

## **NEURONOWA ANALIZA ZDJĘĆ ULTRASONOGRAFICZNYCH W PROCESIE IDENTYFIKACJI POZIOMU ZAWARTOŚCI TŁUSZCZU – BADANIA WSTĘPNE**

Andrzej Przybylak, Piotr Boniecki, Radosław J. Kozłowski

*Instytut Inżynierii Rolniczej, Uniwersytet Przyrodniczy w Poznaniu*

Piotr Ślósarz

*Katedra Hodowli Owiec, Kóz i Zwierząt Futerkowych, Uniwersytet Przyrodniczy w Poznaniu*

**Streszczenie.** Rozwiązywanie problemu identyfikacji ilości tłuszcza wmięsie, na podstawie informacji zawartej w obrazie ultrasonograficznym wykonanym na żywym zwierzęciu, ma istotne znaczenie utylitarne. W pracy zaproponowano wykorzystanie nowoczesnych metod sztucznej inteligencji, a w szczególności aproksymacyjnych technik sztucznych sieci neuronowych.

**Słowa kluczowe:** zawartość tłuszcza, ultrasonografia, analiza obrazu, sieci neuronowe

### **Wstęp**

Tusze zwierzęce o małym otluszczeniu wewnętrzny i dużym udziale mięsa są towarem poszukiwanym na rynku. Otluszczenie tuszy w momencie uboju zwierzęcia ma istotny wpływ na jej wartość rynkową. Wstępna ocenę otluszczenia żywych zwierząt można przeprowadzić na podstawie analizy wieku zwierząt, ich masy ciała oraz płci. Jednak w celu dokładnego oszacowania składu tkankowego należy poszukiwać bardziej obiektywnych metod oceny. Nowoczesne aparaty USG pozwalają na uzyskiwanie doskonalej jakości obrazów przekroju tkanek i precyzyjny pomiar m. in. grubości warstwy tłuszcza podskórneg. Dodatkową zaletą wynikającą z wykorzystania ultrasonografii jest jej nieinwazyjny charakter. Odzwierciedlenie ilości i rozmieszczenia tłuszcza śródmięśniowego na przekroju poprzecznym mięśnia definiowane jest za pomocą pojęcia marmurkowatości. Umiarkowana marmurkowatość, jednolicie rozmieszczona, jest cechą jakościowo pożądaną, szczególnie w procesie oceny mięsa bydlęcego. Nadmierna marmurkowatość może ograniczyć lub całkiem wyeliminować jego przydatność przetwórczą [Ślósarz 2004]. Obecnie ocena poziomu tłuszcza dokonywana jest po przeprowadzeniu uboju zwierząt. Możliwa jest też analiza w czasie rzeczywistym na żywym zwierzęciu przy wykorzystaniu ultrasonografu połączonego z komputerem, wyposażonym w odpowiedni system informatyczny pracujący w oparciu o wygenerowane modele neuronowe.

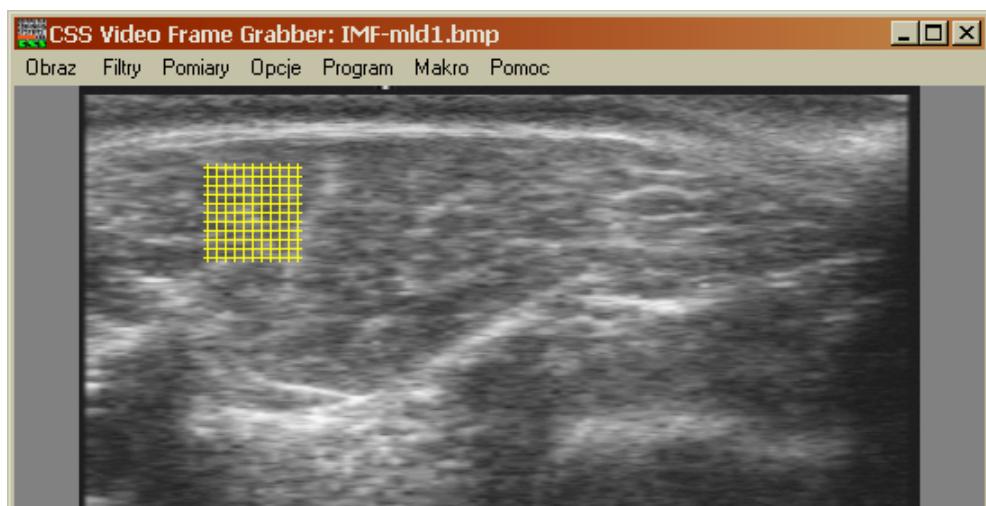
Z uwagi na charakter danych reprezentatywnych uzyskanych ze zdjęć ultrasonograficznych, właściwym wydaje się wybór modeli neuronowych jako instrumentów służących do oceny skali marmurkowatości.

