

# تشخیص خرابی در قطعات فلزی از طریق تصاویر C-scan حاصل از حسگر AMR با استفاده از روش مبتنی بر یادگیری عمیق

سعید رضائی<sup>۱</sup> و رضا حسن‌زاده پاک‌رضائی<sup>۲</sup>

## چکیده

امروزه روش‌های ارزیابی غیرمخرب (NDE) برای تشخیص خرابی در قطعات صنعتی از سه مرحله تشخیص، مکان‌یابی و تعیین مشخصات خرابی تشکیل می‌گردند. اما علی‌رغم اینکه تکنیک‌های مبتنی بر NDE موجود در صنعت دارای نتایج نسبتاً قابل قبول در آشکارسازی وجود خرابی و تعیین محل آن هستند، اما تشخیص دقیق شکل، ابعاد و عمق خرابی هنوز به‌عنوان یک چالش باقی مانده است. در این مقاله روشی برای تخمین قابل اعتماد از مشخصات خرابی در قطعات فلزی با استفاده از سیستم اندازه‌گیری برپایه آزمون جریان‌گردابی (ECT) و سیستم پس‌پردازش مبتنی بر تکنیک یادگیری عمیق ارائه شده است. به این صورت که از یک روش یادگیری عمیق به‌منظور تعیین مشخصات خرابی موجود در یکقطعه فلزی، از طریق تصاویر C-scan حاصل از میدان مغناطیسی سطح قطعه که بوسیله یک حسگر مغناطیسی مقاوم ناهمسانگر (AMR) اخذ شده‌اند، استفاده شد. در این خصوص، پس از مراحل طراحی و تنظیم شبکه عصبی پیچشی عمیق (DCNN) و اعمال آن به تصاویر C-scan اخذ شده از سیستم اندازه‌گیری، روش یادگیری عمیق ارائه شده با روش‌های شبکه‌های عصبی مصنوعی (ANNs) متداول مانند پرسپترون چند لایه (MLP) و تابع پایه شعاعی (RBF) بر روی تعدادی از نمونه‌های فلزی با خرابی مختلف مشخص مقایسه گردید. نتایج نشان دهنده برتری روش پیشنهادی برای تخمین مشخصات خرابی در مقایسه با سایر روش‌های آموزش محور کلاسیک می‌باشد.

## کلیدواژه‌ها

اندازه‌گیری میدان مغناطیسی، شبکه عصبی عمیق، مغناطیسی مقاوم ناهمسانگر، یادگیری عمیق، یادگیری ماشین.

## ۱ مقدمه

می‌تواند باعث گسترش آنها از نظر اندازه شده و در نهایت منجر به ناپایداری ساختار قطعه فلزی در هنگام فعالیت و خسارت‌های بعدی شود. بنابراین آزمون‌های غیرمخرب<sup>۱</sup> (NDT) که می‌توانند بدون آسیب رساندن به قطعه و تغییر در ماهیت آن به تجزیه و تحلیل درست خرابی قبل از ورود قطعه به مرز ناپایداری بپردازند، در صنعت مورد توجه قرار می‌گیرند [۱] و [۲].

با توجه به این واقعیت که اکثر تجهیزات موجود در صنعت از مواد رسانا و مغناطیسی ساخته شده‌اند، خرابی در ساختار آنها معمولاً منجر به تغییری معنی‌دار در ویژگی‌های الکتریکی و

در ساختارهای فلزی مانند پل‌ها، ریل‌ها، تاسیسات لوله‌ای نفت و گاز و غیره، عواملی مانند استفاده طولانی‌مدت و تنش‌های وارده به قطعات مکانیکی در هنگام فعالیت باعث بروز فرسودگی و خرابی در قطعات می‌شوند که عدم تشخیص به‌موقع و دقیق این خرابی‌ها

این مقاله در تیرماه سال ۱۳۹۸ دریافت، در بهمن‌ماه بازنگری و در اسفندماه همان سال پذیرفته شد.

<sup>۱</sup> دانشجوی کارشناسی ارشد مهندسی برق، دانشگاه گیلان، رشت

رایانامه: [saeed\\_ramezani@msc.guilan.ac.ir](mailto:saeed_ramezani@msc.guilan.ac.ir)

<sup>۲</sup> دانشکده مهندسی برق، دانشگاه گیلان، رشت

رایانامه: [hasanzadehpak@guilan.ac.ir](mailto:hasanzadehpak@guilan.ac.ir)

<sup>۱</sup>Non-Destructive Testing

بیشترین حساسیت، به دلیل نیاز به خنک کننده برای کاهش دما به دمای انتقال ابر رسانا، برای اهداف صنعتی مناسب نیستند. اما، حسگرهای MR مزایای قابل توجهی در سیستم‌های NDE ارائه می‌دهند. از مزیت‌های کلیدی حسگرهای MR می‌توان به پاسخ فرکانسی مسطح که از جریان مستقیم تا صدها مگاهرتز گسترش می‌یابد اشاره کرد که این مزیت، آنها را برای بازرسی‌های با فرکانس پایین و چند فرکانسی برای تشخیص خرابی‌ها در عمق‌های مختلف جذاب می‌کند. همچنین اندازه کوچک و مصرف کم این حسگرهای مغناطیسی، آنها را برای استفاده به صورت آرایه‌ای از حسگرها و تراشه‌ای مناسب می‌کند [۲۰] و [۲۱]. در میان حسگرهای MR، حسگرهای AMR، علی‌رغم داشتن دامنه میدان قابل اندازه‌گیری کم، به دلیل توانایی کارکردن در فرکانس‌های پایین، حساسیت به نویز کم و عدم کاهش رزولوشن شار مغناطیسی با کاهش فرکانس خواندن از حسگر (Read-Out) در صنعت ترجیح داده می‌شوند [۱۵].

پدیده AMR نمایانگر تغییرات مقاومت الکتریکی نوار فرّومغناطیسی با آلیاژ Permalloy متناسب با اندازه و جهت مغناطیس و جریان الکتریکی گذرنده از آن است. در این حسگرها، چهار نوار فرّومغناطیسی به شکل پل و تسون<sup>۱۳</sup> برای اندازه‌گیری میدان مغناطیسی در یک محور واحد استفاده می‌شوند که این اندازه‌گیری می‌تواند به صورت مطلق<sup>۱۴</sup> یا گرادیانی<sup>۱۵</sup> باشد [۲۲]. با نمونه برداری از میدان مغناطیسی روی کل سطح نمونه، ماتریسی به نام تصویر C-scan به دست می‌آید که در ادامه این تصاویر برای تجزیه و تحلیل وضعیت قطعه تحت بررسی استفاده می‌شود.

برای شناسایی ویژگی‌های خرابی بوسیله تصاویر C-scan، نیازمند استفاده از روش‌های حل مسئله معکوس هستیم. راه‌حل‌های ارائه شده برای حل مسئله معکوس به دوشاخه اصلی پدیدارشناختی و غیرپدیدارشناختی تقسیم می‌شوند. از کاستی‌های روش پدیدارشناختی این است که از زمان محاسبات بالا برای حل مسئله پیش‌رو رنج می‌برد، که معمولاً این شاخه را برای کاربردهای بلادرنگ<sup>۱۶</sup> غیرقابل قبول می‌سازد [۲۳]. از سوی دیگر، روش‌های غیرپدیدارشناختی می‌توانند ویژگی‌های خرابی را بر اساس تکنیک‌های پردازش سیگنال شناسایی کنند [۲۴]. رویکردهای مبتنی بر یادگیری، مانند شبکه‌های عصبی<sup>۱۷</sup> متعارف (NN) و منطق فازی<sup>۱۸</sup>، رایج‌ترین تکنیک‌های روش غیرپدیدارشناختی هستند. با این حال، به‌رغم عملکرد خوب آنها در تخمین مشخصات خرابی، به دلیل عملکرد بر اساس ویژگی‌های یادگیری<sup>۱۹</sup> دست‌ساز ساخته

مغناطیسی آنها می‌شود. بر این اساس، امروزه روش‌های ارزیابی غیرمخرب<sup>۱</sup> (NDE) مغناطیسی و الکترومغناطیسی مانند آزمون جریان گردابی<sup>۲</sup> (ECT) [۳] و [۴] که امروزه دارای کاربردهای وسیعی در صنعت مانند شناسایی کیفیت ساخت قطعات مکانیکی فلزی [۵] و تشخیص خرابی در قطعات صنعتی است [۶] تا [۹]، اندازه‌گیری میدان ناشی از جریان متناوب<sup>۳</sup> (ACFM) [۱۰]، نشت شار مغناطیسی<sup>۴</sup> (MFL) [۱۱] تا [۱۳] و حسگرهای مغناطیسی<sup>۵</sup> [۱۴] به‌طور گسترده استفاده می‌شوند.

روش ECT به این صورت است که یک میدان مغناطیسی متناوب بوسیله اعمال جریان الکتریکی با دامنه و فرکانس مشخص به یک سیم‌پیچ تولید می‌شود که متقابلاً باعث القای جریانهای گردابی در نمونه رسانا می‌گردد. خرابی یا هرگونه نقص در ساختار قطعه، دامنه و توزیع جریان‌های گردابی را تغییر می‌دهد که می‌توان با اندازه‌گیری میدان مغناطیسی ناشی از این جریان‌ها از طریق حسگرهای مغناطیسی، این خرابی‌ها را تشخیص داد [۱۸] و [۱۹].

