



Machining Features Recognition from Image of Mechanical Parts with The Help of Deep Learning Technic

ARTICLE INFO

Article Type

Original Research

Authors

Mohammadi N.,¹
Nategh M J.^{1*}

How to cite this article

Mohammadi N, Nategh M J. Machining Features Recognition from Image of Mechanical Parts with The Help of Deep Learning Technic. Modares Mechanical Engineering, 2023;23(06):337-345.

¹ Mechanical Engineering Department, Tarbiat Modares University, Tehran, Iran.

*Correspondence

Address: Tarbiat Modares University Jalal AleAhmad St. Tehran, Iran.
P.O.Box: 14115-111.
Nategh@modares.ac.ir

Article History

Received: February 05, 2023
Accepted: March 03, 2023
ePublished: June 16, 2023

ABSTRACT

In the production of industrial parts, machining is one of the most important operations in the field of manufacturing parts. The production of an industrial part takes place in three stages: design, process planning and manufacturing, and in all these stages, the computer is used as a powerful tool. In computer-aided process planning, the stage of identifying machining features is a prerequisite and an introduction to the next steps. Extracting information and identifying features from computer-aided design information has been continuously improved due to the increasing complexity of parts, but the research to find an optimal solution is endless. Over the past few decades, several methods have been introduced and applied by researchers to extract and identify machining features from design file information. In all the previous methods, the number and type of features are extracted as independent variables in the machining features identification pattern and from the part design file data. In this research, the characteristics required to identify the machining features are extracted from the pixel values of the machining feature image by the artificial intelligence system automatically. The artificial intelligence system produced to identify the machining features in this research is able to identify all the information required for machining, including the name, the coordinates of the location of the feature relative to the part, and the dimensions required for the machining, by viewing the image of a part, and the information of the features present in the image the input to the system in a table.

Keywords Machining Feature Recognition, Computer-Aided Process Planning, Artificial Intelligence Depth Learning

CITATION LINKS

1- Semantic approach to the automatic recognition of machining feature. 2- Defining, recognizing and representing feature interactions in a feature-based data model. 3- A review of machining feature recognition methodologies. 4- Graph based automatic process planning system for multi-tasking machine. 5- Hint-based generic shape feature recognition from three-dimensional B-rep models. 6- State of The Art-Intense Review on Artificial Intelligence Systems Application in Process Planning and Manufacturing. 7- Improving neural networks by preventing co-adaptation of feature detectors. 8- Adjacency Matrix based Face Recognition Approach. 9- Automated latent fingerprint recognition. 10- Deep structured output learning for unconstrained text recognition. 11- Speech recognition with deep recurrent neural networks. 12- Face-based feature recognition: generalizing special cases. 13- Computer aided process planning: the state-of-the-art survey. 14- A review of automated feature recognition with rule-based pattern recognition. 15- A hybrid neural network-feature-based manufacturability analysis of mould reinforced plastic parts. 16- Recognition of interacting rotational and prismatic machining features from 3-D mill-turn parts. 17- Graph-based heuristics for recognition of machined features from a 3D solid model. 18- STEP-based feature extraction from STEP geometry for agile manufacturing. 19- Implementation of STEP Application Protocol 224 in an automated manufacturing planning system. 20- Extraction/conversion of geometric dimensions and tolerances for machining features. 21- Extraction of machining features for CAD/CAM integration. 22- An Evaluation of Convolutional Neural Network Models for Object Detection in Images on Low-End Devices

شناسایی فیچرهای ماشین‌کاری از تصویر قطعات مکانیکی با کمک تکنیک یادگیری

عمیق

ناصر محمدی^۱، محمدجواد ناطق^{۱*}

^۱ گروه ساخت و تولید دانشکده مهندسی مکانیک، دانشگاه تر بیت مدرس، تهران، ایران

چکیده

در تولید قطعات صنعتی، ماشین‌کاری از مهم‌ترین عملیاتی است که در حوزه ساخت قطعات مطرح است. تولید یک قطعه صنعتی در سه مرحله طراحی، طرح‌ریزی فرآیند و ساخت صورت می‌گیرد و در کلیه این مراحل، از کامپیوتر به عنوان یک ابزار قدرتمند، استفاده فراوانی شده است. در طرح‌ریزی فرآیند به کمک کامپیوتر، مرحله شناسایی فیچرهای ماشین‌کاری پیش‌نیاز و مقدمه مراحل بعدی می‌باشد. استخراج اطلاعات و شناسایی فیچرها از اطلاعات طراحی به کمک کامپیوتر با توجه به افزایش پیچیدگی قطعات، به صورت دائم بهبود یافته است لیکن تحقیق برای یافتن یک راه حل بهینه پایان ناپذیر است. طی چند دهه گذشته، برای استخراج و شناسایی فیچرهای ماشین‌کاری از اطلاعات فایل طراحی، روش‌های متعددی توسط محققین معرفی و به کارگیری شده است. در کلیه روش‌هایی که تاکنون توسط محققین معرفی و ارائه گردیده است، تعداد و نوع ویژگی‌ها به عنوان متغیرهای مستقل در الگوی شناسایی فیچرهای ماشین‌کاری، توسط طراح الگو و از داده‌های فایل طراحی قطعه استخراج می‌گردد. در این تحقیق ویژگی‌های مورد نیاز برای شناسایی فیچرهای ماشین‌کاری از مقادیر پیکسل‌های تصویر شکل فیچرها و توسط سامانه هوش مصنوعی و بصورت خودکار استخراج می‌گردد. سامانه هوش مصنوعی تولید شده برای شناسایی فیچرهای ماشین‌کاری در این تحقیق قادر است با مشاهده تصویر یک قطعه، کلیه اطلاعات مورد نیاز برای ماشین‌کاری از جمله نام، مختصات محل قرارگیری فیچر نسبت به قطعه و ابعاد مورد نیاز برای ماشین‌کاری قطعه را شناسایی نماید و اطلاعات فیچرهای موجود در تصویر ورودی به سامانه را در یک جدول ارائه دهد.

کلیدواژه‌ها: شناسایی فیچرهای ماشین‌کاری، طرح ریزی فرآیند به کمک کامپیوتر، یادگیری عمیق

تاریخ دریافت: ۱۴۰۱/۱۱/۱۶

تاریخ پذیرش: ۱۴۰۲/۰۳/۱۱

* نویسنده مسئول: Nategh@modares.ac.ir

۱- مقدمه

به طور معمول برای ساخت یک قطعه، اولین مرحله، مرحله طراحی یک قطعه است که طراح با توجه به نیاز و یا یک ایده جدید و با دانش مهندسی اقدام به طراحی قطعه می‌نماید. طرح ارائه شده توسط مهندس طراح سپس برای تعیین چگونگی مراحل ساخت وارد مرحله طرح‌ریزی فرآیند می‌گردد. در مرحله طرح‌ریزی فرآیند، گام‌ها و مراحل که یک قطعه با توجه به امکانات موجود ساخت از جمله قید و بندها، ماشین‌آلات، نوع و شکل هندسی قطعه، ابعاد و دقت ماشین‌کاری مورد نیاز وسایر شرایط، توسط مهندس طراح فرآیند تعیین می‌شود. در مرحله آخر نیز قطعه توسط ماشین‌آلات ساخت، تولید می‌گردد.

