

ZASTOSOWANIA METOD INTELIGENTNYCH W AKUSTYCE

BOŻENA KOSTEK

Katedra Systemów Multimedialnych, Politechnika Gdańska

Streszczenie. Celem referatu jest przegląd wybranych zastosowań metod inteligentnych w akustyce, a w szczególności w szeroko rozumianej inżynierii dźwięku. Przedstawione badania i eksperymenty były prowadzone na podstawie sztucznych sieci neuronowych, metody zbiorów przybliżonych, logiki rozmytej, grafów przepływowych Pawlaka oraz algorytmów genetycznych. Rozwiązywane problemy dotyczyły klasyfikacji dźwięków muzycznych, rozpoznawania fraz muzycznych, przetwarzania muzyki, sterowania klasycznymi organami piszczalkowymi oraz oceny jakości w akustyce.

1. WPROWADZENIE

Prowadzone w Katedrze Systemów Multimedialnych Politechniki Gdańskiej badania dziedzinie akustyki były rozwiązywane za pomocą algorytmów należących do tzw. inteligencji obliczeniowej lub tzw. miękkich obliczeń (ang. *computational intelligence, soft computing*) [3][17]. Jest to dziedzina rozwijająca się obecnie bardzo szybko, wychodząca poza ramy tradycyjnie rozumianej sztucznej inteligencji. Obejmuje ona algorytmy sztucznych sieci neuronowych, metodę zbiorów przybliżonych, logikę rozmytą, algorytmy genetyczne, drzewa decyzyjne, klasyfikatory oparte na metodzie najbliższego sąsiada, metody hybrydowe zawierające dwa lub więcej wymienione podejścia. Metody te uwzględniają również podejście kognitywne do percepcji człowieka [4].

W referacie przedstawione zostały wybrane problemy, których rozwiązanie wymagało zastosowania metod należących do inteligencji obliczeniowej. Przywołano też podstawy wybranych algorytmów sztucznej inteligencji. Dodatkowo zastosowania metod inteligentnych w akustyce zostały rozszerzone o sterowanie klasycznym instrumentem organowym.

2. WYBRANE METODY SZTUCZNEJ INTELIGENCJI

2.1. Sztuczne sieci neuronowe

Sztuczne sieci neuronowe (ang. *artificial neural networks*) są to systemy obliczeniowe przetwarzające informacje w sposób wzorowany na procesach zachodzących w mózgu człowieka [11][15]. Algorytmy te mogą być wykorzystywane do modelowania obiektów o nieznanej lub złożonej charakterystyce. Przetwarzane informacje mają charakter danych numerycznych. Do typowych zastosowań sztucznych sieci neuronowych zalicza się rozpoznawanie, klasyfikację, analizę porównawczą i kompresję obiektów. Szczególnym zakresem zastosowań sztucznych sieci neuronowych jest modelowanie procesów percepcji i

rozpoznawania zjawisk przez człowieka. Dotyczy to m.in. dźwięków (np. rozpoznawanie mowy), muzyki itp. Zagadnienia związane ze sztucznymi sieciami neuronowymi zostały przedstawione w licznych monografiach naukowych, dlatego nie zostaną przedstawiane dokładnie w referacie.

Istnieje wiele metod przetwarzania danych z zastosowaniem sztucznych sieci neuronowych. Metody te różnią się między sobą głównie zastosowanym modelem neuronu, strukturami sieci, sposobem propagacji danych oraz algorytmami adaptacji wag.

2.2. Metoda zbiorów przybliżonych

Pojęcie zbiorów przybliżonych (ang. *rough sets*) zostało wprowadzone przez Pawłaka na początku lat 80. [9]. Metoda zbiorów przybliżonych jest głównie stosowana do analizy danych. Do głównych problemów, które mogą być rozwiązywane przy użyciu zbiorów przybliżonych należą: redukcja danych (eliminacja danych nadmiarowych), znajdowanie zależności między danymi, znajdowanie istotnych danych, generowanie decyzji na podstawie danych, aproksymacyjna klasyfikacja danych, znajdowanie różnic i podobieństwa wśród danych, rozpoznawanie obrazów, odkrywanie zależności przyczynowo-skutkowych. Teoria zbiorów przybliżonych ma liczne powiązania z wieloma działami informatyki stosowanej rozwiniętymi do badania nieprecyzyjności [1].