عمق نفوذ جریان گردابی با فرکانس سیگنال مورد استفاده  $f$ ، هدایت الکتریکی  $\sigma$  و نفوذپذیری قطعه تحت ارزیابی  $\mu$  متناسب است که این ویژگی بررسی عمق‌های مختلف قطعه را امکانپذیر کرده و به صورت زیر محاسبه می‌شود:

$$\delta = \frac{1}{\sqrt{\pi f \mu \sigma}} \quad (1)$$

که در آن  $\delta$  نشان دهنده عمق نفوذ جریان گردابی در نمونه تحت ارزیابی است [۱۸].

امروزه، ویژگی‌های منحصر به فرد از قبیل هزینه کم، حساسیت بالا، طراحی ساده و سرعت بازرسی بالا باعث محبوبیت استفاده از حسگرهای مغناطیسی در صنعت، به‌ویژه در تاسیسات نفت و گاز شده است [۱۵] تا [۱۷]. حسگرهای مغناطیسی از انواع مختلفی نظیر سیم‌پیچ‌های القایی<sup>۶</sup>، حسگرهای اثر هال<sup>۷</sup>، فلاکس-گیت‌ها<sup>۸</sup>، دستگاه‌های تداخل کوانتمی ابررسانا<sup>۹</sup> (SQUID) و حسگرهای مغناطیسی مقاوم<sup>۱۰</sup> (MR) مانند حسگر مغناطیسی مقاوم بزرگ<sup>۱۱</sup> (GMR) و حسگر مغناطیسی مقاوم ناهمسانگر<sup>۱۲</sup> (AMR) تشکیل شده‌اند [۱۴] و [۱۵]. در میان آنها حسگرهای اثر هال دارای کمترین حساسیت و حسگرهای SQUID با وجود داشتن

<sup>1</sup>Non-Destructive Evaluation

<sup>2</sup>Eddy Current Testing

<sup>3</sup>Alternating Current Field Measurement

<sup>4</sup>Magnetic Flux Leakage

<sup>5</sup>Magnetic Sensors

<sup>6</sup>Induction Coil

<sup>7</sup>Hall effect

<sup>8</sup>Fluxgate

<sup>9</sup>Superconducting Quantum Interference Device

<sup>10</sup>Magneto-resistive

<sup>11</sup>Giant Magneto-resistive

<sup>12</sup>Anisotropic Magneto-resistive

<sup>13</sup>Wheatstone bridge

<sup>14</sup>Absolute


<sup>15</sup>Gradient

<sup>16</sup>Real-Time


<sup>17</sup>Neural Network

<sup>18</sup>Fuzzy Logic


<sup>19</sup>Learning Feature



شکل ۳: شماتیک روش اخذ تصویر C-Scan از سطح قطعه.



شکل ۱: سیستم اندازه گیری متشکل از میدل مغناطیسی و اسکنر صفحه ی x-y به همراه قطعه تحت ارزیابی.



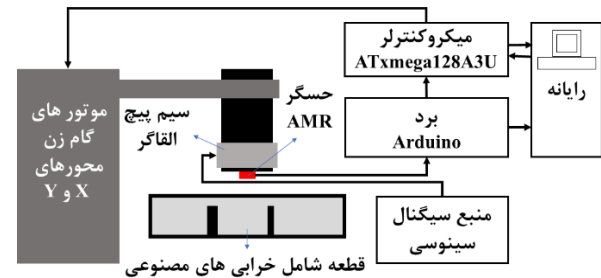
شکل ۴: (الف) سیم پیچ القاگر میدان مغناطیسی (ب) حسگر مغناطیسی.

یادگیری عمیق توضیح داده خواهد شد. نتایج تجربی در بخش چهارم ارائه خواهند شد و نهایتاً در بخش آخر نتیجه گیری ارائه خواهد شد.

## ۲ سیستم اندازه گیری

یک سیستم اندازه گیری متشکل از دو بخش دریافت میدان مغناطیسی و اسکنر صفحه  $x-y$  مورد استفاده قرار گرفته است. همانطور که در شکل ۱ مشاهده می شود، بخش دریافت میدان مغناطیسی شامل میدل مغناطیسی و منبع سیگنال و بخش اسکنر شامل بردهای کنترلی، موتورهای گام زن<sup>۲</sup> و راه انداز<sup>۳</sup> این موتورها می باشد. شماتیک کلی این سیستم در شکل ۲ آمده است. نمونه برداری از سطح قطعه به این صورت انجام می شود که در اندازه مغناطیسی شامل میدل مغناطیسی در ارتفاع  $h$  از قطعه (lift-off) اقدام به نمونه برداری از میدان  $C$ -scan با ابعاد  $M \times N$  برای هریک از محورهای  $x$ ،  $y$  و  $z$  حسگر می شود. شماتیک کلی اخذ تصویر  $C$ -scan در شکل ۳ آمده است.

میدل مغناطیسی شامل سیم پیچ القاگر میدان مغناطیسی و حسگر میدان مغناطیسی است. همانطور که در شکل ۴ (الف) نشان داده شده است، یک سیم پیچ با شعاع ۲ سانتی متر بوسیله ۵۰ دور سیم مسی با مقطع ۱۰۰ میکرومتر به منظور تولید یک میدان مغناطیسی متناوب ساخته شده است. علاوه بر این طبق نتایج آزمایشگاهی، یک سیگنال سینوسی با حداکثر جریان ۸۰ میلی آمپر



شکل ۲: بلاک دیاگرام سیستم اندازه گیری.

شده توسط ناظر انسانی، ماهیت واقعی داده های اعمال شده به شبکه نادیده گرفته می شود [۲۵]. برای غلبه بر این ضعف، روشهای یادگیری عمیق بوجود آمده اند که بزرگترین مزیت آنها نسبت به NNهای متداول عدم نیاز به ویژگی های یادگیری دست ساز بوده و متناسب با مسئله پیش رو، می توانند به طور خودکار ویژگی های یادگیری را از داده های اعمال شده به شبکه استخراج کنند که این امر می تواند منجر به بهبود قابل توجهی در صحت تحلیل و نتایج حاصل در روش های NDE شود [۲۶] تا [۲۸]. به عنوان مثال در کار ارائه شده در [۲۸] از یک شبکه یادگیری عمیق صرفاً جهت تشخیص وجود یا عدم وجود خرابی های سطحی با زاویه ی مشخص اقدام شده است.

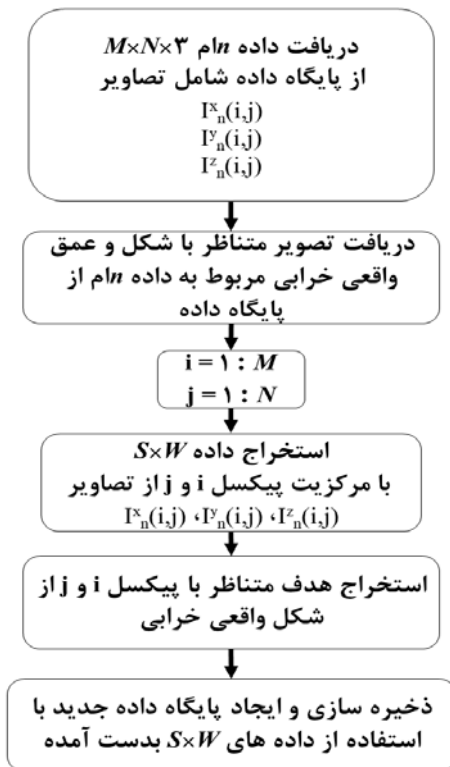
در این مقاله از یک سیستم اندازه گیری شامل یک سیم پیچ تحریک کننده<sup>۱</sup> و حسگر AMR به منظور ایجاد تصاویر  $C$ -scan استفاده شده، سپس یک روش ارزیابی محلی با استفاده از روش یادگیری عمیق برای تعیین مشخصات خرابی های سطحی و زیر سطحی با شکل و زوایای مختلف نسبت به مسیر اسکن در ساختارهای فلزی پیشنهاد می شود. علاوه بر این، کارایی روش یادگیری عمیق پیشنهادی در تخمین مشخصات خرابی با شبکه های عصبی متداول مقایسه می گردد.

