ISSN: 2476-6909; Modares Mechanical Engineering. Proceedings of 2nd Iranian National Conference on Advanced Machining and Machine Tools (CAMMT). 2022;22(10):173-179.

Automatic Machining Features Extraction from Two-Dimensional Image of Mechanical Parts with the Help of Artificial Intelligence

ARTICLE INFO

Authors
Nategh M.J.[1*],
Mohammadi N.[1]

[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

How to cite this article
Nategh M.J, Mohammadi N. Automatic Machining Features Extraction from Two-Dimensional Image of Mechanical Parts with the Help of Artificial Intelligence. Modares Mechanical Engineering. Proceedings of 2nd Iranian National Conference on Advanced Machining and Machine Tools (CAMMT). 2022;22(10):173-179.

ABSTRACT

Extracting the required information from the design file is one of the main steps in the computer aided process planning. In previous methods of extracting machining features, various methods such as graph-based method, volume analysis method, logic rules method and other methods have been used. In all the previous methods, whether traditional methods or methods based on artificial intelligence, the input data to the machine feature identification system is the output information of a computer-aided design system. Converting the output information of a computer-aided design system to input data of a machining feature identification system is faced with limitations such as the variety of format and type of data arrangement, deleting some data from the design file due to geometric interference of features, slow extraction of features due to extensive information in the design file and the limitation of identifying different types of machining features by a unity feature identification system. In the present study, using artificial intelligence techniques based on deep learning, machining features are extracted directly from the two-dimensional image of a workpiece. The image may be prepared by a computer-aided design file, or it can be taken by a camera.

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

ماهنامه علمی مهندسی مکانیک مدرس، ویژه‌نامه مجموعه مقالات دومین کنفرانس ملی ماشین‌کاری و ماشین‌های ابزار پیشرفته.
مهر ۱۴۰۱، دوره ۲۲، شماره ۱۰، صفحه ۱۷۳-۱۷۹.

استخراج خودکار فیچرهای ماشین‌کاری از تصویر دو بعدی قطعات مکانیکی با کمک هوش مصنوعی

مشخصات مقاله

نویسنده‌ها
محمدجواد ناطق[1*]
ناصر محمدی[1]

[1] دانشکده مهندسی مکانیک، دانشگاه تربیت مدرس، تهران، ایران

*** نویسنده مسئول**
آدرس: دانشگاه تربیت مدرس، بزرگراه جلال آل احمد، تهران، ایران.
Nategh@modares.ac.ir

چکیده

استخراج اطلاعات مورد نیاز برای ماشین‌کاری، یکی از مراحل اصلی در طرح ریزی فرایند ماشین‌کاری قطعات به کمک کامپیوتر می‌باشد. استفاده از تکنیک‌های هوش مصنوعی برای شناسایی فیچرهای ماشین‌کاری از روش‌هایی است که بیش از دو دهه مورد توجه و تحقیق محققین در این حوزه بوده است. در کلیه روش‌های قبلی بکار گیری شده اعم از روش‌های سنتی و یا روش‌های مبتنی بر هوش مصنوعی، داده‌های ورودی به سامانه شناسایی فیچرهای ماشین‌کاری، اطلاعات خروجی یک سامانه طراحی به کمک کامپیوتر می‌باشد. شناسایی فیچرهای ماشین‌کاری از داده‌های فایل خروجی طراحی به کمک کامپیوتر با محدودیت‌هایی از قبیل تنوع فرمت و نوع چینش داده‌ها، حذف برخی داده‌ها از فایل طراحی بدلیل وجود تداخل‌های هندسی فیچرها، سرعت کم استخراج فیچرها بدلیل گستردگی اطلاعات موجود در فایل طراحی و همچنین محدودیت شناسایی انواع مختلف فیچرهای ماشین‌کاری توسط یک سامانه شناسایی فیچرها می‌باشد. در روش ارایه شده در این تحقیق با استفاده از تکنیک‌های هوش مصنوعی مبتنی بر یادگیری عمیق، فیچرهای ماشین‌کاری مستقیما از تصویر دو بعدی یک قطعه استخراج و شناسایی می‌شود. تصویر قطعه می‌تواند خروجی یک فایل طراحی به کمک کامپیوتر باشد و یا توسط هر ابزار دیگری تهیه شده باشد و یا توسط یک دوربین عکاسی معمولی از قطعه باشد.

