

## NEURONOWA ANALIZA SPEKTRUM SYGNAŁU AKUSTYCZNEGO W OKREŚLaniu CECH FIZYCZNYCH ZIARNIAKÓW

Robert J. Tomczak, Jerzy Weres

*Instytut Inżynierii Rolniczej, Uniwersytet Przyrodniczy w Poznaniu*

**Streszczenie.** W pracy poddano analizie możliwość wytworzenia modelu neuronowego zależności pomiędzy charakterem częstotliwościowym sygnału akustycznego generowanego w trakcie swobodnego transportu grawitacyjnego ziarniaków kukurydzy a ich wilgotnością. Wytworzono modele neuronowe, określono ich jakość i generowane błędy pomiarowe.

**Słowa kluczowe:** sieć neuronowa, pomiar, ocena, wilgotność, kukurydza

### Wstęp

Jednym z najważniejszych parametrów fizycznych wpływających na ocenę ziarna, zarówno z punktu widzenia jego obróbki termicznej, jak i jego przechowywania, jest zawartość wody związanej fizycznie w ziarnie. Jednocześnie najprostszą metodą realizacji ciągłego transportu surowców sypkich, do których zaliczają się nasiona i ziarniaki roślin rolniczych, jest spadek grawitacyjny. Sytuacja, w której materiał transportowany jest z użyciem spadku swobodnego, bez realizowania przerw w procesie transportu, jest stosunkowo łatwa do wywołania, a często stanowi stały i niezbędny element tego procesu. W trakcie spadku swobodnego generowany jest złożony sygnał akustyczny: zarówno przez spadający materiał, jak i w układzie materiał – środowisko transportowe.

Najprostszą oceną złożonego sygnału akustycznego jest pomiar ciśnienia akustycznego tego sygnału. W wielu przypadkach jest on wystarczający tylko do oceny głośności środowiska, wyznaczenia różnicy pomiędzy sygnałem tła a sygnałem mierzonym i pomiaru wartości skutecznej sygnału [Jakubowska, Kukielka 2006, Herbert, Stennin 1996, Amodeh i in. 2006]. W przypadku złożonego sygnału dźwiękowego, w którym istotna informacja zawarta jest w jego charakterystyce częstotliwościowo-amplitudowej, wymagane są narzędzia umożliwiające bardziej szczegółową analizę. Jednym z najczęściej stosowanych narzędzi jest szybka transformata Fouriera (FFT, ang. Fast Fourier Transform) [Lynn, Furter 1994, Zieliński 2006].

Wykorzystanie sieci neuronowych do modelowania procesów zachodzących w przetwórstwie rolno-spożywczym, a w szczególności parametrów fizycznych ziarna było przedmiotem wielu badań, obejmujących szerokie spektrum cech, których znajomość lub możliwość predykcji jest istotna zarówno w kontekście poznawczym, jak i praktycznym [Francik, Hebda 2005; Tukiendorf 2005; Koszela i in. 2005]. Bardzo często w pracach uzyskiwano modele o bardzo wysokiej jakości, dlatego zdecydowano się wykorzystać tę metodę do modelowania analizowanej relacji.

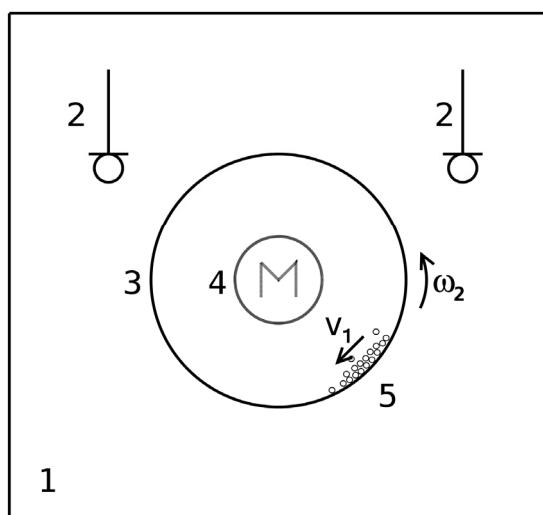
## Cel

Celem badań było opracowanie oraz sprawdzenie oryginalnej metody przeznaczonej do ciągłej oceny parametrów fizycznych ziarna opartej na analizie spektrum sygnału akustycznego i modelowaniu neuronowym, poprzez uzyskanie odpowiedzi na pytanie: Jaki typ modelu neuronowego najlepiej dokonuje interpretacji określonych cech charakteryzujących środowisko badawcze?

