

Krzysztof PILARSKI, Piotr BONIECKI, Jacek DACH, Krzysztof KOSZELA, Andrzej LEWICKI

Uniwersytet Przyrodniczy w Poznaniu, Instytut Inżynierii Rolniczej

ul. Wojska Polskiego 50, 60-637 Poznań

e-mail: pilarski@up.poznan.pl

Zbyszek ZBYTEK

Przemysłowy Instytut Maszyn Rolniczych

ul. Starołęcka 31, 60-963 Poznań

e-mail: office@pimr.poznan.pl

NEURAL ESTIMATION OF METHANE EMISSION LEVEL FROM TYPICAL AGRICULTURAL SUBSTRATES

Summary

The usage of modern methods, which represent predictive neural techniques is an effective approach to the estimation of the processes occurring in the complex empirical systems of agricultural engineering. The artificial neural networks are a rapidly expanding field of knowledge used increasingly in many areas of science, as well as practice. The learning algorithms, enabling the design of appropriate network topology and selection of the parameters of this structure, matched to the problem to be solved are the basis of functioning of artificial neural networks. The paper proposes the use of neural modeling techniques to estimate the level of methane content in the biogas emitted over the methane fermentation process of silage. Obtained research results confirm the hypothesis that predictive neural model describing the methane production during the silage fermentation process in biofermentor is an appropriate tool to assess the forecasting of the level of this emission.

Key words: silage; biogas; methane; processes; evaluation; artificial intelligence; neural networks; modelling; experimentations

NEURONOWA ESTYMACJA POZIOMU EMISJI BIOMETANU Z TYPOWYCH SUBSTRATÓW ROLNICZYCH

Streszczenie

Efektywnym podejściem do estymacji procesów zachodzących w złożonych systemach empirycznych inżynierii rolniczej jest wykorzystanie nowoczesnych metod, jakie reprezentują neuronowe techniki predykcyjne. Sztuczne sieci neuronowe stanowią intensywnie rozwijającą się dziedzinę wiedzy, coraz częściej stosowaną w wielu obszarach zarówno nauki, jak również praktyki. Podstawą działania sztucznych sieci neuronowych są algorytmy uczące, umożliwiające zaprojektowanie odpowiedniej topologii sieci oraz dobór parametrów tej struktury. W pracy zaproponowano wykorzystanie technik neuronowego modelowania do estymacji poziomu zawartości metanu w biogazie, emitowanego w trakcie procesu fermentacji metanowej kiszonki. Uzyskane wyniki badań potwierdzają hipotezę, że predykcyjny model neuronowy, opisujący produkcję metanu w trakcie procesu fermentacji kiszonki w biofermentorze, jest właściwym instrumentem dla dokonania oceny prognozowania poziomu tej emisji.

Słowa kluczowe: kiszonka; biogaz; metan; procesy; ocena; sztuczna inteligencja; sieci neuronowe; modelowanie; badania

1. Wprowadzenie

Potencjał rynku biogazowego w Polsce jest bardzo duży. Komisja Europejska nałożyła na Polskę obowiązek osiągnięcia w 2010 r. 7,5% energii wytwarzanej ze źródeł odnawialnych (OZE), docelowo, w 2020 r. Polska musi wytwarzać 15% energii elektrycznej, natomiast już w 2014 r. 60% energii z OZE musi być wytwarzanych z biomasy różnego pochodzenia, ze źródeł odnawialnych [1, 5, 11]. Rządowe plany budowy ponad 2000 biogazowni przed rokiem 2020 wpisują się więc w tendencje ogólnoeuropejskie [13].