## Cel badań

Praca jest próbą wykorzystania technik analizy obrazu oraz modelowania neuronowego w procesie identyfikacji poziomu zawartości tłuszcza w tkance mięśniowej u żywych zwierząt hodowlanych na podstawie informacji zakodowanych w postaci zdjęć ultrasonograficznych.

## Metodyka

Przedmiotem badań były dane zebrane w czterech kolejnych latach (2000–2003). Każda grupa zwierząt miała wykonane zdjęcia ultrasonograficzne grzbietowej tkanki mięśniowej, a po uboju od każdego zwierzęcia pobrane zostały próbki tejże tkanki w celu określenia poziomu zawartości tłuszcza.



Rys. 1. Pobieranie danych empirycznych z wykorzystaniem próbnika w programie MultiScan  
Fig. 1. Acquiring the dataset with MultiScan probe tool

Całość uzupełniona została o następujące informacje:

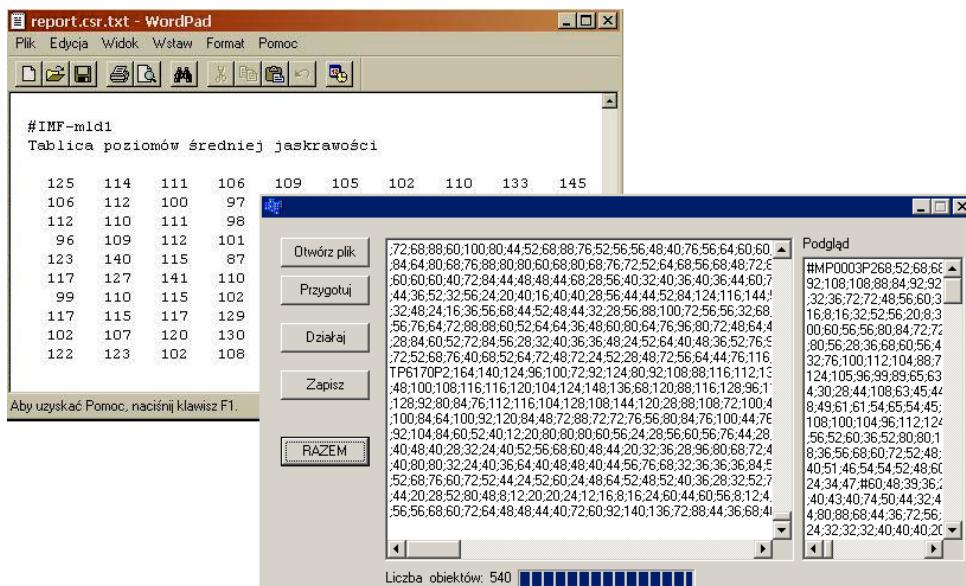
- KOD – unikalny w skali całej bazy numer identyfikacyjny poszczególnych zwierząt,
- TERMIN – oznaczenie kodujące wiek uboju zwierzęcia (1 = 100 dni, 2 = 200 dni, 3 = 140 dni), wiek ten może wpływać na masę ciała i otłuszczenie zwierzęta,
- PL – płeć zwierzęcia,
- ROCZNIK – rok wykonania doświadczenia; w różnych latach występują odmienne warunki środowiskowe (pogoda, jakość paszy), co może wpływać na zwierzęta,
- TUR – liczba jagniąt w miocie, część z nich urodziła się jako jedynaki (TUR = 11), część jako bliźnięta (TUR = 22), co może mieć wpływ na tempo ich wzrostu i w konsekwencji otłuszczenie,

