

Metoda detekcji wad spawalniczych w stanowisku zrobotyzowanym z wykorzystaniem głębokiej sieci neuronowej

Arkadiusz Adamczak

Instytut Technologii Informatycznych, ul. Sienkiewicza 9, 90-113 Łódź

Streszczenie: Współczesna automatyzacja i robotyzacja procesów produkcyjnych wymaga nowych i szybkich metod kontroli jakości produktu. W przypadku spawania łukowego w systemach zrobotyzowanych, gdzie proces produkcyjny przebiega wielkoseryjnie istotną rzeczą jest szybka kontrola poprawności wykonanego spawu. System w oparciu o dane wizualne powinien być zdolny automatycznie określić czy dana spoina spełnia podstawowe wymagania jakościowe a tym samym mieć możliwość zatrzymania procesu w razie zidentyfikowanych wad. W artykule przedstawiono wyniki badań nad stworzeniem wizyjnej metody oceny poprawności wykonanej spoiny w oparciu o głęboką sieć neuronową klasyfikującą, lokalizującą i segmentującą wady spawalnicze. Zaproponowana metoda detekcji została rozbudowana przez zastosowanie połączenia kamery systemu wizyjnego z sześcioksiowym robotem przemysłowym w celu umożliwienia detekcji większej liczby wad spawalniczych oraz pozycjonowania w sześciowymiarowej przestrzeni pracy. Przedstawione w artykule wyniki prac badawczych otrzymano podczas realizacji projektu „Opracowanie metody bazującej na zastosowaniu głębokich sieci neuronowych do inspekcji wizyjnej połączeń spawanych w toku prac B+R” realizowanego w zakładzie ZAP-Robotyka Sp. z o.o. w Ostrowie Wielkopolskim.

Słowa kluczowe: głębokie uczenie maszynowe, Przemysł 4.0, stanowisko zrobotyzowane, detekcja wad spoin

1. Wprowadzenie

Zarządzanie jakością jest podstawowym elementem procesu produkcyjnego [1]. Procesy spawalnicze mogą powodować wady w produkcji, które są szkodliwe dla jakości produktu końcowego [2]. Kontrola wizualna jest jednym z pierwszych i obowiązkowych badań poprawności wykonanego połączenia spawalniczego zaliczanego do badań nieniszczących [3]. Najczęstszą metodą sprawdzania poprawności wykonanego połączenia spawanego jest ocena wizualna dokonywana przez człowieka, która jest oceną kosztowną ze względu na czas inspekcji. Coraz większe wymagania jakościowe połączone z ograniczeniami czasowymi skłaniają do zastosowania automatycznego, wizyjnego systemu kontroli, szczególnie dla procesów produkcyjnych wielkoseryjnych, gdzie kontrola wizualna

pozwala na wykrycie wady na wczesnym etapie produkcyjnym [4]. Rozwiązania stosowane w przemyśle w dziedzinie komputerowego rozpoznawania obrazów nie mogą zostać w pełni wykorzystane do detekcji defektów spawalniczych. Powodem tego jest dowolność położenia tych wad i niezgodności na powierzchni spoiny oraz bardzo duża ilość możliwych kształtów i barw powstałych defektów. W produkcji wielkoseryjnej niewymagającej badań penetracyjnych spoin, wizualna kontrola spoiny jest podstawową metodą badania poprawności złącza spawanego. Każdy element musi zostać poddany ocenie przez pracownika, co równocześnie zwiększa czas i koszty produkcji. Aby przyspieszyć proces i obniżyć koszty na tym etapie produkcji konieczne jest wyeliminowanie czynnika ludzkiego poprzez wprowadzenie systemu wizyjnego kontroli jakości. Oprócz samej kontroli jakościowej produktu istotnym rzeczą jest odpowiednie szybkie zatrzymanie zrobotyzowanej produkcji wielkoseryjnej w celu niedopuszczenia do zniszczenia kolejnych detali poddawanych procesowi spajania. Jednym z perspektywicznych obszarów w dziedzinie rozpoznawania wad spawalniczych jest zastosowanie metod z dziedziny sztucznej inteligencji, bazujących na głębokim uczeniu maszynowym. Podjęto próbę stworzenia systemu opartego na głębokich sieciach neuronowych do wykrywania defektów spawalniczych zlokalizowanych losowo na powierzchni spoiny z wykorzystaniem

Autor korespondujący:

Arkadiusz Adamczak, aadamczak@san.edu.pl

Artykuł recenzowany

nadesłany 16.01.2021 r., przyjęty do druku 04.03.2021 r.