Trzeba jednak podkreślić, że proces fermentacji metanowej nie jest prosty w prowadzeniu [7, 12]. Bardzo często oczekiwania i plany inwestorów rozmiągają się z rzeczywistością wydajnością biogazową uzyskiwaną w realnych biogazowniach. Powszechnym zjawiskiem w Niemczech w latach 2007-2009 było uzyskiwanie wydajności produkcji biometanu znacznie niższych niż zaplanowano w biznesplanach, co zresztą skutkowało bankructwem wielu niemieckich

biogazowni i ich przejmowaniem przez banki. Stąd niezwykle istotne jest badanie substratów na ich rzeczywistą wydajność biogazową i – zwłaszcza – biometanową oraz tworzenie modeli bazujących na realnych danych doświadczalnych pozwalających przewidzieć z dużą dokładnością ilość wytwarzanego CH_4 [17].

Dane dotyczące polskiego rynku biogazowego i planowanych inwestycji wykazują, że najbardziej rozpowszechnionym substratem do fermentacji będą kiszonki i odchody zwierzęce. Od 2009 roku na stronach internetowych Laboratorium Ekotechnologii przy Instytucie Inżynierii Rolniczej UP w Poznaniu udostępniony jest kalkulator biogazowy Biogas Web Planner® (www.ekolab.up.poznan.pl pod zakładką „Biogaz”). Kalkulator ten wykorzystywany jest na zajęciach Inżynierii Biopaliw Gazowych na specjalności Inżynieria Agroenergetyki, ale jest również ogólnodostępny dla każdego potencjalnego inwestora, który chciałby wstępnie określić moc możliwą do uzyskania na bazie dostępnych substratów.

Dzięki wykorzystaniu specjalistycznych skryptów stworzonych przez mgra inż. Tomasza Kluzę z Zakładu Informatyki IIR, udało się zgromadzić bazę danych na temat wyszukiwanych przez kilku tysięcy użytkowników (spoza uczelni) substratów do biogazowni, ich lokalizacji geograficznej czy uzyskiwanych mocy. Analiza uzyskanych danych wykazała, że najczęściej uwzględnianym składnikiem były kiszonki (przede wszystkim z kukurydzy i traw) oraz gnojowica (świńska lub bydłęca), a także obornik [4].

Natomiast w Niemczech najbardziej rozpowszechniona technologia produkcji biogazu „NaWaRo” (*Nachwachsende Rohstoffe*), wykorzystuje głównie gnojowicę, kiszonki z roślin (kukurydzy, traw, buraków i innych odpadów przemysłowych), natomiast inne substraty (np. ziarno zbóż czy odpady) wykorzystywane są znacznie rzadziej w zależności od konkretnych uwarunkowań gospodarstwa. W technologiach mieszanych stosuje się mieszaninę o składzie: gnojowica – ok. 30% oraz kiszonka z kukurydzy (o zawartości 30% s.m) – ok. 70% [15]. Można więc wnioskować, że w warunkach gospodarczych Europy Środkowej jako substraty wykorzystywane w biogazowniach dominują obecnie kiszonki (głównie z kukurydzy), uzupełnione przez nawozy naturalne [2, 8]. Paradoksalnie jednak, mimo tak dużej dominacji dwóch grup substratów, zdarzają się bardzo duże różnice w realnej wydajności biogazowej. Wynika to przede wszystkim z różnych parametrów składu substratów, ale także z problemów technologicznych czy różnych rozwiązań technicznych. Te trudności sprawiają, że stosowane w planowaniu wydajności procesu fermentacji kalkulatory biogazowe określają co prawda ilość wytwarzanego biometanu, ale często te prognozy są dalekie od rzeczywistej emisji. Wydaje się więc celowe poszukiwanie innych metod prognozowania ilości produkowanego w procesie fermentacji CH_4 .

