

Zastosowanie konwolucyjnej sieci neuronowej do identyfikacji struktury przepływu ciecz-gaz w rurociągu z wykorzystaniem histogramów sygnałów z detektorów scyntylacyjnych

Streszczenie. *Znajomość struktury przepływów dwufazowych w rurociągach jest niezbędna dla oceny prawidłowego przebiegu wielu procesów przemysłowych. W niniejszej pracy zastosowano Konwolucyjną Sieć Neuronową (CNN) do analizy histogramów sygnałów uzyskanych dla przepływu ciecz-gaz z wykorzystaniem absorpcji promieniowania gamma. Eksperymenty przeprowadzono na laboratoryjnej instalacji hydraulicznej wyposażonej w radiometryczny układ pomiarowy. W pracy zbadano cztery typy przepływu: rzutowy, tłokowy, tłokowo-pęcherzykowy i pęcherzykowy. Stwierdzono, że sieć CNN poprawnie rozpoznaje strukturę przepływu w ponad 90% przypadków.*

Abstract. *Knowledge of the two-phase flow structure is essential for the proper conduct of industrial processes. In this work, the Convolutional Neural Network (CNN) is applied for analysis of histograms of signals obtained for liquid-gas flow by use gamma-ray absorption. The experiments were carried out on the laboratory hydraulic installation fitted with radiometric measurement system. Four types of flow regimes as plug, slug, bubble, and transitional plug – bubble were studied in this work. It was found that the CNN network correctly recognize the flow structure in more than 90% of cases. (Application of the convolutional neural network to identify the liquid-gas flow structure in a pipeline using histograms of signals from scintillation detectors).*

Słowa kluczowe: przepływ dwufazowy, absorpcja promieniowania gamma, rozpoznawanie struktury przepływu, Konwolucyjne Sieci Neuronowe.

Keywords: two-phase flow, gamma-ray absorption, flow structure recognition, Convolutional Neural Networks.

Wstęp

Znajomość struktury przepływu ciecz-gaz jest ważna dla prawidłowej kontroli wielu procesów przemysłowych (m.in. w przemyśle wydobywczym, nuklearnym, petrochemicznym, energetycznym i ochronie środowiska). O istotności podjętego tematu świadczy bogata literatura przedmiotu, m.in. [1-6]. Najnowsze publikacje dotyczą zastosowania do celu rozpoznawania struktury przepływu metod inteligencji obliczeniowej, do których należą np. systemy ekspertowe i sztuczne sieci neuronowe [7-12]. Ogólnie metody uczenia maszynowego wykorzystują różne cechy sygnałów w dziedzinie przestrzeni stanów, czasu i częstotliwości. W dziedzinie czasu wykorzystywane są parametry statystyczne sygnałów, takie jak wartość średnia, RMS (Root Mean Square), skośność, kurtoza, wariancja i momenty wyższych rzędów [7]. Istotne cechy sygnałów w dziedzinie częstotliwości można wyznaczyć za pomocą transformaty falkowej, transformaty Fouriera, STFT (Short Time Fourier Transform) lub innych metod [9,10].


W niniejszej pracy zastosowano konwolucyjną sieć neuronową do analizy obrazów histogramów sygnałów otrzymanych w pomiarach przepływu woda-powietrze z wykorzystaniem metody absorpcji promieniowania gamma. Dane pomiarowe zostały zarejestrowane na stanowisku laboratoryjnym do badań przepływów dwufazowych w rurociągu poziomym, zbudowanym w AGH w Krakowie. Stanowisko pozwala na symulowanie różnych struktur przepływu ciecz-gaz jak: rzutowy, tłokowy, tłokowo-pęcherzykowy i pęcherzykowy. Do analizy sygnałów wykorzystano oprogramowanie MATLAB.

Idea metody absorpcji promieniowania gamma w pomiarach przepływu ciecz-gaz

Technika wykorzystania absorpcji promieniowania gamma w pomiarach opiera się na wykładniczym tłumieniu wiązki promieniowania γ w funkcji wielkości geometrycznych (grubość), fizycznych (masa, gęstość) i chemicznych (skład pierwiastkowy) absorbentu [1]. Zmiany natężenia promieniowania rejestrowane są przez detektory

scyntylacyjne i przekształcane na impulsy elektryczne (najczęściej napięciowe).

Typowy zestaw pomiarowy do badania przepływu dwufazowego z wykorzystaniem metody absorpcji promieniowania gamma przedstawiono na rysunku 1.



