

Zastosowanie absorpcji promieniowania gamma i wybranych metod sztucznej inteligencji do identyfikacji struktury przepływu ciecz-gaz w rurociągu

Streszczenie. Artykuł przedstawia zastosowanie metody absorpcji promieniowania gamma w połączeniu z wybranymi metodami sztucznej inteligencji do identyfikacji struktury przepływu ciecz-gaz w rurociągu poziomym. Dla sygnałów z zestawu radiometrycznego wyodrębniono na podstawie analizy w dziedzinie czasu szereg cech wykorzystanych następnie do rozpoznawania struktury przepływu. Zastosowano następujące metody sztucznej inteligencji: wielowarstwową sieć neuronową MLP, metodę K-średnich i algorytm wektorów wspierających SVM. Przedstawiono przykładowe wyniki badań dla trzech typów przepływu: tłokowego, tłokowo-pęcherzykowego i pęcherzykowego, uzyskanych na stanowisku laboratoryjnym wyposażonym w zamknięte źródła promieniowania Am-241 i sondy scyntylacyjne NaI(Tl). Otrzymano bardzo dobre wyniki identyfikacji struktury przepływu dla wszystkich analizowanych metod.

Abstract. The article presents the application of the gamma absorption method in combination with selected artificial intelligence methods to identify the structure of liquid-gas flow in a horizontal pipeline. For the signals from the radiometric set, a number of features were distinguished based on time domain analysis. These features were then applied to identify the flow structure. The following artificial intelligence methods were used: multilayer perceptron (MLP) neural network, K-means method and support vectors machine (SVM). Exemplary results for three flow types as plug, transitional plug-bubble and bubble are presented. The experiments were carried out on a laboratory stand equipped with closed Am-241 radiation sources and NaI(Tl) scintillation probes. For all the analyzed methods very good results of the flow structure identification were obtained. (**Application of gamma absorption and selected artificial intelligence methods to identify the structure of liquid-gas flow in the pipeline.**)

Słowa kluczowe: Przepływ dwufazowy, absorpcja promieniowania gamma, identyfikacja typu przepływu, sztuczna inteligencja

Keywords: Two-phase flow, gamma-ray absorption, flow regime identification, artificial intelligence

Wstęp

Przepływy dwufazowe (wspólny przepływ dwóch faz) występują w różnych dziedzinach przemysłu, takich jak przemysł wydobywczy, energetyczny, chemiczny, farmaceutyczny, rolno-spożywczy oraz w inżynierii środowiska. W szczególności przepływy ciecz-gaz cieszą się dużym zainteresowaniem ze względu na ich znaczenie w opisie procesów uzdatniania wody czy wymiany ciepła i masy w urządzeniach takich jak wymienniki ciepła, reaktory, kolumny destylacyjne a także w procesach pneumo- i hydrotransportu [1]. Niejednokrotnie media dwufazowe przesyłane są rurociągami łączącymi poszczególne elementy instalacji produkcyjnej, gdzie gaz i ciecz płyną jednocześnie przez rurę. W trakcie takiego przepływu obydwa składniki mieszaniny tworzą formy geometryczne o różnych kształtach. Wzajemne konfiguracje form noszą nazwę struktur przepływu. Rodzaj struktury uzależniony jest między innymi od objętości i prędkości strumieni obu faz, ich właściwości fizycznych oraz wymiaru, kształtu i usytuowania rurociągu, w którym odbywa się przepływ.

W badaniach przepływów dwufazowych wykorzystuje się różne techniki pomiarowe, m.in. takie jak tomografia komputerowa, przepływomierze Coriolisa i ultradźwiękowe, PIV (Particle Image Velocimetry), LDA (Laser Doppler Anemometry) oraz metody radioizotopowe [1-4]. Te ostatnie dzielą się na metodę radioznacznikową oraz metodę absorpcji promieniowania gamma. Są to metody bardzo dokładne, lecz nieco kłopotliwe w użyciu ze względu na wytwarzane promieniowanie jonizujące.