W naukach rolniczych często nie jest znany w sposób jawny, np. w postaci struktury matematycznej, związek zachodzący pomiędzy badanymi zjawiskami oraz procesami [3]. Fakt ten wynika ze złożonej struktury oraz interdyscyplinarnego charakteru, jaki często reprezentują wspomniane nauki empiryczne. Dysponując jedynie losowymi danymi doświadczalnymi lub wynikami symulacji komputerowych, ważną jest identyfikacja alternatywnych metod budowy modeli, opisujących badane zależności. Taką perspektywę wydają się stwarzać techniki modelowania z wykorzystaniem metody inteligencji obliczeniowej, a w szczególności sztuczne sieci neuronowe [6, 9, 10, 14].

W pracy dokonano identyfikacji topologii neuronowych dedykowanych dla prognozowania poziomu zawartości metanu w biogazie, którego wytwarzanie jest oczekiwanym efektem procesu fermentacji kiszonki w zbiorniku w funkcji wybranych zmiennych reprezentatywnych, warunkujących emisję tego gazu. Jako dane wejściowe przyjęto wybrane parametry charakteryzujące omawiany proces.

2. Materiał i metody

Problem naukowy, którego rozwiązania podjęto się w pracy, wymagał sformułowania odpowiedzi na następujące pytania:

1. Jaka topologia neuronowa jest właściwa dla modelowania poziomu zawartości metanu w trakcie fermentacji kiszonki?
2. W jakim stopniu wybrane zmienne reprezentatywne wpływają na efektywność wygenerowanego modelu neuronowego do prognozy poziomu produkcji metanu?

Realizacja przyjętego celu pracy wymagała przeprowadzenia eksperymentu laboratoryjnego, a następnie utworzenia adekwatnych zbiorów uczących, niezbędnych do wygenerowania rodziny modeli neuronowych.

2.1. Materiał badawczy

Na podstawie badań prowadzonych w IIR UP w Poznaniu z zastosowaniem kalkulatora biogazowego BiogasWebPlanner[®] uzyskano bazę danych zawierającą m.in. podstawowe substraty planowane przez inwestorów do stosowania w biogazowniach rolniczych. Wśród nich dominują odchody zwierzęce (gnojowica, obornik) oraz kiszonka jako podstawowy materiał roślinny [4]. Surowiec ten całkowicie dominuje także w biogazowniach niemieckich. Stąd przyjęto, że podjęta próba stworzenia modelu predykcyjnego efektywności wytwarzania biometanu opartego na sztucznych sieciach neuronowych będzie bazować na fermentacji kiszonki z kukurydzy.

Do badań używano typowej kiszonki pobranej z silosa w gospodarstwie doświadczalnym w Przybrodzie z materiałem paszowym przeznaczonym do żywienia bydła. Od 2012 r. ten sam materiał będzie również wykorzystywany jako substrat do budowanej obecnie biogazowni doświadczalno-dydaktycznej o mocy 250 kW, co dodatkowo podkreśla celowość wyboru tego substratu.

2.2. Badania laboratoryjne


Badania uzyskania biogazu i metanu z substratu prowadzone w Laboratorium Ekotechnologii w IIR UP w Poznaniu prowadzono na podstawie procedur wewnętrznych, bazujących częściowo na zaadoptowanej normie DIN 38 414. Badania fermentacji metanowej prowadzono na łącznie 12 fermentorach o pojemności 1400 cm³ [11]. Schemat sekcji biofermentora przedstawiono na rys. 1.

Monitoring emisji gazów składowych biogazu (CH_4 , CO_2 , NH_3 , O_2 , H_2S) umożliwiła zmodyfikowany system pomiarowy (tzw. *droga gazowa*) pozwalający na monitorowanie emisji gazowych w czasie rzeczywistym. System magazynowania biogazu oparto na zasadzie działania eudiometru według normy DIN 38 414.

W trakcie badań prowadzono analizy parametrów substratów oraz fermentującej pulpy, takie jak: sucha masa/wilgotność (pomiar metodą suszarkową PN-75 C-04616/01), pH (pomiar metodą elektrometryczną PN-90 C-04540/01), konduktywność (PN-EN 27888:1999), materia organiczna oraz popiół (przez spalanie według zmodyfikowanej PN-Z-15011-3).