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

[Downloaded from mme.modares.ac.ir on 2024-05-10]

[DOR: 20.1001.1.10275940.1401.22.10.27.0]

۱- مقدمه

برای استفاده از داده های فایل طراحی یک قطعه در طرح ریزی فرایند ساخت قطعات به کمک کامپیوتر، الگوهای متفاوتی بکارگیری شده است. در میان الگوهای معرفی اطلاعات فایل طراحی، مدل معرفی مرزها یکی از متداول‌ترین روش‌های به کار برده شده در بسیاری از تکنیک‌های استخراج و شناسایی اتوماتیک فیچرهای ماشین‌کاری می‌باشد. برخی دیگر از محققین از مدل ساختار هندسه جسم جامد برای دریافت اطلاعات طراحی یک فیچر استفاده نموده‌اند. از مدل وایرفریم تعداد کمتری از محققین برای استخراج اطلاعات سطح پایین از یک فایل طراحی استفاده نموده‌اند[1]. در مدل معرفی مرزها، فیچر متشکل از گوشه، لبه و سطح می‌باشد، در حالی که در مدل وایرفریم، فیچر فقط متشکل از گوشه و لبه و در مدل هندسه جسم جامد یک فیچر از اشکال هندسی اولیه مانند استوانه و کره تشکیل شده است. در ادامه به برخی از متداول‌ترین روش‌های سنتی شناسایی اتوماتیک فیچرهای ماشین‌کاری در هر یک از مدل‌های ذکر شده پرداخته می‌شود. کاپریانو و همکاران[2] در سال۱۹۸۰ میلادی، روشی مبتنی بر الگوی قواعد نحوی را با استفاده از الگوی معرفی اطلاعات وایرفریم از فایل طراحی ارائه دادند. در روش اشاره مبنا که در سال ۱۹۹۳ میلادی توسط وان دن براند و رکویی چا[3] معرفی گردید، روشی برای حل مشکل تداخل الگوهای مختلف فیچرها ارایه شد و اطلاعات هندسی، توپولوژیکی و سلسله مراتبی راجع به یک قطعه، به‌عنوان یک نشانه برای یک الگوی فیچر خاص، در این روش در نظر گرفته می‌شود. برخی محققین دیگر از جمله پروز و ناطق[4] با استفاده از روش اشاره‌مبنا به‌عنوان يكي از روش‌هاي قدرتمند شناسايي فيچرهاي ماشين‌كاري، علاوه بر ارايه یک روش جدید با حجم محاسبات کمتر، شناسايي فيچرها با قابليت دسترسي ابزار از چند جهت ارايه شده است كه كليه فيچرهاي موجود يك قطعه طراحي شده را بهمراه جهت مخصوص دسترسي ابزار به آنها، ليست مي كند.

روش گراف مبنا که در سال ۱۹۸۷ توسط جوشی و چنگ[5] ارائه شد یکی از پرکاربردترین و معروف‌ترین روش‌های شناسایی فیچرهای ماشین‌کاری می‌باشد. در این روش که بر اساس استخراج فیچر از مدل معرفی مرزها در فایل طراحی استوار است، از یک الگوی گراف همسایگی برای شناسایی استفاده می‌شود. روش مشهور دیگری که برای شناسایی اتوماتیک فیچرها مورد استفاده قرار می‌گیرد، روش مبتنی بر قواعد نامیده می‌شود که برای اولین بار در سال۱۹۸٤ میلادی توسط هندرسون و آندرسون[6] معرفی گردید، اطلاعات اولیه از فایل طراحی در این روش نیز بر مبنای الگوی معرفی مرزها می‌باشد. در این روش از یک مجموعه از قواعد به‌صورت آنگاه- اگر برای شناسایی فیچرها استفاده می‌شود. یکی دیگر از روش‌های متداول شناسایی فیچرهای ماشین‌کاری که از مدل معرفی اطلاعات هندسه جسم جامد استفاده می‌کند، روش تجزیه احجام تشکیل دهنده یک فیچر می‌باشد[7].

با پیشرفت علوم مربوط به هوش مصنوعی، برخی از محققین از روش های مبتنی بر هوش مصنوعی برای استخراج و شناسایی فیچرهای ماشین‌کاری از داده‌های فایل طراحی قطعه استفاده نموده‌اند. ویژگی عمده روش‌های شناسایی اتوماتیک فیچرهای ماشین‌کاری مبتنی بر شبکه‌های عصبی که آن را در زمره یکی از روش‌های مطرح معرفی نموده است، حذف لیست کتابخانه‌ای الگوهای شکل فیچرهای از پیش تعیین شده و قابلیت استخراج الگوهای موجود در ساختار اطلاعات ورودی از طریق آموزش شبکه می‌باشد[8]. در شبکه‌های عصبی مصنوعی اطلاعات ورودی به شبکه عصبی همچنان از همان الگوی استخراج اطلاعات اولیه از یک فایل طراحی تبعیت می‌کند، لیکن به جای تطابق شکل فیچر با فیچرهای موجود در یک بانک اطلاعاتی، از روش‌های یادگیرنده برای شناسایی شکل فیچر استفاده می‌شود.

مزایای عمده روش‌های مبتنی بر شبکه‌های عصبی نسبت به روش‌های متداول عبارتند از[9]:

- شبکه‌های عصبی مصنوعی خطاهای جزئی موجود در اطلاعات ورودی را نادیده می‌گیرد لیکن در شبکه‌های متداول این قابلیت وجود ندارد.
- به دلیل اینکه شبکه‌های عصبی مصنوعی از عملگرهای منطقی پیچیده برای جستجو در میان لیست کتابخانه استفاده نمی‌کنند این شبکه‌ها سرعت بیشتری در شناسایی فیچرهای ماشین‌کاری دارند و از عملیات محاسباتی ساده‌ایی استفاده می‌کنند.
- شبکه‌های عصبی مصنوعی قادر به کسب دانش در فرآیند آموزش هستند و آنها را قادر می‌سازد فیچرهایی که در لیست کتابخانه‌ای از پیش تعیین شده وجود ندارند را نیز شناسایی کنند.