W teorii tej wprowadzono kilka charakterystycznych definicji, a mianowicie: górną i dolną aproksymację, obszar graniczny zbioru. Pojęcie zbioru przybliżonego zostało zdefiniowane na podstawie górnej i dolnej aproksymacji zbiorów. Głównym celem stosowania teorii zbiorów przybliżonych jest podział przestrzeni cech danych rzeczywistych na podzbiory odpowiadające klasom abstrakcji. Aproksymacja dokonywana jest poprzez wyznaczenie dolnego i górnego przybliżenia zbiorów oznaczonych odpowiednio \underline{BX} i \overline{BX} , gdzie [9]:

$$\underline{BX} = \{x \mid [x]_B \subseteq X\} \quad (1)$$

$$\overline{BX} = \{x \mid [x]_B \cap X \neq \emptyset\} \quad (2)$$

Zbiór przybliżony w D definiowany jest jako rodzina wszystkich podzbiorów U posiadających takie samo przybliżenie dolne i przybliżenie górne.

Algorytmy wykorzystujące koncepcję zbiorów przybliżonych opierają się na gromadzeniu wiedzy bazowej. Jest ona zorganizowana w ten sposób, że zapamiętywane są wartości zadanych atrybutów (parametrów), które później ulegają odpowiedniemu przetworzeniu. Celem tej operacji jest wydobywanie reguł decyzyjnych.

Zbiór danych do analizy może być przedstawiony jako tabela, w której każdy kolejny rząd reprezentuje kolejny obiekt. Kolejne atrybuty A opisujące obiekty umieszczone są w kolumnach tabeli. Zdefiniowana w ten sposób tabela zawierająca zbiór danych do analizy nazywana jest systemem informacyjnym (ang. *information system*) lub tabelą decyzyjną (ang. *Decision Table*). Formalnie system informacyjny może być przedstawiony jako [9]:

$$D = (U, A) \quad (3)$$

gdzie:

U – niepusty, skończony zbiór obiektów (ang. *Universe*),

A – niepusty, skończony zbiór atrybutów takich, gdzie $a : U \rightarrow V_a$ dla każdego $a \in A$.

Zbiór V_a nazywany jest zbiorem wartości a .

Tabela decyzyjna może być wyrażona jako: $D = (U, A \cup \{d\})$, gdzie $d \notin A$. Tablica decyzyjna może zawierać dane nadmiarowe. Istnieją dwa rodzaje nadmiarowości w tablicach decyzyjnych – obiekty identyczne, nierozróżnialne (ang. *indiscernible*) oraz nadmiarowe atrybuty.

Algorytmy oparte na zbiorach przybliżonych mogą być użyte jako podstawa do systemu eksperckiego. Rezultatem takiego podejścia są wygenerowane reguły w formie IF THEN. Jednocześnie, atrybuty zawarte w danej regule tworzą tzw. *redukt*, czyli minimalny zbiór parametrów, na podstawie którego można podjąć decyzję [9]. Dla reguł w zbiorach przybliżonych możliwe jest zdefiniowanie funkcji charakterystycznej – miary przybliżonej:

$$m_x^B(x) = \frac{\text{card}(X \cap B(x))}{\text{card } B(x)} \quad (4)$$

Funkcja $m_x^B(x)$ przyjmuje wartości z przedziału [0, 1]. Wartość funkcji charakterystycznej może być interpretowana jako stopień przynależności elementu x do zbioru X . Stopień przynależności może być rozumiany jako prawdopodobieństwo warunkowe. Reguły, dla których miara $m_x^B(x) = 1$, nazywane są regułami pewnymi (także zgodnymi, niesprzecznymi lub deterministycznymi). Reguły o niższych wartościach miary przybliżonej nazywane są regułami niepewnymi.