در ادامه مقاله، در بخش دوم شرح مختصری از سیستم اندازه گیری داده می شود، در بخش سوم روش ارائه شده بر مبنای

<sup>۲</sup>Stepper Motor

<sup>۳</sup>Driver

<sup>۱</sup>Excitation Coil

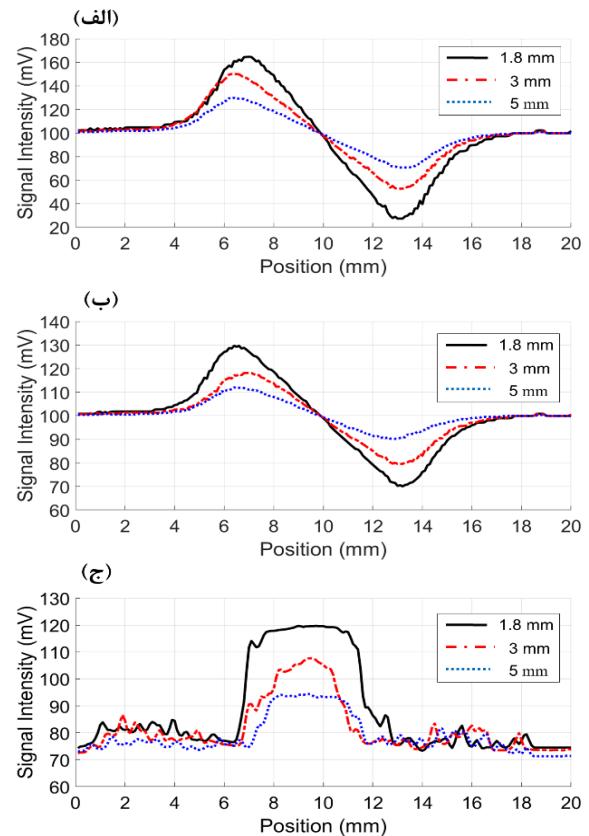


شکل ۶: نحوه ایجاد پایگاه داده‌ی جدید به منظور آموزش شبکه‌های یادگیری عمیق.

۱،۸، ۳ و ۵ میلی‌متر در شکل ۵ آمده است. همانطور که مشاهده می‌شود دامنه برای خرابی در عمق ۱،۸ میلی‌متر بیشینه و برای خرابی در عمق ۵ میلی‌متر کمینه است. از کاستی‌های روش جریان گردابی با استفاده از حسگر مغناطیسی می‌توان به این مورد اشاره کرد که در یک محور از حسگر مغناطیسی، این روش توانایی تشخیص خرابی‌هایی که جهت امتداد آنها موازی با مسیر حرکت هم‌چنین موازی با محور مغناطیسی حسگر مغناطیسی است را ندارد. بنابراین با استفاده‌ی همزمان از تصاویر C-scan محورهای  $x$ ،  $y$  و  $z$  می‌توان ضمن رفع این مشکل، کیفیت عملکرد سیستم اندازه‌گیری محلی را نسبت به شکل و زاویه خرابی در برابر مسیر اسکن، مستقل نمود.

### ۳ روش ارائه شده بر اساس یادگیری عمیق

روش‌های یادگیری عمیق<sup>۲</sup> زیرمجموعه‌ای از روش‌های یادگیری ماشین<sup>۳</sup> هستند که هدف آنها کشف چندین سطح از بازنمودهای توزیع شده توسط داده‌های ورودی است. در واقع، یادگیری عمیق از عملکرد مغز انسان الهام گرفته شده و نیاز به ابزار قدرتمند سخت‌افزاری برای انجام محاسبات پیچیده و همچنین پایگاه داده‌ی بزرگ برای رسیدن به نتایج و عملکرد مطلوب دارد. علاوه بر این، در مقایسه با روش‌های یادگیری ماشین متداول که مسئله را به بخش‌های کوچکتر تقسیم کرده و سپس آنها را حل می‌کنند، روش-



شکل ۵: برشی از تصاویر C-scan حسگر AMR مربوط به خرابی دایروی با قطر ۷ میلی‌متر و عمق‌های ۱،۸، ۳ و ۵ میلی‌متر: (الف) سیگنال خروجی محور  $x$  حسگر، (ب) سیگنال خروجی محور  $y$  حسگر، (ج) سیگنال خروجی محور  $z$  حسگر.

و فرکانس ۵۰ هرتز برای ایجاد میدان مغناطیسی مناسب انتخاب شده است [۲۹].

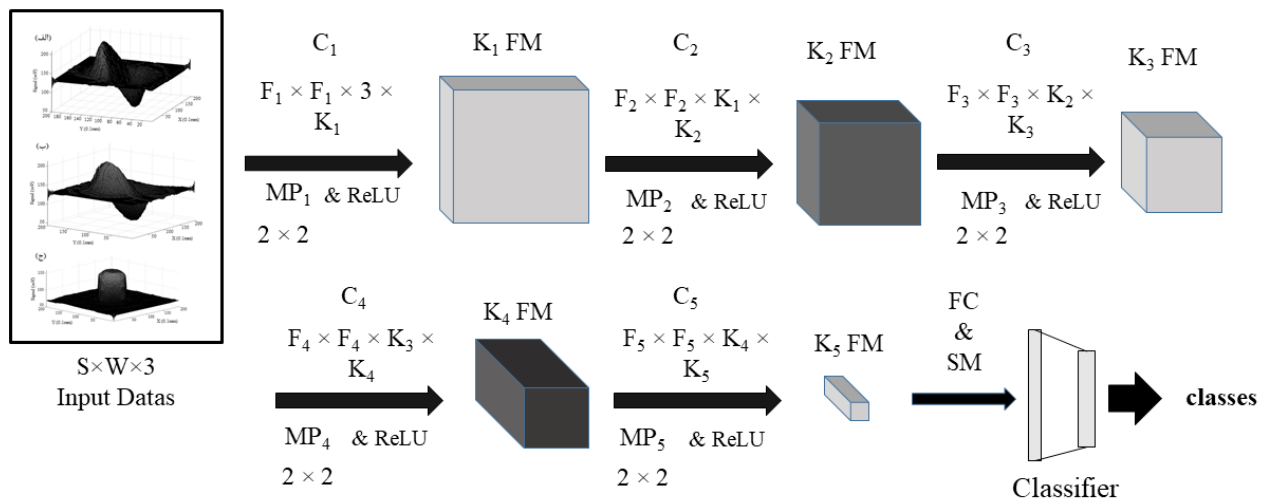
به منظور دریافت و ثبت اطلاعات میدان مغناطیسی از یک حسگر Honeywell HMC5883L AMR استفاده شده است که شکل ۴ (ب) تصویری از حسگر را نشان می‌دهد. این حسگر توانایی تشخیص و اندازه‌گیری میدان مغناطیسی در محور  $x$  و  $y$  به صورت گرادینانی و به صورت مطلق در محور  $z$  را به طور همزمان و با دقت بالای تا ۵ میلی‌گوس دارد.

مزیت دیگر این حسگر مربوط به توانایی آن در ارتباط دیجیتال با پردازنده اصلی از طریق پروتکل ارتباطی دوسیم<sup>۱</sup> ( $I^2C$ ) است. این ویژگی، علاوه بر افزایش سرعت ارتباط، مانع از تاثیر نویز محیطی بر خروجی حسگر می‌شود. همچنین لازم به ذکر است که در یک فرکانس القایی خاص (با توجه به معادله (۱))، اختلاف سیگنال خروجی حسگر با عمق خرابی رابطه‌ی عکس دارد. به این صورت که هرچه خرابی در عمق بیشتری باشد، سیگنال خروجی دریافتی حسگر دارای دامنه کمتر و با نویز بیشتر است. به عنوان مثال برشی از تصویر C-scan محور  $x$ ،  $y$  و  $z$  مربوط به خرابی‌های استوانه‌ای با سطح مقطع دایروی با قطر ثابت ۷ میلی‌متر و عمق‌های متغییر

<sup>2</sup>Deep Learning

<sup>3</sup>Machine Learning

<sup>1</sup>Inter-Integrated Circuit



شکل ۷: شماتیک کلی DCNN هفت لایه طراحی شده به منظور شناسایی مشخصات خرابی: C بیانگر Convolution، MP بیانگر Max-Soft، ReLU، pooling، FM بیانگر Feature Maps، Fully Connected بیانگر FC و SM بیانگر Soft-Max loss است.

روش یادگیری عمیق استفاده شده در این مقاله، یک شبکه عصبی پیچشی عمیق  $S \times W \times 3$ -DCNN هفت لایه شامل یک لایه ورودی  $n=5, S \times W \times 3$  لایه‌ی پنهان و یک لایه Soft-Max loss است. نمایی از معماری این شبکه در شکل ۷ آورده شده است. ورودی شبکه، داده‌هایی با اندازه  $S \times W \times 3$  هستند که توسط پایگاه داده تأمین می‌شود. روش کار این شبکه به این گونه است که در لایه پنهان  $n$ ام، در ابتدا، ورودی به یک زیرلایه‌ی پیچشی شامل بانک فیلتر<sup>۲</sup> با اندازه  $F_n \times F_n \times K_{n-1} \times K_n$  اعمال می‌شود که به استخراج  $K_n$  نگاشت ویژگی<sup>۳</sup> (FM) منجر می‌شود. نحوه انتخاب پارامترها به این صورت است که برای شبکه عصبی عمیق با داده ورودی  $S \times W \times 3$ ، اندازه بانک فیلتر در لایه نخست برابر با  $F_n \times F_n \times 3 \times K_n$  انتخاب شده و در ادامه برای بانک‌های فیلتر لایه‌های بعدی این اندازه‌ها طوری انتخاب می‌شوند که در لایه‌ی آخر به یک بردار ویژگی برسیم. سپس، به‌طور معمول، تبدیل غیرخطی داده‌ها با استفاده از یک تابع هیپربولیک<sup>۴</sup> یا واحد یکسو کننده خطی<sup>۵</sup> (ReLU) اتخاذ می‌شود. در زیرلایه زیرنمونه‌گیری<sup>۶</sup>، اطلاعات ارائه شده توسط زیرلایه پیچشی با اعمال عملگرهای متوسط‌گیر یا ماکزیمم‌گیر<sup>۷</sup> ( $MP_n$ ) با یکدیگر ادغام می‌شوند که به تولید خروجی لایه پنهان  $n$  (ورودی لایه پنهان  $n+1$ ) منجر می‌شود. در نهایت، خروجی آخرین لایه پنهان به یک لایه تمام متصل<sup>۸</sup> (FC) از نرون‌ها (و Soft-Max) به منظور ادغام تمامی

های یادگیری عمیق به طور کامل اقدام به حل مسئله می‌کنند [۲۶].

