

ZASTOSOWANIE SZTUCZNYCH SIĘCI NEURONOWYCH DO PREDYKCJI PRODUKCJI BIOGAZU W WARUNKACH LABORATORYJNYCH

Streszczenie

Celem pracy było wytworzenie aplikacji umożliwiającej prognozowanie ilości wytworzonego biogazu oraz określenie wrażliwości parametrów wyjściowych procesu. W pracy wykorzystano sztuczne sieci neuronowe. Badania produktywności biogazowej prowadzone zostały przy wykorzystaniu normy DIN 38414 S. 8, na 10-komorowym stanowisku fermentacyjnym. Testowano wpływ wybranych czynników fizykochemicznych substratów oraz parametrów procesu na efektywność wytwarzania biogazu. W pracy wykorzystano symulator jednokierunkowych sieci neuronowych zaimplementowany w pakiecie Statistica. Najlepsze właściwości (najmniejszy błąd RMS rzędu 0,046) uzyskano w przypadku sieci perceptronowej czterowarstwowej MLP uczonej kombinacją algorytmów BP oraz CG. Wykazano, że zastosowanie sztucznych sieci neuronowych przyczynia się do predykcji ilości wytworzonego biogazu przy uwzględnieniu szeregu parametrów materiału wsadowego do procesu fermentacji.

Słowa kluczowe: sztuczne sieci neuronowe, biogaz, produkcja, prognozowanie, laboratorium

Wprowadzenie

Proces wytwarzania biogazu z substratów organicznych jest bardzo złożonym zjawiskiem biochemicznym. Dla optymalnego przebiegu procesu wytwarzania biogazu pulpa fermentacyjna powinna mieć odpowiednie parametry fizyczne i chemiczne. Parametry pulpy kształtowane są także przez warunki panujące w instalacjach biogazowych [1]. Wielość czynników wpływających na jakość i ilość produkowanego biogazu wymaga scharakteryzowania pod kątem istotności ich wpływu na wspomniany efekt procesu metalizacji [2]. Ważnym elementem działań jest stworzenie narzędzi i rozwiązań umożliwiających predykcję produkcji biogazu. Z punktu widzenia zastosowań praktycznych użytkownik biogazowni rolnej potrzebuje możliwości modyfikacji technologii w ramach poszukiwania optymalnych substratów do procesu metanizacji [3]. W tym zakresie pomocne mogą okazać się sztuczne sieci neuronowe przede wszystkim ze względu na umiejętność wyszukiwania zależności pomiędzy parametrami w dużych zbiorach danych oraz możliwość przeprowadzenia analizy wrażliwości parametrów wyjściowych procesu [10].

Cel i zakres badań

Celem pracy było wytworzenie aplikacji z zaimplementowaną sztuczną siecią neuronową, która na podstawie danych wprowadzonych przez użytkownika, dokonywałaby prognozy objętości produkowanego biogazu. Celem pośrednim była charakterystyka procesu fermentacji metanowej na bazie wybranych substratów rolniczych i rolno-przemysłowych. Analizę produktywności biogazowej substratów wykorzystano dla określenia wpływu wybranych parametrów procesu fermentacji metanowej na ilość wytwarzanego biogazu.


W ramach badań testowano parametr produktywności biogazowej odpadów celulozowych, kiszonki kukurydzy z całych roślin, wywaru gorzelnianego, odpadów tłuszczowych, sianokiszonki i topinamburu w mieszkankach z gnojowicą bydlęcą. Testowano wpływ i efektywność procesu metanizacji takich parametrów jak: masa wsadu, masa suchej substancji, odczyn, rodzaj substratu, czas fermentacji, zawartość inoculum.

Przebieg i metodyka badań biogazowych

W ramach badań założono następującą kolejność działań. Wybrano dostępne surowce różniące się wybranymi parametrami fizykochemicznymi. Następnie zebrano informacje o charakterystykach produktywności biogazowej testowanych substratów

pozyskiwanych w monitorowanych warunkach. Kolejnym etapem było wytworzenie zbioru uczącego wygenerowaną sieć neuronową i walidacja wytworzonego systemu informatycznego.

