

Design of a Hybrid Data-Driven Classification Model for Optimal Selection of Non-Destructive Testing Methods in Weld Inspection

Amirmahdi Nazari Gharibdoosti^{1✉}  | Mahdi Sarai Tabrizi 

1. Department of Engineering, Islamic Azad University, Science and Research Branch, Tehran, Iran. E-mail: am.nazarigharibdoosti@iau.ir
2. Department of Water Engineering and Sciences, Islamic Azad University, Science and Research Branch, Tehran, Iran.

Article Information:

Research Article

Received 26 December 2024

Revised 12 May 2025

Accepted 30 May 2025

Keywords:

Non-Destructive Inspection,
Weld Inspection,
Machine Learning,
XGBoost,
Data-Driven Modeling.

ABSTRACT

Selecting the most appropriate Non-Destructive Testing (NDT) method for industries such as energy, transportation, automotive, aviation, and oil and gas plays a critical role in enhancing inspection quality, minimizing human errors, and reducing operational costs. In this study, a hybrid data-driven and classification model based on Machine Learning (ML) techniques is developed to recommend the optimal NDT method for weld inspection, considering input features such as material, structure, weld type, thickness, and accessibility. A dataset consisting of 500 records of NDT inspections—including Ultrasonic Testing (UT), Eddy Current Testing (ET), Magnetic Particle Testing (MT), Radiographic Testing (RT), and Liquid Penetrant Testing (PT) were collected and preprocessed. Machine Learning algorithms including Random Forest (RF), Support Vector Machine (SVM), K-Nearest Neighbors (KNN), and Extreme Gradient Boosting (XGBoost) were implemented using Python. The model development process employed 10-fold cross-validation for evaluation and grid search for hyperparameter optimization. Among the models, XGBoost achieved the best performance, reaching 90% accuracy as evaluated by precision, recall, and F1-score metrics. It also outperformed human experts by achieving an average of six percent higher accuracy in predicting the appropriate NDT method. Furthermore, the model's predictions aligned with international standards such as ASME Section V (2023) and ASTM E-Series, confirming its technical validity. The findings demonstrate that the proposed hybrid model effectively supports industrial decision-making frameworks, enhances the consistency of inspection processes, and reduces the likelihood of human errors.

Cite this article: Nazari Gharibdoosti, A.M. and Sarai Tabrizi, M. (2024). Design of a Hybrid Data-Driven Classification Model for Optimal Selection of Non-Destructive Testing Methods in Weld Inspection. *Journal of Nondestructive Testing Technology*, 4 (1), 57-71.



© The Author(s).

DOI: <http://doi.org/10.30494/jndt.2025.493111.1157>

Publisher: Iranian Society for Nondestructive Testing

طراحی مدل ترکیبی داده‌محور و طبقه‌بندی جهت انتخاب روش بهینه آزمون‌های غیرمخرب در بازرسی جوش

امیرمهدی نظری غریبدوستی^۱ | مهدی سرائی تبریزی^۲

۱. گروه مهندسی صنایع، دانشکده فنی و مهندسی، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران، رایانامه: am.nazarigharibdoosti@iau.ir
۲. گروه علوم و مهندسی آب، دانشکده موضوعی کشاورزی، آب، غذا و فراسودمندها، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران.

چکیده:

انتخاب روش مناسب آزمون غیرمخرب (NDT) برای بازرسی جوش، نقش مهمی در ارتقاء کیفیت بازرسی، کاهش خطاهای انسانی و بهینه‌سازی هزینه‌های عملیاتی در صنایع مختلف از جمله انرژی، حمل‌ونقل، خودروسازی و هوافضا دارد. در این پژوهش، یک مدل ترکیبی داده‌محور و طبقه‌بندی با استفاده از تکنیک‌های یادگیری ماشین طراحی شد تا بر اساس ویژگی‌هایی نظیر نوع جوش، ضخامت، جنس قطعه، ساختار و میزان دسترس، روش بهینه آزمون غیرمخرب (NDT) جهت بازرسی جوش را پیشنهاد دهد. برای طراحی مدل، ۵۰۰ داده شامل آزمون‌های UT، MT، RT، PT و ET جمع‌آوری و پس از پیش‌پردازش داده‌ها، از الگوریتم‌های جنگل تصادفی (RF)، ماشین بردار پشتیبان (SVM)، K-نزدیک‌ترین هم‌سایه (KNN) و XGBoost جهت مدل‌سازی با زبان برنامه‌نویسی Python استفاده شد. فرآیند ارزیابی مدل با بهره‌گیری از تکنیک اعتبارسنجی متقابل ۱۰ لایه‌ای و بهینه‌سازی هایپرپارامترها از طریق جستجوی شبکه‌ای انجام شد. نتایج نشان داد مدل XGBoost با دقت ۹۰ درصد و میانگین شاخص‌های صحت، پوشش و امتیاز F1 بیش‌تر از سایر مدل‌ها، بهترین عملکرد را برای این مسئله و داده‌های موجود در آن داشته است. همچنین، خروجی مدل با استانداردهایی نظیر ASME 2023 Section V و ASTM E-Series ویژه جوشکاری صنعتی هم‌راستا بوده و از اعتبار و کاربردپذیری عملی برخوردار است.

اطلاعات مقاله:

مقاله پژوهشی

تاریخ دریافت:

۱۴۰۳/۱۰/۰۶

تاریخ بازنگری:

۱۴۰۴/۰۲/۲۲

تاریخ پذیرش:

۱۴۰۴/۰۳/۰۹

کلیدواژگان:

بازرسی غیرمخرب،
بازرسی جوش،
یادگیری ماشین،
XGBoost،
مدل‌سازی داده‌محور.

استناد: نظری غریبدوستی، امیرمهدی و سرائی تبریزی، مهدی. (۱۴۰۳). طراحی مدل ترکیبی داده‌محور و طبقه‌بندی جهت انتخاب روش بهینه آزمون‌های غیرمخرب در بازرسی جوش. *مجله فناوری آزمون‌های غیرمخرب*، ۴ (۱)، ۷۱-۵۷.

© نویسندگان

ناشر: انجمن آزمون‌های غیرمخرب ایران

DOI: <http://doi.org/10.30494/jndt.2025.493111.1157>



۱- مقدمه

روش‌های آزمون یا بازرسی قطعات یا جوش به دو دسته آزمون‌های مخرب^۱ (DT) و آزمون‌های غیرمخرب^۲ (NDT) تقسیم می‌شوند [۱]. آزمون‌های مخرب (DT) در مهندسی مواد و متالورژی جلوه بیش‌تری داشته و برای سنجیدن مقاومت مکانیکی مواد مانند فشار، کشش، خمش و ضربه استفاده می‌شوند [۲]. پس از انجام آزمون‌های مخرب (DT)، قطعات حالت و خاصیت اولیه خود را از دست می‌دهند و در نتیجه انجام این آزمون‌ها زمانی منطقی است که قطعه مورد نظر، هزینه تولید (ارزش) زیادی نداشته و یا به‌صورت انبوه تولید شود [۱]. آزمون‌های غیرمخرب (NDT) به روش‌هایی از بازرسی گفته می‌شود که در آن کارآیی قطعه پس از انجام آزمایش تغییری نمی‌کند؛ به عبارت دیگر آسیبی به قطعه وارد نمی‌شود. آزمون‌های غیرمخرب (NDT) در بازرسی جوش، برای ارزیابی کیفیت اتصال جوش، تشخیص ناپیوستگی‌ها و افزایش قابلیت اطمینان سازه‌های جوشکاری‌شده، مورد استفاده قرار می‌گیرند [۳ و ۴]. یادگیری ماشین^۳ (ML)، یکی از اجزای مهم هوش مصنوعی^۴ (AI) محسوب می‌شود [۵] و هدف آن، ایجاد مدل‌هایی است که بتوانند همانند انسان تفکر کنند و توانایی تقلید از رفتار انسان را داشته باشند [۶]. در دهه گذشته استفاده از رویکردهای یادگیری ماشین و تکنیک‌های مرتبط با آن، در زمینه آزمون‌های غیرمخرب (NDT) به‌طور قابل‌توجهی افزایش یافته است.

