

Dr hab. inż. Jerzy BALEJKO, Prof. ZUT  
 Wydział Nauk o Żywności i Rybactwa  
 Zachodniopomorski Uniwersytet Technologiczny w Szczecinie  
 Dr hab. inż. Piotr ZAPLETAL, Prof. UR  
 Wydział Hodowli i Biologii Zwierząt  
 Uniwersytet Rolniczy im. H. Kołłątaja w Krakowie  
 Dr inż. Edyta BALEJKO  
 Wydział Nauk o Żywności i Rybactwa  
 Zachodniopomorski Uniwersytet Technologiczny w Szczecinie

## ZASTOSOWANIE SIECI NEURONOWEJ MLP Z PROPAGACJĄ WSTECZNĄ BŁĘDÓW JAKO METODY MODELOWANIA CECH REOLOGICZNYCH SUROWYCH FARSZÓW MIĘSNYCH®

*Celem badań była ocena możliwości analizy danych przy użyciu sztucznych sieci neuronowych do modelowania i prognozowania cech reologicznych surowych farszów mięsnych o założonym składzie surowcowym. Materiał badawczy stanowiło mięso wieprzowe, wołowe, słonina wieprzowa, zamienniki tłuszczu, lód oraz mieszanka pekująca. Surowy farsz mięsny w różnych proporcjach składników poddawano analizie instrumentalnej w celu wyznaczenia 7 wyróżników właściwości lepko-sprężystych farszu. Zaprojektowano model sztucznej sieci neuronowej o architekturze perceptronu wielowarstwowego 7:7-11-7:7 i poddano ją procesowi uczenia metodą wstecznej propagacji błędów w celu rozpoznawania i przewidywania 7 parametrów składających się na charakterystykę tekstury farszów mięsnych.*

**Słowa kluczowe:** sztuczne sieci neuronowe, tekstura, farsze, właściwości reologiczne.

### WSTĘP

Farsze mięsne są mieszaniną wielu składników o odmiennym składzie chemicznym i odmiennych właściwościach mechanicznych, przez co stają się układem bardzo trudnym do modelowania cech reologicznych. Na cechy reologiczne surowych farszów mięsnych bardzo duży wpływ ma rodzaj zastosowanego surowca, proporcje pomiędzy podstawowymi składnikami, a także zabiegi technologiczne stosowane podczas procesu produkcji farszu mięsnego (rozdrabnianie, kutrowanie).

Sterowanie strukturą i jakością produktów wytworzonych z surowych farszów mięsnych wymaga dobrej znajomości właściwości reologicznych farszów mięsnych oraz surowców niezbędnych do ich wytworzenia. Istotny wpływ ma również skład podstawowy surowców oraz parametry procesu technologicznego. Dobranie optymalnych parametrów procesu technologicznego i optymalnego składu surowcowego gwarantuje utrzymanie produktu o pożądanym przez konsumenta właściwościach reologicznych i sensorycznych. Na tej podstawie można prognozować zachowanie się surowców podczas ich przetwarzania, a także przewidywać parametry reologiczne produktów przy zapewnieniu ich maksymalnej wydajności. Rosnące wymagania konsumentów związane z jakością produktów zmuszają technologów żywności do szukania takich sposobów polepszania jakości wyrobu gotowego, aby był on w pełni pożądanym i akceptowanym przez konsumenta.

Przewidywanie cech reologicznych artykułów żywnościowych o różnym stopniu przetworzenia jest procesem

niemożliwym do wykonania jeśli nie znamy modelu reologicznego badanego materiału składającego się z analogów mechanicznych ciał idealnych [9, 13, 30]. Po przeprowadzeniu żmudnych obliczeń matematycznych można stwierdzić, czy materiał wykazuje zdolność do pełzania, relaksacji naprężeń i retardacji, jednakże pod warunkiem, że znane są jego moduły odkształcalności postaciowej i lepkości.

Analiza matematyczna możliwych kombinacji udziału składników farszu w modelu o trzech poziomach zmienności głównego składnika (mięso) daje 5832 wszystkich możliwych rozwiązań. Tak wysoka liczba kombinacji wymaga użycia narzędzi, które będą w stanie zoptymalizować proces doboru procentowego udziału składników farszu.