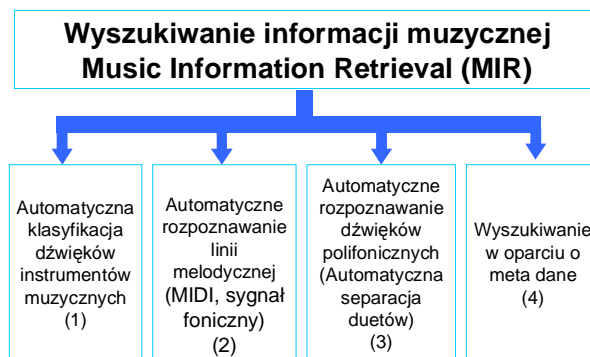
2.3. Logika rozmyta

Założenia logiki rozmytej (ang. *fuzzy logic*) zostały po raz pierwszy sformułowane w 1965 roku przez Zadeha [13]. Teorią tą zajmowali się później i rozwinęli liczni naukowcy, tacy jak Kandel, Lee, Sugeno, Yager i in. [10][14]. Teoria zbiorów rozmytych jest teorią wynikającą z potrzeby opisanego złożonych zjawisk lub słabo zdefiniowanych pojęć, trudnych do określenia za pomocą konwencjonalnego aparatu matematycznego. Klasyczne metody matematyczne, oparte na klasycznej teorii zbiorów i logice dwuwartościowej, są narzędziem ograniczającym opis zachowania się systemów, w których czynnik ludzki odgrywa zasadniczą rolę. Systemy takie występują w wielu dziedzinach życia, np. ekonomii, teorii podejmowania decyzji, medycynie i in. Ogólnie ujmując, logika rozmyta jest logiką wielu zmiennych. Stanowi narzędzie sztucznej inteligencji, która bazuje na sposobie rozumowania człowieka. Podstawową cechą logiki rozmytej wykorzystywaną w systemach kontroli i sterowania jest to, że pozwala ona tworzyć dowolne zespoły liniowych lub nieliniowych funkcji z intuicyjnie formułowanymi wzorcami i regułami. W ten sposób logika rozmyta przybliża sposób rozumowania i interpretowania zjawisk przez człowieka, który odbiera większość procesów zachodzących w przyrodzie w sposób ciągły. Zasady logiki rozmytej są opisane w bogatej obecnie literaturze tematu [14][17], dlatego nie zostaną przedstawione w niniejszym referacie.

3. AUTOMATYCZNE WYSZUKIWANIE INFORMACJI MUZYCZNEJ

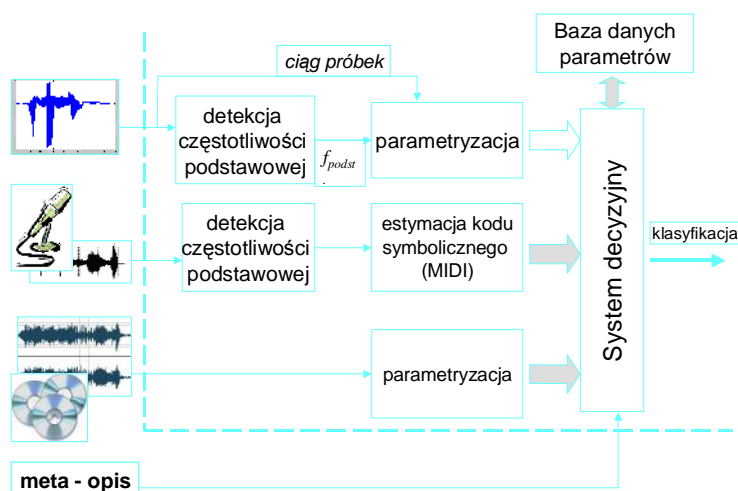
Najważniejsze problemy rozwiązywane w ramach prowadzonych badań dotyczyły zagadnień związanych z przetwarzaniem i klasyfikacją dźwięków instrumentów muzycznych, z uwzględnieniem zastosowań o dźwięki polifoniczne, frazy muzyczne, sygnały głosu ludzkiego (śpiew) oraz metaopis muzyki (rys. 1) [3][4][5][6]. Zagadnienia te tworzą nowo rozwijającą się dziedzinę informatyki muzycznej i jej działu związanego w automatycznym wyszukiwaniu informacji muzycznej (ang. *Music Information Retrieval*) [16].





