

PREDYKCJA ZMIAN TEMPERATURY DLA ZŁOŻA KOMPOSTU W ZALEŻNOŚCI OD STOPNIA NAPOWIETRZENIA PRZY POMOCY SZTUCZNYCH SIECI NEURONOWYCH

Maciej Neugebauer, Janusz Piechocki, Piotr Sołowiej

Katedra Elektrotechniki i Energetyki, Uniwersytet Warmińsko-Mazurski w Olsztynie

Streszczenie. Efektywność procesu kompostowania zależy od wielu czynników. Jednym z nich jest intensywność napowietrzania złoża kompostu. Również zmiana temperatury procesu w czasie jest ważnym czynnikiem warunkującym jakość uzyskanego kompostu oraz wpływa również na czas trwania procesu kompostowania. W ramach przeprowadzonych badań kompostowano materiał biologiczny pochodzenia rolniczego dla różnych wartości intensywności napowietrzania. W ramach badań mierzono również zmiany temperatury w złożu kompostu w czasie kompostowania. Uzyskane dane zostały następnie wykorzystane do uczenia sztucznych sieci neuronowych (SSN). Wybrane SSN (o najniższych wartościach błędów) zostały następnie wykorzystane do przewidywania zmian temperatury w złożu kompostu i czasu trwania procesu kompostowania dla innych wartości napowietrzania złoża.

Słowa kluczowe: kompostowanie, sztuczne sieci neuronowe, napowietrzanie

Wstęp

Proces kompostowania, jeżeli ma być wykorzystywany w praktyce jako metoda utylizacji biomasy odpadowej, musi trwać jak najkrócej. Przebieg procesu kompostowania składa się z trzech faz: mezofilnej, termofilnej oraz wychładzania i dojrzewania. W fazie termofilnej temperatura wewnątrz złoża może osiągnąć wartość 80°C [Guardia 2006], wzrost temperatury jest uzależniony od wielu czynników jednym z nich jest napowietrzanie złoża [Bari i inni 2000; Ekinci i inni 2004; Sołowiej 2007]. Czas trwania procesu kompostowania jest funkcją wielu czynników, jednym z nich jest napowietrzanie złoża. Przy optymalnej wartości napowietrzania, można uzyskać najkrótszy czas kompostowania. Przy zbyt niskim napowietrzaniu, czas kompostowania się wydłuży a przy zbyt dużym, może w ogóle nie dojść do rozpoczęcia procesu, z uwagi na wyprowadzenie zbyt dużej ilości ciepła za złoża, co uniemożliwi rozpoczęcie fazy termofilnej i w konsekwencji procesu kompostowania. Właściwe dobranie intensywności napowietrzania jest kluczowe dla całego przebiegu procesu przy ustalonym składzie wsadu [Dach 2007].

Badania empiryczne w bioreaktorach są czasochłonne, doprowadzenie procesu do końca fazy termofilnej wymaga często dwóch tygodni czasu. Próba rozwiązania tego problemu

może być modelowanie neuronowe zmian temperatury w złożu oraz czasu trwania procesu kompostowania. Sztuczne Sieci Neuronowe (SSN) w świetle badań literaturowych wydają się dobrym narzędziem do rozwiązywania problemów klasyfikacji, regresji czy predykcji [Jack i in. 2002; Liao i in. 2004]. Budowa modelu neuronowego wymaga danych empirycznych na podstawie których, SSN będą uczone [Dach i in. 2001; Neugebauer i inni 2007; Partovi i in. 2002]. Modelowanie neuronowe obejmuje wiele różnych typów modeli: sieci radialne, typu perceptron, kohonena i inne. Budując modele neuronowe należy przebadать różne typy sieci aby wybrać tę która w najlepszym stopniu rozwiązuje dany problem, por. np. [Boniecki 2002].

Cel i zakres pracy

Celem pracy było zbudowanie modelu neuronowego procesu kompostowania biomasy pochodzenia rolniczego umożliwiającego przewidywanie temperatury osiągananej w złożu i czasu trwania procesu kompostowania w zależności od intensywności napowietrzania złoża przy ustalonym składzie wsadu.


