

تشخیص خودکار عیوب جوشکاری در تصاویر خطوط لوله‌های گاز با استفاده از شبکه عصبی عمیق

علیرضا آزادیان^۱، فائزه لطفی کاظمی (نویسنده مسئول)^۲، مجید صالحی^۳

^۱ کارشناسی ارشد مهندسی پرتو پزشکی، تهران، دانشگاه صنعتی امیرکبیر Alirezaaz001@aut.ac.ir

^۲ کارشناسی ارشد مهندسی پرتو پزشکی، تهران، دانشگاه صنعتی امیرکبیر Faloka@aut.ac.ir

^۳ کارشناسی ارشد مهندسی پرتو پزشکی، زنجان، دانشگاه صنعتی امیرکبیر mj.d.salehi56@gmail.com

چکیده

تشخیص غیر مخرب عیوب جوشکاری به خصوص در پروژه‌های صنعتی مساله‌ای است که امروزه بدلیل سرعت بالا و هزینه‌های کمتر و دقت بالاتر و همچنین سالم ماندن قطعه بعد از تست از این رو مورد توجه بسیار قرار گرفته است. به این خاطر که در تست‌های غیر مخرب^۱ غالباً بازرسی توسط افراد و انسان صورت می‌گیرد و تفسیرهای متفاوت بازرسان نتایج در برابر خطای انسانی آسیب‌پذیر خواهد بود. از این رو با استفاده از کامپیوتر و شبکه‌های عصبی و یادگیری عمیق بر آن شده‌اند تا خطای انسانی را حذف کنند و نتایج با دقت بالاتری بدست آورده شود. در تست رادیوگرافی^۲ با استفاده از پرتوهای گاما و اشعه ایکس تصاویر بر روی فیلم رادیوگرافی ظاهر می‌شود که اگر قطعه دارای نقص و عیب باشد تصاویر روشن‌تر یا دارای نقاط تیره‌تر و سیاه‌تر خواهند بود. در این مطالعه ابتدا داده‌های خام تصاویر رادیوگرافی از لوله‌های گاز را به صورت عملی از طریق شرکت آذران جوش شاهین جمع‌آوری شده و سپس توسط متخصص مکانیک از طریق تست‌های اولیه عیوب لوله‌ها تشخیص داده شد. سپس داده‌ها بر اساس نوع عیب‌ها به سه دسته‌ی سالم و ناسالم از نوع متخلخل و ناسالم از نوع ناپیوستگی خطی تقسیم شدند (۴۸ سالم - تخلخل ۵۶ - ناپیوستگی خطی ۳۶). در مرحله‌ی بعد جهت افزایش داده‌ها و بالاتر بردن صحت کار از روش افزایش داده^۳ یا data augmentation استفاده شد. براساس این روش داده‌هایی جدید از روی داده‌های قبلی ساخته شده تا شبکه را به چالش بکشد و حساسیت شبکه را به یک سری از دیتاها کمتر کند. در آخر از روش شبکه عصبی عمیق^۴ ارائه شده جهت استخراج ویژگی‌ها و طبقه‌بندی خودکار داده‌ها استفاده کرده ایم. و از داده‌های جدید جهت تست شبکه استفاده کرده ایم که در نتیجه دقت و صحت طبقه‌بندی این روش برابر با ۹۲٪ و ۹۶٪ است. نتایج این پژوهش نشان داد که استفاده از روش‌های یادگیری می‌تواند با دقت مطلوبی لوله‌ها با عیوب متفاوت را از به صورت خودکار هم تشخیص دهد.

واژه‌های کلیدی

تست غیر مخرب، رادیوگرافی، شبکه عصبی عمیق، افزایش داده

۱. مقدمه

در حین ساخت قطعات، ممکن است نقص‌هایی در ابعاد و اندازه‌های متفاوت بوجود آید یا ممکن است در زمان بهره‌برداری و استفاده از قطعه ترک‌هایی از جمله خستگی و خوردگی رخ دهد که نوع عیب و نقص در کارکرد قطعه و طول عمر آن موثر است. عیوب به ۳ دسته تقسیم بندی می‌شوند:

۱- عیوب بسیار خطرناک:

عیوبی که باعث خرابی زودهنگام قطعه یا موجب نقص در عملکرد قطعه باشد مانند ترک‌های عمیق و حفره که این عیوب را به عنوان عیوب غیر مجاز می‌دانند.