Rys. 1. Idea metody absorpcji promieniowania gamma w badaniach przepływu ciecz-gaz: 1 – źródło promieniowania gamma w kolimatorze, 2 – detektor scyntylacyjny, 3 – kolimator detektora, 4 – wiązka promieniowania γ , 5 - rurociąg, v_g – prędkość gazu, v_l – prędkość cieczy, $I_x(t)$ – napięciowy sygnał impulsowy

Źródło promieniotwórcze, umieszczone z jednej strony rury, emituje wiązkę promieniowania γ (4) kształtowaną przez kolimator (1). Fotony gamma przenikają przez rurociąg (5) z przepływającą mieszaniną ciecz-gaz ulegając częściowej absorpcji. Detektor scyntylacyjny (2) z kolimatorem (3) umieszczone są po przeciwnej stronie rurociągu, naprzeciw źródła. Na wyjściu detektora uzyskuje się impulsy elektryczne $I_x(t)$, kształtowane przez układ front-

end sondy, rejestrowane następnie przez zewnętrzny system akwizycji danych. W badaniach zastosowano radiometryczny układ pomiarowy składający się z liniowego źródła promieniowania Am-241 o energii 59.5 keV oraz detektora z kryształem scyntylacyjnym NaI(Tl).


Stanowisko laboratoryjne

Opisany absorpcyjny zestaw pomiarowy zastosowano na stanowisku laboratoryjnym do badania przepływów dwufazowych metodami radioizotopowymi, zbudowanym w Akademii Górniczo-Hutniczej w Krakowie. Dokładny opis stanowiska przedstawiono w pracach [7,10]. Zasadniczą częścią instalacji hydraulicznej jest rurociąg poziomy wykonany z metalpleksu o długości 4,5 m i wewnętrznej średnicy 30 mm. Widok ogólny sekcji pomiarowej instalacji przedstawiono na rysunku 2.



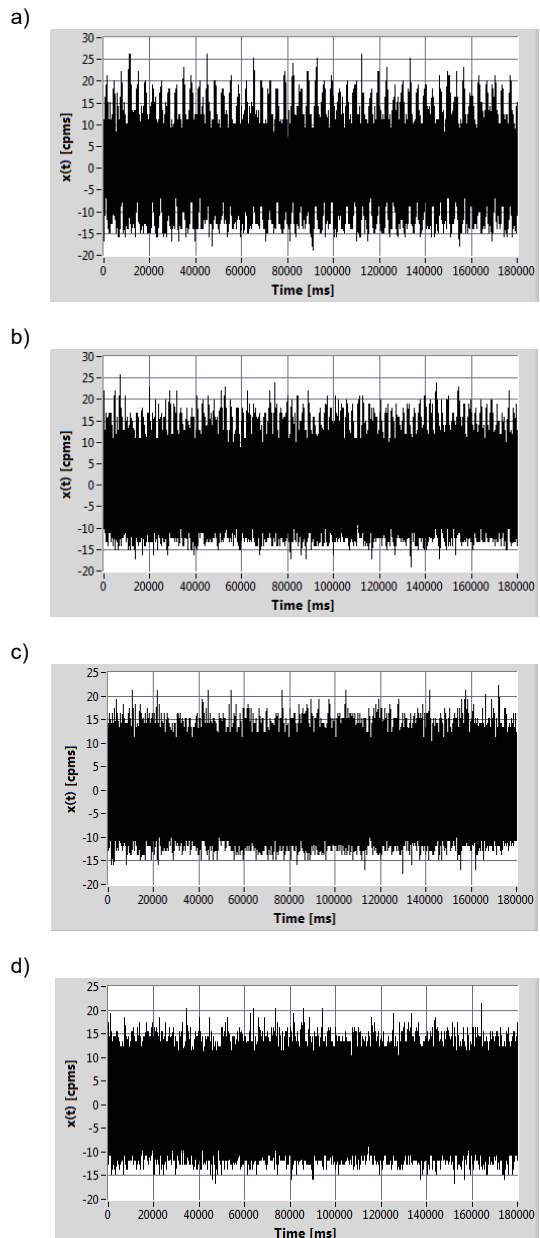
Rys. 2. Widok ogólny sekcji pomiarowej instalacji hydraulicznej do badania przepływów dwufazowych

Z kolei rysunek 3 przedstawia zdjęcia przykładowych struktur analizowanych przepływów: rzutowego (3a), tłokowego (3b), tłokowo-pęcherzykowego (3c) i pęcherzykowego (3d).



