

## ZASTOSOWANIE SZTUCZNYCH SIECI NEURONOWYCH DO MODELOWANIA PROCESU EMISJI AMONIAKU Z PÓL NAWOŻONYCH GNOJOWICĄ

Paweł Niżewski, Jacek Dach, Piotr Boniecki

*Instytut Inżynierii Rolniczej, Akademia Rolnicza w Poznaniu*

**Streszczenie.** Problem emisji amoniaku z pól nawożonych gnojowicą jest w ostatnich 20 latach przedmiotem wielu badań. Nawożenie gnojowicą jest bowiem jednym z głównych źródeł zanieczyszczenia atmosfery przez amoniak. Warto podkreślić, że w Europie właśnie rolnictwo jest źródłem ponad 80%  $\text{NH}_3$  emitowanego do atmosfery. W ostatnim czasie różne zespoły badawcze z krajów UE prowadzą doświadczenia mające na celu oszacowanie wielkości emitowanego amoniaku do atmosfery. Działania te skupione są wokół międzynarodowych sieci naukowych, gdzie opracowywane są różne modele pomagające w szacowaniu poziomu emisji amoniaku w poszczególnych krajach.

**Słowa kluczowe:** emisja amoniaku, sieci neuronowe, gnojowica

### Wstęp

Od lat 60. rolnictwo europejskie jest coraz silniejszym źródłem emisji amoniaku do atmosfery. Szacunki przeprowadzone w latach 90. wykazały, iż z rocznej emisji amoniaku w Europie ocenianej na około 8 mln t, aż 72%  $\text{NH}_3$  jest pochodzenia rolniczego [Sapek 1995], przede wszystkim z gospodarki nawozami naturalnymi. Niektóre dane wskazują, iż ten udział przekracza nawet 80% [Martins 1992]. Ulatnianie się amoniaku do atmosfery powoduje wiele bardzo niekorzystnych zmian w ekosystemach, jak również jest powodem znaczących strat ekonomicznych w rolnictwie wskutek zmniejszenia efektywności nawożenia [Dach i in. 1998]. Dlatego od lat 80 prowadzonych jest wiele badań w celu ustalenia czynników wpływających na emisję, inwentaryzacji źródeł emisji oraz opracowania modeli prognostycznych dla różnych warunków stosowania nawozów organicznych, a zwłaszcza płynnych odchodów zwierzęcych (gnojowicy i gnojówki), najczęściej wykorzystywanych w nawożeniu w Zachodniej Europie [Terman 1979; Ryden i in. 1994; Sommer i in. 1991; Asman i in. 1992; Moal i in. 1995; Genermont i in. 1996]. W licznych badaniach stwierdzono, iż wielkość emisji amoniaku uzależniona jest w bardzo różnym stopniu od wielu czynników pogodowych, glebowych, agrotechnicznych oraz charakterystyki samych nawozów. Na bazie prowadzonych badań powstawały różne modele charakteryzujące wielkość emisji w zależności od czynników występujących w czasie nawożenia. Niniejsza praca przedstawia próbę zastosowania sztucznych sieci neuronowych do oceny emisji amoniaku z gnojowicy aplikowanej na polu w różnych technikach rozlewu (tradycyjny rozlew rozbrzygowy, powierzchniowy i doglebowy).

## Cel i zakres badań

Celem przeprowadzonego doświadczenia było zastosowanie technologii sztucznych sieci neuronowych do wytworzenia modelu, umożliwiającego prognozę strat azotu spowodowanych emisją amoniaku w czasie nawożenia pól gnojowicą. Dodatkowym celem było wykorzystanie właściwości technik neuronowych do określenia poziomu istotności poszczególnych czynników agrotechnicznych na badane zjawisko.

Podstawą do podjęcia badań jest rosnąca dynamika zmian zachodzących w gospodarce nawozami naturalnymi, a zwłaszcza intensyfikacja produkcji i przestawianie się wielu gospodarstw z hodowli obornikowej na gnojowicową, niekorzystną dla środowiska naturalnego. W związku z tym, dla oszacowania skali zagrożenia wzrastającą emisją amoniaku podczas nawożenia gnojowicą, istnieje potrzeba opracowania narzędzia do prognozowania tego zjawiska w polskich warunkach.