Badania optymalizacji produkcji biogazu prowadzone zostały przy wykorzystaniu normy DIN 38414 S. 8 [1], na 10-komorowym stanowisku eudiometrycznym będącym na wyposażeniu Laboratorium Analiz Biogazu Instytutu Inżynierii Biosystemów [1, 4]. Schemat budowy stanowiska badawczego przedstawiono na rys. 1. Pomiary stężenia oraz objętości wydzielanego gazu przeprowadzono w odstępach 24-godzinnych. Mieszanina o identycznym składzie znajdowała się w trzech biofermentorach w celu zwiększenia poprawności wyników. Do pomiarów składu produkowanego



Źródło/Source: opracowanie własne na podstawie [1]/own work [1]

Rys. 1. Schemat fermentora do badań produkcji biogazu: 1 - ogrzewacz wody z regulatorem temperatury, 2 - izolowane przewody cieczy ogrzewającej, 3 - płaszcz wodny o temp. 36-38°C, 4 - Biofermentor z wsadem o pojemności 2 dm³, 5 - zbiornik na biogaz, 6 - zawory odcinające, 7 - przepływomierze gazowe, 8 - analizatory gazowe (CH₄, CO₂, NH₃, H₂S), 9 - sensory pH, 10 - sensor temperatury, 11 - centrala sterująca-rejestrująca, 12 - mieszadła magnetyczne wsadu

Fig. 1. Schema of the fermentor for investigations of biogas production: 1 - heater of water with regulator of temperature, 2 - incommunicado lines of liquid calefaction, 3 - water jacket of temp. 36-38 °C, 4 - biofermentor with batch of capacity 2 dm³, 5 - reservoir for biogas, 6 - cutting off bolts, 7 - gas flow-meters, 8 - gas analyzers (CH₄, CO₂, NH₃, H₂S), 9 - sensors of pH, 10 - sensor of temperature, 11 - headquarters steering and recording, 12 - magnetic stirrers of batch

biogazu zostały zastosowane dyfuzyjne głowice pomiarowe serii MG-72 i MG-73 o zakresach pomiarowych 0-100% objętości i rozdzielczości pomiarowej rzędu od 0,1ppm do 1% objętości. Na podstawie badań własnych [3] oraz analizy literaturowej [4, 5, 10] wybrano czynniki charakteryzujące pulę fermentacyjną, mogące mieć istotny wpływ na procesu wytwarzania biogazu: masa suchej substancji, masa wsadu, pH, skład pulpy oraz czas od rozpoczęcia doświadczenia. Parametrem wyjściowym jest objętość wytworzonego biogazu w ciągu doby [3].

Modelowanie neuronowe

Na bazie danych empirycznych uzyskanych podczas badań optymalizacji produkcji biogazu utworzono zbiór danych uczących w celu przeprowadzenia próby wykorzystania sztucznych sieci neuronowych do analizy badanego procesu. Ostatecznie jego strukturę tworzą: 13 zmiennych wejściowych, 1 zmienna wyjściowa, a zawartość zbioru to 1898 reprezentatywnych przypadków uczących. Wielkość ta wynikała z długości trwania procesu. Średnio proces fermentacji trwał 21 dni. Jednak w celu uniknięcia błędnego nauczania sieci wszystkie przeprowadzone doświadczenia uzupełniono do 30 dnia, zastępując brakujące dane zerami. Parametry poddane analizie i fragment zbioru uczącego przedstawiono w tab. 1. Wstępnie zbiór uczący podzielony został na podzbiory w skali 2:1:1 (uczący, walidacyjny, testowy).