در صنایع مختلف انتخاب نامناسب آزمون‌های غیرمخرب (NDT) می‌تواند به خرابی‌های ناگهانی و خطرناک منجر شود [۲ و ۳]. بر اساس پژوهشی انجام شده، انتخاب صحیح آزمون‌های غیرمخرب می‌تواند خطرات ناشی از نقص‌های پنهان را کاهش دهد و به بهبود قابلیت اطمینان در سازه‌ها کمک کند [۷]. همچنین عدم استفاده از آزمون‌های غیرمخرب مناسب، می‌تواند باعث افزایش زمان توقف تجهیزات شود و در نتیجه، هزینه‌های عملیاتی را افزایش

دهد [۸]. انتخاب صحیح این آزمون‌ها با استفاده از یادگیری ماشین (ML) نه تنها سرعت و دقت بازرسی‌ها را افزایش می‌دهد، بلکه موجب کاهش خطاهای انسانی می‌شود [۲]. آزمون‌های غیرمخرب (NDT) در ایران نیز به‌طور پیوسته از جنبه‌های گوناگون مورد مطالعه و بهبود قرار گرفته‌اند. این پیشرفت‌ها شامل توسعه مداوم در زمینه سخت‌افزار و نرم‌افزارهای مرتبط است که به ارتقای کارایی و دقت این روش‌ها کمک کرده‌اند [۹].

طییبی و همکاران در پژوهشی با استفاده از شبکه‌های عصبی مصنوعی^۵ (ANNS)، روشی برای تشخیص موقعیت و راستای ترک در لوله‌ها ارائه کرده‌اند. نتایج آن‌ها نشان داد که این روش با خطایی کمتر از ۷ درصد، دقت بالایی در پیش‌بینی موقعیت و راستای ترک دارد [۱۰]. همچنین بیگزاده و بدیعی با استفاده از مدل‌سازی مونت کارلو^۶ (MCNPX) و داده‌های حاصل از شبیه‌سازی پرتوهای گاما، مجموعه داده‌ای از ضخامت‌های مختلف برای آموزش شبکه‌های عصبی RBF و MLP ایجاد کرده‌اند. نتایج آن‌ها نشان داد که شبکه MLP در مقایسه با RBF عملکرد بهتری در پیش‌بینی ضخامت فلزات پرکاربرد نظیر آلومینیوم، آهن و مس داشته است [۱۱]. نوری‌هوشیار و همکاران با استفاده از مدل‌های پردازش تصویر در یادگیری ماشین، به شناسایی عیوب در سازه‌های بتنی و فلزی پرداخته‌اند و توانسته‌اند دقت تشخیص عیوب را به‌طور قابل‌توجهی افزایش دهند [۱۲]. همچنین نیکولای و همکاران به بررسی کاربرد ANNS در تشخیص خودکار عیوب پرداخته و نشان داده‌اند که تحلیل تصاویر از زوایای مختلف می‌تواند دقت تشخیص عیوب را در آزمون مایعات نافذ^۷ (PT) بهبود بخشد [۱۳]. نادرپور و همکاران با ارائه مدل ترکیبی از دو مدل ماشین بردار پشتیبان^۸ (SVM) و کی-نزدیک‌ترین همسایه^۹ (KNN) به دقت بالاتری در شبیه‌سازی و پیش‌بینی عیوب در سازه‌های بتنی دست یافته‌اند [۱۴]. حسین در پژوهشی به بررسی نقش یادگیری ماشین در بهبود پایش سلامت پل‌ها و مدل‌های نظارتی و غیرنظارتی در زمینه آزمون‌های

⁶ Mont Carlo N-Particle Transport Code (MCNPX)

⁷ Liquid Penetrant Testing (PT)

⁸ Support Vector Machine (SVM)

⁹ K-Nearest Neighbors (KNN)

¹ Destructive Testing (DT)

² Non-Destructive Testing (NDT)

³ Machine Learning (ML)

⁴ Artificial Intelligence (AI)

⁵ Artificial Neural Networks (ANNS)

هریک از آن‌ها در پیش‌بینی انتخاب بهینه‌ترین آزمون غیرمخرب (NDT) مشخص شود. در نهایت ترتیب اهمیت شاخص‌ها در پیش‌بینی هر مدل مشخص شده و نتایج حاصل، با استانداردها و پژوهش‌های گذشته مقایسه خواهد شد.

۲- مواد و روش‌ها

در این پژوهش، تمامی مراحل یادگیری ماشین مطابق شکل ۱ به صورت گام‌به‌گام اجرا شده تا مدل نهایی به دست آید. در یادگیری ماشین، فارغ از آنکه از چه نوعی باشد باید مراحل شکل ۱ را برای مدل‌سازی آن طی کرد. به عبارت دیگر این فرآیند برای هر نوعی از یادگیری ماشین صدق می‌کند [۱۶].



شکل ۱) فرآیند یادگیری ماشین [۵، ۶ و ۱۷]

۲-۱ فهم مسئله

با توجه به شکل ۱، اولین مرحله در فرآیند یادگیری ماشین، شناخت و فهم مسئله است. بر اساس استاندارد ISO 6520، جوشی که دارای ترک خوردگی، تخلخل، انباشتگی در کنارها، ذوب یا نفوذ ناقص، سوختگی یا بریدگی کناره جوش باشد، به‌عنوان جوش معیوب شناخته می‌شود. حدود پذیرش این عیوب در استانداردهای صنعتی مشخص شده است. به‌عنوان مثال، در استاندارد AWS D1.1، میزان مجاز

غیرمخرب پرداخته و نتایج پژوهش وی نشان داد که استفاده از این روش‌ها برای پایش سازه‌های پل‌ها، امری ضروری است [۱۵]. همچنین وانگ و همکاران به مزایای استفاده از روش‌های یادگیری عمیق^۱ (DL) در شناسایی دقیق‌تر عیوب و بهبود عملکرد بازرسی‌های غیرمخرب اشاره کرده‌اند [۴].

با وجود پژوهش‌های انجام‌شده در زمینه آزمون‌های غیرمخرب (NDT)، بسیاری از مطالعات تنها بر ارزیابی و تشخیص عیوب متمرکز بوده‌اند. پژوهش حاضر در راستای تکمیل تحقیقات گذشته، در پی توسعه مدل پیش‌بینی است که بتواند در شرایط مختلف، مناسب‌ترین آزمون غیرمخرب را از نظر امکان‌پذیری و افزایش دقت بازرسی برای هر قطعه جوش پیشنهاد دهد. برای این منظور، چهار مدل مبتنی بر مدل‌های یادگیری ماشین شامل جنگل تصادفی^۲ (RF)، ماشین بردار پشتیبان^۳ (SVM)، کی-نزدیک‌ترین همسایه (KNN) و افزایش گرادین شدید^۴ (XGBoost) با استفاده از زبان برنامه‌نویسی پایتون مدل‌سازی و طراحی می‌شود. در این پژوهش از رویکرد داده‌محور^۵ برای طراحی مدل استفاده شده است؛ به این معنا که به جای تکیه بر قواعد صریح یا دانش‌محور، ساختار مدل و پیشنهاد روش مناسب آزمون بر اساس داده‌های واقعی و تحلیل آماری آن‌ها شکل گرفته است. این رویکرد امکان استخراج الگوهای پنهان و تصمیم‌گیری بهینه بر مبنای داده‌های تجربی را فراهم کرده و دقت و اعتبار پیش‌بینی‌ها را افزایش می‌دهد.