همچنین روش‌های شناسایی اتوماتیک فیچرهای ماشین‌کاری مبتنی بر شبکه‌های عصبی مصنوعی برخی از نواقص روش‌های متداول شناسایی اتوماتیک فیچرهای ماشین‌کاری مانند عدم توانایی شناسایی فیچرهای ناقص، سرعت اجرایی کم و عدم قابلیت یادگیری را ندارند.[10]

یک نوع تقسیم بندی دیگر در زمینه شناسایی فیچرهای ماشین‌کاری را می‌توان به روش‌های شناسایی مبتنی بر قواعد ساختاریافته منطقی و روش‌های مبتنی بر یادگیری تقسیم بندی نمود[1]. کلیه روش‌های شناسایی متداول مانند روش‌های گراف مبنا، روش قواعد منطقی، روش تجزیه احجام و سایر روش‌های سنتی بر پایه یک سری قواعد منطقی بنا نهاده شده‌اند. از طرفی در کلیه روش‌های قدیم و جدید مبتنی بر هوش مصنوعی، عنصر یادگیری یکی از مولفه‌های مهم و متفاوت این روش‌ها با

[Downloaded from mme.modares.ac.ir on 2024-05-10]

[DOR: 20.1001.1.10275940.1401.22.10.27.0]

روش‌های سنتی است. در روش‌های مبتنی بر شبکه عصبی مصنوعی، اطلاعات ورودی به شبکه از همان سه الگوی معرفی اطلاعات فایل طراحی استفاده می‌نمایند[11]، لیکن از عنصر یادگیری توسط کامپیوتر برای آموزش الگوهایی که توسط مهندسان تعیین می‌شوند، استفاده می‌شود.

برخی از محققین از جمله ژان و همکاران[12] و کان فن کوی و همکاران[13] از روش‌های پیشرفته هوش مصنوعی موسوم به روش یادگیری عمیق برای شناسایی فیچرهای ماشینکاری استفاده نمودند لیکن در کلیه این روش‌ها، داده های ورودی به شبکه از اطلاعات فایل طراحی قطعه استفاده می نماید و کماکان برخی مشکلات روش های قبلی از جمله حذف برخی از داده‌ها بدلیل تداخل هندسی فیچرهای ماشین‌کاری و متکی بودن سیستم شناسایی فیچرهای ماشین‌کاری به داده های قایل طراحی وجود دارد.

در این تحقیق با استفاده از یک شبکه هوش مصنوعی پیشرفته مبتنی بر یادگیری عمیق، فیچرهای ماشین‌کاری از تصویر یک قطعه مکانیکی استخراج و شناسایی می شود. نو آوری این تحقیق استفاده از تصویر یک قطعه برای شناسایی فیچرهای ماشین‌کاری بجای استفاده از داده های فایل طراحی قطعه می‌باشد که با استفاده از روش ارایه شده علاوه بر عدم وابستگی سیستم شناسایی فیچرهای ماشین‌کاری به فایل طراحی (و مشکلاتی از قبیل فرمت های گوناگون فایل‌های طراحی و یا حذف برخی اطلاعات از فایل طراحی بدلیل وجود تداخل هندسی فیچرها) امکان استخراج اطلاعات مورد نیاز از تصویر یک قطعه که خروجی مشترک کلیه فرمت‌های فایل طراحی می‌باشد و یا تصویر مذکور توسط هر ابزاری گرفته شده باشد فراهم گردیده است.

۲- مبانی مفهومی روش

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 مشخصه منحصر بفرد از هر یک از این اهداف تعریف و بکارگیری نمود. این مشخصه در تکنیک های شناسایی تصویر به ویژگی هر هدف شناخته می شود. 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.

همانطور که می دانیم هر تصویر از یک سری نقاط منفصل بنام پیکسل تشکیل شده است و هر پیکسل در تصویر دارای یک رنگ مشخص می باشد. شدت و نوع رنگ هر پیکسل از تصویر را می‌توان با یک عدد مشخص نمود. بعنوان مثال در یک تصویر سیاه و سفید، چنانچه نقاط (پیکسل‌های) رنگ سیاه را با عدد ۱ و نقاط سفید را با عدد صفر نمایش دهیم، یک تصویر با تعداد مشخصی از اعداد صفر و یک خواهیم داشت و لذا هر تصویر منحصر به فرد را می توان با تعداد مشخصی از اعداد صفر و یک بیان نمود. در تصاویر رنگی نیز بر اساس استاندارد رنگ بندی قرمز-سبز-آبی (RGB) هر تصویر را می‌توان ترکیبی از سه رنگ اصلی قرمز، سبز و آبی با شدت رنگ مختلف دانست. در این سیستم شناسایی رنگ‌ها، شدت هر یک از این سه رنگ اصلی از صفر تا ۲۵۵ متفاوت است. از ترکیب این سه رنگ با شدت رنگ های مختلف امکان تولید طیف وسیعی از رنگ های مختلف (در حدود بیش از ۱۶ میلیون رنگ متفاوت) تولید نمود.