۲- عیوب کم خطر:

عیوبی که دارای حد مجاز و استاندارد هستند که اگر در قطعه وجود داشته باشند و بیش از حد مجاز نباشند برای قطعه خطر ساز نخواهند بود

۳- عیوب مفید:

برخی عیوب در حین ساخت صرفاً و عمداً برای افزایش استحکام در قطعات ایجاد می‌شوند تا کارایی قطعه را بالاتر ببرند مانند: رسوب و نابجایی‌ها در قطعه [2]

با وجود محصولات صنعتی و استفاده آنها در شرایط حساس و بارگذاری‌های بالا باید از کیفیت محصول اطمینان حاصل شود. به همین منظور برای بررسی کیفیت محصول دو نوع تست در نظر گرفته شده است:

• تست مخرب

• تست غیر مخرب

تست مخرب (DT):

این تست عموماً برای سنجش مقاومت مکانیکی قطعه انجام می‌شود و قطعه پس از انجام تست‌هایی نظیر آزمایش خمش و کشش و تست ضربه و سختی چون تا تخریب قطعه پیش می‌رود دیگر قابل استفاده نخواهند بود. معایبی که این تست بدنبال دارد می‌توان به موارد زیر اشاره کرد:

• سرعت پایین

• هزینه زیاد

• اطلاعات فقط مربوط به نمونه‌ها

• امکان وجود ایراد و نقص در قطعه‌های دیگر

تست غیر مخرب (NDT):

در این نوع تست پس از انجام بازرسی و اطمینان از محصول که بدون از بین رفتن یا تغییر در قطعه انجام می‌شود می‌توان آن را مورد استفاده مجدد قرار داد. در واقع یک روش غیر تهاجمی در تشخیص درستی از ساختار و اندازه و ماده به کار گرفته می‌شود. و همچنین می‌توان تمام مراحل تولید و همچنین پس از تولید و در حین کارکرد محصول نیز از این نوع تست بهره برد.

با در نظر گرفتن اینکه تست‌های غیر مخرب بر اساس جنس و روش تولید و شرایط قطعات انتخاب می‌گردد به همین منظور از تنوع بسیار بیشتری در روش‌های این نوع تست نسبت به تست مخرب ذکر کرد. دو تست پرکاربرد که با استفاده از شبکه عصبی به دقت و بهینه کردن آن کمک شده است تست اولتراسونیک و رادیوگرافی می‌باشد.

در روش اولتراسونیک نیز تلاش شده است نقص‌ها را اعم از پوکی و خوردگی تشخیص داده شود، با این حال تغییر داده‌ها بر قضاوت ذهنی بازرسی متکی است، بنابراین نتایج در برابر خطای انسانی آسیب‌پذیر است به همین منظور با استفاده از شبکه عصبی که با ۶۸۴۹ تصویر اولتراسونیک با نقص و بدون نقص با دو روش یادگیری عمیق و کم عمق (معمولی) مورد بررسی قرار گرفت و موفق به تشخیص عیوب از قطعه‌های سالم گردیدند نشان داده شد که نتایج بدست آمده از سیستم مبتنی بر یادگیری عمیق با اختلاف زیادی در دقت و تشخیص و پایداری مدل از طرح‌های یادگیری معمولی (کم عمق) بهتر عمل می‌کند. [3]

