

## Application of artificial intelligence to estimate physical parameters of natural gas with hydrogen addition

# Zastosowanie sztucznej inteligencji do estymacji parametrów fizycznych gazu ziemnego z dodatkiem wodoru



DOI: 10.15199/62.2025.5.4

*The possibility of using selected machine learning models (multiple regression – MLR, random forest – RF, artificial neural network – ANN) to estimate phys. parameters (compressibility coeff.  $Z$ ,  $d$ , of the gas mixt., heat of combustion of the mixt.,  $H_2$  content in the mixt.) of natural gas describing its qual. was presented. The methodology assumed the use of a limited amt. of input data, which were collected at redn. and measurement stations, and used changes in gas temp. as a result of the Joule-Thompson effect, occurring during pressure redn. Models built on synthetic data show that the estimation of parameters such as the compressibility factor  $Z$  and gas  $d$ . can be very accurate.*

**Keywords:** natural gas, machine learning, hydrogen, thermodynamics

Przedstawiono możliwość wykorzystania wybranych modeli uczenia maszynowego do estymacji parametrów fizycznych gazu ziemnego, opisujących jego jakość, na podstawie której następuje rozliczanie się z odbiorcami. Obecnie często stosowane na szeroką skalę metody wykorzystują w tym celu założony skład gazu ziemnego oraz równania wirialne. Są przez to opatrzone pewną niedokładnością. Prezentowane rozwiązanie może być alternatywą. Metodologia zakładała użycie ograniczonej liczby danych wejściowych, które są zbierane na stacjach redukcyjno-pomiarowych oraz wykorzystywała zmiany temperatury gazu w wyniku efektu Joule'a i Thompsona, zachodzącego podczas redukcji ciśnienia. Modele stworzone na danych syntetycznych pokazują, że estymacja takich parametrów, jak współczynnik ściśliwości  $Z$  oraz gęstość gazu może być bardzo dokładna.

**Słowa kluczowe:** gaz ziemny, uczenie maszynowe, wódór, termodynamika

Dodatek wodoru do mieszaniny gazu ziemnego jest jedną z możliwości dekarbonizacji przemysłu gazowniczego<sup>1)</sup>. W Polsce produkcja zielonego wodoru dla szeroko rozumianej branży energetycznej może odbywać się z wykorzystaniem morskich farm wiatrowych<sup>2)</sup>. Jak pokazują badania, jego stężenie w zakresie do 8% mol. jest akceptowalne pod kątem bezpieczeństwa użytkowania, systemów pomiarowych oraz jakości dostarczanego paliwa<sup>3, 4)</sup>.

Innowacyjne rozwiązania z dziedziny uczenia maszynowego ML (*machine-learning*) coraz częściej znajdują

zastosowanie w przemyśle naftowo-gazowniczym<sup>5–7)</sup>. Wciąż rosnący popyt na gaz ziemny oraz wymogi odnośnie do bezpieczeństwa dostaw paliwa, sposobu rozliczania go z odbiorcami, czy też szeroko rozumianej zielonej transformacji energetycznej stawiają wiele wyzwań dla branży. W Polsce coraz więcej odbiorców korzysta z gazu po regazyfikacji LNG, a w przyszłości prawdopodobnie również z gazu ziemnego zawierającego domieszki biogazu oraz wodoru<sup>8)</sup>. Jednym z kluczowych warunków technicznych pozwalającym na zastosowanie tego typu rozwiązania na



Prof. dr hab. inż. Mariusz ŁACIAK (ORCID: 0000-0002-7450-7045) w roku 1986 ukończył studia na Wydziale Wiertnictwa, Nafty i Gazu AGH w Krakowie. W 1991 r. uzyskał stopień doktora, a w 2014 r. stopień doktora habilitowanego na tym samym wydziale. Od 2020 r. jest dziekanem na macierzystym wydziale. Specjalność – gazownictwo, energetyka gazowa i inżynieria środowiska.



Mgr inż. Wojciech PANEK (ORCID: 0009-0001-6405-4628) w roku 2020 ukończył studia na Wydziale Wiertnictwa, Nafty i Gazu AGH w Krakowie, gdzie obecnie jest doktorantem. Specjalność – gazownictwo, energetyka gazowa i inżynieria środowiska.

\* Adres do korespondencji:

Akademia Górniczo-Hutnicza im. Stanisława Staszica w Krakowie, al. Adama Mickiewicza 30, 30-059 Kraków, e-mail: wpanek@agh.edu.pl

szerszą skalę jest dokładne opomiarowanie parametrów przesyłanego paliwa. W literaturze naukowej coraz częściej można znaleźć artykuły opisujące zastosowanie uczenia maszynowego i algorytmów sztucznej inteligencji umożliwiających rozwiązanie problemów związanych z tym zagadnieniem.