تعداد پیکسل‌های هر تصویر وابسته به ابعاد و کیفیت تصویر می‌باشد. بنابراین تعداد متغیرها در شناسایی تصویر فیچرهای ماشین‌کاری علاوه بر ارزش عددی پیکسل‌های مختص شکل هر فیچر، به ابعاد تصویر و کیفیت تصویر نیز وابسته است. برای کاهش تعداد متغیرها، در این تحقیق تصویر قطعه کار با هر ابعادی، به یک تصویر با ابعاد ثابت ۴۸۰ در ۴۸۰ پیکسل تبدیل می‌گردد.

۳- مبانی ریاضی روش پیشنهادی

با توجه به توضیحات بخش دوم این مقاله، در گام اول روش شناسایی فیچرهای ماشین‌کاری با استفاده از تصویر قطعه، ابتدا تصویر قطعه به یک تابع چند جمله‌ایی تبدیل می‌گردد. در گام بعدی با اختصاص ضرایبی که این ضرایب با استفاده از تکنیک‌های هوش مصنوعی و یادگیری عمیق تعیین می‌گردند، تابع چند جمله ایی تعریف شده برای شکل کلیه فیچر ماشین‌کاری قابل شناسایی در دامنه کاربرد این تحقیق، توسعه می یابد. در نهایت با نگاشت مقادیر عددی مختص شکل هر فیچر به یک فضای چند بعدی فضای جواب مختص شکل و مشخصات هر یک از فیچرهای ماشین‌کاری تعیین می‌گردد.

۳-۱- تبدیل تصویر به تابع چند جمله ایی خطی

چنانچه مقدار عددی هر یک از پیکسل های تصویر حاوی فیچر ماشین‌کاری را بعنوان یک متغییر در نظر بگیریم، تابع g(x) را می‌توان بعنوان تابع تبدیل تصویر در نظر گرفت و به صورت رابطه (۱) تعریف نمود:

$$g(x) = x_{1,1} + x_{1,2} + \dots\dots + x_{n,m} \rightarrow g(x) = \sum x_{i,j} \quad 0 \le x_{i,j} \le 255 \qquad (۱)$$

[Downloaded from mme.modares.ac.ir on 2024-05-10]

[DOR: 20.1001.1.10275940.1401.22.10.27.0]

در رابطه (۱) هر یک از متغیرهای تابع چند جمله‌ایی مقادیر ارزش عددی پیکسل مربوطه در تصویر قطعه و n و m ابعاد تصویر حاوی قطعه می‌باشد که در این تحقیق برابر ۴۸۰ در نظر گرفته شده‌اند. در شکل ۱ مقادیر تابع تبدیل تصویر قطعات شامل فیچرهای سطح شیبدار (Chamfer)، گوشه گرد داخلی (Fillet) و شکاف V (Vee Slot) با جایگذاری مقادیر پیکسل‌های هر تصویر در رابطه ۱ نشان داده شده است.

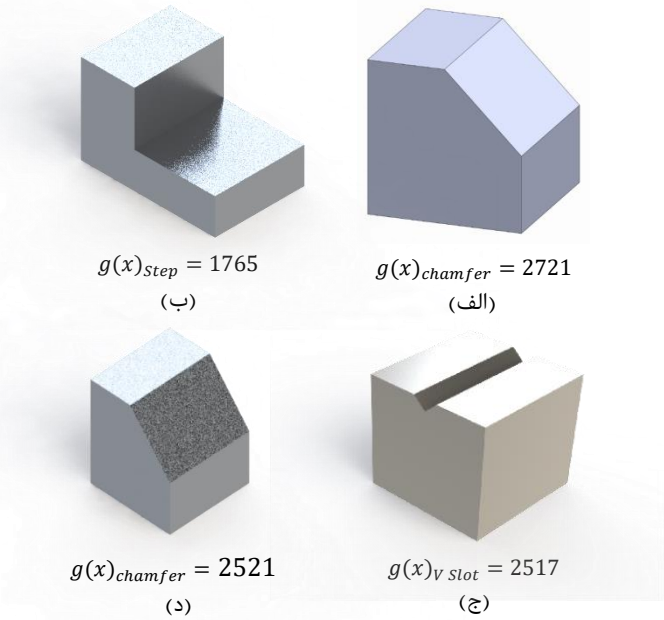

شکل ۱) مقادیر عددی تبدیل تصاویر فیچرهای الف- سطح شیبدار با فرمت جسم جامد؛ ب- فیچر پله، ج- فیچر شکاف V، د-سطح شیبدار با جنس فولاد