Zakres pracy obejmował:

- budowę stanowiska do kompostowania biomasy pochodzenia rolniczego;
- przeprowadzenie procesu kompostowania dla różnych intensywności napowietrzania złoża;
- budowa modelu neuronowego, wykorzystującego SSN, umożliwiającego przewidywanie zmian temperatury w złożu i czasu trwania procesu kompostowania w zależności od intensywności napowietrzania złoża;
- na podstawie uzyskanych danych z badań empirycznych uczenie SSN, a następnie przewidywanie zmian temperatury i czasu trwania procesu dla innych wartości napowietrzania.

Badania empiryczne i budowa modelu neuronowego


Badania empiryczne prowadzono na stanowisku zbudowanym w katedrze, pokazanym schematycznie na rys. 1 i rys. 2. W ramach badań eksperymentalnych zbadano czas i zmiany temperatury w czasie kompostowania dla czterech wartości intensywności napowietrzania dla takich samych wsadów bioreaktora, którym była posiekana świeża kapusta. Badania przeprowadzono dla czterech różnych wartości napowietrzania wynoszących odpowiednio: 5; 7; 7,5 oraz 10 l·min⁻¹.

Uzyskane wyniki zostały następnie użyte do symulacji neuronowej czasu i temperatury procesu kompostowania. Do symulacji neuronowych wykorzystano program Statistica 8.



Rys. 1. Schemat stanowiska pomiarowego. 1 – bioreaktor, 2 – pompa, 3 – zawór, 4 – przepływomierz, 5 – zbiornik na odcieki, 6 – zbiornik na skropliny, 7 – komputer, 8 – źródło wody, 9 – odpływ wody, 10 – chłodnica, 11 – odстойnik, 12 – analizator gazu, 13 – wylot gazu. [Przekop 2009]

Fig. 1. Measurement setup diagram. 1 – bioreactor, 2 – pump, 3 – valve, 4 – flowmeter, 5 – effluent tank, 6 – condensate tank, 7 – computer, 8 – water source, 9 – water outlet, 10 – cooler, 11 – sedimentation tank, 12 – gas analyser, 13 – gas outlet [Przekop 2009]



Rys. 2. Budowa stanowiska pomiarowego [Przekop 2009]

Fig. 2. Measurement setup design [Przekop 2009]

Testowano różne sieci neuronowe – typu Multi Layer Perceptron (MLP) dla trzech warstw i różnej liczbie neuronów w warstwie ukrytej neuronów. Algorytm uczenia – BFGS (Droyden-Fletcher-Goldfarb-Shanno). Funkcje aktywacji – wykładnicza, liniowa, tanh, sinh, logistyczna; - oraz radialne sieci bazowe (RBF), aktywacją gaussowską warstwy ukrytej i liniową warstwy wyjściowej. Funkcję błędu wyliczano metodą (SOS - sum of squares) sumy kwadratów różnic (1) dla sieci MLP i dla sieci RBF metodą SOS i CE (Cross Entropy – funkcja błędu w postaci entropii wzajemnej) wzór nr 2.

$$E_{SOS} = \sum_{i=1}^n (y_i - t_i)^2 \quad (1)$$


$$E_{CE} = - \sum_{i=1}^n t_i \ln \left(\frac{y_i}{t_i} \right) \quad (2)$$

gdzie:

y_i – przewidywanie sieci;
 t_i – wartość rzeczywista.

Następnie dla SSN o najniższym błędzie testowania (jakość uczenia na poziomie 0,85 i wyżej uzyskano dla sieci typu RBF – błąd uczenia i testowania sieci był mniejszy niż 0,1, dla sieci MLP uzyskano bardzo duże błędy testowania i walidacji, więc nie wykorzystano ich do dalszych badań – wybrane wyniki pokazano w tabeli 1) wykonano predykcję czasu trwania fazy termofilnej i rozkładu temperatury w trakcie procesu dla innych (które nie były badane w rzeczywistości) wartości intensywności napowietrzania.