سپس شاخص‌های نوع و ضخامت جوش، جنس و ساختار قطعه و میزان دسترسی به ناحیه سطح جوش به‌عنوان متغیرهای ورودی و آزمون‌های رادیوگرافی^۶ (RT)، التراسونیک^۷ (UT)، ذرات مغناطیسی^۸ (MT)، جریانی گردابی^۹ (ET) و مایعات نافذ (PT) به‌عنوان متغیر خروجی مدل در نظر گرفته می‌شود. علاوه بر مقایسه عملکرد مدل‌های یادگیری ماشین با یکدیگر، عملکرد سه بازرسی^{۱۰} (خبره^{۱۱}) در حوزه آزمون‌های غیرمخرب (NDT) جمع‌آوری شده و با مدل‌های یادگیری ماشین مقایسه می‌شود تا دقت عملکرد

⁷ Ultrasonic Testing (UT)

⁸ Magnetic-Particle Testing (MT)

⁹ Eddy Current Testing (ET)

¹⁰ Inspector

¹¹ Expert

¹ Deep Learning (DL)

² Random Forest (RF)

³ Support Vector Machine (SVM)

⁴ Extreme Gradient Boosting (XGBoost)

⁵ Data-Driven

⁶ Radiography Testing (RT)

مورد نظر است تا دقت انتخاب روش بازرسی افزایش و احتمال خطای انتخاب روش نامناسب، کاهش پیدا کند.

۲-۲ شناخت داده‌ها و مرز مدل

دومین مرحله در فرآیند یادگیری ماشین، شناخت و فهم داده است. در فرآیند مدل سازی، تعیین متغیرهای تأثیرگذار بر مدل از اهمیت بالایی برخوردار است. با توجه به محدودیت‌های مسئله، برخی از این متغیرها ممکن است در مدل سازی لحاظ نشوند [۱۷]. بنابراین، ضروری است که ویژگی متغیرها، قطبیت آن‌ها، بازه‌های تعریف شده و ماهیت کمی یا کیفی آن‌ها مشخص گردد [۱۸].

ترک، تخلخل و سایر ناپیوستگی‌های جوش بر اساس نوع کاربرد سازه تعیین شده است. برای سازه‌های حساس مانند مخازن تحت فشار، الزامات سخت‌گیرانه‌تری اعمال می‌شود، در حالی که برای سازه‌های کم‌اهمیت‌تر، برخی ناپیوستگی‌ها قابل پذیرش هستند. همچنین، استاندارد ISO 5817، جوش‌ها را بر اساس میزان مجاز ناپیوستگی‌ها به سه سطح کیفی B (کیفیت بالا)، C (کیفیت متوسط) و D (کیفیت پایین) دسته‌بندی می‌کند. برای شناسایی و ارزیابی این عیوب، می‌توان از آزمون‌های غیرمخرب (NDT) استفاده کرد. هدف از مدل سازی در این پژوهش، پیش‌بینی مناسب‌ترین آزمون غیرمخرب (NDT) بر اساس ویژگی‌های قطعه و جوش

جدول ۱) ویژگی‌های ورودی مدل همراه با نوع داده و مقیاس اندازه‌گیری آن‌ها

نام ویژگی	نوع داده	نوع مقیاس	تعداد سطوح ^۱ یا بازه تعریف
نوع جوش	کیفی	طبقه‌ای (اسمی)	۵ سطح
ضخامت جوش	کمی	پیوسته	۲ تا ۵۰ میلی‌متر
جنس قطعه	کیفی	طبقه‌ای (اسمی)	۵ سطح
ساختار قطعه	کیفی	طبقه‌ای (اسمی)	۳ سطح
میزان دسترسی به سطح قطعه	کیفی	ترتیبی	۳ سطح

محتمل به‌عنوان پارامترهای مؤثر، به دلیل محدودیت در دسترسی به داده‌های کامل و قابل تحلیل در خصوص این متغیرها، امکان لحاظ کردن آن‌ها در مدل فراهم نبوده است. این مسئله به‌عنوان یکی از محدودیت‌های پژوهش در نظر گرفته می‌شود. یکی دیگر از محدودیت‌های این مدل، نحوه اجرای آزمون رادیوگرافی (RT) است. در این پژوهش، رادیوگرافی صرفاً بر اساس استفاده از منبع گاما^۴ در نظر گرفته شده و سایر روش‌های رادیوگرافی، از جمله رادیوگرافی با اشعه ایکس^۵ بررسی نشده‌اند. همچنین مقادیر قابل قبول برای متغیرهای ورودی به شرح زیر می‌باشد:

۱. متغیر نوع جوش، شامل جوش لب به لب^۶، لبه‌ای^۷، تی‌شکل^۸، همپوشانی^۹ یا زاویه‌ای^{۱۰} می‌باشد.
۲. متغیر ضخامت جوش، بازه‌ای بین ۲ تا ۵۰ میلی‌متر است.

۱-۲-۲ تعیین مرز مدل

مطابق جدول ۱ در این پژوهش، با توجه به هدف مدل سازی انتخاب روش بهینه آزمون غیرمخرب (NDT) جهت بازرسی جوش، مجموعه‌ای از متغیرهای فنی شامل نوع جوش، ضخامت جوش، جنس فلز پایه، ساختار قطعه و میزان دسترسی به ناحیه جوش به‌عنوان متغیرهای ورودی مدل (ویژگی‌ها^۲) و آزمون غیرمخرب به‌عنوان متغیر خروجی (پاسخ^۳) در نظر گرفته شده‌اند. انتخاب این متغیرها بر اساس معیارهای اجرایی و تجربی بازرسی صورت گرفته و هر یک به نحوی بر قابلیت اجرای روش‌های مختلف آزمون و دقت آن‌ها تأثیرگذار هستند. با این حال، با وجود شناسایی برخی عوامل دیگر مانند نوع فرآیند جوشکاری، نوع عیب محتمل و جهت‌گیری آن، شرایط سطحی یا نوع ناپیوستگی‌های

⁶ Butt Weld

⁷ Edge Joint Weld

⁸ Tee Joint Weld

⁹ Lap Weld

¹⁰ Corner Weld

¹ Levels

² Features

³ Response

⁴ Gamma-ray Source

⁵ X-ray Source

غیرمؤثر بر عملکرد مدل از دیتاست حذف شده و همچنین داده‌های دارای آلودگی، اصلاح می‌شوند [۲۰]. برای پیش‌پردازش و مدیریت داده‌ها، از کتابخانه‌های Pandas و NumPy استفاده شد. داده‌ها ابتدا از فایل CSV بارگذاری شده و در ادامه، مراحل بررسی اولیه شامل کنترل مقادیر مفقود، یکنواختی نوع داده‌ها و شمارش کلاس‌ها انجام شد تا از صحت و سازگاری داده‌ها پیش از پیش‌پردازش اطمینان حاصل گردد. در گام اول، تمامی ویژگی‌های متنی شامل نوع جوش، جنس و ساختار قطعه و میزان دسترسی با استفاده از Label Encoding به مقادیر عددی تبدیل شده تا امکان استفاده در مدل‌های عددی فراهم شود. بررسی مقادیر گمشده در داده‌ها با استفاده از توابع isnull و info در کتابخانه Pandas انجام شد. در بررسی مجموعه داده‌ها، هیچ‌گونه مقدار گمشده^۵ مشاهده نشد و نیازی به پاک‌سازی یا جایگزینی داده نبود. در صورت وجود، روش‌هایی مانند میانگین‌گیری، تصمیم‌هوشمندانه یا حذف رکورد ناقص می‌توانست مورد استفاده قرار گیرد. همچنین برای شناسایی داده‌های پرت در ویژگی‌های عددی مانند ضخامت جوش، از روش IQR^۷ استفاده شد. بررسی‌های انجام‌شده نشان داد که پراکندگی داده‌ها در حد قابل قبول بوده و نیاز به حذف یا اصلاح داده پرت احساس نشد.

۳. جنس قطعه محدود به فولاد پُرکربن^۱، ضدزنگ^۲، آلومینیوم، مس یا کامپوزیت می‌باشد.
۴. ساختار قطعه نیز به سه دسته تخت، ساده یا پیچیده دسته‌بندی شده است.
۵. میزان دسترسی به سطح جوش دارای مقادیر زیاد، متوسط یا کم می‌باشد.