همانگونه که در شکل ۱ مشاهده می گردد عدد مشخصه فیچر سطح شیبدار با جنس فولاد (شکل ۱-د) با عدد مشخصه همین فیچر با فرمت جسم جامد و زاویه دید متفاوت، دو عدد متفاوت است و لذا استفاده از رابطه ۱ و تبدیل تصویر به یک عدد به تنهایی قادر به اختصاص یک عدد واحد به شکل یک فیچر خاص نمی‌باشد. همچنین اعداد مشخصه سایر فیچرها بسیار نزدیک به هم می‌باشند و لذا تمایز و تفکیک شکل فیچرها را با مشکل مواجه می نماید. برای حل این مشکل با اختصاص ضرایب متفاوت به هر یک از جمله‌های تابع تبدیل تصویر هر فیچر و همچنین عبور دادن مقادیر تابع چند جمله‌ایی و ضرایب مربوطه از یک تابع غیر خطی می‌توان تفکیک لازم برای تمایز شکل فیچرهای مختلف را فراهم آورد. در هوش مصنوعی به این ضرایب، ضرایب وزن‌های شبکه گفته می‌شود و در فرایند آموزش شبکه هوش مصنوعی، این ضرایب تعیین و نهایی می‌شوند. روابط ریاضی تاثیر ضرایب مذکور در تابع تبدیل تصویر به صورت زیر می‌باشد.

$$\begin{bmatrix} x_{1,1} * w_{1,1} & x_{1,2} * w_{1,2} & x_{1,3} * w_{1,3} & x_{1,4} & x_{1,5} & x_{1,6} \\ x_{2,1} * w_{2,1} & x_{2,2} * w_{2,2} & x_{2,3} * w_{2,3} & x_{2,4} & x_{2,5} & x_{2,6} \\ x_{3,1} * w_{3,1} & x_{3,2} * w_{3,2} & x_{3,3} * w_{3,3} & x_{3,4} & x_{3,5} & x_{3,6} \\ x_{4,1} & x_{4,2} & x_{4,3} & x_{4,4} & x_{4,5} & x_{4,6} \\ x_{5,1} & x_{5,2} & x_{5,3} & x_{5,4} & x_{5,5} & x_{5,6} \\ x_{6,1} & x_{6,2} & x_{6,3} & x_{6,4} & x_{6,5} & x_{6,6} \end{bmatrix} \quad (۲)$$

همانطور که در رابطه نشان داده شده است، هر یک از عناصر آرایه مقادیر پیکسل‌های تصویر در یک ضریب جداگانه ضرب می‌گردد. در رابطه ۲ فقط ۹ ضریب از این ضرایب نشان داده شده است. (ضرایب w در رابطه (۲))

تابع تبدیل تصویر (رابطه ۱) با استفاده از ضرایب نشان داده شده در رابطه (۲) بصورت زیر به یک تابع تبدیل جدید بنام f(x) تبدیل می گردد.

$$w(x) \times g(x) = f(x) \quad (۳)$$

قابل ذکر است عملگر × در رابطه (۳)، یک عملگر ضرب ناحیه‌ایی بنام ضرب کانولوشن است که با انتخاب یک ناحیه (ابعاد آرایه w(x) که هر عنصر از این آرایه نشان دهند ضریب یک پیکسل از تصویر است) و چرخش ناحیه انتخابی در تصویر قطعه، مانند یک فیلتر عمل کرده و با تعیین مقدار مناسب برای ضرایب آرایه w(x) می‌توان برخی از ویژگی های 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 w مناسب 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 برای ضرایب w، اعداد مشخصه مختص هر فیچر بدلایل 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 دسته بندی فیچرهای مختلف را ایجاد کند. برای حل این مشکل در شبکه های هوش مصنوعی پیشرفته 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. در این تحقیق از رابطه غیر خطی زیر استفاده گردیده است.

$$\hat{f}(x) = f(x) tan\, h\left(ln\left(1 + e^{f(x)}\right)\right) \quad (٤)$$

برای تعیین مقادیر ضرایب W پس از طراحی شبکه و تعیین تعداد فیلترها، در ابتدا به هریک از این ضرایب یک مقدار اولیه بصورت اختیاری اختصاص داده می‌شود. سپس مقادیر اختیاری اولیه در آرایه پیکسل‌های تصویر یک قطعه مشخص ضرب می

[Downloaded from mme.modares.ac.ir on 2024-05-10]

[DOR: 20.1001.1.10275940.1401.22.10.27.0]

