

Grzegorz KRZYWOSZYJA, Grzegorz ANDRZEJEWSKI

UNIwersYTET ZIELONOGÓRSKI, WYDZIAŁ ELEKTROTECHNIKI, INFORMATYKI I TELEKOMUNIKACJI
ul. Podgórna 50, 65-246 Zielona Góra

System wspierający diagnostykę rodzin pszczelich**Mgr inż. Grzegorz KRZYWOSZYJA**


W roku 1980 ukończył studia na Wydziale Fizyki i Astronomii Wyższej Szkoły Pedagogicznej w Zielonej Górze. W roku 2000 ukończył studia podyplomowe z informatyki w Wyższej Szkole Inżynierskiej w Zielonej Górze. W roku 2010 ukończył studia inżynierskie w Państwowej Wyższej Szkole Zawodowej w Gorzowie. Obecnie jest słuchaczem trzeciego roku studiów doktoranckich na Uniwersytecie Zielonogórskim. Jest nauczycielem fizyki i przedmiotów zawodowych w szkole średniej.

e-mail: g.krzywoszyja@weit.uz.zgora.pl

**Dr inż. Grzegorz ANDRZEJEWSKI**

Dr inż. Grzegorz Andrzejewski urodził się w roku 1970. Studia ukończył w roku 1995 na Politechnice Poznańskiej. Stopień doktora z zakresu informatyki uzyskał na Politechnice Szczecińskiej w roku 2002. Jego zainteresowania naukowe ukierunkowane są na zagadnienia modelowania i syntezy systemów sterowania cyfrowego.

e-mail: g.andrzejewski@iie.uz.zgora.pl

**Streszczenie**

W artykule opisano konstrukcję systemu diagnostycznego, przeznaczonego do obserwacji zachowań pszczół. Główna część artykułu zawiera ocenę możliwości wydobycia informacji z dźwięków wytwarzanych przez pszczoły. Celem badań jest rozpoznanie stanów rodziny pszczelej oraz ich klasyfikacja. Opisano proces tworzenia modeli dźwięków oraz redukcji ich wymiarów. Przedstawiono obrazy otrzymane w diagnostycznej przestrzeni obserwacji stanów. W części końcowej opisano proces badania wybranego strumienia dźwięków i podjęto próbę interpretacji otrzymanych wyników.

Słowa kluczowe: diagnostyka, dźwięki, pszczoły, stan.**A support system for the diagnosis of bee colonies****Abstract**

The design of a diagnostic system to observe the behavior of bees is described. The main part of the paper contains an assessment of the possibility of extracting information from sounds produced by bees. The aim of the study is to identify the states of colonies and their classification. It describes the processes modeling the sounds and reducing their size. Experimental images created in the diagnostic state space are shown. Finally, the process of testing a selected stream of sounds is outlined and an attempt to interpret the results is made.

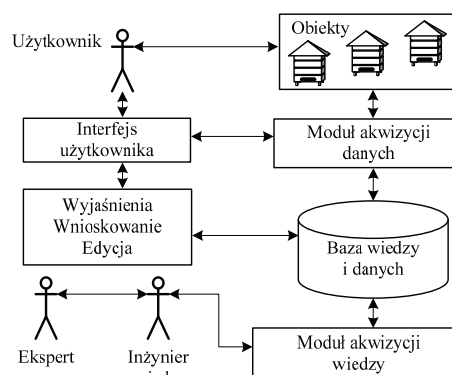
Keywords: bees, condition, diagnostics, sounds.**1. Wstęp**

Problem zaniku gatunku pszczół zmusza naukowców do wzmoczonego wysiłku w celu ustalenia przyczyn niekorzystnego zjawiska. Przyczyny negatywnego zjawiska są nadal nierozpoznane [1]. Spadek ilości pszczół zapyłających powoduje duże straty w produkcji rolnej oraz jest przyczyną zachwiania równowagi w wielu sieciach troficznych. Ważnym elementem prowadzenia gospodarki pszczelarskiej jest przegląd rodzin pszczelich. Szybko zachodzące zmiany w rodzinie pszczelej sprawiają, że często pszczelarz zostaje zaskoczony ich złą kondycją. Zbyt późna diagnoza powodują straty. Istnieje potrzeba tworzenia systemów wspomagających pracę pszczelarzy i naukowców.

