

ESTIMATION OF PROGNOSTIC NEURAL NETWORK APPLICATION IN GASEOUS EMISSIONS MODELING

S u m m a r y

Predictive abilities of artificial neural networks are one of the main topics of their application. The aim of this paper was to use their suitability for modeling of ammonia emission during farmyard manure composting. The best results were obtained while using the MLP neural networks.

OCENA ZASTOSOWANIA PROGNOSTYCZNEJ SIECI NEURONOWEJ W MODELOWANIU EMISJI GAZOWYCH

S t r e s z c z e n i e

Zdolności predykcyjne sztucznych sieci neuronowych stanowią jeden z głównych obszarów ich zastosowania. Doświadczenie miało na celu wykorzystanie tych właściwości do modelowania całkowitej emisji amoniaku w trakcie kompostowania obornika. Najlepsze wyniki uzyskano dla sieci neuronowych MLP.

Wprowadzenie

Amoniak jest gazem, którego emisja jest w ostatnim 15-leciu w Europie przedmiotem licznych badań. Polityka Unii Europejskiej ma na celu oszacowanie i ujęcie w normy zanieczyszczenia powietrza amoniakiem, jednocześnie zmierzając ku jego ograniczeniu. W związku z tym wszystkie kraje Unii Europejskiej zobligowane są do przeprowadzania inwentaryzacji emisji amoniaku na swoim terenie.

Dotychczasowe badania emisji amoniaku dotyczą przede wszystkim jego ulatniania z budynków hodowlanych oraz podczas składowania i nawożenia pola nawozami naturalnymi. Tymczasem niewiele jest doniesień odnośnie badań emisji amoniaku w czasie kompostowania obornika, które w ostatnich 10 latach staje się, zwłaszcza w Europie Zachodniej techniką coraz powszechniej zastępującą tradycyjną, beztlenową gospodarkę tym nawozem. Badania prowadzone w Instytucie Inżynierii Rolniczej AR w Poznaniu w ramach grantu KBN „Emisje gazowe w różnych technologiach zagospodarowania obornika”, wykazały, że emisja amoniaku z kompostowanego obornika może być w pewnych warunkach dość istotnym źródłem zanieczyszczenia powietrza tym gazem [5].

Nadmienić trzeba, że w literaturze światowej brak jest informacji o istnieniu modelu prognozującego ilość amoniaku emitowanego podczas kompostowania obornika w przyrmach. Nasuwa się więc myśl opracowania takiego modelu przy wykorzystaniu wyników z doświadczeń własnych i opublikowanych w literaturze naukowej.

Metodyka badań

Ciągłemu rozwojowi rolnictwa towarzyszy wprowadzanie coraz to nowszych technologii informatycznych. Ścisłej ujmując, to postęp technologiczny szeroko rozumianej informatyki generuje dynamikę rozwoju dziedziny, jaką jest rolnictwo. Rosnące moce obliczeniowe sprzętu oraz stale rozwijająca się inżynieria oprogramowania skutkują wytwarzaniem coraz bardziej zaawansowanego i efektywnego oprogramowania, również dla wspomaganie metod sztucznej inteligencji. Jedną z naczelných przesłanek prowadzenia

prac badawczych nad wykorzystaniem sztucznych sieci neuronowych w rolnictwie jest dążenie do komputerowej symulacji zachodzących procesów i przewidywania ich wyników, na podstawie założonych czynników.

Celem przeprowadzonych badań była ocena zastosowania sztucznych sieci neuronowych do wytworzenia modelu, umożliwiającego prognozowanie poziomu emisji amoniaku w trakcie kompostowania różnych typów obornika, na podstawie parametrów początkowych obornika. Ponadto dodatkowym celem było wykorzystanie właściwości technik neuronowych do określenia stopnia wpływu poszczególnych czynników na badane zjawisko. W związku z tym, pierwszym etapem pracy było określenie struktury zbioru uczącego. Na podstawie studiów literaturowych [2, 15] oraz badań własnych [4, 5] określone zostały parametry charakteryzujące obornik, które mogły by mieć znaczący wpływ na emisję NH_3 podczas jego kompostowania. Zaliczono do nich:

- rodzaj obornika (bydłęcy, kurzy, świński),
- zawartość azotu całkowitego [g/kg s.m.],
- zawartość azotu amonowego [g/kg s.m.],
- suchą masę obornika [%],
- zawartość materii organicznej [g/kg s.m.],
- stosunek zawartości węgla do azotu [-],
- pH obornika [-],
- czas trwania doświadczenia [dni].

