

Krzysztof ŚWIERCZYŃSKI, Piotr BONIECKI, Agnieszka NAWROCKA\*

Uniwersytet Przyrodniczy w Poznaniu, Instytut Inżynierii Rolniczej

ul. Wojska Polskiego 50, 60-637 Poznań

e-mail: [krzysztof.swierczynski@au.poznan.pl](mailto:krzysztof.swierczynski@au.poznan.pl)

\* Instytut Agrofizyki PAN, Zakład Fizycznych Właściwości Materiałów

ul. Doświadczalna 4, 20-290 Lublin

## NEURAL IDENTIFICATION OF WHEAT GRAIN DAMAGES CAUSED BY A GRAIN WEEVIL (*Sitophilus granarius* L.)

### Summary

*Determining characteristics of representative features, describing internal injuries triggered by a grain weevil was a purpose of the work. On this base teaching sets essential to produce classification neural models were built (for 2 variants). Next, the qualitative comparison of created models was executed and an optimal network proposed (taking into account admitted assumption). The investigations were being dedicated for assisting decision-making processes which occur during cereal crops storing.*

## NEURONOWA IDENTYFIKACJA USZKODZEŃ ZIARNA PSZENICY SPOWODOWANYCH PRZEZ WOŁKA ZBOŻOWEGO (*Sitophilus granarius* L.)

### Streszczenie

*Celem pracy było określenie cech reprezentatywnych, opisujących wewnętrzne uszkodzenia ziarniaków wywołane przez wołka zbożowego. Na tej podstawie zbudowano 2 warianty zbiorów uczących (opartych na 2 różnych zbiorach zmiennych reprezentatywnych), które posłużyły do generowania 2 zestawów klasyfikatorów neuronowych. Następnie dokonano porównania jakościowego wytworzonych modeli oraz zaproponowano sieć optymalną (z punktu widzenia przyjętych założeń). Podkreślono aspekt użyteczny przeprowadzonych badań, wskazując na możliwość wsparcia (automatyzacji) procesów decyzyjnych zachodzących w trakcie magazynowania zbóż.*

### 1. Wstęp

Światowe tendencje dotyczące rynku towarowego wskazują na fakt dużego nacisku, jaki kładzie się obecnie na jakość produktu, co w efekcie ma istotny wpływ na jego popyt oraz cenę końcową. W krajach rozwiniętych obserwuje się znaczące wsparcie finansowe udzielane wielu ośrodkom naukowo-badawczym, których celem działania jest poprawa systemu kontroli oraz utrzymanie wysokiej jakości produkcji [7]. Dotyczy to w szczególności produktów żywnościowych, dla których określa się rosnące wymagania. Unia Europejska, której Polska jest członkiem od 2004 roku, wprowadza restrykcyjne normy, mające na celu zachowanie szczególnie wysokiego bezpieczeństwa żywnościowego. Wdrażanie takich norm nie miałyby sensu, gdyby nie istniały możliwości ich kontroli, np. poprzez stosowanie różnego rodzaju metod weryfikacyjnych.

W Polsce produkcja zbóż w 2009 r. oszacowana została na poziomie 29 826 620 ton, z czego 9 789 856 ton stanowiła pszenica (dane GUS). Istotną część produkcji zbóż przeznaczona została na cele przetwórstwa rolno-spożywczego. Ta znacząca skala produkcji oraz niewystarczające moce przerobowe zakładów przetwórczych wymagały wdrożenia procesu magazynowania tego towaru w specjalnie przygotowanych silosach. Ziarno w procesie przechowywania jest narażone na wiele niekorzystnych czynników, do których zaliczyć należy m.in. negatywne skutki spowodowane przez różnego rodzaju szkodniki magazynowe [9]. Za szczególnie groźnego uważa się wołka zbożowego (*Sitophilus granarius* L.) (*Coleoptera, Curculionidae*). Jest to chrząszcz, którego zarówno pożywieniem, jak i miejscem rozmnażania są zmagazynowane ziarna zbóż. Powoduje on ogromne straty jakościowe zgromadzo-

nego ziarna, co prowadzi do znacznego zmniejszenia wartości przechowywanego materiału [3]. Niezwykle istotna jest zatem właściwa oraz szybka identyfikacja tego szkodnika [2]. Ma ona często ograniczony charakter (głównie ze względów technicznych) i na ogół sprowadza się do subiektywnych metod pośrednich. Wynika to z tego, że wołek zbożowy składa jaja do wnętrza ziarniaków poprzez wydrążone otwory, a następnie zalepia je specjalną substancją, co skutecznie utrudnia jego optyczną identyfikację. Dzieje się tak dlatego, że larwy rozwijające się we wnętrzach magazynowanych ziarniaków są niewidoczne dla ludzkiego oka. Opisana wyżej sytuacja jest przyczyną poszukiwań nowych, alternatywnych metod identyfikacji wołka zbożowego w przechowywanym ziarnie. Jednym z możliwych kierunków działania jest próba identyfikacji wołka na podstawie destrukcyjnych efektów jego żerowania w strukturze wewnętrznej ziarna.

Istota procesu identyfikacji sprowadza się do postępowania mającego na celu rozpoznanie danego obiektu na podstawie przyjętych *a priori* cech charakterystycznych, a następnie do przydzielenia go do właściwej, wcześniej zdefiniowanej klasy. Założeniem prowadzonych badań było określenie efektywnej metody rozpoznawania negatywnych skutków, spowodowanych żerowaniem wołka zbożowego w ziarnie pszenicy. Obecnie istniejące i wykorzystywane metody jego identyfikacji są z reguły czasochłonne, w znacznym stopniu subiektywne oraz mało precyzyjne. Wymagają przy tym zaawansowanej wiedzy z zakresu omawianej dziedziny. Dlatego ważne i uzasadnione jest działanie mające na celu opracowanie nowych, oryginalnych metod identyfikacyjnych – szybkich, dokładnych, obiektywnych, a co najważniejsze, w pełni zautomatyzowanych. Zastosowanie do tego celu modelowania neuro-

nowego, mającego już ugruntowaną pozycję wśród instrumentów klasyfikacyjnych, wydaje się być rozwiązaniem uzasadnionym.

Właściwy wybór odpowiednich cech reprezentatywnych, które w sposób optymalny charakteryzują dany problem klasyfikacyjny, stanowi klucz do przeprowadzenia poprawnej identyfikacji. Wybór ten determinuje proces pozyskania adekwatnych zbiorów danych empirycznych stanowiących podstawę do tworzenia tzw. zbiorów wektorów uczących, niezbędnych w procesie generowania topologii neuronowych. W pracy zaproponowano 2 różne warianty zbiorów uczących, których struktury zostały oparte na odmiennych założeniach.