گردد (رابطه ۳) و با اعمال تابع غیر خطی (رابطه ۴) بر روی نتایج حاصل، عدد مشخصه بدست آمده برای شکل فیچر موجود در تصویر ثبت می‌گردد. این عملیات برای تعداد معتنابهی 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 ضرایب فیلترها به روز رسانی شود. چنانچه عدد مشخصه تصویر فیچر ورودی برای سنجش میزان دقت شناسایی شبکه را D_i و بازه اعداد مشخصه فیچر موجود در تصویر را D_0 بنامیم، مقدار خطای تشخیص شبکه را می توان بصورت زیر نمایش داد:

$$E = D_0 - D_i \quad (۵)$$

چنانچه مقدار خطا (مقدار E در رابطه ۵) از یک مقدار مطلوب تجاوز نماید لازم است با به روز رسانی مقادیر W، مقدار خطا را کاهش و به مقدار مطلوب رسانده شود. مرحله به روز رسانی این ضرایب بعنوان مرحله اموزش شبکه هوش مصنوعی شناخته می‌شود. مدل ریاضی به روز رسانی و نهایی سازی این ضرایب با مشتق گیری از رابطه خطا (رابطه ۵) نسبت به متغیر W صورت می‌گیرد:

$$D_i = f(w, \hat{f}(x)) \quad (۶)$$

$$w_{opt} = \frac{\partial E}{\partial w} \quad (۷)$$

با توجه به وجود تعداد زیادی از ضرایب w در یک شبکه هوش مصنوعی، کاهش همزمان کلیه این ضرایب نیاز به انجام برخی تنظیمات از جمله میزان کاهش نرخ شیب منحنی W نسبت به E و سایر پارامترهای شبکه هوش مصنوعی می باشد. در شکل ۲ منحنی نرخ کاهش یکی از این ضرایب نسبت به مقدار خطا نشان داده شده است.

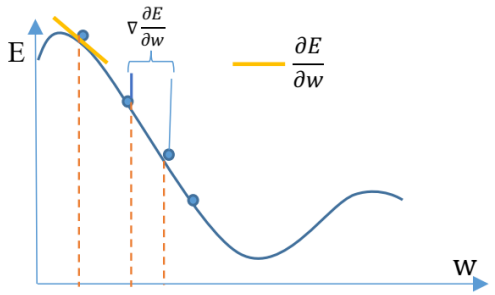

شکل ۲) نرخ کاهش ضریب W نسبت به مقدار خطا برای یکی از ضرایب

۴- تولید شبکه هوش مصنوعی شناسایی فیچرهای ماشین‌کاری

برای تولید شبکه هوش مصنوعی و آموزش آن به نحوی که قادر باشد فیچرهای ماشین‌کاری موجود در تصویر یک قطعه را شناسایی نماید، در ابتدا تعداد ۱۰ هزار تصویر قطعه مکانیکی با استفاده از نرم افزار سالیدورکز تهیه و در بانک داده این تحقیق ذخیره گردید.

جهت استفاده از روابط فصل سوم برای آموزش شبکه هوش مصنوعی لازم است محدوده قرارگیری هر فیچر در تصویر جهت تعیین ارزش مقادیر پیکسل‌های مربوط به هر فیچر تعیین گردد. به این منظور در گام بعدی، محل قرارگیری هر فیچر در کلیه تصاویر موجود در بانک داده تحقیق با رسم یک کادر مستطیلی اطراف هر یک از فیچرهای موجود در تصویر تعیین گردید. در شبکه های هوش مصنوعی به تعیین محدوده هر هدف قابل شناسایی در تصویر، برچسب گذاری گفته می شود. در شکل ۵ یک نمونه از برچسب گذاری فیچرهای موجود در یک قطعه مرکب از دو فیچر سطح شیبدار و گوشه داخلی (فیلت) مشاهده می شود. در شکل ۳-الف کادر رسم شده اطراف هر فیچر در تصویر و در شکل ۳-ب اطلاعات برچسب گذاری بصورت متن و شامل طول و عرض کل تصویر (width , height)، نام هر فیچر، شماره پیکسل شروع و خاتمه هر فیچر در جهت افقی و عمودی (xmin, xmax ymin,ymax) برای هر فیچر مشاهده می‌شود.

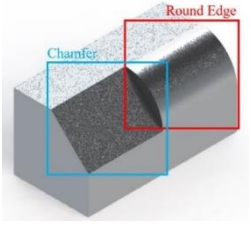

(الف)

(ب)

شکل ۳) برچسب گذاری یک قطعه حاوی دو فیچر سطح شیبدار و گوشه داخلی (فیلت) الف- رسم کادر مستطیلی اطراف هر فیچر بصورت دستی ، ب- خروجی مرحله برچسب گذاری بصورت متن

[Downloaded from mme.modares.ac.ir on 2024-05-10]

[DOR: 20.1001.1.10275940.1401.22.10.27.0]

در مرحله بعدی اطلاعات کلیه فیچرهای بانک داده از فایل متنی به یک فایل صفحه گسترده با فرمت متن (xml) تبدیل گردید. در مرحله آخر آماده سازی داده‌ها، جهت ورود به شبکه هوش مصنوعی، اطلاعات فایل صفحه گسترده به فرمت دودویی تبدیل گردید. علاوه بر داده‌های دودویی بانک داده، مقادیر اولیه ضرایب وزن‌ها، به شبکه هوش مصنوعی تولید شده وارد گردید و با استفاده از رابطه شماره ۷ وزن‌های مذکور به روز رسانی گردید و شبکه هوش مصنوعی به این وسیله آموزش داده شد.

