

Identyfikacja struktury przepływu ciecz-gaz w rurociągu przy zastosowaniu konwolucyjnej sieci neuronowej i spektrogramów sygnałów radiometrycznych

Streszczenie. Identyfikacja struktury przepływów dwufazowych ciecz-gaz w rurociągach jest istotna dla oceny przebiegu wielu procesów przemysłowych. W niniejszej pracy zastosowano Konwolucyjną Sieć Neuronową VGG-16 do analizy spektrogramów sygnałów uzyskanych dla przepływu woda-powietrze z wykorzystaniem metody absorpcji promieniowania gamma. Analizowano cztery typy przepływu: rzutowy, tłokowy, tłokowo-pęcherzykowy i pęcherzykowy. Eksperymenty przeprowadzono na laboratoryjnej instalacji hydraulicznej wyposażonej w radiometryczny układ pomiarowy, zawierający źródło promieniowania Am-241 i detektor scyntylacyjny NaI(Tl). Stwierdzono, że sieć VGG-16 poprawnie rozpoznaje strukturę przepływu w ponad 90% przypadków.

Abstract. Identification of the liquid-gas flow structure is important for assessing the course of many industrial processes. In this work, the Convolutional Neural Network VGG-16 is applied for analysis of spectrograms of signals obtained for water-air flow by use gamma-ray absorption method. Four types of flow regimes as plug, slug, bubble, and transitional plug – bubble were studied. The experiments were carried out on the laboratory hydraulic installation fitted with radiometric measurement system containing an Am-241 radiation source and a NaI(Tl) scintillation detector. It was found that the VGG-16 network correctly recognize the flow structure in more than 90% of cases. (**Identification of the structure of liquid-gas flow in a pipeline using a convolutional neural network and spectrograms of radiometric signals**).

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

W wielu gałęziach przemysłu, np. w przemyśle wydobywczym, nuklearnym, petrochemicznym, energetycznym występują przepływy dwufazowe typu ciecz-gaz. W celu kontroli przebiegu procesów przemysłowych istotna jest znajomość struktury takiego przepływu. Obecnie często stosowanymi technikami do identyfikacji wzorców przepływu dwufazowego są metody inteligencji obliczeniowej, np. systemy ekspertowe i sztuczne sieci neuronowe [1-4]. Do pozyskiwania danych stosowane są różne typy sensorów, np. pojemnościowe, optyczne, termiczne, radiacyjne, różnicy ciśnień. Jedną ze stosowanych technik pomiarowych, wykorzystywaną także przez autorów tej pracy, jest metoda absorpcji promieniowania gamma [5-8].

W metodach uczenia maszynowego stosuje się cechy sygnałów określone w dziedzinie wartości, czasu i częstotliwości. W dziedzinie wartości przydatne mogą być rozkłady prawdopodobieństwa amplitud [9,10], w dziedzinie czasu wykorzystywane są parametry statystyczne sygnałów, takie jak wartość średnia, wariancja, RMS (Root Mean Square), skośność, kurtoza, momenty wyższych rzędów [7,11]. Istotne cechy sygnałów w dziedzinie częstotliwości można wyznaczyć np. za pomocą transformaty Fouriera, a w dziedzinie czas-częstotliwość i czas-skala stosując STFT (Short Time Fourier Transform) i transformatę falkową [6,12,13].

W ostatnich latach w badaniach przepływów dwufazowych przy zastosowaniu sztucznych sieci neuronowych widoczny jest wzrost zainteresowania metodami uczenia głębokiego (deep learning) i wykorzystania konwolucyjnych sieci neuronowych [14, 15]. Jako dane wejściowe najczęściej stosuje się bezpośrednio obrazy przepływów uzyskiwane metodami optycznymi (szybka kamera), ale można też wykorzystać obrazy otrzymane za pomocą innych technik pomiarowych.

W niniejszej pracy zastosowano konwolucyjną sieć neuronową VGG-16 do analizy obrazów spektrogramów sygnałów otrzymanych w pomiarach przepływu woda-


powietrze w rurociągu poziomym z wykorzystaniem metody absorpcji promieniowania gamma. Dane pomiarowe zostały zarejestrowane na stanowisku laboratoryjnym do badań przepływów metodami radioizotopowymi zbudowanym w Akademii Górniczo-Hutniczej w Krakowie. Stanowisko pozwala na symulowanie różnych typów przepływu ciecz-gaz jak: rzutowy, tłokowy, tłokowo-pęcherzykowy i pęcherzykowy. Do przygotowania spektrogramów zastosowano oprogramowanie OCTAVE, w tym pakiet do przetwarzania sygnałów. Do uczenia sieci neuronowej została wykorzystana biblioteka TensorFlow przy pomocy usługi Google Coolab [16].