Estymowane parametry są niezbędne w opomiarowaniu ilości energii dostarczanej do odbiorców. Zgodnie z obowiązującym w Polsce prawem<sup>9)</sup> ilość dostarczanego paliwa nie jest rozliczana w jednostkach objętości, a w ilości energii. Z tego względu każdy operator sieci przesyłowych oraz dystrybucyjnych jest zobligowany do zainstalowania odpowiedniej infrastruktury cyfrowej zdolnej do przeliczania tych wartości. Standardowe rozwiązania szeroko stosowane w polskiej branży gazowniczej wykorzystują równania stanu oraz przyjmują za zmienną wejściową do obliczeń zakładany skład gazu ziemnego<sup>10)</sup>, który może odbiegać od rzeczywistego. Założenie to może powodować pewną niedokładność wyników pomiarów.

Dodatek wodoru do składu mieszaniny gazu ziemnego wpływa na jego parametry fizyczne, takie jak gęstość, ciepło spalania i lepkość dynamiczna<sup>11)</sup>. Ponadto jego udział powyżej 10% mol. stwarza istotne problemy w opomiarowaniu dostarczanej energii<sup>3)</sup>. Kolejnym problemem technicznym związanym z użytkowaniem wodoru jest jego wysoka dyfuzyjność i możliwość przenikania przez materiały obecnie stosowane w tradycyjnym osprzęcie stacji redukcyjno-pomiarowych, jak i w samych gazociągach<sup>12)</sup>. Z powodu zmniejszonej gęstości i lepkości dynamicznej wodoru transport gazu, który go zawiera, cechuje się innymi parametrami niż gaz ziemny<sup>13)</sup>.

Warto zaznaczyć, że dodatek wodoru do gazu ziemnego powoduje zmniejszenie współczynnika Joule'a i Thompsona w miarę zwiększenia jego udziału w mieszaninie. Wpływa to na mniejszy spadek temperatury podczas izentalpowego rozprężania gazu, które zachodzi podczas redukcji jego ciśnienia na stacjach redukcyjno-pomiarowych<sup>14)</sup>. Zmiana ta jest jednak mała w porównaniu z czystym gazem ziemnym<sup>11)</sup>.

Istotnym problemem, na który zwracano uwagę w publikacjach naukowych, jest możliwa niedokładność opomiarowania parametrów jakościowych gazu ziemnego zawierającego w swoim składzie wódór. Niektóre z nich oznaczane są na podstawie analizy równań wirialnych, takich jak AGA8, SGERG 88 oraz GERG-2008 pod kątem ich stosowalności, w odniesieniu do udziału wodoru w składzie mieszaniny gazu ziemnego<sup>15)</sup>.

Wykorzystanie algorytmów sztucznej inteligencji do estymacji wybranych parametrów gazu ziemnego jest badane od wielu lat<sup>16)</sup>. Wykorzystując sztuczne sieci neuronowe ANN (*artificial neural network*), można przewidywać z dużą dokładnością<sup>17)</sup> m.in. współczynnik ściśliwości gazu  $Z$ .

Wiele publikacji wskazuje na możliwość przewidywania parametrów jakościowych gazu ziemnego w wybranych

punktach sieci za pomocą algorytmów sztucznej inteligencji na podstawie danych historycznych<sup>18)</sup>.

Innym podejściem do estymacji parametrów fizycznych gazu ziemnego za pomocą algorytmów sztucznej inteligencji jest oparcie ich procesu trenowania na danych opisujących zjawisko Joule'a i Thompsona zachodzące na stacjach redukcyjno-pomiarowych.

Kolejnym rozwiązaniem było zaimplementowanie zaawansowanych algorytmów, takich jak ANFIS-GA i MLFFN, łączących algorytmy sztucznej inteligencji oraz algorytmy genetyczne. Estymowano nimi gęstość gazu ziemnego i jego współczynnik ściśliwości, przyjmując za dane wejściowe odczyty ze stacji redukcyjno-pomiarowej wyposażonej w chromatograf<sup>19)</sup>. Wyniki tej pracy wskazują na bardzo wysoką dokładność estymacji oraz pokazują korzyści płynące z wykorzystania tego typu rozwiązania.