Rodzaj obornika jest zmienną skategoryzowaną 3- stanową (3 obiekty), pozostałe dane wejściowe to zmienne ciągłe. Jako zmienną wyjściową przyjęto straty azotu w formie amoniaku, w czasie trwania całego doświadczenia, wyrażone w % początkowej zawartości azotu ogólnego.

Zebranie wystarczającego zbioru danych empirycznych obarczone jest czasochłonnością i pracochłonnością przeprowadzania doświadczeń polowych, gdzie proces kompostowania trwa około 6-8 tygodni. Dodatkowym czynnikiem determinującym uzyskanie zbioru uczącego o satysfakcjonującym rozmiarze jest stosunkowo skomplikowany pomiar emisji gazowej w trakcie doświadczeń polowych [3]. Dwie najczęściej stosowane metody przedstawione zostały na zdjęciach (rys. 1 i 2.)



Rys. 1. Pomiar gazowy z powierzchni kompostowanego obornika.

Fig. 1. Gaseous emission measurement from the surface of composted manure



Rys. 2. Tunel aerodynamiczny do badań emisji gazowych

Zbiór danych uczących utworzony został na bazie danych empirycznych uzyskanych podczas badań przeprowa-

dzonych w Instytucie Inżynierii Rolniczej AR oraz danych opublikowanych w literaturze światowej [1, 2, 6, 7, 10, 11, 13, 14, 15, 16]. Ostateczna jego postać zawierała 80 kompletnych, reprezentatywnych przypadków uczących, którego fragment przedstawiono na rys. 3.

Wstępnie zbiór uczący podzielony został na podzbiory w skali 2:1:1 (uczący, walidacyjny, testowy). Szereg testów pokazał, że wyniki błędów dla zbioru walidacyjnego i testowego są bardzo do siebie zbliżone, co sugerowało że sieci dobrze generalizują nabytą wiedzę [17]. Było to podstawą do zrezygnowania ze zbioru testowego na rzecz powiększenia zbiorów uczącego i walidacyjnego.

Analizę danych przeprowadzono przy wykorzystaniu pakietu *Statistica v. 7.1*. Problemy regresyjne w systemie *Statistica* rozwiązywane mogą być przy zastosowaniu następujących typów sieci: perceptronów wielowarstwowych **MLP**, sieci radialnych **RBF** i sieci liniowych [12]. Testowane modele zróżnicowane były pod względem typów, topologii i algorytmów uczenia.

Wyniki badań i dyskusja

Analiza wykazała, iż najlepsze parametry mówiące o jakości neuronowego modelu regresyjnego uzyskano dla sieci typu MLP (rys. 4.). Najistotniejsze informacje zawierają współczynniki: iloraz odchyłeń standardowych (iloraz odchylenia standardowego błędów predykcji i odchylenia standardowego zmiennej wyjściowej) oraz korelacja. Pierwszy z nich wskazuje, czy próba budowy modelu regresyjnego się udała. Im jego wartość jest bliższa zeru tym model lepiej wyznacza nieznanne wartości wyjściowe. Korelacja natomiast przedstawia współczynnik korelacji *R Pearsona* dla wartości rzeczywistych (empirycznych) i wartości uzyskanych przy zastosowaniu modelu neuronowego. Im korelacja jest bliższa jedności tym większa zbieżność wartości uzyskanej podczas działania modelu i wartości oczekiwanej [12].

