



Wydawnictwo  
Naukowe  
AKAPIT



## CZY PO ERZE PRZETWARZANIA I ROZPOZNAWANIA SYGNAŁÓW NADEJDZIE EPOKA ICH AUTOMATYCZNEGO ROZUMIENIA?

RYSZARD TADEUSIEWICZ

### *WILL AFTER THE ERA OF SIGNAL RECOGNITION AND PROCESSING BEGIN THE ERA OF THEIR AUTOMATIC UNDERSTANDING?*

#### *Abstract*

*The paper presents some problems connected with the automatic interpretation and understanding of the content of the collected data of any kind. Author discusses the possibility of application of the methods developed for the understanding of the medical images to the analysis of any database. Such approach can be treated as the fifth step of the data processing, after collection of signals/data, filtering of signals/data, and analysis of signals, data recognition.*

### 1. WPROWADZENIE

Seminarium *NeuroMet*, w którym staram się uczestniczyć od początku jego istnienia, dotyka szerokiego spektrum zagadnień związanych ze stosowaniem metod i technik sztucznej inteligencji w problematyce metalurgii i inżynierii materiałowej. Na początku koncentrowaliśmy się wszyscy – zgodnie z nazwą tego Seminarium – głównie na stosowaniu sieci neuronowych w zagadnieniach metalurgicznych. Była to problematyka, którą bardzo aktywnie wtedy propagowałem, stąd w początkowych kilku latach moje referaty, które tradycyjnie były wygłaszane na otwarcie tego Seminarium, dotyczyły tej właśnie problematyki, na co wskazują ich tytuły: 1997 – *Wprowadzenie do sieci neuronowych*, 1998 – *Nowe metody uczenia w sztucznych sieciach neuronowych*, 1999 – *Samoorganizujące się sieci neuronowe jako nowa*

*metoda wizualizacji złożonych zbiorów danych*, 2000 – *Problemy optymalizacji struktury modelu neuronowego*. Potem jednak okazało się, że zasób możliwych do wykorzystania nowoczesnych narzędzi informatycznych, określanych często jako *soft computing*, jest znacznie szerszy, więc obok sieci neuronowych zaczęły być stosowane (i omawiane na seminarium) także i inne techniki komputerowe. Dlatego już w 2001 pojawił się nowy motyw (*Sztuczna inteligencja to nie tylko sieci neuronowe*), a tytuł mojego referatu z 2002 roku *Sztuczna inteligencja jako narzędzie do odkrywania nowych faktów naukowych w pozornie wyeksplorowanych danych badawczych* wcale już nie nawiązywał do sieci neuronowych.

Referat tegoroczny idzie jeszcze dalej w tym samym kierunku, wyznaczanym dążeniem do stałego poszerzania instrumentarium metod i technik sztucz-


nej inteligencji, mianowicie proponuje poszerzenie tradycyjnego zestawu działań, jakie wykonuje się na różnych danych (w szczególności na różnych sygnałach) o nową koncepcję, dla której zaproponowano nazwę **automatycznego rozumienia**. Koncepcję tę pierwotnie zaproponowano głównie dla obrazów (Leś i Tadeusiewicz, 2000), zwłaszcza że można ją było oprzeć na wcześniej rozwijanej technice syntaktycznej (lingwistycznej) analizy i klasyfikacji wybranych obrazów medycznych (Ogiela i Tadeusiewicz, 1999; Ogiela i Tadeusiewicz, 2001) ale potem udało się zaproponować podobną metodologię do opisu innych złożonych sygnałów na przykład sygnału mowy patologicznej (Tadeusiewicz i in., 2001), a także znacząco ją wzbogacić i uogólnić (Tadeusiewicz i Ogiela, 2002; Tadeusiewicz i Ogiela, 2004) w takim stopniu, że aktualnie można o niej mówić jako o technice nadającej się do zastosowania w niemal wszystkich typach sygnałów (Tadeusiewicz, 2004a). Co więcej w pracy (Tadeusiewicz i Ogiela, 2003) wykazano, że prezentowaną tu technikę automatycznego rozumienia sygnałów używać można nie tylko dla potrzeb ich klasyfikacji czy wykorzystania w diagnostyce, ale również można z niej skorzystać jako z techniki wspomagającej semantycznie zorientowane wyszukiwanie informacji w Internecie i w multimedialnych bazach danych, co znacząco poszerzyło zakres jej użyteczności. Pełniejszy opis prezentowanej tu techniki można znaleźć w monografii książkowej (Tadeusiewicz i Ogiela, 2004b), do której odsyłam wszystkich Czytelników bardziej zainteresowanych szerokim wykorzystaniem techniki rozumienia sygnałów w uprawianiu przez siebie dziedzinie badań naukowych.