۲-۲-۲ تهیه مجموعه داده

مجموعه داده^۳ یا دیتاست، مجموعه‌ای از داده‌های سازمان‌دهی شده است و برای تحلیل‌ها، مدل‌سازی‌های آماری و یادگیری ماشین به کار می‌رود. این داده‌ها می‌توانند شامل اطلاعات متنی، عددی و یا تصویری باشند. در هر دیتاست معمولاً داده‌ها به صورت جدول‌هایی سازمان‌دهی شده‌اند که سطرهای آن، نشان‌دهنده رکوردها^۴ و ستون‌ها، نشان‌دهنده ویژگی‌ها (شاخص‌ها) می‌باشند. [۱۹]. دیتاست این پژوهش، شامل ۵۰۰ نمونه (رکورد) و شش ویژگی (پنج شاخص و یک کلاس) می‌باشد. این داده‌ها توسط یک شرکت بازرسی فنی و مهندسی فعال در حوزه خدمات بازرسی غیرمخرب جمع‌آوری شده است. جدول ۲ نمونه‌ای از داده‌های مورد استفاده در این پژوهش را نمایش می‌دهد.

۲-۳ پیش‌پردازش داده‌ها

پیش‌پردازش و آماده‌سازی داده‌ها^۵ یکی از مهم‌ترین مراحل فرآیند یادگیری ماشین است که در آن داده‌های

جدول ۲) پنج نمونه (رکورد) از دیتاست تهیه شده برای مدل‌سازی از پایگاه داده شرکت آزمون گستر آسیا

جنس قطعه	ساختار قطعه	نوع جوش	ضخامت جوش (میلی‌متر)	میزان دسترسی به سطح جوش	آزمون انجام شده
فولاد پُرکربن	ساده	لب به لب	۲۴	متوسط	RT
فولاد پُرکربن	تخت	لب به لب	۳۷	زیاد	UT
فولاد ضد زنگ	پیچیده	زاویه‌ای	۱۳	زیاد	PT
فولاد ضد زنگ	تخت	همپوشانی	۹	زیاد	ET
مس	ساده	لب به لب	۱۱	متوسط	MT

⁵ Data Preprocessing

⁶ Missing Value

⁷ Interquartile Range (IQR)


¹ Carbon Steel (C.S)

² Stainless Steel (S.S)

³ Dataset

⁴ Records

مدل	کتابخانه تخصصی	نیازمند نرمال‌سازی داده‌ها	منبع
RF	Scikit-learn	خیر	[۲۱]
SVM	Scikit-learn	بله	[۲۲]
KNN	Scikit-learn	بله	[۲۳]
XGBoost	XGBoost	خیر	[۲۴]



شکل ۲) انجام آزمون PT توربین ژنراتور (سمت راست) و انجام آزمون RT بر روی لوله ۴۸ اینچ انتقال گاز شهری (سمت چپ)

در ادامه، جهت نرمال‌سازی داده‌ها در مدل‌هایی مانند SVM و KNN که به مقیاس داده‌ها حساس هستند، از تکنیک MinMaxScaler استفاده شد. این روش، داده‌ها را به بازه [۰،۱] نگاشت کرده و ویژگی‌های مقیاسی را به شکل یکنواخت و قابل مقایسه تبدیل می‌کند. لازم به ذکر است که برای مدل‌هایی مانند RF و XGBoost به دلیل ماهیت درختی و غیرخطی، نیازی به نرمال‌سازی داده‌ها وجود ندارد.

همچنین شکل ۲ تصاویر مربوط به نمونه‌هایی از داده‌های دیتاست مدل‌سازی جدول ۲ را نشان می‌دهد.

۲-۴ آموزش مدل

در این پژوهش، از چهار مدل یادگیری ماشین برای پیش‌بینی بهینه آزمون‌های غیرمخرب (NDT) در محیط برنامه‌نویسی Jupyter و زبان برنامه‌نویسی پایتون استفاده می‌شود که عبارت‌اند از: جنگل تصادفی (RF)، ماشین بردار پشتیبان (SVM)، کی-نزدیک‌ترین همسایه و افزایش گرادیان شدید (XGBoost).

۲-۴-۱ کتابخانه‌های مورد نیاز

برای پردازش داده‌ها و مدیریت متغیرها، از دو کتابخانه NumPy و Pandas استفاده می‌شود. کتابخانه Pandas به‌عنوان ابزاری برای بارگذاری، پیش‌پردازش و مدیریت داده‌ها مورد استفاده قرار می‌گیرد. همچنین کتابخانه NumPy برای انجام محاسبات عددی، کار با آرایه‌ها و ماتریس‌های چندبعدی استفاده می‌شود. جدول ۳ کتابخانه‌های تخصصی مورد نیاز هر مدل را نشان می‌دهد.

۲-۴-۲ تنظیم هایپرپارامترها
فراپارامترها یا هایپرپارامترها^۱ مقادیری هستند که پیش از شروع فرآیند آموزش مدل در یادگیری ماشین تعیین می‌شوند و نقش مهمی در عملکرد نهایی مدل دارند. به‌منظور یافتن بهترین ترکیب این پارامترها برای هر مدل، از تکنیک جستجوی شبکه‌ای^۲ استفاده شده است. این تکنیک با استفاده از اعتبارسنجی متقابل پنج‌گانه^۳، تمامی ترکیب‌های ممکن از هایپرپارامترهای تعریف‌شده را بررسی کرده و پیکربندی بهینه را انتخاب می‌کند. جدول ۴ هایپرپارامترهای کلیدی هر مدل را همراه به مقادیر پیش‌فرض و بهینه آن‌ها برای این مدل‌سازی نشان داده شده است.

مدل	هایپرپارامترها	مقدار پیش‌فرض	مقدار بهینه
RF	Max_depth	None	۱۰
	Min_samples_split	۲	۴
	N_estimators	۱۰۰	۱۵۰
SVM	C	۱	۱۰
	Kernel	rbf	rbf
	Gamma	scale	۰/۱

³ Fold Cross-validation-5

¹ Hyperparameters

² GridSearchCV

مقیاس	مقیاس	Metric	
۵	۵	N_neighbors	KNN
فاصله	همسایگان	Weights	
۰/۳	۰/۳	Learning_rate	
۵	۶	Max_depth	XGBoost
۲۰۰	۱۰۰	N_estimators	

۲-۵ ارزیابی مدل

پس از آموزش مدل‌ها و تنظیم بهینه‌های پارامترها، عملکرد آن‌ها با استفاده از روش اعتبارسنجی متقابل ده‌لایه‌ای^۱ مورد ارزیابی قرار گرفته است. در این روش، مجموعه داده به ۱۰ بخش هم‌اندازه تقسیم می‌شود و در هر تکرار، ۹ بخش برای آموزش مدل و ۱ بخش برای ارزیابی آن در نظر گرفته می‌شود. این فرآیند برای تمامی بخش‌ها تکرار شده و میانگین نتایج به‌عنوان شاخص نهایی عملکرد مدل گزارش می‌گردد. برای سنجش کیفیت مدل‌ها از معیارهای استاندارد ارزیابی شامل دقت^۲، صحت^۳، پوشش^۴ و امتیاز F1 استفاده شده است. اساس محاسبه این معیارها، ماتریس درهم‌ریختگی^۵ می‌باشد که نمای کلی آن در جدول ۵ نمایش داده شده است.

جدول ۵) ماتریس درهم‌ریختگی در یادگیری ماشین

		پیش‌بینی انجام شده توسط مدل	
حالت واقعی	پیش‌بینی	مثبت (بله)	منفی (خیر)
		مثبت (بله)	TP
منفی (خیر)	FP	TN	

با توجه به جدول ۵، روابط زیر استخراج می‌شود:

- به حالتی که پیش‌بینی مدل با مقدار واقعی برابر و مثبت باشد، True Positive (TP) گفته می‌شود.
- به حالتی که پیش‌بینی مدل با مقدار واقعی برابر و منفی باشد، True Negative (TN) گفته می‌شود.
- به حالتی که پیش‌بینی مدل با مقدار واقعی نابرابر و مثبت باشد، False Positive (FP) گفته می‌شود.
- به حالتی که پیش‌بینی مدل با مقدار واقعی نابرابر

و منفی باشد، False Negative (FN) گفته می‌شود.