۵- بررسی نتایج

برای بررسی دقت شبکه در تشخیص فیچرهای موجود در شبکه تعداد ۲۰۰ تصویر از زوایای مختلف و با ترکیبات مختلف به شبکه وارد گردیدو توسط نرم افزار پایتون نتایج تشخیص شبکه اندازه گردید.در شکل ٤ نتایج تشخیص برخی از فیچرهای ماشین‌کاری بر اساس تعداد تصاویر صحت سنجی دقت تشخیص مشاهده می‌گردد.

```
class: Chamfer
loading annotations into memory...
Done (t=0.00s)
creating index...
index created!
Average Precision (AP) @[ IoU=0.50 | area= all
| maxDets=100 ] = 0.917
class: Vee Slot
loading annotations into memory...
Done (t=0.00s)
creating index...
index created!
Average Precision (AP) @[ IoU=0.50 | area= all
| maxDets=100 ] = 0.881
class: Round Edge
loading annotations into memory...
Done (t=0.00s)
creating index...
index created!
Average Precision (AP) @[ IoU=0.50 | area= all
| maxDets=100 ] = 0.965
class: Fillet
loading annotations into memory...
Done (t=0.00s)
creating index...
index created!
Average Precision (AP) @[ IoU=0.50 | area= all
| maxDets=100 ] = 0.854
class: Step
loading annotations into memory...
Done (t=0.00s)
creating index...
index created!
Average Precision (AP) @[ IoU=0.50 | area= all
| maxDets=100 ] = 0.998
```

شکل ٤) نتایج خروجی سنجش دقت شبکه در شناسایی برخی از فیچرهای ماشین‌کاری

همانطور که در شکل ۵ مشاهده می گردد دقت تشخیص شبکه در برخی فیچرها بیشتر و در برخی کمتر می باشد. علت متفاوت بودن دقت تشخیص شبکه در فیچرهای مختلف به عللی همچون پیچیدگی شکل قطعه، تعداد داده های آموزش شبکه در هر تصویر و زوایا مختلف شکل فیچر در تصاویر تعیین دقت تشخیص شبکه می باشد. در شکل‌های ٦، ۷ و ۸ چند نمونه موردی از تشخیص شبکه هوش مصنوعی تولید شده مشاهده می گردد.

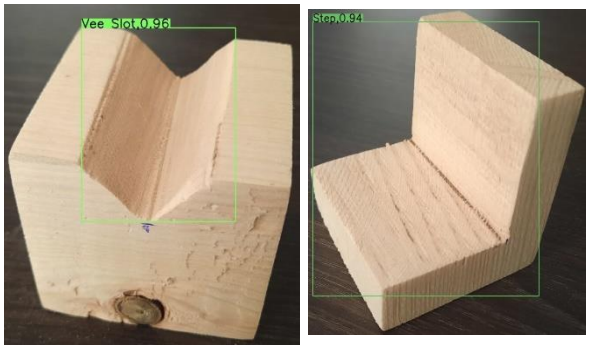

(ب) (الف)

شکل ۵) نتایج تشخیص فیچرهای ماشین‌کاری در قطعات حاوی یک فیچر ماشین‌کاری الف- فیچر پله با دقت تشخیص ۹۴ درصد ب- فیچر شکاف ۷ با درصد تشخیص ۹۶ درصد.

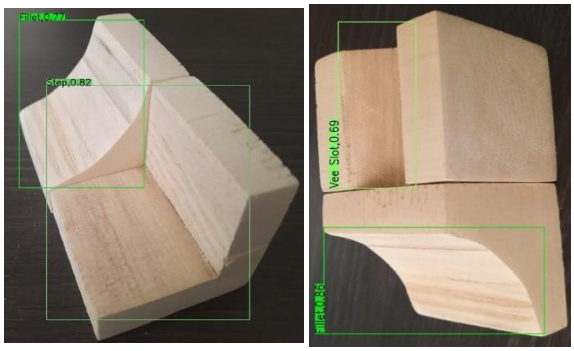

(ب) (الف)

شکل ٦) نتایج تشخیص فیچرهای ماشین‌کاری در قطعات حاوی دو فیچر ماشین‌کاری الف- فیچر شکاف ۷ با دقت تشخیص ٦۹ درصد و فیچر گوشه داخلی با دقت تشخیص ۸٦ درصد، ب- فیچر پله با درصد تشخیص ۸۲ درصد و فیچر گوشه داخلی با دقت تشخیص ۷۷ درصد

