

# Głębokie sieci rekurencyjne i konwolucyjne w detekcji wad spawalniczych dla systemów z robotem przemysłowym

Arkadiusz Adamczak

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

**Streszczenie:** Podczas procesów spawania metodą MIG/MAG w produkcji wielkoseryjnej na stanowiskach zrobotyzowanych, często wymagana jest automatyczna kontrola jakości wykonanego spawu. Określanie defektów spawalniczych jest trudne, a powód ich wystąpienia nie zawsze jest znany. Jednym z warunków poprawnie wykonanej spoiny jest stabilność podczas procesu spawania, co przekłada się na ciągłość i zwiększenie ogólnej wydajności produkcji. W artykule przedstawiono wyniki badań nad systemem detekcji defektów spoiny łączącego analizę i klasyfikację szeregów czasowych parametrów spawania dla metody MIG/MAG wraz z równoczesną analizą i klasyfikacją danych obrazowych spoiny dla systemów zrobotyzowanych. Wykorzystane zostały konstrukcje głębokich sieci neuronowych rekurencyjnych i konwolucyjnych. Przedstawiono również konstrukcję sieci neuronowej zawierającej dwa wejścia systemowe, umożliwiającej w jednym czasie klasyfikację zdjęcia spoiny wraz z szeregiem czasowym dla zastosowania w stanowisku zrobotyzowanym. Przedstawione 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” finansowanego z Wielkopolskiego Regionalnego Programu Operacyjnego na lata 2014–2020 i realizowanego w zakładzie ZAP-Robotyka Sp. z o.o. w Ostrowie Wielkopolskim.

**Słowa kluczowe:** głębokie uczenie maszynowe, szeregi czasowe, stanowisko zrobotyzowane, detekcja wad spoin

## 1. Wprowadzenie

Główną przyczyną zastosowania uczenia maszynowego w rozpoznawaniu defektów spawalniczych był brak możliwości jednoznacznej zalgorytmizacji wady spawalniczej za pomocą modelu matematycznego. Zastosowanie głębokich sieci neuronowych w detekcji obrazowej, jak i w rozpoznawaniu wzorców występujących w przebiegach czasowych parametrów spawania, dało nowe możliwości. Zaproponowano koncepcję systemu neuronowego umożliwiającego kontrolę wizyjną wykonanej spoiny oraz analizę oscylogramów parametrów spawania, zwanych dalej szeregami czasowymi, po procesie spawania. Równoczesne zastosowanie głębokich sieci neuronowych do analizy obrazu i szeregów czasowych pozwoliło zwiększyć prawdopodobieństwo rozpoznania defektu spawalniczego mogącego wynikać z niestabilności procesu spawania i tym samym wykonać ocenę

połączenia spawanego w odniesieniu do wymaganych założeń. Przedstawiono modele sieci rekurencyjnych i sieci konwolucyjnych 1D do klasyfikacji szeregów czasowych oraz modele sieci konwolucyjnych 2D [1] do klasyfikacji zdjęć spoin. Zaproponowany został klasyfikator oparty na modelu sieci neuronowej, złożony z dwóch wejść systemowych – zdjęcia wraz z szeregiem czasowym. Wykorzystane zostały również techniki składania kilku modeli uczonych na tych samych danych, co w drodze prób zwiększyło prawdopodobieństwo rozpoznania defektu spoiny. W ramach prowadzonych prac badawczo-rozwojowych, zamysłem była integracja systemu neuronowego z systemem robota przemysłowego. Opracowane modele głębokich sieci neuronowych umożliwiających detekcję wady spawalniczej na podstawie szeregu czasowego oraz na podstawie obrazu połączono w jeden system wykorzystujący kontroler robota przemysłowego jako jednostkę sterującą. Podczas prób nad wizualizacją wad spawalniczych na obrazie, skorzystano z map ciepła aktywacji klas (ang. *Map CAM*) [2], jednej z technik wizualizacji używanej do określenia części obrazu, na podstawie którego sieć neuronowa podejmuje decyzję o zaklasyfikowaniu wady spawalniczej do danej klasy, a tym samym pokazującego określony wzorzec. Została ona wykorzystana jako istotne narzędzie do badania poprawności działania sieci w procesie uczenia, gdyż obrazowanie procesu klasyfikacji pozwalało przyjrzeć się, jakimi kryteriami sieć neuronowa sugerowała się podejmując decyzję, a jakimi sugerowała się w przypadku błędnej klasyfikacji. Tym samym technika pozwoliła na wery-

### Autor korespondujący:

Arkadiusz Adamczak, aadamczak@san.edu.pl

### Artykuł recenzowany

nadesłany 31.05.2021 r., przyjęty do druku 23.06.2021 r.