2. Budowa systemu diagnostycznego

System diagnostyczny składa się z: jednostek pomiarowych umieszczonych w ulach, sieci lokalnej, serwera z bazą danych oraz jednostki pomiarów parametrów środowiska. Jednostka pomiarowa zawiera: mikrofon elektretowy, wzmacniacz z filtrem dolnoprzepustowym, mikrokontroler LPC1768 z 12 bitowym przetwornikiem analogowo-cyfrowym oraz kontroler ethernetu. Zadaniem jednostki pomiarowej jest: rejestracja dźwięków, przetwarzanie ich, identyfikacja stanu badanego obiektu oraz transport wyników i danych pomiarowych do serwera.

Do zadań serwera należy obsługa bazy danych i aplikacje zarządzającej jednostkami pomiarowymi. Badanie zgromadzonego materiału oraz administrowanie systemem prowadzone będzie na zdalnym komputerze. Schemat budowy systemu diagnostycznego przedstawiono na rys. 1, a szczegóły jego budowy opisano wcześniej [8].



Rys. 1. Architektura systemu
Fig. 1. The system architecture


3. Przygotowanie materiału badawczego

Do wstępnych badań dźwięki pszczół rejestrowano stereofonicznym dyktafonem cyfrowym. Częstotliwość próbkowania wynosiła 44,1 kHz, a rozdzielczość 16 bitów. Nagrania zapisywano bez kompresji. Korzystano z elektretowego mikrofonu połączonego kablem z dyktafonem. Rejestracje dźwięków prowadzono w sytuacjach osobliwego zachowania pszczół oraz w czasie ich normalnej pracy. Sztucznie wywoływano stan intensywnego zbioru pokarmu, podając syrop cukrowy, lub stan stresu - odymiając rodzinę pszczelą. W izolowanych warunkach rejestrowano dźwięki pszczół z uszkodzonymi skrzydłami przez chorobę (Varroa Jacobsoni). Podczas rejestracji dźwięków prowadzono notatki opisujące warunki panujące w środowisku. Zebrany materiał poddano selekcji i oczyszczeniu z dźwięków obcych. Wybrane przez eksperta fragmenty poddano analizie.

4. Ocena materiału dźwiękowego

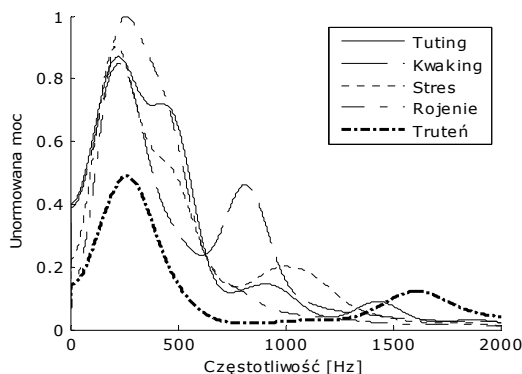
Rozkład energii dźwięków wytwarzanych przez pszczoły zbliżony jest do szumu czerwonego. Na rys. 2 przedstawiono fragment skumulowanego rozkładu energii wszystkich badanych stanów, zmierzony w całym paśmie akustycznym. Połowa energii dźwięków wytwarzanych przez pszczoły zawarta jest w paśmie do około 300 Hz. Pasma od częstotliwości około 7 kHz do 22 kHz

zawiera zaledwie jeden procent całej energii dźwięków. Z powyższych faktów wynika, że dolna część widma nadaje się do poszukiwania mierzalnych różnic, występujących w dźwiękach reprezentujących różne stany zachowania pszczół.




Rys. 2. Skumulowana energia dźwięków
Fig. 2. The cumulative energy of sound

Na rys. 3 przedstawiono rozkład mocy dźwięków reprezentujących kilka badanych stanów.



Rys. 3. Unormowana moc dźwięków
Fig. 3. Normalized power of sound

Zróznicowanie rozkładów mocy dźwięków w różnych stanach daje możliwość ich klasyfikacji. Na rys. 4 przedstawiono widma dźwięków zarejestrowane w jednym stanie (stan 7 – „Rojenie”). Brak większych różnic w składzie widma dźwięków daje możliwość jednoznacznej ich klasyfikacji.