Rys. 3. Przykładowe struktury przepływu ciecz-gaz w rurociągu poziomym: rzutowy (a), tłokowy (b), tłokowo-pęcherzykowy (c) i pęcherzykowy (d).


System akwizycji danych zawiera dedykowaną kartę licznikową podłączaną do komputera PC przez port USB. Impulsy napięciowe $I_x(t)$ były rejestrowane z częstotliwością próbkowania 1 kHz w czasie 3 minut, co pozwoliło uzyskać sygnały $x(t)$. Sygnały dla analizowanych typów przepływów, po operacji centrowania, przedstawiono na rysunku 4.



Rys. 4. Przebiegi sygnałów $x(t)$ zarejestrowane dla przepływu: rzutowego (a), tłokowego (b), tłokowo-pęcherzykowego (c) i pęcherzykowego (d)

Konwolucyjna sieć neuronowa

Konwolucyjna sieć neuronowa (ang. Convolutional Neural Network - CNN) to struktura wykorzystująca operacje splotu [13]. Najczęściej tego typu sieci są wykorzystywane do rozpoznawania obrazów; w przypadku klasyfikacji sygnałów najpopularniejsze jest zastosowanie spektrogramu na wejściu sieci (predyktor). Wykresy wejściowe są pozbawione tytułów, legend i opisu osi, aby takie dane nie wpływały negatywnie na proces uczenia. Do klasyfikacji typu przepływu przy zastosowaniu CNN jako predyktory można wykorzystać obrazy histogramów sygnałów uzyskiwanych z detektorów scyntylacyjnych. W tej pracy wykorzystano histogramy przefiltrowanych dolnoprzestowo (częstotliwości odcięcia 50 Hz ustalono eksperymentalnie) sygnałów z sond o długości 20000 próbek. Na rysunku 5 przedstawiono przykładowe obrazy histogramów (liczba klas 112) dla analizowanych typów przepływów.



Rys. 5. Przykłady obrazów histogramów sygnałów $x(t)$ dla przepływów: rzutowego (a), tłokowego (b), tłokowo-pęcherzykowego (c) i pęcherzykowego (d).

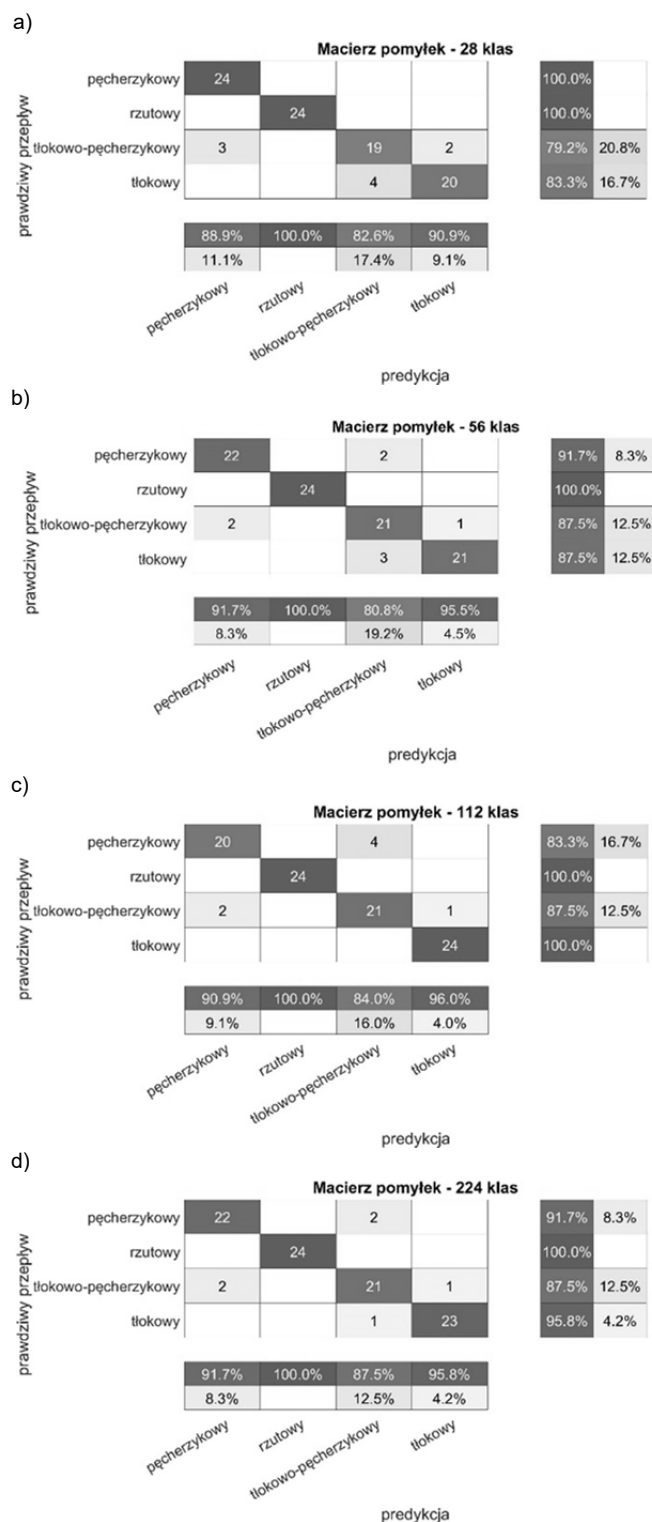
Sieć wykorzystana do uczenia, to zmodyfikowana sieć VGG-16 dostępna w środowisku MATLAB [14]. Sieć ta pierwotnie powstała do uczenia, na podstawie bazy ImageNet. Na potrzeby obliczeń zmianie uległa warstwa 14 (zmiana wejścia klasyfikatora na „auto”, wymuszona mniejszym rozmiarem zbioru uczącego) i warstwa 16 (zmiana wyjścia klasyfikatora z 1000 na 4). Na wejście sieci podawano obrazy histogramów o rozmiarze 224x224 pikseli.