## 2. POSTAWIENIE PROBLEMU

W ramach seminariów z cyklu NeuroMet koncentrujemy uwagę głównie na tym, jak używać zaawansowanych narzędzi obliczeniowych (w szczególności narzędzi należących do tak zwanej sztucznej inteligencji) w tym celu, aby lepiej modelować złożone zjawiska i procesy, a także by nimi skutecznie sterować względnie trafnie prognozować ich wynik. Jednak wszystkie obszary wiedzy, w których uczestnicy seminarium NeuroMet stosują techniki komputerowe, opierają się w maksymalnym stopniu na danych empirycznych. Dlatego można bez ryzyka popelnienia błędu twierdzić, że rozwój naukowej wiedzy oraz praktyki w tej dziedzinie w ogromnym stopniu zależy od tego, co i jak potrafimy zmierzyć, jakie sygnały potrafimy zarejestrować, a także – i to jest przedmiotem niniejszego referatu – co potrafimy zrobić z wynikami pomiarów.

## Etap 0: Pozyskanie informacji

Obiekt badań



Rysunek 1. Każdy proces badawczy (empiryczny) zaczyna się od zbierania sygnałów.

Figure 1. Each research (empirical) process begins from collecting the signals.


Każdy obiekt generuje pewne sygnały, które niosą informację o zachodzących w nim zjawiskach i procesach. Sygnały te możemy zbierać za pomocą czujników (rys. 1), przetwarzać za pomocą odpowiednich konwerterów, oczyszczać albo formować za pomocą filtrów i kompensatorów (rys. 2), a potem analizować z pomocą odpowiednich algorytmów, tak aby uzyskać w wyniku obliczeń takie ich cechy i parametry, które dostarczą nam niezbędnej wiedzy o badanym zjawisku (rys. 3).

Jeśli to nam jeszcze nie wystarcza, to możemy same sygnały albo ich parametry, będące wynikiem wstępnej analizy, poddać pogłębionej analizie i klasyfikacji z pomocą zaawansowanych metod sztucznej inteligencji (rys. 4).

Do każdego z wymienionych wyżej etapów procesu przetwarzania, analizy i rozpoznawania sygnałów stworzono już mnóstwo wyspecjalizowanych narzędzi zarówno hardware'owych jak i software'owych. Można używać filtrów liniowych i nieliniowych żeby

## Etap 1: Filtracja sygnałów

Obiekt badań



Rysunek 2. Dla prawidłowego wnioskowania na temat badanych zjawisk sygnały muszą być oczyszczone z zakłóceń oraz spreparowane w kierunku poprawy ich reprezentatywności.

Figure 2. For proper conclusions regarding investigated phenomena signals have to be cleared from disturbances and prepared towards improvement of their representational value.

uzyskiwane z czujników sygnały uwolnić od zniekształceń i zakłóceń a także w taki sposób je przetworzyć, żeby lepiej odzwierciedlały istotne aspekty badanego zjawiska.

W celu prawidłowego wydobywania, mierzenia i oceniania cech i parametrów badanych zjawisk konieczne jest korzystanie z wielu założeń, dotyczących rozstrzygnięcia, co w badanych zjawiskach jest istotne i powinno się znaleźć wśród opisujących je cech, a co ma charakter mniej lub bardziej przyczynkowy. Dla prawidłowego wydobywania istotnych cech sygnałów można tworzyć modele badanego zjawiska – czasem matematyczne (przyczynowo-skutkowe, albo przynajmniej statystyczne), a w innych przypadkach wyłącznie koncepcyjne. Ważne jest to, żeby znalezione parametry naprawdę dobrze reprezentowały te cechy sygnałów, które są najistotniejsze dla badanego zjawiska.