### Struktura zbioru uczącego

Na podstawie studiów literaturowych oraz badań własnych wybrano czynniki agrotechniczne, które mają znaczący wpływ na emisję  $\text{NH}_3$ . Zaliczono do nich:

- początkową zawartość azotu amonowego ( $\text{N-NH}_4$ ) w gnojowicy,
- dawkę gnojowicy jaka została rozlana na polu,
- okres agrotechniczny, określony jako kolejny tydzień roku,
- metodę jaką gnojowica była rozlewana po polu.

Sukces wytworzenia sieci neuronowej zdeterminowany jest posiadaniem reprezentatywnego zbioru danych, manifestujących modelowane zjawisko [Duch i in. 2000]. Dane empiryczne niezbędne do budowy zbioru danych zbierano na podstawie wyników uzyskanych w rzeczywistych badaniach polowych, prowadzonych przez znaczące ośrodki naukowe w Europie Zachodniej [Asman i in. 1992; Moal i in. 1995; Genermont i in. 1996; Sommer i in. 2000; Sommer i in. 2001; Hujismans 2003]. Czas trwania wszystkich pomiarów wahał się od 58 do 100 godzin po aplikacji gnojowicy. Wiadomo, że ponad 90% strat amoniaku powstaje w ciągu pierwszych 24-36 h. Emisje podczas kolejnych dni osiągają znikomy poziom, dlatego też parametr długości trwania pomiarów został pominięty [Sommer i in. 2001].

Jako zmienne wyjściowe przyjęto 4 wielkości, które stanowiły czynniki agrotechniczne wymienione powyżej. Na ich podstawie przeprowadzona została próba predykcji jednej zmiennej wyjściowej, a mianowicie poziomu emisji amoniaku do atmosfery wyrażonego w postaci procentowej wartości strat początkowej zawartości  $\text{N-NH}_4$  w gnojowicy. Ostateczna postać zbioru danych zawierała 154 wektory uczące (rys. 1) i podzielny został on standardowo na podzbiory w proporcjach 2:1:1 (uczący, walidacyjny, testowy).

## Zastosowanie sztucznych sieci neuronowych...

	1	2	3	4	5
	Zawartość N-NH <sub>4</sub> [g/kg]	Aplikowana dawka [m <sup>3</sup> /ha]	Okres agrotechniczny [-]	Metoda aplikacji	Emisja amoniaku [% TAN]
103	2.5	16.4	36	rozlewanie	67.8
104	2.1	17.3	11	rozlewanie	86.2
105	2.2	17.6	12	rozlewanie	84.8
106	1.8	19.1	16	doglebowo	5.2
107	1.8	17.9	16	doglebowo	2.8
108	1.8	19.2	16	doglebowo	3.8
109	1.8	18.7	16	rozlewanie	57.2
110	2.6	13.5	17	przystawka	30.1
111	2.6	14	17	przystawka	11.9
112	2.6	24.9	17	rozlewanie	66
113	2	11.6	21	rozlewanie	87.7
114	2	15.6	25	doglebowo	9.9
115	2	20.6	25	doglebowo	15.2
116	2	30.8	25	doglebowo	14.1
117	2	31.3	25	doglebowo	15.8
118	2.1	28.1	26	przystawka	50.3
119	2.1	27.1	26	przystawka	38.2


Rys. 1. Zbiór danych do uczenia sieci neuronowej

Fig. 1. Data set for neural network learning

### Przebieg doświadczenia

Do przeprowadzenia eksperymentu wykorzystano symulator sieci neuronowych *Statistica Neural Networks v. 4.0*. Problemy regresyjne w systemie *Statistica Neural Networks* rozwiązywane mogą być przy zastosowaniu następujących typów sieci: perceptronów wielowarstwowych *MLP*, sieci radialnych (bayesowskich), sieci regresyjnych i sieci liniowych [Tadeusiewicz i in. 2001]. Przy zastosowaniu wcześniej utworzonego zbioru danych przeprowadzono szereg testów powyższych typów sieci neuronowych z zastosowaniem *Automatycznego projektanta sieci*. Najlepsze wartości parametrów mówiących o jakości neuronowego modelu regresyjnego uzyskały perceptrony wielowarstwowe *MLP*.