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

fikację poprawności działania sieci neuronowej. Przedstawiony system może zostać wykorzystany do szerokiej gamy zrobotyzowanych stanowisk spawalniczych korzystających z metod spawania łukowego MIG/MAG.

## 2. Zbiór danych spawalniczych

Zbiór danych został stworzony na podstawie prób laboratoryjnych z wykorzystaniem robota przemysłowego Fanuc Arc Mate 100iD oraz zintegrowanego z nim synergicznego źródła spawalniczego firmy Fronius TPS 500i CMT. Podczas wykonywania prób zbierane były przebiegi czasowe parametrów spawalniczych przez dedykowane oprogramowanie firmy Fronius – WeldCube, które zapisywało rezultaty w plikach CSV (ang. *comma-separated values*). Zebrane dane przedstawiały wartości parametrów w czasie, takich jak prąd, napięcie, wysuw drutu. Przykładowy przebieg został przedstawiony na rys. 1.

Dla każdej spoiny zostały wykonane zdjęcia, które stanowiły drugą daną wejściową dla systemu detekcji wad spawalniczych. Zdjęcia zostały przetworzone do rozdzielczości 500 px × 500 px i następnie podzielone na zbiory: treningowy, walidacyjny i testowy. Każdy zbiór składał się ze zdjęć wad spawalniczych oraz odpowiadających im szeregów czasowych i został podzielony następnie na pięć klas wadliwości (tabela 1).

Ponieważ modele sieci neuronowych budowane były przy pomocy m.in. bibliotek Tensorflow [3] i Keras [4] to należało wykonać wektoryzację danych wejściowych do postaci  $n$ -wymiarowych tensorów. Przetworzono w tym celu dane obrazowe i sekwencyjne odpowiednio do cztero- i trójwymiarowych tensorów o wartościach liczbowych według powszechnie stosowanych matematycznych przekształceń [1]. Wstępne przetwarzanie miało na celu przygotowanie danych do tego, aby mogły zostać skierowane do sieci neuronowej. Dane obrazowe w postaci zdjęć poddano obróbce wstępnej przez normalizację ich wartości kana-

łów z zakresu [0, 255] do zakresu [0, 1]. Wartości cech danych sekwencyjnych ( $x_1, x_2, \dots, x_n$ ) w postaci szeregów czasowych parametrów procesowych znormalizowano wykonując algorytm (1.1), który dla każdej próbki wykonał operację odjęcia od wartości cechy średniej arytmetycznej (1.2) a następnie podzielenie przez wartość odchylenia od średniej standardowej (1.3) z próbki:

$$\text{for } (i = 1; i \leq \text{liczba\_próbek}; i++)\{$$

$$x_i = x_i - x_m;$$

$$x_i = x_i/\sigma;\}$$
(1.1)

gdzie:  $x_m$  – średnia arytmetyczna z przebiegu

$$x_m = \frac{\sum_{i=1}^n x_i}{n}$$
(1.2)

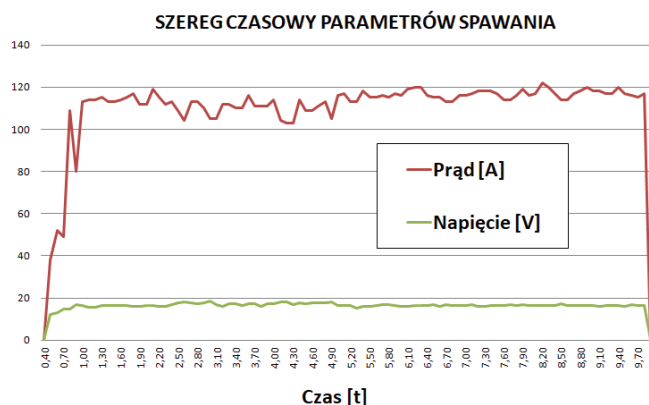
$\sigma$  – odchylenie standardowe z przebiegu

$$\sigma = \sqrt{\frac{(x_1 - x_m)^2 + (x_2 - x_m)^2 + \dots + (x_n - x_m)^2}{n}}$$
(1.3)

