

TINERI CERCETĂTORI
JUNIOR RESEARCHERS

Detecția imperfecțiunilor de material la sudare cu sisteme avansate de inteligență artificială

Detection of welding imperfections using advanced artificial intelligence systems

Anamaria Luisa Urșan^{1*}, Imelda-Ibolya Peter¹

¹ Universitatea Tehnică Cluj

Rezumat

Lucrarea prezintă o serie de cercetări care vizează detecția imperfecțiunilor de sudare folosind algoritmi Deep Learning și tehnologii de inteligență artificială (AI). Această direcție de cercetare se încadrează într-un domeniu de mare interes, atât pentru companii, cât și pentru institute de cercetare sau universități. Conform studiului introductiv prezentat în lucrare se estimează o creștere semnificativă a impactului AI asupra activității industriale, în particular asupra metodelor de control și examinare nedistructivă (NDE), precum și pentru o gamă tot mai extinsă de tehnologii de procesare a materialelor, inclusiv în domeniul sudării materialelor.

Cuvinte cheie

Sursă termică hibridă, procedeu FFF, soluții constructive, modelare și simulare câmp termic, măsurare temperaturi

Abstract

The paper presents a series of research focusing on the detection of welding imperfections using Deep Learning algorithms and artificial intelligence (AI) technology. This research direction falls within a highly interesting field, both for companies and research institutes or universities. According to the introductory study presented in the paper, a significant increase in the impact of AI on industrial activities is estimated, particularly on non-destructive testing and examination (NDE) methods, as well as for an increasingly wide range of material processing technology, including in the field of welding materials.

Keywords

Hybrid heat source, FFF process, structural design, modelling and simulation of thermal field, temperature measurements

1. Introducere

Tehnologiile de sudare stau la baza dezvoltării industriale a țărilor puternic dezvoltate: China, USA, Japonia, UE, UK etc. Sudarea reprezintă o tehnologie cheie de fabricație în diverse sectoare industriale: de la industria constructoare de autovehicule, construcții navale, civile sau industriale, la industria energetică sau aerospațială. În România, producția industrială are o contribuție la PIB de 24,1% și asigură locuri de muncă pentru 22% din forța de muncă a țării [1].

1.1 Imperfecțiuni de material la sudare

După cum este indicat în familia de standarde EN ISO 9001:2018, sudarea este un proces special în care „conformitatea produsului rezultat nu

1. Introduction

Welding technologies underpin the industrial development of highly developed countries: China, USA, Japan, EU, UK etc. Welding represents a key manufacturing technology in various industrial sectors: from the automotive industry, shipbuilding, civil or industrial construction, to the energy or aerospace industry. In Romania, industrial production contributes 24.1% to the GDP and provides jobs for 22% of the country's workforce [1].

1.1 Welding Imperfections

As indicated in the EN ISO 9001:2018 family of standards, welding is a special process where "the conformity of the resulting product is not easily or eco-

este ușor sau economic verificată". Pentru asigurarea calității, producătorii de construcții metalice suate implementează sistemul de asigurare a calității ISO 9001. Libera circulație a produselor în Europa și obligația de a obține un marcaj CE face necesară certificarea și a produsului, nu doar a companiei. Prin urmare, certificarea pe baza EN 1090 este obligatorie [2]. Prin imperfecțiune de sudare se înțelege orice abatere de la continuitate, formă, dimensiune, aspect, structură care are loc la nivelul unei îmbinări sudate. Imperfecțiunile de sudare în cazul procedeelor de sudare prin topire se pot grupa în imperfecțiuni interne volumice, imperfecțiuni interne plane, imperfecțiuni de formă și de suprafață [3-7].

Standardul EN 1090 impune companiilor să aibă un sistem de control al producției din fabrică, care se realizează prin respectarea cerințelor specificate în standardele ISO 3834 - cerințe de calitate pentru sudarea prin topire a materialelor metalice, ISO 14731 - coordonarea operațiunilor de sudare și ISO 9606:2012 (revizuit în 2023) care sunt utilizate pentru calificarea sudorului în conformitate cu materialele sudate: ISO 9606-1: oțeluri, ISO 9606-2: aliaje de aluminiu și Al, ISO 9606-3: cupru și aliaje de cupru, ISO 9606-4: nichel și aliaje de nichel, ISO 9606-5: titan și aliaje de titan, Zr și aliaje de zirconiu.