در خروجی اطلاعات طراحی، قطعه‌کار به عنوان یک سری از فیچرهای طراحی و ساخت تشریح و مدل می‌شود که هر فیچر می‌تواند توسط چند عملیات ماشین‌کاری تولید شود. در واقع فیچرها، اطلاعات ماشین‌کاری هستند که در طرح‌ریزی فرآیند به کمک کامپیوتر به کارگیری می‌شوند. در روش‌های معمول شناسایی فیچرهای ماشین‌کاری اطلاعات طراحی قطعه، که در هر یک از نرم افزارهای طراحی تعاریف منحصر به آن نرم افزار را دارد به عنوان اطلاعات ورودی سیستم‌های استخراج فیچرهای ماشین‌کاری به کار برده می‌شود. در سیستم‌های فعلی شناسایی و استخراج فیچرهای ماشین‌کاری از اطلاعات طراحی، روش‌های متنوعی بکار گرفته شده است. برخی از معروف‌ترین روش‌هایی که تاکنون به کارگیری شده‌اند عبارتند از روش گراف‌مبنا، روش تجزیه احجام، روش نشانه مبنا، روش‌های ترکیبی و روش مبتنی بر هوش مصنوعی^[1]. در کلیه این روش‌ها، با کمک الگوریتم‌های متنوع شناسایی و استخراج فیچرهای ماشین‌کاری، با استفاده از اطلاعات اولیه نرم افزار طراحی که در یک فایل خنثی ذخیره شده است، فیچر مربوطه شناسایی می‌شود.

مرحله طرح ریزی فرآیند ساخت به کمک کامپیوتر مشتمل بر تبادل اطلاعات بین مرحله طراحی و مرحله ساخت است و با توجه به این که غالباً طراحی و ساخت در دو شرکت مستقل و حتی در دو کشور متفاوت صورت می‌گیرد و هر شرکت از استانداردها و و نیازمندی‌های نرم‌افزار خود تبعیت می‌کند که این الزامات ممکن است شامل ورژن نرم افزار مورد استفاده، رویکرد مدل‌سازی مجزا و نام‌گذاری و وجود پسوندهای متفاوت برای نرم‌افزارهای مختلف باشد، لذا استفاده از روش استخراج فیچرها از یک تصویر (به‌عنوان یک فرمت و زبان مشترک) برای کاهش هزینه، کاهش زمان و افزایش قابلیت‌های ساخت و تولید قطعات روش بسیار موثری خواهد بود. روش‌های فعلی استخراج فیچرهای ماشین‌کاری علیرغم پیشرفت‌های زیادی که تاکنون داشته است دارای ضعف‌ها و مشکلاتی نیز می‌باشد که با توجه به رشد سریع فناوری در کلیه رشته‌ها خصوصاً در حوزه استفاده از کامپیوتر و به کارگیری آخرین یافته‌ها در حوزه فن‌آوری اطلاعات در شناسایی و استخراج فیچرهای ماشین‌کاری می‌تواند علاوه بر برطرف کردن نقاط ضعف فعلی، پنجره جدیدی در طرح‌ریزی فرآیند به کمک کامپیوتر باز نماید. برخی از مشکلات روش‌های فعلی استخراج فیچرهای ماشین‌کاری که در مراجع مختلف از جمله^[1,2] به آنها اشاره شده است به شرح زیر می‌باشد:

- حذف برخی از اطلاعات در فرآیند تبدیل اطلاعات از فایل طراحی به کمک کامپیوتر به الگوریتم‌های شناسایی؛
- تفسیرهای متفاوت از یک قطعه با توجه به وجود روش‌های متفاوت؛
- عدم توانمندی در شناسایی تداخل فیچرها؛
- نیاز به وجود یک فایل خنثی حاوی اطلاعات اولیه؛

شناسایی صدا^[11] و بسیاری از حوزه‌های دیگر مورد استفاده قرار گرفته است.

پیشینه روش‌های سنتی شناسایی فیچرهای ماشین‌کاری به اواخر دهه ۱۹۸۰ میلادی بر می‌گردد^[12]. کاپریانو در اواخر دهه ۱۹۸۰ میلادی در تحقیق خود مفهومی بنام نمایش مرز معرفی کرد که حاوی اطلاعات سطوح و مرزهای یک جسم صلب بود. این مفهوم تا سالیان متممادی به عنوان یک مبنا در شناسایی فیچرهای ماشین‌کاری مورد استفاده قرار گرفته است. الگوی نمایش مرز به‌عنوان اصلی‌ترین الگوی شناسایی فیچرهای ماشین‌کاری در همه روش‌های موجود به کار رفته است چرا که این رویکرد به صورت یکتا صفحات و مرزها را در یک جسم جامد تعریف می‌نماید^[13].

در سال ۲۰۰۷ میلادی بوجان بابیک و همکاران در تحقیقی که با عنوان مروری بر شناسایی اتوماتیک فیچر با استفاده از یک الگوی شناسایی قاعده‌مند، ارائه دادند، دسته بندی جامعی از انواع روش‌هایی که تا سال ۲۰۰۷ جهت شناسایی فیچرها ابداع و به کارگیری شده بود ارائه دادند^[14]. آنها انواع روش‌های شناسایی فیچرها را به سه گروه طراحی بر اساس فیچر، شناسایی اتوماتیک فیچر و شناسایی تعاملی شکل فیچر دسته بندی نمودند.

در طراحی بر اساس فیچر، فیچرها بر اساس الگوهای از قبل تعیین شده فیچر در مرحله طراحی که در کتابخانه نرم افزار طراحی موجود است، طراحی می‌شوند^[15]. در روش شناسایی اتوماتیک فیچرها از روش جستجوی اطلاعات نمایش مرزی یک جسم صلب برای یافتن یک شکل خاص از فیچر استفاده می‌شود. در این روش، هدف در کلیه تحقیقات انجام شده مبتنی بر یافتن یک الگوریتم مناسب برای شناسایی هر نوع فیچر ماشین‌کاری می‌باشد. شناسایی تعاملی شکل فیچر نیز سیستمی است که در آن یک کاربر مجموعه‌ای از الگوهای فیچر را انتخاب نموده و برای فیچر انتخابی پارامترهای لازم را تعریف می‌نماید^[16].