Trudna sztuka znajdowania właściwych parametrów opisujących interesujące nas procesy oraz intuicja badawcza (lub inżynierska) konieczna do trafnego typowania mierzalnych cech obiektów i zjawisk podlegających badaniom - jest obecnie przedmiotem bardzo wielu ważnych badań naukowych. Mnóstwo niebanalnych problemów naukowych i praktycznych wyłania się też w momencie, gdy uświadomimy sobie, że nie wystarczy wymyślić jakąś cechę i wykazać jej użyteczność w kontekście określonego zadania praktycznego – ale konieczne jest jeszcze stworzenie algorytmów skutecznej ekstrakcji tej cechy z mierzalnych sygnałów. W tej dziedzinie dużo już osiągnięto, ale wciąż jeszcze bardzo dużo jest do osiągnięcia i do zbadania w przyszłości. Jednak scharakteryzowanie badanego zjawiska czy procesu za pomocą właściwych dla niego parametrów to dopiero wstępny krok na pew-


nej długiej i trudnej drodze.

Dalszy ciąg tej drogi staje się jasny, jeśli uświadomimy sobie, że wszelkie badania i komputerowe analizy prowadzimy zwykle po to, żeby rozstrzygnąć jakiś problem albo podjąć jakąś decyzję. Dlatego finalnym etapem „klasycznej” obróbki sygnałów jest próba automatycznego podjęcia decyzji, której najczęstszą formą jest próba automatycznego rozpoznania lub klasyfikacji obiektów będących źródłem sygnału. Używamy do tego różnych metod sztucznej inteligencji, na przykład sieci neuronowych, algorytmów rozpoznawania obrazów (*pattern recognition*), logiki rozmytej, zbiorów przybliżonych albo technik ewolucyjnych. Metod klasyfikacji i rozpoznawania zbudowano w ostatnich latach bardzo wiele, a ich wspólną cechą jest to, że pozwalają one wprowadzić w zbiorowości badanych zjawisk i procesów pewien porządek. Jeśli uda się stwierdzić, że badane obiekty lub zjawiska da się zaliczyć do pewnych klas lub przyporządkować do pewnych wzorców, to możliwe staje się przeniesienie ich analizy na nowy (wyższy) poziom abstrakcji, gdyż możemy wtedy formułować sądy ogólne o całych **klasach** obiektów, zjawisk lub sygnałów, zamiast wnioskować wyłącznie o konkretnych egzemplarzach konkretnych zjawisk lub procesów. Takie przejście do wyższego poziomu abstrakcji, które jest często związane z zamianą **języka** opisu zjawisk (odwołującego się do ich konkretnych właściwości i cech) na **metajęzyk** operujący ogólniejszymi pojęciami i pozwalający na formułowanie bardzo ogólnych sądów na temat relacji, jakim podlegają wyodrębnione klasy, jest zawsze warunkiem wstępnym i podstawą każdej naukowej refleksji.

Podstawową tezą przedstawianego referatu jest stwierdzenie, że mimo bezspornej przydatności klasycznych metod przetwarzania, analizy (ukierunko-

## Etap 2: Analiza sygnałów

Obiekt badań




Rysunek 3. Wydobycie w następstwie analizy sygnałów cechy badanego obiektu powinny wystarczać do jego pełnego scharakteryzowania, chociaż objętość cech jest zwykle znacznie mniejsza niż objętość sygnału (również przefiltrowanego).

Figure 3. Features of the object, which are revealed during analysis of signals, should be satisfactory for full characterization of this object, even so the volume of the features is usually much smaller than the volume of the signal (also filtered).

## Etap 3: Rozpoznawanie

Obiekt badań



Rysunek 4. Finalnym efektem tradycyjnej sekwencji czynności zmierzającej do komputerowej analizy sygnału jest najczęściej jego klasyfikacja albo rozpoznawanie.

Figure 4. Classification or recognition of the signal is often the final effect of conventional sequence of actions towards computer analysis of signals.

wanej na wydobywanie parametrów oraz cech) a także klasyfikacji i rozpoznawania sygnałów – istnieje sfera potrzeb związanych z inteligentną interpretacją sygnałów, która do tej pory nie znalazła dostatecznie dobrego rozwiązania. Sferę tę wiążemy z tytułowym problemem automatycznego **rozumienia** sygnałów.

Bardzo istotne jest stwierdzenie, że **rozumienie** sygnałów jest czymś istotnie bogatszym i czymś zasadniczo odmiennym od ich analizy czy klasyfikacji. Podczas analizy sygnału usiłujemy ustalić (obliczyć), jakie wartości mają takie lub inne cechy lub arbitralnie wybrane parametry, natomiast przy próbie automatycznego rozumienia dążymy do tego, żeby odpowiedzieć na pytanie, co z tego wynika, że te cechy lub parametry mają takie właśnie wartości. Podobnie podczas prób automatycznego rozpoznawania oraz klasyfikacji zmierzamy do znalezienia kategorii (oraz wzorców – ang. *pattern*) do których można zaliczyć określone obiekty oraz ich sygnały, natomiast próba rozumienia zmusza nas do poszukiwania merytorycznego znaczenia tego faktu, że jakiś obiekt należy do jakiejś kategorii (rys. 5).