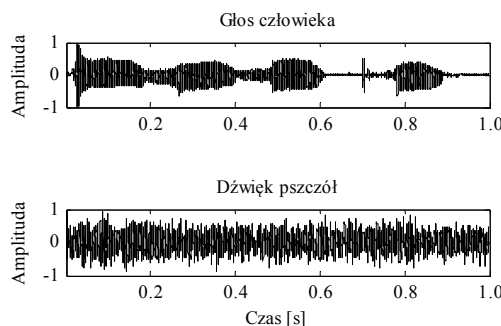


Rys. 4. Widma dźwięków wybranego zachowania
Fig. 4. Sound spectrum of the selected behaviour

Podczas obserwacji w szerokim zakresie widma, zauważano sporadycznie dźwięki o częstotliwościach rzędu 10 kHz [8], a nawet bliskie górnej granicy pasma akustycznego. Zróznicowanie dźwięków i wibracji wytwarzanych przez pszczoły jest nadal

przedmiotem wielu badań naukowych z wykorzystaniem najnowszych zdobyczy techniki [2-7].

Dźwięki wytwarzane przez pszczoły są na ogół pozbawione głębokiej modulacji. Do wyjątkowych należą dźwięki wytwarzane przez matki, w których obserwujemy jednoczesną modulację amplitudy i częstotliwości. Zmianie stanu rodziny pszczelej towarzyszy zmiana amplitudy i składu widma wytwarzanych dźwięków. Dźwięki pszczół są proste, a zmiany następują w nich wolniej (sekundy, minuty) niż w mowie człowieka. Na rys. 5 przedstawiono fragment wypowiedzi człowieka oraz typowy dźwięk wytwarzany przez populację pszczół.



Rys. 5. Głos człowieka i dźwięk pszczół
Fig. 5. Human voice and a sound of bees

Do określenia cech wystarczy niewielka ilość próbek dźwięku, a pomiary mogą być wykonywane w większych odstępach czasu. Te własności dźwięków wytwarzanych przez pszczoły są korzystne dla procesu diagnostycznego, ponieważ zmniejszają złożoność obliczeniową i obciążenie systemu pomiarowego.


5. Modele dźwięków

Do badań wykorzystano dwa modele dźwięków. Do konstrukcji pierwszego modelu wybierano jednosekundowy fragment nagrania reprezentujący badany stan. Fragment ten podzielono na 10 segmentów po 4410 próbek (100 ms). Dla każdego segmentu oddzielnie budowano wektor diagnostyczny. Kolejne wymiary wektora stanowiły: wariancja obliczona dla całego segmentu, trzy najbardziej znaczące współczynniki autokorelacji, pięć współczynników cepstrum, unormowane amplitudy współczynników cepstrum, entropia i kurtoza obliczone dla całego segmentu oraz liczba przejść sygnału przez zero. Dziesięć otrzymanych wektorów reprezentowało jeden stan badanego obiektu. W taki sam sposób konstruowano wektory diagnostyczne pozostałych badanych stanów. Do wstępnego porównania cech należących do pary różnych klas stosowano metodę dyskryminacji Fishera [9] przedstawioną wzorem

$$S_{12}(f) = \frac{|C_1 - C_2|}{\sigma_1 + \sigma_2}, \quad (1)$$

gdzie: C_1 , C_2 to współrzędne centrum klas oraz σ_1 , σ_2 to odchylenia standardowe cechy należącej do obu klas. Metodą SFS (Sequential Forward Selection) dodawano kolejne cechy badając ich wpływ, na jakość klasyfikacji. Celem była maksymalizacja współczynnika $S(f)$. Duża wartość licznika jest osiągnięta dla klas, których centra są odległe (możliwa jest jednoznaczna klasyfikacja). Duża wartość mianownika świadczy o tym, że łączne rozproszenie klas jest duże. W tym przypadku dane są rozproszone i mogą być przemieszane, co utrudni proces klasyfikacji. Metoda kończyła swoje działanie w chwili, gdy dodawanie kolejnych cech nie poprawiało klasyfikacji. Osiągane wyniki klasyfikacji w pierwszej metodzie nie gwarantowały skutecznego działania systemu diagnostycznego.

Wobec małej zmienności dźwięków wytwarzanych przez pszczoły (rys. 3) do reprezentacji stanu wybrano segment złożony z 400 próbek, co odpowiada około 9.07 ms nagrania przy częstotliwości próbkowania 44100 próbek na sekundę. Długość segmentu jest porównywalna z krótkim fonemem reprezentującym spółgłoskę „t”. Następnie podzielono segment na pięć mniejszych po 80 próbek (około 1.8 ms). Otrzymane małe segmenty uśredniono w dziedzinie czasu dodając do siebie odpowiednio kolejne próbki z segmentów [13,14]. Uśrednianie przeprowadzono bez synchronizacji. Na rys. 6 przedstawiono efekt uśrednienia pięciu kolejnych segmentów w wektor stanu. Linie przerywane określają granice wartości minimalnych i maksymalnych występujących w uśrednianych segmentach.