Zezwala się na korzystanie z artykułu na warunkach licencji Creative Commons Uznanie autorstwa 3.0

urządzenia manipulacyjnego, jakim jest robot przemysłowy. W wyniku badań zastosowany został model sieci neuronowej posiadającej jedno wejście i trzy wyjścia systemowe, umożliwiające w jednym czasie klasyfikować, segmentować i lokalizować dane obrazowe odwzorowując jednocześnie te wartości na układ współrzędnych robota przemysłowego. Uniwersalność systemu pozwala na zastosowanie go do badania połączeń spawanych wykorzystując zdjęcia rentgenowskie [5] spoin i z powodzeniem może zostać wdrożony w proces produkcyjny zastępując urządzeniem mogąącym takie zdjęcia wykonać po wcześniejszym przeprowadzeniu dostrojenia sieci neuronowej dla nowych danych.

2. Zbiór danych i oznaczenie wad spawalniczych

Baza danych zdjęć stanowiących dane wejściowe dla systemu została sporządzona na podstawie prób spawalniczych wykonanych w wewnętrznym laboratorium na specjalnie do tego celu przygotowanym i skonfigurowanym stanowisku zrobotyzowanym, w skład którego wchodził:

- robot przemysłowy Fanuc ArcMate 120iD,
- inwertorowe spawalnicze źródło zasilające ze sterowaniem synergicznym Fronius TPS 500i CMT,
- oprzyrządowanie potrzebne do powtarzalnego zamontowania próbek na stole pozycjonera.


Zastosowanie robota oraz połączonego z nim sygnałowo inwertorowego źródła ze sterowaniem synergicznym podyktowane było potrzebą zapewnienia stabilności i powtarzalności warunków prowadzenia prób, zarówno na etapie tworzenia danych wejściowych (generowania niezgodności), jak i badań z wykorzystaniem tworzonego systemu ich rozpoznawania. Konfiguracja robota spawalniczego wraz ze źródłem spawalniczym sterowanym synergicznie jest połączeniem często występującym podczas implementacji stanowisk zrobotyzowanych spawania łukowego metodami MIG/MAG. Reprezentatywne wady spoin zostały sfotografowane a następnie zmniejszone do rozdzielczości 600×600 pikseli oraz 500×500 pikseli i podzielone na pięć podzbiorów przedstawionych w tabeli 1.

Każde zdjęcie zostało oznaczone za pomocą narzędzia do adnotacji zdjęć VGG Image Annotator [6] (rys 1), gdzie zdefiniowano regiony defektów na obrazach.

Wszystkie wady spawalnicze oznaczone na obrazie zostały przypisane do danej klasy wadliwości i wyeksportowane do pliku tekstowego w formacie JSON (ang. *JavaScript Object Notation*). Następnie w programie zostały na ich podstawie wygenerowane dane wyjściowe dla systemu sieci neuronowej w postaci klasy, maski i współrzędnych położenia defektu spawalniczego. Całość systemu została zaimplementowana z wykorzystaniem bibliotek Tensorflow [9] oraz Keras [10] i języka programowania Python.

Augmentacja danych

Dane uczące odpowiednio zostały zmodyfikowane stosując własne techniki augmentacji takie jak losowe: przycinanie,



Rys. 1. Oznaczenie zdjęć przy wykorzystaniu narzędzia VGG Image Annotator, a) rozpryski, b) pory powierzchniowe z rozpryskami, c) przepalenie i krater, d) nieregularne lico

Fig. 1. Images using the VGG Image Annotator tool, a) splashes, b) surface pores with splashes, c) burn and crater, d) irregular face

odwracanie wertykalne i horyzontalne, zmiana jasności i kontrastu. Powodem dodatkowej augmentacji danych jest mała liczba zdjęć w stosunku do dużej głębokości sieci neuronowej. Wykonanie prób w wykorzystaniem tego typu augmentacji jest dostosowanie systemu do rzeczywistego stanowiska zrobotyzowanego, gdzie w warunkach przemysłowych często występują zakłócenia wynikające ze zmiennego oświetlenia oraz niewystarczająca ilość danych treningowych dla sieci w trakcie wdrożenia systemu zrobotyzowanego.