روش یادگیری عمیق دارای انواع مختلفی است. یکی از پرکاربردترین آنها که به منظور حل مسائل با ورودی تصویر استفاده می‌شود، شبکه عصبی پیچشی عمیق<sup>۱</sup> است که به صورت اختصاری به آن DCNN گفته می‌شود. این شبکه برپایه‌ی شبکه عصبی متعارف پیچشی بوده و شامل یک یا چند لایه‌ی پنهان است که منجر به استخراج خودکار ویژگی‌های آموزشی از داده‌های ورودی می‌شود [۲۶]. این ساختار چند لایه عمیق توانایی شناسایی توابع توضیحی را حتی در مسائل پیچیده دارد که باعث می‌شود عملکرد آن نسبت به شبکه‌های عصبی متعارف بسیار بهتر شود. همچنین این نکته که خود شبکه توانایی استخراج ویژگی‌ها را از داده‌های ارائه شده دارد باعث می‌شود که عمومیت بسیار بیشتری برای حل مسائل پیچیده مختلف داشته باشد.

در این مقاله با توجه به این واقعیت که سیگنال مغناطیسی دریافتی در یک نقطه از فضا، برآیند تاثیرات صفحه‌ای از نقاط به مرکزیت آن نقطه است، لذا به منظور آموزش شبکه یادگیری عمیق، بجای اعمال مستقیم تصاویر C-scan اخذ شده توسط سیستم اندازه‌گیری به شبکه‌ها برای مرحله‌ی آموزش، پنجره‌هایی با اندازه  $S \times W \times 3$  از تصاویر C-scan با اندازه‌ی  $M \times N \times 3$  و به مرکزیت هر پیکسل از تصویر استخراج می‌گردد. همچنین آموزش شبکه به نحوی صورت می‌گیرد که برای هر پیکسل از داده‌ی آزمایش، متناسب با صفحه‌ای از سیگنال خروجی حسگر با اندازه‌ی  $S \times W \times 3$ ، سیستم ارزیابی محلی تعیین می‌کند که پیکسل جزء ناحیه‌ی سالم یا جزء ناحیه‌ی خرابی با عمق مشخص است. نحوه ساخت پایگاه‌های داده جدید در شکل ۶ آمده است.

<sup>2</sup>Filter Bank

<sup>3</sup>Feature Map

<sup>4</sup>Hyperbolic Tangent Function

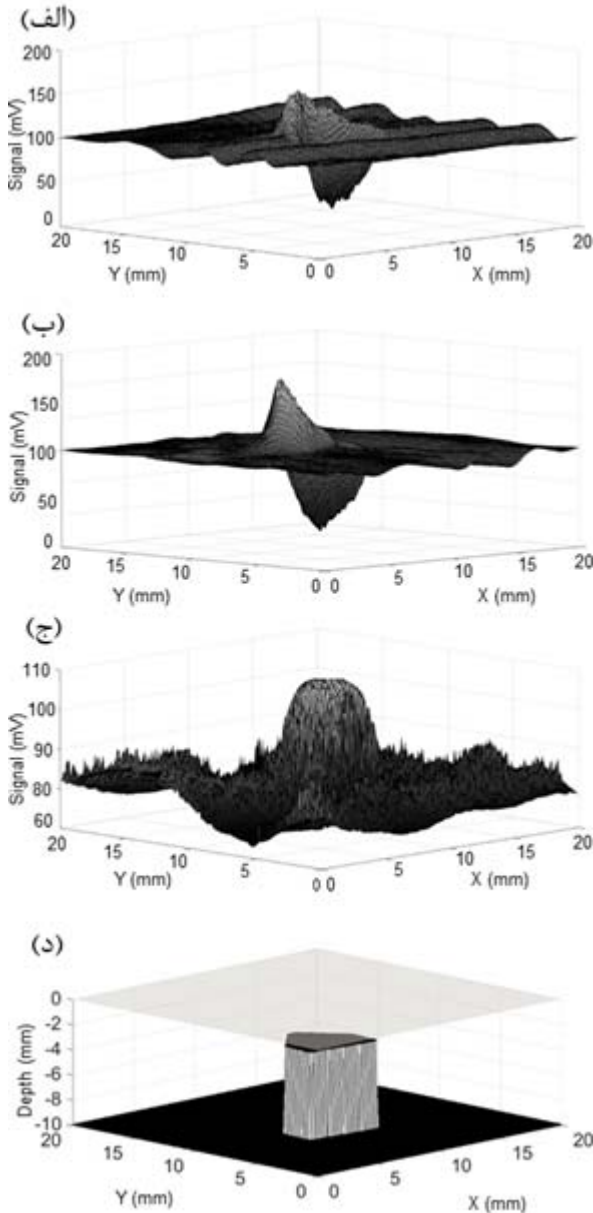
<sup>5</sup>Rectified Linear Unit

<sup>6</sup>Subsampling

<sup>7</sup>Max pooling

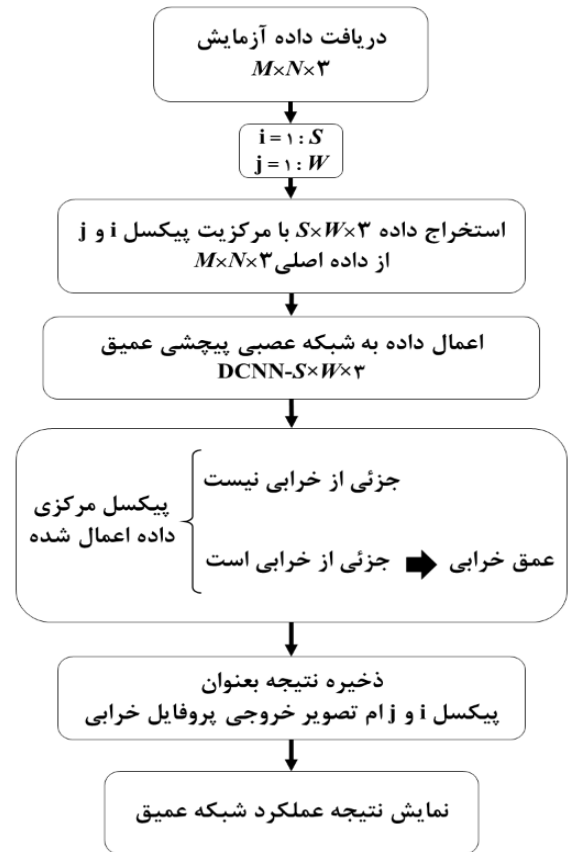
<sup>8</sup>Fully Connected

<sup>1</sup>Deep convolutional Neural Network



شکل ۹: سیگنال‌های میدان مغناطیسی اخذ شده توسط حسگر، مربوط به خرابی پنج ضلعیبا عمق ۳ میلی‌متر، (الف) خروجی محور x حسگر، (ب) خروجی محور y حسگر، (ج) خروجی محور z حسگر، (د) شکل واقعی خرابی.

اندازه  $M \times N \times 3 = 200 \times 200 \times 3$  متناظر با خرابی‌ها ساخته‌شد. شکل‌های ۹ و ۱۰ به ترتیب نمونه‌ای از سیگنال‌های مربوط به خرابی پنج ضلعی در عمق ۳ میلی‌متر و خرابی شش ضلعی در عمق ۱٫۸ میلی‌متری را نشان می‌دهند. لازم به ذکر است که به دلیل عملکرد حسگر به صورت مطلق در محور z، تصویر C-scan خروجی این محور با تصویر محورهای x و y متفاوت است، همچنین اگرچه به نظر می‌رسد که تصویر محور z شکلی کلی از خرابی را نشان می‌دهد، اما مشخصات آن برابر با مشخصات واقعی خرابی نمی‌باشد و صرفاً شکلی گوسی فرم با دامنه‌ای متناسب با عمق خرابی است.




شکل ۸: نحوه تخمین مشخصات خرابی متناظر با میدان مغناطیسی حاصل از آن.

ویژگی‌های یادگیری استخراج شده) و یک کلاسبند<sup>۱</sup> برای شناسایی کلاس مسئله اعمال می‌شود [۲۷] تا [۳۱]. سپس در مرحله آزمایش عملکرد شبکه یادگیری عمیق، داده‌های با اندازه  $S \times W \times 3$  از تصاویر C-scan جدید با ابعاد  $M \times N \times 3$  (خارج از پایگاه داده اصلی) استخراج شده و به DCNNهای آموزش یافته در مرحله قبل اعمال می‌شود. شماتیک کلی تعیین مشخصات خرابی در شکل ۸ نمایش داده شده است.