Tak przygotowane dane przyjęły charakterystyki zarazem małych wartości oraz będących homogenicznymi czyli przyjmującymi wartości z tego samego zakresu. Oprócz samego przekształcenia wartości na podstawie średniej i odchylenia standardowego próbek, skorelowano je z wzorcowym przebiegiem dla spoiny dobrej. Dla danych obrazowych wad spawalniczych założono, że barwa jest jednym z czynników mogących wpływać na dokładność działania modelu klasyfikującego, dlatego zdecydowano się na stworzenie modeli neuronowych dla zdjęć kolorowych o trzech kanałach barw (RGB) oraz zdjęć monochromatycznych o jednym kanale. Zmniejszenie liczby kanałów z trzech do jednego, będącego tylko informacją o luminancji danego piksela, pozwoliło na zmniejszenie liczby parametrów sieci neuronowej gdzie dla zdjęć o dużej rozdzielczości ograniczeniem są zasoby sprzętowe oraz czas procesu uczenia sieci neuronowej. Podczas obróbki wstępnej danych obrazowych istotnym parametrem była rozdzielczość, gdzie trzeba było znaleźć kompromis, aby przy możliwie małych wymiarach zdjęcia zachować informację obrazową w nim zawartą.

## 3. Struktura i trening sieci neuronowych

Badania rozpoczęto od budowy sieci neuronowych klasyfikujących szeregi czasowe. Wykorzystano do tego celu strukturę sieci rekurencyjnych wykorzystujących moduły LSTM [5] i GRU [6] oraz sieci konwolucyjne 1D [7]. W drodze eksperymentów wzorując się na powyższych rozwiązaniach zaproponowano

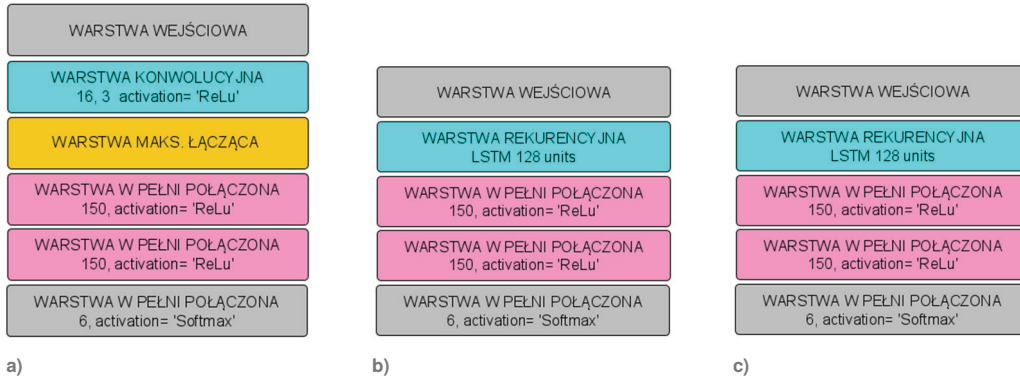


Rys. 1. Przebiegi czasowe parametrów procesowych (prąd i napięcie)  
Fig. 1. Time series of process parameters (current and voltage)

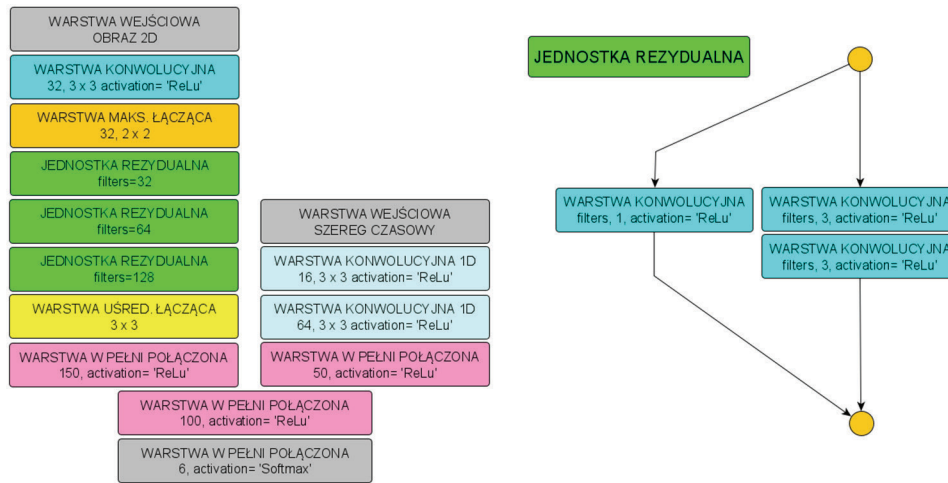
Tab. 1. Zbiór danych zdjęć i szeregów czasowych z oznaczonymi wadami spoin