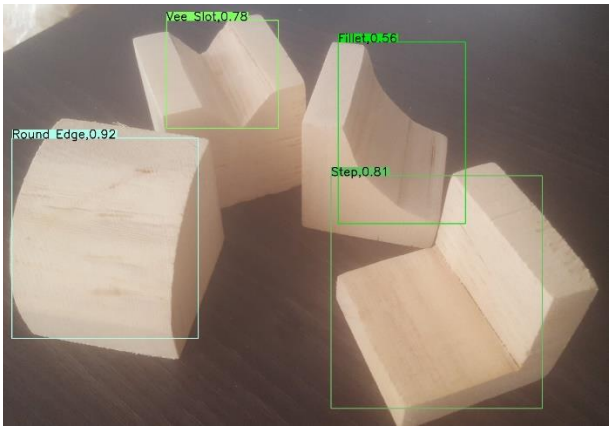

شکل ۷) نتایج تشخیص فیچرهای ماشین‌کاری در تصویر حاوی سه و چهار فیچر ماشین‌کاری الف-تصویر حاوی چهار فیچر شامل فیچر پله با دقت تشخیص ۸۱ درصد، فیچر گوشه داخلی گرد با دقت تشخیص ٥٦ درصد، فیچر شکاف ۷ با دقت تشخیص ۷۸ درصد و فیچر لبه بیرونی با دقت تشخیص ۹۲ درصد، ب-تصویر حاوی ۳ فیچر شامل فیچر پله با درصد تشخیص ۹۰ درصد، فیچر شکاف ۷ با دقت تشخیص ۸۹ درصد و فیچرلبه بیرونی گرد با دقت تشخیص ۸۲ درصد

[Downloaded from mme.modares.ac.ir on 2024-05-10]

[DOR: 20.1001.1.10275940.1401.22.10.27.0]

در شکل ۵-الف و ۵-ب به ترتیب نتیجه خروجی شبکه برای شناسایی فیچرهای پله (Step) و شکاف (Vee Slot) V مشاهده می‌گردد. در شکل ٦ نتایج تشخیص شبکه برای تصاویر حاوی دو فیچر و در شکل ۷ نتایج تشخیص شبکه برای تصاویر حاوی بیش از دو فیچر ماشین‌کاری مشاهده می‌شود. اعداد جلوی کادر تشخیص در هر تصویر نشان دهنده دقت تشخیص شبکه برای شناسایی فیچر مربوطه می‌باشد.

٦- نتیجه گیری و پیشنهاد

در تحقیق حاضر یک روش جدیدی برای شناسایی فیچرهای موجود در تصویر یک قطعه کار معرفی گردید. نتایج این تحقیق نشان می دهد که با توجه به پیشرفت های قابل ملاحظه در علوم کامپیوتر و هوش مصنوعی، امکان استفاده از روش های هوش مصنوعی پیشرفته و یادگیری عمیق در شناسایی فیچرهای ماشین‌کاری بدون استفاده از داده‌های فایل طراحی و تنها با در دست داشتن تصویر یک قطعه امکان پذیر است. از نتایج این تحقیق می توان در ساخت قطعات مکانیکی که نمونه قبلی از آن موجود است و فایل طراحی آن در دسترس نمی باشد، و یا در قطعاتی که در مراحل طراحی بوده و به تولید انبوه نرسیده است و نیاز به ساخت یک نمونه از آن برای انجام بررسی های بیشتر و رفع اشکالات و بهبود قطعه قبل از تولید انبوه است می تواند مورد استفاده قرار گیرد. در ادامه این تحقیق پیشنهاد می شود روش معرفی شده برای شناسایی فیچرهای ماشین‌کاری از طریق نقشه ساخت قطعه و نیز استفاده از فرامین صوتی برای ساخت قطعه با کمک روش یادگیری عمیق در هوش مصنوعی استفاده گردد.

مراجع

1-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.

2- Kyprianou LK. Shape classification in computer-aided design (Doctoral dissertation, University of Cambridge).

3- Vandenbrande JH, Requicha AA. Spatial reasoning for the automatic recognition of machinable features in solid models. IEEE Transactions on Pattern Analysis and Machine Intelligence. 1993;15(12):1269-85.

4- Parvaz H, Nategh MJ. A multi-TAD framework for recognizing machining features using hint based recognition algorithm. InAdvanced Materials Research 2012 (Vol. 445, pp. 905-910). Trans Tech Publications Ltd.

5- Joshi S, Chang TC. Graph-based heuristics for recognition of machined features from a 3D solid model. Computer-Aided Design. 1988; 20(2):58-66.

6- Henderson MR, Anderson DC. Computer recognition and extraction of form features: a CAD/CAM link. Computers in industry. 1984; 5(4):329-39.

7- Han J, Pratt M, Regli WC. Manufacturing feature recognition from solid models: a status report. IEEE transactions on robotics and automation. 2000;16(6):782-96.

8- 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; 25(3):289.

9- Ding L, Matthews J. A contemporary study into the application of neural network techniques employed to automate CAD/CAM integration for die manufacture. Computers & Industrial Engineering. 2009; 57(4):1457-71.

10- Yue Y, Ding L, Ahmet K, Painter J, Walters M. Study of neural network techniques for computer integrated manufacturing. Engineering Computations. 2002.

11- 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; 25(3):289.

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

13- 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. 2020:1-9.

[Downloaded from mme.modares.ac.ir on 2024-05-10]

[DOR: 20.1001.1.10275940.1401.22.10.27.0]