W innych publikacjach przedstawiono rozwiązania, które wykorzystywały syntetyczne dane reprezentujące podstawowe parametry gazu ziemnego, które można mierzyć na stacjach redukcyjno-pomiarowych. Posłużyły one do wytrenowania ANN, pozwalających precyzyjnie estymować współczynnik ściśliwości gazu  $Z$ . W pracy wskazano na różnice w dokładności analiz, w zależności od założonego składu gazu ziemnego<sup>20)</sup>. Ponadto stosując podobne podejście, wykorzystujące zjawisko Joule'a i Thompsona oraz sztuczną inteligencję, można z powodzeniem przewidywać gęstość gazu ziemnego<sup>21)</sup>.

Celem pracy było przedstawienie możliwości zastosowania algorytmów sztucznej inteligencji do estymacji wybranych parametrów fizycznych gazu ziemnego na podstawie odczytów z podstawowych przyrządów pomiarowych, które są najczęściej zainstalowane na stacjach redukcyjno-pomiarowych (zarówno I, jak i II stopnia)<sup>9)</sup> oraz charakterystyki zmiany temperatury gazu ziemnego podczas procesu redukcji ciśnienia przepływającego gazu.

## Część badawcza

### Metodyka badań

Przegląd literaturowy wskazuje na możliwość zastosowania uczenia maszynowego do dokładnej estymacji współczynnika ściśliwości gazu  $Z$  oraz innych właściwości termodynamicznych gazu ziemnego, stosując zarówno modele wytrenowane na danych przemysłowych, jak i syntetycznych.

Podczas badań skupiono się na odwzorowaniu tego typu rozwiązań, z uwzględnieniem charakterystyki polskiej branży gazowniczej. Dodatkowo sprawdzono, jak dodatek wodoru do składu mieszaniny gazowej wpływa na dokładność estymacji wybranych parametrów fizycznych gazu ziemnego za pomocą algorytmów uczenia maszynowego.

W pracy wzięto pod uwagę kilka kluczowych parametrów fizycznych gazu ziemnego. Pierwszym z nich był współczynnik ściśliwości  $Z$ . Opisuje on odstępstwo zachowania i parametrów mieszaniny gazu w zadanych warunkach od

warunków normalnych<sup>22)</sup>. Może być on wyznaczany za pomocą równań wirialnych, takich jak szeroko stosowane modele SGERG88, GERG2008 i AGA8<sup>23, 24)</sup>. Kolejnym estymowanym parametrem była gęstość mieszaniny gazowej, opisująca masę gazu w danej objętości<sup>23)</sup>. Następnym parametrem było ciepło spalania mieszaniny gazu ziemnego, opisujące ilość energii, którą można pozyskać ze spalania 1 m<sup>3</sup> mieszaniny<sup>25)</sup>. Ostatnim parametrem była zawartość wodoru w składzie mieszaniny gazu. Jego wartość wahała się w przedziale 0–10% mol.<sup>3)</sup>.

## Przygotowanie danych

Kolejnym krokiem w pracy badawczej było przygotowanie zbioru danych uczących. Ze względu na brak dostatecznych danych przemysłowych opisujących charakterystykę zmiany temperatury gazu ziemnego zawierającego w swoim składzie wodór, w procesie redukcji jego ciśnienia na stacji redukcyjno-pomiarowej wykorzystano dane syntetyczne. W tym celu w sposób losowy z zachowaniem pewnych zasad wyznaczono parametry odzwierciedlające charakterystykę pracy polskiej sieci przesyłowej. Zasady losowego generowania warunków oraz poszczególnych składników mieszaniny gazu ziemnego przedstawiały się następująco: (i)  $P_1$  – przedział 4,8–8,4 MPa; (ii)  $P_2$  – przedział 0,27–0,6 MPa; (iii)  $T_1$  – przedział 303–315 K; (iv)  $CH_4$  – 85–92% mol.; (v)  $C_2H_6$  – 0–5% mol.; (vi)  $N_2$  – 0,1–14% mol., (vii)  $H_2$  – 0,0–10% mol.; (viii)  $C_3H_8$  – dopełnienie do 100% mol.

Przedziały zostały dobrane w taki sposób, aby w jak najdokładniejszym stopniu odwzorować warunki pracy polskiego systemu gazowego, zgodnie z przyjętym prawem w Polsce i standardami inżynierskimi oraz tak, aby uwzględnić w nich dodatek wodoru<sup>22, 26)</sup>.