پایه رادیوگرافی جذب و نفوذ پرتوهای ایکس و گاما در قطعات می‌باشد. در رادیوگرافی صنعتی اغلب از ایزوتوپ‌های مصنوعی مانند ایریدوم ۱۹۲، کبالت ۶۰ و سزیم ۱۳۷ برای بازرسی مواد استفاده می‌شود و پرتوهای ایکس نیز بصورت الکتریکی و از طریق تیوب اشعه ایکس تولید می‌شوند. و نحوه تشخیص عیوب بصورت علائم و ناپیوستگی‌هایی است که بر روی فیلم رادیوگرافی بوجود می‌آید بطور مثال حفرات گازی به دلیل کاهش موضعی ضخامت، تصویر سیاه روی فیلم بوجود می‌آورند یا سرباره‌ها بدلیل کمتر بودن دانستیه در مقایسه با فلز پایه فیلم را سیاه می‌کند و یا ناخالصی‌های فلزی همچون تنگستن که دانستیه بیشتری دارند موجب روشن تر شدن فیلم می‌شوند. [4]

در رادیوگرافی نیز به دلیل تفسیرهای مختلف انسانی و بروز خطا از کامپیوتر و شبکه عصبی به ویژه بر پایه یادگیری عمیق استفاده شده است. که بازرسی خودکار عیوب از سه جنبه بررسی می‌شود: پیش پردازش (مانند عملیات مورفولوژیکی و عملیات آستانه گذاری که کیفیت را بهبود می‌بخشد)، تقسیم بندی نقص، طبقه بندی نقص و در نهایت مزیت مدل‌های عمیق مورد تجزیه و تحلیل قرار گرفت و کاربرد آن‌ها در بازرسی عیوب جوش معرفی شد. [5]

با استفاده از تکنیک تقویت داده‌ها و استراتژی‌های تنظیم دقیق برای دستیابی به عملکرد بهتر مجموعه داده‌های کوچک استفاده شده است که با دقت اعتبارسنجی ۹۵ درصد رویکرد رضایت بخشی را پدید آورده اند که می‌توان برای طبقه بندی عیوب جوش توسط تست رادیوگرافی مفید باشد. [6]

علاوه بر روش CNN از روش‌های دیگری نیز برای تشخیص عیوب جوش بکار گرفته شده است از جمله این روش‌ها RCNN و DNN و DCNN می‌باشد.

تشخیص خودکار عیوب در اتصالات جوش براساس همجوشی پواسون و یادگیری عمیق پیشنهاد شده است. که روش تقویت مبتنی بر همجوشی تصویر پواسون برای شبیه سازی فرسایش لبه در تصویر رادیوگرافی ارائه شده است. هیسستوگرام برای یافتن موقعیت مناسب برای همجوشی پواسون نقص جسم و ناحیه پس زمینه استفاده می‌شود. مدل تشخیص در چارچوب سریعتر R-CNN با ResNet50 از پیش آموزش دیده به دست آمده است. [7]

Tania Mezzadri Centeno و Celia Cristina Bojarczuk در دسامبر ۲۰۱۹ با استفاده از یک الگوی ترکیبی شامل سیستم‌های ایمنی مصنوعی (AIS) و یادگیری عمیق (DNN) طبقه بندی عیوب جوش و قطعات سالم را انجام داد. [8]

همچنین برای جوش‌های نامتعادل با کمک اشعه ایکس و روش یادگیری عمیق با بهره گیری از شبکه عصبی پیچیده (DCNN) با دقت ۹۷.۲ درصد که بطور قابل توجهی بهتر از استفاده روش‌های استخراج ویژگی سنتی بدست آمده است. [9]

۰۲. روش

۰۱.۲ روش افزایش داده (DATA AUGMENTATION)

با چرخش تصویر در زاویه‌های مختلف و تغییر میزان شدت و اندازه‌ی عکس می‌توانیم تصاویری جدید از قبلی‌ها بسازیم. در واقع دیتا اضافه می‌کنیم و هزینه‌ای هم برای ما ندارد و این باعث می‌شود سیستم ما جنرال‌تر بشود. باید توجه داشته باشیم سیستم ما تصویر را نمی‌بیند در واقع یک سری عدد می‌بیند و با تغییر زاویه کل اعداد ما تغییر می‌کند که به قبلی ربطی ندارد از نظر عددی اما اگر به صورت چشمی ببینیم همان تصویر rotate شده است. با این کار تعداد دیتاها شبیه به هم نمی‌شوند اما از یک لیبیل هستند. و این باعث می‌شود تا از over fitting جلوگیری شود. چراکه حساسیت شبکه به یک تصویر خاص را از بین می‌برد و از حفظ کردن تصاویر در حین آموزش شبکه جلوگیری می‌شود. [10]