## Neuronowa analiza zdjęć...

- MPU – masa ciała przed ubojem [kg]; zwierzęta o większej masie ciała w danym wieku są z reguły bardziej otluszczone,
- GTP – grubość warstwy tłuszczu podskórnego [mm] – zmierzona u żywych zwierząt na obrazach ultrasonograficznych. Grubość warstwy tłuszczu ma związek z ogólnym otluszczeniem zwierzęcia,
- WOP – głębokość (grubość) przekroju poprzecznego mięśnia najdłuższego grzbietu [mm] zmierzona na obrazach ultrasonograficznych,
- POP – pole powierzchni przekroju poprzecznego mięśnia najdłuższego grzbietu [ $\text{cm}^2$ ] zmierzona na obrazach USG. Oba pomiary (WOP i POP) mają przede wszystkim związek z umięśnieniem zwierzęcia ale również z otluszczeniem (kwestią proporcji obu tych tkanek).

Ze zdjęć ultrasonograficznych pobrane zostały dane empiryczne przy wykorzystaniu programu MultiScan. Uzyskano w ten sposób macierze odcienni szarości dla wszystkich obrazów USG. Każda macierz zawiera przekonwertowaną i zakodowaną informację o „poziomie szarości” 100 uśrednionych punktów użytego próbnika obrazu (ramka 40x40 pikseli, z czego wartości 2 x 2 piksele uśredniane były do jednej zmiennej) reprezentując liczby w zakresie 0 – 255 (8 bitowa skala „szarości”:  $2^8$ ).

W dalszej kolejności dane zostały przetworzone do postaci akceptowalnej przez symulator sieci neuronowych Statistica v8.0. Do konwersji użyty został, specjalnie do tego celu wytworzony, oryginalny moduł generujący pliki w formacie CSV.



Rys. 2. Przykładowa macierz odcienni szarości oraz moduł konwertujący dane do formatu \*.csv  
Fig. 2. Example of grey-tint data matrix and tool converting data to \*.csv file

Na zbiorze uczącym, zawierającym 110 zmiennych i 1690 przypadków (845 przypadków uczących, 423 walidacyjnych i 422 testowych), przeprowadzone zostały badania wstępne, w których użyte zostało efektywne narzędzie zaimplementowane w pakiecie Statistica v.8.0, jakim jest „automatyczny projektant”. Następnie wykonano cykl eksperymentów symulacyjnych mających na celu wygenerowanie optymalnej sieci (ze względu na postawione zadanie). Poszukiwana topologia sieci neuronowej powinna rozwiązać problem regresyjny, polegający na identyfikacji ciąglej zmiennej liczbowej (opisującej poziom zawartości tłuszcza) w oparciu o zbiór wektorów danych wejściowych, opisujący reprezentatywne cechy badanego problemu. Z uwagi na potencjalne zastosowanie praktyczne wygenerowany model neuronowy powinien posiadać wysoką zdolność do generalizacji (uogólniania nabytej wiedzy) [Boniecki 2004].