Dane wygenerowane miały za zadanie jak najdokładniej odwzorować warunki przemysłowe pracy stacji redukcyjno-pomiarowych I stopnia, będących punktami pomiędzy sieciami wysokiego i średniego ciśnienia, zasilanych gazem o parametrach zbliżonych do gazu ziemnego typu E, w którego składzie może występować wodór. Założono pewien margines błędu dla wartości ciśnień oraz brak zastosowania dodatkowego podgrzewania przepływającego gazu. Dane wygenerowane miały jednostajny ciągły rozkład i zostały zapisane do pliku \*.xlsx w celu dalszego procesowania. Ich objętość wynosiła 30 tys. wierszy, zawierających wygenerowane udziały molowe poszczególnych składników

gazu ziemnego, ciśnienie oraz temperaturę przed redukcją i ciśnienie docelowe.

## Obliczanie współczynnika ściśliwości $Z$ oraz współczynnika Joule'a i Thompsona

W celu dopełnienia zbioru uczącego odpowiadającego charakterystyce pracy stacji redukcyjno-pomiarowej, za pomocą równania stanu Penga i Robinsona obliczono temperaturę po redukcji, na podstawie zjawiska Joule'a i Thompsona. Do obliczeń wykorzystano metodę różniczkową<sup>27)</sup>. Dla każdej próbki wyznaczono również gęstość gazu oraz jego ciepło spalania. Przykładowe dane stosowane do nauki modeli przedstawiono w tabeli 1.

## Analiza danych uczących

Po wygenerowaniu zbioru uczącego dane zostały przeanalizowane. W tym celu wykorzystano macierz korelacji oraz mapę ciepła (*heat map*). Wynika z niej m.in., że największy wpływ na zmienność ciepła spalania gazu ma molowa zawartość propanu w jego składzie. Współczynnik ściśliwości gazu  $Z$  charakteryzuje się współczynnikiem korelacji  $R^2$  z ciśnieniem po redukcji równym 0,81, a gęstość gazu współczynnikiem korelacji  $R^2$  z ciśnieniem po redukcji wynoszącym 0,71. Molowa zawartość wodoru w składzie mieszaniny gazowej nie wykazuje znaczących korelacji z jakąkolwiek zmienną.

Omawiając podstawowe parametry statystyki wygenerowanego zbioru uczącego, warto zwrócić uwagę na duże odchylenie standardowe ciepła spalania (68,21) oraz temperatury po redukcji ciśnienia (24,43). Pokazuje to, że relatywnie małe zmiany w składzie gazu ziemnego, w przypadku ciepła spalania, mają znaczący wpływ na jego wartość. Zmienne te nie były generowane, lecz obliczane.

## Nauka modeli uczenia maszynowego

W celu estymacji współczynnika ściśliwości  $Z$ , gęstości, wartości opałowej oraz udziału molowego wodoru w składzie mieszaniny gazu ziemnego wytrenowano wiele popularnych algorytmów uczenia maszynowego, takich jak regresja wieloraka MLR (*multiple regression*)<sup>27–29)</sup>, las losowy RF (*random forest*)<sup>30)</sup> oraz sztuczna sieć neuronowa ANN<sup>31)</sup>. Następnie przeprowadzono walidację wyników określonych przez te algorytmy z danymi testo-

Table 1. Example values of data used for learning

Tabela 1. Przykładowe dane stosowane do nauki modeli

| $T_1$ ,<br>K | $P_1 M$ ,<br>Pa | $P_2 M$ ,<br>Pa | $T_2$ ,<br>K | $N_2$ ,<br>% mol. | $CH_4$ ,<br>% mol. | $C_2H_6$ ,<br>% mol. | $C_3H_8$ ,<br>% mol. | $H_2$ ,<br>% mol. | Gęstość,<br>kg/mol | Ciepło<br>spalania,<br>kJ/mol | $Z$  |
|--------------|-----------------|-----------------|--------------|-------------------|--------------------|----------------------|----------------------|-------------------|--------------------|-------------------------------|------|
| 308,46       | 7,93            | 0,33            | 208,56       | 9,26              | 85,77              | 1,47                 | 1,53                 | 1,97              | 0,0038             | 825,95                        | 0,87 |
| 307,43       | 6,08            | 0,28            | 222,83       | 8,79              | 86,41              | 0,54                 | 3,06                 | 1,19              | 0,0030             | 848,94                        | 0,89 |
| 305,20       | 4,82            | 0,27            | 240,72       | 8,56              | 86,93              | 1,84                 | 0,18                 | 2,50              | 0,0025             | 813,40                        | 0,92 |
| 307,46       | 5,98            | 0,27            | 225,04       | 8,70              | 88,50              | 1,23                 | 0,91                 | 0,67              | 0,0028             | 828,83                        | 0,90 |
| 308,72       | 6,04            | 0,27            | 224,49       | 9,61              | 86,00              | 0,97                 | 2,51                 | 0,92              | 0,0029             | 838,81                        | 0,89 |