Tab. 1. Data set of photo and time series 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
Kratery	34	12	4	5



Rys. 2. Budowa warstwowej sieci neuronowej: a) konwolucyjnej 1D, b) rekurencyjnej z jednostkami LSTM, c) rekurencyjnej z jednostkami GRU  
Fig. 2. Construction of layered neural networks: a) convolutional 1D, b) recurrent with LSTM units, c) recurrent with GRU units



Rys. 3. Budowa sieci konwolucyjnej do klasyfikacji z dwoma wejściami systemowymi (obrazem i szeregiem czasowym)  
Fig. 3. Construction of a convolutional network for classification with two system inputs (image and time series)

trzy konstrukcje sieci (rys. 2). Sieć neuronowa konwolucyjna 1D (rys. 2a) składa się z warstwy konwolucyjnej przyjmującej na wejściu trójwymiarowy tensor postaci (*próbki, czas, cechy*), zawierającej 16 filtrów i funkcji aktywacji ReLu, warstwy łączącej (*MaxPooling1D*) oraz dwóch warstw gęsto połączonych składających się odpowiednio ze 150 neuronów i sześciu neuronów w każdej z warstw. Natomiast zaproponowane sieci rekurencyjne zawierają odpowiednio jedną warstwę LSTM lub GRU składającą się ze 128 jednostek i dwie warstwy sieci gęsto połączonej ze 150 neuronami w każdej warstwie (rys. 2b, 2c).

Dla każdej z konstrukcji sieci przeprowadzono uczenie na danych treningowych oraz badania poprawności klasyfikacji. Kolejnym etapem pracy było opracowanie sieci neuronowej, aby była zdolna do jednoczesnego przetwarzania danych obrazowych i danych sekwencyjnych. Zaproponowano w tym celu sieć neuronową z dwoma wejściami systemowymi i jednym wyjściem kategoryalnym (rys. 3).

Sieć składa się z równoległych gałęzi stosów warstw konwolucyjnych połączonych ze sobą za pomocą sieci gęsto połączonej ze 100 neuronami w warstwie. Pierwsza gałąź, odpowiadająca za przyjmowanie danych obrazowych, składa się ze stosu warstw o architekturze zbliżonej do architektury sieci ResNet [8] z połączeniami rezydualnymi. Warstwa konwolucyjna jest połączona z warstwą łączącą (*Max Pooling*) oraz stosem trzech warstw z połączeniami rezydualnymi, warstwą uśredniającą (*Average Pooling*) i warstwą sieci gęsto połączonej ze 150 neuronami. Druga gałąź odpowiedzialna za przetwarzanie sekwencji czasowych, składa się z dwóch warstw konwolucyjnych 1D i warstwy gęsto połączonej z 50 neuronami.

Mając na uwadze, że proces uczenia sieci neuronowej jest szczególnym zadaniem optymalizacji i dla wielu zastosowań jest procesem trudnym i kosztownym, skorzystano ze znanych i specjalnie opracowanych zbiorów technik optymalizacji do szkolenia sieci neuronowych z pakietu Keras. Tworząc architekturę sieci niezbędną rzeczą było określenie:

- Funkcji straty (funkcji celu) – zwracającą wartość, która była minimalizowana w procesie uczenia, będąca jednocześnie miarą sukcesu.
- Optymalizatora – będącego sposobem, w jaki były modyfikowane wagi sieci neuronowej podczas procesu uczenia, implementującego określony wariant algorytmu stochastycznego spadku wzdłuż gradientu.