Detectarea imperfecțiunilor de sudare reprezintă o operație necesară pentru prevenirea respingerii unor produse ce conțin subsansamble sudate, pentru reducerea costurilor de reparații ale acestora și pentru asigurarea siguranței în exploatare a mașinilor, instalațiilor și a construcțiilor sudate.

Imperfecțiunile de sudare reprezintă una din principalele cauze care stau la baza producerii unor avarii grave soldate cu pagube materiale importante, sau chiar cu victime umane. Principalele grupe de factori care pot afecta calitatea îmbinărilor sudate sunt:

- **Procedurile de sudare incorecte**

Nerespectarea procedurilor de sudare sau întocmirea acestora incorect, nerespectarea temperaturilor de preîncălzire, a temperaturii între treceri, a ordinii de sudare, rezultarea unor viteze de răcire neadecvate în metalul depus și în zona de influență termică (ZIT), calitatea materialelor de adaos și auxiliare etc.

- **Concentratorii de tensiuni**

Aceștia apar datorită designului sau formei incorecte a cusăturii sudate, nerespectarea parametrilor de sudare sau datorită calificării insuficiente a sudorilor, respectiv datorită bridării excesive a structurilor metalice sudate.

nomically verified." To ensure quality, manufacturers of welded metal constructions implement the ISO 9001 quality assurance system. The free movement of products in Europe and the obligation to obtain CE marking makes product certification necessary, not just company certification. Therefore, certification based on EN 1090 is mandatory [2].

Welding imperfections refer to any deviation from continuity, shape, size, appearance, structure that occurs at the level of a welded joint. Welding imperfections in the case of fusion welding processes can be grouped into volumetric internal imperfections, flat internal imperfections, shape imperfections, and surface imperfections [3-7].

Standard EN 1090 requires companies to have a factory production control system, which is implemented by complying with the requirements specified in standards such as ISO 3834 - quality requirements for fusion welding of metallic materials, ISO 14731 - coordination of welding operations, and ISO 9606:2012 (revised in 2023) which are used for welder qualification in accordance with welded materials: ISO 9606-1: steels, ISO 9606-2: aluminum and Al alloys, ISO 9606-3: copper and copper alloys, ISO 9606-4: nickel and nickel alloys, ISO 9606-5: titanium and titanium alloys, Zr and zirconium alloys.

Detecting welding imperfections is a necessary operation to prevent the rejection of products containing welded subassemblies that presents quality issues, to reduce repairing consequent costs, and to ensure the safety of machines, installations, and welded constructions in operation.

Welding imperfections are one of the main causes of serious failures that can lead to significant material damage or even human casualties. The main groups of factors that can affect the quality of welded joints and could lead to such events are:

- **Incorrect welding procedures**

Non-compliance with welding procedures or incorrect preparation thereof, failure to comply with preheating temperatures, interpass temperature, welding sequence, resulting in inadequate cooling rates in the deposited metal and in the heat-affected zone (HAZ), quality of filler and auxiliary materials etc.

- **Stress concentrators**

These occur due to incorrect design or shape of the welded joint, failure to comply with welding parameters, or due to insufficient qualification of welders, respectively due to excessive bracing of welded metal structures.

- **Control de calitate** sau inspecție/testare necorespunzătoare;
- **Design eronat** sau **condiții de exploatare improprii**, precum supraîncărcări excesive, apariția fenomenelor de coroziune, de oboseală mecanică și termică mentenanță deficitară ș.a.

Conform Miller Co [3], pot fi identificate șase stadii pentru care sunt asociate creșteri exponențiale ale costurilor pentru remedierea imperfecțiunilor de sudare, aspecte ilustrate în figura 1.

- **Improper quality control** or inspection/testing;
- **Erroneous design or improper operating conditions**, such as excessive overloads, occurrence of corrosion phenomena, mechanical and thermal fatigue, poor maintenance etc.