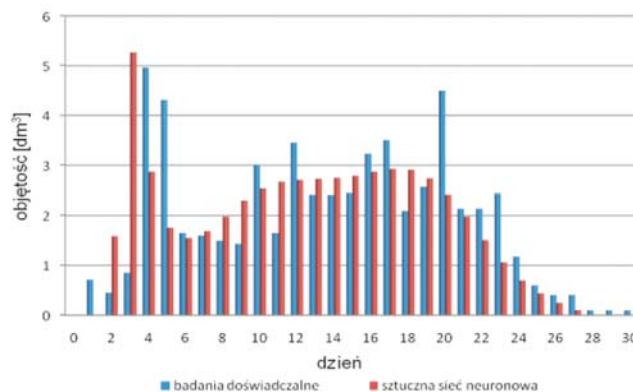
W celu przeprowadzenia eksperymentu komputerowego wykorzystano symulator jednokierunkowych sieci neuronowych zaimplementowany w pakiecie Statistica v. 7.1. firmy StatSoft [6]. Do wygenerowania zbioru adekwatnych topologii sieci neuronowych posłużono się efektywną procedurą w postaci automatycznego projektanta sieci (w wersji zaawansowanej). Jest to silne narzędzie pozwalające skrócić czas żmudnych poszukiwań właściwych topologii sieci neuronowych, uczonych w oparciu o posiadany zbiór danych [7].

Losowy charakter procesu uczenia sieci powoduje, że sieci neuronowe opracowane do modelowania tego samego procesu mogą

różnić się wartościami błędów. W pracy przyjęto, że kryterium wyboru najlepszego modelu neuronowego będzie wartość błędu RMS (ang: *Root Mean Squared*) dla zbioru walidacyjnego [6, 8, 9].

Po przeanalizowaniu dziesięciu najlepszych sieci wygenerowanych przez program Statistica wybrano sieć o najlepszym współczynniku korelacji. Najlepsze właściwości (najmniejszy błąd RMS rzędu 0,046) uzyskano w przypadku sieci perceptronowej czterowarstwowej MLP (ang: *MultiLayer Perceptron*) (nr 10) uczonej kombinacją algorytmów BP (ang: *Back Propagation* algorytm wstecznej propagacji błędów) oraz CG (ang: *Conjugate Gradient* - algorytm gradientów sprzężonych) (tab. 2). Sieć ta posiadała strukturę typu 13:100:20:1, tzn. posiadała 2 warstwy ukryte, zawierające odpowiednio 100 i 20 neuronów.

Wygenerowany model neuronowy charakteryzuje się jakością walidacyjną na poziomie 0,798668 (najwyższa wartość dla mieszanki kiszonki kukurydzy z gnojowicą bydłą) - rys. 2.



Źródło/Source: na podstawie badań własnych/own work

Rys. 2. Walidacja wytworzonego modelu dla mieszanki gnojowicy bydłej i kiszonki kukurydzy

Fig. 2. Validation of the created model for the blend of liquid cattle manure and the maize silage

Tab. 1. Struktura zbioru uczącego sieci neuronowej
Table 1. Structure of the teaching set of the neural network