Na wstępie, jako zmienne wejściowe, przyjęto wybrane cechy fizyczne porażonego ziarniaka, których pomiar dokonano za pomocą specjalistycznego urządzenia SKCS 4100 (*Single-Kernel Characterization System*). Przeprowadzone badania symulacyjne wykazały jednak, że wygenerowane klasyfikatory neuronowe (uczone w oparciu o wspomniane wyżej cechy) nie reprezentowały modeli o satysfakcjonującej jakości. W związku z tym, podjęto próby poszukiwania innych, nowych cech reprezentatywnych. W kolejnych badaniach, do uczenia sztucznych sieci neuronowych, wykorzystano informację zakodowaną w postaci cyfrowych zdjęć rentgenowskich ziarniaków, uszkodzonych przez żerującego wołka zbożowego. Przeprowadzona analiza obrazu umożliwiła pozyskanie wiedzy o zaistniałych zmianach strukturalnych, jakie wywołuje wołek wewnątrz pojedynczego ziarniaka. Do ich identyfikacji oraz oceny jakościowej wykorzystano wybrane współczynniki kształtu powszechnie stosowane w klasycznej analizie obrazu [12].

Celem pracy było określenie cech reprezentatywnych, opisujących wewnętrzne uszkodzenia ziarniaków wywołane przez wołka zbożowego, a następnie wytworzenie oraz weryfikację zbioru identyfikacyjnych modeli neuronowych, wspo-

magających procesy decyzyjne zachodzące w trakcie magazynowania zbóż [1].

## 2. Metodyka badań

Przeprowadzona analiza dorobku naukowo-badawczego z omawianej tematyki ujawnia brak dostatecznej wiedzy dotyczącej efektywnej metody identyfikacyjnej.

Niezawodna i obiektywna identyfikacja skutków żerowania wołka zbożowego w przechowywanym ziarnie wymaga zaprojektowania, wytworzenia oraz zweryfikowania nowego, oryginalnego modelu klasyfikacyjnego. Powszechnie uznane właściwości klasyfikacyjne, jakie reprezentują sztuczne sieci neuronowe, implikują zasadność wykorzystania ich w procesie identyfikacji uszkodzeń ziarniaków wywołanych przez wołka zbożowego [13]. W literaturze przedmiotu nie znaleziono przykładów skutecznego wykorzystania modelowania neuronowego w procesie identyfikacji wewnętrznych uszkodzeń ziarniaków pszenicy, wywołanych przez żerujące w nich szkodniki. Ponadto nie znaleziono publikacji, w których określono rodzaj oraz poziom istotności wybranych cech reprezentatywnych, mających wpływ na przebieg procesu identyfikacji destrukcyjnych efektów żerowania wołka zbożowego w ziarnie pszenicy.

Niezbędnym elementem neuronowej identyfikacji skutków destrukcyjnego działania wołka zbożowego było określenie cech reprezentatywnych, które w sposób adekwatny i obiektywny będą charakteryzowały negatywne skutki żerowania tego szkodnika w magazynowanym ziarnie. Było to konieczne do tworzenia klasyfikacyjnych topologii neuronowych, wygenerowanych w oparciu o zbiory uczące, zawierające w swojej strukturze uprzednio zdefiniowane cechy reprezentatywne [1]. Zakres pracy obejmował wykonanie badań zgrupowanych w dwóch wariantach (tab. 1).

Tab. 1. Dwa warianty przeprowadzonych badań  
Table 1. Two variants of carried out examinations

Etap pracy	Wariant 1 Realizacja celu z wykorzystaniem cech fizycznych ziarniaków (SKCS model 4100)	Wariant 2 Realizacja celu z wykorzystaniem analizy rentgenowskiej ziarniaków ( <i>Elektronika 25</i> )
1. Przeprowadzanie badań laboratoryjnych	<ul style="list-style-type: none"> <li>• przygotowanie próbek pszenicy do badań empirycznych</li> <li>• inkubacja ziarna pszenicy z wołkiem zbożowym (5, 10, 15, 20 dni)</li> </ul>	
2. Uzyskanie danych empirycznych z badań laboratoryjnych	<ul style="list-style-type: none"> <li>• zapis danych z urządzenia SKCS 4100</li> <li>• eksport danych do programu <i>Microsoft Excel 2007</i></li> </ul>	<ul style="list-style-type: none"> <li>• wykonanie rentgenogramów aparatem rentgenowskim <i>Elektronika 25</i></li> <li>• wykonanie akwizycji obrazu z wykorzystaniem skanera <i>Epson Perfection V700</i></li> <li>• proces binaryzacji pojedynczych ziarniaków (dla progów 60, 70, 80)</li> <li>• odczyt wybranych cech reprezentatywnych z każdego pojedynczego ziarniaka z programu opracowanego w IIR UP Poznań</li> <li>• zapis danych do pliku programu <i>Microsoft Excel 2007</i></li> </ul>
3. Konwersja danych empirycznych	Wyeksportowane dane musiały zostać poddane konwersji do postaci zbiorów uczących, właściwych dla cyfrowego symulatora sieci neuronowych.	
4. Wstępny proces modelowania	Wykorzystanie modułu „ <i>Automatycznego projektanta sieci</i> ” neuronowej programu <i>Statistica v. 8.0</i> .	

Etap pracy	Wariant 1
5. Generowanie wybranych topologii sztucznych sieci neuronowych	Właściwe modelowanie za pomocą „Projektanta użytkownika” modułu programu Statistica v 8.0.
6. Testowanie i analiza jakości wygenerowanych modeli neuronowych	<ul style="list-style-type: none"> <li>• wyznaczenie jakości uczenia, walidacyjnej</li> <li>• wykonanie macierzy pomyłek</li> <li>• przeprowadzenie analizy wrażliwości</li> <li>• analiza ROC (Receiver Operating Characteristic)</li> </ul>
7. Zakończenie pracy	Analiza wyników oraz sformułowanie wniosków końcowych

## 2.1. Badania empiryczne

W badaniu, zgodnym z wariantem 1 (identyfikacja uszkodzeń ziarniaków w oparciu o analizę wybranych cech fizycznych), wykorzystano 10 (uszkodzonych przez wołka zbożowego *Sitophilus granarius* L.) odmian pszenicy: 5 odmian pszenicy jarej oraz 5 odmian pszenicy ozimej (tab. 2 i tab. 3). W badaniach zgodnych z wariantem 2 (identyfikacja uszkodzeń ziarniaków w oparciu o analizę rentgenogramów) wyselekcjonowano 4 odmiany: Torka, Narwa, Banti, Symfonia, które wybrano na podstawie ich udziału w całkowitej powierzchni zasiewów podanych przez Centralny Ośrodek Badania Odmian Roślin Uprawnych w 2004 roku [14]. Wszystkie odmiany pochodziły z 2 stacji hodowli roślin: Hodowla Roślin Strzelce Sp. z o.o. oraz Hodowla Roślin Rolniczych - Nasiona Kobierzyc Sp. z o.o. Próby wybrane były losowo.