Identyfikacja struktury przepływu dwufazowego jest ważnym zagadnieniem w procesach przepływowych spotykanych w przemyśle. Do rozpoznawania struktury stosuje się m.in. metody sztucznej inteligencji (SI). Bazują one na analizie cech statystycznych sygnałów uzyskiwanych z czujników. W literaturze opisywanych jest szereg tego typu rozwiązań wykorzystujących metody radioizotopowe. Publikacja [5] przedstawia zastosowanie absorpcji promieniowania gamma i sztucznych sieci neuronowych do rozpoznawania typu przepływu


dwufazowego ciecz-gaz i predykcji stopnia wypełnienia gazem rurociągu pionowego. Zastosowano źródło promieniowania gamma Cs-137 (energia 662 keV) i dwa detektory NaI - jeden do pomiaru głównej wiązki promieniowania przechodzącej przez rurociąg, drugi do promieniowania rozproszonego. Wyodrębniono trzy cechy - dwie z widma energetycznego (zliczenia dla pików absorpcji głównej i „ogona” komptonowskiego) oraz jedną dla promieniowania rozproszonego (całkowita liczba zliczeń) i zastosowano je jako wejścia dla sztucznej sieci neuronowej MLP (Multi-Layer Perceptron - perceptron wielowarstwowy). Dla trzech badanych typów przepływów (homogeniczny - pęcherzykowy, rozwarstwiony i pierścieniowy) uzyskano rozpoznawanie struktury ze 100% dokładnością. Wypełnienie rurociągu w zakresie 5-95% mierzono z błędem mniejszym niż 1,1%. Uzyskane wyniki były zgodne z przeprowadzoną wcześniej symulacją w programie MCNP. W pracy [6] przy zastosowaniu takiego samego zestawu radioizotopowego jak w [5], ale o nieco zmodyfikowanej geometrii, badano trzy typy przepływu olej-powietrze w rurociągu pionowym: rozwarstwiony, pierścieniowy i homogeniczny. Do rozpoznawania typu przepływu zastosowano sieć o radialnej funkcji aktywacji RBF (Radial Basic Function). Predyktorami były dwie cechy - liczby zliczeń uzyskiwane z dwóch zastosowanych detektorów. Stwierdzono, że wszystkie trzy typy przepływu były prawidłowo rozpoznawane. Dla pomiaru wypełnienia rurociągu frakcją gazową uzyskano błąd pomiaru mniejszy niż 1,5%. W artykule [7] symulowano w programie MCNP układ pomiarowy jak w [6] dla tych samych trzech typów przepływu. Rozważono podwójne źródło promieniowania gamma Cs-137 + AM-241 i dwa detektory NaI. Wyodrębniono 4 cechy sygnałów - liczby zliczeń pod głównymi pikami energii Cs-137 i Am-241 dla każdego z detektorów. Do rozpoznawania typu przepływu zastosowano sieć RBF i uzyskano prawidłowe rozpoznawanie wszystkich trzech analizowanych typów przepływów. Dla pomiaru wypełnienia rurociągu otrzymano względny błąd pomiaru mniejszy niż 5,68%. W publikacji [8]

rozważono zastosowanie zestawu radiometrycznego złożonego z jednego źródła promieniowania gamma Co-60 i jednej sondy scyntylacyjnej NaI do identyfikacji typu przepływu gaz-ciecz (powietrze - olej napędowy) oraz określania wypełnienia rurociągu frakcją gazową. W programie MCNP symulowano przepływ rozwarstwiony, pierścieniowy i homogeniczny w zakresie wypełnienia rurociągu gazem 5-95%. Z widma energetycznego sygnału z sondy wyodrębniono trzy cechy (liczby zliczeń w określonych pasmach energetycznych) zastosowane następnie do uczenia sieci neuronowej MLP. Uzyskano prawidłowe rozpoznawanie tylko dwóch struktur przepływu – rozwarstwowanego i pierścieniowego. Stopień wypełnienia rurociągu gazem określano z błędem względnym 0,42%. W omówionych publikacjach do rozpoznawania struktury przepływu stosuje się sieci neuronowe MLP i RBF. Na wejścia sieci podaje się cechy sygnałów, które określa się na podstawie analizy widma energetycznego sygnałów z sond scyntylacyjnych.