Źródło/Source: na podstawie badań własnych/own work

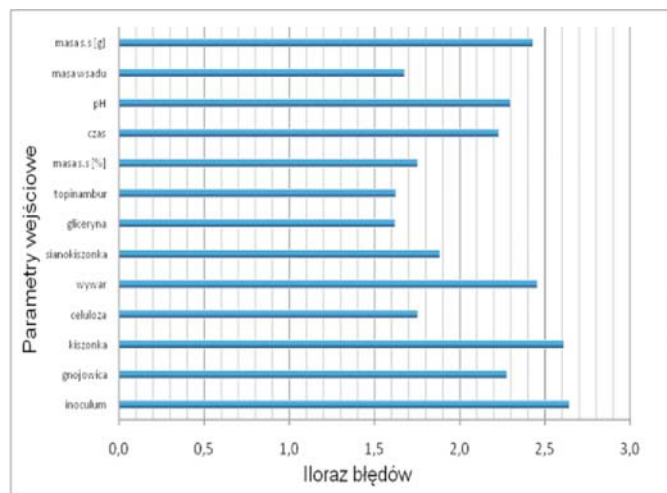
	innoculum (s.m.) [g]	gnojowica (s.m.) [g]	kiszonka z kukurydzy (s.m.) [g]	celuloza (s.m.) [g]	wywar gorzelniany (s.m.) [g]	olej z nasion kukurydzy (s.m.) [g]	gliceryna (s.m.) [g]	Topinambur (s.m.) [g]	masa suchej substancji	czas	pH	masa wsadu [g]	masa suchej substancji całego wsadu [g]	objętość/dzień
3														
4	4,00	77,00	51,00	0,00	0,00	0,00	0,00	0,00	6,44	0,00	6,80	2050,00	132,00	0,00
5	4,00	77,00	51,00	0,00	0,00	0,00	0,00	0,00	6,44	1,04	6,80	2050,00	132,00	2,65
6	4,00	77,00	51,00	0,00	0,00	0,00	0,00	0,00	6,44	2,00	6,80	2050,00	132,00	1,18
7	4,00	77,00	51,00	0,00	0,00	0,00	0,00	0,00	6,44	3,00	6,80	2050,00	132,00	2,63
8	4,00	77,00	51,00	0,00	0,00	0,00	0,00	0,00	6,44	4,00	6,80	2050,00	132,00	2,17
9	4,00	77,00	51,00	0,00	0,00	0,00	0,00	0,00	6,44	5,00	6,80	2050,00	132,00	1,69
10	4,00	77,00	51,00	0,00	0,00	0,00	0,00	0,00	6,44	6,00	6,80	2050,00	132,00	1,62
(...)	(...)	(...)	(...)	(...)	(...)	(...)	(...)	(...)	(...)	(...)	(...)	(...)	(...)	(...)
1892	15,00	8,92	66,42	0,00	0,00	0,00	0,00	61,82	7,84	20,69	8,33	1940,60	152,17	0,31
1893	15,00	8,92	66,42	0,00	0,00	0,00	0,00	61,82	7,84	21,88	8,33	1940,60	152,17	0,00
1894	15,00	8,92	66,42	0,00	0,00	0,00	0,00	61,82	7,84	22,78	8,33	1940,60	152,17	0,40
1895	15,00	8,92	66,42	0,00	0,00	0,00	0,00	61,82	7,84	23,67	8,33	1940,60	152,17	0,40
1896	15,00	8,92	66,42	0,00	0,00	0,00	0,00	61,82	7,84	24,71	8,33	1940,60	152,17	0,00
1897	15,00	8,92	66,42	0,00	0,00	0,00	0,00	61,82	7,84	25,36	8,33	1940,60	152,17	0,00
1898	15,00	8,92	66,42	0,00	0,00	0,00	0,00	61,82	7,84	26,00	8,33	1940,60	152,17	0,00
1899	15,00	8,92	66,42	0,00	0,00	0,00	0,00	61,82	7,84	27,83	8,33	1940,60	152,17	0,00
1900	15,00	8,92	66,42	0,00	0,00	0,00	0,00	61,82	7,84	28,79	8,33	1940,60	152,17	0,00
1901	15,00	8,92	66,42	0,00	0,00	0,00	0,00	61,82	7,84	29,75	8,33	1940,60	152,17	0,00

Tab. 2. Parametry wygenerowanych sieci neuronowych
Table 2. Parameters of generated neuronal networks