Metoda 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 [17]. 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 rys. 1.

Źródło promieniotwórcze (2), umieszczone z jednej strony rury, emituje wiązkę promieniowania γ (3) kształtowaną przez kolimator (1). Fotony gamma przenikają przez rurociąg z przepływającą mieszaniną ciecz-gaz ulegając częściowej absorpcji. Detektor scyntylacyjny (5) z kolimatorem (4) umieszczone są po przeciwnej stronie rury, 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 omawianych 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).



Rys. 1. Zasada zastosowania metody absorpcji promieniowania gamma w badaniach przepływu ciec-z-gaz w rurociągu poziomym: 1 – kolimator źródła, 2 – źródło promieniowania gamma, 3 – główna wiązka promieniowania γ , 4 – kolimator detektora, 5 - detektor scyntylacyjny, v_G – prędkość gazu, v_L – prędkość cieczy, $I_x(t)$ – napięciowy sygnał impulsowy

Stanowisko laboratoryjne


Wyżej opisany absorpcyjny zestaw pomiarowy zastosowano na stanowisku laboratoryjnym do badania przepływów metodami radioizotopowymi, zbudowanym w AGH w Krakowie. Szczegółowy opis stanowiska przedstawiono w pracach [7,12]. 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 rys. 2.



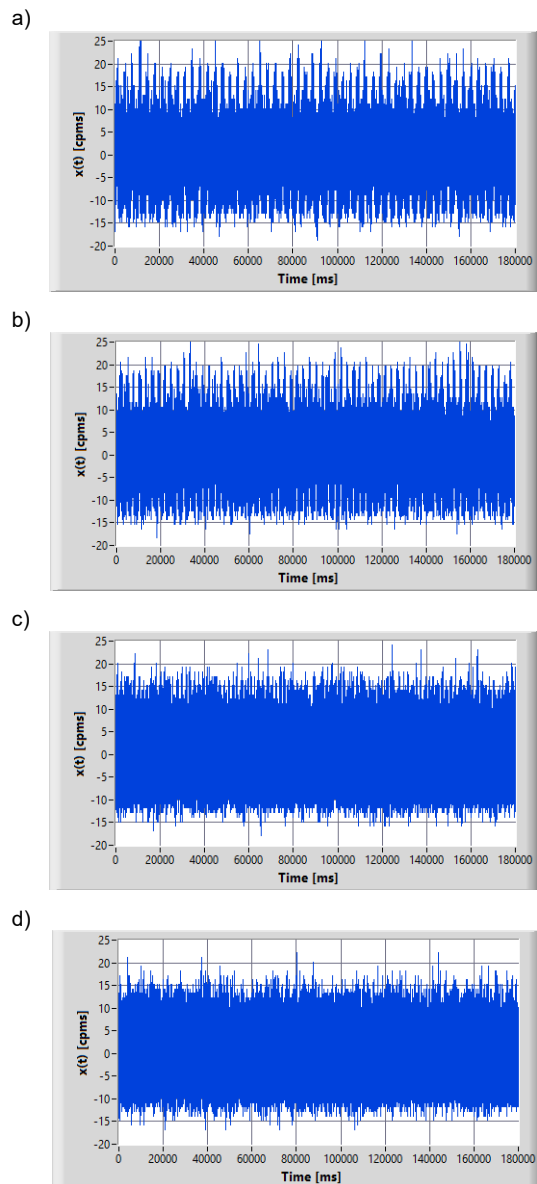
Rys. 2. Sekcja pomiarowa instalacji hydraulicznej do badania przepływów metodami radioizotopowymi w Akademii Górniczo-Hutniczej w Krakowie

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

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 $x(t)$ składające się ze 180 000 próbek. Przebiegi czasowe sygnałów dla analizowanych typów przepływów, po operacji centrowania, przedstawiono na rys. 4.