| 1<br>KOD | 2<br>TERMIN | 3<br>PL     | 4<br>ROZNIK | 5<br>TUR      | 6<br>MPU      | 7<br>GTP      | 8<br>WOP      | 9<br>Zmn9     | 10<br>POP     | 11<br>Zmn11   | 12<br>Zmn12   | 13<br>Zmn13   | 14<br>Zmn14   |                |
|----------|-------------|-------------|-------------|---------------|---------------|---------------|---------------|---------------|---------------|---------------|---------------|---------------|---------------|----------------|
| MP0010P  | 1           | 2           | 2002        | 22            | 27,2          | 1             | 26            | 9,78          | 49            | 56            | 64            | 60            | 49            |                |
| MP0010P  | 1           | 2           | 2002        | 22            | 27,2          | 1             | 26            | 9,78          | 54            | 52            | 43            | 56            | 65            |                |
| MP0010P  | 1           | 2           | 2002        | 22            | 27,2          | 1             | 26            | 9,78          | 51            | 52            | 45            | 53            | 57            |                |
| MP0010P  | 1           | 2           | 2002        | 22            | 27,2          | 1             | 26            | 9,78          | 58            | 57            | 56            | 78            | 68            |                |
| MP0010P  | 97<br>Zmn97 | 98<br>Zmn98 | 99<br>Zmn99 | 100<br>Zmn100 | 101<br>Zmn101 | 102<br>Zmn102 | 103<br>Zmn103 | 104<br>Zmn104 | 105<br>Zmn105 | 106<br>Zmn106 | 107<br>Zmn107 | 108<br>Zmn108 | 109<br>Zmn109 | 110<br>Tłuszcz |
|          | 69          | 60          | 68          | 71            | 93            | 64            | 72            | 63            | 68            | 66            | 64            | 67            | 61            | 1,25           |
|          | 55          | 56          | 87          | 63            | 77            | 87            | 67            | 61            | 64            | 64            | 71            | 73            | 101           | 1,25           |
|          | 79          | 70          | 65          | 93            | 86            | 71            | 62            | 62            | 57            | 54            | 60            | 68            | 66            | 1,25           |
|          | 70          | 66          | 61          | 63            | 61            | 62            | 76            | 73            | 58            | 55            | 66            | 81            | 70            | 1,25           |
|          | 55          | 53          | 59          | 59            | 54            | 77            | 77            | 59            | 57            | 54            | 52            | 52            | 54            | 1,25           |
|          | 62          | 56          | 57          | 70            | 62            | 60            | 64            | 65            | 77            | 76            | 71            | 50            | 51            | 1,25           |
|          | 99          | 118         | 113         | 58            | 64            | 66            | 65            | 88            | 88            | 79            | 91            | 88            | 82            | 1,25           |
|          | 64          | 56          | 62          | 121           | 107           | 71            | 59            | 56            | 59            | 58            | 57            | 71            | 69            | 1,25           |

Rys. 3. Wybrane fragmenty zbioru uczącego

Fig. 3. Selected fragments of the dataset

## Wyniki

Jako zmienna wyjściową przyjęto zawartość tłuszcza (ramka na rys.3). Proces uczenia przeprowadzono technika „z nauczycielem”. Zbiór dziesięciu najlepszych otrzymanych sieci zaprezentowano na rys. 4.

|    | typ                   | jakosc ucz | blad wal | blad test | uczenie     |
|----|-----------------------|------------|----------|-----------|-------------|
| 1  | RBF 109:109-68-1:1    | 0,833056   | 0,856782 | 0,866317  | SS,KN,PI    |
| 2  | RBF 109:109-37-1:1    | 0,844732   | 0,854352 | 0,859122  | KM,KN,PI    |
| 3  | RBF 109:109-34-1:1    | 0,840960   | 0,853496 | 0,867265  | KM,KN,PI    |
| 4  | RBF 109:109-44-1:1    | 0,828440   | 0,845223 | 0,861882  | KM,KN,PI    |
| 5  | Liniowa 109:109-1:1   | 0,814075   | 0,197475 | 0,202234  | PI          |
| 6  | MLP 109:109-15-19-1:1 | 0,793805   | 0,148017 | 0,153040  | BP100,CG38b |
| 7  | MLP 109:109-17-1:1    | 0,807805   | 0,146907 | 0,149530  | BP100,CG36b |
| 8  | MLP 109:109-11-1:1    | 0,652674   | 0,142858 | 0,147950  | BP100,CG69b |
| 9  | MLP 109:109-18-13-1:1 | 0,750532   | 0,142791 | 0,144266  | BP100,CG45b |
| 10 | MLP 109:109-17-1:1    | 0,670504   | 0,141782 | 0,150927  | BP100,CG62b |