According to Miller Co [3], six stages can be identified for which exponential increases in costs for remedying welding imperfections are associated, aspects illustrated in figure 1.




Figura 1. Evoluția costurilor de fabricație în funcție de momentul detecției imperfecțiunilor de sudare [3]

Figure 1. Evolution of manufacturing costs depending on the moment of detecting welding imperfections [3]

1.2 Clase de execuție la sudare

Standardul SR EN ISO 5817:2023 [4] stabilește trei niveluri de calitate (B, C și D) în raport cu imperfecțiunile de material la sudare în cazul îmbinărilor sudate prin topire din oțel, nichel, titan și aliajele lor. Clasificarea imperfecțiunilor geometrice din îmbinările sudate ale materialelor metalice în cazul procedeelor de sudare prin topire se face conform SR EN ISO 6520-1:2007 [5]. Asigurarea calității structurilor metalice sudate se face prin respectarea cerințelor prevăzute în SR EN 1090-2, care prevede încadrarea lucrărilor de sudare în patru posibile clase de execuție în ordinea crescătoare de la EXC1 până la EXC4. Această încadrare se face ținând cont de complexitatea structurii, respectiv de consecințele cedării acesteia sau a unor elemente structurale sudate [6].

2. Stadiul actual al cercetărilor în domeniu și aplicații

Detectarea imperfecțiunilor de material la sudare prin utilizarea unor sisteme avansate de viziune computerizată în combinație cu sisteme de *inteligență artificială* (AI) utilizând algoritmi de *machine learning* (ML) de tip supravegheat, prezintă un interes tot mai ridicat în cadrul companiilor din sectoare de înaltă tehnologie.

În prezent se pune accent tot mai mult pe controlul în timp real a calității în industria sudării fo-

1.2 Classifications of welding execution

The SR EN ISO 5817:2023 standard [4] establishes three quality levels (B, C, and D) in relation to welding imperfections in the case of fusion welding joints of steel, nickel, titanium, and their alloys. The classification of geometric imperfections in welded joints of metallic materials in the case of fusion welding processes is done according to SR EN ISO 6520-1:2007 [5]. Ensuring the quality of welded metal structures is achieved by complying with the requirements provided in SR EN 1090-2, which consider the classification of welding works into four possible execution classes in increasing order from EXC1 to EXC4. This classification takes into account the complexity of the structure and the consequences of its failure or failure of welded structural elements [6].

2. Current stage of research and applications

Detecting welding imperfections using advanced computer vision systems combined with *artificial intelligence* (AI) systems using supervised *machine learning* (ML) algorithms is increasingly of interest to companies in the automotive industry and other high-tech industrial sectors.

There is currently a growing emphasis on real-time quality control in the welding industry using AI-

losind sisteme bazate pe AI și senzori. Când apare o imperfecțiune în timpul sudării, acesta poate fi detectată în timp real prin sisteme avansate de viziune computerizată (*machine vision*) și AI, prin monitorizarea câmpului magnetic și electric, prin analiza spectrului de radiații și monitorizarea temperaturii și emisiei acustice a arcului electric etc. Achiziționarea de date în timp real de la acești senzori (IIoT) – *Industrial Internet of Things* și printr-un control avansat al proceselor de sudare, devine posibilă corectarea în timp real a unor imperfecțiuni de sudare reducând astfel timpul și costurile de producție și inspecție [7,8].

În figura 2 este prezentat un astfel de sistem de inspecție vizuală a subansamblor sudate în fabricația de auto-vehicule la o companie mare din Germania [7, 8].

When a flaw occurs during welding, it can be detected in real-time through advanced computer vision (*machine vision*) and AI systems, by monitoring magnetic and electric fields, by analyzing the radiation spectrum, or by monitoring the temperature and acoustic emission of the electric arc etc.

Real-time data acquisition from these sensors (IIoT)-*Industrial Internet of Things*- and through advanced welding process control, it becomes possible to correct welding imperfections in real-time, thus reducing production and inspection time and costs [7,8].

Figure 2 illustrates such a visual inspection system for welded subassemblies in the automotive domain at a large company in Germany [7, 8].