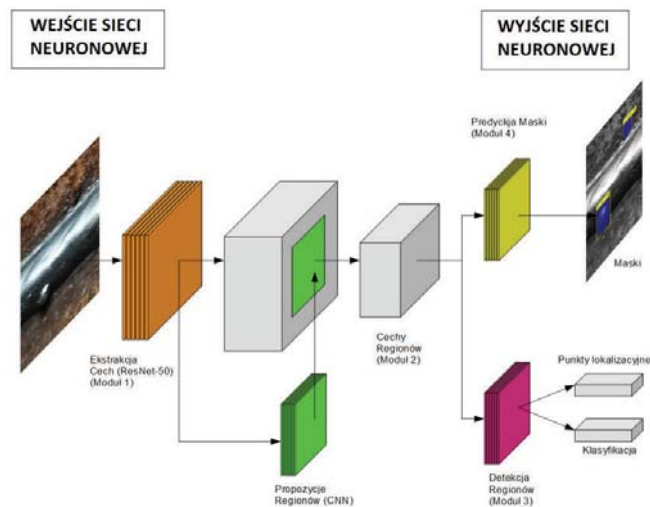
Tabela 1. Zbiór danych zdjęć z oznaczonymi wadami spoin

Table 1. Data set of photos with marked weld defects

	Zbiór treningowy	Zbiór walidacyjny	Zbiór testowy	Oznaczenie klasy
Spoiny z pęcherzami gazowymi lub porami powierzchniowymi	320	100	50	1
Spoiny przepalone	293	78	50	2
Spoiny z rozpryskami	340	134	50	3
Spoiny z nieregularnością spoiny	230	89	50	4
Krater	34	12	4	5

3. Architektura i trening głębokiej sieci neuronowej

Przeprowadzono badania nad zastosowaniem systemu rozpoznawania defektów spawalniczych z wykorzystaniem głębokich konwolucyjnych sieci neuronowych [9]. Badania miały na celu zaproponowanie systemu neuronowego mogącego oprócz samej klasyfikacji wad spawalniczych wykonać ich segmentację i lokalizację na obrazie w celu określenia stopnia wadliwości detalu na podstawie tego defektu wraz z określeniem jego pozycji. Zaproponowano system oparty o architekturę głębokiej sieci neuronowej Mask R-CNN [10]. Założeniem proponowanego systemu było jednoczesne wykrywanie i segmentowanie defektów spawalniczych na poziomie instancji aby następnie przy odpowiedniej kalibracji kamery lokalizować je w sześciowymiarowej przestrzeni pracy R^6 robota. Wybór systemu spowodowany był wynikami działania sieci Mask R-CNN [10] z dziedziny rozpoznawania i segmentacji instancji obiektów na obrazach osiągniętego przez tą sieć. Zaproponowany system zobrazowany został w sposób poglądowy na schemacie (rys. 2). System składa się z czterech głównych modułów. Każdy z modułów odpowiadający za konkretne zadanie został opisany w dalszej części artykułu.



Rys. 2. Schemat systemu neuronowego detekcji wad spawalniczych oparty o architekturę Mask-RCNN

Fig. 2. Scheme of the neural system for the detection of welding defects based on the Mask-RCNN architecture

Moduł 1 odpowiada za ekstrakcję cech przekształcając piksele obrazu w funkcjonalną reprezentację wysokiego poziomu. Wykorzystano do tego celu ekstraktor cech ResNet [11] wykorzystujący połączenie rezydualne.

Moduł 2 jest to sieć konwolucyjna propozycji regionów, która przyjmując mapę cech o dowolnym wymiarze jako daną wejściową wyodrębnia zestaw propozycji miejsc w postaci obiektów prostokątnych, z których każdy zawiera prawdopodobieństwo, że ten region zawiera obiekt, w naszym przypadku wadę spoiny.