Problem automatycznego rozumienia sygnałów wydaje się na pierwszy rzut oka trochę dziwny, a może nawet sztuczny albo wydumany. W rzeczywistości jest to jednak jedno z kluczowych wyzwań współczesnej nauki. Dzięki postawieniu (a także rozwiązaniu) wielu zagadnień związanych z automatycznym rozumieniem wybranych sygnałów (na przykład obrazów medycznych, patrz wykaz bibliografii) udało się w pełni wykorzystać możliwości techniki komputerowej jako narzędzia nadającego się do tego, by przeniknąć przez powierzchowną sferę wizualnej **formy** określonych obrazów i dotrzeć do ich merytorycznej (w tym przypadku medycznej) **treści** tych zobrazowań. Ta treść pozwala **zrozumieć**, jaki proces chorobowy roz-

wija się w organizmie pacjenta, przy czym ustalenie określonych **znaczeń** powstaje w wyniku **wnioskowania lingwistycznego** na podstawie widocznych zmian morfologicznych w obrazach badanych narządów.

Wydaje się, że zaproponowana (i obszerniej opisana w cytowanych pozycjach literatury) technika automatycznego rozumienia sygnałów może się przydać podczas obróbki sygnałów pochodzących z analizy procesów i zjawisk którymi interesują się uczestnicy seminarium NeuroMet, gdyż w ich badaniach także spełniony jest warunek, że nie chodzi o wartości takich czy innych parametrów, lecz o **zrozumienie** istoty analizowanych zjawisk i procesów.

### 3. SZKIC SPOSOBU ROZWIĄZANIA PROBLEMU

Można podać następujący zestaw **cech** automatycznego rozumienia sygnałów (zgodnego z koncepcją tej pracy):

1. W maksymalnym stopniu naśladowany jest naturalny sposób rozumowania specjalisty, który zna sens i znaczenie rejestrowanych sygnałów i potrafi powiązać z nimi określone stwierdzenia, mające charakter oceny ich merytorycznego znaczenia;
2. Dzięki stworzeniu lingwistycznego opisu merytorycznej treści sygnału (patrz niżej) możliwe jest uzyskiwanie jego semantycznej reprezentacji bez apriorycznego określenia liczby rozpoznawanych klas;
3. Tworzony opis lingwistyczny ma charakter strukturalny i pozwala na prowadzenie analizy znaczenia sygnału, która może być dokonywana z różnym stopniem szczegółowości dla potrzeb klasyfikacji lub indeksacji.

Odwołajmy się do przykładu, na bazie którego opisywane tu metody zostały pierwotnie sformułowane i wykorzystane. Wyobraźmy sobie zatem, że interesującymi nas sygnałami są obrazy medyczne, a celem ich zrozumienia jest postawienie trafnej diagnozy. Rozwijając tę myśl można stwierdzić, że w przypadku użycia w diagnostyce rozpoznawania obrazu mamy zawsze do czynienia z pewną liczbą z góry ustalonych wzorców, a proces przetwarzania informacji obrazowej zmierza do tego, by z obrazu wydobyć cechy pozwalające na zaliczenie go do jednej z tych z góry zadanych klas. Taki model przetwarzania zakłada jednokierunkowy przepływ sygnałów (rys. 6).

W odróżnieniu od tego schematu, w przypadku rozważania zadania **rozumienia** obrazu, które lepiej odpowiada postępowaniu diagnostycznemu prowadzonemu przez lekarza, przepływ informacji jest dwukierunkowy, gdyż strumień empirycznych danych,

