی از عوامل مانند تعداد داده‌های موجود در بانک داده، تعداد فیچرهای موجود در یک قطعه مرکب از چند فیچر، تعداد کل فیچرهای قابل شناسایی توسط سامانه، زاویه چرخش قطعه در تصویر، اندازه قطعه در تصویر و نیز نامشخص بودن قسمتی از شکل فیچر در تصویر قطعه از عوامل تأثیر گذار بر قابلیت سامانه در شناسایی فیچرهای ماشین‌کاری می‌باشند. تعداد تصاویر موجود در بانک داده یکی از مهمترین عوامل تأثیر گذار بر افزایش دقت سامانه در تشخیص فیچرهای ماشین‌کاری می‌باشد. با توجه به اینکه مقدار نهایی وزن‌های شبکه یادگیری عمیق در رابطه ۱ تأثیر مستقیمی در تشخیص صحیح فیچرها بر اساس روبط ۲ تا ۴ دارد، هر چه تعداد تصاویر فیچرها در بانک داده بیشتر باشد، درصد دقت سامانه در شناسایی فیچرها افزایش می‌یابد. همان‌طور که در منحنی‌های دقت سامانه در شکل ۵ مشاهده می‌شود با افزایش تعداد تصاویر بانک داده از ۸۰۰۰ تصویر به ۲۱۴۰۰ تصویر، دقت سامانه از ۸ درصد به ۸۸ درصد افزایش یافته است. بررسی منحنی‌های آموزش و دقت در مراحل مختلف آموزش سامانه با تعداد کمتر فیچر قابل شناسایی نشان داد که کاهش تعداد فیچرهای قابل شناسایی (بعنوان مثال ۵ فیچر از ۲۰ فیچر دامنه کاربرد این تحقیق) در صورتی که تعداد تصاویر هر فیچر در بانک داده از حداقل ۱۰۰۰ تصویر کمتر نباشد، تأثیری در افزایش دقت سامانه در شناسایی فیچرها نخواهد داشت. بررسی تشخیص سامانه در شکل‌های ۷، ۸ و ۹ نشان می‌دهد که دقت تشخیص سامانه متأثر از تعداد فیچرها در یک قطعه مرکب از چند فیچر نمی‌باشد و لذا قابلیت تشخیص فیچرها در یک قطعه پیچیده یکی از توانمندی‌های قابل توجه روش معرفی شده می‌باشد. همان‌طور که در شکل ۸- الف مشاهده می‌شود بخشی از فیچر تورفتگی (جیب) گرد بدلیل تداخل هندسی با فیچر شکاف تی و نیز زاویه دید این فیچر در تصویر قابل مشاهده نمی‌باشد، لیکن سامانه با موفقیت قادر به تشخیص هر دو فیچر موجود در تصویر شده است. با توجه به نتیجه تشخیص سامانه در شکل مذکور و نیز نتایج اخذ شده در سایر تصاویر ارزیابی سامانه، مشخص گردید که سامانه قادر است با مشاهده بخشی از تصویر فیچر، نوع فیچر مذکور را تشخیص دهد. همچنین با ملاحظه شکل‌های ۷- الف، ۸- ب و ۹- الف

مشاهده می‌گردد که فیچر سطح شیبدار با زاویه دید متفاوت توسط سامانه شناسایی شده است و لذا قابلیت تشخیص سامانه مستقل از زاویه دید فیچر در تصویر است. همچنین اندازه و زاویه دید فیچر گوشه داخلی در شکل‌های ۷- الف و ۹- ج کاملاً متفاوت می‌باشد، با این حال سامانه با موفقیت این فیچر را در تصاویر مذکور شناسایی نموده است.