Poszczególne odmiany zostały podzielone na następującą grupę [15]:

- **E**: elitarne,
- **A**: jakościowe,
- **B**: chlebowe (przeznaczone są do wypieku chleba),
- **C**: pozostałe o gorszej jakości.

Charakterystyka odmian pochodzących z Hodowli Roślin Strzelce Sp. z o.o. została przeprowadzona w oparciu o dane opublikowane na internetowej stronie producenta ([www.hr-strzelce.pl](http://www.hr-strzelce.pl) - dostęp online z dnia: 23.10.2009). Są to następujące odmiany:

- Torka - pszenica ta należy do grupy elitarniej o bardzo dobrej wartości wypiekowej mąki. Charakteryzuje się: dużą masą 1000 ziaren (45-52 g), dobrą odpornością na wyleganie, przeciętną zawartością białka, wymiałowalnością od dobrej do bardzo dobrej, zdrowotnością bardzo dobrą, plennością od średniej do dobrej.
- Kokska - charakteryzuje się: wysoką wartością wypiekową (należy do grupy jakości A), dużą zawartością białka i glutenu, dobrym wyrównaniem, masą 1000 ziaren w przdziele 45-55 g, odpornością na osypywanie i porastanie.

Tab. 2. Odmiany pszenicy jarej  
Table 2. Varieties of the spring wheat

Lp.	Odmiana	Rok wpisania do rejestru krajowego	Udział w kwalifikacji polowej (%) w 2003 r.	Pochodzenie nasion (hodowla)
Elitarne (grupa E)				
1.	Torka	1996	1,9	Strzelce
Jakościowe (grupa A)				
2.	Kokska	2000	13,5	Strzelce
3.	Nawra	1999	14,6	Strzelce
Chlebowe (grupa B)				
4.	Banti	1994	4,3	Kobierzyc
5.	Eta	1986	3,5	Kobierzyc

Tab. 3. Odmiany pszenicy ozimej  
Table 3. Varieties of the winter wheat

Lp.	Odmiana	Rok wpisania do rejestru krajowego	Udział w kwalifikacji polowej (%) w 2003 r.	Pochodzenie nasion (hodowla)
Jakościowe (grupa A)				
1.	Sukces	2001	15,3	Strzelce
2.	Zyta	1999	11,1	Strzelce
Chlebowe (grupa B)				
3.	Kobra Plus	1992	9,2	Kobierzyc
4.	Tonacja	2001	6,6	Strzelce
Pozostałe (grupa C)				
5.	Symfonia	1999	1,8	Strzelce

- Narwa - odmiana ta cechuje się bardzo dobrą wartością wypiekową, wysoką zawartością białka i glutenu w ziarnie, masą 1000 ziaren powyżej 50 g, dobrą odpornością na osypywanie i porastanie, dobrą zdrowotnością i wczesnym terminem dojrzewania.

- Sukces - odmiana nagrodzona godłem „Teraz Polska”, która posiada następujące cechy: dużą masę 1000 ziaren, dobre wyrównanie i odporność na porastanie, dobrą zdrowotność oraz przeciętne wymagania glebowe i dobrze wykorzystuje nawożenie azotowe.

- Zyta - odmiana, która uzyskała Złoty Medal Polagry za niską wrażliwość na zmiany pogody w ciągu okresu wegetacyjnego oraz za duże plonowanie przy dwóch dawkach nawożenia azotowego. Posiada wysoką zawartość białka oraz charakteryzuje się dobrą odpornością na rdzę, septoriozy oraz jest bardzo tolerancyjna na opóźniony wysiew.

- Tonacja - również ta odmiana posiada Złoty Medal Polagry za bardzo wysoką plenność oraz bardzo dobrą mrozoodporność (5,5 w skali 9-stopniowej). Poza tym posiada ziarno czerwone o dużej masie 1000 ziaren (50-55 g), bardzo dobrym wyrównaniu oraz wysoką zawartość skrobi w ziarnie.

- Symfonia - odmiana ta posiada: masę 1000 ziaren na poziomie ok. 45 g, wysoką odporność na porastanie i osypywanie (8 w skali 9-stopniowej). Dodatkowo jest odporna na mączniaka, rdzę żdźbłową, septarię liści i plew oraz choroby podstaw żdźbła. Zalecana jest do uprawy na terenie całego kraju oraz tam, gdzie potrzebny jest siew odmian o bardzo dobrej zimotrwałości (6,5 w skali 9-stopniowej).

Charakterystyki odmian pochodzących ze stacji Nasiona Koberzyc Sp. z o.o., opublikowanych na stronie producenta (źródło: [www.nasiona.com.pl](http://www.nasiona.com.pl) dostęp online z dnia: 30.09.2009), są następujące:

- Banti - odmiana, która charakteryzuje się dużą zawartością białka, dobrą wartością wypiekową, skłonnością do porastania w kłosach oraz średnio dużą masę 1000 ziaren.

- Eta - jest to odmiana, której masa 1000 ziaren jest średnia oraz posiada dobrą wartość wypiekową i ma średnio-późny termin dojrzewania.

- Kobra Plus - najważniejszą cechą tej odmiany jest odporność na wylegania (od dobrej do bardzo dobrej) oraz wczesny termin dojrzewania. Niestety, posiada wartość wypiekową od złej do dobrej.