Przykładowe wyniki

Jak już wspomniano obliczenia zrealizowano w środowisku MATLAB. Na podstawie przeprowadzonych eksperymentów zastosowano następujące opcje sieci: algorytm optymalizacji sieci: SGDM (Stochastic Gradient Descent with Momentum); wartość współczynnika uczenia 0,001; maksymalna liczba epok: 60, liczba danych analizowana w danej chwili przez sieć (batch size): 4 [15].

Sieć była uczona dla obrazów histogramów o różnej liczbie klas: 28, 56, 112 i 224. Zastosowane liczby klas to dzielniki liczby 224.

Na podstawie zbioru testowego przetestowano nauczoną sieć i wykreślono macierze pomyłek. Macierze te dla ww. liczby klas przedstawiono na rysunku 6. Do uczenia został wykorzystany zbiór 212 elementów, do testu 96, do walidacji 16.



Rys. 6. Macierze pomyłek dla CNN VGG-16 uczonej obrazami histogramów o liczbie klas: a) 28, b) 56, c) 112, d) 224

Następnie obliczono wskaźniki: dokładność (*Dok*), czułość (*Czul*), specyficzność (*Spec*) oraz precyzja (*Prec*) z zależności [16-18]:

$$(1) \quad Dok = \frac{TP + TN}{TP + FP + TN + FN}$$

$$(2) \quad Czul = \frac{TP}{TP + FN}$$

$$(3) \quad Spec = \frac{TN}{TN + FP}$$

$$(4) \quad Prec = \frac{TN}{TP + FP}$$

gdzie *TP* i *TN* oznaczają odpowiednio liczbę prawdziwie rozpoznanych przypadków rzadkich i większościowych, *FP* – liczbę przypadków większościowych rozpoznanych jako rzadkie i *FN* – liczbę przypadków rzadkich rozpoznanych jako większościowe. Wyniki zestawiono w tabelach 1 - 4.

Tabela 1. Wartości wskaźnika dokładność

Liczba klas	28	56	112	224
pęcherzykowy	0,969	0,958	0,938	0,958
rzutowy	1	1	1	1
łtokowo-pęcherzykowy	0,906	0,917	0,927	0,938
łtokowy	0,938	0,958	0,990	0,979

Tabela 2. Wartości wskaźnika czułość

Liczba klas	28	56	112	224
pęcherzykowy	1	0,917	0,833	0,917
rzutowy	1	1	1	1
łtokowo-pęcherzykowy	0,792	0,875	0,875	0,875
łtokowy	0,833	0,875	1	0,958

Tabela 3. Wartości wskaźnika specyficzność

Liczba klas	28	56	112	224
pęcherzykowy	0,958	0,972	0,972	0,972
rzutowy	1	1	1	1
łtokowo-pęcherzykowy	0,944	0,931	0,944	0,958
łtokowy	0,972	0,986	0,986	0,986

Tabela 4. Wartości wskaźnika precyzja

Liczba klas	28	56	112	224
pęcherzykowy	0,889	0,917	0,909	0,917
rzutowy	1	1	1	1
łtokowo-pęcherzykowy	0,826	0,808	0,840	0,875
łtokowy	0,909	0,955	0,960	0,958

Wartości wskaźników z tabel 1-3 świadczą o dobrych wynikach rozpoznawania. Precyzja (tab. 4) informuje na ile można ufać otrzymanemu modelowi, gdy przewiduje, że wynik rozpoznawania będzie pozytywny.