	1	2	3	4	5	6	7	8	9
	Rodzaj obornika	N-tot	N-NH4	S. M.	M. O.	C/N	pH	Czas dośw.	Straty amoniaku
29	s	23,0496	17,37589	28,2	900,709	19,5	8,4	28	23,30
30	k	33,65	11,06	35	851	15	8,25	35	45,44
31	k	32,19	10,86	35	842	15	8,18	35	31,22
32	k	35,55	10,84	35	848	14	8,33	35	41,27
33	k	34,04	11	35	849	14	8,27	35	50,53
34	k	33,65	11,06	35	851	15	8,25	168	58,00
35	k	32,19	10,86	35	842	15	8,18	168	58,00
36	k	35,55	10,84	35	848	14	8,33	168	58,00
37	k	34,04	11	35	849	14	8,27	168	58,00
38	s	22	7,5	38	940	20,4	8,41	91	9,09
39	s	24	6	38	930	22,5	8,53	91	12,50
40	b	20,2	1,5	41	855	20,8	7,5	30	2,60
41	b	19,81	1,28	42	855	21,3	7,5	30	1,20
42	b	19,7	1,66	38	863	21,3	7,5	30	3,00

Rys. 3. Fragment zbioru uczącego

Fig. 3. Fragment of teaching file

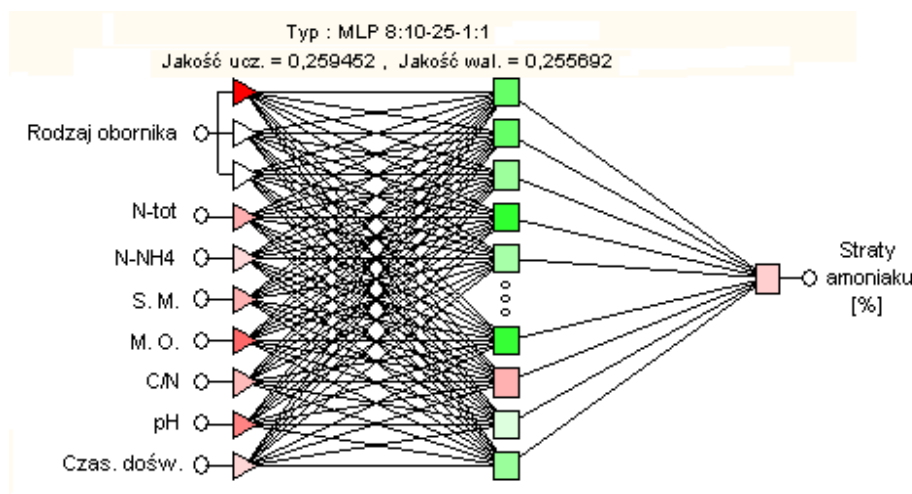
raport* - Regresja (1-20) (dane statistica)

	Regresja (dane statistica)		
	Liniowa	MLP	RBF
Średnia	25,20933	25,20933	25,20933
Odch. std.	16,40700	16,40700	16,40700
Średni błąd	-0,11369	0,17364	0,96275
Odch. błędu	9,17054	4,30161	12,55857
Śr. bł. bezwz.	7,54828	3,25843	9,53169
Iloraz odch.	0,55878	0,25819	0,70003
Korelacja	0,82935	0,96636	0,71436

Regresja (1-20) (dane statistica) Raport podsumowania modelu (dane statistica)

Rys. 4. Porównanie wyników analiz dla sieci liniowej, MLP i RBF

Fig. 4. Comparison between the analysis results of linear, MLP and RBF neural network.