Źródło/Source: na podstawie badań własnych/own work

Raport podsumowania modelu (przypadki uczące wersja 2 sta)													
Zesp.	Typ	Jakość ucz.	Jakość wal.	Jakość test.	Błąd ucz.	Błąd walid.	Błąd test.	Uczenie	Wejść	Ukryta(1)	Ukryta(2)		
1	0 MLP 13-13-100-26-1-1	0.402408	0.459975	0.512013	0.051032	0.059249	0.077079	BP100.CG20.CG231b	13	100	26		
2	0 MLP 13-13-100-22-1-1	0.454082	0.436434	0.697331	0.057295	0.058607	0.099512	BP100.CG20.CG231b	13	100	22		
3	0 MLP 13-13-100-22-1-1	0.469437	0.452887	0.638664	0.060447	0.057742	0.080512	BP100.CG20.CG196b	13	100	22		
4	0 MLP 13-13-100-24-1-1	0.490270	0.499612	0.496315	0.063968	0.057508	0.066757	BP100.CG20.CG126b	13	100	24		
5	0 MLP 13-13-100-23-1-1	0.440627	0.497952	0.877011	0.058323	0.057054	0.090722	BP100.CG20.CG141b	13	100	23		
6	0 MLP 12-12-100-22-1-1	0.567265	0.545236	0.639701	0.074572	0.056126	0.094824	BP100.CG20.CG66b	12	100	22		
7	0 MLP 13-13-100-26-1-1	0.427388	0.430535	0.529383	0.054971	0.055099	0.067379	BP100.CG20.CG284b	13	100	26		
8	0 MLP 13-13-100-24-1-1	0.423476	0.478638	0.645537	0.055251	0.053042	0.092211	BP100.CG20.CG176b	13	100	24		
9	0 MLP 13-13-100-18-1-1	0.503439	0.437990	0.595588	0.065739	0.052406	0.071060	BP100.CG20.CG169b	13	100	18		
10	0 MLP 13-13-100-20-1-1	0.501067	0.407540	0.596344	0.066209	0.046137	0.067039	BP100.CG20.CG148b	13	100	20		

Na podstawie wybranego modelu, w celu określenia intensywności wpływu poszczególnych parametrów na ilość wytwarzanego biogazu, przeprowadzono analizę wrażliwości zmiennych wejściowych. Podstawową jej miarą jest iloraz błędów, mówiący o wzroście sumarycznego błędu popełnianego przez model przy nieuwzględnieniu rozpatrywanej zmiennej wejściowej. Im iloraz błędów jest większy tym zmienna ma większy wpływ na wynik działania sieci. Jeżeli iloraz błędów dla danej zmiennej jest równy lub nawet mniejszy od 1, to nie ma ona wpływu na jakość sieci [6, 8]. Na rys. 3 zestawiono uzyskane wartości ilorazów błędów.



Źródło/Source: na podstawie badań własnych/own work
Rys. 3. Wartości ilorazów błędów wszystkich parametrów procesu
Fig. 3. Ratio of the errors for entrance parameters

Podsumowanie i wnioski

Wyniki przeprowadzonych badań upoważniają do wyprowadzenia następujących stwierdzeń i wniosków.

1. Zastosowanie sztucznych sieci neuronowych przyczynia się do predykcji ilości wytworzonego biogazu przy uwzględnieniu szeregu parametrów materiału wsadowego do procesu fermentacji.
2. Analiza wyników doświadczeń prowadzonych przy wykorzystaniu wygenerowanej sieci neuronowej wykazała, iż największy wpływ na ilość wytwarzanego biogazu miała dawka

inoculum. Kolejne parametry to udział kiszonki i wywaru gorzelnianego w pulpie fermentacyjnej.

3. Spośród właściwości fizykochemicznych pulpy największy wpływ na ilość produkowanego biogazu miały masa suchej substancji oraz pH fermentującej pulpy.
4. Poziom inoculum i wynikająca z niego dynamika szczepienia złoza fermentującego dla procesu tworzenia biogazu stają się parametrem optymalizacji procesu fermentacji w warunkach laboratoryjnych.