wymi i walidacyjnymi, określono dokładność estymacji za pomocą opisanego średniego procentowego błędu bezwzględnego MAPE (*mean absolute percentage error*) oraz współczynnika korelacji Pearsona ( $R^2$ ). Na koniec porównano wyniki dokładności przewidywania poszczególnych algorytmów. Każdorazowo zbiór danych był w sposób losowy dzielony na zbiór uczący (70%), testowy (20%) i walidacyjny (10%)<sup>32</sup>.

Z uwagi na to, że na większości stacji redukcyjno-pomiarowych mierzone są tylko 4 podstawowe parametry, takie jak ciśnienie i temperatura przed i po redukcji ciśnienia, to w celu rozszerzenia zbioru uczącego zastosowano tzw. *stacking*. Modele z kolejnych kroków badań przed rozpoczęciem nauki estymowały za pomocą wytrenowanych modeli z kroków poprzednich ich wartości wyjściowe i dopisywały do zbioru uczącego używanego w danej iteracji.

Algorytm opisujący działanie programu można przedstawić w następujący sposób:

Dla każdego modelu z listy [MLR, RF, ANN]:

1. Załaduj dane reprezentujące wartości mierzone na stacjach redukcyjno-pomiarowych [ $T_1, T_2, P_1, P_2$ ] jako zmienne wejściowe
2. Wytrenuj oraz dokonaj walidacji modelu do estymacji współczynnika ściśliwości  $Z$
3. Wybierz najdokładniejszy model
4. Jeśli współczynnik  $R^2 > 0,9$  i  $MAPE < 1,5$  dla walidacji najlepszego modelu, to przewiduj współczynnik ściśliwości  $Z$  dla każdego zestawu danych za pomocą najlepszego modelu i dopisuj go do zbioru uczącego. Jeśli współczynnik  $R^2 < 0,9$  i  $MAPE > 1,5$  dla walidacji najlepszego algorytmu, to poinformuj użytkownika o konieczności dostosowania modelu i przerwij program

$$T_1, P_1, T_2, P_2 \rightarrow Z$$

5. Załaduj zaktualizowany zbiór uczący, zawierający oprócz danych użytych do nauki w kroku poprzednim, przewidziany współczynnik ściśliwości gazu  $Z$
6. Wytrenuj oraz dokonaj walidacji algorytmu do estymacji gęstości gazu
7. Wybierz najlepszy model
8. Jeśli współczynnik  $R^2 > 0,9$  i  $MAPE < 1,5$  dla walidacji najlepszego modelu, to przewiduj gęstość gazu dla każdego zestawu danych za pomocą najlepszego modelu i dopisuj go do zbioru uczącego. Jeśli współczynnik  $R^2 < 0,9$  i  $MAPE > 1,5$  dla walidacji najlepszego modelu, to poinformuj użytkownika o konieczności dostosowania modelu i przerwij program

$$T_1, P_1, T_2, P_2, Z_{est} \rightarrow \text{gęstość}$$

9. Załaduj zaktualizowany zbiór uczący, zawierający oprócz danych użytych do nauki w kroku poprzednim przewidzianą gęstość gazu
10. Wytrenuj oraz dokonaj walidacji algorytmu do estymacji wartości ciepła spalania gazu

11. Wybierz najlepszy model

12. Jeśli współczynnik  $R^2 > 0,9$  i  $MAPE < 1,5$  dla walidacji najlepszego modelu, to przewiduj ciepło spalania dla każdego zestawu danych za pomocą najlepszego modelu i dopisuj go do zbioru uczącego. Jeśli współczynnik  $R^2 < 0,9$  i  $MAPE > 1,5$  dla walidacji najlepszego modelu, to poinformuj użytkownika o konieczności dostosowania modelu i przerwij program

$$T_1, P_1, T_2, P_2, Z_{est}, \text{gęstość}_{est} \rightarrow \text{ciepło spalania}$$

13. Załaduj zaktualizowany zbiór uczący, zawierający oprócz danych użytych do nauki w kroku poprzednim, przewidziane ciepło spalania gazu

14. Wytrenuj oraz dokonaj walidacji algorytmu do estymacji udziału molowego wodoru w składzie mieszaniny gazu

$$T_1, P_1, T_2, P_2, Z_{est}, \text{gęstość}_{est}, \text{ciepło spalania}_{est} \rightarrow \% \text{ mol. H}_2$$

15. Przedstaw wyniki estymacji w formie graficznej i tabelarycznej oraz zapisz najlepsze modele dla każdego typu zmiennej estymowanej.