از این معیارها می‌توان روابط ارزیابی عملکرد مدل را استخراج کرد و میزان کارایی آن را سنجید. معیار دقت یک مدل یادگیری ماشین، از رابطه (۱) محاسبه می‌شود:

$$Accuracy = \frac{1}{n} \sum_{i=1}^n \frac{tp_i + tn_i}{tp_i + tn_i + fp_i + fn_i} \quad (1)$$

این معیار، نسبت تعداد پیش‌بینی‌های درست به کل نمونه‌ها را نشان می‌دهد. رابطه (۲) نحوه محاسبه معیار پوشش را نشان داده و بیان کننده آن است که چه تعداد از نمونه‌های درست در هر کلاس، به درستی شناسایی و پیش‌بینی شده‌اند:

$$Recall = \frac{1}{n} \sum_{i=1}^n \frac{tp_i}{tp_i + fn_i} \quad (2)$$

رابطه (۳) نحوه محاسبه معیار صحت را بیان می‌کند:

$$Precision = \frac{1}{n} \sum_{i=1}^n \frac{tp_i}{tp_i + fp_i} \quad (3)$$

رابطه فوق نسبت نمونه‌های مثبت و درست را به تمامی نمونه‌هایی که مثبت شناسایی و پیش‌بینی شده‌اند را نشان می‌دهد. رابطه (۴) نیز نشان‌دهنده نحوه محاسبه امتیاز F1 می‌باشد که میانگینی از معیارهای صحت و پوشش است و برای ارزیابی تعادل مدل به کار می‌رود:

$$F1 \text{ score} = \frac{2Precision \cdot Recall}{Precision + Recall} \quad (4)$$

این چهار معیار همگی برای ارزیابی عملکرد مدل استفاده می‌شوند، اما هر کدام دیدگاه متفاوتی نسبت به پیش‌بینی‌های مدل ارائه می‌دهند. دقت نشان می‌دهد که چه مقدار از پیش‌بینی‌های مدل صحیح هستند، صحت بر نمونه‌های مثبت تمرکز دارد، پوشش مشخص می‌کند که مدل چه میزان از نمونه‌های واقعی را شناسایی کرده است و امتیاز F1 توازن بین صحت و پوشش را برقرار می‌کند.

⁴ Recall

⁵ Confusion Matrix

¹ Fold Cross-validation-10

² Accuracy

³ Precision

می‌شود. اما در فاز بعدی، که اعتبارسنجی مدل در محیط‌های واقعی و صنعتی است، پیش‌بینی‌های مدل با استانداردهای معتبر، داده‌های عملیاتی و نظرات متخصصان انسانی مقایسه می‌شود. این مرحله (فاز دوم) تعیین می‌کند که آیا مدل یادگیری ماشین می‌تواند به‌عنوان یک ابزار قابل اعتماد در انتخاب آزمون غیرمخرب (NDT) مناسب مورد استفاده قرار گیرد یا نیاز به اصلاح و بهینه‌سازی بیشتری دارد.

پس از تکمیل فرآیند آموزش و ارزیابی مدل، خروجی مدل در محیط برنامه‌نویسی Jupyter قابل مشاهده است. این خروجی ترکیبی از معیارهای ارزیابی که در باره آن‌ها صحبت شده بود، می‌باشد. این خروجی در جدول ۶ قابل مشاهده است.


در مجموعه داده‌هایی که توزیع کلاس‌ها نامتوازن است، معیار دقت ممکن است گمراه‌کننده باشد. برای مثال، اگر در یک مجموعه داده، ۹۵ درصد از نمونه‌ها متعلق به یک کلاس (دسته) باشند، مدلی که همه نمونه‌ها را به همان کلاس اختصاص دهد، دقت بالایی خواهد داشت، اما در عمل مدل عملکرد خوبی ندارد. در این شرایط، معیارهای صحت، پوشش و امتیاز F1 کاربرد بیشتری دارند.

همچنین امتیاز F1 زمانی مهم است که هر دو خطای FN و FP اهمیت داشته باشند. این معیار زمانی که یک کلاس کمتر از سایرین مشاهده شده باشد، مدل را تشویق می‌کند تا هم پوشش خوبی داشته باشد و هم دقت معقولی ارائه دهد.

تمامی این معیارها در فاز ارزیابی عملکرد مدل استفاده

جدول ۶) خروجی نهایی مدل‌های یادگیری ماشین به‌همراه معیارهای ارزیابی مدل

تعداد کل داده‌های استفاده شده برای مدل‌سازی: ۵۰۰						
روش ارزیابی: اعتبارسنجی متقابل ده‌لایه‌ای						
مدل	کلاس (آزمون)	صحت	پوشش	امتیاز F1	پشتیبان	دقت مدل
RF	RT	۰/۹۱	۰/۸۹	۰/۹۰	۲۶	۸۶ درصد
	MT	۰/۸۴	۰/۸۲	۰/۸۳	۲۵	
	UT	۰/۸۶	۰/۸۴	۰/۸۵	۱۸	
	PT	۰/۸۶	۰/۸۴	۰/۸۵	۱۶	
SVM	ET	۰/۸۸	۰/۸۷	۰/۸۸	۱۵	۸۷ درصد
	RT	۰/۸۹	۰/۸۷	۰/۸۸	۲۲	
	MT	۰/۸۸	۰/۸۶	۰/۸۷	۲۳	
	UT	۰/۸۵	۰/۸۳	۰/۸۴	۲۲	
KNN	PT	۰/۹۰	۰/۸۸	۰/۸۹	۱۶	۷۹ درصد
	ET	۰/۸۸	۰/۸۶	۰/۸۷	۱۷	
	RT	۰/۸۷	۰/۸۳	۰/۸۵	۱۷	
	MT	۰/۸۱	۰/۷۸	۰/۷۹	۲۲	
XGBoost	UT	۰/۸۰	۰/۷۷	۰/۷۸	۲۱	۹۰ درصد
	PT	۰/۷۸	۰/۷۵	۰/۷۶	۲۰	
	ET	۰/۷۶	۰/۷۴	۰/۷۵	۲۰	
	RT	۰/۹۳	۰/۹۱	۰/۹۲	۲۱	
XGBoost	MT	۰/۹۱	۰/۹۰	۰/۹۰	۲۸	۹۰ درصد
	UT	۰/۹۱	۰/۸۹	۰/۹۰	۲۳	
	PT	۰/۹۲	۰/۹۱	۰/۹۱	۱۶	
	ET	۰/۹۴	۰/۹۳	۰/۹۳	۱۲	



شکل ۳) منحنی مشخصه عملکرد مدل‌های یادگیری ماشین

شکل ۳ منحنی مشخصه عملکرد (ROC) مدل‌های پیش‌بینی را به همراه شاخص سطح زیر نمودار (AUC) نشان می‌دهد که منشأ آن‌ها، ماتریس‌های درهم‌ریختگی است که در جدول ۵ به آن‌ها اشاره شده بود. نمودارهای ROC و مقادیر AUC هر مدل، توانایی آن‌ها را در تفکیک کلاس‌های مختلف را نمایان می‌سازد. به‌طور کلی، هرچه مقدار AUC به یک نزدیک‌تر باشد و از نقطه‌چین به سمت بالا و دورتر باشد، دقت مدل در شناسایی کلاس مربوطه بیشتر است [۲۷]. با توجه به شکل ۳، مدل XGBoost بهترین عملکرد را در تفکیک کلاس‌های مختلف داشته است به‌طوری‌که مقدار AUC آن برای هر کلاس به‌طور میانگین ۹۰ درصد است. همچنین مدل‌های SVM و RF به‌ترتیب با مقدار AUC میانگین ۸۷ و ۸۶ درصد در جایگاه‌های بعدی از نظر عملکرد و تفکیک کلاس‌های مختلف داشته‌اند. مدل KNN اما در این بین ضعیف‌ترین عملکرد را داشته است، به‌طوری‌که مقدار AUC میانگین آن برابر با ۷۹ درصد است. این موضوع نشان می‌دهد که مدل KNN در تفکیک کلاس‌های مختلف دقت کمتری نسبت به سایر مدل‌ها داشته و میزان هم‌پوشانی بین کلاس‌ها در این مدل بیشتر است. این مسئله می‌تواند به دلیل حساسیت بالای KNN به نویز داده‌ها و تأثیر مستقیم تعداد همسایگان انتخابی در فرآیند طبقه‌بندی داده‌ها باشد. بنابراین، با توجه به مقادیر AUC، می‌توان نتیجه گرفت که مدل XGBoost انتخاب

۳- نتایج و بحث

در این پژوهش، مقایسه‌ای بین پیش‌بینی‌های سه بازرسی (خبره) و مدل‌های یادگیری ماشین برای انتخاب بهینه آزمون‌های غیرمخرب انجام شد. برای این منظور، ۱۰۰ داده از آزمون‌های انجام شده که در مرحله آموزش مدل از آن‌ها به‌عنوان داده‌های ارزیابی مدل استفاده شده بود، در قالب یک پرسشنامه به بازرسان داده شد تا بدون دسترس به پاسخ نهایی صحیح، همانند مدل‌های یادگیری ماشین، بهترین آزمون غیرمخرب را بر اساس شاخص‌های مدل‌سازی، پیش‌بینی کنند. نتایج این پیش‌بینی‌ها در جدول ۶ آورده شده است.