2.3. Modelowanie neuronowe

Doświadczalne odtworzenie naturalnych warunków procesu fermentacji kiszonki umożliwiło zgromadzenie danych empirycznych, adekwatnych dla opisu procesu wytwarzania metanu. Pozyskane dane zgromadzone zostały w postaci zbioru, który stanowił podstawę do tworzenia zbioru uczącego, niezbędnego w procesie generowania sztucznych sieci neuronowych. Jako zmienne (sygnały) wejściowe oraz wyjściowe zbioru przyjęto 5 mierzalnych cech reprezentatywnych, charakteryzujących w sposób podstawowy parametry procesu fermentacji metanowej (tab.). Warto dodać, że w przypadku eksploatacji biogazowni rolniczych te właśnie parametry powinny być pod stałą kontrolą.



Rys. 1. Schemat 5-komorowej sekcji biofermentora [18]: 1 – ogrzewacz wody z regulatorem temperatury, 2 – izolowane przewody cieczy ogrzewającej, 3 – płaszcz wodny, 4 – biofermentor z wsadem o pojemności 2 dm³, 5 – zbiornik na biogaz, 6 – zawory odcinające, 7 – przepływomierze gazowe, 8 – analizatory gazowe (CH₄, CO₂, NH₃, O₂, H₂S), 9 – sensory pH, 10 – sensor temperatury, 11 – centrala rejestrująca, 12 – mieszadła magnetyczne wsadu

Fig. 1: Scheme of biofermentor for biogas production research (5-chamber section): 1 – water heater with temperature regulator, 2 – insulated conductors of calefaction liquid, 3 – water coat with temp. 36-38°C, 4 – biofermentor with charge capacity 2 dm³, 5 – biogas reservoir, 6 – cutting off valves, 7 – 7 – gas flow-meters, 8 – gaseous analyzers (CH₄, CO₂, NH₃, O₂, H₂S), 9 – pH sensors, 10 – temperature sensor, 11 – steering – recording central station, 12 – charge magnetic mixers

Tab. Zmienne wejściowe oraz wyjściowe zbioru danych
Table. Input and output variables of data file

Lp.	Nazwa	Oznaczenie	Jednostka
Sygnały wejściowe (5 zmiennych)			
1	Masa suchej substancji	SM	[%]
2	Masa suchej substancji organicznej	SMO	[%]
3	Konduktywność	KONDUKTY	[μS]
4	pH	PH	[-]
5	Objętość wytwarzanego biogazu	OBJĘTOŚĆ	[dm ³]
Sygnał wyjściowy (1 zmienna)			
1	Produkcja metanu CH ₄	CH4	[%]

Dane pomiarowe wymienionych wielkości fizycznych (tab.) stanowiły strukturę wytworzonego zbioru uczącego, którego fragment przedstawiono na rys. 2. Zbiór uczący zawierał 420 przypadków uczących.

Utworzony zbiór standardowo podzielony został następnie na 3 podzbiory: uczący zawierający 200 przypadków, walidacyjny zawierający 150 przypadków oraz testowy, który zawierał 70 przypadków (rys. 2).

W oparciu o przeprowadzone badania wstępne postanowiono szczegółowo przeanalizować i porównać zachowanie następujących typów sieci neuronowych (tradycyjnie dedykowanych dla rozwiązywania problemów predykcyjnych):

- perceptron wielowarstwowy typu MLP (ang. *Multi Layer Perceptron*),
- sieć o radialnych funkcjach bazowych typu RBF (ang. *RadialBasisFunction*).