Figura 2. Sistem automatizat de verificare NDE Josy 3D Weld Inspection prin triangulație laser [7,8]

Figure 2. Automated verification system NDE Josy 3D Weld Inspection through laser triangulation [7,8]

Un factor major care a condus la dezvoltarea accelerată a aplicațiilor bazate pe soluții automatizate și AI a fost și este în continuare deficitul mare de forță de muncă calificată în domeniul sudării. Potrivit Raportului EURES privind penuria și excedentele de forță de muncă, în prezent există 17 țări din UE care au un deficit de 54% de sudori profesioniști [2, 9]. Conform estimărilor Cedefop [2], pentru patru din zece locuri de muncă din UE anumite sarcini vor fi automatizate, cerând noi nevoi de competențe pentru a completa tehnologiile AI. Sondaje și studii statistice realizate de companii specializate în studii de piață, precum Statista, Edison Research, Pew Research Center, Gartner ș.a. (149 studii în total), arată evoluția și impactul AI asupra locurilor de muncă [11]:

- AI va contribui cu 15,7 trilioane de dolari la economia globală până în 2030, creștere 14%.
- AI ar putea elimina până în 2025, peste 85 de milioane de locuri de muncă. Tehnologia AI crește productivitatea companiei cu 40%. Până în 2030, roboții inteligenți ar putea înlocui 30% din forța de muncă globală, iar 375 de milioane de oameni ar putea

A major factor that has led to the accelerated development of applications based on automated solutions and AI is and continues to be the significant shortage of skilled labor in the welding field. According to the EURES Report on labor shortages and surpluses, there are currently 17 EU countries facing a 54% shortage of professional welders [2, 9].

According to Cedefop estimates [2], for every four out of ten jobs in the EU, certain tasks will be automated, requiring new skills to complement AI technologies. Surveys and statistical studies conducted by market research companies such as Statista, Edison Research, Pew Research Center, Gartner etc. (149 studies in total), show the evolution and impact of AI on jobs [11]:

- AI is expected to contribute \$15.7 trillion to the global economy by 2030, which means a 14% increase.
- AI could eliminate over 85 million jobs by 2025. AI technology increases company productivity by 40%. By 2030, intelligent robots could replace 30% of the global workforce, and 375 million people

avea nevoie să-și schimbe cariera până în 2030.

- Un risc ridicat de automatizare afectează 38% din locurile de muncă din SUA, 35% în Germania, 30% în UK și 21% în Japonia și peste 20 de mil. de locuri de muncă în producție ar putea fi pierdute până în anul 2030.

3. Sisteme avansate AI de detecție a obiectelor (YOLO)

Detectarea, identificarea și localizarea obiectelor dintr-o imagine sau un stream video este o parte importantă dintr-o serie de aplicații cum ar fi supravegherea, conducerea autonomă a mașinilor, robotica, inspecțiile vizuale, de exemplu ale îmbinărilor sudate, soluțiile de automatizare în diverse procese industriale etc.

Primele reușite în detecția obiectelor folosind AI și algoritmi *Deep Learning* a fost modelul R-CNN dezvoltat de Ross Girshick și echipa sa de la Microsoft Research în anul 2014 [12,13]. O contribuție majoră la dezvoltarea algoritmilor deep learning de detecție și clasificare a obiectelor a avut o lucrare publicată de un colectiv din University of Washington, Allen Institute for AI și Facebook AI Research, care până în prezent a fost citată în diverse cercetări de peste 45.000 de ori [14]. YOLO (You Only Look Once) propune utilizarea unei rețele neuronale care face predicții simultane despre casetele de delimitare ale obiectelor, cât și asupra probabilităților de clasă pentru care a fost antrenată rețeaua neuronală. YOLO abordează într-un mod diferit algoritmi de detecție a obiectelor față de alte versiuni similare, ceea ce a condus la o creștere a performanței algoritmului în ceea ce privește acuratețea, localizarea și clasificarea obiectelor.