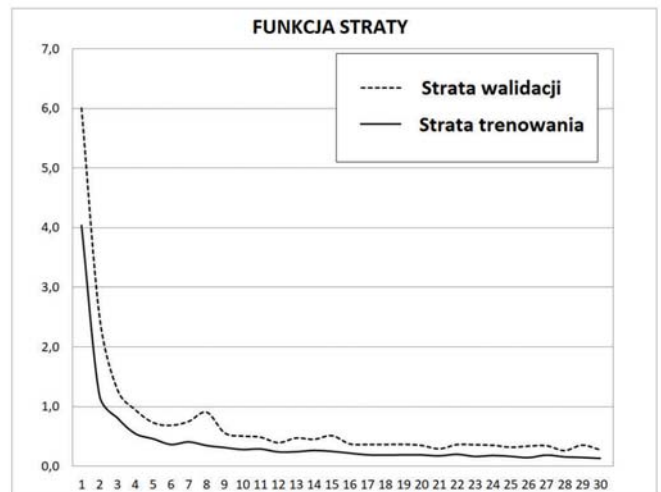
Moduł 3 służy do detekcji wad spawalniczych. Koncepcja detektora jest oparta na szybkiej sieci wykrywania obiektów Faster R-CNN [12]. Sieć generuje dwa wektory wyjściowe. Jeden odpowiada za oszacowanie prawdopodobieństwa przynależności danej wady spawalniczej do jednej z N klas. Natomiast drugi zwraca pozycję ramki w postaci dwóch punktów ograniczającej daną wadę z N klas.

Moduł 4 dla każdego regionu generuje przewidywaną maskę. Przewidywanie maski wykonywane jest przez inną sieć konwolucyjną nazwaną siecią segmentacji instancji. Sieć segmentacji instancji ma wyjściowy wymiar 28×28 pikseli dla każdego

regionu propozycji, który koduje N masek binarnych o rozdzielczości 28×28 pikseli, po jednej dla każdej z N klas.

Uczenie sieci neuronowej

Uczenie modelu systemu neuronowego przeprowadzono na komputerze z procesorem CPU Intel Core i7-9750H, 32 GB pamięci RAM i pojedynczym procesorze graficznym GPU model NVIDIA GeForce RTX 2060 6 GB RAM. Uczenie przebiegło w sposób analogiczny do uczenia innych nowoczesnych sieci neuronowych. Dążono do minimalizacji wartości błędu na wyjściu sieci będącego sumą błędów z poszczególnych wyjść systemowych sieci neuronowej takich jak maska, klasa, region.



Rys. 3. Wartość błędów podczas procesu uczenia będący sumaryczną wartością błędów poszczególnych wyjść

Fig. 3. The error value during the learning process, which is the total error value of individual outputs

Wykonane obrazy zostały również przeskalowane do wartości 500×500 pikseli, aby zmniejszyć czas i wymagania procesu uczenia systemu. Użyto ekstraktora cech ResNet-50 [11]. Proces uczenia wykonano dla 50 % zdjęć zbioru treningowego dla wszystkich warstw sieci neuronowej przez 50 epok, a następnie douczano przez kolejne 30 epok dla kolejnych 50 % zdjęć zbioru treningowego. Uzyskano skuteczność na poziomie 93,7 % rozpoznawanych defektów. Wykorzystując techniki uczenia transferowego, skorzystano ze wstępnie nauczonej sieci na dużym zestawie danych COCO [13]. Wykorzystanie wstępnie nauczonej sieci na dużym zbiorze danych pozwoliło na zmniejszenie czasu uczenia oraz poprawienie skuteczności rozpoznawania wzorców na obrazie. W dalszej części uczenia systemu dostrajano na zbiorze treningowym danych końcowe cztery dolne warstwy sieci neuronowej zamrażając oprócz nich wszystkie pozostałe przez 30 epok (rys. 3). Technika ta pozwoliła polepszyć o 1,6% skuteczność rozpoznawania defektów niż poprzez ponowne uczenie wszystkich warstw sieci neuronowej aby ostatecznie uzyskać wynik 95,3 % skuteczności.