Na podstawie wskaźników precyzja i czułość obliczono wartości współczynnika *F1* (tab. 5), będącego ich średnią harmoniczną i opisywanego zależnością [18]:

$$(5) \quad F1 = \frac{2 \cdot TP}{2 \cdot TP + FP + FN}$$

Wartości wskaźnika *F1* mieszczą się w przedziale [0, 1], gdzie minimum jest osiągnięte dla *TP* = 0, to znaczy, gdy wszystkie pozytywne próbki są błędnie sklasyfikowane, a

maksimum dla *FN* = *FP* = 0, czyli dla bezbłędnej klasyfikacji. Dwie główne cechy wyróżniają wskaźnik *F1* od dokładności: *F1* jest niezależny od *TN* oraz nie jest symetryczny w przypadku zamiany klas [18]. Uzyskane wartości wskaźnika *F1* są we wszystkich przypadkach dobre, tzn. współczynnik jest większy niż 0,8. Najlepsze wyniki uzyskano dla przepływu rzutowego.

Tabela 5. Wartości wskaźnika *F1*

Liczba klas	28	56	112	224
pęcherzykowy	0,941	0,917	0,869	0,917
rzutowy	1	1	1	1
łtokowo-pęcherzykowy	0,809	0,840	0,857	0,875
łtokowy	0,869	0,913	0,980	0,958

Podsumowanie

W artykule przedstawiono możliwość zastosowania konwolucyjnej sieci neuronowej do identyfikacji struktury przepływu ciecz-gaz w rurociągu poziomym, w oparciu o analizę sygnałów z radiometrycznego systemu pomiarowego. Badania zostały wykonane dla czterech typów przepływów: rzutowego, łtokowego, łtokowo-pęcherzykowego i pęcherzykowego. Na wejście zmodyfikowanej przez autorów sieci VGG-16, dostępnej w środowisku MATLAB, jako predyktory wykorzystano obrazy histogramów o rozmiarze 224x224 pikseli, wykonane dla sygnałów z detektora scyntylicyjnego. W celu porównania wyników histogramy wykonano dla różnej liczby klas: 28, 56, 112 i 224. Dla wszystkich czterech typów przepływów i wszystkich liczb klas uzyskano dobre wyniki rozpoznawania, co potwierdzają obliczone wskaźniki (wartości powyżej 0,8). Najlepsze rozpoznanie (wartości wszystkich wskaźników równe 1) uzyskano dla przepływu rzutowego.

Otrzymane wyniki klasyfikacji mogą być przydatne w radiometrycznych pomiarach przepływów dwufazowych ciecz-gaz w rurociągach, w których wyznacza się prędkości (ew. natężenie przepływu) i udział poszczególnych składników mieszaniny. Identyfikacja struktury przepływu jest kolejną informacją, istotną do kontroli przebiegu procesów przemysłowych, a uzyskiwaną dodatkowo z rejestrowanych sygnałów pomiarowych.

Przedstawione wyniki, wraz z wynikami przedstawionymi w artykułach autorów [7, 10], gdzie do rozpoznawania struktur przepływu ciecz-gaz wykorzystano inne metody inteligencji obliczeniowej, pozwalają na poszukiwanie optymalnej metody klasyfikacyjnej.

Projekt finansowany w ramach programu Ministra Edukacji i Nauki pod nazwą „Regionalna Inicjatywa Doskonałości” w latach 2019–2022, nr projektu 027/RID/2018/19, kwota finansowania 11 999 900 zł.

Autorzy: mgr inż. Piotr Ochał, absolwent Politechniki Rzeszowskiej, E-mail: pochal@mail.com; dr hab. inż. Robert Hanus, Politechnika Rzeszowska, Wydział Elektrotechniki i Informatyki, al. Powstańców Warszawy 12, 35-959 Rzeszów. E-mail: rohan@prz.edu.pl; dr hab. inż. Marcin Zych, AGH Akademia Górniczo-Hutnicza, Wydział Geologii, Geofizyki i Ochrony Środowiska, al. Mickiewicza 30, 30-059 Kraków. E-mail: zych@geol.agh.edu.pl.