Zmienne	SM %	SMO %	KONDUKTY	PH	OBJĘTOŚĆ	CH4 %
175	71,33	89,7	0,747	6,71	0,03	35
176	72,5	89,31	0,732	6,68	0,02	32
177	73,45	89,68	0,725	6,65	0,02	31
178	72,16	90,1	0,765	6,65	0,04	32
179	72,65	92,87	0,756	6,64	0,06	33,4
180	73,35	92,19	0,751	6,65	0,04	34,1
181	74,53	90,52	0,765	6,64	0,05	33
182	73,08	92,72	0,708	6,65	0,04	33,2
183	72,78	90,8	0,744	6,64	0,03	35
184	73,37	92,85	0,709	6,65	0,02	31,2
185	75,37	91,11	0,802	6,64	0,01	33
186	73,07	90,09	0,72	6,65	0	32,1
187	73,98	90,44	0,752	6,64	0	31,2
188	73,66	92,27	0,73	6,65	0	33,4
189	72,17	91,1	0,757	6,65	0	33,1

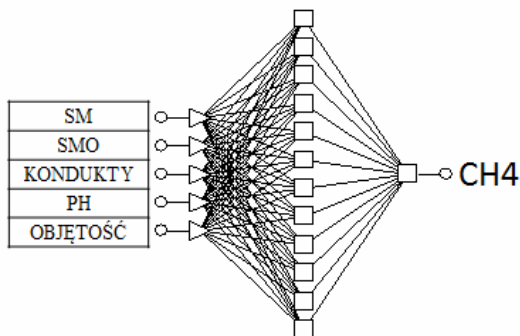
Rys. 2. Fragment zbioru uczącego w programie Statistica
Fig. 2. Fragment of the learning file in the Statistica program

Tworzenie modeli neuronowych przebiegło dwuetapowo. Na wstępie wykorzystano efektywną opcję wspomagającą proces projektowania sieci neuronowych („Automatyczny projektant sieci”) zaimplementowaną w statystycznym systemie informatycznym *Statistica* Narzędzie to pozwalało na zautomatyzowanie oraz uproszczenie procedur wstępniego poszukiwania zbioru sieci neuronowych, najlepiej modelujących badany proces.

W drugim etapie budowy modeli neuronowych wykorzystano narzędzie „Projektant sieci użytkownika”. Daje ono możliwość zaawansowanej ingerencji w parametry oraz sposoby uczenia generowanych sieci neuronowych. Narzędzie to uruchamiano wielokrotnie modyfikując zarówno ustawienia początkowe dotyczące parametrów, algorytmów uczących jak i struktury samej sieci [16].

3. Wyniki badań

W wyniku zastosowania narzędzi dostępnych w programie *Statistica* z wykorzystaniem zbioru uczącego (rys. 2) wygenerowano zbiór 10 topologii predykcyjnych, estymujących poziom metanu, z których wybrano sieć optymalną. Jest to model neuronowy typu MLP o strukturze: 5-12-1 (rys. 3).



Rys. 3. Model neuronowy typu MLP o strukturze: 5-12-1
Fig. 3. Neural model MLP type with structure: 5-12-1

Statystyki zagadnień regresyjnych wskazują na dobrą jakość wygenerowanego modelu (rys. 4). Bliska 1 wartość korelacji zmiennych stochastycznych zbioru uczącego, walidacyjnego oraz testowego z wartościami generowanymi przez wytworzony model neuronowy wskazują na dobre własności regresyjne sieci neuronowej (zdolność do uogólniania i odporność na przeuczenie sieci). Świadczy o tym również niska wartość (~0.12) ilorazu odchyłeń standardowych [3].