Liczba warstw i neuronów w sztucznych sieciach neuronowych została dobrana metodą prób i błędów. Jako optymalizator (*optimizer*) sieci wykorzystano algorytm Adam, jako funkcję błędu (*loss function*) błąd średnio kwadratowy MSE (*mean square error*), funkcję aktywacji neuronów w warstwach ukrytych ReLu (*rectified linear units*), a w warstwie wynikowej funkcję liniową.

## Wyniki badań i ich omówienie

Do oceny dokładności estymacji wybranych parametrów gazu ziemnego posłużono się dwoma obliczanymi zmiennymi: współczynnikiem korelacji Pearsona ( $R^2$ ) oraz średnim bezwzględnym błędem procentowym (MAPE). Są to parametry szeroko wykorzystywane do tego typu zadań<sup>33, 34</sup>.

Przewidywanie współczynnika ściśliwości  $Z$  charakteryzowało się wysokim współczynnikiem korelacji ( $R^2 = 0,99$ ), jak pokazano na rys. 1, oraz niskim średnim bezwzględnym




Fig. 1. Compressibility factor of natural gas  $Z$ , real vs. predicted;  $R^2 = 0,99$ , model ANN

Rys. 1. Współczynnik ściśliwości gazu  $Z$  rzeczywisty vs. przewidziany;  $R^2 = 0,99$ , model ANN




Fig. 2. Natural gas density, real vs. predicted;  $R^2 = 0.99$ , model ANN

Rys. 2. Gęstość gazu rzeczywista vs. przewidziana;  $R^2 = 0.99$ , model ANN




Fig. 3. Calorific value, real vs. predicted;  $R^2 = 0.92$ , model ANN

Rys. 3. Ciepło spalania rzeczywiste vs. przewidziane;  $R^2 = 0.92$ , model ANN




Fig. 4. Hydrogen content in natural gas mix, real vs predicted;  $R^2 = 0.74$ , model RF

Rys. 4. Zawartość wodoru w składzie gazu rzeczywista vs przewidziana;  $R^2 = 0.74$ , model RF

Table 2. Results of prediction accuracy for each of the predicted parameters of natural gas

Tabela 2. Wyniki dokładności predykcji poszczególnych parametrów gazu ziemnego

| Najlepszy model | Zmienna estymowana                              | Liczba zmiennych użytych do estymacji | Współczynnik korelacji Pearsona $R^2$ | MAPE |
|-----------------|-------------------------------------------------|---------------------------------------|---------------------------------------|------|
| ANN             | współczynnik ściśliwości $Z$                    | 4                                     | 0,99                                  | 0,08 |
| ANN             | gęstość                                         | 5                                     | 0,99                                  | 1,34 |
| ANN             | ciepło spalania                                 | 6                                     | 0,92                                  | 0,43 |
| RF              | udział molowy wodoru w składzie mieszaniny gazu | 7                                     | 0,74                                  | 21,8 |

błędem procentowym (MAPE = 0,08) dla najlepszego modelu, jakim jest ANN. Model był szkolony przez 50 epok, a architektura sieci opierała się na 3 warstwach ukrytych, z których każda zawierała po 32 neurony. Na wykresach przedstawiono graficznie wyniki uzyskane przez algorytmy uczenia maszynowego, czyli wartości estymowane dla poszczególnych właściwości gazu ziemnego oraz wartości rzeczywiste, których użyto do ich walidacji (część z wygenerowanego zbioru danych, która nie była użyta do tworzenia modelu). Celem prezentacji graficznej tych wyników było częściowe sprawdzenie dokładności estymacji.

Sieć o tych samych hiperparametrach (*hyperparameters*) zastosowano do nauki i przewidywania gęstości oraz ciepła spalania gazu. Obydwa oszacowania charakteryzowały się wysokim stopniem dokładności, a współczynniki korelacji Pearsona  $R^2$  wynosiły odpowiednio 0,99 i 0,92, jak pokazano na rys. 2 i 3. MAPE dla gęstości był wyższy i wyniósł 1,34, natomiast dla ciepła spalania 0,43.

Model RF wykazał największą dokładność predykcji szacowania zawartości wodoru w mieszaninie gazowej spośród wszystkich trzech testowanych modeli. Dokładność nie była jednak tak wysoka, jak w przypadku wcześniejszych parametrów, gdyż współczynnik korelacji Pearsona  $R^2$  wyniósł 0,74, co pokazano na rys. 4, a MAPE 21,8.