**Celem artykułu jest przedstawienie uzyskanych wyników badań dotyczących oceny możliwości zastosowania metody sztucznych sieci neuronowych do modelowania i prognozowania cech reologicznych surowych farszów mięsnych na etapie przygotowania mieszaniny o założonym składzie surowcowym.**

Aby osiągnąć zamierzony cel, postanowiono opracować model sztucznej sieci neuronowej i poddać ją procesowi uczenia, w celu rozpoznawania i przewidywania 7 parametrów składających się na charakterystykę reologiczną farszów mięsnych.

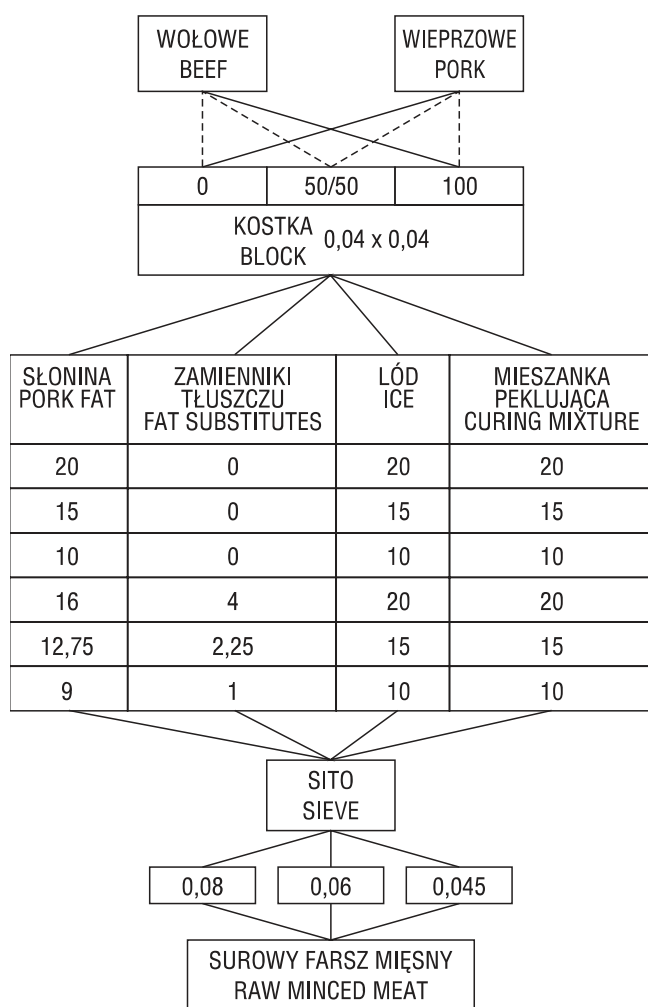
### MATERIAŁ I METODY

Jako materiał do badań posłużyły:

- ◆ mięso wieprzowe bez kości pochodzące z szynki, barwy naturalnej jasnoróżowej, o konsystencji mięśni jędrnej, elastycznej, swoistym zapachu, charakterystycznym dla świeżego mięsa wieprzowego, bez oznak wskazujących

na zaparzenie mięsa lub rozpoczynających się procesów psucia, pozbawione tkanki tłuszczowej [17, 19]. Mięso dostarczone do badań pozbawione było wad, a do czasu badania składowano w warunkach chłodniczych w temperaturze 276,15 °K (3 °C).

- ◆ mięso wołowe bez kości pochodzące z udźca, barwy naturalnej jasnoczerwonej, o konsystencji mięśni jędrnej, elastycznej, swoistym zapachu, charakterystycznym dla świeżego mięsa wołowego, bez oznak wskazujących na zaparzenie mięsa lub rozpoczynających się procesów psucia, pozbawione tkanki tłuszczowej, wolne od wad [17, 19].
- ◆ słonina wieprzowa w płatach o grubości 0,04 m, o barwie białej matowej z odcieniem kremowym, w dotyku wy-czuwalna wilgotność i lekka lepkość [18].
- ◆ zamienniki tłuszczu to skrobia rozpuszczalna cz. d. a. (C<sub>6</sub>H<sub>10</sub>O<sub>5</sub>)<sub>n</sub> – 162,10 g/mol produkcji, Chempur oraz błonnik z bambusa. Dystrybutor błonnika spożywczego: Nan-jing Lauta Food Additives Co., Ltd.
- ◆ lód kruszony z wody wodociągowej o twardości 14–20 dh, wyprodukowany w kostkarce SD 23 WS – 6 Simag



Rys. 1. Schemat przedstawiający procentowy udział składników w sporządzonym surowym farszu mięsnym o trzech poziomach zmienności.