	Uc. CH4 %	Wa. CH4 %	Te. CH4 %
Średnia	49,60929	50,04417	53,315
Odch. std.	16,99887	17,03682	17,47423
Średni błąd	0,0008353	-0,0592	0,1389343
Odch. błędu	2,056442	2,22546	1,960515
Śr. bł. bezwz.	1,445599	1,559474	1,397615
Iloraz odch.	0,1209752	0,1306265	0,1121947
Korelacja	0,9926557	0,9914374	0,9937583

Rys. 4. Statystyki regresyjne sieci MLP o strukturze: 5-12-1
Fig. 4. Regression statistics of neural model MLP type with structure: 5-12-1

Przeprowadzona analiza wrażliwości sieci MLP o strukturze: 5-12-1 na zmienne wejściowe wskazuje na istotność zmiennych wejściowych, odpowiednio w kolejności: objętość, pH, konduktywność, masa substancji suchej oraz masa substancji organicznej (rys. 5).

	SM %	SMO %	KONDUKTY	PH	OBJĘTOŚĆ
Ranga	3	5	4	2	1
Błąd	12,65789	11,28882	12,49723	13,92362	16,45465
Iloraz	1,17966	1,052069	1,164688	1,297621	1,533501
Ranga	4	5	3	2	1
Błąd	9,742058	9,586827	10,11518	11,2964	16,09684
Iloraz	1,046025	1,029358	1,086088	1,212918	1,728351

Rys. 5. Analiza wrażliwości sieci MLP o strukturze: 5-12-1 na zmienne wejściowe

Fig. 5. The sensitivity analysis of neural model MLP type with structure: 5-12-1 for input variables

Uzyskane wyniki analizy wrażliwości sieci na zmienne wejściowe potwierdzają obserwacje laboratoryjne z prowadzonych badań. W trakcie realizacji szeregu prac badawczych dotyczących analizy biogazowej różnych substratów rolniczych często zauważyć można prawidłowość, że wraz ze wzrostem ilości wytwarzanego biogazu wzrasta w nim stężenie biometanu. Z kolei rola pH w fermentacji jest nie do przecenienia, gdyż z doświadczeń wyniesionych z badań laboratoryjnych oraz z realnie pracujących instalacji wynika, że zaburzenia odczynu (zwłaszcza jego spadek) mogą gwałtownie zahamować czy wręcz zupełnie zatrzymać proces wytwarzania biometanu.

4. Wnioski

Modelowanie neuronowe wykorzystane do predykcji poziomu emisji metanu w trakcie procesu fermentacji okazało się właściwą metodą, mogącą wspomagać procesy decyzyjne zachodzące podczas energetycznego przetwarzania najbardziej typowego substratu roślinnego, jakim jest kiszonka z kukurydzy. Przeprowadzone badania pozwoliły na sformułowanie następujących wniosków:

1. Uzyskane wyniki badań pozwalają na stwierdzenie, że predykcyjny model neuronowy, opisujący produkcję metanu w trakcie procesu fermentacji kiszonki w biofermentorze, jest właściwym instrumentem w celu dokonania oceny prognozowania poziomu tej emisji.
2. Analiza jakościowa wytworzonych modeli neuronowych wskazała, że najlepszą zdolność predykcyjną osiągnęła topologia neuronowa typu perceptron czterowarstwowy MLP, o strukturze: 5-12-1 uczona techniką hybrydową (metody: Qasi-Newtona: 1000 epok, gradientów sprzężonych: 900 epok oraz Lovenberga-Marqardta: 800 epok).
3. Analiza wrażliwości modelu na zmienne wejściowe badanego procesu wykazała, że najistotniejszymi parametrami charakteryzującymi wielkość emisji biometanu są (w kolejności): objętość wytwarzanego biogazu, pH, konduktyw-

ność, masa substancji suchej oraz masa substancji organicznej.

4. Badania wstępne wskazują na przydatność modelowania neuronowego przy projektowaniu oraz eksploatacji nowoczesnych technologii fermentacji.