## 2.2. Wariant 1

Badania zostały przeprowadzone w laboratorium Zakładu Entomologii Instytutu Ochrony Roślin – Państwowego Instytutu Badawczego w Poznaniu (IOR – PIB Poznań). Doświadczenie wymagało przygotowania odpowiedniej liczby chrząszczy poprzez ich specjalistyczną hodowlę. Na podstawie różnic morfologicznych w budowie ryjka


oraz odwłoku (z wykorzystaniem mikroskopu stereoskopowego *Olympus SZ 40* z oświetlaczem światłowodowym *Olympus Highlight 3100*) zostały zaklasyfikowane i odseparowane samce od samic [7]. Do badania wykorzystano przygotowane i opisane 50 pojemników polipropylenowych (wysokość 65 mm, średnica 38 mm, pojemność 60 ml), które posiadały odpowiednią budowę umożliwiającą dopływ powietrza, ale uniemożliwiającą wydostanie się szkodnika na zewnątrz. Do każdego z pojemników wsypano po 400 losowo wybranych ziarniaków, a następnie wprowadzono po 20 par chrząszczy wołka zbożowego (20 osobników płci męskiej i 20 żeńskiej).

Kolejnym etapem było umieszczenie tak przygotowanych zbiorników w cieplarni laboratoryjnej, w której zostały utrzymane stałe warunki przechowywania, optymalne do wzrostu i rozwoju wołka zbożowego. W urządzeniu zapewniono stałą temperaturę 26°C oraz wilgotność względną powietrza na poziomie 75%. Stałą wilgotność uzyskano, umieszczając przesycony roztwór NaCl (40 g NaCl na 100 cm<sup>3</sup> wody). Czas przebywania chrząszczy w poszczególnych pojemnikach był ściśle określony i wynosił: 5, 10, 15 i 20 dni. W tym czasie wołki zbożowe żerowały, kopulowały oraz składały jaja, z których rozwijały się larwy tego szkodnika. Pojemniki umieszczane były w cieplarni w odpowiedniej kolejności tak, aby umożliwić pomiar i uzyskać dane empiryczne w jednym czasie (rys. 1).

Do pomiarów wybranych cech fizycznych uszkodzonego (przez wołka) ziarna pszenicy wykorzystano Aparat SKCS 4100 firmy *Perten Instruments AB*. Jest on urządzeniem laboratoryjnym umożliwiającym uzyskanie danych empirycznych, mierzonych dla pojedynczego ziarniaka. Za pomocą SKCS wykonano serię pomiarów 7 wielkości fizycznych, a potem (wykorzystując pakiet *Statistica v.8*) wykonano standardową obróbkę statystyczną uzyskanych wyników. Zmierzone wielkości fizyczne uznano jako cechy reprezentatywne w procesie pośredniej identyfikacji wołka zbożowego, zasiedlającego magazynowane ziarno pszenicy [10]. Są to:

- masa [g],
- średnica zastępcza [mm],
- wilgotność [%],
- indeks twardości [-],
- konduktywność [S·m<sup>-1</sup>],
- konduktancja [S],
- siła kruszenia [N].

Indeks twardości ziarniaka wyznaczono na podstawie siły użytej do jego zgniotu z wykorzystaniem zaimplementowanego (w urządzeniu SKCS) algorytmu. Oznaczenie indeksu twardości ziarna było zgodne z normami opracowanych przez USDA/GIPSA (United States Department of Agriculture/Grain Inspection, Packers and Stockyards Administration).




Rys. 1. Schemat pozyskania danych empirycznych w wariant 1  
Fig. 1. Way of acquiring empirical data in variant 1

Po okresie inkubacji wołka zbożowego na ziarniakach, próbki zostały oczyszczone z chrząszczy oraz z innych zanieczyszczeń. Z każdej z próbek zostało losowo wybranych 400 ziarniaków i umieszczonych w urządzeniu. SKCS umożliwia w jednym cyklu uzyskanie danych dla 300 ziarniaków. Proces ten powtarzano aż do momentu uzyskania wyników z wszystkich prób. Wyniki pomiarów zapisywane były na dysku twardej urządzenia, a następnie zebrane i umieszczone w arkuszach kalkulacyjnych programu *Microsoft Excel*. Pozyskane dane empiryczne zostały przekonwertowane do postaci zbioru uczącego, właściwego dla symulatora sztucznych sieci neuronowych pakietu *Statistica v.8.0*.

### 2.3. Wariant 2

Schemat pozyskania danych empirycznych w wariantcie 2 przedstawiono na rys. 2.



Rys. 2. Schemat pozyskania danych empirycznych w wariantcie 2

Fig. 2. Way of acquiring empirical data in variant 2

Z każdej z próbek 4 wyselekcjonowanych odmian (Banti, Narwa, Torka oraz Symfonia) zostało losowo wybranych 30 ziarniaków i następnie ułożonych na arkuszu papieru, który posiadał jedną warstwę z nałożonym klejem. Tak przygotowany materiał został umieszczony w aparacie rentgenowskim *Elektronika 25* emitującym promieniowanie „miękkie”, którym wykonano serię zdjęć [5]. Zdjęcia wykonano na kliszach *Kodak XS1*, które po wywołaniu zostały poddane procesowi akwizycji obrazu do postaci cyfrowej. W tym celu został użyty skaner *Epson Perfection V700 Photo*. Skan klisz odbywał się przy rozdzielczości 200 dpi w 8-bitowej skali szarości. Postać cyfrową zapisano w formacie BMP, który oferuje bezstratną kompresję danych RLE (*Run-Length Encoding*).

Z tak przygotowanych skanów klisz rentgenowskich zostały wyodrębnione pojedyncze ziarniaki i zapisane w osobnych plikach, również w formacie BMP.

Następnie pliki zostały poddane procesowi progowania (binaryzacji) obrazu. W pracy przyjęto jedną z najprostszych metod, polegającą na porównaniu każdego punktu obrazu z zadaną wartością progową [6]. Jest ona realizowana zgodnie z zależnością (1):

$$J_{wx,y=1}, J(x,y) > t, J(x,y) \leq t \quad (1)$$

gdzie:

$t$  – próg binaryzacji.

W oparciu o klasyczną analizę pozyskanych obrazów cyfrowych [6] wyznaczono wartości 7 wybranych standardowych współczynników kształtu, które uznano za zmienne reprezentatywne [12]:

- bezwymiarowy współczynnik kształtu ( $WK$ ),
- współczynnik *Fereta* ( $WF$ ) – informujący o wydłużeniu obiektu,
- 2 współczynniki cyrkularności ( $WC1$ ,  $WC2$ ) – pierwszy określa średnicę koła, którego obwód jest równy obwodowi analizowanego obiektu, drugi również średnicę koła, ale takiego, którego pole jest równe polu analizowanego obiektu,
- współczynnik *Malinowskiej* ( $WM$ ),
- pole ( $P$ ) – obliczanie pola polega na zliczaniu punktów należących do analizowanego obiektu,
- obwód ( $O$ ) – wyznaczany na podstawie zliczenia punktów brzegowych obiektu przy jednoczesnym uwzględnieniu ich położenia, co skutkuje zliczaniem punktów sąsiadujących z odpowiednią wagą (punkty brzegowe sąsiadujące w pionie – waga wynosi 1, a brzegowe z wagą 2).