از میان روش‌های ذکر شده روش طراحی بر اساس فیچر و روش شناسایی تعاملی شکل فیچر با توجه به وجود مشکلات ساختاری مورد استقبال محققان قرار نگرفت لیکن در خصوص روش شناسایی اتوماتیک فیچرهای ماشین‌کاری تحقیقات فراوانی انجام شده است.

بوجان بابیک و همکاران^[14] در تحقیق خود شناسایی اتوماتیک فیچرها را به سه مرحله تقسیم نمودند. استخراج ویژگی‌های هندسی از فایل طراحی به‌کمک کامپیوتر، اولین مرحله شناسایی اتوماتیک فیچر می‌باشد. در این مرحله اطلاعات سطح پایین مانند گوشه، لبه و سطح از خروجی فایل طراحی استخراج می‌شود. استخراج این اطلاعات بر اساس رویکرد نمایش مرز، رویکرد ساختار هندسه جسم و یا در موارد معدودی از رویکرد نمایش خطی چارچوب صورت می‌گیرد.

- منحصر به فرد بودن اطلاعات هر یک از نرم افزارهای طراحی به‌کمک کامپیوتر و عدم امکان استفاده از اطلاعات همین نرم افزار در یک سیستم دیگر؛

- نیاز به فضا، زمان پردازش و حافظه بالا بدلیل نیاز به تبدیل مکرر اطلاعات به یکدیگر.

با استفاده از روش یادگیری عمیق علاوه بر رفع کلیه مشکلات ذکر شده، وابستگی زنجیره طراحی به‌کمک کامپیوتر، طرح‌ریزی فرآیند به‌کمک کامپیوتر و ساخت به‌کمک کامپیوتر با یکدیگر از حیث انتقال داده‌های خام از بین می‌رود ولی با حذف این وابستگی، ارتباط آنها از میان نمی‌رود و مشکلی ایجاد نمی‌کند. این وابستگی سبب بروز برخی محدودیت‌ها در تولید قطعات می‌گردد که مشکلات پیش گفته شده ناشی از برخی از این محدودیت‌ها می‌باشد.


با نگاهی به روند توسعه تحقیقات انجام شده در زمینه طرح‌ریزی فرآیند به‌کمک کامپیوتر مشاهده می‌گردد که عمده توسعه روش‌های موجود خصوصاً در حوزه شناسایی اتوماتیک فیچرهای ماشین‌کاری مربوط به تکمیل روش‌های مشهور استخراج فیچرهای ماشین‌کاری از جمله روش گراف‌مینا و سایر روش‌ها می‌باشد^[3]. به عنوان مثال توسعه روش گراف‌مینا برای قابلیت شناسایی تداخل تکنیکی^[4,5] همگی بر روی افزایش قابلیت‌های روش‌های موجود هستند که این روش‌ها عمدتاً بین سال‌های ۱۹۸۰ تا ۲۰۱۰ میلادی ابداع و به کارگیری شده‌اند^[3] و هیچ نظریه جدیدی در چند سال اخیر روش‌های شناسایی فیچرهای ماشین‌کاری را به صورت بنیادی تغییر نداده است. آخرین پیشرفت‌های بنیادی مربوط به شناسایی فیچرهای ماشین‌کاری مربوط به استفاده از شبکه عصبی در شناسایی فیچرهای ماشین‌کاری می‌باشد^[6]. روش شناسایی فیچرها به‌کمک شبکه عصبی نیز مانند سایر روش‌ها، مبتنی بر استفاده از داده‌های خام فایل خنثی (اطلاعات خروجی سیستم طراحی به‌کمک کامپیوتر) می‌باشد و اشکالات روش‌های سنتی شناسایی فیچرهای ماشین‌کاری مانند وجود فرمت‌های مختلف فایل داده‌های ورودی به سامانه شناسایی فیچرهای ماشین‌کاری را کم و بیش دارا می‌باشد و لذا استفاده از شبکه‌های عصبی در طرح‌ریزی فرآیند نیز به واسطه عدم کارایی مطلوب، مورد توجه جدی محققان قرار نگرفته است. از طرفی نگاهی اجمالی به تعداد تحقیقات انجام شده در حوزه شناسایی فیچرها در سال‌های اخیر^[3] حاکی از اشباع شدن پیشرفت‌ها در این زمینه با رویکردهای موجود می‌باشد.

یادگیری عمیق که مبنای روش پیشنهادی بوده و در رده آخرین پیشرفت‌های حوزه هوش مصنوعی و بینایی کامپیوتر می‌باشد که از سال ۲۰۱۲ توسط الکس کریژوسکی و جفری هینتون^[7] پایه‌گذاری شده است و در بیشتر حوزه‌های علمی از جمله پزشکی، شناسایی چهره^[8]، شناسایی اثر انگشت^[9]، شناسایی متن^[10]،

برای تبدیل یک تصویر به معادل یک آرایه متشکل از اعداد صفر و یک، می‌توان از نرم افزارهای مختلفی استفاده نمود. یکی از نرم افزارهای قدرتمند در این زمینه نرم افزار متلب می باشد. به عنوان مثال برای نشان دادن چگونگی این تبدیل، در شکل ۱ تصویر یک هگزاپاد با کمک نرم افزار متلب به یک آرایه صفر و یک (خروجی تصویر سیاه و سفید) تبدیل شده است.



(الف)



(ب)

شکل ۱ تصویر دودویی یک هگزاپاد، الف) آنچه انسان می‌بیند، ب) آنچه یک کامپیوتر می‌بیند.

پس از تبدیل تصویر قطعات مکانیکی به آرایه‌ایی از اعداد، برای استخراج ویژگی‌های منحصر به فرد تصویر یک قطعه مکانیکی در هوش مصنوعی و یادگیری عمیق، آرایه اعداد تصویر در یک آرایه جدید بنام آرایه فیلتر یا کرنل ضرب کانولوشن می‌شود. کانولوشن یا همگشت یک عملگر ریاضی است که بر روی دو تابع مانند f و g عمل کرده و تابع سومی را ایجاد می‌کند که می‌تواند به‌عنوان نسخه اصلاح شده یکی از دو تابع به کار گرفته شود. در شبکه عصبی کانولوشنی چنانچه تابع f را تابعی که آرایه دو بعدی یک تصویر را معرفی می‌کند در نظر بگیریم و تابع g را یک آرایه چند بعدی در نظر بگیریم که برای استخراج ویژگی‌ها، این تصویر مورد استفاده قرار می‌گیرد، با انجام ضرب کانولوشن تابع g در تابع تصویر (تابع f) می‌توان تصویر سومی بدست آورد که ویژگی‌های مورد نیاز را دارا باشد.