Rys. 6. Uśrednianie próbek dźwięku
Fig. 6. Averaging samples of sound

Z uśrednionego wektora o długości 80 próbek utworzono macierz o dziesięciu wierszach i ośmiu kolumnach. Utworzona macierz stanu posiadała dziesięć wektorów diagnostycznych w ośmiowymiarowej hiperprzestrzeni pseudo cech diagnostycznych. Dziesięć badanych stanów reprezentowała macierz diagnostyczna o 100 wierszach i 8 kolumnach.

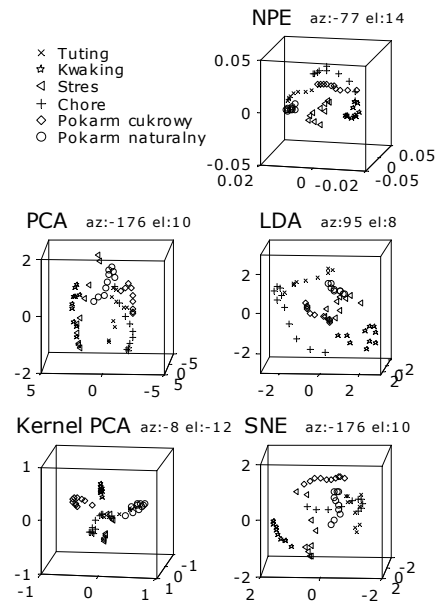
Macierze diagnostyczne obu modeli poddano redukcji wymiarów. Zredukowana macierz transformacji służyła do testowania nowych danych. Po redukcji wymiaru macierzy diagnostycznych analizowano obrazy w przestrzeni obserwacji stanów. Wyniki obserwacji były podstawą oceny możliwości identyfikacji stanów. Porównanie wyników wykazało, że lepsze efekty klasyfikacji stanów oraz mniejszą złożoność obliczeniową zapewnia drugi model dźwięków budowany z surowych danych. Do redukcji wymiarów wykorzystano pakiet obliczeniowy „Matlab Toolbox for Dimensionality Reduction” [12].

6. Przestrzeń stanów

Zbiorowi parametrów charakteryzujących obiekt w badanym stanie można przyporządkować współrzędne wektora hiperprzestrzeni, który wskazuje punkt. Stan obiektu jest reprezentowany w hiperprzestrzeni przez wiele punktów, ponieważ pomiary cech diagnostycznych obarczone są błędami, a stan obiektu ulega ewolucji podczas pomiaru. W diagnostycznej przestrzeni obserwacji stan reprezentuje pewna podprzestrzeń. Dla potrzeb obserwacji zredukowano wielowymiarowe przestrzenie matematyczne do dwóch lub trzech wymiarów. Dokonano transformacji i redukcji wymiarów danych stosując przekształcenia: LDA (Linear Discriminant Analysis), PCA (Principal Component Analysis), NPE (Neighbourhood Preserving Embedding), KPCA (Kernel Principal Component Analysis) i SNE (Stochastic Neighbor Embedding). Błąd rekonstrukcji danych wyznaczano ze wzoru

$$\varepsilon = \frac{1}{N} \sum_{n=1}^N \|x_n - x_E\|, \quad (2)$$

gdzie: x_n jest wartością dokładną, a x_E wartością estymowaną. Podczas badań stosowano różne metody redukcji danych porównując ich skuteczność. Na rys. 7 przedstawiono sześć stanów reprezentowanych przez figury o różnych kształtach. Na wykresach można obserwować odmienne sposoby ewolucji badanych stanów.



Rys. 7. Obserwacje w przestrzeni stanów
Fig. 7. Observations in the states space

Większość badanych stanów zajmuje oddzielne miejsca w przestrzeni obserwacji. Stany, których ewolucja odbywa się wzdłuż krzywej przestrzennej lub wokół wspólnego środka są trudne do klasyfikacji. Jakość klasyfikacji klasy g określa niemianowany współczynnik η_g opisany wzorem

$$\eta_g = \frac{\sum_{j=1}^p (\bar{x}_{jg} - \bar{x}_{jG})^2}{n \sum_{i=1}^n \sum_{j=1}^p (x_{ijg} - \bar{x}_{jg})^2}, \quad (3)$$

gdzie: licznik zawiera kwadrat odległość p wymiarowego centroidu klasy x_{jg} od p wymiarowego centroidu wszystkich klas x_{jG} . Mianownik zawiera sumę kwadratów odległości n punktów klasy od centroidu klasy. Wyniki pomiaru współczynnika jakości klasyfikacji przedstawiono w tab. 1.