#### ۴ نتایج آزمایشگاهی

نمونه مورد بررسی یک قطعه فلزی با ضخامت ۱۰ میلی‌متر حاوی خرابی‌های مصنوعی به صورت استوانه‌هایی با عمق‌های ثابت ۱٫۸، ۳ و ۵ میلی‌متری از سطح فلز و سطوح مقطعی ۱- دایروی با قطر ۳ میلی‌متر، ۲- دایروی با قطر ۷ میلی‌متر، ۳- شش ضلعی با مساحت تقریبی ۲۴ میلی‌مترمربع، ۴- پنج ضلعی با مساحت تقریبی ۱۹ میلی‌مترمربع و ۵- چهارضلعی با مساحت تقریبی ۲۵ میلی‌مترمربع می‌باشند. ابتدا با استفاده از سیستم اندازه‌گیری و نمونه‌گیری از میدان مغناطیسی بر سطح نمونه با اندازه  $X \times Y = 2 \times 2 \text{ cm}^2$ ،  $r = 100 \mu\text{m}$  در هر محور و  $h = 1 \text{ mm}$ ، یک پایگاه داده متشکل از ۷۰ تصویر C-scan محورهای x، y و z با

<sup>1</sup>Classifier



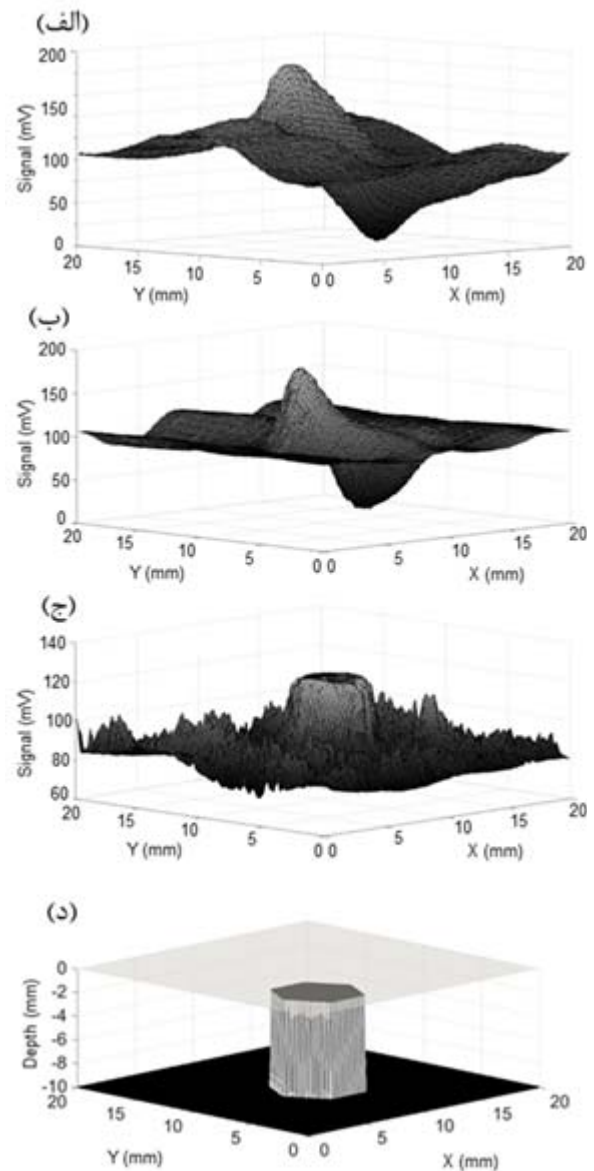
شکل ۱۱: شماتیک روش اخذ تصویر C-Scan از سطح قطعه.

سالم نسبت به تعداد پنجره‌های منتسب به نقاط خرابی، ۳ پایگاه داده‌ی جدید شامل ۱۷۳۵۴۱ داده با اندازه  $S \times W \times 3$  ساخته می‌گردد. سپس ۸۰٪ از این داده‌های پایگاه داده برای آموزش و ۲۰٪ باقیمانده برای ارزیابی در مرحله‌ی آموزش شبکه‌ها استفاده شد. هر شبکه  $DCNN-41 \times 41 \times 3$ ،  $DCNN-51 \times 51 \times 3$  و  $DCNN-61 \times 61 \times 3$  به‌طور جداگانه توسط پایگاه داده جدید آموزش داده شده‌اند. برای آموزش هر  $DCNN$ ، روش تقریب گرادینان نزولی با پارامترهای موجود در جدول ۳ استفاده شده است. در مرحله ارزیابی عملکرد شبکه یادگیری عمیق، پنجره‌های  $S \times W \times 3$  (شامل ابعاد  $41 \times 41 \times 3$ ،  $51 \times 51 \times 3$  و  $61 \times 61 \times 3$ ) از تصاویر C-scan جدید با ابعاد  $M \times N \times 3 = 200 \times 200 \times 3$  خارج از پایگاه داده‌ی اصلی استخراج و به  $DCNN$ ‌ها اعمال می‌شود.

یک مثال از تصاویر C-scan محورهای  $x$ ،  $y$  و  $z$  از خرابی استوانه‌ای با قطر ۷ و عمق ۱٫۸ میلی‌متر و شکل واقعی آن در شکل ۱۱ نمایش داده شده است. همچنین برای خرابی‌های استوانه‌ای با سطح مقطع دایروی با قطر ۷ میلی‌متر در عمق ۱٫۸ میلی‌متری، شش ضلعی در عمق ۱٫۸ میلی‌متری و پنج ضلعی در عمق ۳ میلی‌متری سطح قطعه، خروجی  $DCNN-41 \times 41 \times 3$ ،  $DCNN-51 \times 51 \times 3$  و  $DCNN-61 \times 61 \times 3$  و خطای بین پروفایل خرابی تخمین زده شده و مشخصات واقعی آن به ترتیب در شکل‌های ۱۲، ۱۳ و ۱۴ آورده شده است. همانطور که مشاهده می‌شود،  $DCNN-61 \times 61 \times 3$  دارای بهترین نتیجه در هر سه مورد است.

به منظور مقایسه عملکرد  $DCNN$ ‌ها با شبکه‌های عصبی مصنوعی متداول پرسپترون چندلایه<sup>۱</sup> (MLP) و تابع پایه شعاعی<sup>۲</sup> (RBF) که در کارهای گذشته برای تخمین مشخصات خرابی‌ها استفاده شده‌اند، شبکه‌های MLP دو لایه و RBF با پارامترهای ارائه شده در جدول ۳، طراحی و پیاده‌سازی شده‌اند [۲۵] و [۳۲] و [۳۳].

از آنجا که برای  $DCNN$ ‌ها، پایگاه داده با اندازه‌ی پنجره  $S \times W \times 3 = 61 \times 61 \times 3$  دارای بهترین نتیجه بوده است، برای آموزش دو شبکه عصبی مذکور نیز از این پایگاه داده استفاده شد.



شکل ۱۰: سیگنال‌های میدان مغناطیسی اخذ شده توسط حسگر، مربوط به خرابی شش ضلعی با عمق ۱٫۸ میلی‌متر، (الف) خروجی محور  $x$  حسگر، (ب) خروجی محور  $y$  حسگر، (ج) خروجی محور  $z$  حسگر، (د) شکل واقعی خرابی.

به منظور تعیین مشخصات خرابی‌ها نظیر شکل خرابی و عمق آن از طریق تصاویر C-scan، سه  $DCNN-S \times W \times 3$  شامل ۵ لایه پنهان و یک Soft-Max loss طراحی شده‌اند. به عنوان مثال  $DCNN-61 \times 61 \times 3$  شامل ۵ لایه پنهان متشکل از زیرلایه‌های توابع پیچشی با بانک‌های فیلتر، توابع فعال سازی ReLU، توابع ماکزیمم‌گیر محلی MP با اندازه‌ی  $2 \times 2$  و یک لایه تمام متصل از نرون است. مشخصات بانک‌های فیلتر و برخی پارامترهای شبکه‌ی یادگیری عمیق  $DCNN-61 \times 61 \times 3$  به ترتیب در جدول‌های ۱ و ۲ آورده شده است.

سپس در فاز آموزش، پنجره‌هایی با ابعاد  $S \times W \times 3$  (شامل ابعاد  $41 \times 41 \times 3$ ،  $51 \times 51 \times 3$  و  $61 \times 61 \times 3$ ) از پایگاه داده با ابعاد  $M \times N \times 3 = 200 \times 200 \times 3$  استخراج و پس از زیر نمونه‌گیری از این داده‌ها (به دلیل بالا بودن تعداد پنجره‌های منتسب به نقاط

<sup>۱</sup>Multi-Layer Perceptron

<sup>۲</sup>Radial Basis Function

جدول ۲: مشخصات برخی پارامترهای مرحله آموزش شبکه‌های یادگیری عمیق DCNN، شبکه عصبی MLP و RBF.