W tabeli 2 przedstawiono zbiorcze wyniki pracy.

## Podsumowanie

W trakcie badań stworzono zbiór danych uczących, wygenerowany losowo w sposób kontrolowany, tak

aby odzwierciedlał warunki przemysłowe oraz wytrenowano i porównano różne modele uczenia maszynowego (ML). Zastosowano uczenie nadzorowane, tzn. takie, w którym algorytmy podczas nauki dostosowywały swoje parametry w celu zminimalizowania błędu pomiędzy zmienną estymowaną, będącą wynikiem końcowym algorytmu (*predicted value*) na podstawie zmiennych opisujących (*input value*), a rzeczywistą wartością zmiennej opisującej (*target value*)<sup>7)</sup>.

Estymacja współczynnika ściśliwości *Z* gazu zawierającego w swoim składzie wodor za pomocą danych reprezentujących odczyty z podstawowych przyrządów pomiarowych zainstalowanych na stacjach redukcyjno-pomiarowych oraz odpowiedniego algorytmu uczenia maszynowego była bardzo dokładna. Dokładność predykcji była zbliżona do wyników uzyskanych w pracach o podobnej tematyce, stosujących podobne algorytmy uczenia maszynowego<sup>35)</sup>, pomimo rozpatrywania mniejszej liczby zmiennych uczących. Należy jednak podkreślić, że w badaniu w składzie gazu ziemnego uwzględniono również dodatek wodoru.

Sztuczna sieć neuronowa okazała się być najdokładniejszym algorytmem do predykcji współczynnika ściśliwości gazu *Z*, gęstości gazu oraz ciepła spalania.

Udział molowy wodoru w składzie mieszaniny gazu ziemnego był najdokładniej przewidywany przez algorytm RF. Wysoki błąd MAPE oraz stosunkowo niski współczynnik korelacji Pearsona *R*<sup>2</sup> pomiędzy danymi rzeczywistymi a przewidzianymi pokazuje, że sposób określania udziału molowego wodoru zaprezentowany w pracy wymaga dopracowania, gdyż wyniki nie są użyteczne.

Otrzymano: 16-04-2025                      Zrecenzowano: 22-04-2025  
Zaakceptowano: 06-05-2025              Opublikowano: 19-05-2025

LITERATURA

[1] P. Martin i in., *Energy Sci. Eng.* 2024, **12**, 3995.  
[2] K. Ligeza, M. Łaciak, B. Ligeza, *Energies* 2023, **16**, 6301.  
[3] J. Jaworski i in., *Nafta-Gaz* 2019, **10**, 625.