Rys. 5. Topologia sieci neuronowej typu MLP

Fig. 5. Topology of neural network type MLP

raport* - Analiza wrażliwości - 1-6 (dane statistica)

	Analiza wrażliwości (dane statistica)							
	Rodzaj obornika	N-tot	N-NH4	S. M.	M. O.	C/N	pH	Czas dośw.
Iloraz	2,202017	1,563564	2,246279	1,420770	1,234429	1,590897	1,477116	1,748092
Ranga	2	5	1	7	8	4	6	3

Raport podsumowania modelu (dane statistica) Regresja (1-6) (dane statistica) Analiza wrażliwości - 1-6 (dane s

Rys. 6. Analiza wrażliwości dla najlepszej wygenerowanej sieci neuronowej

Fig. 6. Sensibility analysis for the best generated neural network

Stosunkowo niskie parametry jakościowe uzyskane dla modelu liniowego świadczą o nieliniowym charakterze zagadnienia i słuszności wyboru sieci neuronowych do prognozowania podjętego problemu. Nieliniowy charakter zależności pomiędzy czynnikami agrotechnicznymi a poziomem emisji gazowych potwierdzają także dotychczas przeprowadzone doświadczenia w IIR AR [9].

Jako najlepszą, spośród testowanych sieci neuronowych, wybrano trójwarstwową sieć typu MLP posiadającą

25 neuronów w warstwie ukrytej (rys. 5.). Determinantem przy wyborze właściwego modelu był najmniejszy iloraz odchyień standardowych (0,26). Korelacja pomiędzy danymi empirycznymi a uzyskanymi odpowiedziami wybranej sieci neuronowej (0,97) wskazuje, że model poprawnie odzwierciedla prognozowaną wartość.

Analiza wrażliwości zmiennych wejściowych (rys. 6.) wykazała, iż największy wpływ na straty azotu miała początkowa zawartość azotu amonowego w kompostowanym

materiale. Minimalnie mniejsze znaczenie miał rodzaj obornika. Te dwie dane są jednak ze sobą bezpośrednio związane, gdyż w zależności od rodzaju obornika średnia zawartość N-NH₄ może różnić się kilkukrotnie (zdecydowanie najwyższa jest dla obornika kurzego, najniższa w świńskim).

Wpływ czasu doświadczenia na wartość emisji jest prawdopodobnie związany z faktem, iż najkrótsze doświadczenia wzięte pod uwagę przy budowie zbioru uczącego trwały zaledwie 10 dni (najdłuższe 160). Wynika więc z tego, że proces emisji amoniaku w kompostowanym materiale jest zjawiskiem trwającym dłużej niż 10 dni, gdyż straty azotu wskutek emisji wzrastają wraz z trwaniem doświadczenia. Wpływ stosunku węgla do azotu na emisję amoniaku jest potwierdzony w licznych badaniach [8], stąd też zalecenia do optymalizacji kompostowania podają, iż powinien być on początkowo na poziomie co najmniej 20.

Inne parametry, jak zawartość azotu ogólnego, pH i sucha masa mają również wpływ na proces emisji amoniaku, jednak nie jest on tak istotny jak poprzednie zmienne. Zawartość materii organicznej w kompostowanym oborniku ma najmniejszy wpływ na emisję amoniaku, co jest o tyle zrozumiałe, iż amoniak jest mineralną formą azotu ogólnego.

Wnioski

Na podstawie przeprowadzonych badań oceniono zastosowanie sztucznych sieci neuronowych do wytworzenia modelu umożliwiającego prognozowanie poziomu emisji amoniaku w trakcie kompostowania różnych typów obornika, na podstawie jego parametrów początkowych, stwierdzając, co następuje:

1. Analiza wykazała nieliniowy charakter zagadnienia i słuszność wyboru technik neuronowych jako narzędzia do wytworzenia założonego modelu prognozującego poziom emisji amoniaku przy danych parametrach początkowych obornika
2. Uzyskano poprawne parametry mówiące o jakości modelu prognostycznego (korelacja = 0,97, iloraz odchyłeń stand. = 0,26)
3. Najważniejszą przyczyną silnej emisji amoniaku jest wysoka zawartość azotu amonowego w oborniku. Dlatego jeśli technologia kompostowania obornika będzie rozwijać się w Polsce równie dynamicznie, jak np. we Francji, z punktu widzenia ochrony środowiska należy podjąć działania zmierzające do obniżenia tego parametru w oborniku
4. Jakość modeli prognostycznych w znaczący sposób uzależniona jest od liczby przypadków uczących. Założono więc rozszerzenie zbioru uczącego o kolejne reprezentatywne wektory uczące równoległe z przeprowadzanymi w Instytucie Inżynierii Rolniczej AR w Poznaniu doświadczeniami i doniesieniami literatury światowej.