۰۲.۲ شبکه‌ی عصبی عمیق

اساس کار آبی شبکه‌های عصبی برگرفته از الگوهای نورون‌های مغزی انسان است. همانطور که در مغز انسان سلول‌های عصبی مصنوعی به عنوان عنصر اصلی پردازش اطلاعات در نظر گرفته می‌شود، در شبکه‌های عصبی نیز به این صورت است. در واقع، اطلاعات ورودی که Xها هستند (نورون‌های ورودی) دارای وزن مخصوص W است. نورون‌ها اطلاعات ورودی را گرفته و داده پردازش در آنها صورت می‌گیرد. در واقع، هر ورودی بایستی در وزن خود ضرب شود تا در آخر به تابع سیگما داده شود (حاصل ضرب Xها در Wها باهم جمع می‌شود). و در آخر خروجی و نتیجه شبکه مشخص می‌شود.

فرمول شبکه عصبی:

(1)

$$[W] @ [X] + [Bias] = [Z]$$

۰۳. پیاده‌سازی و نتایج

۰۱.۳ پیش پردازش داده‌ها مطالعه

ابتدا داده‌های خام از طریق روش عملی توسط شرکت آذران جوش شاهین از چندین منطقه‌ی مورد بازرسی متفاوت توسط دستگاه رادیو گرافی جمع‌آوری شد. سپس تصاویر داده‌ها جهت ارزیابی و تایید دسته‌بندی عیوب و سالم به تیم متخصص داده‌ها شد. تعداد و مشخصات داده‌ها در جدول ۱ آورده شده است.

ششمین همایش بین‌المللی افق های نوین در مهندسی برق، کامپیوتر و مکانیک

6th International Conference on the New Horizons in
Electrical Engineering, Computer and Mechanical

www.mhconf.ir


جدول ۱. یک نمونه جدول

نوع جوش	تعداد
سالم	۴۸
ناسالم نوع اول از نوع تخلخل	۵۶
ناسالم نوع دوم از نوع ناپیوستگی خطی	۳۶

در شکل ۱ نمونه هایی از تصاویر خام گرفته شده به تفکیک عیوب قابل مشاهده است . همانطور که مشاهده میکنید خطوط سیاه داخل تصاویر نماینده ی عیوب احتمالی است .



الف (عیوب ناپیوستگی خطی



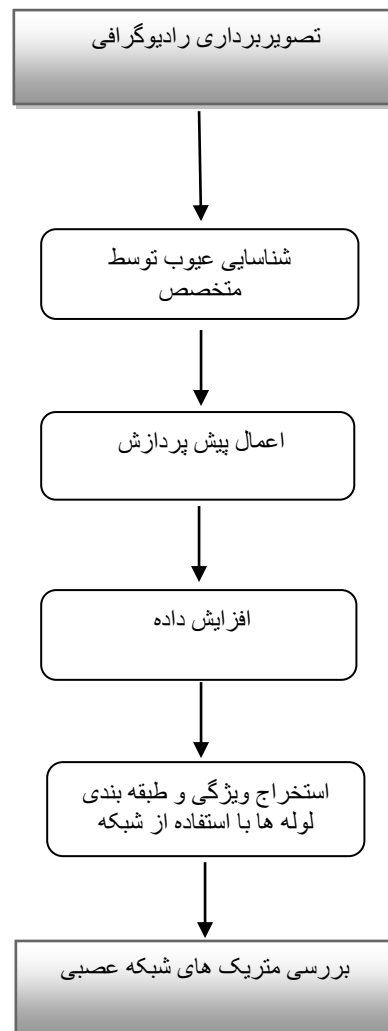
ب) عیوب تخلخل



پ) سالم

شکل ۱ (داده ی های خام گرفته شده از پایگاه داداده - الف) ناسالم ناپیوستگی خطی ، ب) ناسالم متخلخل ، پ) سالم

پردازش داده‌های خام از تصاویر رادیوگرافی عمدتاً به صورت چشمی و توسط متخصصین انجام میشود. در این بخش به بررسی ساختار روش پیشنهادی انجام شده پرداخته میشود. شکل ۲ ساختار کلی روش پیشنهادی را نشان میدهد.