Rys. 1. Wyszukiwanie informacji muzycznej

Proces klasyfikacji danych muzycznych można przedstawić na podstawie ogólnego schematu zawartego na rys. 2. Przykładowe zapytanie (ang. *query-by-example*) do systemu decyzyjnego może być dokonane zarówno za pomocą ciągu próbek, kodu symbolicznego (kod MIDI, zapis nutowy, zapis notacji w języku XML) czy metaopisu. Jak widać z rys. 2 ważnymi elementami w procesie są: akwizycja danych muzycznych, obejmująca w przypadku sygnałów muzycznych blok detekcji częstotliwości podstawowej, parametryzacji oraz system decyzyjny. Problem parametryzacji został w ostatnich latach bardzo intensywnie rozwijany i zakończył się powstaniem standardu MPEG 7, który zawiera bogaty zestaw deskryptorów do parametryzacji danych muzycznych [2][8]. Przeprowadzone eksperymenty w Katedrze Systemów Multimedialnych Pol. Gdańskiej oparte na bazie ponad 3500 próbek kilkunastu instrumentów muzycznych wykazały, że system poprawnie klasyfikuje od 92,3% do 100% próbek dźwiękowych, w zależności od liczby klasyfikowanych instrumentów i wykorzystywanego algorytmu. W Tab. 1 przedstawiono wyniki otrzymane w procesie klasyfikacji dla zestawu 10 instrumentów muzycznych. Najlepsze wyniki klasyfikacji uzyskano przy pomocy grupy sieci neuronowych (Tab. 2). Uzyskane wyniki są typowo o 1-2 punkty procentowe lepsze niż na przykład z zastosowaniem pojedynczej sieci neuronowej przy takich samych założeniach (a mianowicie liczba klasyfikowanych instrumentów wynosiła w tym przypadku 10). Taki rezultat jest efektem specjalizacji każdej sieci na identyfikację mniejszej liczby obiektów. Pozwoliło to uzyskać 98% skuteczność określenia grupy instrumentu oraz klasy instrumentu przy prawidłowo rozpoznanej grupie; dało to łączną skuteczność ponad 96%.

Rys. 2. Przykładowe zapytania do systemu decyzyjnego (ang. *query-by-example*)

Innym analizowanym zagadnieniem jest szeroko rozumiana analiza fraz muzycznych. Zakresem badań było objęte m. in. poszukiwanie optymalnego wektora cech dystynktywnych dla reprezentacji melodycznych i rytmicznych w materiale muzycznym w celu rozpoznawania np. motywów czy stylów muzycznych, jak również automatycznego generowania akompaniamentu. Okazało się, że w przypadku rozpoznawania stylów muzycznych skuteczność systemów decyzyjnych była mniejsza niż w przypadku klasyfikacji dźwięków instrumentów muzycznych. Jednak dodanie do wektora cech wybranych parametrów należących do deskryptorów wysokiego poziomu (tzw. meta opis) pozwoliło na uzyskanie bezbłędnej skuteczności zastosowanych systemów decyzyjnych. Automatyczne wyszukiwanie zadanych motywów muzycznych, które również było przedmiotem badań zapoczątkowanych uprzednio przez autorkę i jej współpracowników, polegało na badaniu związków pomiędzy jednostkami muzycznymi, które tworzą hierarchię strukturalnego uporządkowania materiału muzycznego [12]. Celem prowadzonych prac było m.in. znalezienie struktury wzorców rytmicznych z podziałem na motywy, frazy, zdania i okresy muzyczne, co odpowiada podziałowi zdania języka naturalnego na hierarchiczne struktury gramatyczne. Omawiany problem związany był z rozwinięciem metodyki poszukiwania optymalnego wektora cech dystynktywnych dla reprezentacji melodycznych i rytmicznych w materiale muzycznym przy użyciu klasyfikatorów neuronowych [2][12]. W ramach eksperymentów opracowano metodę tworzenia wszystkich możliwych hierarchicznych struktur rytmicznych, zwanych hipotezami rytmicznymi. Otrzymane hipotezy były następnie porządkowane w kolejności malejącej wartości funkcji rankingującej, aby ustalić, która ze znalezionych hipotez mogła być uznana za właściwą strukturę rytmiczną utworu muzycznego. Zaimplementowane algorytmy znajdują zastosowanie m.in. w generowaniu automatycznego podkładu perkusyjnego do linii melodycznych.