Fig. 1. Percentage composition of raw minced meat at three levels of ingredient content.

Źródło: Opracowanie własne

o wydajności 28 kilogramów lodu na dobę. Przed dodaniem do farszu w trakcie procesu kutowania lód kruszono na kostki o średnicy zastępczej ok. 0,005 m.

- ◆ solanka peklująca zakupiona w Przedsiębiorstwie Produkcyjnym Gaster-Sól, to roztwór o stosunku chloru sodu NaCl 11 % i 1,5 % azotanu (III) sodu. Solanka peklująca spełniała wymagania zawarte w normie [20]. Mieszanekę w postaci suchej soli peklującej zalano w kolbie miarowej o pojemności 1000 ml wodą w ilości 87,5 %. Sporządzoną w ten sposób solankę peklującą dodawano podczas kutowania surowego farszu mięsnego w ilości do 20% w stosunku do masy sporządzanego farszu mięsnego.

Wszystkie surowce mięsne pochodziły z Zakładu Doświadczalno-Produkcyjnego Przetwórstwa Spożywczego Mas-AR Sp. z o.o. w Szczecinie.

Wyprodukowane farsze mięsne przebadano w trzech poziomach zmienności składników. Farsze do badań przygotowywano w kilogramowych porcjach. Stosunek mięsa wieprzowego do wołowego zmieniał się w przedziale: 100% mięsa wieprzowego (linia przerywana na rys. 1), 50% mięsa wieprzowego i 50% mięsa wołowego (linia punktowa na rys. 1), 100 % mięsa wołowego (linia ciągła na rys. 1).

Dodatek tłuszczu w postaci słoniny stanowił 10, 15 oraz 20% w stosunku do masy sporządzanego farszu. Rozdrobnione mięso peklowano solanką peklującą w ilości 10, 15 i 20% w stosunku do masy farszu. Aby ograniczyć udział słoniny wieprzowej w farszu, zastosowano zamienniki tłuszczu w postaci skrobi ziemniaczanej oraz błonnika z bambusa. Zamienniki tłuszczu dodawane były w ilości 10, 15 i 20% w stosunku do masy słoniny. Dodatek wody w postaci lodu kruszonego stanowił 10, 15 i 20% w stosunku do masy farszu.

Użyte składniki receptury, czyli mięso wieprzowe, mięso wołowe i słonina wieprzowa, pochodziły z uboju sobotniego, a zakupione były w poniedziałek w postaci schłodzonej. Dostarczone do badań składowe farszu rozdrabniano na fragmenty w postaci kostki o wymiarach 0,04 x 0,04 m.