شکل ۲) ساختار کلی مراحل روش پیشنهادی

۳.۳. افزایش دیتا

همانطور که در بخش قبل گفته شد، با توجه به اینکه فراهم کردن داده‌های اصلی جهت آموزش شبکه بسیار روند طولانی دارد و همچنین با توجه به مقدار محدود داده‌ها، در این پروژه از روش افزایش داده استفاده شده است. همچنین به جهت تقویت محاسبه‌ی معمولاً از روش **data augmentation** برای افزایش داده‌های ورودی استفاده میشود [۱۵۰]. در این مطالعه نیز برای اینکه بتوانیم تعداد داده‌های **train** بهتری داشته باشیم از **data augmentation** استفاده کردیم. داده‌های ورودی به طور تصادفی با چرخشی به طور تصادفی تصویر را در جهت عقربه‌های ساعت با تعداد معینی از ۰ تا ۳۶۰ به آنها اعمال شد. همچنین روشنایی تصویر را با تیره تر شدن تصادفی تصاویر، یا روشن تر کردن تصاویر یا هر دو افزایش داد. هدف این است که به یک مدل اجازه دهیم در تصاویر آموزش داده شده در سطوح مختلف نور، تعمیم دهد. متغیر دیگر افزایش زوم به صورت تصادفی است. در این حالت تصویر را بزرگنمایی می‌کند و یا مقادیر پیکسل جدیدی را در اطراف تصویر اضافه می‌کند یا به ترتیب مقادیر پیکسل را درون یابی می‌کند. محدوده بزرگنمایی [۱-مقدار، ۱+مقدار] خواهد بود که در این مثال، محدوده [۰.۷، ۱.۳]، یا بین ۷۰٪ (بزرگنمایی) و ۱۳۰٪ (کوچک نمایی) خواهد بود. در آخر نیز با رنج [۰.۵، ۱.۵] در طول و عرض جابجا و تغییر اندازه می‌یابند.



شکل ۳) یک نمونه از خروجی تصاویر با روش افزایش داده

۳.۴. شبکه‌ی عصبی عمیق

شبکه‌های عصبی کانولوشنی یکی از مدل‌های بینایی ماشین است که از سال ۲۰۱۲ بعد با ارائه‌ی الگوریتم‌های پیشرفته‌تر و پیچیده‌تر و با پیشرفت روز افزون تکنولوژی و سخت افزار مورد استفاده بیشتری قرار گرفت. با بیشتر شدن میزان پیچیدگی تصاویر تفاوت انسان و مدلها بیشتر می‌شود و همچنین به دلیل بالابردن دقت و کم کردن خطاهای انسانی در این مطالعه سعی شده تا با بررسی و طراحی شبکه عمیق و با استخراج ویژگی‌های پیچیده‌تر تصاویر به تشخیص خودکار عیوب جوشکاری در لوله‌های گاز کمک کنیم.

مدلی پیشنهادی ما بر اساس **tuning** کردن مرحله به مرحله‌ی شبکه به صورت زیر ارائه شده است. همانطور که ملاحظه میشود شبکه دارای دو لایه **Conv2D** کانولوشنی با ویژگی‌های **kernel_size=(3, 3)**, **activation="relu"** است. همچنین دارای دو لایه **MaxPooling2D** با **pool_size=(2, 2)** است.