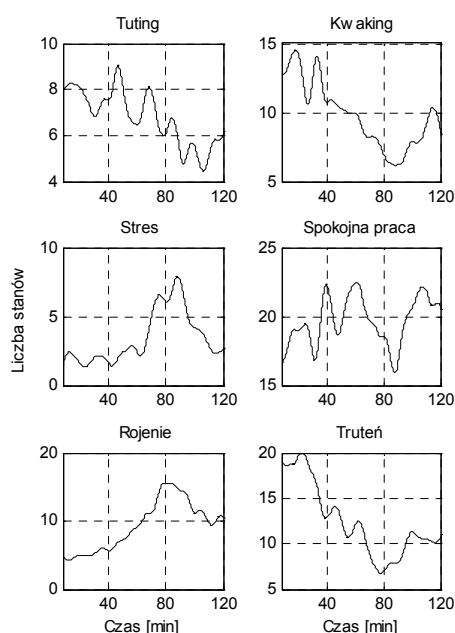
Tab. 1. Jakość klasyfikacji
Tab. 1. The quality of classification

Nazwa stanu	Metoda redukcji wymiaru danych					Suma
	NPE	PCA	LDA	KPCA	SNE	
Tuting	0.17	0.32	0.21	0.51	0.32	1.53
Kwaking	0.39	0.36	0.08	0.50	0.39	1.72
Stres	0.14	0.18	0.11	0.21	0.20	0.84
Chore	0.12	0.15	0.08	0.17	0.15	0.67
Pokarm cukrowy	0.16	0.45	0.33	0.96	0.40	2.29
Pokarm naturalny	0.09	0.20	0.14	0.11	0.18	0.72
Suma	1.06	1.67	0.95	2.45	1.64	7.77

Sumy kolumnowe w tabeli wyników określają jakość klasyfikacji danej metody dla badanych stanów natomiast, sumy wierszowe określają jakość klasyfikacji wszystkich metod dla wybranego stanu. Najlepsze rezultaty klasyfikacji osiąga metoda nieliniowej transformacji [11] (KPCA z jądrem gaussowskim - 2.45). Natomiast, najlepszą jakość klasyfikacji osiągnięto dla stanu, w którym pszczoły są sztucznie podkarmiane („Pokarm cukrowy” - 2.29).

7. Wykrywanie stanów w strumieniu danych akustycznych

Zmiany stanów diagnozowanych obiektów mają charakter statystyczny. Otrzymane wyniki klasyfikacji stanów mogą być rozpatrywane po uśrednieniu [10]. Do testów wybrano dźwięki reprezentujące zjawisko wyjścia roju. Obserwacja trwała około 2 godzin. Diagnostyczną macierz trenującą budowano w odstępach 10 sekundowych, zachowując dokładnie procedurę tworzenia modelu uczącego. Wymiar macierzy testującej odpowiadał wymiarowi macierzy diagnostycznej uczącej. Otrzymane wyniki poddano klasyfikacji metodą NN (najbliższego sąsiada) stosując odległość euklidesową. Wyniki klasyfikacji zliczono dla każdego rodzaju wykrytego stanu oddzielnie, tworząc szereg czasowy reprezentujący diagnozy. Dla ukazania trendu usunięto zmiany sezonowe, stosując filtrację średnią kroczącą z wagami okna Hanninga. Przebieg zliczeń stanów w czasie przedstawiono na rys. 8.



Rys. 8. Klasyfikacja stanów w strumieniu danych
Fig. 8. The classification of states in the data stream

Interpretację otrzymanych wyników powierzono ekspertowi. Aktywność matek zmniejszała się stopniowo w miarę zbliżania się do momentu wyjścia roju (stany: „Tuting”, „Kwaking”, 80 minuta obserwacji). Podobnie przebiegał proces wykrywania stanów aktywności trutni. Liczba wykrytych stanów stresu i rojenia wzrosła przez 40 minut przed wyjściem roju i osiągnęła maksymalną wartość w ciągu kilkunastu następnych minut. Stany odpowiadające spokojnej pracy rzadziej wykrywane są po wyjściu roju. Spadek aktywności całej populacji (stan „Spokojna praca”) uzasadnia gwałtowny spadek jej liczności. Pewien poziom wzrostu aktywności można uzasadnić powrotem zbieraczek, które nie wyszły wraz z rojem. Zjawisko rojenia pszczół przebiega podobnie jak zjawisko narastania stresu.