4. Transformacje układów współrzędnych w celu pozycjonowania defektu wady na obrazie w sześciowymiarowej przestrzeni pracy robota

Większą stabilność systemu rozpoznawania defektów spawalniczych osiągnięto przez zastosowanie urządzenia manipulacyjnego w postaci sześciooosiowego szeregowego robota przemysłowego. Wykonano definicję dwóch narzędzi (palmika, kamery) oraz zdefiniowano układ współrzędnych użytkownika.

Definicja narzędzia pozwoliła jednoznacznie określić punkt $P[x, y, z, w, p, r]$ będący punktem środkowym narzędzia w sześciowymiarowej przestrzeni R^6 pracy robota. Zostały zdefiniowane punkty środkowe narzędzi zwane TCP (ang. *Tool Center Point*) odpowiednio dla narzędzia palnika i narzędzia kamery. Zaprogramowana trajektoria ruchu robota przemysłowego, którą podąża punkt TCP narzędzia palnika została wykorzystana do inspekcji wizyjnej przez kamerę bez konieczności programowania nowych punktów robota. Umożliwiła to automatyczna zmiana wartości definicji narzędzia w trakcie wykonywania programu robota przemysłowego [5]. Poglądowy algorytm działania zamiany wartości definicji narzędzia został przedstawiony na rys. 4.

Oprócz samej zamiany definicji narzędzia i otrzymaniu aktualnej pozycji w globalnym układzie współrzędnych kartezjańskich robota przemysłowego, przeliczono ją na wartość w nowo zdefiniowanym układzie współrzędnych użytkownika. Wykonano w tym celu operację pobrania aktualnych wartości punktu TCP (palnika lub kamery) w globalnym układzie współrzędnych robota przemysłowego oraz transformację do układu współrzędnych użytkownika. Na rys. 5 przedstawiono położenie układów współrzędnych w przestrzeni pracy robota przemysłowego. Przekształcenia pozwoliły na wyznaczenie wartości punktu TCP w układzie współrzędnych użytkownika i transformację na narzędzie kamery a następnie podanie wektora pozycji defektu w sześciowymiarowym układzie R^6 układu współrzędnych użytkownika na podstawie zdjęcia w przestrzeni dwuwymiarowej R^2 . Tak przeliczone dane pozycji defektu lub obiektu na obrazie mogą zostać wykorzystane do określenia dokładnej pozycji przez robota. Ma to znaczenie, gdy system zostanie użyty do raportowania błędów, określenia dokładnych rozmiarów defektu spawalniczego lub dla aplikacji gdzie zamiast defektu rozpoznawany jest detal, który następnie musi zostać odpowiednio pozycjonowany dla robota.

Zaletą zastosowania tego typu przekształceń była możliwość pozycjonowania elementów poddawanych inspekcji wizyjnej w przestrzeni pracy robota z dowolnym zdefiniowanym układem współrzędnych użytkownika. Pozwoliło to na jednoznaczną identyfikację pozycji defektów zapisanych w układzie współrzędnych użytkownika, co ma znaczenie przy określaniu pozycji robota

w połączeniu z urządzeniami pozycjonującymi o większej liczby osi skrętnych działających w ruchu skoordynowanym z robotem. Metoda pozwala na zastosowanie do pozycjonerów wieloosiowych w procesie spawania, na których jest zdefiniowany układ współrzędnych poruszający się zgodnie z kinematyką pozycjonera i bezpośrednim określeniu pozycji detalu w przestrzeni pracy robota.

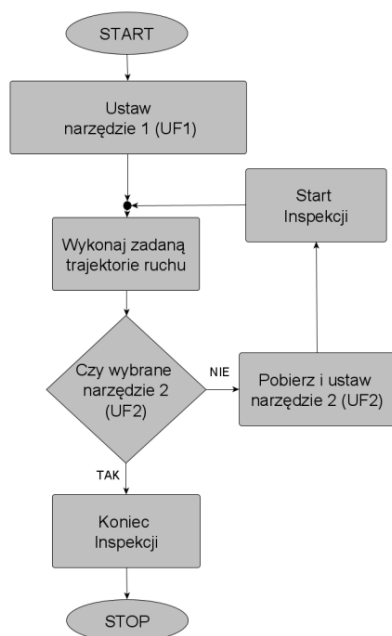
5. Rezultaty

Wynikiem działania systemu opartego o głęboką sieć neuronową jest informacja na podstawie wykonanego zdjęcia w postaci trzech danych wyjściowych:

- segmentacja wady spoiny na obrazie
 - maska o wymiarach $H \times W$,
- lokalizacja wady spoiny na obrazie
 - punkty $P_1(x_1, y_1)$, $P_2(x_2, y_2)$,
- klasyfikacja wady spoiny na obrazie – $h: X \rightarrow Y$; gdzie $Y \in 1, \dots, n$.