## 3. Modelowanie neuronowe

### 3.1. Wariant 1

Po przekonwertowaniu danych zebranych z urządzenia SKCS, oraz uzupełniania cechy reprezentatywne o 3 dodatkowe zmienne (rok badań, odmiana, rodzaj odmiany), został zbudowany zbiór uczący  $Z$ . Zgodnie z przyjętą metodyką wszystkie przypadki uczące, pozyskane z próbek uszkodzonych przez wołka zbożowego, niezależnie od czasu jego żerowania, zostały oznaczone cyfrą **1**, jako „porażone”. Natomiast wszystkie przypadki z próby kontrolnej zostały oznaczone cyfrą **0**, jako „zdrowe”. Oznaczenia te, czyli **1** – „porażony” oraz **0** – „zdrowy” dla wszystkich przypadków stanowiły sygnał wyjściowy. Główny zbiór uczący składa się z 44 984 przypadków (tab. 4). Ze zbioru  $Z$  zostały losowo wyodrębnione zbiory: uczące, walidacyjne oraz testowe w proporcji 2:1:1.

Tab. 4. Główny zbiór uczący  $Z$  uzyskany z urządzenia SKCS

Table 4. Main set  $Z$  of entrance vectors get from the SKCS device

Odmiana	Próba kontrolna	Liczba przypadków w zależności od liczby dni inkubacji (dni)				Suma
		5	10	15	20	
Banti	900	900	900	900	900	4 500
Eta	900	900	900	900	900	4 500
Kobra Plus	900	900	900	900	900	4 500
Koksa	900	900	900	900	900	4 500
Narwa	900	900	900	900	900	4 500
Sukces	900	900	900	899	900	4 499
Symfonia	900	900	899	898	900	4 497
Tonacja	900	898	899	899	898	4 494
Torka	900	900	900	900	900	4 500
Zyta	898	900	899	897	900	4 494
Suma	8 998	8 998	8 997	8 993	8 998	44 984

Ostatecznie do budowy głównego zbioru uczącego wykorzystano 10 zmiennych wejściowych, które uznano jako cechy reprezentatywne. Są to następujące cechy:

- rok badań,
- odmiana (nominalna zmienna 10-stanowa),
- masa [mg],
- średnica zastępcza [mm],
- wilgotność [%],
- indeks twardości [bez miana],
- konduktywność [ $S \cdot m^{-1}$ ],
- konduktancja [S],
- siła kruszenia [N],
- rodzaj odmiany: 0 – zboża ozime, 1 – zboża jare (nominalna zmienna 2-stanowa).

Konstrukcję zbioru uczącego dla wariantu 1 przedstawiono na rys. 3. Sygnały wejściowe stanowi 10 zmiennych realizowanych w strukturze sieci przez 20 neuronów wejściowych (zmienna: odmiana jest realizowana przez 10 neuronów, zmienna: rodzaj odmiany przez 2 neurony natomiast pozostałe zmienne przez 1 neuron). Sygnał wyjściowy stanowi zmienna dychotomiczna: „1” (ziarnik uszkodzony) lub „0” (ziarnik zdrowy).

### 3.2. Wariant 2

Zbiór uczący został wygenerowany (przy współpracy z Instytutem Agrofizyki PAN w Lublinie) na podstawie pozytywnych wcześniej zdjęć rentgenowskich. W zbiorze cyfrowych obrazów rentgenowskich ziaren porażonych znajdują się wszystkie ziarniaki, które posiadały jakiegokolwiek cechy żerowania wołka zbożowego (nie uwzględniono ziaren zawierających otwory, które mogły służyć do umieszczenia jaja w ziarniaku). Do zbioru ziaren zdrowych należą wszystkie przypadki ze zbioru ziaren kontrolnych oraz te,

które nie wykazywały żadnych uszkodzeń, spowodowanych żerowaniem szkodnika. Z wszystkich przypadków uczących został utworzony zbiór składający się z 1664 wektorów wejściowych. Tab. 5 przedstawia dokładny obraz głównego zbioru uczącego.

Z głównego zbioru wektorów wejściowych zostały wyodrębnione 3 podzbiory ( $\alpha$ -60,  $\beta$ -70,  $\gamma$ -80), odrębne dla każdego progu binaryzacji (próg wynosił odpowiednio 60, 70, 80). Następnie zostały one podzielone na zbiory: uczące, walidacyjne oraz testowe. Zbiory te składają się z losowo wybranych przypadków ze zbioru głównego, w proporcji 2:1:1.

Ostatecznie do budowy głównego zbioru uczącego wykorzystano 8 następujących cech:

- bezwymiarowy współczynnik kształtu (*WK*, nazwa w zbiorze uczącym – bezwymiarowy),
- współczynnik *Fereta* (*WF*, nazwa w zbiorze uczącym – fereta),
- współczynnik cyrkularności *WC1*, (nazwa w zbiorze uczącym: *c1*),
- współczynnik cyrkularności *WC2* (nazwa w zbiorze uczącym: *c2*),
- współczynnik *Malinowskiej* (*WM*, nazwa w zbiorze uczącym: *mali*),
- pole powierzchni,
- obwód,
- odmiana (nominalna zmienna 4-stanowa).

Konstrukcję zbioru uczącego dla wariantu 1 przedstawiono na rys. 4. Sygnały wejściowe stanowi 8 zmiennych, realizowanych w strukturze sieci przez 11 neuronów wejściowych (zmienna: odmiana jest realizowana przez 4 neurony, pozostałe zmienne przez 1 neuron). Sygnał wyjściowy stanowi zmienna dwustanowa: „p” (porażony) lub „z” (zdrowy).