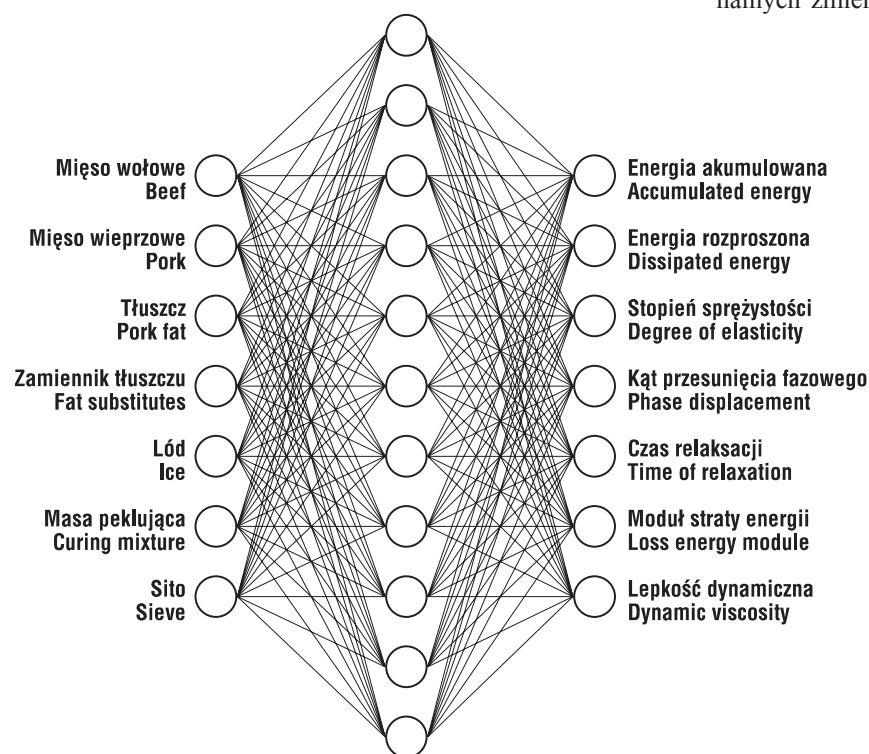
Rozdrobnione mięso i słoninę mielono w wilku do mięsa model M-8 o mocy całkowitej 370 W i wydajności 40 kg/godz., przez sita o średnicy oczek kolejno 0,008 m, 0,006 m oraz 0,0045 m. Po zmieleniu składników receptury odważano 1 kg porcje gotowego farszu i poddawano mieszanin w 5 dm<sup>3</sup> misie robota kuchennego firmy Clatronic model KM 2718. W początkowej fazie procesu mieszano zmielone mięso z tłuszczem oraz lodem, następnie dodawano pozostałe składniki w kolejności: solanka peklująca oraz zamienniki tłuszczu. Proces trwał do równomiernego rozprowadzenia składników i osiągnięcia temperatury farszu 15±1<sup>0</sup> C. Materiał doświadczalny przygotowano w 35 odrębnych seriach produkcyjnych. Otrzymany produkt w pełni zgodny był z definicją farszu mięsnego zawartej w normie [21]. Bezpośrednio po procesie próby o jednakowej temperaturze (15±1<sup>0</sup>C) poddawano pomiarowi tekstury przy użyciu aparatu MULTITEST [1, 2, 4]. Do pomiaru parametrów reologicznych farszów mięsnych zastosowano badanie polegające na podwójnym zagłębieniu trzpienia pomiarowego o średnicy 0,01 m w próbę o wysokości początkowej 0,02±1 m na głębokość 0,014 m, co stanowiło 70% jej wysokości. Wykonano 10

pomiarów dla każdej próby. Na zbiór 1050 danych liczbowych składały się średnie otrzymane z 10 powtórzeń. Z uzyskanych krzywych obliczano energię akumulowaną, energię rozproszoną, stopień sprężystości, kąt przesunięcia fazowego, czas relaksacji, składową urojoną zespolonego modułu sprężystości  $E''$  oraz moduł lepkości dynamicznej  $\eta'$  [2, 3, 6, 7, 10, 12, 14, 15, 16, 22, 27, 28].

Proces tworzenia sieci neuronowej przeprowadzono przy pomocy automatycznego projektanta sztucznych sieci neuronowych zawartego w pakiecie statystycznym Statistica 9.0 [26].

Zbiór składał się z 1050 danych liczbowych otrzymanych z pomiaru tekstury surowych farszów mięsnych. Dane zostały podzielone losowo na trzy kategorie w stosunku procentowym: dane testowe – 70%, dane uczące – 15%, dane walidacyjne – 15%.

W badaniach z przetrenowanych na zbiorze danych 1000 sieci neuronowych wybrano taką, która wykazywała najmniejszy błąd we wszystkich trzech podzbiorach (uczącym, walidacyjnym, testowym). Dopasowanie elementów stworzonego modelu nastąpiło podczas procesu uczenia sztucznej sieci neuronowej przy pomocy algorytmu wstecznej propagacji błędów [5, 8, 11, 23, 25]. Wybrany modelem sztucznej sieci neuronowej zastosowanej do predykcji i modelowania właściwości reologicznych surowych farszów mięsnych była trzywarstwowa sieć MLP o architekturze 7:7–11–7:7. Zmierzonymi objaśniającymi była dla niej procentowa zawartość poszczególnych składników w farszu: mięso wołowe, mięso wieprzowe, tłuszcz, zamienniki tłuszczu, lód, masa pekująca oraz sito i średnica oczka sita urządzenia do rozdrabniania.