Dzięki zastosowaniu segmentacji instancji wady spawalniczej zostały oznaczone wszystkie wady występują na obrazie i na podstawie nałożenia wygenerowanej maski na obraz wejściowy spoiny. Jednoznaczna lokalizacja, rozmiar i rodzaj defektu spawalniczego umożliwiły ocenę czy dana spoina spełnia założone wymogi jakościowe. System na danych testowych osiągnął dokładność rozpoznawania spoin na poziomie 95,3 %. Przykładowe rezultaty będące wynikiem działania systemu zostały przedstawione w tabeli 2. Można tu zobaczyć efekt działania systemu w postaci zdjęć z oznaczonymi, zlokalizowanymi i sklasyfikowanymi wadami spoin na obrazie dla zbioru danych testowych.

Zastosowanie urządzenia manipulacyjnego pozwoliło na zwiększenie skuteczności rozpoznawania defektów poprzez mniejszy wpływ zakłóceń na jednostkowe zdjęcie w warunkach przemysłowych a także możliwość wykonania większej liczby zdjęć przez zmianę położenia kamery w trakcie ruchu. Zastosowanie urządzenia manipulacyjnego umożliwiło również pozycjonowanie defektu w sześciowymiarowej przestrzeni pracy robota przemysłowego. Jest to niezbędne do określenia dokładnego położenia defektu spawalniczego oraz określenia jego wielkości, gdy wymagane jest zaklasyfikowanie detalu jako dobrego lub wadliwego. Dzięki kali-



Rys. 4. Algorytm zamiany wartości definicji narzędzia


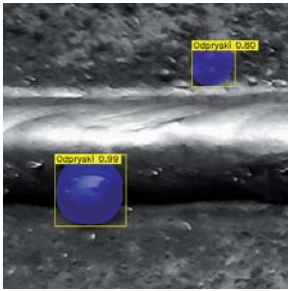

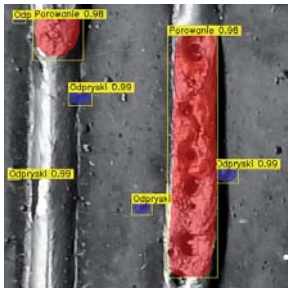

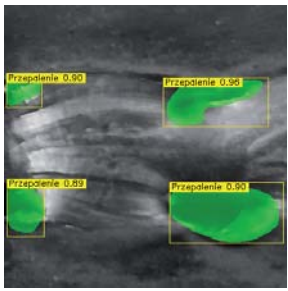
Fig. 4. Algorithm for replacing the tool definition value



Rys. 5. Układy współrzędnych robota przemysłowego: 1 – Robot przemysłowy, 2 – kamera, 3 – palnik spawalniczy, WORLD – globalny układ współrzędnych, UF – układ współrzędnych użytkownika, UT1 – układ współrzędnych narzędzia palnika, UT2 – układ współrzędnych kamery

Fig. 5. Coordinate systems of an industrial robot: 1 – industrial robot, 2 – camera, 3 – welding torch, WORLD – global coordinate system, UF – user coordinate system, UT1 – user tool torch coordinate system, UT2 – user tool camera coordinate system

Tabela 2. Wyniki działania systemu wykrywania wad spawalniczych
 Table 2. The results of the operation of the welding deflection system

Opis wady	Zdjęcie wejściowe	Wynik działania systemu
Widoczne odpryski na powierzchni spoiny		
Pory powierzchniowe spowodowane niewystarczającą ilością lub brakiem gazu osłonowego		
Przepalenia materiału spawanego		

bracji kamery i parametryzacji systemu detekcji, możliwe było zdefiniowanie progów wadliwości elementu, przy których detal był uznawany jako wadliwy.