W niniejszym artykule przedstawiono możliwości wykorzystania sygnału uzyskiwanego z zestawu radiometrycznego, złożonego ze źródła promieniowania gamma Am-241 i sondy scyntylacyjnej NaI(Tl), do rozpoznawania struktury przepływu ciecz-gaz w rurociągu poziomym. Do wyznaczania cech sygnału zastosowano analizę w dziedzinie czasu, a do rozpoznawania struktury przepływu wybrano trzy metody SI: sztuczną sieć neuronową MLP, metodę K-średnich (K-means) i algorytm wektorów wspierających SVM (Support Vector Machine). Do analizy sygnałów wykorzystano oprogramowanie Matlab i DTREG.

Idea metody absorpcji promieniowania gamma


Idea badania przepływu mieszaniny ciecz-gaz w rurociągu metodą absorpcji promieniowania gamma została przedstawiona na rysunku 1.



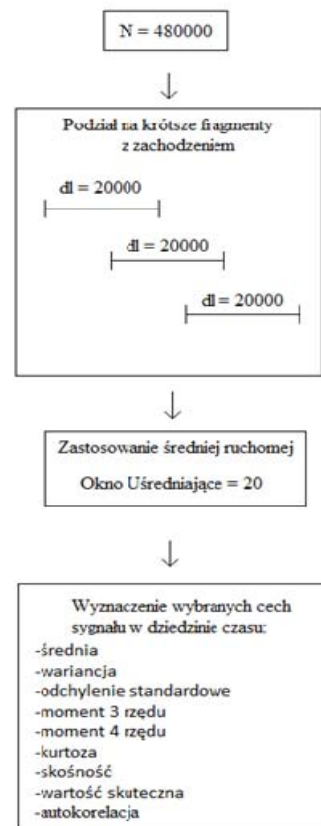

Rys. 1. Idea pomiaru przepływu ciecz-gaz metodą absorpcji promieniowania gamma: 1 – kolimator źródła, 2 – źródło promieniowania gamma, 3 – wiązka promieniowania, 4 – kolimator detektora, 5 – detektor scyntylacyjny; u_G – prędkość gazu, u_L – prędkość cieczy

Źródło promieniowania gamma 2 umieszczone w kolimatorze ołowianym 1 emituje wiązkę promieniowania 3 prześwietlającą rurociąg z przepływającą mieszaniną. Promieniowanie to ulega częściowej absorpcji przez przepływające medium i trafia do sondy scyntylacyjnej 5 przez kolimator 4. Na wyjściu sondy otrzymuje się napięciowe przebiegi impulsowe $I_x(t)$, zależne od gęstości przepływającej mieszaniny. Zliczanie impulsów w określonym

okresie próbkowania Δt (w tym przypadku $\Delta t = 1$ ms) pozwala uzyskać dyskretne sygnały $x(n)$, gdzie $n = t/\Delta t$.



Rys. 2. Przykładowe struktury przepływu ciecz-gaz w rurociągu: a) tłokowy, b) tłokowo-pęcherzykowy, c) pęcherzykowy



Rys. 3. Algorytm analizy sygnału $x(n)$

W artykule wykorzystano dane zarejestrowane na stanowisku do badań przepływów, zbudowanym w

Pracowni Radiometrii Przemysłowej Wydziału Fizyki i Informatyki Stosowanej AGH w Krakowie. Szczegółowy opis instalacji przedstawiono w pracach [3,9]. Zasadniczą jej część stanowi przezroczysta rura z metapleksu o długości 4,5 m, na której umieszczony jest zestaw radiometryczny złożony z liniowego źródła promieniowania gamma Am-241 o aktywności 100 mCi i energii 59,5 keV oraz detektora scyntylicyjnego NaI(Tl).

Regulacja prędkości przepływu wody w instalacji i odpowiednie dozowanie powietrza pozwala na uzyskiwanie różnych struktur przepływu ciec-gaz w odcinku pomiarowym rurociągu. Przykłady trzech analizowanych struktur pokazano na rysunku 2.

Analiza sygnałów

Analiza sygnałów z detektora scyntylicyjnego umożliwia wyznaczenie kilku parametrów przepływu dwufazowego, m.in. średniej prędkości fazy rozproszonej, objętościowego natężenia przepływu, współczynnika wypełnienia rurociągu gazem oraz na rozpoznawanie struktury przepływu.