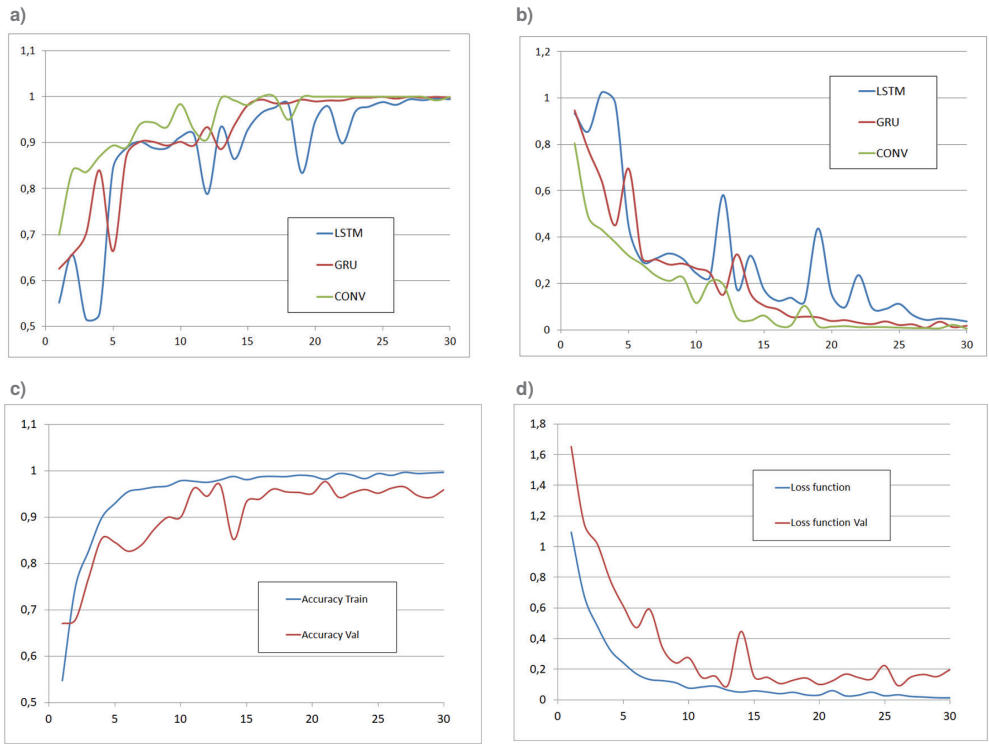
Podczas wyboru funkcji straty dla problemu klasyfikacji zdjęć spoin oraz przebiegów czasowych będącego typowym przykładem klasyfikacji wieloklasowej oparto się na wskazówkach i praktykach przy doborze funkcji dla ogólnych zagadnień klasyfikacyjnych. Proces uczenia wykonano dla 30 epok. Podczas procesu uczenia brano pod uwagę dziewięć cech przebiegu czasowego zbieranego przez źródło spawalnicze:

$$V(c_{\min}, c, c_{\max}, v_{\min}, v, v_{\max}, p_{\min}, p, p_{\max}) \quad (2.1)$$

gdzie:  $c$  – prąd,  $v$  – napięcie,  $p$  – dostarczona moc.

Uzyskane wyniki dokładności klasyfikacji i funkcji straty dla trzech sieci neuronowych przedstawiono na rys. 4.

Zdecydowano się na wybór kategoryzacyjnej entropii krzyżowej [9]. Kategoryzacyjna entropia krzyżowa mierzyła wydajność



Rys. 4. Przebieg uczenia sieci neuronowych: a) dokładność (LSTM, GRU, CONV 1D), b) funkcja straty (LSTM, GRU, CONV 1D), c) dokładność (CONV 2D i CONV 1D), d) funkcja straty (CONV 2D i CONV 1D)

Fig. 4. The learning process of neural networks: a) accuracy (LSTM, GRU, CONV 1D), b) loss function (LSTM, GRU, CONV 1D), c) accuracy (CONV 2D & CONV 1D), d) loss function (CONV 2D & CONV 1D)

modelu, którego wyniki były prawdopodobieństwa z przedziału  $[0; 1]$  dla danej wyjściowej w postaci wektora. Odnosnie optymalizatora wybrano optymalizator ADAM [10], który jest algorytmem optymalizacji gradientowej pierwszego rzędu stochastycznych funkcji celu. Algorytm ma dobrą wydajność obliczeniową, niewielkie wymagania dotyczące pamięci i jest dostosowany do sieci o dużej liczbie parametrów. Implementację wszystkich sieci neuronowych wykonano wykorzystując biblioteki Tensorflow, Keras oraz Numpy [11]. Proces uczenia został przeprowadzony z wykorzystaniem GPU (ang. *graphics processing unit*) model Nvidia RTX 2060. Proces uczenia przeprowadzono dla każdej z zaproponowanych sieci neuronowych.