در مرحله دوم یک تعریف مناسب برای نمایش الگوی شکل قطعه آرایه می‌گردد. در این مرحله برای سیستم‌های مبتنی بر نمایش مرز و یا نمایش چارچوب سیمی، مختصات هندسی قطعه به مختصات مکانی آن متصل می‌گردد در حالی‌که در سیستم‌های مبتنی بر ساختار هندسه جسم، ویژگی‌های اولیه هندسی از طریق عملگرهای جبر خطی به یکدیگر متصل می‌گردند[17]. در مرحله سوم الگوی فیچر شناسایی با تکیه بر مراحل قبلی از کتابخانه فیچرهای موجود و یا در سیستم‌های پیشرفته‌تر، با کمک هوش مصنوعی به‌عنوان یک فیچر جدید شناسایی می‌شوند.

در غالب تحقیقات شناسایی اتوماتیک فیچرها مراحل اول و دوم تحت عنوان استخراج فیچر و مراحل دوم و سوم تحت عنوان شناسایی فیچر شناخته می‌شود. همه روش‌های استخراج ویژگی‌ها از فایل طراحی به‌کمک کامپیوتر عمدتاً یا از طریق پروتکل رابط کاربری برای دستیابی به اطلاعات هندسی و توپولوژیکال قطعه استفاده می‌کند و یا از اطلاعات فایل خنثی که حاوی اطلاعات خام هندسی و توپولوژیکی نرم‌افزارهای طراحی می‌باشد، استفاده می‌کند. در مراجع [18-21] برخی از تحقیقاتی که در خصوص استخراج ویژگی از فایل خنثی انجام شده است ذکر گردیده است.

۲- مبانی مفهومی

داده‌کاوی یکی از مفاهیم بنیادی در کلیه روش‌های هوش مصنوعی می‌باشد. استفاده از داده‌های ورودی به مسئله و بکارگیری روابط ریاضی در داده‌کاوی و دسته بندی داده‌ها جهت تفکیک مفاهیم و موضوعات، از مهمترین رویکردهای مبانی مفهومی روش بکارگیری شده در شناسایی فیچرهای ماشین‌کاری می باشد. این موضوعات شامل اهدافی هستند که با شناسایی و تفکیک آنها در یک تصویر حاوی قطعه مکانیکی، امکان شناسایی فیچر ماشین‌کاری در تصویر قطعه فراهم می گردد.

برای شناسایی هر یک از این اهداف در یک تصویر، لازم است یک سری مشخصه‌های منحصر بفرد از هر یک از این اهداف تعریف و بکارگیری نمود. این مشخصه‌ها در تکنیک‌های شناسایی تصویر به ویژگی هدف شناخته می‌شود. در شناسایی تصویر هر فیچر ابتدا لازم است اطلاعات موجود بصورت اعداد مشخص و منحصر بفرد تبدیل شود. برای این کار اولین گام تبدیل تصویر یک قطعه به یک عدد مشخص می باشد. در تصاویر رنگی، یک تصویر ترکیبی از سه رنگ اصلی قرمز، سبز و سیاه (RGB) می‌باشد که هر رنگ می‌تواند شدتی بین صفر تا ۲۵۶ داشته باشد. در تصاویر سیاه و سفید یک تصویر را می‌توان با اعداد صفر و یک (یک، نقاط سیاه و صفر نقاط سفید) نمایش داد.

اعداد مشخصه مختص هر فیچر بدلائل مختلف از جمله وجود چرخش در شکل قطعه کار در تصویر، اندازه قطعه کار در تصویر با ابعاد ثابت و یا تفاوت رنگ (بدلیل تفاوت جنس متریال قطعه) ممکن است نتواند تمایز و تفکیک لازم برای دسته‌بندی فیچرهای مختلف را ایجاد کند.

برای حل این مشکل در شبکه‌های یادگیری عمیق از توابع غیر خطی متفاوتی استفاده می‌گردد. به این منظور کلیه عناصر حاصل از ضرب کانولوشن فیلترها در تصویر قطعه از یک تابع غیر خطی عبور داده می‌شود تا اعداد مشخصه شکل هر فیچر با در نظر گرفتن ابعاد، چرخش رنگ و سایر ویژگی‌ها در یک محدود خاص از اعداد قرار گیرد به نحوی که بتوان عدد مشخصه بدست آمده برای شکل هر فیچر را با کمک روابط ذکر شده در یک بازه مشخص از اعداد محدود نمود. با استفاده از این تکنیک سامانه معرفی شده در این تحقیق قادر است هر یک از فیچرهای ماشین‌کاری را با زوایای مختلف قابل مشاهده در تصویر و یا با متریال و رنگ‌های متنوع را شناسایی نماید. در این تحقیق از رابطه غیر خطی زیر به این منظور استفاده گردیده است.

$$\hat{z}(x, y) = z(x, y) \tanh(\ln(1 + e^{z(x, y)})) \quad (۳)$$

برای تعیین مقادیر عناصر آرایه هر یک از کرنل‌ها، پس از طراحی شبکه و تعیین تعداد کرنل‌ها، در ابتدا به هریک از عناصر آرایه کرنل‌ها یک مقدار اولیه بصورت اختیاری اختصاص داده می‌شود. سپس مقادیر اختیاری اولیه در آرایه پیکسل‌های تصویر یک قطعه کار مشخص ضرب می‌گردد (رابطه ۱) و با اعمال تابع غیر خطی (رابطه ۳) بر روی نتایج حاصل، عدد مشخصه بدست آمده برای شکل فیچر موجود در تصویر ثبت می‌گردد. این عملیات برای تعداد معتناهی از تصاویر حاوی فیچرهای مختلف تکرار می‌شود تا بازه اعداد مشخصه مختص شکل هر یک فیچرها مشخص گردد.

در مرحله بعد یک تصویر حاوی شکل فیچر جدید به شبکه وارد می‌گردد. چنانچه عدد مشخصه بدست آمده در بازه اعداد مختص هر فیچر که در مرحله قبل بدست آمده است قرار داشته باشد، بازه مذکور بعنوان بازه اعداد مشخصه شکل هر فیچر پذیرفته می‌شود و در غیر اینصورت لازم است مقادیر عناصر آرایه کرنل‌ها به روز رسانی شود. چنانچه عدد مشخصه تصویر فیچر ورودی برای سنجش میزان دقت شناسایی شبکه را N_i و بازه اعداد مشخصه فیچر موجود در تصویر را N_0 بنامیم، مقدار خطای تشخیص شبکه را می‌توان بصورت زیر نمایش داد:

$$E = N_0 - N_i \quad (۴)$$

چنانچه مقدار خطا (مقدار E در رابطه ۴) از یک مقدار مطلوب تجاوز نماید لازم است با به روز رسانی مقادیر عناصر آرایه کرنل، مقدار خطا را کاهش و به مقدار مطلوب رسانده شود. مرحله به روز رسانی این ضرایب بعنوان مرحله آموزش شبکه هوش

در شبکه عصبی یادگیری عمیق، تابع g را تابع فیلتر یا کرنل (Kernel) می‌گویند که مقادیر نهایی این تابع بایستی در فرآیند آموزش شبکه تعیین گردد.