Rys. 2. Schemat zastosowanej sztucznej sieci neuronowej o architekturze 7:7–11–7:7.

Fig. 2. Architecture of the artificial neural network model MLP 7:7–11–7:7.

Źródło: Opracowanie własne

## WYNIKI I DYSKUSJA

Sieci neuronowe w technologii żywności zastosowano dotychczas w celu skorelowania właściwości reologicznych ciasta i momentu obrotowego w mieszalniku [24], tekstury suszonego groszku i czasu gotowania [29], oraz do modelowania lepkości klarowanego soku owocowego [23]. Zbudowane do tych zadań modele nie były złożone i operowały maksymalnie na trzech zmiennych np.: temperatura gotowania – czas – parametr tekstury.

Wybór takiej architektury sztucznej sieci neuronowej poddyktowany był najlepszym dopasowaniem modelu sztucznej sieci neuronowej do danych zawartych w zbiorze walidacyjnym. Współczynniki korelacji wyników utrzymywały się na poziomie  $r = 0,65$ , co oznacza silną korelację wyników generowanych przez sieć neuronową MLP z danymi uzyskanymi z pomiarów metodami instrumentalnymi.

Bardzo ważnym elementem modelowania i zdolności predykcyjnych sztucznych sieci neuronowych jest reprezentatywność i liczebność przypadków wykorzystywanych w procesach uczenia i walidacji sieci. Ze względu na dużą liczbę wyników (z zestawienia 36 kolumn i 1050 wierszy otrzymujemy 37 800 wyników), przykładowe zależności średnich wartości przewidywanych względem obserwowanych przedstawiono w postaci graficznej (rys. 3 i 5).

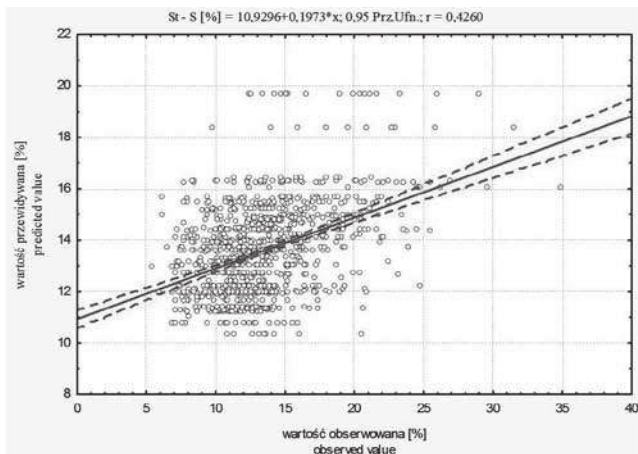
Normalność rozkładów badanych zmiennych analizowano za pomocą wykresów prawdopodobieństwo – prawdopodobieństwo oraz dwóch testów normalności: Shapiro-Wilka i Kołmogorowa-Smirnowa. Do zanalizowania problemu badawczego użyto też wieloczynnikowej analizy składowych głównych (rys. 7), która znajduje kombinacje liniowe oryginalnych zmiennych zachowujących maksimum oryginalnej wariancji danych.

Na podstawie wykresów rozrzutu stworzonego modelu (Rys. 3, Rys. 5), można stwierdzić, iż dopasowana linia regresji dosyć dobrze pokrywa się z danymi, szczególnie w przypadku lepkości dynamicznej (współczynnik determinacji  $R^2=0,45$ ). Świadczy to o związku liniowym pomiędzy wartościami obserwowanymi a przewidywanymi. Umiarkowaną jakość modelu uzyskano w przypadku stopnia sprężystości ( $R^2=0,18$ ).

W celu oceny normalności składnika losowego modelu dokonano analizy reszt.

Oceniając na wykresie normalności reszt (rys. 4 i 6) położenie punktów w stosunku do dopasowanej linii prostej można stwierdzić, że rozkład reszt nie odbiega od rozkładu normalnego, co potwierdza fakt dobrego dopasowania oszacowanego modelu liniowego do danych empirycznych.