جدول ۷) عملکرد پیش‌بینی متخصصان انسانی (خبره)

پیش‌بینی کننده	مدرک تخصصی	دقت
بازرس اول	سطح دو	۸۸ درصد
بازرس دوم	سطح دو	۸۶ درصد
بازرس سوم	سطح سه	۹۱ درصد

با توجه به جدول‌های ۶ و ۷ مشخص می‌شود که دو مدل از چهار مدل یادگیری ماشین در مقایسه با عملکرد پیش‌بینی‌های متخصصان انسانی دقت بالاتری داشته و می‌توانند اشتباهات انسانی را کاهش و نتایج دقیق‌تری برای انتخاب بهینه آزمون‌ها ارائه دهند. مدل XGBoost با دقت ۹۰ درصد بهترین عملکرد را برای این مسئله براساس داده‌های موجود در دیتاست داشته و مدل KNN با دقت ۷۹ درصد نشان داد که نه تنها در مقایسه با دیگر مدل‌های یادگیری ماشین عملکرد ضعیف‌تری در پیش‌بینی بهینه آزمون‌های غیرمخرب دارد، بلکه متخصصان انسانی نیز دقت و عملکرد به مراتب بهتری نسبت به این مدل از خود نشان داده‌اند. همچنین در پژوهشی که کاروالو و همکاران انجام داده‌اند، به نتایج مشابهی دست‌یافته‌اند که نرخ خطای انسانی در تشخیص صحیح آزمون‌های غیرمخرب بین ۵ تا ۱۵ درصد می‌باشد. آن‌ها استفاده از مدل‌های خودکارسازی (اتوماسیون) و مدل‌های یادگیری ماشین را به‌عنوان راهکاری برای کاهش نرخ خطا و بهبود دقت در انتخاب آزمون‌های غیرمخرب مناسب پیشنهاد داده‌اند [۲۶].



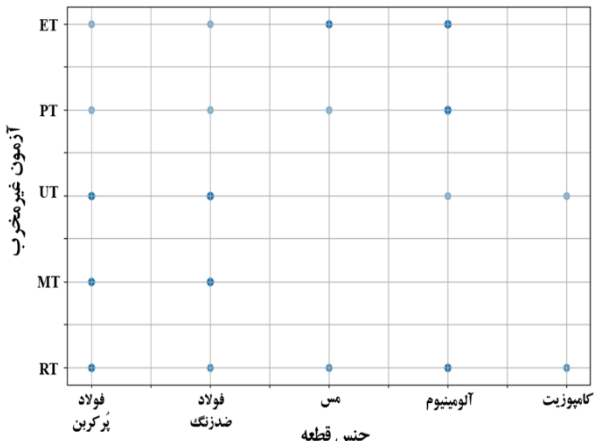
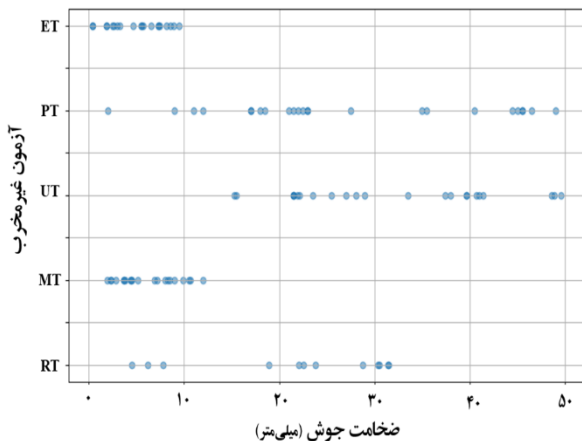
مدل‌سازی دارند. به عبارت دیگر، این دو ویژگی بیش‌ترین تأثیر را در تعیین آزمون غیرمخرب بهینه (کلاس) در هر نمونه دارند. پژوهش ماکادو نیز نشان می‌دهد که انتخاب آزمون غیرمخرب مناسب برای جوشکاری‌های انجام شده، به‌طور قابل‌توجهی تحت تأثیر این دو ویژگی قرار دارد. این پژوهش بیان می‌کند که بسته به نوع روش آزمون، یکی از این ویژگی‌ها ممکن است تأثیر بیش‌تری داشته باشد؛ به‌ویژه در آزمون‌هایی مانند UT و RT، ضخامت جوش عامل تعیین‌کننده‌ای است که به دقت نتایج کمک می‌کند. علاوه بر این، ضخامت جوش نیز به عنوان یک متغیر کلیدی در نظر گرفته شده است، چراکه برخی روش‌های NDT مانند UT و RT به ضخامت جوش وابسته هستند و از یک مقادیری کمتر یا بیش‌تر قابل استفاده نیستند. در نهایت، میزان دسترسی به سطح جوش نیز تأثیر قابل‌توجهی دارد، زیرا برخی روش‌های NDT (نظیر ET) به دسترسی مستقیم به سطح نیاز دارند، در حالی که روش‌هایی مانند RT می‌توانند در شرایط محدود نیز مورد استفاده قرار گیرند. [۲۸].

مناسبتی برای پیش‌بینی آزمون‌های غیرمخرب (NDT) بر اساس داده‌های موجود است.



شکل ۴) میزان اهمیت متغیرها جهت پیش‌بینی آزمون بهینه

در شکل ۴، میزان اهمیت ویژگی‌ها (شاخص‌ها) در پیش‌بینی بهینه آزمون‌های غیرمخرب نمایش داده شده است. نتایج نشان می‌دهد که به‌طور میانگین در هر چهار مدل RF، SVM، KNN و XGBoost شاخص‌های جنس قطعه و نوع جوشکاری انجام شده، به‌عنوان مهم‌ترین ویژگی‌ها شناسایی شده‌اند که بیش‌ترین تأثیر را در



شکل ۵) نتایج مدل XGBoost بر اساس ویژگی‌های جنس قطعه، ضخامت جوش، نوع جوش و ساختار قطعه

نتایج پژوهش‌های پیشین، جدول ۸ بر اساس داده‌های استخراج شده از شکل ۵ تهیه شده است. در این جدول، نتایج مدل با یافته‌های پژوهش‌های پیشین و استانداردهای بین‌المللی ASTM E-Series و ASME Section V 2023 (مانند E94، E165، E1004، E144 و...) مقایسه شده است. هدف این مقایسه، بررسی میزان تطابق مدل توسعه یافته با استانداردهای بین‌المللی و مطالعات گذشته است تا مشخص شود که آیا مدل توسعه یافته به درستی آزمون‌های مناسب را پیشنهاد دهد یا خیر.