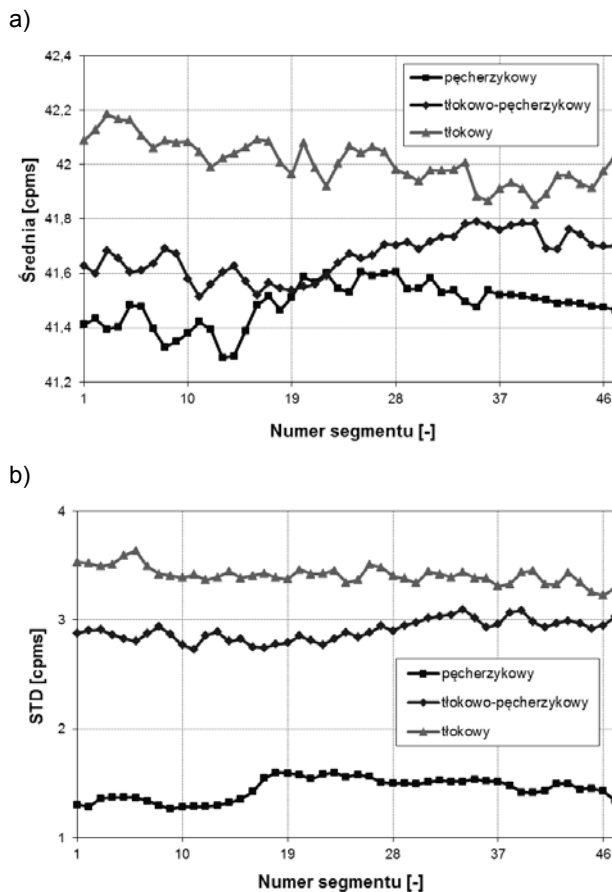
W pracy analizowano sygnały o długości 480 s (liczba próbek $N = 480\ 000$) zgodnie z algorytmem przedstawionym na rysunku 3. W górnej części tego rysunku pokazano przykładowy sygnał z detektora dla przepływu pęcherzykowego. W pierwszym etapie analizy sygnały uzyskane dla trzech typów przepływu (rys. 2) dzielono na częściowo nakładające się segmenty o liczności 20 000 próbek, które wygładzane były następnie przy zastosowaniu średniej ruchomej. Eksperymentalnie stwierdzono, że najlepszą separację cech dla badanych przepływów uzyskano dla nakładania 50% i prostokątnego okna uśredniającego o długości 20 próbek. Otrzymano w ten sposób 47 rekordów danych dla jednego sygnału. Następnie dla każdego sygnału i każdego rekordu wyznaczano zestawy dziewięciu cech (parametrów) charakterystycznych. Były to następujące parametry: wartość średnia, wariancja, odchylenie standardowe, momenty 3 i 4 rzędu, kurtoza, skośność, RMS i wartość funkcji autokorelacji dla wybranego argumentu [10,11]. Odpowiednie skrypty do przetwarzania sygnałów napisano w programie MATLAB. Przykładowo na rysunku 4 pokazano wartości średnie i odchylenia standardowe w funkcji numeru segmentu danych, uzyskane dla trzech analizowanych typów przepływu ciec-gaz.

Identyfikacja struktury przepływu

Do rozpoznawania struktury przepływu wybrano trzy metody SI: sieć neuronową MLP, metodę K-średnich i algorytm wektorów wspierających SVM. Metody te są szczegółowo opisane w literaturze, np. [12,13], dlatego poniżej podano tylko ich krótką charakterystykę.

- MLP jest jednokierunkową wielowarstwową siecią neuronową. Składa się z trzech warstw: wejściowej, ukrytej oraz wyjściowej. Ze względu na charakter danych, liczba neuronów w warstwie wejściowej i wyjściowej wynosi odpowiednio 9 i 4. Liczbę neuronów w warstwie ukrytej dobierano eksperymentalnie z przedziału $\{2,3,\dots,10\}$. Do aktywacji wszystkich neuronów użyto logistycznej funkcji przejścia. Sieć MLP uczono za pomocą algorytmu gradientów sprzężonych.
- Metoda K-średnich wykorzystana jest w niniejszej pracy jako klasyfikator. Wykorzystuje do tego celu algorytm klasteryzacji, który polega na podziale danych na K grup na podstawie podobieństwa atrybutów. Dzięki temu wyznaczone jest K środków. Dane wejściowe znajdujące się najbliższe środka przypisywane są do grupy, którą ten środek reprezentuje. Daje to możliwość przeprowadzenia procesu klasyfikacji i predykcji. W pracy parametr K dobierany był z przedziału $\{2,3,\dots,45\}$.