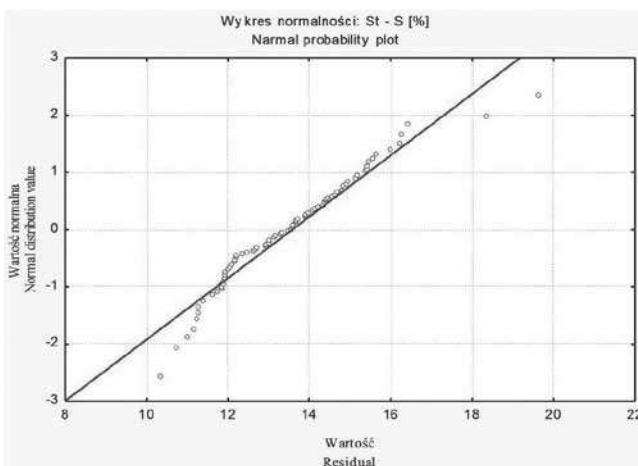
Dla określenia siły związku pomiędzy wartościami średnich z pomiarów instrumentalnych i danych z predykcji przy pomocy sztucznej sieci neuronowej zastosowano nieparametryczny test korelacji rang Spearmana, służący do opisu siły korelacji



Rys. 3. Analiza regresji liniowej pomiędzy doświadczalnymi wartościami stopnia sprężystości a obliczonymi przez model neuronowy.

Fig. 3. Linear regression analysis between experimental data of degree of elasticity and those calculated from neural network model.

Źródło: Opracowanie własne



Rys. 4. Wykres normalności reszt dla oszacowanego modelu liniowego stopnia sprężystości.

Fig. 4. Residual normality plots for linear regression model of degree of elasticity.

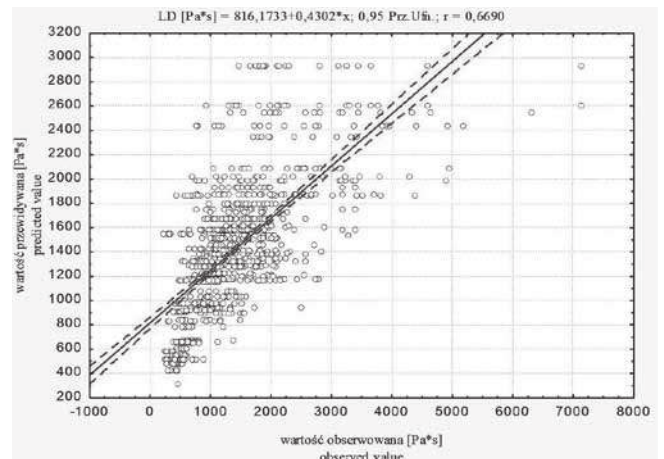
Źródło: Opracowanie własne

dwóch cech w przypadku, gdy cechy te są mierzalne, a badana zbiorowość nieliczna, oraz cechy mają charakter jakościowy i istnieje możliwość ich uporządkowania.

Test korelacji rang Spearmana wykazał korelację dodatnią o średnim natężeniu w przypadku stopnia sprężystości ( $r = 0,3832$ ) i kąta przesunięcia fazowego ( $r = 4931$ ). Silną korelację dodatnią wykazują: energia akumulowana ( $r = 6884$ ), energia rozproszona ( $r = 0,6890$ ), czas relaksacji ( $r = 0,5171$ ) i lepkość dynamiczna ( $r = 0,6973$ ). Bardzo silną korelację dodatnią wykazał moduł straty energii ( $r = 0,7021$ ).

## WNIOSKI

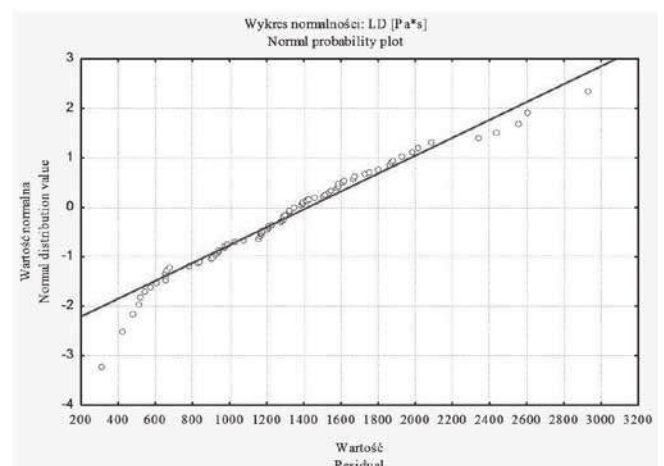
1. Porównanie wyników uzyskanych z pomiarów instrumentalnych i wyników uzyskanych z predykcji za pomocą sztucznych sieci neuronowych upoważnia do stwierdzenia, że sztuczna sieć neuronowa 7:7-11-7:7 o architekturze perceptronu wielowarstwowego uczonego metodą