نماد	مقدار		توضیح
	شبکه‌های یادگیری عمیق DCNN	شبکه‌های MLP و RBF	
پارامترهای مربوط به ساختار شبکه	$F_n \times F_n$ $K_n$ mini-batch	$4 \times 4$ و $5 \times 5$ و $6 \times 6$ $4 < K_n < 500$ ۱۰۰	- - - اندازه بانک‌های فیلتر جهت استخراج ویژگی از داده‌ی ورودی. اندازه بردار ویژگی که در هر لایه از داده ورودی استخراج می‌شود. مجموعه آموزشی به دسته‌های ۱۰۰ تایی شکسته شده و برای هر دسته گرادیان محاسبه می‌شود.
پارامترهای مربوط به ساختار داده‌های استفاده شده	$M \times N \times 3$ $S \times W \times 3$ $G \times H$	$200 \times 200 \times 3$ $51 \times 51 \times 3$ و $61 \times 61 \times 3$ $41 \times 41 \times 3$ -	- - $15 \times 15$ و $9 \times 9$ و $7 \times 7$ اندازه تصاویر اصلی C-scan اخذ شده توسط سیستم اندازه‌گیری. اندازه پنجره‌های استخراج شده از تصاویر اصلی C-scan به منظور آموزش شبکه‌های یادگیری عمیق. به منظور استخراج ویژگی از تصاویر $61 \times 61 \times 3 = S \times W \times 3$ ، از تبدیل هیستوگرام گرادیان جهت‌دار (HOG) با اندازه پنجره‌های متفاوت $G \times H$ استفاده شده است.
DCNN- $S \times W \times 3$	DCNN- $61 \times 61 \times 3$	-	شبکه یادگیری عمیق که برای آموزش آن از پایگاه داده با اندازه $61 \times 61 \times 3$ استفاده شده است.
MLP- $S \times W \times 3$ - $G \times H$	-	MLP- $61 \times 61 \times 3$ $-7 \times 7$	شبکه عصبی پرسپترون که برای آموزش آن از پایگاه داده با اندازه $61 \times 61 \times 3$ استفاده شده است. همچنین برای استخراج ویژگی از این پایگاه داده از تبدیل هیستوگرام گرادیان جهت‌دار (HOG) با اندازه پنجره‌های $7 \times 7$ استفاده شده است.

بر اساس نتایج، شبکه عصبی MLP عملکرد بهتری در تخمین مشخصات خرابی در مقایسه با RBF داشته است. نتایج حاصل از سه  $MLP-61 \times 61 \times 3-G \times H$  و خطای بین پروفایل خرابی تخمین زده شده و مشخصات واقعی آن برای خرابی‌های استوانه‌ای با سطح مقطع دایروی با قطر ۷ میلی‌متر در عمق ۱٫۸ میلی‌متری، شش ضلعی در عمق ۱٫۸ میلی‌متری و پنج ضلعی در عمق ۳ میلی‌متری سطح قطعه به ترتیب در شکل‌های ۱۵، ۱۶ و ۱۷ آورده شده است.


قابل ذکر است از آنجا که شبکه‌های عصبی توانایی استخراج خودکار ویژگی‌های یادگیری را نداشته و مبتنی بر ویژگی‌های ارائه شده توسط ناظر انسانی هستند، بنابراین، برای استخراج ویژگی‌ها، از روش هیستوگرام گرادیان جهت‌دار (HOG) با اندازه پنجره‌های اشاره شده در جدول ۱، جهت استخراج زاویه و اندازه‌ی لبه‌ها در تصاویر استفاده شد. مشخصات برخی پارامترهای آموزش این شبکه‌ها در جدول ۳ آورده شده است.

جدول ۱: مشخصات بانک‌های فیلتر شبکه یادگیری عمیق DCNN- $61 \times 61 \times 3$  پنج لایه.

فیلتر بانک لایه nام	طول × عرض	بردار ویژگی	
		ورودی	خروجی
لایه اول	$F_1 \times F_1 = 5 \times 5$	۳	$K_1 = 10$
لایه دوم	$F_2 \times F_2 = 6 \times 6$	$K_1 = 10$	$K_2 = 20$
لایه سوم	$F_3 \times F_3 = 5 \times 5$	$K_2 = 20$	$K_3 = 100$
لایه چهارم	$F_4 \times F_4 = 5 \times 5$	$K_3 = 100$	$K_4 = 500$
لایه پنجم	$F_5 \times F_5 = 4 \times 4$	$K_4 = 500$	$K_5 = 4$

جدول ۳: پارامترهای مرحله آموزش برای شبکه‌های استفاده شده.

نوع شبکه	دوره یادگیری (Epoch)	نرخ یادگیری	تعداد نرون	spread factor
DCNN	۵۰۰	$5 \times 10^{-4}$	۳۰ = لایه اول ۱۰ = لایه دوم	-
MLP	۲۵۰	$5 \times 10^{-4}$	۳۰ = لایه اول ۱۰ = لایه دوم	-
RBF	-	$5 \times 10^{-4}$	۲۵۰	۰٫۱

شکل ۱۲: خروجی شبکه‌های یادگیری عمیق: (۱)  $DCNN 61 \times 61 \times 3$ ،

(۲)  $DCNN-51 \times 51 \times 3$ ، (۳)  $DCNN-41 \times 41 \times 3$  برای خرابی استوانه‌ای در عمق ۱٫۸ میلی‌متر، سطرها: الف- پروفایل عمق، ب- نمای سطح مقطع و شکل واقعی خرابی (به رنگ قرمز)، ج- اختلاف نواحی تخمینی و واقعی.

در نهایت، برای مقایسه عملکرد DCNN ها با شبکه‌های عصبی MLP و RBF در تشخیص مشخصات خرابی، پارامتر



جدول ۴: عملکرد شبکه‌های عصبی پیچشی عمیق و شبکه‌های عصبی پرسپترون چندلایه و تابع شعاعی بر مبنای فاکتورهای RMSE، Precision و Accuracy.

نوع خرابی و معیارهای سنجش	استوانه‌ای			پنج ضلعی			شش ضلعی			
	RMSE	ACC	PPV	RMSE	ACC	PPV	RMSE	ACC	PPV	
نوع روش تعیین مشخصات خرابی	RBF-۶۱×۶۱×۳-۷×۷	۰,۵۰۲	۰,۷۴۴	۰,۲۵۶	۰,۵۰۷	۰,۷۴۱	۰,۱۵۶	۰,۲۶۵	۰,۹۳۷	۰,۴۵۸
	RBF-۶۱×۶۱×۳-۹×۹	۰,۵۷۱	۰,۶۶۵	۰,۱۹۳	۰,۶۷۲	۰,۵۶۶	۰,۰۳۷	۰,۳۱۵	۰,۹۰۸	۰,۳۶۲
	RBF-۶۱×۶۱×۳-۱۵×۱۵	۰,۶۱۱	۰,۶۵۱	۰,۱۷۸	۰,۶۸۷	۰,۵۶۱	۰,۰۲۰	۰,۴۰۲	۰,۸۲۶	۰,۲۱۶
	MLP-۶۱×۶۱×۳-۷×۷	۰,۳۲۶	۰,۸۹۳	۰,۴۸۲	۰,۳۳۱	۰,۸۹۰	۰,۲۲۲	۰,۲۱۰	۰,۹۵۶	۰,۵۹۲
	MLP-۶۱×۶۱×۳-۹×۹	۰,۴۴۰	۰,۸۰۵	۰,۳۱۸	۰,۵۴۲	۰,۷۰۶	۰,۰۸۹	۰,۲۳۷	۰,۹۴۴	۰,۵۰۳
	MLP-۶۱×۶۱×۳-۱۵×۱۵	۰,۵۶۳	۰,۶۸۲	۰,۲۱۳	۰,۶۳۹	۰,۵۹۲	۰,۰۵۵	۰,۲۹۴	۰,۹۱۳	۰,۳۶۹
	DCNN-۴۱×۴۱×۳	۰,۱۶۳	۰,۹۷۳	۰,۸۲۵	۰,۲۵۱	۰,۹۳۷	۰,۳۹۱	۰,۱۷۰	۰,۹۷۱	۰,۷۱۱
	DCNN-۵۱×۵۱×۳	۰,۱۳۲	۰,۹۸۲	۰,۸۶۶	۰,۱۶۳	۰,۹۷۳	۰,۶۹۲	۰,۱۱۷	۰,۹۸۶	۰,۸۹۶
	DCNN-۶۱×۶۱×۳	۰,۰۹۰	۰,۹۹۱	۰,۹۴۸	۰,۱۰۱	۰,۹۹۰	۰,۸۷۵	۰,۱۰۶	۰,۹۸۹	۰,۸۹۶

$$PPV = \frac{TP}{TP+FP} \quad (۴)$$

که در آنها (TP(True Positive)، TN(True Negative)، FP(False Positive) و FN(False Negative) پارامترهای ماتریس درهم‌ریختگی<sup>۴</sup> بوده و مطابق شکل ۱۸ به دست آورده می‌شوند.

لازم به ذکر است که ACC عملکرد کلی شبکه در تشخیص مشخصات و PVV نشان دهنده میزان دقت شبکه در تشخیص درست فقط خرابی است، همچنین مقدار کوچکتر برای RMSE نشان دهنده عملکرد مناسب‌تر شبکه در تخمین شکل خرابی است. خلاصه نتایج آزمایشات در جدول ۴ ارائه شده است که بیانگر برتری مطلق شبکه‌های DCNN نسبت به MLP و RBF می‌باشد.