## 4. Rezultaty

Każda z sieci neuronowych zaprezentowanych w punkcie 2, została poddana procesowi uczenia i dla każdej uzyskano wyniki klasyfikacji będącymi stosunkiem ilości dobrze rozpoznanych wad spawalniczych do wszystkich wad poddanych procesowi klasyfikacji. Dobrym rozwiązaniem do przetwarzania szeregów czasowych okazało się zastosowanie jednowymiarowej sieci konwolucyjnej. Sieci konwolucyjne są znane z tego, że są zdolne wykonywać ekstrakcję cech na podstawie lokalnych fragmentów danych wejściowych i tworzą modułowe reprezentacje. Ten sam mechanizm, który sprawdził się w przetwarzaniu obrazu, sprawdza się przy przetwarzaniu sekwencji. Warstwy konwolucyjne mogą rozpoznawać lokalne wzorce sekwencji (takie jak zaburzenia parametrów spowodowane przepaleniem materiału lub brakiem gazu osłonowego) w dowolnym miejscu i nie są wrażliwe na przesunięcia. Sieć konwolucyjna 1D konkuruje z sieciami rekurencyjnymi ze względu na niższy koszt obliczeniowy, tym samym sieć okazała się szybsza w działaniu od rekurencyjnych o 0,1–0,2 sekundy dla jednego szeregu czasowego.

### 4.1. Składanie modeli w celu poprawy skuteczności klasyfikacji

Podczas uczenia modeli napotkano sytuację, że modele o tej samej architekturze lecz uczone w inny sposób osiągają róż-

niące się wyniki dla tych samych danych. Aby zminimalizować to zjawisko została wykorzystana w projekcie technika składania modeli, pozwalająca na uzyskanie lepszych wyników klasyfikacji niż tylko użycie jednego modelu. Metoda polega na łączeniu przewidywań zwracanych z modeli o innej konstrukcji oraz innym sposobie uczenia. Złożenie różnych konstrukcji modeli trenowanych w sposób niezależny zwiększa prawdopodobieństwo  $vp_f$  poprawnej końcowej klasyfikacji. W tym celu wykorzystano odpowiednie wycięcia [1], na podstawie wyników poszczególnych sieci neuronowych. Najprostszym sposobem składania modeli dla klasyfikatorów było wycięcie średniej  $vp_f$  (3.1) dla  $n$  wyników modeli  $p_1, p_2, \dots, p_n$ .

$$vp_f = \frac{\sum_{i=1}^n p_i}{n} \quad (3.1)$$

gdzie:  $vp_f$  – średnia wartość przewidywana zwrócona przez  $n$  modeli,  $p_i$  – wartości przewidywane zwrócone przez dany model.

Rozwiązanie takie sprawdzało się jeśli wszystkie modele działały porównywalnie dobrze. Natomiast jeśli jeden z nich odbiegał od reszty, to wpływał na pogorszenie wyniku końcowego w postaci spoin prawidłowo rozpoznanych. Lepszym rozwiązaniem okazało się wycięcie średniej ważonej  $vp_{fw}$  (3.2), przypisując poszczególnym modelom  $p_1, p_2, \dots, p_n$  odpowiednio wartości wag  $w_1, w_2, \dots, w_n$ , które były wyznaczone eksperymentalnie, na podstawie testów poprawności klasyfikacji dla każdego z modeli.

$$vp_{fw} = \frac{\sum_{i=1}^n p_i w_i}{\sum_{i=1}^n w_i} \quad (3.2)$$

Metoda składania modeli okazała się bardziej wydajna niż stosowanie każdego modelu z osobna. W tabeli 2 przedstawiono wyniki klasyfikacji dla poszczególnych sieci neuronowych.