Rys. 4. Zbiór dziesięciu najlepszych modeli neuronowych

Fig. 4. Ten best neural network models

## Neuronowa analiza zdjęć...

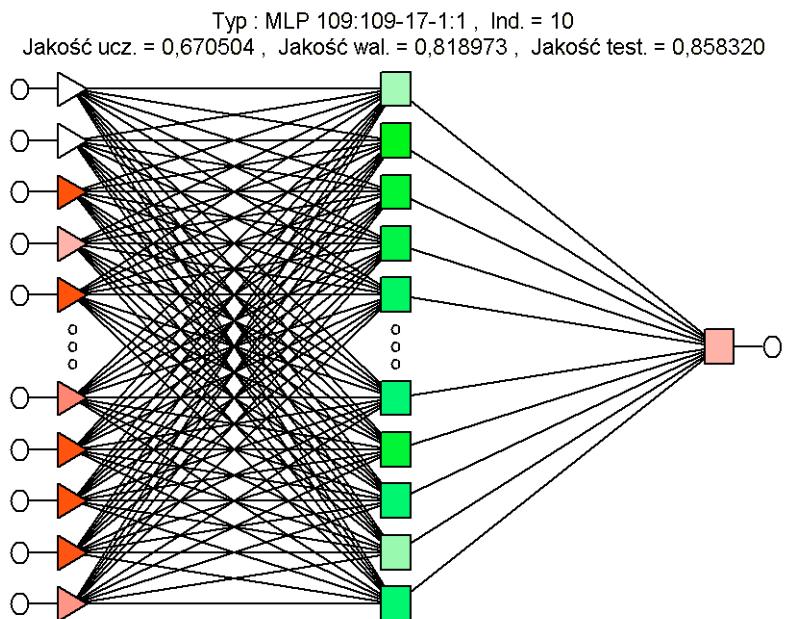
---

W procesie uczenia sieci wykorzystane zostały następujące algorytmy:

- algorytm wstecznej propagacji błędów (ang. Back Propagation, BP) - jest to podstawowy algorytm uczenia nadzorowanego wielowarstwowych jednokierunkowych sieci neuronowych. Polega na takiej zmianie wag sygnałów wejściowych każdego neuronu w każdej warstwie, by wartość błędu dla kolejnych par uczących zawartych w zbiorze uczącym była jak najmniejsza. Wykorzystuje on w tym celu metodę gradientową - najbliższego spadku,
- algorytm gradientów sprzężonych (ang. Conjugate Gradient, CG) - jest to zaawansowana metoda uczenia perceptronów wielowarstwowych. Działa on zwykle znacznie lepiej niż algorytm wstecznej propagacji błędów, zaś zakresy zastosowań obu algorytmów uczenia pokrywają się,
- algorytm pseudoinwersji (ang. Pseudo-Inverse, PI) - stosowany jest do określenia wartości wag w ścisłe liniowej warstwie wyjściowej sieci neuronowej. Algorytm pseudoinwersji wykorzystuje liniową technikę dekompozycji według wartości szczególnych do wyznaczenia macierzy pseudoodwrotnej, która potrzebna jest do określenia wartości wag,
- algorytm próbkowania (ang. Sub-Sample, SS),
- algorytm K-średnich (ang. K-Means, KM) - algorytm wyznacza centra radialne, które przechowywane są w neuronach radialnych znajdujących się w pierwszej warstwie ukrytej sieci. Celem działania algorytmu k-średnich jest określenie zbioru centrów skupień, które w najlepszy sposób reprezentują rzeczywisty rozkład przypadków uczących,
- algorytm K-najbliższych sąsiadów (ang. K-Nearest Neighbour, KN) – metoda wyznacza odchylenia neuronów radialnych w oparciu o odległość RMS (RMS - root mean squared) od k neuronów najbliższych położonych od danego neuronu (ale nie pokrywających się z nim).

Modelem neuronowym najlepiej realizującym badane zagadnienie okazał się perceptron wielowarstwowy (ang. Multi-Layer Perceptron, MLP). Perceptrony wielowarstwowe są to jednokierunkowe sieci neuronowe z liniowymi funkcjami potencjału postsynaptycznego i (zwykle) nieliniowymi funkcjami aktywacji. Najlepsza z wygenerowanych sieci posiada 109 wejść oraz 17 neuronów w warstwie ukrytej. Uczona była algorytmami wstecznej propagacji błędów (BP) oraz gradientów sprzężonych (CG).