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

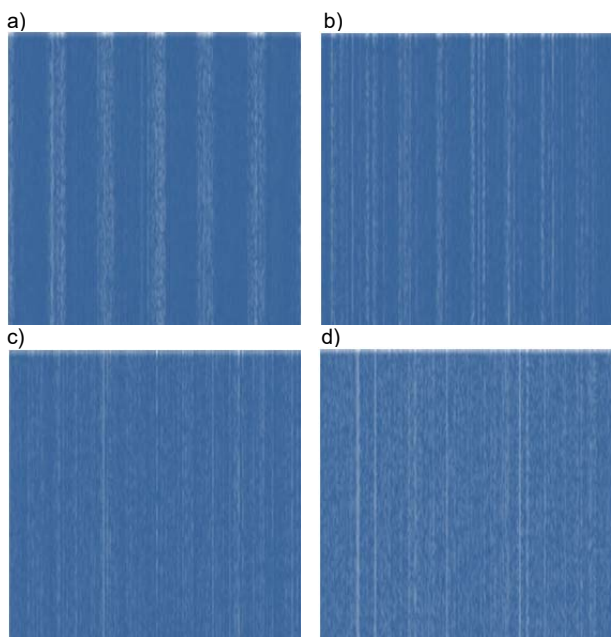


Rys. 4. Przebiegi czasowe sygnałów $x(t)$ zarejestrowane dla przepływu: rzutowego (a), tłokowego (b), tłokowo-pęcherzykowego (c) i pęcherzykowego (d)

Konwolucyjna sieć neuronowa

Spośród różnych struktur głębokiego uczenia w zadaniach identyfikacji obrazów najpopularniejsza jest konwolucyjna sieć neuronowa (ang. Convolutional Neural Network - CNN). Jest to struktura wykorzystująca operacje splotu [18]. Najczęściej wykorzystywane w badaniach przepływów dwufazowych struktury CNN to: LeNet-5, AlexNet i VGG-16. Te trzy typy CNN różnią się głębokością sieci i rozmiarem filtra. Opisane w [14] badania struktury przepływu dwufazowego na podstawie analizy obrazów z szybkiej kamery pokazały, że najlepsze wyniki uzyskano przy zastosowaniu sieci VGG-16. Z tego względu ten typ sieci wykorzystano także w niniejszej pracy.

Do klasyfikacji typu przepływu przy zastosowaniu CNN jako predyktory można wykorzystać obrazy spektrogramów sygnałów uzyskiwanych z detektorów scyntylicyjnych. Wykresy wejściowe są pozbawione tytułów, legend i opisu osi, aby takie dane nie wpływały negatywnie na proces uczenia. W tej pracy wykorzystano spektrogramy sygnałów o liczności 20000 próbek. Zastosowano podział sygnałów na segmenty o długości 448 próbek, okienkowanie wybranym typem okna o długości 152 próbek i nakładanie (overlapping), które wynosiło 63 próbki. Parametry te dobrano w celu uzyskania obrazu o wymiarze 224 na 224 piksele, co jest związane z domyślnym rozmiarem danych wejściowych sieci VGG-16. W niniejszym artykule analizowano spektrogramy uzyskane przy zastosowaniu okna Hamminga, przedstawione na rys. 5.



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

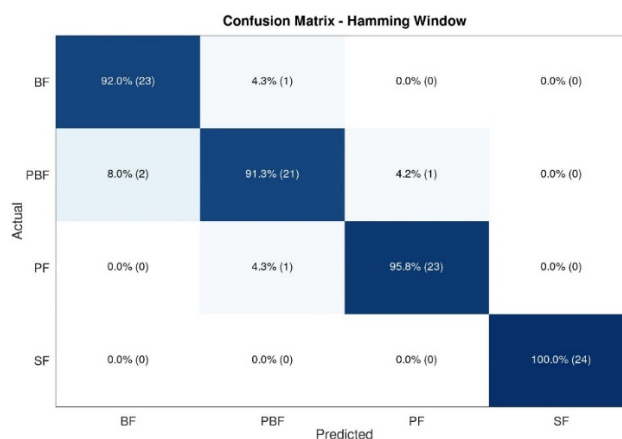
Sieć wykorzystana do uczenia, to zmodyfikowana sieć VGG-16 dostępna w bibliotece TensorFlow [16]. Sieć ta pierwotnie powstała do uczenia na podstawie bazy ImageNet. Na potrzeby opisanych analiz liczba klas została ustawiona na 4. Tryb łączenia cech ustawiono na maksymalny (max-pooling). Jest to operacja zmniejszająca liczbę cech - zachowująca istotne a usuwająca nieistotne - co powoduje zmniejszenie kosztów obliczeń [19].