5. Bibliografia

- [1] Adamski M., Pilarski K., Dach J.: Możliwości wykorzystania wywaru gorzelnianego jako substratu w biogazowni rolniczej. *Journal of Research and Applications in Agricultural Engineering*, 2009, Vol. 54 (3): 10-15.
- [2] Amon T., Amon B., Kryvoruchko V., Machmuller A. Methane production through anaerobic digestion of various energy crops grown in sustainable crop rotations. *Bioresource Technology*, 2007, 98: 3204–3212.
- [3] Boniecki P.: Elementy modelowania neuronowego w rolnictwie. Wydawnictwo UP w Poznaniu, 2008.
- [4] Dach J.: Rynek biogazowni w Polsce: ocena i perspektywy. *Czysta Energia*, 2010, 5: 38-42.
- [5] Dach J., Zbytek Z., Pilarski K., Adamski M.: Badania efektywności wykorzystania odpadów z produkcji biopaliw jako substratu w biogazowni. *Technika Rolnicza Ogrodnicza Leśna*, 2009, nr 6: 7-9.
- [6] Duch W., Korbicz J., Rutkowski L., Tadeusiewicz R.: Sieci neuronowe. Warszawa: Akademicka Oficyna Wydawnicza EXIT, 2000.
- [7] Edelmann, W., Schleiss, K., Joss, A.: Ecological, energetic and economic comparison of anaerobic digestion with different competing technologies to treat biogenic wastes. *Water Sci. Technol.*, 2000, 41 (3): 263–273.
- [8] Fugol M., Szlachta J.: Zasadność używania kiszonki z kukurydzy i gnojowicy świńskiej do produkcji biogazu. *Inżynieria Rolnicza*, 2010, nr 1 (119): 169-174.
- [9] Francik S., Ślipek Z.: Dobór funkcji trendu do prognozowania techniczno eksploatacyjnych wskaźników maszyn rolniczych. *Inżynieria Rolnicza*, 1999.
- [10] Korbicz J., Obuchowicz A., Uciński D.: Sztuczne sieci neuronowe – podstawy i zastosowania. Warszawa: Akademicka Oficyna Wydawnicza, 1994.
- [11] Pilarski K., Dach J., Mioduszevska N.: Porównanie wydajności produkcji metanu z gnojowicy świńskiej i bydłej z dodatkiem gliceryny rafinowanej. *Journal of Research and Applications in Agricultural Engineering*, 2010, Vol. 55(2): 78-81.
- [12] Pilarski K., Dach J., Pilarska A.: Preferowane kierunki rolniczego zagospodarowania odpadów z produkcji biopaliw. *Technika Rolnicza Ogrodnicza Leśna*, 2010, nr 3: 5-6.
- [13] Przybył J., Mioduszevska N., Dach J., Pilarski K.: Sugar beet used for traditional purposes and for energy. An economic comparison. *Inżynieria Rolnicza*, 2011, 7 (132): 131-140.
- [14] Rutkowska D.: Inteligentne systemy obliczeniowe. Akademicka Oficyna Wydawnicza, 1997.
- [15] Szlachta J., Fugol M.: Analiza możliwości produkcji biogazu na bazie gnojowicy oraz kiszonki z kukurydzy. *Inżynieria Rolnicza*, 2009, nr 5 (114): 275-280.
- [16] Lula P., Tadeusiewicz R.: *Statistica Neural Networks PL: wprowadzenie do sieci neuronowych*. StatSoft Polska, Kraków, 2001.
- [17] Vedrenne, F., Beline, F., Dabert, P., Bernet, N.: The effect of incubation conditions on the laboratory measurement of the methane producing capacity of livestock wastes. *Bioresource Technology*, 2008, 99: 146–155.
- [18] Zhou Mo, Pilarski K.: The preliminary comparison of biogas productivity between maize silage and maize straw silage. *Journal of Research and Applications in Agricultural Engineering*, 2011, Vol. 56 (2): 88-91.

Praca została zrealizowana w ramach projektu "Technologie odzysku odpadów z wytwarzania biopaliw ciekłych i gazowych", finansowanego przez Ministerstwo Nauki i Szkolnictwa Wyższego (umowa nr N N313 050036).