Descrierea detaliată a arhitecturii algoritmului YOLO depășește obiectul lucrării de față, dar putem aminti faptul că într-o perioadă foarte scurtă de timp YOLO a fost perfecționat prin contribuția mai multor specialiști IT care au dezvoltat arhitecturi AI YOLO open-source. În figura 3 este prezentată evoluția în timp a mai multor modele AI bazate pe prima versiune YOLO [12,13]. În prezent există deja versiunea YOLO 9 [15], iar în literatura de specialitate sunt prezentate diferențele, îmbunătățirile aduse și indicatorii de performanță pentru diferite versiuni YOLO. Proiectul *Weld Visual Inspection* are ca și scop principal dezvoltarea unei arhitecturi software bazate pe AI și *deep machine learning*, figura 4, care va fi capabil să detecteze imperfecțiuni de sudare din medii diferite: piese sudate, fișiere video, camere web sau industriale, poze, rulând pe PC-uri, inclusiv pe dis-

may need to change their careers by 2030.

- High automation risk affects 38% of jobs in the USA, 35% in Germany, 30% in the UK, and 21% in Japan, with over 20 million manufacturing jobs potentially lost by 2030.

3. Advanced AI Object Detection Systems (YOLO)

Detecting, identifying, and localizing objects in an image or video stream is an important part of various applications such as surveillance, autonomous driving, robotics, visual inspections such as welded joints, automation solutions in various industrial processes etc.

The first successes in object detection using AI and *Deep Learning* algorithms came with the R-CNN model developed by Ross Girshick and his team at Microsoft Research in 2014 [12,13]. A major contribution to the development of deep learning algorithms for object detection and classification was a paper published by a collective from the University of Washington, Allen Institute for AI, and Facebook AI Research, which has been cited in various researches over 45,000 times [14]. YOLO (You Only Look Once) proposes the use of a neural network that makes simultaneous predictions about object bounding boxes and class probabilities (prediction probabilities of correctly predicting the types of objects for which the neural network has been trained). YOLO approaches object detection algorithms differently (compared to similar detection versions), which has led to improved algorithm performance in terms of accuracy, localization, and object classification.

The detailed description of the YOLO algorithm architecture exceeds the scope of this paper, but it is worth noting that in a very short period of time, YOLO has been improved by the contributions of several IT specialists who have developed open-source YOLO AI architectures. Figure 3 illustrates the evolution over time of several AI models based on the first YOLO version [12, 13]. Currently, there is already the YOLO 9 version [15], and in the specialist literature, the differences, improvements, and performance indicators for different YOLO versions are presented.

Weld Visual Inspection Project aims to develop a software architecture based on AI and *deep machine learning*, as shown in figure 4, which will be capable of detecting welding imperfections from different environments: welded parts, video files, web or industrial cameras, photos, running on PCs, including




Figura 3. Evoluția algoritmului YOLO în timp [12]

Figure 3. The evolution of the YOLO algorithm over time [12]

pozitive mobile tip smartphone sau tabletă. Nu în ultimul rând, proiectul Weld Visual Inspection va constitui o platformă de lucru colectivă pentru studenții din programele de studii Știința Materialelor și Ingineria și Protecția Mediului, care vor învăța cum să lucreze și să dezvolte noi aplicații în *computer vision* și AI.

smartphones or tablet-type mobile devices. Last but not least, the Weld Visual Inspection project will provide a collaborative working platform for students in Material Science and Environment Engineering and Protection study programs, who will learn how to work and develop new applications in *computer vision* and AI.




Figura 4. Mediul de lucru Roboflow utilizat în proiect pentru dezvoltare aplicații de computer vision

Figure 4. The Roboflow working environment used in the project for developing computer vision applications

Prima versiune a proiectului Weld Visual Inspection a utilizat o bază de date cu 155 de imagini ce conțin diferite imperfecțiuni de sudare ce pot fi detectate prin inspecție vizuală, figura 5.

The first version of the Weld Visual Inspection project used a database of 155 images containing various welding imperfections that can be detected through visual inspection, as is shown in figure 5.