Po przeprowadzonych testach zauważono również, że wartości błędów dla zbiorów walidacyjnego i testowego są bardzo do siebie zbliżone, co sugerowało, że sieć dobrze generalizuje nabytą wiedzę [Żurada i in. 1996]. Zrezygnowano więc ze zbioru testowego i przeznaczono jego przypadki na rzecz powiększenia zbiorów uczącego i walidacyjnego w celu uzyskania jeszcze lepszych wyników. Skupiając się na sieciach typu *MLP* przeprowadzono proces wyszukania odpowiedniej topologii sieci neuronowej przy wykorzystaniu *Projektanta sieci użytkownika*, pozwalającego samodzielnie wybrać architekturę sieci, algorytmy uczące i dostosować współczynniki uczenia. Przetestowano około 2500 różnych konfiguracji sieci *MLP* o 1, 2 lub 3 warstwach ukrytych i stwierdzono, że najlepsze wyniki uzyskała sieć trójwarstwowa z 15-oma neuronami w pierwszej warstwie ukrytej i 5-oma w drugiej (rys. 2). Najodpowiedniejszą natomiast techniką uczenia okazał się algorytm wstecznej propagacji błędów.



Rys. 2. Topologia sieci MLP  
 Fig. 2. Topology of the MLP network

### Charakterystyka perceptronów wielowarstwowych *MLP*

Wśród sporej liczby typów sieci neuronowych perceptrony wielowarstwowe *MLP* (*MultiLayer Perceptrons*) wydają się najbardziej rozpowszechnione. Neurony ułożone są w warstwy, przy czym pomiędzy warstwą wejściową a wyjściową musi znajdować się przynajmniej jedna warstwa ukryta. Neurony tworzą strukturę jednokierunkową, co oznacza że przepływ sygnałów zachodzi tylko w kierunku od wejścia sieci do jej wyjścia. Rys. 3 przedstawia sieć *MLP* o jednej warstwie ukrytej.



Rys. 3. Sieć MLP z jedną warstwą ukrytą [Osowski 2000]  
 Fig. 3. MLP network with one hidden layer [Osowski 2000]

Wagi neuronów tworzących warstwę ukrytą opisane są górnym indeksem (1) a warstwę wyjściową indeksem (2). Impulsy wyjściowe neuronów warstwy ukrytej opisuje symbol  $v_j$ , w którym  $j = 1, 2, \dots, K$ , a warstwy wyjściowej symbol  $y_j$ , w którym  $j = 1, 2, \dots, M$ . Funkcja aktywacji neuronów jest funkcją sigmoidalną unipolarną lub bipolarną. Wektor wejść sieci ma postać  $x = [x_0, x_1, x_2, \dots, x_N]^T$ , gdzie  $x_0$  to jednostkowy sygnał polaryzacji. Wektorowi wejść odpowiadają dwa wektory wyjściowe, mianowicie:

- wektor wyjść sieci aktualnie obliczonych podczas przejścia sygnału przez strukturę sieci  $y = [y_1, y_2, \dots, y_M]^T$
- wektor wzorcowy  $d = [d_1, d_2, \dots, d_M]^T$

Podstawowym celem uczenia sieci jest takie zmodyfikowanie wag wszystkich warstw, aby dla podanych wektorów  $x_i$  otrzymywać na wyjściu wektory  $y_i$  zbliżone z odpowiednią dokładnością do analogicznych im wektorów wzorcowych  $d_i$  dla  $i = 1, 2, \dots, M$ . Możliwe jest włączenie wag polaryzacji do wektora wag poszczególnych neuronów poprzez potraktowanie polaryzacji jako jednej ze składowych wektora wejściowego  $x$ . Impuls wyjściowy  $i$ -tego neuronu warstwy ukrytej charakteryzuje funkcja:

$$v_i = f \left( \sum_{j=0}^N w_{ij}^{(1)} x_j \right) \quad (1)$$

gdzie:

- $w_{ij}$  – jest wektorem wag,
- $x_j$  – wartość wejściowa, indeks 0 - odpowiada sygnałowi i wagom polaryzacji.