Tabela 1. Porównanie skuteczności klasyfikacji zaimplementowanych algorytmów

Instrument	Pojedyncza sieć neuronowa			Grupa sieci neuronowych			Metoda najbliższego sąsiada			Metoda zbiorów przybliżonych		
	razem	błędy	skuteczność [%]	razem	błędy	skuteczność [%]	razem	błędy	skuteczność	razem	błędy	skuteczność [%]
fagot	137	5	96,35	146	5	96,58	159	5	96,86	112	4	96,4
klarnet	156	5	96,79	160	1	99,38	145	7	95,17	112	7	93,8
obój	136	6	95,59	137	1	99,27	125	3	97,60	99	11	88,9
puzon	136	12	91,18	138	3	97,83	146	7	95,21	106	15	85,8
róg	144	13	90,97	123	21	82,93	121	6	95,04	98	12	87,8
saksofon	110	3	97,27	113	4	94,46	132	6	95,45	75	7	90,7
skrzypce	140	3	97,86	141	18	87,23	142	5	96,48	116	11	90,5
trąbka	125	7	94,40	117	2	98,29	107	2	98,13	87	7	92,0
tuba	122	4	96,72	115	2	98,26	121	2	98,35	89	1	98,9
wiolonczela	125	9	92,80	141	4	97,16	134	6	95,52	126	7	94,4

Tabela 2. Skuteczność rozpoznawania grup instrumentów muzycznych

Grupa instrumentów	Liczba dźwięków	Błędy	Skuteczność [%]
strunowe	411	6	98,54
dęte drewniane	902	17	98,12
dęte blaszane	712	18	97,47

Niewątpliwie najtrudniejszym problemem do rozwiązania jest inteligentne wyszukiwanie muzyki w olbrzymich zasobach baz internetowych. Bardzo interesujące okazało się wykorzystanie metod opartych na sztucznych sieciach neuronowych czy zbiorach przybliżonych Pawlaka [7]. Metoda ta została wykorzystana do wyszukiwania utworów muzycznych w zasobach internetowych na podstawie słów kluczowych zawartych w opisie znajdującym się na płytach CD. Na podstawie swobodnego opisu tej zawartości wprowadzanego przez użytkownika i na podstawie nie w pełni ścisłej definicji podawanej przez użytkowników w trakcie uruchamiania procesów wyszukiwania informacji, system powinien wskazać adresy adekwatnych plików. Niwelowanie skutków rozbieżności kontekstowej pomiędzy istniejącym opisem zbiorów i treścią zapytań staje się możliwe w przypadku stosowania algorytmów rozwijanych na gruncie metod przetwarzania języka naturalnego (ang. *language engineering*).

3. SYSTEM STEROWANIA TRAKTURĄ ORGANÓW PISZCZAŁKOWYCH

Klasyczne organy piszczałkowe są niewątpliwie przypadkiem szczególnym w dziedzinie sterowania komputerowego instrumentami muzycznymi. Instrumenty takie są wciąż licznie budowane, dlatego zaistniała potrzeba określenia jakościowych i ilościowych związków pomiędzy sposobem sterowania trakturą organów piszczałkowych a jakością tego rodzaju sterowania, i - co najważniejsze - brzmieniem instrumentów [3].

Z muzycznego punktu widzenia pożądanym jest sposób sterowania pobudzaniem piszczałek, który może zapewnić nie tylko możliwość włączania poszczególnych dźwięków, lecz również umożliwia stosowanie muzycznej artykulacji typowej dla gry na organach. Spośród dotychczasowo stosowanych rozwiązań najlepiej spełniającymi powyższe założenie były traktury mechaniczne. Rozwój systemów sterowania organami doprowadził kolejno do zastosowania traktury pneumatycznej, a następnie elektrycznej, które znacząco ułatwiły grę. Niestety, traktury tego typu wykorzystują, jak to określają muzycy, obcą siłę wprowadzoną pomiędzy klawisz a źródło dźwięku, wobec czego gra została w dużym stopniu zubożona od strony artykulacyjnej. Dodatkowo, instrument o sterowaniu elektrycznym reaguje zawsze w ten sam sposób na zróżnicowane naciskanie klawiszy w czasie gry, pozostając nieczuły na artykulację muzyczną stosowaną przez wykonawcę. Zawsze jednakowo otwierające się elektromagnetyczne zawory piszczałkowe nie pozwalają na wydobywanie wielu interesujących odcieni brzmieniowych organów, co w konsekwencji powoduje, że nawet bardzo starannie intonowane instrumenty nie wytrzymują porównania z klasycznymi organami o trakturach mechanicznych.