۳- مبانی ریاضی روش پیشنهادی

چنانچه هر یک از مقادیر آرایه پیکسل‌های تصویر یک فیچر را $f(x, y)$ و مقادیر عناصر آرایه کرنل را با تابع $g(x, y)$ نمایش دهیم، از ضرب همگشت (کانولوشن) عناصر آرایه کرنل در عناصر آرایه پیکسل‌های تصویر یک آرایه جدید حاصل خواهد شد که هر یک از عناصر آرایه جدید، مقادیر پیکسل‌های یک تصویر جدید است که در این تصویر جدید یک سری ویژگی‌های منحصر به فرد مربوط به هر یک از فیچرهای ماشین‌کاری را می‌توان با انتخاب مقادیر مناسب عناصر آرایه کرنل بدست آورد. چنانچه آرایه حاصل از ضرب کانولوشن را $z(x, y)$ بنامیم خواهیم داشت:

$$\begin{bmatrix} x_{1,1} & x_{1,2} & x_{1,3} & x_{1,4} & x_{1,5} & x_{1,6} \\ x_{2,1} & x_{2,2} & x_{2,3} & x_{2,4} & x_{2,5} & x_{2,6} \\ x_{3,1} & x_{3,2} & x_{3,3} & x_{3,4} & x_{3,5} & x_{3,6} \\ x_{4,1} & x_{4,2} & x_{4,3} & x_{4,4} & x_{4,5} & x_{4,6} \\ x_{5,1} & x_{5,2} & x_{5,3} & x_{5,4} & x_{5,5} & x_{5,6} \\ x_{6,1} & x_{6,2} & x_{6,3} & x_{6,4} & x_{6,5} & x_{6,6} \end{bmatrix} \times \begin{bmatrix} w_{1,1} & w_{1,2} \\ w_{2,1} & w_{2,2} \end{bmatrix} = \begin{bmatrix} z_{1,1} & z_{1,2} & z_{1,3} & z_{1,4} & z_{1,5} \\ z_{2,1} & z_{2,2} & z_{2,3} & z_{2,4} & z_{2,5} \\ z_{3,1} & z_{3,2} & z_{3,3} & z_{3,4} & z_{3,5} \\ z_{4,1} & z_{4,2} & z_{4,3} & z_{4,4} & z_{4,5} \\ z_{5,1} & z_{5,2} & z_{5,3} & z_{5,4} & z_{5,5} \end{bmatrix}$$

و یا :


$$f(x, y) \times g(x, y) = z(x, y) \quad (۱)$$

در رابطه ۲ هر یک از مولفه‌های تابع $f(x, y)$ (عناصر آرایه پیکسل‌های تصویر) با $x_{i,j}$ و هر یک از مولفه‌های تابع $g(x, y)$ (عناصر آرایه کرنل) با $w_{i,j}$ نشان داده شده‌اند. مولفه‌های آرایه $z(x, y)$ با $z_{i,j}$ نشان داده می‌شود و از رابطه زیر استخراج می‌گردد:

$$z_{i,j} = \sum_a \sum_b w_{a,b} x_{(i+a)(j+b)} \quad (۲)$$

تعیین عناصر تابع کرنل (تابع $g(x, y)$) یکی از موضوعات مهم تحقیق می‌باشد که در واقع با تعیین عناصر این آرایه، وزن‌های شبکه عصبی یادگیری عمیق به نحوی تعیین و آموزش داده می‌شود که بتواند فیچرهای ماشین‌کاری را بدرستی تشخیص دهد. با تعیین مقدار مناسب برای ضرایب آرایه $g(x, y)$ می‌توان برخی از ویژگی‌های متمایز کنند شکل هر فیچر را برجسته و با ضرب این ضرایب در نواحی مختلف تصویر قطعه، وجه تمایز تصویر هر فیچر نسبت به سایر فیچرها را بزرگ‌نمایی نمود.

تعیین مقادیر عناصر آرایه $g(x, y)$ به نحوی که بتواند تمایز کافی در مقدار مشخصه متناظر با تصویر هر فیچر ماشین‌کاری ایجاد نماید، در مرحله آموزش شبکه هوش مصنوعی صورت می‌گیرد. علاوه بر تعیین مقادیر مناسب عناصر آرایه $g(x, y)$



شکل ۲) برچسب گذاری یک قطعه مرکب از دو فیچر ماشین کاری سطح شیبدار و گوشه داخلی

جدول ۱) اطلاعات متنی فیچرهای برچسب گذاری شده در شکل ۲

Class	width	height	X(min)	Y(min)	X(max)	Y(max)
Chamfer	۱۴۶	۱۳۹	۲۴۹	۸۰	۴۰۱	۳۶۰
Fillet	۱۲۰	۱۰۷	۱۲۸	۲۴۳	۲۱۳	۴۳۶

در گام بعدی تمام داده‌های متنی برچسب‌گذاری شده تصاویر بانک داده تحقیق بصورت رکوردهای مجزا در دو فایل جداگانه اکسل با فرمت CSV یکی برای شکل و موقعیت ابعاد و اندازه‌ها و دیگری برای اعداد، حروف و متن‌های درج شده بر روی هر فیچر ماشین کاری ذخیره گردید.

در آخرین مرحله از آماده‌سازی داده‌ها، هر یک از دو فایل با فرمت CSV به یک فایل با فرمت TF record تبدیل گردید که داده‌های بانک داده را به یک فرمت باینری قابل درک توسط کامپیوتر تبدیل می‌کند. اطلاعات مذکور سبب می‌شود که سامانه شناسایی فیچرهای ماشین کاری، ویژگی‌های مورد نیاز برای شناسایی شکل فیچر و یا سایر اطلاعات مربوط به هر یک از فیچرهای مشاهده شده در بخشی از تصویر که حاوی اطلاعات قابل رویت در تصویر است را در یک کادر مستطیلی محدود نماید و با استفاده از پیکسل‌های تشکیل دهنده تصویر در محدوده کادر برچسب‌گذاری شده بدست آورد. برای به چالش کشاندن تشخیص شبکه و افزایش قدرت شناسایی آن از تکنیک دست‌کاری داده‌ها (Augmentation) از قبیل چرخش تصویر، رسم خطوط غیر موازی به صورت تصادفی و سایر تکنیک‌ها استفاده گردید.