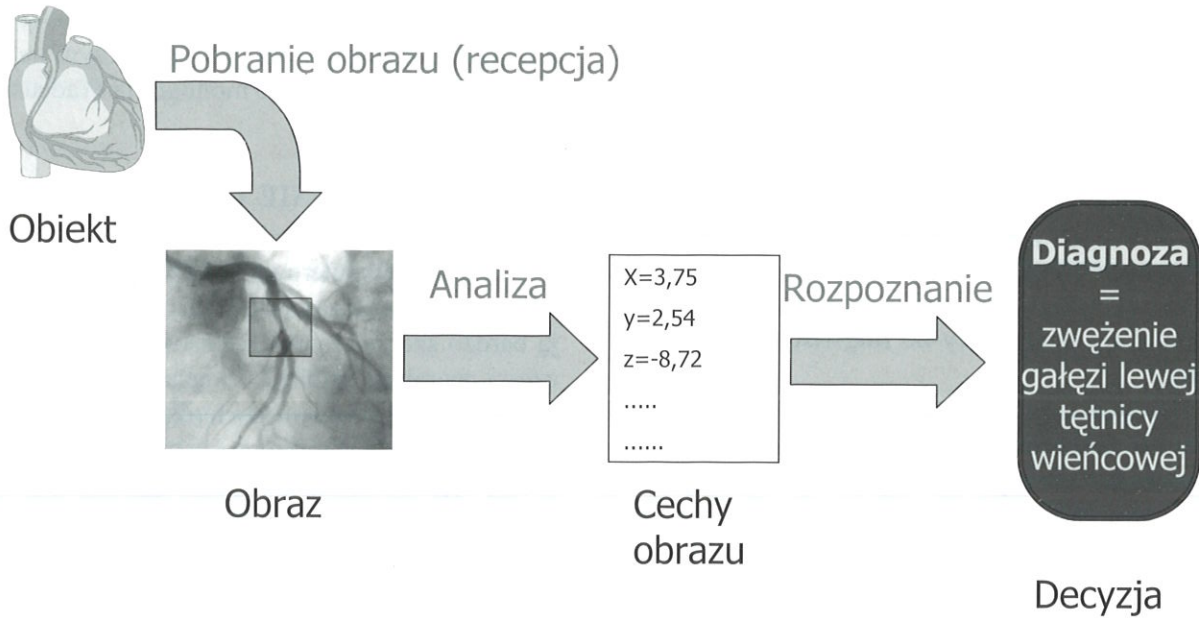
## Etap 4: Rozumienie sygnałów

Obiekt badań



Rysunek 5. Przeniknięcie do merytorycznej treści analizowanego obiektu pozwala automatycznie wykryć jego sens i znaczenie, co może być znacznie bardziej użyteczne, niż jego rozpoznanie.

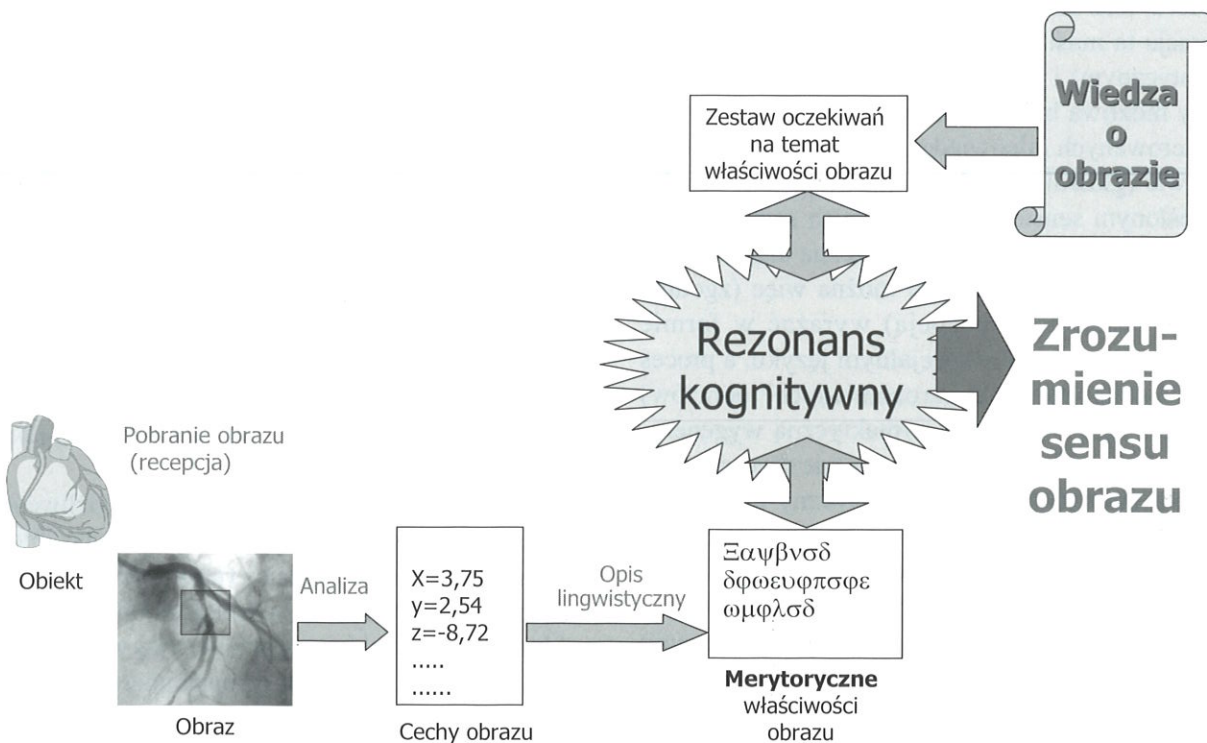
Figure 5. Transfer of technical content of analyzed object allows the automatic revealing of its meaning, which can be more useful than recognition of this object.