Rys. 5. Analiza regresji liniowej pomiędzy doświadczalnymi wartościami lepkości dynamicznej a obliczonymi przez model neuronowy.

Fig. 5. Linear regression analysis between experimental data of dynamic viscosity and those calculated from neural network model.

Źródło: Opracowanie własne



Rys. 6. Wykres normalności reszt dla oszacowanego modelu liniowego lepkości dynamicznej.

Fig. 6. Residual normality plots for linear regression model of dynamic viscosity.

Źródło: Opracowanie własne

wstecznej propagacji błędów pozwala na prognozowanie parametrów analizy profilu tekstury.

2. Wyniki badań wykazały przydatność sztucznej sieci neuronowej MLP uczonej metodą wstecznej propagacji błędów do prognozowania i modelowania reologicznych parametrów tekstury surowych farszów mięsnych.

## LITERATURA

- [1] BALEJKO J. 2003. Opracowanie dynamicznej metody wyznaczania reologicznych właściwości artykułów żywnościowych. Wyd. Nauk. AR w Szczecinie, rozpr. nr 218.
- [2] BALEJKO J. 2006. *Badanie metodą dynamiczną zmian właściwości lepko-sprężystych mięsa wywołanych ogrzewaniem*. Żywność. Nauka. Technologia. Jakość, 4 (49), 145-153.