۵- بررسی نتایج

برای ارزیابی توانمندی سامانه هوش مصنوعی تولید شده در این تحقیق برای شناسایی مشخصات کامل فیچرهای ماشین کاری از معیار ارزیابی میانگین صحت تشخیص (AP)، معیار ارزیابی میانگین حساسیت به تشخیص‌های نادرست (AR) و معیار ارزیابی کاپا (Kappa Indexes) بطور مستقل برای شناسایی اعداد و اندازه‌ها و شناسایی شکل فیچرها و موقعیت قرارگیری ابعاد و اندازه‌ها استفاده گردید. به این منظور نتایج تشخیص سامانه در شناسایی حدود ۱۰۰۰ کارکتر شامل اعداد، حروف و علایمی مانند پرانتز، کاما، نقطه اعشار و علایم مثبت و منفی (برای تشخیص تترانس‌های اندازه گذاری بر روی فیچرها) و نیز نتایج تشخیص

مصنوعی شناخته می‌شود. مدل ریاضی به روز رسانی و نهایی سازی این ضرایب با مشتق گیری از رابطه خطا (رابطه ۶) نسبت به عناصر آرایه $g(x, y)$ صورت می‌گیرد:

$$N_i = f(f(x, y), g(x, y)) \quad (5)$$


$$g(x, y)_{new} = \frac{\partial E}{\partial w} \quad (6)$$

با توجه به وجود تعداد زیادی از عناصر آرایه کرنل‌ها در یک شبکه هوش مصنوعی، کاهش همزمان کلیه این ضرایب نیاز به انجام برخی تنظیمات از جمله میزان کاهش نرخ شیب منحنی عناصر تابع $g(x, y)$ نسبت به تابع خطا (تابع E) و سایر پارامترهای شبکه هوش مصنوعی می‌باشد.

۴- تولید شبکه هوش مصنوعی شناسایی فیچرهای ماشین کاری


برای تهیه بانک اطلاعاتی سامانه هوش مصنوعی یادگیری عمیق در این تحقیق تعداد ۱۰ هزار تصویر با فرمت‌های وایرفریم، ایزومتریک، دی‌متریک و تصویر معمولی (عکس) هر فیچر و ترکیبات مختلف این فیچرها از زوایای مختلف و با مترال مختلف توسط نرم‌افزار سالیید ورکس تهیه گردید. برای محاسبه مقادیر نهایی عناصر آرایه کرنل‌ها (آموزش شبکه یادگیری عمیق)، لازم است تصاویر و اطلاعات موجود در بانک اطلاعاتی، به اطلاعات مورد نیاز برای آموزش شبکه تبدیل گردد. به این منظور با استفاده از زبان برنامه نویسی پایتون، تمامی تصاویر بانک داده با ابعاد مختلف به ابعاد ثابت ۴۸۰ در ۴۸۰ پیکسل تبدیل شدند. در گام بعدی برای بدست آوردن تناسب ابعاد تصاویر و تعیین محدوده قرارگیری پیکسل‌های شکل هر فیچر در تصویر، یک کادر مستطیلی بصورت دستی اطراف هر یک از فیچرها در کلیه تصاویر بانک داده ترسیم گردید. تعیین محدوده هر فیچر در بانک داده تحقیق برچسب‌گذاری (لبیل‌گذاری) گفته می‌شود. برچسب‌گذاری تصاویر بانک داده یکی از مراحل اصلی و زمان‌بر در آماده‌سازی داده‌ها در شبکه‌های یادگیری عمیق می‌باشد و با توجه به تعداد بالای تصاویر بانک داده در این تحقیق، زمان زیادی صرف آماده‌سازی داده‌ها در بانک داده تحقیق گردید. در شکل ۲ تصویر قطعه برچسب‌گذاری شده دو فیچر ماشین کاری سطح شیبدار (چمفر) و گوشه داخلی (فیلت) مشاهده می‌شود. همچنین در جدول ۱ اطلاعات پیکسل‌های هر یک از فیچرهای برچسب‌گذاری شده در شکل ۲ به عنوان داده‌های متنی مستقل ذکر گردیده است. مقادیر ذکر شده در جدول ۱ بر حسب پیکسل و با مبدا مختصات گوشه سمت راست بالای تصویر می‌باشند.

که در یک قطعه مرکب از دو یا چند فیچر دارای تداخل هندسی هستند. در سایر روش‌های شناسایی فیچرهای ماشین‌کاری که تاکنون معرفی و ارایه شده‌اند، مشکل شناسایی فیچرهای تداخلی همچنان به عنوان یکی از مشکلات اصلی شناسایی فیچرهای ماشین‌کاری مطرح می‌باشد. برای بررسی توانمندی شبکه یادگیری عمیق تولید شده در شناسایی تداخل هندسی فیچرهای ماشین‌کاری از دو قطعه که هر یک شامل دو فیچر دارای تداخل هندسی می‌باشند، استفاده گردید. تصاویر این دو قطعه در شکل‌های ۳ و ۴ نشان داده شده است. در شکل ۳ یک قطعه شامل ۲ فیچر شکاف ۷ متقاطع مشاهده می‌شود.



شکل ۳) تداخل هندسی دو فیچر متقاطع شکاف ۷

تداخل این دو فیچر سبب حذف قسمتی از لبه‌های هر فیچر و ایجاد چهار لبه جدید که هر لبه در هر دو فیچر مشترک می‌باشد، شده است. این تغییرات سبب حذف برخی از اطلاعات (قسمتی از لبه‌های هر دو فیچر) و اضافه شدن برخی اطلاعات جدید (چهار لبه مشترک در هر دو فیچر) در اطلاعات خروجی فایل طراحی می‌گردد که در روش‌های سنتی شناسایی فیچرهای ماشین‌کاری، بازیابی اطلاعات حذف شده و یا اطلاعات اضافه شده به دو فیچر اصلی توسط برخی الگوریتم‌های مجزا انجام می‌گردد که استفاده از این الگوریتم‌ها سبب پیچیدگی این سامانه‌ها و افزایش زمان شناسایی آنها می‌گردد.



شکل ۴) تداخل هندسی دو فیچر لبه مدور و شکاف ۷

شبکه بر روی بیش از ۱۰۰۰ شکل فیچر و موقعیت قرارگیری ابعاد و اندازه‌ها بررسی و ارزیابی گردید.

در جدول ۲ نتیجه محاسبات صورت گرفته برای تعیین معیارهای ارزیابی، ذکر شده است. همانطور که در جدول ۲ ملاحظه می‌شود مقادیر معیارهای صحت شناسایی میانگین (AP)، حساسیت به تشخیص نادرست میانگین (AR) و نیز معیار کاپا برای سامانه شناسایی شکل فیچرها و فرمت‌های اندازه‌گذاری بالای ۹۰ درصد می‌باشد در حالی که در سامانه شناسایی ابعاد، اندازه‌ها و علائم، بجز معیار AP که مقداری بالاتر از ۹۰ درصد دارد مقادیر معیار صحت تشخیص متوسط (AP) برابر با ۸۰ درصد و مقدار معیار کاپا برابر با ۰/۷۶ بدست آمده است که این همبستگی بین مقادیر معیارهای مختلف حاکی از صحت اندازه‌گیری این معیارها می‌باشد. از طرفی پایین بودن مقدار معیارهای ارزیابی سامانه شناسایی علائم، ابعاد و اندازه‌ها نسبت به سامانه شناسایی شکل و فرمت اندازه‌گذاری فیچرها حاکی از کارایی بهتر سامانه شناسایی شکل و فرمت اندازه‌گذاری فیچرها می‌باشد و علت پایین بودن کارایی سامانه شناسایی ابعاد و اندازه‌ها حسب بررسی‌های به عمل آمده بدلیل وجود فونت‌های مختلف اعداد و اندازه‌ها و نیز ابعاد کوچک و شباهت‌های مانند کاما و نقطه اعشار و یا شباهت اعداد ۶ و ۹ و همچنین شباهت عدد یک به علامت پرانتز می‌باشد که در کاربردهای عملی با افزایش تعداد نمونه‌ها در مرحله آموزش امکان بهبود تشخیص سامانه شناسایی ابعاد و اندازه‌ها وجود خواهد داشت.