Literatura

- [1] Amon B., Amon T., Boxberger J., Pollinger A., 1999. Emission of NH₃, N₂O and CH₄ from composted and anaerobically stored farmyard manure. Proceeding at

the 9th International Conference on Management Strategies for Organic Waste Use in Agriculture, Rennes, France, p. 209-216

- [2] Chadwick D.R., 2005 Emissions of ammonia, nitrous oxide and methane from cattle manure heaps: effect of compaction and covering. *Atmospheric Environment* 39, p. 787-799
- [3] Dach J., Sęk T., 1998 Aerodynamiczne metody pomiaru strat amoniaku z obornika i gnojowicy. Poznań
- [4] Dach, J., Pietrowski M., 2003. The Research on Ammonia Emissions from the Manure During Storage, Composting Process and Spreading on the Field, w: Myczko, A.(red.), *Elim. Agric. Risks Health Envir.* 2003, r.1 *Basick Problems in Agriculture*. Wyd. Center of Excellence Tragen Poznań, 123-132
- [5] Dach J., Kowalik I., Zbytek Z., Pietrowski M. 2004 Badanie emisji gazowych w procesie kompostowania obornika, *Wybrane zagadnienia ekologiczne we współczesnym rolnictwie*. PIMR, Monografia, str. 292-297
- [6] Dewes T., 1999. Ammonia emissions during the initial phase of microbial degradation of solid and liquid cattle manure. *Bioresource Technology* 70, p. 245-248.
- [7] Michel F., Kelner H., Rigot J., Wilkinson T., Pecchia J., 2004 Effects of Straw, Sawdust and Sand Bedding on Dairy Manure Composting. *ASAE/CSAE Annual International Meeting*. Ontario, Canada
- [8] Mustin, M. (1987.). "Le compost, gestion de la matiere organique." Edition Francois Dubuse-Paris 947
- [9] Niżewski P., Dach J., Boniecki P., Zastosowanie sztucznych sieci neuronowych do modelowania procesu emisji amoniaku z pól nawożonych gnojowicą. *Inżynieria Rolnicza*. (przyjęty do druku)
- [10] Paillat J. M., Robin P., Hassouna M., Leterme P., 2005 Predicting ammonia and carbon dioxide emissions from carbon and nitrogen biodegradability during animal waste composting. *Atmospheric Environment* 39, p. 6833-6842
- [11] Sommer S. G., Dahl P., 1999 Nutrient and Carbon Balance during Composting of Deep Litter. *J. Agric. Engng. Res.* 74, p. 145-153
- [12] Tadeusiewicz R., Lula P., 2001. *Statistica Neural Networks PL: wprowadzenie do sieci neuronowych*. Stat-Soft Polska, Kraków
- [13] Tiquia S. M., Tam N. F. Y., 1997 Composting of spent pig litter in turned and forced-aerated piles. *Environmental Pollution* 99, p. 329-337
- [14] Tiquia S. M., Tam N. F. Y., 2001 Characterization and composting of poultry litter in forced-aeration piles. *Process Biochemistry* 37, p. 869-880
- [15] Tiquia, S. M., Richard T.L., Honeyman M.S., 2002. Carbon, nutrient, and mass loss during composting. *Nutr. Cycling Agroecosyst.* 62, p. 15-24
- [16] Zvomuya F., Larney F. J., Nichol C. K., Olson A. F., Miller J. J., DeMaere P. R., 2005 Chemical and Physical Changes Following Co-Composting of Beef Cattle Feedlot Manure with Phosphogypsum. *Journal of Environmental Quality*, p. 2318-2327
- [17] Żurada J., Barski M., Jędruch W., 1996. *Sztuczne sieci neuronowe*. Wydawnictwo Naukowe PWN, Warszawa.