Sygnały wejściowe										Sygnał wyjściowy
1	2	3	4	5	6	7	8	9	10	11
rok	odmiana	masa	sred.zas	wilgotność	twardość	siła kruszenia	konduktywność	konduktancja	rodz.odm	wołek
58	2 koksa	14,7	1,6	12,5	63,5	302	2057	1,82972000E-9	1	1
59	2 narwa	16,7	1,9	12,4	53,7	311	2056	1,83467000E-9	1	1
60	2 eta	19,3	1,6	12,5	45	649	2055	1,80796000E-9	1	0
61	2 banti	29,2	2,4	12,4	14,8	763	2054	1,83266000E-9	1	0
62	2 koksa	12,4	1,2	12,4	95,2	333	2050	1,85261000E-9	1	1
63	2 koksa	21,4	1,7	11,8	94,7	998	2048	1,86266000E-9	1	0
64	2 banti	16,8	2,1	13,3	20,6	249	2047	1,87984000E-9	1	1
65	2 koksa	20,9	2,1	12	82,3	711	2045	1,87784000E-9	1	0

Rys. 3. Fragment zbioru uczącego dla wariantu 1  
Fig. 3. Fragment of teaching file for variant 1

Tab. 5. Główny zbiór wektorów wejściowych uzyskanych ze zdjęć RTG  
Table 5. Main set of entrance vectors get from RTG photographs

Odmiana	Uszkodzone			Uszkodzone suma	Zdrowe			Zdrowe suma	Suma
	Próg binaryzacji ( <i>t</i> )				Próg binaryzacji ( <i>t</i> )				
	60	70	80		60	70	80		
Banti	40	40	40	120	111	111	111	333	453
Narwa	38	38	38	114	118	118	118	354	468
Symfonia	10	10	10	30	127	127	127	381	411
Torka	31	31	31	93	73	73	73	219	312
Suma	119	119	119	357	429	429	429	1 287	1 644

	Sygnały wejściowe								Sygnał wyjściowy
	1 bezwymi arowy	2 fereta	3 c1	4 c2	5 mali	6 pole	7 obwód	8 odmiana	9 odp
1	0,962181	1,559211	192,5293	188,8535	-0,01909	29098	593	banti	p
2	1,234506	1,661765	174,2719	193,6306	0,111083	23841	608	banti	p
3	1,119946	1,68	164,6111	174,2038	0,058275	21271	547	banti	p
4	1,224433	1,707317	159,1578	176,1146	0,106541	19885	553	banti	p
5	1,141303	1,644444	176,1803	188,2166	0,068318	24366	591	banti	p
6	1,212457	2,103093	142,8776	157,3248	0,101116	16025	494	banti	p
7	1,266768	1,51634	187,0352	210,5096	0,125508	27461	661	banti	p
8	1,335116	1,878261	156,001	180,2548	0,155472	19104	566	banti	p
9	1,593848	1,731092	149,5897	188,8535	0,262477	17566	593	banti	p
10	1,450811	1,814516	168,1598	202,5478	0,204496	22198	636	banti	p
11	1,50971	1,666667	175,9922	216,242	0,228703	24314	679	banti	p

Rys. 4. Fragment zbioru uczącego dla wariantu 2

Fig. 4. Fragment of teaching file for variant 2

#### 4. Wyniki badań

Zgodnie z przyjętą metodyką wygenerowano szereg modeli neuronowych, adekwatnych dla wytworzonych zbiorów uczących. W pracy zostały zaprezentowane po trzy neuronowe modele identyfikacyjne dla każdego zbioru (dla wariantów 1 i 2).

##### 4.1. Wariant 1

Najlepsze 3 zaprojektowane modele neuronowe (**Z-1**, **Z-2**, **Z-3**) to sieci neuronowe typu MLP (*MultiLayer Perceptron*), które zaprezentowano w tab. 6. Zostały one zbudowane z wykorzystaniem zbioru uczącego **Z** (tab. 4). Miernikiem jakości wygenerowanych modeli jest stosunek procentowy poprawnie zaklasyfikowanych przypadków do ogólnej liczby przypadków zawartych w zbiorze testowym (tzw. jakość testowa).

Jakość testowa najlepszego modelu (**Z-3**) wynosi 88,5%. Model ten to perceptron trójwarstwowy z 20 neuronami w warstwie wejściowej, 3 w 1 warstwie ukrytej, 2 w 2 warstwie ukrytej oraz 1 w wyjściowej. Zbliżone poziomy jakości uczenia oraz jakości walidacyjnej świadczą o zdolności aproksymacyjnej wytworzonej sieci neuronowej (brak zjawiska „przeuczenia sieci”).

Wykonana analiza wrażliwości modeli na zmienne wejściowe (tab. 7) wskazuje, że dla modelu nr **Z-3**, który ma najlepszą jakość, cechami, które mają istotny wpływ w procesie klasyfikacji, są (wg rangi): konduktywność, wilgotność, masa, rok badań oraz siła kruszenia. Żadna ze zmiennych wejściowych nie uzyskała błędu poniżej 1, co oznacza, że wszystkie zmienne miały wpływ na wynik przydziału do klas. Oznacza to, że wybrane cechy fizyczne uszkodzonych ziarniaków zostały wyselekcjonowane prawidłowo.

Tab. 6. Wygenerowane modele neuronowe

Table 6. Generated neural models

Model		Jakość uczenia [%]	Jakość walidacyjna [%]	Jakość testowa [%]	Algorytm i liczba epok uczenia
<b>Z-1</b>	MLP 20:6-2:1	83,3	84,0	84,1	BFGS 440
<b>Z-2</b>	MLP 20:14-2:1	85,6	85,6	86,8	BFGS 800
<b>Z-3</b>	MLP 20:3-2:1	87,8	85,6	88,5	BFGS 610

Tab. 7. Analiza wrażliwości modeli

Table 7. Sensitivity analysis of models

Model	<b>Z-1</b>		<b>Z-2</b>		<b>Z-3</b>	
	MLP 20:6-2:1		MLP 20:14-2:1		MLP 20:3-2:1	
	Błąd	Ranga	Błąd	Ranga	Błąd	Ranga
Rok badań	1,369	5	3,782	3	5,182	<b>4</b>
Odmiana (10 stanów)	1,291	7	2,039	6	1,116	8
Masa	1,746	1	2,671	4	5,836	<b>3</b>
Średnica zastępcza	1,007	10	1,008	10	1,001	10
Wilgotność	1,484	3	3,906	2	14,134	<b>2</b>
Indeks twardości	1,297	6	1,458	8	2,002	6
Konduktywność	1,504	2	6,221	1	37,208	<b>1</b>
Konduktancja	1,019	9	1,109	9	1,006	9
Siła kruszenia	1,258	8	1,911	7	3,004	<b>5</b>
Rodzaj odmiany (2 stany)	1,454	4	2,451	5	1,200	7

Macierz pomyłek (tab. 8) informuje o liczbie poprawnie oraz niepoprawnie sklasyfikowanych przypadków do danych klas. Z analizy macierzy pomyłek wynika, że SSN źle klasyfikują ziarna zdrowe (**0**). Wielkość niepoprawnie sklasyfikowanych ziaren jako zdrowe waha się między 41,2% a 81,3%. Zupełnie odwrotnie wygląda procent źle przypisanych przypadków do klasy ziaren uszkodzonych (**1**). Tutaj wielkość ta waha się w przedziale od 0,5% do 4,5%. Z tego wynika, że modele neuronowe uzyskane na podstawie zbioru **Z** (wariant 1) mają problem z poprawną klasyfikacją zdrowych ziaren, nieporażonych przez wołka zbożowego.