[4] A. Jedlikowski i in., *Gaz Woda Tech. Sanitarna* 2023, nr 12, 10.  
[5] D. Koroteev, Z. Tekic, *Energy AI* 2021, **3**, 100041.  
[6] F.I. Syed i in., *J. Petroleum Explor. Prod. Technol.* 2021, **11**, 3509.  
[7] W. Panek, T. Włodek, *Energies* 2022, **15**, 348.  
[8] J. Grzegorzewska, W. Grządziński, T.M. Mróz, *Instal* 2014, **6**, 10.  
[9] Rozporządzenie Ministra Gospodarki z dnia 26 kwietnia 2013 r. w sprawie warunków technicznych, jakim powinny odpowiadać sieci gazowe i ich usytuowanie, *Dz.U.* 2013, poz. 640.  
[10] Certyfikat badania typu WE PL-MI002-1450CQ0001, Instytut Nafty i Gazu, 2015.  
[11] T. Włodek, K. Polański, W. Panek, *Przem. Chem.* 2019, **98**, nr 5, 817.  
[12] A. Raj i in., *Int. J. Hydrogen Energy* 2024, **60**, 136.  
[13] Ł. Zabrzęski, P. Janusz, K. Liszka, M. Łaciak, A. Szurlej, *Mat. Międzynarodowej Konf. „International Conference on the Sustainable Energy and Environmental Development”*, Kraków, 14–17 listopada 2017 r., 214.  
[14] J. Li, Y. Su, P. Weng, D. Sun, *ACS Omega* 2021, **6**, 26.  
[15] M. Farzaneh-Gord, M. Farsiani, A. Arabkoohsar, *J. Nat. Gas Sci. Eng.* 2015, **26**, 1018.  
[16] S. Nuthakki, C. Kulkarni Shripad, S. Kathiriya, Y. Nuthakki, *Int. J. Eng. Adv. Tech. (IJEAT)* 2024, **13**, 3.  
[17] M. Farzaneh-Gord i in., *J. Petrol. Sci. Eng.* 2021, **202**, 108427.  
[18] J. Szopik, P. Muchel, *Energy* 2023, **12**, 263.  
[19] J. Hu, Z. Yang, H. Su, *Energies* 2023, **16**, 2.  
[20] A. Ghanem, M.F. Gouda, R.D. Alharathy, S.M. Desouky, *Energies* 2022, **15**, 5.  
[21] A. Khosravi, L. Machado, R.O. Nunes, *J. Petrol. Sci. Eng.* 2018, **168**, 201.  
[22] Rozporządzenie Ministra Klimatu i Środowiska z dnia 6 sierpnia 2022 r. zmieniające rozporządzenie w sprawie szczegółowych warunków funkcjonowania systemu gazowego, *Dz.U.* 2022, poz. 1899.  
[23] C. Wang, A. Jia, Z. Guo, S. Huang, X. Shi, F. Cui, *Energies* 2023, **16**, 105.  
[24] M. Farzaneh-Gord, B. Mohseni-Gharyehsafa, A. Toikka, I. Zvereva, *J. Nat. Gas Sci. Eng.* 2018, **57**, 310.  
[25] P. Ulbig, D. Hoburg, *Thermochim. Acta* 2002, **328**, 27.  
[26] Obwieszczenie Ministra Energii z dnia 16 maja 2018 r. w sprawie ogłoszenia jednolitego tekstu rozporządzenia Ministra Gospodarki w sprawie szczegółowych warunków funkcjonowania systemu gazowego, *Dz.U.* 2018, poz. 1158.  
[27] R.M. Pratt, *Chem. Eng. Edu.* 2001, **35**, 112.  
[28] L. Fahrmeir, T. Kneib, S. Lang, B. Marx, *Regression. Models, methods and applications*, Springer, Berlin 2013.  
[29] M. Pal, P. Bharati, *Introduction to correlation and linear regression analysis [in:] Applications of regression techniques*, Springer, Berlin 2019.  
[30] L. Breiman, *Machine Learning* 2001, **45**, 5.  
[31] A.F. Agarap, *arXiv* 2019, 1803.08375.  
[32] A. Saha, V.C. Raykar, *Mat. Międzynarodowej Konf. „ECML-PKDD”*, Porto, 7–11 września 2015 r., 9284.  
[33] T. Hastie, R. Tibshirani, J. Freidman, *The elements of statistical learning*, Springer, Berlin 2009.  
[34] J. Gareth, D. Witten, T. Hastie, R. Tibshirani, J. Taylor, *An introduction to statistical learning with applications in Python*, Springer, Berlin 2023.  
[35] M. Farzaneh-Gord i in., *Renew. Energy* 2019, **147**, 179.

KALENDARZ WYDARZEŃ W 2025 R.

| Miesiąc  | Data      | Wydarzenie                                                                                                                      | Miejsce  | Organizator                 |
|----------|-----------|---------------------------------------------------------------------------------------------------------------------------------|----------|-----------------------------|
| Maj      | 27.05.    | XIV Międzynarodowa Konferencja Przemysłu Detergentowego                                                                         | Warszawa | EPS Media                   |
|          | 28.05.    | I Międzynarodowa Konferencja Przemysłu Kosmetycznego                                                                            | Warszawa | EPS Media                   |
|          | 29–30.05. | XII Kongres Polska Chemia                                                                                                       | Kraków   | PIPC                        |
| Czerwiec | 9–11.06.  | Spotkanie Polonijnych i Polskich Inżynierów<br>VI Światowy Zjazd Inżynierów Polskich<br>XXVIII Kongres Techników Polskich       | Poznań   | NOT, Politechnika Poznańska |
|          | 3–5.06.   | 18. Międzynarodowe Targi Wynałazków i Innowacji<br>INTARG®<br>Międzynarodowe Targi Ekologii i Ochrony Środowiska<br>INTARG® EKO | Katowice | Eurobusiness – Haller       |
| Lipiec   | 1–4.07.   | Polska Konferencja Chemii Analitycznej PoKoCha 2025                                                                             | Gdańsk   | Politechnika Gdańska        |
| Grudzień | 3–5.12.   | Konferencja Przemysł Chemiczny 2025<br>Konkurs o tytuł „Inżynier Przemysłu Chemicznego” 2025                                    | Warszawa | SITPChem                    |