Należy jednak zaznaczyć, że otrzymane wyniki klasyfikacji zostały wykonane w warunkach laboratoryjnych dla wzorcowych przebiegów czasowych spoin. Problemem podczas badań na rzeczywistym stanowisku okazało się, że podczas zmiany wartości parametrów zadanych na źródle spawalniczym klasyfikator działał ze skutecznością poniżej 80 %. Dla danych obrazowych

Tab. 2. Wyniki klasyfikacji dla badanych sieci neuronowych  
Tab. 2. Classification results for the examined neural networks


Lp.	Rodzaj sieci	Wynik klasyfikacji
1	Sieć rekurencyjna z jednostkami GRU	95,2 %
2	Sieć rekurencyjna z jednostkami LSTM	94,1 %
3	Sieć konwulucyjna warstwowa 1D	96,4 %
4	Sieć konwulucyjna warstwowa 2D z konwulucyjną 1D	94,8 %
5	Złożenie sieci (GRU, LSTM, Conv 1D, Conv 2D i 1D)	96,6 %

zmiana parametrów wejściowych nie była tak widoczna. Przy zmianie parametrów należy ponownie wykonać proces uczenia sieci neuronowej dla nowych przebiegów czasowych ze zmienionymi parametrami wejściowymi. Może to jednak powodować trudności wynikające z potrzeby generowania i oznaczania wad dla nowych danych. Kolejną trudnością jest niedostateczna częstość (co 100 ms) zbieranych danych rzeczywistych na źródle spawalniczym. Wahaniami amplitudy przebiegu czasowego są między tymi wartościami pomijane co w konsekwencji może nie obrazować rzeczywistego przebiegu.

#### 4.2. Wizualizacja wad spawalniczych za pomocą map ciepła warstwy konwulucyjnej

W celu wizualizacji wady spawalniczej zastosowano rozwiązanie polegające na wykorzystaniu techniki wizualizacji map ciepła w procesie klasyfikowania wad spawalniczych (rys. 5).

Technika ta umożliwiła, na podstawie decyzji podjętej przez wytrenowaną sieć, określić położenie wady spawalniczej. Skorzystano z implementacji opisanej w artykule *Grad-CAM: Visual Explanations from Deep Networks via Gradient-based Localization* [2] polegającej na przechwytywaniu wejściowej mapy cech jednej z warstw konwulucyjnych powstałej przy przetwarzaniu obrazu defektu spawalniczego. Zastosowane rozwiązanie generuje mapy ciepła i nanosi je na obrazy wejściowe. Mapa ciepła



Rys. 5. Wizualizacja przykładowych wad spawalniczych na podstawie map ciepła warstwy konwulucyjnej: a) Przepalenie, b) Nieregularne lico  
Fig. 5. Visualization of exemplary welding defects on the basis of heat maps of the convolution layer: a) Burnout, b) Irregular face

w tym przypadku jest dwuwymiarową siatką wyników dla danej klasy wyjściowej obliczonych dla każdego punktu obrazu wyjściowego. Pokazuje to, jak decyzyjny jest dany obszar ze względu na wybraną przez sieć neuronową klasę. Zastosowanie map ciepła zostało wykorzystane jako alternatywa do wizualizacji wad spawalniczych spoin na obrazach przedstawionej w artykule *Metoda detekcji wad spawalniczych w stanowisku zrobotyzowanym z wykorzystaniem głębokiej sieci neuronowej* [12].

## 5. Podsumowanie

Przedstawione zostały w artykule metody detekcji wad spawalniczych wykorzystujące głębokie sieci neuronowe na podstawie wykonanego zdjęcia spoiny z równoczesną analizą szeregu czasowego parametrów procesowych. W drodze badań otrzymano obiecujące rezultaty klasyfikacji i wykazano, że istnieje możliwość na podstawie niestabilności procesu spawania rozpoznać defekt spoiny. Podstawową wadą analizy szeregów czasowych jest jednak niewystarczająca ilość danych zbieranych przez oprogramowanie źródła spawalniczego spowodowana ograniczeniami technicznymi stosowanych źródeł spawalniczych. Powoduje to trudności lub niemożliwość w wyznaczaniu większej liczby wad spawalniczych. Kolejnym problemem przy analizie szeregów czasowych jest wrażliwość na zmiany zadawanych parametrów spawalniczych ustawianych na źródle. Każda zmiana powoduje pogorszenie zdolności klasyfikacyjnych sieci neuronowej, mimo skorelowania przebiegu ze wzorcowym przebiegiem spoiny dobrej. Przysparza to trudności przy kalibracji systemu. Można zauważyć na podstawie badań, że głębokie sieci neuronowe klasyfikujące przebiegi czasowe mają bardzo duży potencjał, lecz wymagają dostarczenia dokładniejszych danych wejściowych. Połączenie z analizą obrazową spoiny szeregu czasowego, jest podejściem nowatorskim, nie stosowanym w kontroli poprawności spoin. Początkowe próby klasyfikacyjne dają również obiecujące wyniki i zostaną w dalszym etapie badań kontynuowane. Zaprezentowane w artykule podejście do automatycznej wizualizacji wad spawalniczych przy pomocy map ciepła warstwy konwulucyjnej, może być używane niezależnie od zaprezentowanej w artykule *Metoda detekcji wad spawalniczych w stanowisku zrobotyzowanym z wykorzystaniem głębokiej sieci neuronowej* [12] metody segmentacji wad spawalniczych. Mimo innego podejścia obie te metody mogą zostać zastosowane do rozwiązania przemysłowego systemu detekcji wad spawalniczych na stanowisku zrobotyzowanym dla produkcji wielkoseryjnej.