LITERATURA

- [1] Zhao Y., Qincheng B., Richa H., Recognition and measurement in the flow pattern and void fraction of gasliquid two-phase flow in vertical upward pipes using the gamma densitometer, *Appl. Therm. Eng.*, vol. 60 (2013), 398-410
- [2] Roshani M., Phan G., Faraj R.H., Phan N.-H., Roshani G.H., Nazemi B., Corniani E., Nazemi E., Proposing a gamma

- radiation based intelligent system for simultaneous analyzing and detecting type and amount of petroleum by-products, *Nucl. Eng. Technol.* 53(4), (2021), 1277-1283
- [3] Roshani G.H., Nazemi E., Feghhi S.A.H., Setayeshi S., Flow regime identification and void fraction prediction in two-phase flows based on gamma ray attenuation, *Measurement* 62 (2015), 25–32
- [4] Karami A., Roshani G.H., Khazaei A., Nazemi E., Fallahi M., Investigation of different sources in order to optimize the nuclear metering system of gas–oil–water annular flows, *Neural Comput. Appl.* 32 (2020), 3619–3631
- [5] Hanus R., Zych M., Golijanek-Jędrzejczyk A., Investigation of liquid–gas flow in a horizontal pipeline using gamma-ray technique and modified cross-correlation, *Energies* 15(16) (2022), 5848
- [6] Roshani M., Sattari M.A., Ali P.J.M., Roshani G.H., Nazemi B., Corniani E., Nazemi E., Application of GMDH neural network technique to improve measuring precision of a simplified photon attenuation based two-phase flowmeter, *Flow Meas. Instrum.* 75 (2020), 101804
- [7] Hanus R., Zych M., Kusy M., Jaszczur M., Petryka L., Identification of liquid-gas flow regime in a pipeline using gamma-ray absorption technique and computational intelligence methods, *Flow Meas. Instrum.* 60 (2018), 17-23
- [8] Salgado R.W.L., Dam S.F., Salgado C.M., Optimization of a flow regime identification system and prediction of volume fractions in three-phase systems using gamma-rays and artificial neural network, *Appl. Radiat. Isot.* 169 (2021), 109552
- [9] Salgado C.M., Dam S.F., Puertas E.J.A., Salgado R.W.L., Calculation of volume fractions regardless scale deposition in the oil industry pipelines using feed-forward multilayer perceptron artificial neural network and MCNP6 code, *Appl. Radiat. Isot.* 185(10–11) (2022), 110215
- [10] Hanus R., Zych M., Jaszczur M., Computational intelligence approach for liquid-gas flow regime classification based on frequency domain analysis of signals from scintillation detectors. In: Rojas I., Joya G., Catala A. (eds) *Advances in Computational Intelligence. IWANN 2019*. Lecture Notes in Computer Science, vol. 11507, 339-349, Springer, Cham 2019
- [11] Iliyasa A.M., Mayet A.M., Hanus R., Abd El-Latif A.A., Salama A.S., Employing GMDH-type neural network and signal frequency feature extraction approaches for detection of scale thickness inside oil pipelines, *Energies* 15(12) (2022), 4500
- [12] Mayet A.M., Alizadeh S.M., Nurgalieva K.S., Hanus R., Nazemi E., Narozhnyy I.M., Extraction of time-domain characteristics and selection of effective features using correlation analysis to increase the accuracy of petroleum fluid monitoring systems, *Energies* 15(6) (2022), 1986
- [13] Raitoharju J., Convolutional neural networks, in: *Deep Learning for Robot Perception and Cognition*, Academic Press, 2022
- [14] <https://www.mathworks.com/help/deeplearning/ref/vgg16.html;jsessionid=27ee6b23c86210369251f413f898>
- [15] Ochał P., Identyfikacja struktury przepływu dwufazowego przy zastosowaniu analizy widmowej i metod sztucznej inteligencji. Praca dyplomowa magisterska, Politechnika Rzeszowska, 2022
- [16] Osowski S., *Metody i narzędzia eksploracji danych*, Wydawnictwo BTC, Legionowo 2013
- [17] Grandini M., Bagli E., Visani G., Metrics for Multi-Class Classification: an Overview, arXiv:2008.05756, <https://doi.org/10.48550/arXiv.2008.05756>
- [18] Chicco D., Jurman G., The advantages of the Matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation, *BMC Genomics* 21(6) (2020), <https://doi.org/10.1186/s12864-019-6413-7>