Bibliografia

- [1] DIN 38414 S 8. Niemiecka znormalizowana metoda badań wody, ścieków i osadów. Osady i sedymenty (grupa S). Określenie charakterystyki fermentacji (S. 8). DIN Deutsches Institut für Normung e. V., Berlin, 2012.
- [2] Dach J., Zbytek Z., Pilarski K., Adamski M.: Badania efektywności wykorzystania odpadów z produkcji biopaliw jako substratu w biogazowni. Technika Rolnicza Ogrodnicza Leśna, 2009, 6, 7-9.
- [3] Pilarski K., Adamski M.: Perspektywy wytwarzania biogazu przy uwzględnieniu mechanizmów reakcji w zakresie analizy ilościowej i jakościowej procesów fermentacji. Journal of Research and Applications in Agricultural Engineering. Poznań, 2009, Vol. 54(2), 81-86.
- [4] Gelegenis J., Georgakakish D., Angelidakic I., Mavris V.: Optimization of biogas production by co-digesting whey with diluted poultry manure. Renewable Energy, 2007, Vol. 32, 2147-2160.
- [5] Jędrzak A.: Biologiczne przetwarzanie odpadów. Wydawnictwo Naukowe PWN, Warszawa, 2007.
- [6] Wójtowicz P.: Polska wersja Statistica Neural Networks. StatSoft Polska, Kraków, 2001.
- [7] Tadeusiewicz R.: Sieci neuronowe. Akademicka Oficyna Wydawnicza, Warszawa, 1993.
- [8] Markowska-Kaczmar U., Kwaśnicka H.: Sieci neuronowe w zastosowaniach. Wrocław: Oficyna Wydawnicza Politechniki Wrocławskiej, 2005.
- [9] Zaborowicz M., Boniecki P., Przybylak A.: Sieć neuronowa typu MLP jako narzędzie w komputerowej analizie obrazów. Journal of Research and Applications in Agricultural Engineering, 2010, Vol. 55(2), 124-127.
- [10] Boniecki P., Dach J., Pilarski K., Piekarska-Boniecka H.: Artificial neural networks for modeling ammonia emissions released from sewage sludge composting. Atmospheric Environment, 2012, Vol. 57, 49-54.

APPLICATION OF THE ARTIFICIAL NEURAL NETWORKS IN THE PREDICTION OF BIOGAS PRODUCTIONS IN LABORATORY CONDITIONS

Summary

The aim of the work was to create the application which makes possible to forecast volumes of produced biogas and to determine the sensitivity of output parameters of the process. In this research the artificial neural networks were used. The research on the biogas productivity was conducted complying with the standard DIN 38414 p. 8, on 10-chamber fermentation post. Influence of the chosen factors of physicochemical substrates and of the process parameters on the effectiveness of biogas production was tested. In the research a simulator of one-way neural networks was used. The simulator was implemented in the Statistica package. The best properties (the smallest RMS mistake with the value 0.046) were obtained in case of the MLP net which was taught with combination of algorithms the Bp and CG. It was shown that the application of the artificial neural networks contributed to the prediction of the amount of produced biogas taking into account many parameters of batch material designed to the fermentation.

Key words: artificial neural networks, biogas, production, prediction, laboratory



BEZPIECZEŃSTWO MASZYN I CIĄGNIKÓW ROLNICZYCH W ZAKRESIE OBSZARU NIEZHARMONIZOWANEGO W UNII EUROPEJSKIEJ

ISBN 83-921598-1-0
ilość stron: 113; il. 47; tabl. 7

Wydawca: PIMR-Poznań

Książka adresowana jest do osób i podmiotów, które wpływają na szeroko rozumiane bezpieczeństwo użytkowania maszyn i ciągników rolniczych, tj. do konstruktorów i producentów krajowych sprzętu rolniczego, importerów, producentów zagranicznych i ich przedstawicieli, personelu badawczego oraz posiadaczy i użytkowników maszyn i ciągników rolniczych. Publikacja jest źródłem wiedzy w zakresie upowszechnienia sposobów zapewnienia bezpieczeństwa ludzi i środowiska rolniczego.