Rysunek 6. Diagram przepływu informacji przy zwykłym przetwarzaniu i rozpoznawaniu sygnałów (na przykładzie obrazów medycznych).  
 Figure 6. Diagram of information flow and signal recognition (using a medical picture as an example).

pochodzących od podsystemu rejestrującego i analizującego obraz, interferuje w tym modelu ze strumieniem *oczekiwań* (rys. 7). Oczekiwania te mają charakter postulatów, określających właściwości badanego obrazu przy założeniu, że merytoryczna zawartość tego obrazu odpowiada jednemu z możliwych wariantów jego **semantycznej** (znaczeniowej) interpretacji. Zakłada się przy tym, że system *rozumiejący* obraz dysponuje zestawem generatorów wspo-

mnianych *oczekiwań*, związanych z różnymi hipotetycznymi sposobami *merytorycznej interpretacji* zawartości obrazu (Leś i Tadeusiewicz, 2000; Ogiela i Tadeusiewicz, 1999; Ogiela i Tadeusiewicz, 2001). Taka struktura systemu rozumienia obrazu w ogólnym zarysie odpowiada jednemu z psychologicznych modeli percepcji wzrokowej, opartemu na koncepcji korzystania z wiedzy o postrzeganych obiektach, co omówimy niżej.



Rysunek 7. Dwukierunkowy przepływ informacji podczas próby rozumienia sygnałów (na przykładzie obrazów medycznych).  
 Figure 7. Two-directional flow of information during an attempt of understanding the signals (using a medical picture as an example).

Musimy teraz skonkretyzować przedstawione wyżej ogólne koncepcje automatycznego rozumienia obrazu, tak żeby można było związać z nimi określone modele obliczeniowe i dokonać ich praktycznej implementacji. Poszukując obliczalnych formuł, mogących odpowiadać pojęciom rezonansu kognitywnego, zachodzącego pomiędzy cechami obrazu, oczekiwanymi na podstawie wiedzy, a tymi cechami, które rzeczywiście dają się wykryć w aktualnym obrazie – odwołam się w tej pracy do **lingwistyki matematycznej**.

Decyzja ta w pierwszej chwili może się wydawać nieco dziwaczna, gdyż lingwistyka tradycyjnie stosowana jest do zupełnie innych celów – na przykład do tworzenia języków programowania lub do analizy tekstów. Jednak takie właśnie podejście jest w pełni uzasadnione, gdy przypomnimy sobie, jaki był powód porzucenia wygodnego modelu *rozpoznawania* obrazu i poszukiwania nowego paradygmatu – nazwanego właśnie automatycznym jego *rozumieniem*.

Otóż stwierdziliśmy wyżej, że w przypadku analizy złożonych sygnałów (w szczególności obrazów medycznych) niemożliwe jest wskazanie *a priori* jakichkolwiek *wzorców* ani podanie z góry dokładnej *liczby* rozpoznawanych klas. Automatyczne „rozumienie” obrazów trzeba więc utożsamiać z takim procesem analizy informacji obrazowej, w wyniku którego powstawać może *potencjalnie nieograniczona* liczba różnych wniosków. Nie wchodzi więc w rachubę żaden *wyбір* odpowiedzi z założonego z góry ustalonego zbioru, lecz konieczna jest *generacja* odpowiedzi. Generacja ta musi podlegać jednak ścisłym regułom (gramatycznym) i musi być prowadzona w taki sposób, by możliwa była potem precyzyjna analiza tych wygenerowanych odpowiedzi i wnioskowanie na ich podstawie (głównie w celu znajdowania klas opisów w określonym sensie ekwiwalentnych semantycznie – na przykład związanych z identyczną diagnozą).