در شکل ۵، پراکندگی آزمون‌های پیش‌بینی شده توسط مدل XGBoost بر اساس ویژگی‌های جنس و ساختار قطعه، نوع جوش و ضخامت آن نمایش داده شده است. این نمودارهای پراکندگی به تحلیل رابطه میان ویژگی‌های مختلف قطعه و آزمون‌های غیرمخرب (NDT) پیشنهادی توسط مدل می‌پردازند. هدف اصلی این تحلیل، شناسایی الگوهای موجود در داده‌ها و بررسی میزان تأثیر هر یک از ویژگی‌های قطعه در انتخاب آزمون غیرمخرب مناسب است. این بخش جزء فاز دوم ارزیابی مدل محسوب می‌شود، زیرا در این مرحله باید عملکرد مدل با واقعیت‌های صنعتی و استانداردهای موجود مقایسه شود. به منظور بررسی صحت عملکرد مدل XGBoost و انطباق نتایج آن با استانداردها و

جدول ۸) بررسی نتایج مدل XGBoost با پژوهش‌های گذشته و استانداردهای ASTM E-Series و ASME 2023 Section V

استاندارد	نتایج مشابه مطالعات گذشته			نتایج مدل XGBoost
	منبع	سال	نویسنده (گان)	
ASME-23 Section V: Article 1, I-121.5 Article 7, T-720	[۲۹]	۲۰۲۳	بیاتی و فراهانی	آزمون MT تنها برای مواد فرومغناطیسی و شناسایی عیوب سطحی و زیر سطحی مناسب می‌باشد. همچنین از نظر ساختار و هندسه قطعه، محدودیت خاصی وجود ندارد. این روش برای جوش‌های زاویه‌ای، تی‌شکل و لبه‌ای مناسب می‌باشد.
	[۳]	۲۰۲۰	هنرور	
ASME-23 Section V: Article 2, T-210 Article 2, T-260 Article 2, T-270 Article 2, T-274 ASTM E94-04: Section 1.1 ~ 1.5	[۲۹]	۲۰۲۳	بیاتی و فراهانی	آزمون RT از نظر ساختار هندسی قطعه محدودیتی ندارد و برای انواع قطعات فلزی و غیرفلزی مناسب می‌باشد. همچنین، برای بازرسی قطعات با ضخامت بالا، به دلیل نیاز به منابع پر قدرت و احتمال افزایش ناخواسته میزان پرتوگیری خارجی بازرسی، منبع ایکس (X-ray) پیشنهاد می‌شود. همچنین این آزمون برای جوش‌های لب به لب بیشترین کاربرد را دارد.
	[۳۰]	۲۰۱۸	هیرماز	
	[۳۲]	۲۰۲۱	گوپتا و همکاران	
ASTM E165-23: Section 1.1 Section 8.4 Section 8.5	[۳]	۲۰۲۰	هنرور	آزمون PT تنها برای شناسایی عیوب سطحی و مواد غیرمتخلخل مناسب می‌باشد. همچنین این روش به دلیل تمرکز بر شناسایی عیوب سطحی، به ضخامت کلی جوش و قطعه وابسته نمی‌باشد.
	[۳۲]	۲۰۲۱	گوپتا و همکاران	
ASTM E709-21: Section 1.1 Section 1.3 Section 4.1	[۲۹]	۲۰۲۳	بیاتی و فراهانی	آزمون ET تنها برای مواد رسانا (هادی الکتریسیته) و شناسایی عیوب سطحی و زیر سطحی مناسب می‌باشد. همچنین به دلیل عمق نفوذ محدود، برای قطعات با ضخامت بالا توصیه نمی‌شود. این روش برای جوش‌های همپوشانی مناسب می‌باشد.
	[۳۲]	۲۰۲۱	گوپتا و همکاران	
	[۳]	۲۰۲۰	هنرور	
ASTM E164-19: Section 1.1 Section 1.2 Section 3.1 Section 4	[۲۹]	۲۰۲۳	بیاتی و فراهانی	آزمون UT از نظر جنس قطعه محدودیتی ندارد و به دلیل دقت و حساسیت بالا، برای شناسایی عیوب زیر سطحی و عمقی مناسب می‌باشد و برای شناسایی عیوب سطحی به دلیل هزینه بالا و نیاز به تخصص و آموزش گسترده، معمولاً توصیه نمی‌شود. همچنین این روش برای قطعات با ضخامت کم یا ساختارهای پیچیده به دلیل محدودیت‌های فنی و اجرایی، پیشنهاد نمی‌شود. این آزمون برای جوش‌های لب به لب کاربرد گسترده‌ای دارد.
	[۳۱]	۲۰۲۱	اولسا و همکاران	
	[۳]	۲۰۲۰	هنرور	
	[۳]	۲۰۲۰	هنرور	

داده‌ها، تعمیم‌پذیری آن را ارتقا داد و دقت مدل را در شرایط واقعی افزایش بخشید. همچنین، استفاده از یادگیری عمیق می‌تواند منجر به شنا سایی روابط پیچیده‌تری میان متغیرها شود و عملکرد مدل را در تشخیص آزمون‌های غیرمخرب بهینه، بهبود دهد. علاوه بر این، پیشنهاد می‌شود که متغیرهای بیشتری از جمله ویژگی‌های فیزیکی و شیمیایی مواد، شرایط محیطی جو شکاری، نوع ترکیب مواد سازنده و داده‌های سه‌بعدی از ساختار جوش در مدل‌سازی لحاظ گردد تا دقت پیش‌بینی افزایش یابد. همچنین پیشنهاد می‌شود متغیرهای کلان‌تر مانند هزینه‌ها، فاکتورهای انسانی، ملاحظات محیط‌زیستی و... را نیز در نظر گرفت تا به یک سیستم جامع‌تر در فرآیند انتخاب روش آزمون غیرمخرب مناسب تبدیل شود.

۵- تشکر و قدردانی

از مؤسسه بازرسی و مشاوره فنی و مهندسی آزمون گستر آسیا به دلیل همکاری ارزشمند در تأمین داده‌ها و همچنین بهره‌مندی از تخصص و دانش کارشناسان آن مؤسسه در این پژوهش، صمیمانه قدردانی می‌نمایم. این حمایت‌ها، به‌ویژه دسترسی به اطلاعات کاربردی و نظرات متخصصان، نقش مهم در پیشبرد و ارتقای کیفیت این پژوهش داشته است.

۶- تعارض منافع

هیچ‌گونه تعارض منافع توسط نویسندگان وجود ندارد.

۷- منابع

- [1] Taheri, H., Gonzalez Bocanegra, M. and Taheri, M. (2022). Artificial Intelligence, Machine Learning and Smart Technologies for Nondestructive Evaluation. *Sensors*, 22(11), 1-17.
- [2] Kumpati, R., Skarka, W. and Ontipuli, S.K. (2021). Current Trends in Integration of Nondestructive Testing Methods for Engineered Materials Testing. *Sensors*, 21(18), 1-32.
- [3] Honarvar, F. (2020). Nondestructive Testing (Principles, Methods and Applications), 1st Volume K.N. Toosi University of Technology Press, 1-287. (in Persian)
- [4] Wang, W., Chen, J., Han, G., Shi, X. and Qian, G. (2024). Application of Object Detection Algorithms in Non-Destructive Testing of Pressure Equipment: A Review. *Sensors*, 24(18), 1-28.