Uzyskane wyniki

Obliczenia zrealizowano przy pomocy usługi Google Coolab. Na podstawie przeprowadzonych eksperymentów

zastosowano następujące opcje sieci: algorytm optymalizacji sieci: SGDM (Stochastic Gradient Descent with Momentum); wartość współczynnika uczenia 0,001, a moment na 0,95; maksymalna liczba epok: 180; liczba danych analizowana w danej chwili przez sieć (batch size): 4. Sieć była uczona dla obrazów spektrogramów uzyskanych przy zastosowaniu okna Hamminga.

Na podstawie zbioru testowego przetestowano nauczoną sieć i wykreślono macierz pomyłek. Macierz tę przedstawiono na rys. 6. Do uczenia został wykorzystany zbiór 228 elementów, natomiast do testowania i walidacji – zbiór 96 elementów.



Rys. 6. Macierz pomyłek dla CNN VGG-16 uczonej obrazami spektrogramów wykonanych przy zastosowaniu okna Hamminga: BF - przepływ pęcherzykowy, PBF – przepływ tłokowo-pęcherzykowy, PF – przepływ tłokowy, SF – przepływ rzutowy

Na podstawie uzyskanych wyników obliczono wskaźniki: dokładność (*Dok*), czułość (*Czul*), specyficzność (*Spec*), precyzja (*Prec*) oraz *F1* z zależności [20-22]:

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

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

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

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

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

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.

Otrzymane wyniki zestawiono w tabeli 1. Wartości wskaźników *Dok*, *Czul*, *Spec* świadczą o dobrych wynikach rozpoznawania. Wskaźnik *Prec* informuje na ile można ufać otrzymanemu modelowi, gdy przewiduje, że wynik rozpoznawania będzie pozytywny. Wartości współczynnika *F1* można obliczyć na podstawie wskaźników *Prec* i *Czul* (*F1* jest ich średnią harmoniczną).

Tabela 1. Zestawienie wartości wskaźników

Wskaźnik Typ przepływu	Dok	Czul	Spec	Prec	FI
rzutowy	1,000	1,000	1,000	1,000	1,000
łokowy	0,979	0,958	0,986	0,958	0,958
łokowo-pęcherzykowy	0,948	0,875	0,959	0,913	0,894
pęcherzykowy	0,969	0,958	0,986	0,920	0,939

Wartości wskaźnika FI zawierają się w przedziale $[0, 1]$, gdzie minimum jest osiągnięte dla $TP = 0$ (gdy wszystkie pozytywne próbki są błędnie sklasyfikowane), a maksimum dla $FN = FP = 0$, czyli dla bezbłędnej klasyfikacji. Dwie główne cechy wyróżniają wskaźnik FI od dokładności: FI jest niezależny od TN oraz nie jest symetryczny w przypadku zamiany klas [22]. Uzyskane wartości wskaźnika FI są we wszystkich przypadkach dobre, tzn. wartości tego współczynnika są większe niż 0,8. Najlepsze wyniki uzyskano dla przepływu rzutowego.

Podsumowanie

W artykule przedstawiono możliwość zastosowania konwolucyjnej sieci neuronowej VGG-16 do identyfikacji struktury przepływu ciecz-gaz w rurociągu poziomym, w oparciu o analizę spektrogramów sygnałów z radiometrycznego systemu pomiarowego. Badania zostały wykonane dla czterech typów przepływów: rzutowego, łokowego, łokowo-pęcherzykowego i pęcherzykowego. Na podstawie uzyskanych wyników stwierdzono, że sieć CNN VGG-16 poprawnie rozpoznaje strukturę przepływu w ponad 90% przypadków.

W radioizotopowych pomiarach przepływów dwufazowych ciecz-gaz zwykle wyznacza się prędkości i objętości poszczególnych składników mieszaniny stosując różne metody statystyczne [23-25]. Wykorzystując te same sygnały pomiarowe i sztuczne sieci neuronowe można uzyskać dodatkową informację o strukturze przepływu, co jest istotne dla kontroli przebiegu procesów przemysłowych.