همچنین به دلیل جلوگیری از رخ دادن اورفیت کردن در این شبکه از layers.Dropout با میزان ۵۰٪ استفاده شده است. این به آن معناست که در هر بار ترین نصف نورون‌ها به طور تصادفی خاموش میشود تا میزان حساسیت احتمالی یک نورون و بیش از اندازه متکی شدن شبکه به یک سری نورون خاص حذف شود. و در لایه ی خروجی fc با ۱۲۸ node در آخر استفاده کردیم. بهینه ساز آدام با mini-batch size برابر با ۱۰ و $\beta_1 = 0.9$ و $\beta_2 = 0.9$ ، میزان learning rate 10-3 استفاده کردیم. در این آزمایش، بیشتر موارد در ۲۰ دوره آموزشی به حالت همگرایی رسیده اند، و ما این را به عنوان ارزیابی عملکرد در هنگام اعتبار سنجی داخلی در نظر گرفتیم. همچنین میزان تقسیم بندی train به test را برابر با ۷۰ به ۳۰ درصد گرفتیم تا میزان عملکرد را دقیقتر بررسی کنیم.

۳.۴.۱. محاسبه ی متریک‌ها

بعد از طراحی شبکه و آموزش داده آن باید متریک‌های مناسب جهت ارزیابی عملکرد درست شبکه بررسی شود. متریک‌های مورد استفاده در این مقاله دقت و صحت و تابع خطا میباشد. باید دقت داشته باشیم که میخواهیم تابع خطا برابر با حداقل مقدار ممکن min شود و متریک صحت و دقت برابر حداکثر مقدار max شود. همچنین باید لحاظ داشت که شبکه دچار اورفیت نشده و داده‌ها را حفظ نکرده باشد. که راهکارهای مناسب پیشتر ارائه داده شد. در بخش زیر به بررسی فرمولهای محاسبه ی متریک‌ها میپردازیم.

۱. تابع loss function خطا

یک راه مفید برای تست عملکرد شبکه ی عصبی محاسبه ی تابع خطا است. با بررسی خروجی به دست آمده نسبت به خروجی به اصلی از فرمول loss function استفاده میکنیم. که انواع روش‌ها وجود دارد. برای طبقه بندی بیشتر از فرمول زیر استفاده میشود:

فرمول تابع خطا:

(2)

$$L(y,y) = -(y \log(y) + (1-y)\log(1-y))$$

۲. محاسبه ی میزان دقت یا accuracy

اینکه همیشه میزان loss function را چک کنیم درست نیست باید متریک‌ها را چک کنیم [1] که متوجه بشویم سیستم به چه سمتی میرود با استفاده متریک‌ها میتوان نحوه ی عملکرد مدل را پیش بینی کرد. فرمول محاسبه ی دقت:

$$\text{ACCURACY} = \frac{\text{Number of correct prediction}}{\text{Total Number of predictions made}} \quad (3)$$

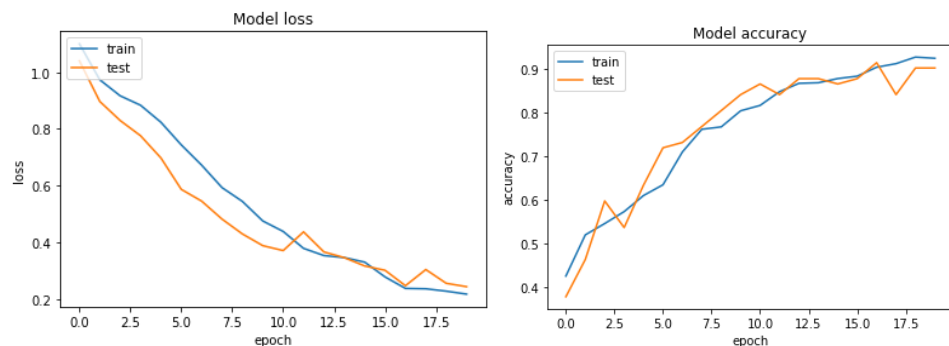
۳. محاسبه‌ی صحت در روش محاسبه‌ی میزان حساسیت یا sensitivity ابتدا تشخیص‌های درست را تقسیم بر تشخیص‌های درست و غلط میکند. در واقع محاسبه‌ی میکند که سیستم چندتا درست توانسته است پیش‌بینی کند

$$\text{Sensitivity} = \frac{\text{False positive}}{\text{True positive} + \text{False positive}}$$

مقدار تمامی متریک‌های محاسبه‌شده در جدول ۲ آورده شده است.