Figura 5. Baza de date cu imperfecțiuni de sudare, program Weld Visual Inspection

Figure 5. Database of welding imperfections, Weld Visual Inspection program

În faza următoare de pre-procesare a imaginilor se introduc o serie de filtre de augmentare, precum rotații ($\pm 15^\circ$), saturație ($\pm 25\%$), luminozitate ($\pm 15\%$), expunere ($\pm 10\%$), zgomot de fundal, temperatură culori ($\pm 15^\circ$), rezultând un număr de 375 de imagini,

In the next preprocessing phase of the images, a series of augmentation filters are introduced, such as rotations ($\pm 15^\circ$), saturation ($\pm 25\%$), brightness ($\pm 15\%$), exposure ($\pm 10\%$), background noise, color temperature ($\pm 15^\circ$), resulting in a total of 375 im-

figura 5. Dintre acestea 330 au fost folosite pentru antrenarea rețelei neuronale, 30 pentru validare (output) și 15 imagini au fost folosite pentru testare rețea. Parametrii de performanță ai rețelei calculați pe baza celor 15 imagini de testare sunt 43.6% mAP, 79.2% precision, and 36.3% recall.



Figura 6. Detectii imperfectiuni de sudare, program Weld Visual Inspection

Figure 6. Welding imperfection detections, Weld Visual Inspection program

În figura 6 sunt ilustrate o serie de imperfecțiuni de sudare care au fost detectate cu ajutorul programului Weld Visual Inspection realizat de către autori. Fiecare clasă de imperfecțiuni detectată este încadrată cu un chenar de culori diferite, fiind prezentat și scorul de încredere pentru detectia respectivă.

4. Concluzii

1. Caracteristicile de rezistență și performanță ale îmbinărilor sudate reprezintă un aspect esențial pentru exploatarea eficientă și în siguranță a structurilor metalice sudate.
2. Detecția imperfecțiunilor de sudare cu algoritmi de AI este o metodă performantă, precisă și pretabilă pentru automatizare.
3. Proiectul Weld Visual Inspection este o arhitectură software bazată pe AI și Deep Machine Learning, care este capabil să detecteze imperfecțiuni de sudare din medii diferite: piese sudate, fișiere video, camere web sau industriale, poze.
4. Performanțele aplicației pot fi îmbunătățite prin adăugarea de noi imagini în baza de date și printr-o nouă sesiune de antrenare.

Confirmare

Mulțumim d-lui Ș.L. dr. ing. Marius Bodea pentru coordonare și sprijinul acordat în realizarea acestei lucrări.

Bibliografie/References

- [1] M. Bodea, Detection of Welding Imperfections by Using Machine Learning Algorithms, International Symposium AroEND, Mamaia, 15-17 June 2022
- [2] Edward Petzek, Radu Băncilă, Anamaria Feier, Unele observații privind aplicarea standardului SR EN-1090 în domeniul podurilor metalice de șosea și cale ferată, Archivio 2.pdf (cesol.es)
- [3] M. Bodea, New Weldability Model Based on the Welding Parameters and Hardness, Materials Research Proceedings (2018) 115-124, doi: <http://dx.doi.org/10.21741/9781945291999-13>

ages, figure 5. Out of these, 330 were used for training the neural network, 30 for validation (output), and 15 images were used for network testing. The performance parameters of the network calculated based on the 15 test images are 43.6% mAP, 79.2% precision, and 36.3% recall.

Figure 6 illustrates a series of welding imperfections that have been detected with the Weld Visual Inspection program developed by the authors. Each detected imperfection class is framed with a different color border, and the confidence score for that detection is also presented.

4. Conclusions

1. The strength and other performance characteristics of welded joints are essential for the efficient and safe operation of welded metal structures.
2. Detecting welding imperfections with AI algorithms is an efficient, accurate, and automation-suitable method.
3. The Weld Visual Inspection project is a software architecture based on AI and Deep Machine Learning, which is capable of detecting welding imperfections from different environments: welded parts, video files, web or industrial cameras, photos.
4. The app's performance can be improved by adding new images to the database and through a new training session.

Acknowledgement

We thank Mr. Ş.L. PhD. Marius Bodea for his coordination and support in the realization of this work.