Zwycięski model o strukturze 109 wejść, 17 neuronów w warstwie ukrytej oraz jednym wyjściu (rys. 5) posiada najmniejszy błąd walidacyjny. Wzrost tego błędu na pewnym etapie uczenia wskazuje na przeuczenie sieci (nadmiernie dopasowanie się do konkretnych danych ze zbioru uczącego). Algorytm może się wtedy zatrzymać i odzyskać sieć z takiego etapu uczenia, gdy błąd walidacyjny był najmniejszy, unikając wady przeuczenia. Automatyczny projektant zawsze korzysta z tej możliwości. Błąd testowy stanowi ostateczną weryfikację sieci [Tadeusiewicz 1993]. Przy podejmowaniu decyzji, której sieci użyć powinniśmy przede wszystkim brać pod uwagę błąd walidacyjny. Błąd uczący bardzo niewiele mówi o zdolności sieci do znajdowania poprawnych wartości wyjściowych dla nowych danych na wejściu. W zasadzie nie ma powodu, aby do wyboru sieci używać błędu testowego, którego właściwym celem jest końcowa weryfikacja jakości. Błąd testowy nadaje się do diagnozowania problemów z uczeniem sieci [Osowski 2000 ].



Rys. 5. Schemat sieci neuronowej o najlepszych parametrach  
Fig. 5. Optimal neural network scheme

## Podsumowanie

Po przeprowadzeniu wstępnych badań można wnioskować, iż właściwym był wybór modelu neuronowego jako narzędzia do identyfikacji poziomu zawartości tłuszcza w tkance mięśniowej. Opracowany model dokonuje klasyfikacji w zbiorze danych, jednak wyniki obarczone są błędem. Sugeruje to celowość ponownej akwizycji danych empirycznych i dalszą ich obróbkę w celu zoptymalizowania działania modelu. Uzasadnionym wydaje się być również poszukiwanie innych cech charakterystycznych, pełniej reprezentujących badane zagadnienie.

## Bibliografia

- Boniecki P.** 2004. Sieci neuronowe typu MLP oraz RGB jako komplementarne modele aproksymacyjne w procesie predykcji plonu pszenicy. *Journal of Research and Application in Agricultural Engineering*, Vol. 49(1). Poznań. s. 28-30.
- Osowski S.** 2000. Sieci neuronowe do przetwarzania informacji. Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa. ISBN 83-7207-187-X
- Ślósarz P.** 2004. Ultrasonograficzne pomiary umięśnienia i otluszczenia w ocenie wartości hodowlanej jagniąt białogłównej owcy mięsnej. *Rocz. AR Poznań. Rozpr. Nauk. Zeszyt nr 347*. s. 73.
- Tadeusiewicz R.** 1993. Sieci Neuronowe. Akademicka Oficyna Wydawnicza, RM Warszawa. s. 49-62.

Neuronowa analiza zdjęć...

---

## **NEURAL ANALYSIS OF THE ULTRASONOGRAPHIC IMAGES IN THE INTRAMUSCULAR FAT LEVEL CONTENT IDENTIFICATION PROCESS - PRELIMINARY RESEARCH**

**Abstract.** The solution of the problem in the identification process of the quantity of the intramuscular fat, on the basis of contained information in the ultrasonographic photo from living animal, has the essential utilitarian meaning. This paper investigates the utilization of methods of artificial intelligence, in particularly approximation algorithms of artificial neural network models.

**Key words:** fat content, ultrasonographic, image analysis, neural networks

**Adres do korespondencji:**

Andrzej Przybylak; e-mail: andrzej.przybylak@au.poznan.pl  
Instytut Inżynierii Rolniczej  
Uniwersytet Przyrodniczy w Poznaniu  
ul. Wojska Polskiego 50  
60-637 Poznań