## ۵ نتیجه‌گیری

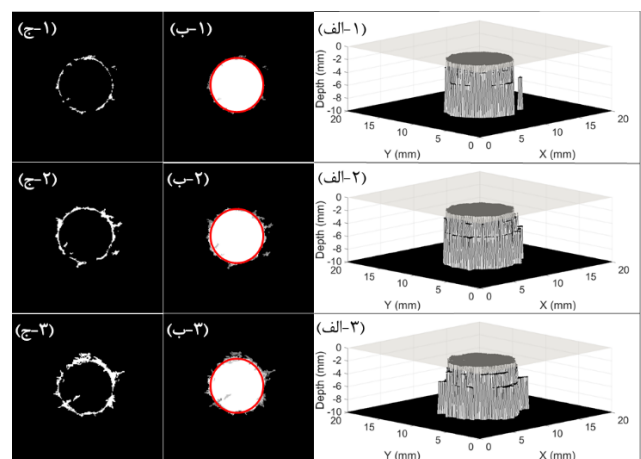
در این مقاله، یک روش یادگیری عمیق به عنوان روش حل مسئله معکوس برای تشخیص مشخصات خرابی در ساختارهای فلزی از طریق تصاویر C-scan حاصل از حسگر AMR پیشنهاد شده است. در ابتدا یک پایگاه داده شامل تصاویر C-scan از سه محور x, y و z با استفاده از حسگر AMR و یک سیم‌پیچ القاکننده میدان مغناطیسی ایجاد شده است. سپس سه DCNN مجزا جهت پردازش ورودی‌هایی با اندازه متفاوت به منظور تشخیص شکل و عمق خرابی، طراحی و آموزش داده شده است. علاوه بر این، برای مقایسه کارایی روش یادگیری عمیق، شبکه‌های عصبی MLP و RBF طراحی و اجرا شده و عملکرد این سه روش با استفاده از معیارهای مختلف شناخته شده مورد مقایسه قرار گرفته‌اند. لازم به ذکر است که با استفاده از روش ارائه شده در این مقاله، علاوه بر تشخیص وجود یا عدم وجود خرابی‌های سطحی و زیرسطحی، مشخصات خرابی‌ها نظیر شکل خرابی و عمق محلی خرابی

خطای متوسط مربعات ریشه<sup>۱</sup> (RMSE)، درستی<sup>۲</sup> (ACC) و دقت<sup>۳</sup> (PPV) استفاده شده است. این پارامترها را می‌توان به صورت زیر محاسبه کرد:

$$RMSE = \sqrt{\frac{1}{M \times N} \sum_{i=1}^M \sum_{j=1}^N (P_{ij} - O_{ij})^2} \quad (۲)$$

که در آن  $O_{ij}$  به ترتیب داده‌های تصویر تخمین زده شده توسط سیستم ارزیابی محلی و شکل واقعی خرابی هستند و  $M \times N$  تعداد داده‌ها است.

$$ACC = \frac{TP+TN}{TP+TN+FP+FN} \quad (۳)$$




شکل ۱۳: خروجی شبکه‌های یادگیری عمیق: (۱) DCNN-۶۱×۶۱×۳، (۲) DCNN-۵۱×۵۱×۳، (۳) DCNN-۴۱×۴۱×۳ برای خرابی شش ضلعی در عمق ۱,۸ میلی‌متر، سطرها: الف- پروفایل عمق، ب- نمای سطح مقطع و شکل واقعی خرابی (به رنگ قرمز)، ج- اختلاف نواحی تخمینی و واقعی.

<sup>۱</sup>Root Mean Square Error

<sup>۲</sup>Accuracy

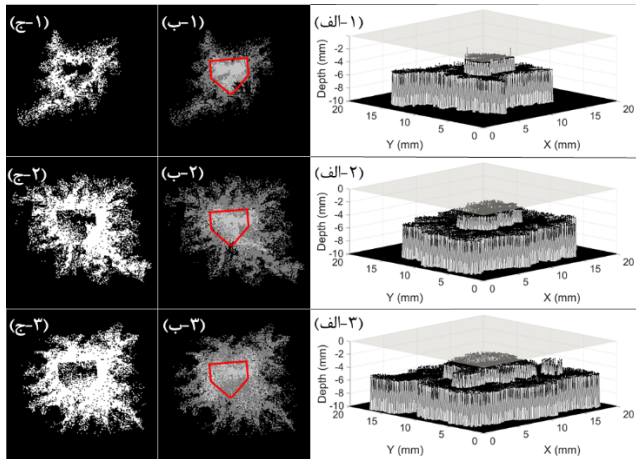
<sup>۳</sup>Positive Predictive Value

<sup>۴</sup>Confusion Matrix



شکل ۱۶: خروجی شبکه‌های عصبی MLP (۱:  $7 \times 7$  -

MLP- $61 \times 61 \times 3$ ، MLP- $9 \times 9$  (۲، MLP- $61 \times 61 \times 3$ ، MLP- $15 \times 15$  (۳، برای خرابی شش ضلعی در عمق ۱٫۸ میلی‌متر، سطرها: الف- پروفایل عمق، ب- نمای سطح مقطع و شکل واقعی خرابی (به رنگ قرمز)، ج- اختلاف نواحی تخمینی و واقعی.



شکل ۱۷: خروجی شبکه‌های عصبی MLP (۱:  $7 \times 7$  -

MLP- $61 \times 61 \times 3$  (۲، MLP- $61 \times 61 \times 3$ ، MLP- $15 \times 15$  (۳، برای خرابی پنج ضلعی در عمق ۳ میلی‌متر، سطرها: الف- پروفایل عمق، ب- نمای سطح مقطع و شکل واقعی خرابی (به رنگ قرمز)، ج- اختلاف نواحی تخمینی و واقعی.

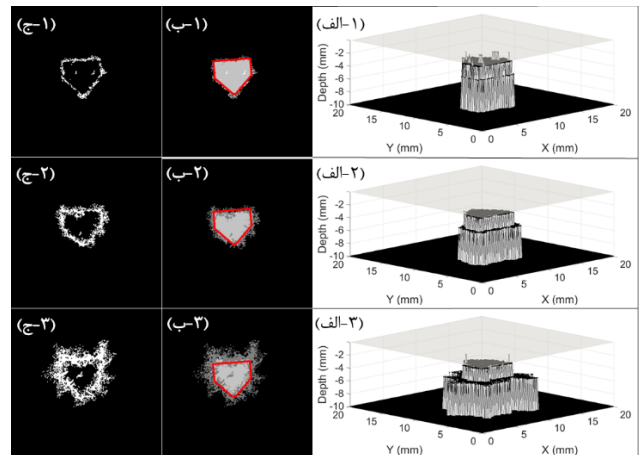
کلاس تشخیص داده شده

	+	-
+	TP مثبت صحیح	FN منفی کاذب
-	FP مثبت کاذب	TN منفی صحیح

کلاس واقعی

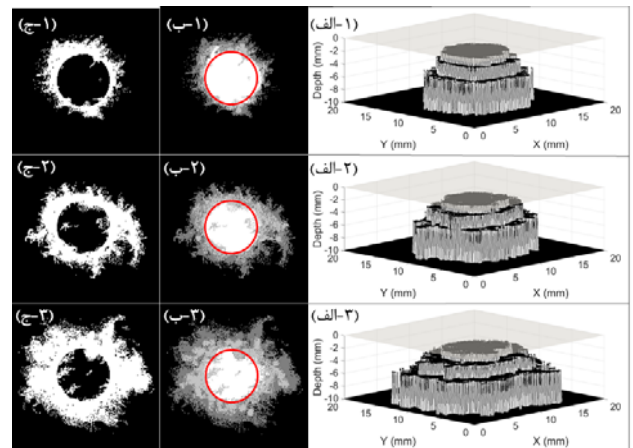
شکل ۱۸: ماتریس درهم‌ریختگی که عملکرد شبکه در تشخیص کلاس مسئله مورد نظر را نشان می‌دهد

نسبت به سطح قطعه، بدون تاثیرپذیری از زاویه‌ی قرارگیری آنها نسبت به مسیر اسکن تعیین می‌شوند.  
در نهایت، نتایج به‌دست آمده نشان می‌دهند که روش یادگیری عمیق می‌تواند عملکرد بهتری در تعیین مشخصات خرابی نظیر شکل و عمق آن در مقایسه با شبکه‌های عصبی متداول داشته‌باشد. این نتیجه به‌دلیل توانایی DCNN در استخراج خودکار ویژگی‌های یادگیری مناسب از داده‌های اعمال شده منجر می‌شود.  
سعی در حصول افزایش دقت روش یادگیری عمیق و نیز عمومیت بیشتر آن برای انواع خرابی‌های دلخواه با عمق متغییر از طریق تصاویر C-scan اخذ شده بوسیله حسگر AMR به‌عنوان گام بعدی در تحقیقات آتی مولفین مدنظر است.



شکل ۱۴: خروجی شبکه‌های یادگیری عمیق (۱: DCNN- $61 \times 61 \times 3$ ،

DCNN- $51 \times 51 \times 3$  (۲، DCNN- $41 \times 41 \times 3$  (۳، برای خرابی پنج ضلعی در عمق ۳ میلی‌متر، سطرها: الف- پروفایل عمق، ب- نمای سطح مقطع و شکل واقعی خرابی (به رنگ قرمز)، ج- اختلاف نواحی تخمینی و واقعی.