- SVM jest algorytmem do klasyfikacji danych dwóch klas. Jako rezultat podaje on zbiór wektorów wspierających, które tworzą równanie optymalnej hiperpłaszczyzny separującej dane wejściowe. Poprzez odpowiednie funkcje jądra, algorytm SVM może być wykorzystywany w klasyfikacji danych liniowo i nieliniowo separowalnych. W niniejszej pracy jako funkcje jądra zaproponowano funkcję Gaussa. Aby rozwiązać problem separowalności trzech klas, zastosowano metodę jeden-przeciw-jednemu.



Rys. 4. Wartości średnie (a) i odchylenia standardowe (b) sygnałów z sondy scyntylicyjnej dla trzech typów przepływu w funkcji numeru segmentu danych

W niniejszej pracy wszystkie procesy klasyfikacji zostały wykonane przy zastosowaniu oprogramowania DTREG [14]. Dla każdej z wybranych metod przeprowadzona została walidacja krzyżowa. Uzyskano jednakowe i bardzo dobre wyniki klasyfikacji dla wszystkich trzech zastosowanych metod. Przedstawiono je w postaci macierzy pomyłek dla zbiorów testujących i walidacyjnych (tabele 1 i 2). Przyjęto następujące oznaczenia: Klasa 1 – przepływ łukowy, Klasa 2 – przepływ łukowo-pęcherzykowy, Klasa 3 – przepływ pęcherzykowy.

Tabela 1. Macierz pomyłek dla wszystkich trzech badanych metod SI (testowanie)

Stan aktualny	Predykcja		
	Klasa 1	Klasa 2	Klasa 3
Klasa 1	47	0	0
Klasa 2	0	47	0
Klasa 3	0	0	47

Tabela 2. Macierz pomyłek dla wszystkich trzech badanych metod SI (walidacja)

Stan aktualny	Predykcja		
	Klasa 1	Klasa 2	Klasa 3
Klasa 1	47	0	0
Klasa 2	0	47	0
Klasa 3	0	0	47

Następnie wyznaczono wskaźniki: dokładność (*Dok*), czułość (*Czul*), oraz specyficzność (*Spec*) ze wzorów [12]:

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

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

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

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 tabeli 3.

Tabela 3. Dokładność, czułość i specyficzność dla badanych metod

Parametr \ Metoda	Klasa 1			Klasa 2			Klasa 3		
	Dok	Czul	Spec	Dok	Czul	Spec	Dok	Czul	Spec
K-Śr	1	1	1	1	1	1	1	1	1
MLP	1	1	1	1	1	1	1	1	1
SVM	1	1	1	1	1	1	1	1	1

Podsumowanie

W artykule przedstawiono możliwość wykorzystania metody absorpcji promieniowania gamma w połączeniu z metodami sztucznej inteligencji do identyfikacji struktury przepływu ciecz-gaz w rurociągu poziomym. Badania przeprowadzono dla trzech typów przepływów: tłokowego, tłokowo-pęcherzykowego i pęcherzykowego. Na podstawie analizy sygnału z detektora scyntylicyjnego w dziedzinie czasu wyodrębniono dziewięć parametrów zastosowanych następnie jako predyktory dla trzech wybranych metod SI (MLP, K-średnich, SVM). Dla wszystkich analizowanych metod uzyskano bardzo dobre wyniki klasyfikacji - 100% poprawnie rozpoznanych struktur przepływu. Potwierdzają to wyznaczone wskaźniki: dokładność, czułość oraz specyficzność. Otrzymane wyniki klasyfikacji można wykorzystać w radioizotopowych badaniach przepływów dwufazowych ciecz-gaz, gdzie zwykle wyznacza się prędkości i objętości poszczególnych składników mieszaniny. Możliwość określania struktury przepływu jest dodatkową informacją, uzyskiwaną z tych samych sygnałów pomiarowych, istotną np. w przemysłowych procesach przepływowych. Badania przedstawione w tej pracy można kontynuować, stosując analizę sygnałów pomiarowych w dziedzinie częstotliwości czy wykorzystując inne metody SI do klasyfikacji [15-19].