Różnice pomiędzy poszczególnymi instrumentami organowymi w zakresie rozwiązań traktur wpływają bezpośrednio na ocenę tych instrumentów przez muzyków i słuchaczy, dlatego w prowadzonych badaniach w pierwszym rzędzie określono kryteria oceny instrumentów organowych (np. parametry czasowe i widmowe, które pozwalają na uwidocznienie zjawisk zachodzących w sygnale muzycznym, związanych z artykulacją muzyczną) i powiązanie tych kryteriów z ocenami subiektywnymi. Prace badawcze dotyczyły również możliwości wyposażenia traktury organowej w sterowanie oparte na logice rozmytej. W tym celu zaprojektowano i wykonano model traktury organowej oraz system sterowania oparty na logice rozmytej (rys. 3), który posłużył do badań nad tego typu sterowaniem [3].

Sterowanie ruchem zaworu elektromagnetycznego jest zadaniem trudnym, gdyż prędkość przemieszczania się kotwicy elektromagnesu zależy w sposób silnie nieliniowy od prądu pobudzającego. Ponadto czujnik ruchu klawisza umieszczony pod klawiaturą muzyczną również nie odwzorowuje sposobu naciskania klawiszy w sposób liniowy. Znalazienie

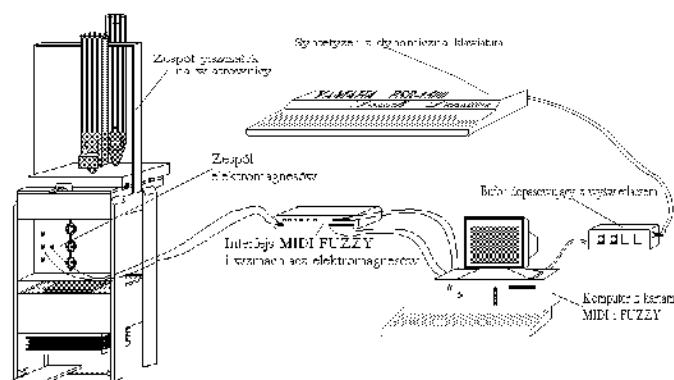
precyzyjnego opisu tych funkcji nieliniowych jest rzeczą trudną, a nawet wręcz niemożliwą. Wynika stąd potrzeba użycia reguł logiki rozmytej do tego typu zastosowań.

Zaprojektowany układ analizuje dwie wielkości wejściowe: prędkość, z jaką jest klawisz naciskany i numer klawisza. Sterownik zrealizowany w technice rozmytej dokonuje analizy numeru naciskanego klawisza, ponieważ proces nabrzmiwania dźwięku inaczej przebiega w piszczałkach o dużych rozmiarach (8', 16' i większe) przyporządkowanych do klawiszy z dolnej części klawiatury, niż w piszczałkach o małych rozmiarach, którym odpowiadają klawisze z "wyższej" części klawiatury. Ze względów praktycznych (jakościowych i ekonomicznych) przyjęto, że możliwość stosowania artykulacji muzycznej dotyczy przede wszystkim dźwięków niskich. Wielkości sterujące układem pobudzania piszczałki, a więc prędkość i numer klawisza są otrzymywane z syntetyzera wyposażonego w dynamiczną klawiaturę, który wielkości te generuje i wysyła w kodzie MIDI. Stworzone zgodnie z zasadami logiki rozmytej oprogramowanie systemu, umożliwi przetworzenie w czasie rzeczywistym zadanych parametrów wejściowych na wielkości wyjściowe, decydujące o tym, jak szybko zawór piszczałki zostanie otwarty. Realizację praktyczną zapewnia układ elektromagnesów, w których wielkość płynącego prądu decyduje o wypadkowej prędkości otwarcia dopływu powietrza do piszczałki.

a.



b.