جدول ۲) نتایج معیارهای ارزیابی توانمندی سامانه شناسایی فیچرهای ماشین‌کاری

معیارهای ارزیابی	شناسایی شکل فیچرها و فرمت‌های اندازه‌گذاری	شناسایی ابعاد، اندازه‌ها و علائم
AP	۹۷ درصد	۹۵ درصد
AR	۹۳ درصد	۸۰ درصد
Kappa	۰/۹۲	۰/۷۶

برای ارزیابی کارایی مدل در شبکه‌های یادگیری عمیق از مقایسه معیارهای ارزیابی بر روی داده‌های برخی بانک‌های اطلاعاتی مهم و مشهور همچون بانک اطلاعاتی "اشیاء عمومی کاربردی" (COCO(Common Objects in Context)) و یا سایر بانک‌های اطلاعاتی مشهور استفاده می‌شود. در این تحقیق با توجه به مقادیر بدست آمده برای معیارهای ارزیابی در مقایسه با مقادیر ارزیابی سامانه یادگیری عمیق یولو بر روی بانک اطلاعاتی "کلاس‌های اشیا قابل رویت" (VOC(Visual Object Classes)) با مقدار صحت تشخیص ۵۸/۷ درصد^[22]، سامانه تولید شده در این تحقیق از دقت و کارایی قابل قبولی برخوردار می‌باشد. یکی دیگر از قابلیت‌های منحصر به فرد سامانه هوش مصنوعی تولید شده در این تحقیق، توانمندی در شناسایی فیچرهایی است

همچنین در شکل ۴ دو فیچر لبه مدور و شکاف v دارای تداخل هندسی هستند و این تداخل سبب حذف قسمتی از سطح فیچر لبه مدور گردیده است. در جدول ۳ نتایج خروجی شبکه یادگیری عمیق به کارگیری شده در این تحقیق برای شناسایی این دو فیچر متداخل مشاهده می‌گردد.

جدول ۳) نتایج شبکه شناسایی فیچرهای متداخل در شکل ۳ و ۴

زاویه شعاع عمق ارتفاع مختصات نام فیچر شماره فیچر					
۵۸	*	۱/۸	*	(۷,۶۵,۴)	Vslot
۳۵	*	۱۰	*	(۳۴,۹۸,۶۵)	EdgeRound
۹۰	*	۱۰	۲۱	(۴,۲۳,۵۱)	Vslot
۹۰	*	۱۰	۳۱	(۵,۱۶,۷)	Vslot

* این مشخصه برای این فیچر تعریف نشده است.

همانطور که مشاهده می‌گردد در قطعه شکل ۳ فیچر لبه مدور با شماره فیچر f5، شعاع ۳۵ و مرکز مختصات (۳۴,۹۸,۶۵) نسبت به مختصات مرجع و با عمق ۱۰ و فیچر شکاف v با شماره فیچر f9، مختصات (۷,۶۵,۴) نسبت به مختصات مرجع، طول ۱/۸ و زاویه شکاف ۵۸ درجه توسط شبکه شناسایی شده است. همچنین در قطعه شکل ۲، فیچرهای متقاطع شکاف v با نام‌های f14 و f15 با ابعاد و مشخصات درج شده در جدول ۳ توسط شبکه تولید شده در این تحقیق شناسایی و استخراج گردیده است.

با توجه به وجود تداخل‌های متنوع هندسی، مدل ارائه شده برای شناسایی هر نوع تداخل هندسی دو فیچر ماشین کاری هیچ محدودیتی ندارد. قابلیت شناسایی فیچرهای تداخلی در سامانه ارائه شده در این تحقیق کاملاً به نحوه آموزش شبکه و تعداد فیچرهای تداخلی وابسته است که در تصاویر بانک داده آموزش شبکه وجود دارد و سامانه در فرایند آموزش شبکه آن نوع تداخل را چندین بار دیده باشد.

۶- نتیجه گیری و پیشنهاد

در این تحقیق با استفاده از تکنیک یادگیری عمیق، مشخصات مورد نیاز برای شناسایی فیچرهای ماشین کاری از تصویر اندازه‌گذاری شده قطعه استخراج شده و به صورت جدولی حاوی اطلاعات مورد نیاز برای ماشین کاری قطعه به دست می‌آید. در روش به کارگیری شده در این تحقیق، ضرایب تاثیر مقادیر پیکسل‌های شکل هر فیچر در تصویر یک قطعه مکانیکی به نحوی تعیین شدند که ارتباط معنادار بین مقادیر پیکسل‌های شکل هر فیچر در تصویر یک قطعه مکانیکی را استخراج و یک الگوی جدید شناسایی فیچرهای ماشین کاری با استفاده از شکل هر فیچر ارائه و سامانه شناسایی فیچرهای ماشین کاری با استفاده از شبکه یادگیری عمیق طراحی و پیاده سازی و ارائه شده است. تصاویر نمونه‌های مختلف قطعات حاوی فیچرهای منفرد و قطعه مرکب از دو فیچر با فرمت‌های نقشه‌های مهندسی

و تصویر معمولی شکل فیچرها به سامانه هوش مصنوعی تولید شده وارد گردید و سامانه با موفقیت قادر به شناسایی شکل فیچرها و ابعاد و اندازه‌های آنها می‌باشد. سرعت شناسایی فیچرهای ماشین کاری در مدل ارائه شده در این تحقیق بسیار بالا و کمتر از یک ثانیه بعد از مشاهده تصویر فیچر توسط مدل می‌باشد، لیکن بکارگیری روش ارائه شده در این تحقیق مستلزم زمان زیادی برای تهیه تصاویر بانک داده آموزش، برچسب گذاری و آماده سازی داده‌ها و تبدیل آنها به فرمت‌های قابل استفاده در شبکه یادگیری عمیق و همچنین فرایند آموزش شبکه (البته فقط برای یک بار در مرحله آماده سازی داده‌ها و آموزش شبکه) می‌باشد. اطلاعات به دست آمده در خروجی شبکه می‌تواند در مراحل بعدی یک سیستم برنامه‌ریزی فرآیند به کمک رایانه برای تبدیل به داده‌های G-code و ماشین کاری قطعه مورد استفاده قرار گیرد. تهیه تصویر قطعه و اندازه‌گیری آن از جمله ابعاد، تلرانس‌ها و سایر اطلاعات موجود در تصویر قطعه برای فیچرهای پایلوت در این تحقیق را می‌توان از خروجی یک سیستم طراحی کامپیوتری استخراج و یا با هر ابزار دیگری تهیه کرد. فرمت اندازه‌گیری و اطلاعات مورد نیاز برای ماشین کاری قطعه در این تحقیق متعارف بوده و به روش‌های دیگری غیر از آنچه در این تحقیق استفاده می‌شود، قابل تغییر است. تغییر فرمت اندازه‌گیری و اطلاعات مورد نیاز برای ماشین کاری قطعات بر اساس نیاز و نوع کاربرد مشکلی برای سامانه ارائه شده در این مطالعه ایجاد نمی‌کند.