Autorzy: dr hab. inż. Robert Hanus, dr inż. Maciej Kusy, Politechnika Rzeszowska, Wydział Elektrotechniki i Informatyki, al. Powstańców Warszawy 12, 35-959 Rzeszów. E-mail: rohan@prz.edu.pl, mkusy@prz.edu.pl; inż. Piotr Hanus (student), Politechnika Rzeszowska, al. Powstańców Warszawy 12, 35-959 Rzeszów. E-mail: piotrhanus90@gmail.com; dr 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] Dziubiński M., Prywer J., *Mechanika płynów dwufazowych*, WNT, Warszawa 2010
- [2] Falcone G., Hewitt G.F., Alimonti C., *Multiphase flow metering: principles and applications*, Elsevier, Amsterdam 2009
- [3] Petryka L., Hanus R., Zych M., Śleziak M., Radioizotopowe pomiary przepływów dwufazowych, *Przegląd Elektrotechniczny*, Vol. 86 (2010), nr. 5, 24-29
- [4] Powell R.L., Experimental techniques for multiphase flows, *Physics of Fluids*, Vol. 20 (2008), 040605
- [5] 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*, Vol. 62 (2015), 25–32
- [6] Nazemi E., Roshani G.H., Feghhi S.A.H., Setayeshi S., Eftekhari Zadeh E., Fatehi A., Optimization of a method for identifying the flow regime and measuring void fraction in a broad beam gamma-ray attenuation technique, *International Journal of Hydrogen Energy*, Vol. 41 (2016), 7438-7444
- [7] Roshani G.H., Nazemi E., Roshani M.M., Intelligent recognition of gas-oil-water three-phase flow regime and determination of volume fraction using Radial Basis Function, *Flow Measurement and Instrumentation*, Vol. 54 (2017), 39-45
- [8] Roshani G.H., Nazemi E., Feghhi S.A.H., Investigation of using 60Co source and one detector for determining the flow regime and void fraction in gas-liquid two-phase flows, *Flow Measurement and Instrumentation*, Vol. 50 (2016), 73–79
- [9] Petryka L., Zych M., Hanus R., Stanowisko do oceny metod pomiaru przepływu cieczy w rurociągu, *Pomiary Automatyka Kontrola*, Vol. 54 (2008), nr. 12, 863-865
- [10] Hanus P., Zastosowanie metod inteligencji obliczeniowej do rozpoznawania struktury przepływu dwufazowego. Praca dyplomowa inżynierska, Politechnika Rzeszowska, 2017
- [11] Hanus R., et al., Signals features extraction in liquid-gas flow measurements using gamma densitometry: Part 1: time domain, *EPJ Web of Conferences*, Vol. 114 (2016), 02035
- [12] Osowski S., *Metody i narzędzia eksploracji danych*, Wydawnictwo BTC, Legionowo 2013
- [13] Larose D.T., *Odkrywanie wiedzy z danych. Wprowadzenie do eksploracji danych*, PWN, Warszawa 2006
- [14] <https://www.dreg.com> (dostęp 2.01.2018)
- [15] Salgado C.M., Pereira C., Schirru R., Brandão L.E.B., Flow regime identification and volume fraction prediction in multiphase flows by means of gamma-ray attenuation and artificial neural networks, *Progress in Nuclear Energy*, Vol. 52 (2010), 555-562
- [16] Rosa E.S., Salgado R.M., Ohishi T., Mastelari N., Performance comparison of artificial neural networks and expert systems applied to flow pattern identification in vertical ascendant gas-liquid flows, *International Journal of Multiphase Flow*, Vol. 36, (2010), 738–754
- [17] Hanus R., et al., Application of ANN and PCA to two-phase flow evaluation using radioisotopes, *EPJ Web of Conferences*, Vol. 143 (2017), 02033
- [18] 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 Measurement and Instrumentation* (przyjęty do druku)
- [19] Zhou Y., Chen F., Sun B.: Identification method of gas-liquid two-phase flow regime based on image multi-feature fusion and support vector machine, *Chinese Journal of Chemical Engineering*, 16(6) (2008), 832-840