## Podziękowanie

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

## Bibliografia

- Chollet F., *Deep learning with Python*. Vol. 361. New York: Manning, 2018.
- Selvaraju R.R., et al. *Grad-cam: Visual explanations from deep networks via gradient-based localization*. Proceedings of the IEEE international conference on computer vision. 2017, DOI: 10.1007/s11263-019-01228-7.
- Abadi M., et al. *Tensorflow: A system for large-scale machine learning*. [In:] 12th {USENIX} symposium on operating systems design and implementation ({OSDI} 16), 2016, 265–283.
- Chollet F., et al. *Keras: The python deep learning library*. Astrophysics Source Code Library, 2018, ascl: 1806.022.
- Yu Y., et al. *A review of recurrent neural networks: LSTM cells and network architectures*. "Neural computation", Vol. 31, No. 7, 2019, 1235–1270, DOI: 10.1162/neco\_a\_01199.

6. Chung J., et al. *Empirical evaluation of gated recurrent neural networks on sequence modeling*. arXiv preprint arXiv:1412.3555, 2014.
7. Kiranyaz S., et al. *1D convolutional neural networks and applications: A survey*. "Mechanical Systems and Signal Processing", Vol. 151, 2021, DOI: 10.1016/j.ymssp.2020.107398.
8. Kaiming H., et al., *Deep residual learning for image recognition*. Proceedings of the IEEE conference on computer vision and pattern recognition. 2016.
9. De Boer, Pieter-Tjerk, et al. *A tutorial on the cross-entropy method*. "Annals of operations research", Vol. 134, No. 1, 2005, 19-67, DOI: 10.1007/s10479-005-5724-z.
10. Zijun Z., *Improved adam optimizer for deep neural networks*. 2018 IEEE/ACM 26th International Symposium on Quality of Service (IWQoS), DOI: 10.1109/IWQoS.2018.8624183.
11. van der Walt S., Colbert S.C., Varoquaux G., *The NumPy array: a structure for efficient numerical computation*. "Computing in science & engineering", Vol. 13, No. 2, 2011, 22-30, DOI: 10.1109/MCSE.2011.37.
12. Adamczak A., *Metoda detekcji wad spawalniczych w stanowisku zrobotyzowanym z wykorzystaniem głębokiej sieci neuronowej*, „Pomiary Automatyka Robotyka”, R. 25, Nr 1, 2021, 67-72, DOI: 10.14313/PAR\_239/67.

////////////////////////////////////

## Deep Recurrent and Convolutional Networks in the Detection of Welding Defects for Systems with an Industrial Robot

**Abstract:** During MIG/MAG welding processes in large-scale production on robotic stations, automatic quality control of the weld is often required. Determining welding defects is difficult and the reason for their occurrence is not always known. One of the conditions for a correctly made weld is stability during the welding process, which translates into continuity and increase in overall production efficiency. The article presents the results of research on the creation of a weld defect detection system combining the analysis and classification of time series of welding parameters for the MIG/MAG method along with the simultaneous analysis and classification of weld image data for robotic systems. For this purpose, the structures of deep recursive and convolutional neural networks were used. The design of a neural network with two system inputs allowing for the classification of the weld photo together with the time series for use in a robotic station is also presented. 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, time series, 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.