8. Wnioski

Opisana metoda daje możliwość obserwacji zachowania matek, trutni i robotnic w tym samym czasie. Wyniki badań wskazują na istnienie możliwości elektronicznego rozpoznawania zachowania owadów.

W opisanym procesie testowania, dostrzegalna zmiana ilości zliczanych stanów następuje około godzinę przed zdarzeniem wyjścia roju. Wyniki obserwacji rojącej pozytywnie na możliwość predykcji krótkoterminowej.

Należy przypuszczać, że ciągły monitoring rodzin pszczelich, dostarczy wystarczającej ilości informacji umożliwiających genozowania stanów oraz ich predykcję długoterminową. Posiadanie materiału badawczego z całego okresu rozwojowego owadów, umożliwi pełniejszą eksplorację danych, a w szczególności: odkrywanie asocjacji, poszukiwanie osobliwości oraz tworzenie nowych klas zachowań.

Reprezentacja wiedzy o badanym obiekcie w formie zidentyfikowanych stanów jest zwięzła, łatwa do prezentacji i analiz. Stosowanie surowych danych do tworzenia macierzy diagnostycznej oraz prostego sposobu klasyfikacji lub uśredniania wyników, ma na celu uproszczenie obliczeń. Przedstawione obliczenia wykonano na komputerze personalnym o znacznej mocy obliczeniowej, natomiast, w działającym systemie diagnostycznym ciężar obliczeń przeniesiony zostanie na jednostkę pomiarową z mikrokontrolerem o małej mocy obliczeniowej.

9. Literatura

- [1] Hackett K.: Colony Collapse Disorder 2012 Annual Progress Report, U.S. Department of Agriculture Washington, 2012, www.ars.usda.gov/is/br/ccd/ccdprogressreport2012.pdf.
- [2] Kastberger G., Weihmann T., Hoetzl T.: Social waves in giant honeybees (*Apis dorsata*) elicit nest vibrations, Springer, Naturwissenschaften, s. 595–609, 2013.
- [3] Mezquida D., J. Martínez J.: Short communication. Platform for bee-hives monitoring based on sound analysis. A perpetual warehouse for swarm's daily activity, Spanish Journal of Agricultural Research Madrid, Vol. 7, No. 4, s. 824–828, 2009.
- [4] Feldman A., Balch T.: Representing Honey Bee Behavior for Recognition Using Human Trainable Models, Internal Report, Georgia Institute of Technology Atlanta, s. 1–13, 2005.
- [5] Seeley T., Visscher P.: Group decision making in nest-site selection by honey bees, *Apidologie*, Vol. 35, s. 101–116, 2004.
- [6] Schneider S., Lewis L.: The vibration signal, modulatory communication and the organization of labor in honey bees, *Apis mellifera*, *Apidologie*, Vol. 35, s. 117–131, 2004.
- [7] Papachristoforu A.: High frequency sounds produced by Cyprian honeybees *Apis mellifera cypria* when confronting their predator, the Oriental hornet *Vespa orientalis*, *Apidologie*, Vol. 39, s. 468–474, 2008.
- [8] Krzywoszyna G., Binder P., Andrzejewski G.: A concept of a system for monitoring bee families, *Przegląd Elektrotechniczny*, Vol. 9, No. 89, s. 118–123, 2013.
- [9] Bishop H.: *Pattern Recognition and Machine Learning*, Springer, s. 186–191, 2006.
- [10] Durbin J., Koopman S.: *Time Series Analysis by State Space Methods*, Oxford University Press, s. 10–37, 2012.
- [11] Sahbi H.: Kernel PCA for similarity invariant shape recognition, *Elsevier Neurocomputing*, Vol. 70, s. 3034–3045, 2007.
- [12] Maaten L.: Matlab Toolbox for Dimensionality Reduction, <http://cseweb.ucsd.edu/~lvdmaaten/dr/download.php>, Delft University of Technology, 2013.
- [13] Momot A.: Weighted Averaging of ECG Signal Using Criterion Function Minimization, Springer, *Advances in Soft Computing*, Vol. 47, s. 267–274, 2008.
- [14] Drongelen W.: *Signal Processing for Neuroscientists*, Elsevier, s. 55–56, 2007.