Na rysunku 3 pokazano predykcję czasu trwania procesy kompostowania godzinach wykonaną dla różnych SSN i wartości rzeczywistych w zależności od wartości napowietrzania złoża w $l \cdot min^{-1}$ – czas trwania procesu liczono od momenty osiągnięcia przez złożo temperatury $18^{\circ}C$ do chwili spadku temperatury poniżej $18^{\circ}C$. Dla porównania pokazano również czasy trwania dla procesów rzeczywistych.



Rys. 3. Predykcja czasu trwania procesy kompostowania wykonana dla różnych SSN i wartości rzeczywistych w zależności od wartości napowietrzania złoża, sieci radialne

Fig. 3. Prediction of composting process duration carried out for different ANN and actual values depending on bed aeration values, radial networks


Predykcja zmian temperatury...

Tabela 1. Wybrane wyniki przewidywania czasu trwania procesu kompostowania dla sieci regresyjnych – radialnych i MLP oraz wartości rzeczywistych w zależności od intensywności napowietrzania

Table 1. Selected results of predicting composting process duration for regression networks – radial and MLP, and for actual values depending on aeration intensity

SSN								wartość rzeczywista	intensywność napowietrzania
RBF 1-17-1	błąd testowania	RBF 1-24-1	błąd testowania	MLP 1-5-1	błąd testowania	MLP 1-7-1	błąd testowania		
czas [h]									[l·min ⁻¹]
264,24	0,08	264,71	0,075	256,13	0,45	267,96	0,39		2,5
269,00		269,00		269,00		269,00		269	5,0
268,71		268,68		269,84		268,88			5,5
263,00		263,00		263,00		263,00		263	7,0
258,59		258,60		253,67		252,96		258	8,0
259,82		259,85		264,57		264,78		260	10,5
259,84		260,17		280,13		274,29			12,5
260,10		260,79		290,24		276,22			15,0
260,18		260,97		295,73		276,87			20,0

Na rysunku 4 pokazano rozkłady temperatury [°C] w czasie kompostowania rzeczywiste (dla wartości napowietrzania 5; 7; 7,5; 10 l·min⁻¹) i uzyskane za pomocą SSN dla wartości napowietrzania 2; 4; 8; 10; 12; 16; i 20 l·min⁻¹.



Rys. 4. Zmiany temperatury w czasie kompostowania rzeczywiste i uzyskane za pomocą SSN dla różnych wartości napowietrzania złoża

Fig. 4. Temperature changes in time during composting: actual and obtained using the ANN for different bed aeration values

Wnioski

1. Sztuczne sieci neuronowe typu RBF charakteryzowały się dużo mniejszymi błędami uczenia i testowania w porównaniu do sieci typu MLP dla badanych modeli (RBF błędy uczenia mniejsze 0,1, dla RBF 1-24-1, błąd uczenia wynosił 0,056, dla MLP najlepsza sieć miała wartość błędu równą 0,49).
2. Dla przewidywania czasu trwania procesu kompostowania widać, że żadna z wybranych sieci nie określiła właściwie czasu trwania dla wartości napowietrzania $2,5 \text{ l}\cdot\text{min}^{-1}$. Czas ten powinien być dłuższy niż dla wartości $5 \text{ l}\cdot\text{min}^{-1}$. Natomiast pozostałe wartości są przewidziane właściwie, szczególnie sieci 1-24-1, dobrze pokazały wzrost czasu kompostowania wraz ze wzrostem wartości napowietrzania powyżej wartości optymalnej (wg badań wynosi ona dla tego bioreaktora i wsadu ok. $7 \text{ l}\cdot\text{min}^{-1}$ – czas trwania procesu – 258 h).
3. Przewidywania zmian temperatury w czasie procesu kompostowania SSN dla wartości napowietrzania powyżej $14 \text{ l}\cdot\text{min}^{-1}$ są na wykresie identyczne (różnice są niewidoczne na wykresie) i wykresy te wykazują dużą zmienność temperatury, szczególnie powyżej 90 godzin. Świadczy to o błędnym przewidywaniu SSN. Przewidywania dla pozostałych wartości napowietrzania są zgodne z oczekiwaniami. Przed wykorzystaniem SSN do predykcji zmian temperatury należy zweryfikować te rozkłady poprzez badania empiryczne.
4. Wykorzystanie SSN umożliwi zmniejszenie ilości badań empirycznych (najbardziej czasochłonnych) i symulacyjne dobranie najkorzystniejszej z punktu widzenia czasu trwania procesu kompostowania wartości napowietrzania złoza.