Sygnał wyjściowy  $k$ -tego neuronu warstwy wyjściowej opisuje następująca funkcja:

$$y_k = f \left( \sum_{i=0}^K w_{ki}^{(2)} v_i \right) = f \left( \sum_{i=0}^K w_{ki}^{(2)} f \left( \sum_{j=0}^N w_{ij}^{(1)} x_j \right) \right) \quad (2)$$

gdzie:

- $w_{ki}$  – wartości wag poszczególnych neuronów,
- $x_j$  – wartość wejściowa.

Na wartość ostatecznych impulsów wyjściowych  $y_k$  mają wpływ wagi wszystkich warstw sieci. Jeśli sieć posiada większą ilość warstw to na wektor sygnałów wyjściowych warstwy ukrytej wpływ mają wagi danej warstwy i wszystkich warstw poprzedzających ją [Tadeusiewicz 1993; Żurada i in. 1996; Osowski 2000].

## Omówienie wyników

Do oceny jakości wytworzonego modelu neuronowego wykorzystane zostały standardowe narzędzia dostępne w systemie *Statistica Neural Networks v. 4.0*. a rys. 4 przedstawia statystyki obrazujące jakość najlepszego modelu regresyjnego.

Średnia	37.31623
Odch. std.	27.98025
Średni błąd	-0.44376
Odch. błędu	9.42631
Śr. bł. bezwz.	7.59625
Iloraz odch.	0.33689
Korelacja	0.94160

Rys. 4. Statystyki regresyjne

Fig. 4. Regressive statistics

Najistotniejsze informacje zawierają współczynniki: iloraz odchylenia standardowego (iloraz odchylenia standardowego błędów predykcji i odchylenia standardowego zmiennej wyjściowej) i 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.

Dla zmiennych wejściowych przeprowadzona została analiza wrażliwości. Podstawową jej miarą w analizie wrażliwości zaimplementowanej w pakiecie *Statistica Neural Networks v. 4.0* jest *Iloraz* mówiący o wzroście sumarycznego błędu popełnianego przez model przy nieuwzględnieniu rozpatrywanej zmiennej wejściowej. Im *Iloraz* jest większy tym zmienna ma większy wpływ na poprawność predykcji. Analiza wrażliwości pozwoliła ustalić, że z spośród wybranych czynników agrotechnicznych największe znaczenie na wielkość strat azotu w wyniku emisji amoniaku ma sposób rozlewu gnojowicy (kolumna 4, rys. 1). Szereg doświadczeń potwierdza bowiem, że dogłębne wprowadzenie gnojowicy jest najskuteczniejszym sposobem obniżenia emisji amoniaku [Dach i in. 1998].

Na uwagę zasługuje fakt, iż pozostałe z analizowanych czynników mają znacznie mniejszy i zbliżony do siebie wpływ na straty amoniaku. Największe znaczenie w tej grupie miał termin nawożenia, co związane jest z wpływem warunków pogodowych na szybkość ulatniania się amoniaku, zwłaszcza temperatury, wilgotności powietrza oraz prędkości wiatru. Czynnikiem ten wydaje się mieć minimalne znaczenie przy dogłębowym wprowadzeniu gnojowicy, co potwierdzone jest w licznych badaniach [Huijsmans 2003].

## Wnioski

1. Na podstawie badań stwierdzono, iż techniki neuronowe są właściwym narzędziem predykcyjnym umożliwiającym wytworzenie modelu opisującego proces emisji amoniaku przy danych parametrach.
2. Ustalono, że największy wpływ na wielkość strat azotu w wyniku emisji amoniaku ma sposób rozlewu gnojowicy. Pozostałe z analizowanych czynników posiadały znacznie mniejszy wpływ na emisję amoniaku, przy czym w grupie tej największe znaczenie ma termin nawożenia.