Wyniki rozumienia obrazu można więc (zgodnie z prezentowaną tu koncepcją) wyrażać w formie „zdań” zapisywanych w specjalnym języku, a proces wnioskowania (na temat „zrozumianych” obrazów) wiązać się będzie z analizą syntaktyczną wygenerowanych zdań, wykorzystującą specjalnie stworzoną dla tego celu gramatykę oraz automatyczny parser, dokonujący koniecznej analizy składniowej. W większości przypadków można tak zbudować słownik, gramatykę i parser, że pojęcia związane z rozumieniem obrazu i wnioskowaniem opartym na tym rozumieniu – w naturalny sposób przekładają się na konkretne działania analizatora syntaktycznego, znane z translacji języków formalnych. Szczegóły tego procesu są niestety dosyć złożone, w związku z czym nie mieszczą się w ramach tego referatu, dlatego odsyłam bar-

dziej dociekliwego Czytelnika do wymienionych w bibliografii obszerniejszych prac, przy czym na szczególne polecenie zasługuje monografia (Tadeusiewicz i Ogiela, 2004b).

#### 4. PODSUMOWANIE I WNIOSKI

Techniki komputerowe są obecnie często i chętnie stosowane w większości dziedzin nauki i techniki i mają bardzo szeroki zakres zastosowań. Zaczynając od części aparatury najbliższej związanej z badanym zjawiskiem albo procesem stwierdzamy, że komputery lub specjalizowane mikroprocesory (na przykład procesory sygnałowe DSP) są dziś nagminnie stosowane do rejestracji różnych sygnałów, gdyż są bez porównania wygodniejsze i elastyczniejsze od wszelkich innych technik zbierania danych. Dzięki komputerowej rejestracji sygnałów, które dzięki temu dostępne są od początku w formie cyfrowej, możliwe jest ich dowolne przetwarzanie i agregowanie, zarówno w dziedzinie czasu, jak i w dziedzinie częstotliwości a także w funkcji specjalnych parametrów wyznaczających na przykład skalę dla transformacji falkowych. Możliwości komputerowego przetwarzania sygnałów są wręcz nieograniczone, bo wszyscy znamy zalety techniki cyfrowej i jej przewagę nad metodami analogowego rejestrowania i przetwarzania sygnałów, jednak przetworzony sygnał nadal pozostaje sygnałem i wymaga dopiero inteligentnej interpretacji, żeby mógł się stać źródłem użytecznej wiedzy.

Automatycznie prowadzona komputerowa analiza sygnału pozwala zageścić informacje w nim zawarte, dzięki czemu kilka lub kilkanaście dobrze dobranych liczb (cech, parametrów, charakterystyk) może nieść tę samą ilość użytecznej informacji, jak cały sygnał oryginalny, z reguły cechujący się dużą objętością informacyjną. Obliczanie i wyznaczanie stosownych cech sygnału jest istotą ogromnej większości badań laboratoryjnych lub ekspertyz wykonywanych we współczesnym przemyśle lub w badaniach naukowych. Jednak zestaw nawet najbardziej wyrafinowanych cech sygnału nie jest tożsamy z tą wiedzą, której poszukujemy – więc także i ten etap wykorzystania techniki komputerowej nie można traktować jako etap finalny.

Postępując dalej napotykamy na możliwości, jakie stwarzają współczesne metody sztucznej inteligencji w zakresie klasyfikacji i **rozpoznawania**. Najczęściej mówi się tu o rozpoznawaniu obrazów, chociaż klasyfikowanymi i rozpoznawanymi wzorcami mogą tu być dowolne regularne zgrupowania praktycznie dowolnych sygnałów. Jednak nawet rozpoznanie przynależności sygnału do pewnej z góry nieznannej klasy nie przyczynia się do zrozumienia tej informacji, któ-

rą niesie rozważany sygnał i która jest głównym przedmiotem zainteresowania badacza.