System detekcji wizyjnej wraz robotem przemysłowym po wykonaniu inspekcji spoiny zwraca informację o:

- rodzajach wad – $h: X \rightarrow Y$; gdzie $Y \in 1, \dots, n$.
- lokalizacji wad na spoinie w przestrzeni R^6 pracy robota – punkty $P_1(x_1, y_1, z_1, w_1, p_1, r_1)$, $P_2(x_2, y_2, z_2, w_2, p_2, r_2)$ dla każdego rozpoznanego defektu, gdzie:
 - x, y, z – są wartościami położenia defektu w przestrzeni kartezjańskiej R^3 wyrażonymi w milimetrach (mm),
 - w, p, r – są wartościami orientacji narzędzia względem spoiny wyrażonymi w stopniach (deg);
- wartości procentowej wad spoin na podstawie wyliczenia liczby pikseli maski w stosunku do liczby pikseli całej spoiny,
- zdjęcie wykonanej inspekcji wraz z nałożonymi maskami wad spoin w celu archiwizacji i diagnostyki skuteczności detekcji.

Czas inspekcji wizyjnej wraz z czasem potrzebnym na zwrócenie wyników mieści się granicach 0,4–0,7 sekundy dla GPU 6 GB pamięci RAM, co w warunkach przemysłowych jest parametrem istotnym ze względu na wymogi czasowe aplikacji.

6. Podsumowanie

Zaprezentowana w artykule metoda rozpoznawania wad spawalniczych bazująca na głębokich konwolucyjnych sieciach neuronowych daje nowe możliwości w dziedzinie klasyfikacji wad spawalniczych na podstawie danych obrazowych spoin. Przedstawiona w pracy technika jednoczesnej klasyfikacji, segmentacji i lokalizacji wraz z zastosowaniem uczenia transferowego

pozwoły na uzyskanie skuteczności rozpoznawania wad spawalniczych na poziomie 0,953. Zastosowanie systemu neuronowego wraz z robotem przemysłowym umożliwiło ustalenie jednoznacznej pozycji wady spoiny w sześciowymiarowej przestrzeni pracy. Na podstawie wyników badań można stwierdzić, że z zastosowaniem sieci konwolucyjnych należy wiązać duże nadzieje w dziedzinie automatycznego rozpoznawania wad spawalniczych w stanowiskach zrobotyzowanych i zautomatyzowanych. Przewidywane jest kontynuowanie badań nad ulepszeniem oraz zastosowaniem nowych modeli sieci, które będą mogły osiągać lepszą skuteczność niż dotychczas badane. Istotnym czynnikiem wpływającym na skuteczność rozpoznawania będzie zgromadzenie większych ilości danych w postaci zdjęć wadliwych spoin. Równoczesne badania nad nowymi konstrukcjami głębokich sieci konwolucyjnych pozwolą na bardziej szczegółowe rozpoznawanie defektów innych wad takich jak podtopienia lub nieprawidłowe mieszanki gazu osłonowego. Ulepszony w ten sposób system

będzie mógł być z powodzeniem wdrożony dla każdego rodzaju aplikacji spawalniczej i eliminować wadliwe połączenia spawane, których wady są możliwe do rozpoznania za pomocą percepcji wzrokowej. Zastosowana metoda klasyfikacji, lokalizacji i segmentacji wady spawalniczej w połączeniu z kinematyką robota przemysłowego, może z powodzeniem zostać wykorzystana nie tylko do rozpoznawania defektów spawalniczych, lecz do rozpoznawania detali i odpowiedniego ich lokalizowania w przestrzeni pracy robota przemysłowego, znajdując zastosowanie w systemach paletyzacji zrobotyzowanej.