Powierzchnia pod krzywą ROC (*Receiver Operating Characteristic*) dla modelu o najwyższej jakości testowej (nr **Z-3**), na podstawie przeprowadzonej analizy (tab. 9) wynosi 0,92 i jest to najlepszy wynik spośród analizowanych modeli wariantu 1.

#### 4.2. Wariant 2

W wariacie tym optymalną strukturą neuronową okazał się perceptron wielowarstwowy MLP (*MultiLayer Perceptron*). Najwyższą jakość testową modeli uczonych zbiorem  $\alpha$ -60 ( $t = 60$ ) wynoszącą 97,5% uzyskał model  **$\alpha$ -1** (tab. 10). Model ten stanowiła topologia neuronowa, posiadająca 11 neuronów w warstwie wejściowej, 7 w pierwszej warstwie ukrytej, 2 w drugiej warstwie ukrytej i jeden w warstwie wyjściowej. Dla zbioru  $\beta$ -70 ( $t = 70$ ) najlepszą jakość testową (wynoszącą 98,8%) uzyskał model  **$\beta$ -2** o strukturze pokazanej

w tab. 10. Natomiast dla zbioru  $\gamma$ -80 najlepszym modelem okazał się  $\gamma$ -3 o strukturze: 8:6-2:1.

Analiza wrażliwości dla modelu  **$\alpha$ -1** wykazała (tab. 11), że najważniejszą cechą biorącą udział w procesie klasyfikacji jest współczynnik Fereta (*WF*), informujący o wydłużeniu obiektu. Można przypuszczać, że zerowanie wołka zbożowego powoduje silne zmiany kształtu, a w szczególności zmianę wydłużenia ziarna. Kolejnymi 3 cechami (wg rangi) są: odmiana, obwód i współczynnik cyrkularności *WC2*.

Z analizy macierzy pomyłek modeli klasyfikacyjnych (w wariacie 2) wynika (tab. 12), że najlepiej z identyfikacją zasiedlonych ziarniaków „**p**” poradził sobie model  **$\gamma$ -3**, który osiągnął 100% poprawnie sklasyfikowanych ziaren. Nieco gorzej wypadł model  **$\alpha$ -1** (94,5% poprawnie sklasyfikowanych porażonych ziaren) oraz  **$\beta$ -2** z wynikiem 93,3% poprawnych identyfikacji uszkodzeń. Biorąc pod uwagę liczbę poprawnie sklasyfikowanych ziaren zdrowych „**z**”, najlepiej wypadł model  **$\beta$ -2**, który uzyskał 100% poprawności, natomiast model  **$\alpha$ -1** oraz  **$\gamma$ -3** po 98,4%.

Na podstawie przeprowadzonej analizy ROC można zauważyć, że najlepszym klasyfikatorem (wg tego kryterium) jest model  **$\gamma$ -3**, który uzyskał pole pod krzywą wynoszące 0,996 (tab. 13). Pozostałe modele uzyskały:

- $\alpha$ -1 – 0,979,
- $\beta$ -2 – 0,983.

Tab. 8. Macierz pomyłek modeli klasyfikacyjnych  
Table 8. Matrix of mistakes of classification models

Model		Zdrowe ( <b>0</b> )	Uszkodzone ( <b>1</b> )	Razem	
<b>Z-1</b>	MLP 20:6-2:1	Razem	1291	5456	6747
		Poprawne	242	5431	5673
		Niepoprawne	1049	25	1074
		Poprawne [%]	18,7	99,5	84,1
		Niepoprawne [%]	81,3	0,5	15,9
<b>Z-2</b>	MLP 20:14-2:1	Razem	1291	5456	6747
		Poprawne	548	5307	5855
		Niepoprawne	743	149	892
		Poprawne [%]	42,4	97,3	86,8
		Niepoprawne [%]	57,6	2,7	13,2
<b>Z-3</b>	MLP 20:3-2:1	Razem	1291	5456	6747
		Poprawne	759	5210	5969
		Niepoprawne	532	246	778
		Poprawne [%]	58,8	95,5	88,5
		Niepoprawne [%]	41,2	4,5	11,5

Tab. 9. Charakterystyka krzywych ROC uzyskanych modeli dla zbioru **Z**  
Table 9. Characteristics of ROC curves of models for teaching file **Z**

Model		Powierzchnia ROC
<b>Z-1</b>	MLP 20:6-2:1	0,782
<b>Z-2</b>	MLP 20:14-2:1	0,890
<b>Z-3</b>	MLP 20:3-2:1	<b>0,921</b>

Tab. 10. Modele klasyfikacyjne wariantu 2  
Table 10. Neural models for variant 2

Model		Jakość uczenia [%]	Jakość walidacyjna [%]	Jakość testowa [%]	Algorytm i liczba epok uczenia
<b><math>\alpha</math>-1</b>	MLP 11:7-2:1	96,3	97,5	97,5	BFGS 300
<b><math>\beta</math>-2</b>	MLP 11:8-2:1	95,1	90,1	98,8	BFGS 140
<b><math>\gamma</math>-3</b>	MLP 11:6-2:1	91,6	91,4	<b>98,8</b>	BFGS 150



Tab. 11. Analiza wrażliwości modeli neuronowych wariantu 2  
 Table 11. Sensitivity analysis of neural models of variant 2

Model	$\alpha-1$		$\beta-2$		$\gamma-3$	
	MLP 11:7-2:1		MLP 11:8-2:1		MLP 11:6-2:1	
	Błąd	Ranga	Błąd	Ranga	Błąd	Ranga
WC1	1,443	5	1,345	4	1,029	8
WC2	1,450	4	1,164	6	1,171	5
Pole	1,397	6	1,567	2	1,244	<b>3</b>
WF	1,628	1	1,540	3	1,482	<b>2</b>
Odmiana	1,544	2	1,943	1	4,302	<b>1</b>
WM	1,148	7	1,042	7	1,112	7
Obwód	1,457	3	1,168	5	1,172	<b>4</b>
WK	1,035	8	1,002	8	1,148	6