Dlatego w przedstawionym artykule zaproponowano wykonanie kolejnego kroku: podjęcie próby automatycznego rozumienia merytorycznego sensu sygnału i wynikającej z tego sensu semantycznej (znaczeniowej) interpretacji badanego zjawiska, obiektu lub procesu. Automatyczna analiza znaczeń, nazwana w tej i we wcześniejszych pracach automatycznym rozumieniem sygnałów, wymaga szeregu nietypowych zabiegów. Po pierwsze właściwości analizowanego sygnału muszą być wyrażone w formie lingwistycznej, a to oznacza konieczność stworzenia specjalnego języka opisu merytorycznej zawartości sygnału oraz określenia jego gramatyki. Po drugie wnikanie w semantyczną treść sygnału wymaga stworzenia bazy wiedzy, która będzie generatorem hipotez badawczych wykorzystywanych przy dwukierunkowym „zderzaniu” strumienia danych percepcyjnych (pochodzących od czujników i przetworników pomiarowych) ze strumieniem oczekiwań na temat tych danych, wynikających z posiadanej bazy wiedzy. I wreszcie po trzecie konieczne jest zdefiniowanie pojęciowe i zrealizowanie implementacyjne elementu algorytmu automatycznego rozumienia sygnałów, który nazwano rezonansem kognitywnym. Jest to najtrudniejsza część zadania, ale – jak wynika z cytowanych niżej publikacji – dla wielu niebanalnych problemów taki mechanizm rezonansu kognitywnego udało się zaproponować i zaimplementować.

Podsumowując można stwierdzić, że mając do czynienia z sygnałami cyfrowymi, opisującymi różne procesy i zjawiska, można pokusić się o domknięcie procesu ich analizy na etapie automatycznego rozumienia, a nie samego tylko (na przykład) rozpoznawania, gdyż dzięki temu można uzyskać wyniki – znacznie ciekawsze naukowo i znacząco bardziej użyteczne w praktyce. Trzeba bowiem stale pamiętać, że w każdym przypadku pomiar i sygnał nie są celem ostatecznym, gdyż tym celem jest zawsze wiedza, a ona jest wynikiem rozumienia – naturalnego lub automatycznego.

## LITERATURA

- Leś, Z., Tadeusiewicz, R., 2000.: Shape Understanding System, Polygon Class Processing Methods, *Signal Processing and Communications*, (ed.), Hamza, M.H., IASTED/ACTA Press, Anaheim, Calgary, Zurich, 447-454 .
- Ogiela, M., Tadeusiewicz, R., 1999, Syntactic Analysis and Languages of Shape Feature Description in Computer-Aided Diagnosis and Recognition of Cancerous and Inflammatory Lesions of Organs in Selected X-Ray Images. *J. Digital Imaging*, 12, 2, Suppl. 1, 24-27.
- Ogiela, M.R., Tadeusiewicz, R., 2001, Image Understanding Methods in Biomedical Informatics and Digital Imaging, *J. Biomedical Informatics*, 34, 377-386.
- Tadeusiewicz, R., Wszolek, W., Izvorski, A., Wszolek, T., 2001, Understanding of vocal tract pathology using speech signals analysis, *Mater. 2. Int. Workshop on Models And Analysis of Vocal Emissions for Biomedical Applications*, (ed.), Manfredi C., Bruscaiglioni P., University of Firenze, 2001, Book of Abstracts, 52-53 + pełna wersja CD-ROM (9 stron bez numeracji)
- Tadeusiewicz, R., Ogiela, M. R., 2002, Automatic Understanding of Medical Images – New Achievements in Syntactic Analysis of Selected Medical Images, *Biocybernetics and Biomedical Engineering*, 22, 4, 17-29.
- Tadeusiewicz, R., Ogiela, M.R., 2003, Artificial Intelligence Techniques in Retrieval of Visual Data Semantic Information, *Advances in Web Intelligence*, (ed.), Menasalvas, E., Segovia, J., Szczepaniak, P.S.: Lecture Notes in Artificial Intelligence, nr 2663, Springer Verlag, Berlin – Heidelberg – New York, 18-27.
- Tadeusiewicz, R., 2004, Automatic Understanding of Signals. Rozdział w książce: *Intelligent Information Processing and Web Mining*, (ed.), Kłopotek, A., Wierchoń, S., Trojanowski, K., Springer-Verlag, Berlin – Heidelberg – New York, 577 – 590.
- Tadeusiewicz, R., Ogiela, M. R., 2004a, The New Concept in Computer Vision: Automatic Understanding of the Images. Rozdział w książce: *Artificial Intelligence and Soft Computing, Lecture Notes in Artificial Intelligence*, (ed.), Rutkowski, L. i in., Vol. 3070, Springer-Verlag, Berlin – Heidelberg – New York, 133-144.
- Tadeusiewicz, R., Ogiela, M.R., 2004b, *Medical Image Understanding Technology*, Książka wydana w serii: Studies in Fuzziness and Soft Computing, Vol. 156, Springer-Verlag, Berlin – Heidelberg – New York.

Artykuł otrzymano 7 czerwca 2004 r.