Autorzy: mgr inż. Piotr Ochał, Bury Technologies, ul. Wspólna 2, 35-205 Rzeszów, e-mail: pochala@mail.com; mgr inż. Małgorzata Augustyn, dr hab. inż. Robert Hanus, Politechnika Rzeszowska, Wydział Elektrotechniki i Informatyki, al. Powstańców Warszawy 12, 35-959 Rzeszów, e-mail: m.augustyn@prz.edu.pl, rohan@prz.edu.pl; dr hab. inż. Marcin Zych, AGH w Krakowie, Wydział Geologii, Geofizyki i Ochrony Środowiska, al. Mickiewicza 30, 30-059 Kraków, e-mail: zych@agh.edu.pl.

LITERATURA

- [1] Aarabi Jeshvaghani P., Rezaee Kh., Rezaee K., Feghi S.A.H., Jafari A., Using statistical features and a neural network to predict gas volume fractions independent of flow regime changes, *Flow Meas. Instrum.* 93 (2023), 102430
- [2] 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
- [3] 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
- [4] Roshani G.H., Nazemi E., Feghi 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
- [5] Roshani G.H., Nazemi E., Shama F., Imani M.A., Mohammadi S., Designing a simple radiometric system to predict void fraction percentage independent of flow pattern using radial basis function, *Metrol. Meas. Syst.* 25(2) (2018), 347–358
- [6] Zhao Y., Qincheng B., Richa H., Recognition and measurement in the flow pattern and void fraction of gas-liquid two-phase flow in vertical upward pipes using the gamma densitometer, *Appl. Therm. Eng.* 60 (2013), 398-410
- [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] 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
- [9] Liu W., Lv X., Jiang S., Li H., Zhou H., Dou X., Two-phase flow pattern identification in horizontal gas-liquid swirling pipe flow by machine learning method, *Ann. Nucl. Energy*, 12 (2022), 109644
- [10] Ochał P., Hanus R., Zych M., Zastosowanie konwolucyjnej sieci neuronowej do identyfikacji struktury przepływu ciecz-gaz w rurociągu z wykorzystaniem histogramów sygnałów z detektorów scyntylicyjnych, *Przegl. Elektrotech.* 98(11), 2022, 185-189
- [11] 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
- [12] 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
- [13] Hosseini S., Taylan O., Abusurrah M., Akilan T., Nazemi E., Eftekhari-Zadeh E., Bano F., Roshani G.H., Application of Wavelet Feature Extraction and Artificial Neural Networks for Improving the Performance of Gas-Liquid Two-Phase Flow Meters Used in Oil and Petrochemical Industries, *Polymers*, 13(21) (2021), 3647
- [14] Du M., Yin H., Chen X., Wang X., Oil-in-water two-phase flow pattern identification from experimental snapshots using convolutional neural network, *IEEE Access*, 7 (2018), 6219–6225
- [15] Salgado W.L., Dam R.S.D.F., Desterro F.S.M.D., da Cruz B.L., Silva A.X.D., Salgado C.M., Application of deep neural network and gamma radiation to monitor the transport of petroleum by-products through polyducts, *Appl. Radiat. Isot.*, 200 (2023), 110973
- [16] Pang B., et al., Deep Learning With TensorFlow: A Review, *J. Educ. Behav. Stat.*, 45 (2019), 227-248
- [17] Johansen G.A., Jackson P., *Radioisotope Gauges for Industrial Process Measurements*, John Wiley & Sons, New York, 2004
- [18] Raitoharju J., Convolutional neural networks, in: *Deep Learning for Robot Perception and Cognition*, Academic Press, 2022
- [19] Zafar A., et al., A Comparison of Pooling Methods for Convolutional Neural Networks, *Appl. Sci.* 12(17) (2022), 8643
- [20] Osowski S., *Metody i narzędzia eksploracji danych*, Wydawnictwo BTC, Legionowo 2013
- [21] Grandini M., Bagli E., Visani G., Metrics for Multi-Class Classification: an Overview, arXiv:2008.05756, <https://doi.org/10.48550/arXiv.2008.05756>
- [22] 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)
- [23] 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
- [24] Hanus R., Zych M., Mosorov V., Golijanek-Jędrzejczyk A., Jaszczur M., Andruszkiewicz A., Evaluation of liquid-gas flow in pipeline using gamma-ray absorption technique and advanced signal processing, *Metrol. Meas. Syst.* 28(1) (2021), 145–159
- [25] Hanus R., Zych M., Golijanek-Jędrzejczyk A., Measurements of dispersed phase velocity in two-phase flows in pipelines using gamma-absorption technique and phase of the cross-spectral density function. *Energies* 15(24) (2022), 9526