شکل ۱۵: خروجی شبکه‌های عصبی MLP (۱:  $7 \times 7$  -

MLP- $61 \times 61 \times 3$  (۲، MLP- $9 \times 9$  (۳، MLP- $15 \times 15$  (۳، برای خرابی استوانه‌ای در عمق ۱٫۸ میلی‌متر، سطرها: الف- پروفایل عمق، ب- نمای سطح مقطع و شکل واقعی خرابی (به رنگ قرمز)، ج- اختلاف نواحی تخمینی و واقعی.

## مراجع

- [14] H. G. Ramos and A. L. Ribeiro, "Present and Future Impact of Magnetic Sensors in NDE," *Procedia Engineering*, vol. 86, pp. 406–419, December 2014.
- [15] A. Jander, C. Smith and R. Schneider, "Magneto resistive sensors for nondestructive evaluation," *In Advanced Sensor Technologies for Nondestructive Evaluation and Structural Health Monitoring*, vol. 5770, pp. 1–14, May, 2005.
- [16] F. Franco, F. A. Cardoso, L. S. Rosado, R. Ferreira, S. Cardoso, M. Piedade and P. P. Freitas, "Advanced NDT inspection tools for titanium surfaces based on high-performance magneto resistive sensors," *IEEE Transactions on Magnetics*, vol. 53, no. 4, pp. 1–5, 2016.
- [17] L. Udpa, and S. Udpa, "Optimization and Validation of Rotating Current Excitation with GMR Array Sensors for Riveted Structures Inspection," *Sensors*, vol. 16, no. 9, 2016.
- [18] M. Ravan, S. H. H. Sadeghi and R. Moini, "Field Distributions Around Arbitrary Shape Surface Cracks in Metals, Induced by High-Frequency Alternating-Current-Carrying Wires of Arbitrary Shape," *IEEE Transactions on magnetics*, vol. 42, no. 9, pp. 2208–2214, Sep 2006.
- [19] H. Dongfeng, "Eddy-current NDE Using an AMR Magnetometer," *Progress in Electro magnetics Research Symposium Proceedings*, Moscow, Russia, August 2009.
- [20] D. F. He, M. Shiwa, J. P. Jia, J. Takatsubo and S. Moriya, "Multi-frequency ECT with AMR sensor," *NDT & E International*, vol. 44, no. 5, pp. 438–441, 2011.
- [21] D. J. Mapps, "Magneto resistive sensors," *Sensors and Actuators A: Physical*, vol. 59, no. 1–3, pp. 9–19, April 1997.
- [22] P. Ripka and M. Janosek, "Advances in magnetic field sensors," *IEEE Sensors Journal*, vol. 10, no. 6, pp. 1108–1116, 2010.
- [23] M. Li and D. A. Lowther, "The application of topological gradients to defect identification in magnetic flux leakage-type," *IEEE Transactions on magnetics*, vol. 46, no. 8, pp. 3221–3224, 2010.
- [24] A. Noroozi, R. Hasanzadeh and M. Ravan, "A Fuzzy Learning Approach for Identification of Arbitrary Crack Profiles Using ACFM Technique," *IEEE Transactions on Magnetics*, vol. 49, no. 9, pp. 5016–5027, 2013.
- [25] M. Wrzuszczak and J. Wrzuszczak, "Eddy current flaw detection with neural network applications," *Measurement*, vol. 38, no. 2, pp. 132–136, 2005.
- [26] J. Schmidhuber, "Deep learning in neural networks: An overview," *Neural networks*, vol. 61, pp. 85–117, 2015.
- [27] K. Virupakshappa and E. Oruklu, "Performance analysis of deep learning architectures for ultrasonic NDE applications," *IEEE International Ultrasonic Symposium (IUS)*, Washington, DC, pp. 1–1, November 2017.
- [1] R. I. Stephens, "Metal fatigue in engineering," *New York: Wiley*, 2001.
- [2] H. A. Richard and M. Sander, "Fatigue Crack Growth," *Springer*, Berlin, pp. 27–30, 2016.
- [3] J. García-Martín, J. Gómez-Gil and E. Vázquez-Sánchez, "Non destructive techniques based on eddy current testing," *Sensors*, vol. 11, no. 3, pp. 2525–2565, 2011.
- [4] J. Blitz, "Electrical and magnetic methods of non-destructive testing," *Springer Science & Business Media*, vol. 3, 2012.
- [5] B. Guo, Z. Zhang and R. Li, "Ultrasonic and eddy current non-destructive evaluation for property assessment of 6063 aluminum alloy," *NDT & E International*, vol. 93, pp. 34–39, 2018.
- [6] L. Janousek, A. Stubendekova and M. Smetana, "Novel insight into swept frequency eddy-current non-destructive evaluation of material defects," *Measurement*, vol. 116, pp. 246–250, 2018.
- [7] R. James, M. Faisal Haider, V. Giurgiutiu, and D. Lilienthal, "A Simulative and Experimental Approach toward Eddy Current Nondestructive Evaluation of Manufacturing Flaws and Operational Damage in CFRP Composites," *ASME. ASME J Nondestructive Evaluation*, vol. 3, no. 1, 2020.
- [8] S. Nagata and M. Numachi, "Eddy Current Non-Destructive Evaluation for Healthiness of Radiator Structure," *IEEE Transactions on Magnetics*, vol. 53, no. 11, pp. 1–4, 2017.
- [9] M. Kermadi, S. Moussaoui, A. Taieb Brahimi and M. Feliachi, "Defect localization and characterization in eddy current nondestructive testing by change detection and global optimization," *COMPEL - The international journal for computation and mathematics in electrical and electronic engineering*, vol. 37, no. 2, pp. 948–970, 2018.
- [10] S. H. H. Sadeghi and D. Mirshekar-Syahkal, "A new technique for sizing cracks in metals, utilizing an induced surface magnetic field," *Review of Progress in Quantitative Nondestructive Evaluation*, pp. 593–600, 1990.
- [11] G. S. Park and E. S. Park, "Improvement of the sensor system in magnetic flux leakage-type nondestructive testing (NDT)," *IEEE Transactions on magnetics*, vol. 38, no. 2, pp. 1277–1280, 2002.
- [12] W. Dehui, S. Lingxin, W. Xiaohong, "A Novel Non-destructive testing Method by Measuring the Change Rate of Magnetic Flux Leakage," *J Non destruct Eval*, vol. 4, 2017.
- [13] Y. Ege, M. Coramik, "A new measurement system using magnetic flux leakage method in pipeline inspection," *Measurement*, vol. 123, pp. 163–174, 2018.



**سعید رمضانی** مدرک کارشناسی خود را در رشته مهندسی برق گرایش الکترونیک در سال ۱۳۹۴ و مدرک کارشناسی ارشد خود را در رشته مهندسی برق گرایش سیستم‌های الکترونیک دیجیتال در سال ۱۳۹۸ از دانشگاه گیلان کسب نمود. علاقه‌مندی‌های علمی ایشان شامل پردازش سیگنال، پردازش تصویر، یادگیری ماشین، یادگیری عمیق و هوش مصنوعی است.



**رضا حسن‌زاده پاک‌رضائی** مدرک کارشناسی را در رشته مهندسی برق گرایش الکترونیک در سال ۱۳۷۹ از دانشگاه گیلان و مدارک کارشناسی ارشد و دکتری خود را در رشته مهندسی برق گرایش الکترونیک دیجیتال به ترتیب در سال‌های ۱۳۸۱ و ۱۳۸۶ از صنعتی امیرکبیر (پلی تکنیک تهران) کسب نمود. ایشان هم‌اکنون دانشیار گروه مهندسی برق دانشگاه گیلان و

زمینه‌های پژوهشی مورد علاقه ایشان شامل پردازش سیگنال، تصویر، یادگیری ماشین و منطق فازی در کاربردهای ارزیابی غیرمخرب صنعتی و پزشکی می‌باشد.

- [28] G. Psuj, "Multi-Sensor Data Integration Using Deep Learning for Characterization of Defects in Steel Elements," *Sensors*, vol. 18, no. 2, pp. 292, January 2018.
- [29] D. f. He and M. Shiwa, "Deep Defect Detection Using Eddy Current Testing with AMR Sensor," *PIERS Proceedings*, pp. 12–15, 2013.
- [30] S. Zhou, Y. Chen, D. Zhang, J. Xie and Y. Zhou, "Classification of surface defects on steel sheet using convolutional neural networks," *Mater, Techno*, vol. 51, pp. 123–131, 2017.
- [31] S. Faghieh-Roohi, S. Hajizadeh, A. Núñez, R. Babuska and B. D. Schutter, "Deep convolutional neural networks for detection of rail surface defects," *In IJCNN*, pp. 2584–2589, July, 2016.
- [32] B.P.C Rao, B. Raj, T. Jayakumar and P. Kalyanasundaram, "An artificial neural network for eddy current testing of austenitic stainless steel welds," *NDT & E International*, Vol. 35, no. 6, pp. 393–398, 2002.
- [33] J. A. Buck, P. R. Underhill, J. E. Morelli and T. W. Krause, "Simultaneous multi parameter measurement in pulsed eddy current steam generator data using artificial neural networks." *IEEE Transactions on Instrumentation and Measurement*, Vol. 65, no. 3, pp. 672–679, 2016.