Bibliografia

- Bari Q.H., Koenig A., Guihe T.** 2000. Kinetic analysis of forced aeration composting. I. Reaction rates and temperature. *Waste Manage. Res.* Volume: 18. p. 303-312.
- Boniecki P.** 2002. The Comparison of Multilayer Perceptron Networks and Radial Networks with Regard to Their Use as Prediction Instruments in Agricultural Engineering Problems *Journal of Research and Applications in Agricultural Engineering* 3. s. 38-45.
- Dach J.** 2007. Badania wpływu aeracji na dynamikę procesu kompostowania osadów ściekowych w bioreaktorze. *Journal of Research and Applications in Agricultural Engineering*. Vol. 52/1. p. 68-72.
- Dach J., Niedbala G., Przybył J.** 2001. Zastosowanie sieci neuronowych w rolnictwie. *Inżynieria Rolnicza*. Nr 1 (21). s. 57-62.
- Ekinci K., Keener H.M., Elwell D.L., Michel F.C.** 2004. Effects of aeration strategies on the composting process. Part I. Experimental studies. Volume: 47. p. 1697-1708.
- Guardia A., Petiot C., Rogeau D.** 2006. Influence of aeration rate and biodegradability fractionation on composting kinetics. *Waste Management*. Vol. 28. s. 73-84.
- Jack F. R., Steel G. M.** 2002. Modelling the sensory characteristics of Scotch whisky using neural networks – a novel tool for generic protection, *Food Quality and Preference* 13. s. 163.
- Liao Y., Fang S. C., Nuttle H. L. W.** 2004. A neural network model with bounded-weights for pattern classification, *Computers & Operations Research* 31. s. 1411.

- Neugebauer M., Nalepa K., Sołowiej P.** 2007. Sieci neuronowe jako narzędzie umożliwiające prognozowanie zapotrzebowania na wodę w uprawach rolnych. *Inżynieria Rolnicza*. Nr 2(90). Kraków s. 205.
- Partovi F. Y., Anandarajan M.** 2002. Classifying inventory using an artificial neural network approach, *Computers & Industrial Engineering* 41. s. 389.
- Przekop P.** 2009. Badanie wpływu napowietrzania na dynamikę kompostowania wybranych rodzajów biomasy. Praca magisterska wykonana w Katedrze Elektrotechniki i Energetyki UWM Olsztyn. Maszynopis.
- Sołowiej P.** 2007. Przykład wykorzystania pryzmy kompostu jako niskotemperaturowego źródła ciepła. *Inżynieria Rolnicza*. Nr 8(96). Kraków. s. 247-253.

PREDICTION OF TEMPERATURE CHANGES FOR COMPOST BED DEPENDING ON AERATION DEGREE, CARRIED OUT USING ARTIFICIAL NEURAL NETWORKS

Abstract. Composting process intensity depends on many determinants. One of them is compost bed aeration intensity. Also, process temperature change in time is an important factor determining quality of obtained compost. Moreover, it affects composting process duration. The scope of carried out research involved composting biological material of agricultural origin for different aeration intensity values. Moreover, completed tests covered measuring temperature changes in compost bed during composting. Then, obtained data was used to teach artificial neural networks (ANN). The selected ANN (with lowest error values) were then used to predict temperature changes in compost bed and composting process duration for other bed aeration values.

Key words: composting, artificial neural networks, aeration

Adres do korespondencji:

Maciej Neugebauer e-mail: mak@uwm.edu.pl
Katedra Elektrotechniki i Energetyki
Uniwersytet Warmińsko-Mazurski w Olsztynie
ul. Oczapowskiego 11
10-957 Olsztyn