## Metodyka

Źródłem danych do budowy modeli neuronowych było stanowisko doświadczalne (rys. 1) służące do generowania ciągłego sygnału akustycznego w układzie obiekt – bieżnia w wyniku spadku grawitacyjnego obiektu. Stanowisko umożliwia precyzyjną regulację prędkości bieżni. Obiektem generującym sygnał były ziarniaki dwóch odmian kukurydz.

Dane przekształcono z użyciem szybkiej transformaty Fouriera, a następnie podzielono na pasma częstotliwości o szerokości 500 Hz, których wartości stanowiły zmienne wejściowe dla SSN. Łączna liczba próbek zbioru referencyjnego wykorzystanego do uczenia sieci wyniosła 5246, a zbiorów testowych o różnorodnej charakterystyce wykorzystanych do analizy jakości wytworzonych sieci 11107 próbek.



Rys. 1. Schemat stanowiska pomiarowego (1 – komora, 2 – mikrofony, 3 – pojemnik, 4 – silnik, 5 – złożo ziarna,  $v_1$  – wektor prędkości ziarna,  $\omega_2$  – wektor prędkości obrotowej pojemnika)  
Fig. 1. Measurement setup diagram (1 – chamber, 2 – microphones, 3 – container, 4 – motor, 5 – seed deposit,  $v_1$  – seed velocity vector,  $\omega_2$  – container rotational speed vector)

## Wyniki

Na podstawie jednego z czterech zbiorów danych, zróżnicowanych ze względu na serię badawczą i prędkość obrotową pojemnika, wygenerowane zostały trzy modele neuronowe. Statystyki wytworzonych sieci przedstawia tab. 1. Wytworzone modele charakteryzują się niskimi wartościami ilorazu odchyлеń standardowych wyników i wartości oczekiwanych, przedstawionych jako jakość uczenia. Przyjmuje się, że wartość tego ilorazu na poziomie równym lub mniejszym od 0,1 świadczy o dobrej realizacji regresji przez sieć [Tadusiewicz 1993]. Średni błąd kwadratowy dla tych sieci przyjmuje bardzo niskie wartości. Wartości tych parametrów dla sieci liniowej są gorsze, jednakże na poziomie pozwalającym stwierdzić, iż modelowane zjawisko ma charakter quasiliniowy.

Tabela 1. Statystyki wytworzonych sieci  
Table 1. Statistics of generated networks

Symbol sieci	Schemat sieci	Jakość		Błąd	
		Walidacji	Testowania	Walidacji	Testowania
$\alpha$	Liniowa 45:45-1:1	0,1356	0,1748	0,0422	0,0556
$\beta$	MLP 45:45-7-1:1	0,0508	0,0588	0,0126	0,0149
$\gamma$	MLP 45:45-20-8-1:1	0,0437	0,0607	0,0108	0,0200

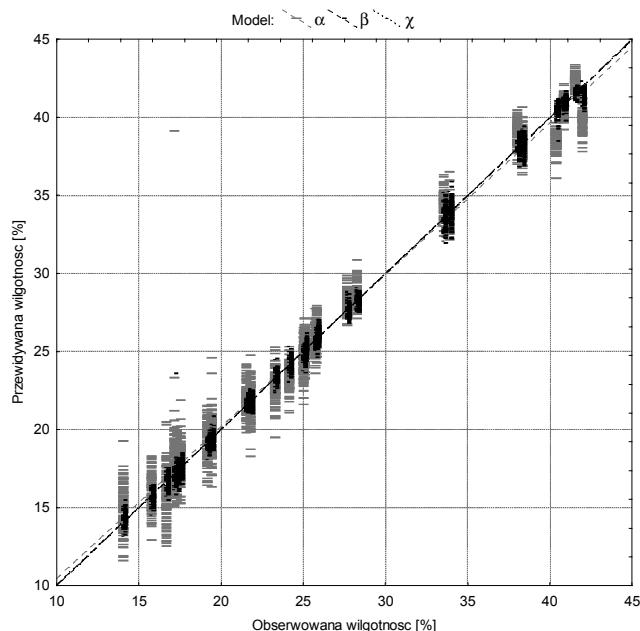
Obserwując wskaźniki: średniego błędu bezwzględnego i odchylenia standardowego tego błędu (tab. 1) można stwierdzić, że sieci MLP dokonują predykcji wilgotności z przeciętną odchyłką wynoszącą poniżej 1 punktu procentowego, a sieć liniowa poniżej 2 punktów, przy założonych warunkach pomiarowych.

Analiza dopasowania liniowego wskazuje na niewielkie przesunięcie dodatnie prostej, przy niewiele mniejszym od jedności wskaźniku nachylenia. Oznacza to, że model zawyża predykowane wartości dla niższych wilgotności, a zaniża dla wyższych.

Rozrzut danych przewidywanych jako funkcji danych oczekiwanych i proste dopasowania liniowego przedstawiono na rys. 2.