- [3] **BALEJKO J. 2007.** Reologia żywności. Wyd. Nauk. AR, Szczecin.
- [4] **BALEJKO J. 2012.** Urządzenie do wyznaczania parametrów reologicznych artykułów żywnościowych lepkością, Patent 2012, nr: 210 484.
- [5] **BOCCORH R. K., PATERSON A. 2002.** *An Artificial neural network model for prediction flavor intensity in blackcurrant concentrates.* Food Quality and Preference, 13, 117-128.
- [6] **BOURNE M. C. 1978.** *Texture profile analysis.* Food Technol., 7, 62-66.
- [7] **BOURNE M. C. 1982.** Food Texture and Viscosity: Concept a Measurement. Academic Press, INC, New York.
- [8] **HUSSAIN M. A., SHAFIUR RAHMAN M., Ng C. W. 2002.** *Prediction of pores formation (porosity) in food during drying: generic models by the idea of hybrid neural network.* J. Food Engin., 51, 239-248.
- [9] **KRZYWDZIŃSKA-BARTKOWIAK M., DOLATA W. 2005.** *Wpływ dodatku wody na mikrostrukturę drobno rozdrobnionych farszów mięsnych i wyprodukowanych z nich wędlin.* Żywność. Nauka. Technologia. Jakość, 3 (44) supl., 121-130.
- [10] **LACHOWICZ K., ŻOCHOWSKA J. 2002.** *Wpływ dodatku mięsa dzików na teksturę drobno rozdrobnionych modelowych farszów mięsnych.* Zesz. Nauk. AR, Szczecin, (2), 81-88.
- [11] **Li Y. Y., BRIDGWATER J. 2000.** *Prediction of extrusion pressure using an artificial neural Network.* Powder Technology, 108, 65-73.
- [12] **MARSILI R. 1993.** *Texture and mouthfeel making rheology real.* Food Products Design, 8, 54-58.
- [13] **PALKA K., MIGDAŁ W., WOJTYSIAK D., NATONEK-WIŚNIEWSKA M., DUDKIEWICZ A., MUZYCZKA K., WANTUCH M., BAUREK E. 2010.** *Wpływ rasy i wieku świń na właściwości modelowych farszów mięsnych i kielbas.* Żywność. Nauka. Technologia. Jakość, 1 (68), 80-92.
- [14] **PELEG M. 1997.** *Contact and fracture elements as components of the rheological memory of solid foods.* J. Texture Stud., 8, 39-48.
- [15] **PIĄTEK J. W., DĄBROWSKI K. J. 1980.** *Instrymentalna ocena tekstury żywności.* Przemysł Spożywczy, 34, 419-421.
- [16] **PIGGOTT J. R. 1988.** Sensory analysis of foods. Elsevier Science Publishers Ltd., London.
- [17] **PN-65/A-82000: 1965.** *Mięso i podroby zwierząt rzeźnych. Wspólne wymagania i badania.*
- [18] **PN-85/A-85800: 1985.** *Słonina.*
- [19] **PN-A-82014: 1997.** *Mięso i przetwory mięsne. Mięso bez kości do produkcji przetworów z mięsa rozdrobnionego.*
- [20] **PN-A-82117: 1997.** *Solanka do peklowania. Wymagania i badania mikrobiologiczne.*
- [21] **PN-A-82023: 2000.** *Mięso i przetwory mięsne. Terminologia.*
- [22] **PONS M., FISZMAN S. M. 1996.** *Instrymental texture profile analysis with particular reference to gelled systems.* J. Texture Stud., 27, 597-624.
- [23] **RAI P., MAJUMDAR G. C., DASGUPTA S., DE S. 2005.** *Prediction of the viscosity of clarified fruit juice using artificial neural network: a combined effect of concentration and temperature.* Journal Food Engineering, 68, 527-533.
- [24] **RUAN R., ALMAER S., ZHANG J. 1995.** *Prediction of Dough Rheological Properties Using Neural Networks.* Cereal Chemistry, 72 (3), 308-311.
- [25] **SKORBIŁOWICZ M. 2009.** *Wykorzystanie techniki sztucznych sieci neuronowych (ANN) do prognozowania stężenia mineralnych form azotu w wodach górnej Narwi.* Woda – Środowisko – Obszary Wiejskie, 9 (25), 129-14.000.
- [26] **Stat Soft PL. 2009.** STATISTICA®, version 9.0. [www.statsoft.pl](http://www.statsoft.pl)
- [27] **STEFFE J. F. 1996.** *Rheological methods in food process engineering.* Freeman Press. East Lansing, USA.
- [28] **TYSZKIEWICZ S., BARYŁKO-PIKIELNA N., DOBRZYCKI J., KŁOSOWSKA D., JANKOWSKI T., FORMAL J., GWIAZDA S., POLISZKO S. 1989.** *Postęp w analizie żywności. Tom II. Wybrane zagadnienia analizy sensorycznej i fizykochemicznej.* Pr. zbior. pod red. S. Tyszkiewicza, Warszawa.
- [29] **XIE G., XIONG R., CHURCH I. 1998.** *Comparison of Kinetics Neural Network and Fuzzy Logic in Modelling Texture Changes of Dry Peas in Long Time Cooking.* Lebensm.-Wiss. u.-Technol., 31, 639-647.
- [30] **ŻOCHOWSKA-KUJAWSKA J., LACHOWICZ K., SOBCZAK M., GAJOWIECKI L., KOTOWICZ M., ŻYCH A., ORYL B. 2010.** *Wykorzystanie mięsa z dzików do produkcji modelowych kielbas drobno rozdrobnionych ze zmiennym dodatkiem wody i tłuszczu.* Żywność. Nauka. Technologia. Jakość, 2 (69), 29-39.

## APPLYING THE MLP NEURAL NETWORK WITH BACK PROPAGATION AS METHOD OF MODELING AND FORECASTING RHEOLOGICAL FEATURES OF RAW MINCED MEAT

### SUMMARY

The aim of the study was to elaborate a method of modeling and forecasting rheological features which could be applied to raw minced meat at the stage of mixture preparation with a given ingredient composition. The investigated material contained pork and beef meat, pork fat, fat substitutes, ice and curing mixture in various proportions. Seven parameters were measured for each sample of raw minced meat. Then, the neural network model of multi-layer perceptron architecture 7:7-11-7:7 was designed and trained with back propagation algorithm in order to predict texture features. Statistical analysis of the results revealed, that artificial neural network model is able to predict rheological parameters of raw minced meat.

**Key words:** artificial neural nets, texture, minced meat, rheological properties.