Podziękowanie

Praca zrealizowana została w ramach projektu nr RPWP.01.02.00-30-0084/19, B+R

Bibliografia

- The future of manufacturing: 2020 and beyond*, [www.nist.gov/system/files/documents/2016/11/16/iw_kronos_research_report_2016.pdf]
- Cegielski P., Bugyi Ł., *Wybrane aspekty identyfikacji zakłóceń procesu spawania łukowego MIG/MAG*, „Przegląd spawalnictwa”, R. 89, Nr 6, 2017, 30–35.
- Raj B., Subramanian C.V., Jayakumar T., *Non-destructive testing of welds*. 2000.
- Ghorai S., Mukherjee A., Gangadaran M., Dutta P.K., *Automatic defect detection on hot-rolled flat steel products*, “IEEE Transactions on Instrumentation and Measurement”, Vol. 62, No. 3, 2013, 612–621, DOI: 10.1109/TIM.2012.2218677.
- Guo W., Qu H., Liang L., *WDXI: The Dataset of X-Ray Image for Weld Defects*, 14th International Conference on

- Natural Computation, Fuzzy Systems and Knowledge Discovery (ICNC-FSKD), Huangshan, China, 2018, 1051–1055, DOI: 10.1109/FSKD.2018.8686975.
6. Dutta A., Zisserman A., *The VIA annotation software for images, audio and video*. Proceedings of the 27th ACM International Conference on Multimedia, 2019, DOI: 10.1145/3343031.3350535.
 7. Abadi M., et al., *Tensorflow: A system for large-scale machine learning*. 12th USENIX symposium on operating systems design and implementation (OSDI 16), 2016, 265–283.
 8. Chollet F., et al., *Keras: The python deep learning library*. Astrophysics Source Code Library, 2018, ascl: 1806.022.
 9. O’Shea K., Nash R., *An Introduction to Convolutional Neural Networks*, arXiv:1511.08458v2.
 10. He K., Gkioxari G., Dollr P., Girshick R., *Mask R-CNN*, arXiv:1703.06870.
 11. He K., Zhang X., Ren S., Sun J., *Deep Residual Learning for Image Recognition*, Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016, 770–778, DOI: 10.1109/CVPR.2016.90.
 12. Ren S., He K., Girshick R., Sun J., *Faster R-CNN: Towards real-time object detection with region proposal networks*, Advances in Neural Information Processing Systems (NIPS 2015), 91–99.
 13. Lin T.Y., et al., *Microsoft COCO: Common Objects in Context*. In: Fleet D., Pajdla T., Schiele B., Tuytelaars T. (eds) Computer Vision – ECCV 2014. Lecture Notes in Computer Science, Vol. 8693. Springer, Cham. DOI: 10.1007/978-3-319-10602-1_48.

Detection Method of Welding Defects in a Robotic Station Using the Deep Neural Network

Abstract: Modern automation and robotization of production processes requires new and fast methods of product quality control. In the case of arc welding in robotic systems, where the production process takes place in large series, it is important to quickly control the correctness of the weld. Based on visual data, the system should be able to automatically determine whether a given weld meets the basic quality requirements, and thus be able to stop the process in the event of identified defects. The article presents the results of research on the creation of a visual method for assessing the correctness of the weld seam based on the deep neural network classifying, locating and segmenting welding defects. The proposed detection method was extended by using a combination of a vision system camera with a six-axis industrial robot in order to enable detection of a larger number of welding defects and positioning in a six-dimensional workspace. The research results presented in this article were obtained during the implementation of the project entitled „Development of a method based on the use of deep neural networks for visual inspection of welded joints in the course of R&D works” implemented at the company ZAP-Robotyka Sp. z o.o. in Ostrów Wielkopolski.

Keywords: Deep Learning, Industry 4.0, Robotic station, Detection of weld defects

mgr inż. Arkadiusz Adamczak

aadamczak@san.edu.pl

ORCID: 0000-0002-3840-8568



Absolwent Politechniki Łódzkiej kierunku Informatyka o specjalnościach Mechatronika oraz Inteligentne Systemy Baz Danych. Tytuł inżyniera uzyskał w 2008 r., tytuł magistra w 2010 r. W 2011 r. rozpoczął pracę jako programista w firmie ZAP-Robotyka w zakresie systemów automatyki, robotyki, baz danych i sztucznej inteligencji. Od 2017 r. jest również nauczycielem akademickim w Społecznej Akademii Nauk w zakresie przedmiotów informatycznych. Główne zainteresowania naukowe to: sztuczna inteligencja, deep learning, systemy baz danych, automatyka i robotyka.