جدول ۲) متریک‌های به دست آمده

Model Accuracy: 0.921 Model Loss: 0.210 Model sensitivity 0.962



شکل ۴) الف- خروجی function loss برای مدل انتخاب شده. ب- خروجی accuracy برای مدل انتخاب شده.

۴. بحث و نتیجه گیری

با توجه به افزایش نیاز صنعت به تشخیص غیر مخرب عیوب جوشکاری در لوله های نفت و گاز که منجر به سرعت بالای تشخیص و هزینه های کمتر و دقت بالاتر و همچنین سالم ماندن قطعه بعد از تست ، در این پروژه یک راه حل خودکار برای دسته بندی بدون نیاز به انسان و با سرعت و دقت بالا ارائه شد تا با استفاده از کامپیوتر و شبکه های عصبی و یادگیری عمیق خطای انسانی را حذف کند و نتایج با دقت و صحت بالاتری بدست آورده شود. هماتطور که قبلا ذکر شد تست رادیوگرافی از طریق متخصصان شرکت آذران جوش شاهین جمع آوری و سپس تصاویر بر روی فیلم رادیوگرافی ظاهر شدند. در این مرحله قطعات دارای نقص و عیوب جدا سازی شده و همراه با تصاویر سالم برای آموزش به شبکه ی عصبی طراحی شده داده شد. و سپس تصاویر جدید جهت تست شبکه به آن اعمال شد . همانطور که در این مدل پیشنهادی دیده شد استفاده از روش **data augmentation** برای افزایش داده میتواند میزان دقت و کارایی شبکه را افزایش دهد . به این دلیل که ، میزان پیچیدگی تصاویر برای شبکه بیشتر میشود . همچنین مشکل فراهم آوردن داده های زیاد جهت تقویت شبکه نیز رفع میشود . در واقع مزیت استفاده از این معماری در این است که داده های دیپ لرنینگ میتواند به ازای داده های بیشتر دقت بهتری از ماشین لرنینگ ارائه دهد . که در این بین دقت و صحت به میزان قابل قبولی برابر با ۹۲٪ و ۹۶٪ رسید .

منابع

- [1] تحلیل و طبقه بندی هوشمند اتصالات عملکردی مغز در اختلال شناختی با استفاده از الگوریتم شبکه های عصبی یادگیری عمیق. فائزه لطفی کاظمی
- [2] بررسی روش تست غیر مخرب از مون حرارتی برای بررسی کیفیت اتصالات جوشی و مقایسه آن با روش تست غیر مخرب رادیوگرافی. نوید ابطحی فروشانی
- [3] تشخیص اتوماتیک عیوب جوشکاری خطوط لوله نفت در تصاویر رادیوگرافی بر اساس ویژگیهای بافتی و مبتنی بر طبقه‌بند شبکه عصبی. وحید راجی خواه
- [4] Review on Computer Aided Weld Defect Detection from Radiography Images
Appl. Sci. 2020, Sensors 10(5), 1878 Follow journal DOI: 10.3390/app10051878
- [5] Development of Radiographic Image Classification System for Weld Defect Identification
using Deep Learning Technique May 2021 DOI: 10.14299/ijser.2021.05.01
- [6] CNN Training with Twenty Samples for Crack Detection via Data Augmentation
August 2020, Sensors 20(17):4849 Follow journal DOI: 10.3390/s20174849
- [7] Detection of Weak Defects in Weld Joints Based on Poisson Fusion and Deep Learning
December 2019 DOI: 10.1007/978-981-15-1922-2_21
- [8] A Deep Artificial Immune System to Detect Weld Defects in DWDI Radiographic Images
of Petroleum Pipes December 2019 DOI: 10.1109/ACCESS.2019.2959810
- [9] Deep features based on a DCNN model for classifying imbalanced weld flaw types
January 2019 DOI: 10.1016/j.measurement.2018.09.011
- [10] Computerized Ultrasonic Imaging Inspection: From Shallow to Deep Learning
Sensors 2018, 18(11):3820 Follow journal DOI: 10.3390/s18113820