Tab. 12. Macierz pomyłek modeli klasyfikacyjnych wariantu 2  
 Table 12. Matrix of mistakes of classification models for variant 2

Model			Porażone „p”	Zdrowe „z”	Razem
$\alpha-1$	MLP 11:7-2:1	Razem	18	63	81
		Poprawne	17	62	79
		Niepoprawne	1	1	2
		Poprawne [%]	94,5	98,4	97,5
		Niepoprawne [%]	5,5	1,6	2,5
$\beta-2$	MLP 11:8-2:1	Razem	15	66	81
		Poprawne	14	66	80
		Niepoprawne	1	0	1
		Poprawne [%]	93,3	100,0	98,8
		Niepoprawne [%]	6,7	0,0	1,2
$\gamma-3$	MLP 11:6-2:1	Razem	17	64	81
		Poprawne	17	63	80
		Niepoprawne	0	1	1
		Poprawne [%]	<b>100,0</b>	<b>98,4</b>	<b>98,8</b>
		Niepoprawne [%]	0,0	1,6	1,2

Tab. 13. Charakterystyka krzywych ROC modeli wariantu 2  
 Table 13. Characteristics of ROC curves of models for variant 2

Model		Powierzchnia ROC
$\alpha-1$	MLP 11:7-2:1	0,979
$\beta-2$	MLP 11:8-2:1	0,983
$\gamma-3$	MLP 11:6-2:1	<b>0,996</b>

## 5. Podsumowanie

Uzyskane wyniki uczenia sztucznych sieci neuronowych pozwalają na pozytywną ocenę przyjętych założeń badawczych oraz trafność wyboru metodyki. Modelowanie neuronowe, wykorzystane do identyfikacji negatywnych skutków żerowania wołka zbożowego w magazynowanej pszenicy, okazało się efektywną metodą, wspomagającą procesy decyzyjne zachodzące podczas tworzenia i eksploatacji nowoczesnych technologii wspierających systemy magazynowania płodów rolnych. Przeprowadzone badania pozwoliły na sformułowanie następujących wniosków:

1. Klasyfikator neuronowy okazał się efektywnym narzędziem dla procesu identyfikacji negatywnych skutków żerowania wołka zbożowego w zmagazynowanym ziarnie pszenicy.
2. Skuteczniejszą (i łatwiejszą w realizacji) metodą identyfikacyjną okazała się klasyfikacja neuronowa dokonana w oparciu o informacje zakodowaną w postaci zdjęć rentgenowskich uszkodzonych ziarniaków (wariant 2).
3. Spośród wygenerowanych modeli neuronowych, siecią najlepiej realizującą proces identyfikacji skutków żerowania wołka zbożowego (charakteryzującą się najwyższą

jakością testową), okazał się perceptron trójwarstwowy  $\gamma-3$  typu MLP 11:6-2:1. Model ten uzyskał największą liczbę poprawnie sklasyfikowanych uszkodzonych ziaren (powierzchnia pod krzywą ROC wyniosła 0,996).

4. Analiza wrażliwości tej sieci neuronowej na zmienne wejściowe pozwoliła na wskazanie cech reprezentatywnych, mających kluczowe znaczenie w procesie identyfikacji uszkodzonych ziarniaków. Są nimi w kolejności: odmiana, współczynnik Fereta (WF) oraz pole (P) ziarniaka.

## 6. Literatura

- [1] Boniecki P.: Elementy modelowania neuronowego w rolnictwie. Wydawnictwo Uniwersytetu Przyrodniczego w Poznaniu, 2008.
- [2] Gołębiowska Z., Nawrot J.: Szkodniki magazynowe. Warszawa: Państwowe Wydawnictwo Rolnicze i Leśne, 1976.
- [3] Ignatowicz S.: Straty przechowywanych produktów powodowane przez szkodniki. Przegląd Zbożowo-Młynarski, 1999, nr 8, s. 33–34.
- [4] Kwiatkowski W.: Metody automatycznego rozpoznawania wzorców. Warszawa: BEL Studio Sp. z o.o., 2007.
- [5] Karunakaran C., Jayas D.S., White N.: X-ray Image Analysis to Detect Infestations Caused by Insects in Grain. Cereal Chemistry, 2003, nr 5 (80), s. 553-557.

- [6] Malina W., Smiatcz M.: Metody cyfrowego przetwarzania obrazów. Warszawa: Akademicka Oficyna Wydawnicza EXIT, 2005.
- [7] Nawrot J., Gawlak M.: Zanieczyszczenia biologiczne jako problem bezpieczeństwa żywności. *Progress in Plant Protection*, 2009, nr 49 (1), s. 445-450.
- [8] Nowakowski K.: Neuronowa identyfikacja wybranych mechanicznych makrouszkodzeń ziarniaków. Praca doktorska. Poznań, 2007.
- [9] Olejarski P.: Zagrożenia dla zmagazynowanych zbóż. *Agro Serwis*, 2005, nr 2, s. 87-90.
- [10] Pearson T.C., Brabec D.L.: Automated detection of hidden internal insect infestations in wheat kernels using electrical conductance. *Materiały konferencyjne – ASAE Annual International Meeting*, 2002.
- [11] Rychlicki-Kicior K.: *C#*. Tworzenie aplikacji graficznych w .NET 3.0, Helion, 2007.
- [12] Tadeusiewicz R., Flasiński M.: *Rozpoznawanie obrazów*. Warszawa: Państwowe Wydawnictwo Naukowe, 1991.
- [13] Tadeusiewicz R.: *Sieci neuronowe*. Warszawa: Akademicka Oficyna Wydawnicza, 1993.
- [14] Szymczyk R.: (red.) *Lista Opisowa Odmian. Rośliny Rolnicze. Część 1. Zbożowe. Przemysłowe*. Centralny Ośrodek Badania Odmian Roślin Uprawnych, Słupia Wielka, 2004, s. 160.
- [15] Zych J.: *Odmiany pszenicy*. *Agro Serwis*, 2005, nr 2, s. 10-19.
- [16] Zweig, M.H., Campbell, G.: Receiver-Operating Characteristic (ROC) Plots: A Fundamental Evaluation Tool in Clinical Medicine. *Clin. Chem* 1993, 39 (4), pp. 561-577.