۴- نتیجه‌گیری

در این تحقیق یک سامانه جدید شناسایی فیچرهای ماشین‌کاری با استفاده از شبکه یادگیری عمیق طراحی و پیاده‌سازی شده است. این تحقیق در واقع استفاده کاملاً کاربردی از شبکه‌های یادگیری عمیق در شناسایی فیچرهای ماشین‌کاری می‌باشد که با داشتن تصویر یک قطعه مکانیکی، فیچرهای ماشین‌کاری را تشخیص می‌دهد. از مزایای این شبکه بی نیازی و استقلال از فرمت‌های گوناگون داده‌های خروجی از یک فایل طراحی و استفاده از تصویر بعنوان خروجی مشترک کلیه سیستم‌های طراحی اعم از طراحی به کمک کامپیوتر و یا طراحی دستی و یا هر ابزاری که بتواند تصویر یک قطعه را تولید کند می‌باشد. روش ارایه شده توانمندی و قابلیت شناسایی فیچرهای ماشین‌کاری دارای تداخل هندسی را نیز دارا می‌باشد که در روش‌های قبلی در این زمینه مشکلاتی وجود داشته است. پس از تهیه بیش از ۲۱ هزار تصویر از ۲۰ فیچر ماشین‌کاری با فرمت‌های مختلف توسط نرم‌افزار سالیدورکز و نیز با استفاده از دوربین معمولی گوشی تلفن همراه و تهیه بانک داده، و تنظیم پارامترها، شبکه یادگیری عمیق با استفاده کارت گرافیک مجازی شرکت گوگل آموزش داده شد. بررسی نتایج تشخیص شبکه بر روی تصاویر با فرمت‌های مختلف و از زوایای دید متفاوت نشان داد که دقت تشخیص شبکه در حدود ۸۸ درصد و خطای تشخیص نیز در حدود ۰/۱ می‌باشد که می‌توان نتیجه گرفت با استفاده از روش معرفی شده در این تحقیق، امکان شناسایی فیچرهای ماشین‌کاری در یک قطعه از طریق تصویر با دقت قابل قبول و حل برخی از مشکلات روش‌های قبلی از جمله مشکل تداخل هندسی فیچرها وجود دارد.

۵- مراجع

[1] Babic BR, Nesic N, Miljkovic Z. Automatic feature recognition using artificial neural networks to integrate design and manufacturing: Review of automatic feature recognition systems. Artificial Intelligence for Engineering Design, Analysis and Manufacturing: AI EDAM. 2011 Aug 1;25(3):289.

[2] Zhang Z, Jaiswal P, Rai R. Featurenet: Machining feature recognition based on 3d convolution neural network. Computer-Aided Design. 2018 Aug 1;101:12-22.

[3] Babic B, Nesic N, Miljkovic Z. A review of automated feature recognition with rule-based pattern recognition. Computers in industry. 2008 Apr 1;59(4):321-37.

[4] Brousseau E. Intelligent techniques for automatic feature recognition in CAD models. Cardiff University (United Kingdom); 2005.

[5] Devireddy CR. Feature-based modelling and neural networks-based CAPP for integrated manufacturing. International Journal of Computer Integrated Manufacturing. 1999 Jan 1;12(1):61-74.

[6] Shi Y, Zhang Y, Xia K, Harik R. A Critical review of feature recognition techniques. Computer-Aided Design and Applications. 2020;17(5):861-99.

[7] Prabhakar S, Henderson MR. Automatic form-feature recognition using neural-network-based techniques on boundary representations of solid models. Computer-Aided Design. 1992 Jul 1;24(7):381-93.

[8] LeCun Y, Bottou L, Bengio Y, Haffner P. Gradient-based learning applied to document recognition. Proceedings of the IEEE. 1998 Nov;86(11):2278-324.

[9] Shi P, Qi Q, Qin Y, Scott PJ, Jiang X. A novel learning-based feature recognition method using multiple sectional view representation. Journal of Intelligent Manufacturing. 2020 Jan 22:1-9.

[10] Yeo C, Kim BC, Cheon S, Lee J, Mun D. Machining feature recognition based on deep neural networks to support tight integration with 3D CAD systems. Scientific reports. 2021 Nov 12;11(1):1-20.

[11] Balu A, Ghadai S, Lore KG, Young G, Krishnamurthy A, Sarkar S. Learning localized geometric features using 3d-cnn: An application to manufacturability analysis of drilled holes. arXiv preprint arXiv:1612.02141. 2016 Dec 7.

[12] Lambourne JG, Willis KD, Jayaraman PK, Sanghi A, Meltzer P, Shayani H. BRepNet: A topological message passing system for solid models. InProceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition 2021 (pp. 12773-12782).

[13] Colligan AR, Robinson TT, Nolan DC, Hua Y, Cao W. Hierarchical CADNet: Learning from B-Reps for Machining Feature Recognition. Computer-Aided Design. 2022 Jun 1;147:103226.

[14] Moreno-García CF, Elyan E, Jayne C. New trends on digitisation of complex engineering drawings. Neural computing and applications. 2019 Jun 1;31(6):1695-712.

[15] Zhao Y, Deng X, Lai H. A deep learning-based method to detect components from scanned structural drawings for reconstructing 3D models. Applied Sciences. 2020 Mar 19;10(6):2066.

[16] Bolón-Canedo V, Remeseiro B. Feature selection in image analysis: a survey. Artificial Intelligence Review. 2019 Aug 9:1-27.

[17] Redmon J, Divvala S, Girshick R, Farhadi A. You only look once: Unified, real-time object detection. InProceedings of the IEEE conference on computer vision and pattern recognition 2016 (pp. 779-788).