۴- نتیجه‌گیری

پژوهش حاضر با توسعه مدل پیش‌بینی مبتنی بر یادگیری ماشین، گامی در جهت بهینه‌سازی فرآیند انتخاب آزمون‌های غیرمخرب (NDT) برای بازرسی قطعات و جوش‌ها برداشته است. این مدل، با در نظر گرفتن شاخص‌های کلیدی نظیر جنس و ساختار قطعه، نوع جوش و ضخامت آن، می‌تواند فرآیند انتخاب آزمون‌های غیرمخرب را بهینه‌سازی کرده و میزان دقت در این فرآیند را افزایش دهد. نتایج مدل‌سازی نشان داد که مدل XGBoost با دقت ۹۰ درصد، در مقایسه با سایر مدل‌ها عملکرد بهتری برای این مسئله و داده‌های موجود داشته و به‌ویژه در شرایطی که قطعات از تنوع جنس و ضخامت برخوردار بودند. همچنین، نتایج مدل با پژوهش‌های پیشین و استانداردهای بین‌المللی ASTM E-Series و ASME 2023 Section V انطباق دارد. پژوهش حاضر از ترکیب مدل‌های یادگیری ماشین و داده‌محور برای انتخاب آزمون غیرمخرب بهینه در بازرسی جوش بهره برده است. در حالی که پیش‌تر تصمیم‌گیری در این زمینه عمدتاً بر اساس تجربه متخصصان یا استانداردها انجام می‌شد، این پژوهش یک سیستم تصمیم‌ساز طراحی کرده است که قادر به کاهش خطاهای انسانی و بهبود دقت انتخاب آزمون‌های غیرمخرب است. مقایسه نتایج مدل با پیش‌بینی‌های انجام‌شده توسط متخصصین انسانی، بهبود ۵ درصدی دقت را نشان می‌دهد. علاوه بر مدل XGBoost، سایر مدل‌های بررسی‌شده نیز عملکرد مطلوبی داشتند، به‌ویژه مدل‌های SVM و RF که به ترتیب با دقت ۸۶ و ۸۷ درصدی، نتایج نسبتاً قابل‌قبولی ارائه داده‌اند. اما مدل KNN با دقت ۷۹ درصد، عملکرد ضعیف‌تری نسبت به سایر مدل‌ها داشت. با این وجود، پژوهش حاضر دارای محدودیت‌هایی نظیر حجم نمونه کم و تنوع محدود در داده‌ها است و ممکن است این داده‌ها تمام شرایط عملیاتی و پیچیدگی‌های موجود در محیط‌های صنعتی واقعی را پوشش ندهند. همچنین، وابستگی مدل به برخی ویژگی‌های خاص مانند نوع و ضخامت جوش، جنس و ساختار قطعه ممکن است منجر به کاهش عملکرد آن در شرایطی شود که اطلاعات این ویژگی‌ها ناقص یا ناموجود باشند. برای بهبود و توسعه بیشتر مدل پیشنهادی، می‌توان با افزایش حجم و تنوع

- Ati Negar, 1-160. (in Persian)
- [17] Bararpour, K. (2023). Business Dynamics: Systems Thinking and Modeling for a Complex World, 1st Volume, SAMT, 1-788. (in Persian)
- [18] Tabatabaei, M.S., Yazdian Dehkordi, M. and Jahangard Rafsanjani, A. (2022). Predicting Dimensional Deviation of Ceramic Tiles using Machine Learning Methods. *Journal of Iranian Association of Electrical and Electronics Engineers*, 19(2), 201-208. (in Persian)
- [19] Turkian, A. (2021). Deep Learning, 1st Edition. *Niaze Danesh*, 1-552. (in Persian)
- [20] Raeisi, Z., Adibnia, F. and Yazdian, M. (2024). A New Hybrid Method Based on Intelligent Algorithms for Intrusion Detection in SDN-IoT. *Iranian Journal of Electrical and Computer Engineering (IJECE)*, 1(22), 1-11. (in Persian)
- [21] Sarica, A., Cerasa, A. and Quattrone, A. (2017). Random Forest Algorithm for the Classification of Neuroimaging Data in Alzheimer's Disease: A Systematic Review. *Front Aging Neurosci*, 9:329.
- [22] Kar, A., Nath, N., Kemprai, U. and Aman . (2024). Performance Analysis of Support Vector Machine (SVM) on Challenging Datasets for Forest Fire Detection. *International Journal of Communications, Network and System Sciences*, 17(1), 11-29.
- [23] Suyal, M. and Goyal, P. (2022). A Review on Analysis of K-Nearest Neighbor Classification Machine Learning Algorithms based on Supervised Learning. *International Journal of Engineering Trends and Technology*, 70(7), 43-48.
- [24] Chen, T. and Guestrin, C. (2016). XGBoost: A Scalable Tree Boosting System. *22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD '16)*, 785-794.
- [25] Esmaeili Gorjan, H. and Gil Jiménez, V.P. (2024). Improving Indoor WiFi Localization by Using Machine Learning Techniques. *Sensors*, 24(19), 1-21.
- [26] Carvalho, A.A., Rebello, J.M.A., Souza, M.P.V., Segrilo, L.V.S. and Soares, S.D. (2008). Reliability of Non-Destructive Test Techniques in the Inspection of Pipelines Used in the Oil Industry. *International Journal of Pressure Vessels and Piping*, 85(11), 745-751.
- [27] Junge, M.R.J. and Dettori, J.R. (2018). ROC Solid: Receiver Operator Characteristic (ROC) Curves as a Foundation for Better Diagnostic Tests. *Global Spine Journal*, 8(4), 424-429.
- [28] Machado, M.A. (2024). Eddy Currents Probe Design for NDT Applications: A Review. *Sensors*, 24(17), 1-42.
- [29] Bayati, A. and Farahani, M. (2023). Non-
- [5] Rezaei Ghahroodi, Z. and Aghamohamadi, Z. (2022). Record Linkage with Machine Learning Methods. *Journal of Statistical Sciences (JSS)*, 16(1), 1-24.
- [6] Yousefi, A. A., M Nekouei, M. A., Brendjchi, A. H., & Amiri, M. (2022). Machine Learning Applications in Organic Solar Cells. *Basparesh*, 11(4), 51-64. (in Persian)
- [7] Torbali, M.E., Zolotas, A. and Avdelidis, N.P. (2023). A State-of-the-Art Review of Non-Destructive Testing Image Fusion and Critical Insights on the Inspection of Aerospace Composites Towards Sustainable Maintenance. *Applied Sciences*, 13(4), 1-30.
- [8] Schmid, M., Bhogaraju, S.K., Liu, E. and Elger, G. (2020). Comparison of Nondestructive Testing Methods for Solder, Sinter, and Adhesive Interconnects in Power and Opto-Electronics. *Applied Sciences*, 10(23), 1-30.
- [9] Javaheri Pour, J. (2018). UK National Aerospace NDT Board (NANDTB). *Journal of Nondestructive Testing Technology (JNDT)*, 2(2), 14-18. (in Persian)
- [10] Yaghootian, A., Fatahi, L. and Tayebi, S. (2021). Implementation of Neural Networks for Prediction of Location and Orientation of Pipe Defects in Guided Wave Ultrasonic Testing. *Journal of Nondestructive Testing Technology (JNDT)*, 2(8), 8-17. (in Persian)
- [11] Beigzadeh, A., and Badiei, S. (2023). Thickness Measurement of Metals Using Neural Network and Radioisotope Measurement-Modelling. *Journal of Nondestructive Testing Technology (JNDT)*, 3(2), 1-15 (in Persian)
- [12] Noori Hoshyar, A., Rashidi, M., Liyanapathirana, R. and Samali, B. (2019) Algorithm Development for the Non-Destructive Testing of Structural Damage. *Applied Sciences*, 9(14), 1-22.
- [13] Niccolai, A., Caputo, D., Chieco, L., Grimaccia, F. and Mussetta, M. (2021). Machine Learning-Based Detection Technique for NDT in Industrial Manufacturing. *Mathematics*, 9(11), 1-16.
- [14] Naderpour, H., Abbasi, M., Kontoni D.P.N., Mirrashid, M., Ezami, N. and Savvides A.A. (2024). Integrating Image Processing and Machine Learning for the Non-Destructive Assessment of RC Beams Damage. *Buildings*, 14(1), 1-24.
- [15] Hussain, B. (2024). Integration of Non-Destructive Testing Techniques and Machine Learning Algorithms for Enhanced Structural Health Monitoring of Bridges. *Current Journal of Applied Science and Technology*, 43(9), 20-31.
- [16] Fallah, H.R. and Esmaeili, M. (2021). Machine Learning Specialization (Andrew Ng). 1st Edition,

Destructive Evaluation of the Welded Joints Using Infrared Thermography Technique. *Journal of Nondestructive Testing Technology (JNDT)*, 3(3), 13-26.

- [30] Hirmaz, M.S. (2018). Non-Destructive Testing Methods of Composite Materials: A Review. *International Journal of Scientific Engineering and Research (IJSER)*, 6(8), 5-9.
- [31] Olisa, S.C., Khan, M.A. and Starr, A. (2021). Review of Current Guided Wave Ultrasonic Testing (GWUT) Limitations and Future Directions. *Sensors*, 21(3), 1-28.
- [32] Gupta, M., Ahmad Khan, M., Butola, R. and Singari, R.M. (2021). Advances in applications of Non-Destructive Testing (NDT): A review. *Advances in Materials and Processing Technologies*, 8(2), 2286–2307.