- [4] M. Bodea, C. Prică, N. Sechel, Concepte noi privind sudabilitatea în Industria 4.0, Revista SUDURA Nr.3/2018.
- [5] Miller Co., Understanding the True Cost of Weld Defects, Understanding the True Cost of Weld Defects | Miller-Welds, accesat martie 2024
- [6] SR EN ISO 5817:2023. Sudare. Îmbinări sudate prin topire din oțel, nichel, titan și aliajele acestora (cu excepția sudării cu fascicule de energie). Niveluri de calitate pentru imperfecțiuni
- [7] SR EN ISO 6520-1:2007. Sudare și procedee conexe. Clasificarea imperfecțiunilor geometrice din îmbinările sudate ale materialelor metalice. Partea 1: Sudare prin topire
- [8] Josy & Co., 3D Inline Weld Inspection, SmartRay GmbH, www.smartray.com, accesat martie 2024
- [9] Metrology News, Inline 3D MAG Weld Inspection Solution for manufacturers, <https://metrology.news/inline-3d-mag-weld-inspection-solution/>, Issue June 2020
- [10] European Labour Authority, EURES Report on labour shortages and surpluses 2022, DOI 10.2883/50704, <https://www.ela.europa.eu/sites/default/files/2023-03/eures-labour-shortages-report-2022.pdf>
- [11] CEDEFOP, Centrul European pentru Dezvoltarea Formării Profesionale, Inteligența artificială sau cea umană?, Notă de informare Iunie 2019, Inteligența artificială sau cea umană? (europa.eu), accesat martie 2024
- [12] M. Bodea, Industria de sudare în EU. Actualități și perspective, Revista Sudura, Nr.1/2024, ISSN 1453-0384
- [13] Nikolaj Buhl, YOLO models for Object Detection Explained [YOLOv8 Updated], February 8, 2023 YOLOv8 for Object Detection Explained by Encord, accesat martie 2024
- [14] Rohit Kundu, YOLO: Algorithm for Object Detection Explained, January 17, 2023, YOLO Algorithm for Object Detection Explained [+Examples] (v7labs.com), accesat martie 2024
- [15] Joseph Redmon, Santosh Divvala, Ross Girshick, Ali Farhadi, University of Washington, Allen Institute for AI, Facebook AI Research, You Only Look Once: Unified, Real-Time Object Detection, [1506.02640] (arxiv.org)
- [16] Tasmia Ansari, Object Detection Gets a New Upgrade with YOLO v9, 26 Feb.2024, Object Detection Gets a New Upgrade with YOLO v9 (analyticsindiamag.com)
- [17] Everything you need to build and deploy computer vision models, Roboflow: Give your software the power to see objects in images and video

Pentru citare:

Urșan, A.L., Peter, I.-I., *Detection of welding imperfections using advanced artificial intelligence systems, Sudura, nr. 4 (2024), year XXXIV, 18-27, 10.70652/sud.2024.4.2*



Revista SUDURA Noi recunoașteri internaționale

SUDURA

EBSCO

Demersurile începute în urmă cu doi ani pentru creșterea vizibilității revistei SUDURA au cunoscut mai multe succese.

În luna ianuarie 2023 revista SUDURA a fost acceptată în baza de date Elton B. Stephens Company (EBSCO) la secțiunile Applied Science & Technology Source Ultimate (EBSCO) și Central & Eastern European Academic Source- CEEAS (EBSCO).

Demersurile au continuat, iar începând cu 19 august 2024 revista SUDURA este listată în cadrul Information Matrix for the Analysis of Journals, MIAR organizată de Universitat de Barcelona.



Începând cu 3 iunie 2024 s-a solicitat un audit din partea bazei de date SCOPUS, auditul fiind încă în derulare.

Un audit similar este derulat și de baza de date ProQuest, începând din septembrie 2024.



Un important proces finalizat cu succes a fost introducerea revistei SUDURA în baza de date CrossRef. Începând cu 22 octombrie SUDURA este membră a acestei baze de date și a primit dreptul de conferi începând cu



28 noiembrie 2024 coduri DOI (Digital Object Identifier) articolelor pe care le publică.

Acordarea codurilor DOI se face prin intermediul Bibliotecii Centrale Universitare „Lucian Blaga” din Cluj-Napoca, Partener al CrossRef.

În cazul revistei SUDURA codurile DOI vor avea formatul 10.70652/SUD.ANUL.VOLUM.NRAR-TICOL și vor fi pentru prima dată asigurate articolelor din numărul 4/2024.