Wartości opisujące działanie modelu (tab. 2) należy przeanalizować ze szczególną uwagą. Wysokie wartości błędu i odchylenia błędu oraz stosunkowo wysoka, choć jeszcze akceptowalna, wartość ilorazu odchyłeń sugerują niepoprawne działanie modelu, odwrotnie niż wysoka wartość współczynnika korelacji. Analiza prostych dopasowania wskazuje przyczynę rozbieżności. Wyniki takie wywołane są wysokimi wartościami przesunięcia prostych, przy czym należy zwrócić szczególną uwagę na kąt ich odchylenia (rys. 2). Kąt ten w przypadku sieci MLP jest stosunkowo duży, co przy przesunięciu osi, pozwala na wysoką wartość korelacji zmiennych w ograniczonym zakresie; w przypadku sieci liniowej jego wartość jest zbliżona do jedności.

Pozwala to na przyjęcie hipotezy, że jest możliwe dokonanie kalibracji modelu z użyciem jednej analizy określającej wartość, o którą model zawyża tutaj lub zaniża predykowaną wilgotność dla różnych odmian.



Rys. 2. Rozkład predykcji dla analizowanych sieci o 45 wejściach  
 Fig. 2. Distribution of prediction for analysed networks with 45 inputs

Tabela 2. Regresja i współczynniki dopasowanych prostych  
 Table 2. Regression and coefficients of matched up straight lines

Symbol	Średni błąd bezwzględny	Odchylenie standardowe	Iloraz odchylen	Współczynnik korelacji	Dopasowanie a+bx	
					a	b
$\alpha$	0,9640	1,3028	0,1523	0,9883	0,7428	0,9720
$\beta$	0,3372	0,4528	0,0529	0,9986	0,0752	0,9960
$\gamma$	0,2860	0,4165	0,0487	0,9988	0,0846	0,9970

## Wnioski

1. Istnieje quasi liniowa zależność pomiędzy charakterystyką częstotliwościową generowaną w układzie ziarno – kanał transportowy w trakcie spadku swobodnego a wilgotnością ziarna.
2. Wygenerowane modele charakteryzowały się dobrymi parametrami i wysoką jakością. Najbardziej uniwersalny i obarczony najmniejszym błędem okazał się model oparty na perceptronie wielowarstwowym.

## Bibliografia

- Amoodeh, M. T., Khosthagaza, M. H. i Minaei, S.** 2006. Acoustioc on-line grain moisture meter, Computers and Electronics in Agriculture 52. s. 71-78.
- Berbert, P. A. i Stennin, B. C.** 1996. On-line Moisture Content Measurement of Wheat, Jurnal of Agricultural Engineering Resources 65. s. 287–296.
- Francik S., Hebda T.** 2005. Wyznaczanie gęstości nasion jęczmienia jarego przy wykorzystaniu sztucznych sieci neuronowych. Inżynieria Rolnicza. Nr 10(70). Kraków. s. 83-90.
- Jakubowska M., Kukielka L.** 2006. Optymalizacja procesu rozróżniania składników mieszaniny kamieni i bulw ziemniaka metodą emisji akustycznej. Inżynieria Rolnicza. Nr 12(87). s. 189–197.
- Lynn P. A. i Fuerst W.** 1994. Digital signal processing with computer applications. John Wiley and Sons. New York.
- Tadusiewicz, R.** 1993. Sieci neuronowe, Akademicka Oficyna Wydawnicza, Warszawa. ISBN 83-85769-03-X
- Tukiendorf M.** 2005. Zastosowanie sieci FBM w neuronowym modelowaniu mieszania dwuskładnikowych układów ziarnistych. Inżynieria Rolnicza. Nr 14 (74). s. 367-373.
- Zielinski, T. P.** 2006. Cyfrowe przetwarzanie sygnałów. Od teorii do zastosowań. Wyd. 2. WKiŁ Warszawa. ISBN 978-83-206-1640-8.

## NEURAL ANALYSIS OF ACOUSTIC SIGNAL SPECTRUM DURING DETERMINATION OF SEED PHYSICAL PROPERTIES

**Abstract.** The paper presents an analysis of possibility to develop a neural model for relationship between frequency-related character of an acoustic signal generated during free gravitational transport of corn seeds and their humidity. Neural models were developed, and their quality and generated measurement errors were determined.

**Key words:** neural network, measurement, assessment, humidity, corn

**Adres do korespondencji:**

Robert J. Tomczak; e-mail: rjt@up.poznan.pl  
Instytut Inżynierii Rolniczej  
Uniwersytet Przyrodniczy w Poznaniu  
ul. Wojska Polskiego 50  
60-624 Poznań