Rys. 3. Model organów piszczałkowych (a), układ sterowania trakturą organową (b)

PODSUMOWANIE

Prowadzone w Katedrze Systemów Multimedialnych Pol. Gdańskiej eksperymenty badawcze, obejmujące wdrożenie wybranych metod inteligencji obliczeniowej do celów akwizycji i rozpoznawania monofonicznych sygnałów muzycznych, pozwoliły wypracować nowatorski sposób podejścia do zagadnień wyszukiwania i klasyfikacji danych fonicznych. Problemy te, ze względu na swoją złożoność, jak również z uwagi na niepełną powtarzalność wymykają się analizie opartej na modelach deterministycznych, dlatego zastosowanie metod należących do tzw. inteligencji obliczeniowej do rozwiązywania istotnych problemów z zakresu akustyki czy szeroko pojętej inżynierii dźwięku wydaje się w pełni uzasadnione. Dodatkowo przeprowadzone wyniki badań i analiz potwierdziły możliwość zastosowania traktury elektrycznej wyposażonej w system oparty na logice rozmytej do sterowania organami piszczałkowymi.



LITERATURA

1. Bazan J.G., Nguyen H.S., Skowron A., Szczuka M. A View on Rough Set Concept Approximations. In Wang G, Liu Q, Yao Y, Skowron A (Eds.) Proc of RSFD. Lecture Notes in Computer Science 2639, Springer, Chongqing, 181-188, 2003.
2. Kostek, B., Czyżewski, A., Representing Musical Instrument Sounds for their Automatic Classification, J. Audio Engineering Society 49, 768 – 785, 2001.
3. Kostek B., Soft Computing in Acoustics, Applications of Neural Networks, Fuzzy Logic and Rough Sets to Musical Acoustics. Physica Verlag, Heidelberg New York 1999.
4. Kostek B., Perception-Based Data Processing in Acoustics. Applications to Music Information Retrieval and Psychophysiology, Springer Verlag, Studies in Computational Intelligence, Berlin, Heidelberg, New York 2005.
5. Kostek B., Application of soft computing to automatic music information retrieval, J. American Society for Information Science and Technology, 55, No. 12, 1108-1116, 2004.
6. Kostek B., Musical Instrument Classification and Duet Analysis Employing Music Information Retrieval Techniques, Proc. of the IEEE, 92, No. 4, 712-729, April 2004.
7. Kostek B., Czyżewski A., Processing of Musical Metadata Employing Pawlak's Flow Graphs, Rough Set Theory and Applications (RSTA), Transactions on Rough Sets, Advances in Rough Sets, LNCS 3100, 1, 285-305, 2004.
8. Lindsay A.T., Herre J., MPEG-7 and MPEG-7 Audio – An Overview, J. Audio Eng. Soc., 49, 7/8, 589-594, 2001.
9. Pawlak Z., Rough Sets, J. Computer and Information Science, 11, No. 5, 1982.
10. Takagi T., Sugeno M., Fuzzy Identification of Systems and its Application to Modelling and Control. IEEE Trans on Systems, Man and Cybernetics, 15, 116-132, 1985.
11. Tadeusiewicz R., Sztuczne sieci neuronowe, Akademicka Oficyna Wydawnicza RM, Warszawa 1993.
12. Wójcik J., Kostek B., Intelligent Methods for Musical Rhythm Finding Systems, in Intelligent Technologies for Inconsistent Knowledge Processing (Nguyen N.T., Ed.), 10, Chapter 11, 187-202, Australia 2004.
13. Zadeh L., Fuzzy Sets. Information and Control, 8, 1965, 338-353, 1965.
14. Zadeh L., Kacprzyk J. (Eds.), Fuzzy Logic for the Management of Uncertainty, Wiley, New York 1992.
15. Żurada J., Introduction to Artificial Neural Systems, West Publishing Comp., St. Paul, 1992.
16. URL: <http://ismir2005.ismir.net/> Music Information Retrieval website (2005)
17. URL: <http://www.soft-computing.de/def.html>

APPLICATIONS OF COMPUTATIONAL INTELLIGENCE TECHNIQUES TO ACOUSTICS

Summary. The aim of this paper was to review some chosen applications of computational techniques to acoustics and in particular to sound engineering. The presented research studies employed artificial neural networks, rough set method, fuzzy logic, genetic algorithms, Pawlak's flow graphs and other soft computing techniques. The investigated problems were devoted to classification of musical instrument sounds, musical phrases, and intelligent music processing, and also to the domain of computer control of classical organ instruments.