نوآوری اصلی در این تحقیق در مقایسه با سایر روش‌های شناسایی فیچرهای ماشین کاری که تا کنون ارائه شده است، عدم وابستگی مدل ارائه شده در این تحقیق به فرمت‌های مختلف داده‌های فایل طراحی و استفاده از تصویر قطعه مکانیکی است که خروجی مشترک کلیه سیستم‌های طراحی بوده و امکان تهیه آن حتی بدون استفاده از سیستم طراحی و توسط ابزارهای مختلف مانند دوربین عکاسی و یا نرم افزارهای عمومی ترسیم و ویرایش تصویر وجود دارد. همچنین با استفاده از مدل ارائه شده در این تحقیق مشکل شناسایی فیچرهای تداخلی که در سایر مدل‌ها از جمله مدل‌های ارائه شده در روش‌های سنتی شناسایی فیچرهای ماشین کاری وجود داشت برطرف گردیده است.

تأییدیه اخلاقی: محتویات علمی این مقاله حاصل پژوهش نویسندگان است و در هیچ نشریه ایرانی و غیر ایرانی منتشر نشده است.

تعارض منافع: (نمونه) در این مقاله از برخی نتایج حاصل از رساله دکتری نویسنده مسئول استفاده شده است. هیچ تعارض منافع دیگری برای اظهار وجود ندارد.

منابع مالی: نویسندگان این مورد را بیان نکردند.

- 17- Joshi S, Chang TC. Graph-based heuristics for recognition of machined features from a 3D solid model. *Computer-aided design*. 1988 Mar 1;20(2):58-66.
- 18- Bhandarkar MP, Nagi R. STEP-based feature extraction from STEP geometry for agile manufacturing. *Computers in industry*. 2000; 41(1):3-24.
- 19- Sharma R, Gao JX. Implementation of STEP Application Protocol 224 in an automated manufacturing planning system. *Proceedings of the Institution of Mechanical Engineers, Part B: Journal of Engineering Manufacture*. 2002; 216(9):1277-89.
- 20- Gao J, Zheng DT, Gindy N, Clark D. Extraction/conversion of geometric dimensions and tolerances for machining features. *The International Journal of Advanced Manufacturing Technology*. 2005; 26:405-14.
- 21- Gao J, Zheng DT, Gindy N. Extraction of machining features for CAD/CAM integration. *The International Journal of Advanced Manufacturing Technology*. 2004; 24:573-81.
- 22- Foley D, O'Reilly R. An Evaluation of Convolutional Neural Network Models for Object Detection in Images on Low-End Devices. *AICS*. 2018; 2259:1-2.

منابع مالی: تمامی منابع مالی این تحقیق توسط دانشگاه تربیت و گزنت استاد راهنما تامین شده است.

مراجع

- 1- Zhang Y, Luo X, Zhang B, Zhang S. Semantic approach to the automatic recognition of machining features. *The International Journal of Advanced Manufacturing Technology*. 2017; 89:417-37.
- 2- Dipper T, Xu X, Klemm P. Defining, recognizing and representing feature interactions in a feature-based data model. *Robotics and Computer-Integrated Manufacturing*. 2011; 27(1):101-14.
- 3- Verma AK, Rajotia S. A review of machining feature recognition methodologies. *International Journal of Computer Integrated Manufacturing*. 2010; 23(4):353-68.
- 4- Zhu J, Kato M, Tanaka T, Yoshioka H, Saito Y. Graph based automatic process planning system for multi-tasking machine. *Journal of Advanced Mechanical Design, Systems, and Manufacturing*. 2015; 9(3): JAMDSM0034-.
- 5- Li H, Huang Y, Sun Y, Chen L. Hint-based generic shape feature recognition from three-dimensional B-rep models. *Advances in Mechanical Engineering*. 2015; 7(4):1687814015582082.
- 6- Kumar SL. State of the art-intense review on artificial intelligence systems application in process planning and manufacturing. *Engineering Applications of Artificial Intelligence*. 2017; 65:294-329.
- 7- Hinton GE, Srivastava N, Krizhevsky A, Sutskever I, Salakhutdinov RR. Improving neural networks by preventing co-adaptation of feature detectors. *arXiv preprint arXiv:1207.0580*. 2012.
- 8- Rohil H, Kaushik P. Adjacency Matrix based Face Recognition Approach. *International Journal of Computer Applications*. 2014; 98(20).
- 9- Singla N, Kaur M, Sofat S. Automated latent fingerprint identification system: A review. *Forensic science international*. 2020; 309:110187.
- 10- Jaderberg M, Simonyan K, Vedaldi A, Zisserman A. Deep structured output learning for unconstrained text recognition. *arXiv preprint arXiv:1412.5903*. 2014.
- 11- Graves A, Mohamed AR, Hinton G. Speech recognition with deep recurrent neural networks. In: *2013 IEEE international conference on acoustics, speech and signal processing 2013 (pp. 6645-6649)*. Ieee.
- 12- Corney J, Clark DE. Face-based feature recognition: generalizing special cases. *International Journal of Computer Integrated Manufacturing*. 1993; 6(1-2):39-50.
- 13- Alting L, Zhang H. Computer aided process planning: the state-of-the-art survey. *The International Journal of Production Research*. 1989;27(4):553-85.
- 14- Babic B, Nesic N, Miljkovic Z. A review of automated feature recognition with rule-based pattern recognition. *Computers in industry*. 2008;59(4):321-37.
- 15- Marquez M, White A, Gill R. A hybrid neural network-feature-based manufacturability analysis of mould reinforced plastic parts. *Proceedings of the Institution of Mechanical Engineers, Part B: Journal of Engineering Manufacture*. 2001;215(8):1065-79.
- 16- Tseng YJ, Joshi SB. Recognition of interacting rotational and prismatic machining features from 3-D mill-turn parts. *International Journal of Production Research*. 1998;36(11):3147-65.