## Bibliografia

- Asman W.A.H., Jaarveld H.A.** 1992. Ammonia emission for use in atmospheric transport model. W: Ammonia emissions in Europa: Emission coefficients and abatement costs. Proceedings of a Workshop held 4-6 February at IIASA. Laxenburg, Austria. CP-92-04 September 1992. s. 3-16.
- Dach J., Sęk T.** 1998. Aerodynamiczne metody pomiaru strat amoniaku z obornika i gnojowicy. IV Międzyn. Konf. Nauk. "Problemy intensyfikacji produkcji zwierzęcej przy uwzględnieniu ograniczeń ochrony środowiska". IBMER. Warszawa. s. 347-353.
- Duch W.** (red.) 2000. Biocybernetyka i inżynieria biomedyczna. Tom 6: Sieci neuronowe. Exit. Warszawa.
- Genermont S., Cellier P., Morvan T., Flura D., Laville P.** 1996. Mesure de la volatilisation d'ammoniac a l'aide de la methode aerodynamique dans les conditions de la pratique agricole. C. R. Acad. Sci. Paris, Sciences de la vie. Ecologie 319. s. 1145-51.
- Huijsmans J.F.M.** 2003. Manure application and ammonia volatilization. PhD thesis. Wageningen University. The Netherlands.
- Martins O.** 1992. Loss of Nitrogenous Compounds during Composting of Animal Wastes. Biore-sources Technology. Vol. 42. s. 103-111.
- Moal J.F., Martinez J.** 1995. Emission d'ammoniac apres epandage de lisier: le probleme. Ingenieries – EAT. Vol. 1. s. 53-60.
- Oowski S.** 2000. Sieci neuronowe do przetwarzania informacji. Oficyna Wydawnicza Politechniki Warszawskiej. Warszawa.
- Ryden J.C., McNeill J.E.** 1984. Application of the micrometeorological mass balance method to the determination of ammonia loss from a grazed sward. J. Sci. Food Agric. Vol. 35. s. 1297-1310.
- Sapek A.** 1995. Emisja amoniaku z produkcji rolnej. Postępy Nauk Rolniczych. Nr 2. s. 3-23.
- Sommer G.S., Olesen J.E., Christensen B.T.** 1991. Effects of temperature, wind speed and air humidity on ammonia volatilisation from surface applied cattle slurry. Journal of Agricult. Science. Vol. 117. Cambridge. s. 91-100.
- Sommer S.G., Olesen J.E.** 2000. Modelling ammonia volatilization from animal slurry applied with trail hoses to cereals. Atmospheric Environment. Vol. 34. s. 2361-2372.
- Sommer S.G., Hutchings N.J.** 2001. Ammonia emission from field applied manure and its reduction-invited paper. European Journal of Agronomy. Vol. 15. s. 1-15.
- Tadeusiewicz R.** 1993. Sieci neuronowe. Akademicka Oficyna Wydawnicza, Warszawa.
- Tadeusiewicz R., Lula P.** 2001. Statistica Neural Networks PL: Wprowadzenie do sieci neuronowych. StatSoft Polska. Kraków.
- Terman G.L.** 1979. Volatilization losses of nitrogen as ammonia from surface-applied fertilizers, organic amendements, and crop residues. Advances in Agronomy. Vol. 31. s. 189-221.
- Żurada J., Barski M., Jędruch W.** 1996. Sztuczne sieci neuronowe. Wydawnictwo Naukowe PWN. Warszawa.

## **ARTIFICIAL NEURAL NETWORKS FOR MODELLING AMMONIA EMISSION FROM FIELD APPLIED SLURRY MANURE**

**Summary.** For the last 20 years the problem of ammonia emission from the fields fertilized with a liquid manure has been a subject of many research. Liquid manure fertilization became one of the main sources of atmospheric ammonia pollution. In Europe the agronomy produces more than 80% of NH<sub>3</sub> emitted into the atmosphere. During the last years different scientific teams carried on the research concerning an estimation of ammonia emission size and the factors influencing on this emission. These activities are focused around an international concerted actions where the different models of ammonia emissions are developed for many countries and different conditions.

**Key words:** ammonia emission, neural networks, slurry manure

**Adres do korespondencji:**

Jacek Dach; e-mail: [jdach@au.poznan.pl](mailto:jdach@au.poznan.pl)  
Instytut Inżynierii Rolniczej  
Akademia Rolnicza w Poznaniu  
ul. Wojska Polskiego 50  
60-627 Poznań