

# 17<sup>th</sup> SYMPOSIUM ON HYDROACOUSTICS

Jurata May 23-26, 2000



## WIELOCZĘSTOTLIWOŚCIOWE WIELOETAPOWE KLASYFIKATORY NEURONOWO-ROZMYTE DO ROZPOZNAWANIA TYPU DNA MORSKIEGO

T. V. Dung, A. Stepnowski  
Politechnika Gdańska, Katedra Telemonitoringu Środowiska  
ul. Narutowicza 11/12, 80-952 Gdańsk  
e-mail: [dung@dolphin.eti.pg.gda.pl](mailto:dung@dolphin.eti.pg.gda.pl), [astep@pg.gda.pl](mailto:astep@pg.gda.pl)

*A hybrid multistage neuro-fuzzy classifiers were developed for sea-bottom recognition from acoustic echoes. A multistage fuzzy neural network was implemented and tested on the data collected on two echosounder's frequencies. Two structures termed as incremental fuzzy neural network (IFNN) and aggregated fuzzy neural network (AFNN), were analysed. In IFNN, an approximate decision is undertaken firstly, based only on the one set of input variables. The decision is then fine-tuned by considering more factors in following stages until the final decision, assigning the output class, is undertaken. In AFNN, the input variables are divided into  $M$  subsets, where each of them is fed to one sub-stage. The final output is derived by the reasoning with all intermediate variables, which work as the outputs of sub-stages in the preceding stage. The proposed structures improve the generalisation ability of the system and reduces requirements on computation power and memory.*

### 1. WPROWADZENIE

W ostatnich latach metody akustyczne rozpoznawania typu dna morskiego stały się standardowymi technikami nieinwazyjnej klasyfikacji i monitorowania dna morza i osadów dennych. Wśród tych metod istotne stało się tworzenie automatycznych metod identyfikacji typu dna morskiego na podstawie analizy obwiedni echa, z których najczęściej wykorzystane są metody sztucznej inteligencji m. in. sieci neuronowych. Główną zaletą sieci neuronowej jest jej zdolność klasyfikacji nieznanymi danymi po nauczeniu pewnego zbioru treningowego [1]. W przypadku, gdy dostępna jest *a priori* pewna wiedza o obiekcie badań, korzystne jest jednoczesne zastosowanie logiki rozmytej, która wydaje się być doskonałym narzędziem w procesie klasyfikacji. Aby wykorzystać zalety obu metod połączono je i stworzono hybrydową strukturę sieci neuronowo-rozmytej. Uzyskane początkowo rezultaty klasyfikacji danych jednoczęstotliwościowych przy użyciu systemu adaptacyjnego wnioskowania neuronowo-rozmytego (ANFIS) osiągnęły poziom 70% poprawnych klasyfikacji [2]. Następnie, przy użyciu danych wieloczęstotliwościowych i zastosowaniu struktury równoległej otrzymano 84% poprawnych klasyfikacji [3].

W artykule przedstawiono rozwinięcie tych badań na modele wieloetapowych wieloczęstotliwościowych sieci neuronowo-rozmytych. Parametry wejściowe modeli były ekstrahowane z echa od dna morskiego, odbieranego na dwóch częstotliwościach. W mo-

delu przyrostowym IFNN (ang. *Incremental Fuzzy Neural Network*), parametry te były przetwarzane szeregowo, tzn., że rezultat klasyfikacji z poprzedniego etapu wpływa na decyzję podjętą na wyjściu następnego etapu. W modelu sumującym AFNN (ang. *Aggregated Fuzzy Neural Network*), parametry były przetwarzane w podetapach występujących w pierwszym etapie, a wynik klasyfikacji otrzymywano na podstawie wszystkich odpowiedzi pochodzących z pierwszego etapu.

## 2. MODEL ADAPTACYJNEGO WNIOSKOWANIA NEURONOWO-ROZMYTEGO SUGENO

System adaptacyjnego wnioskowania neuronowo-rozmytego (ANFIS), który został oparty na architekturze systemu wnioskowania rozmytego [4], posiada zdolność optymalizacji kształtu funkcji przynależności na podstawie danego zbioru (nazwanego zbiorem uczącym).

Klasyfikatory badane w eksperymencie zostały zbudowane na podstawie struktury systemu wnioskowania rozmytego Sugeno [4]. W wersji neuronowo-rozmytej, struktura ta jest ukryta w sieci neuronowej, dlatego system ANFIS może adaptować parametry związane z logiką rozmytą podczas procesu uczenia sieci.

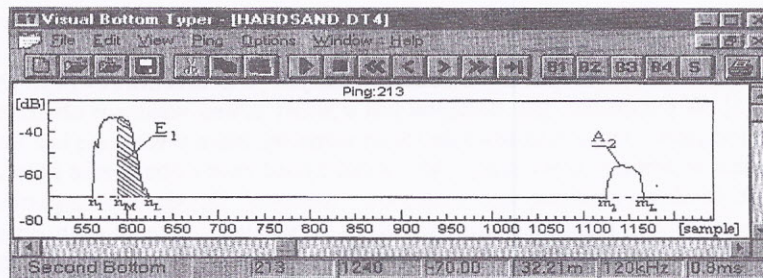
## 3. DANE HYDROAKUSTYCZNE

Dane eksperymentalne zostały zebrane w trakcie przeszukiwań akustycznych na jeziorze Washington. Do tego celu została użyta cyfrowa sonda jednowiązkowa DT4000 pracująca na częstotliwościach 38 kHz i 120 kHz. W eksperymencie, do badania zostały wybrane tylko dane pochodzące z tej samej lokalizacji, dla tego samego typu dna i zbierane dla tych wyżej wymienionych częstotliwości. Dane wejściowe stanowiły 645 sklasyfikowanych impulsów echa od dna występujących w czterech klasach: *twardy piasek, skała, miękki piasek, mul*.

Przykładową obwiednię echa od dna morskiego przedstawiono na Rys. 1. Zbiór parametrów ekstrahowanych z każdego echa jest następujący:

- 4) Energia części opadającej pierwszego echa (sygnatura nierówności dna), E1;
- 5) Amplituda drugiego echa (sygnatura twardości dna), A2.

W ten sposób, dla każdej pary ech uzyskano cztery parametry oznaczone jako E1(38kHz), A2(38kHz), E1(120kHz) i A2(120kHz).



Rys. 1. Graficzna interpretacja parametrów ekstrahowanych z echa

Fig. 1. Graphical interpretation of the parameters extracted from the bottom echo

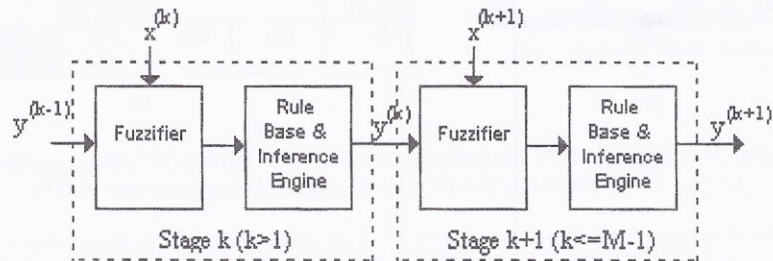
#### 4. EXPERYMENT

Głównym celem eksperymentu było stworzenie wieloetapowego klasyfikatora, w którym zamiast zwiększania wymiaru wektora wejściowego zostało zastosowane przetwarzanie etapowe parametrów pochodzących z ech akustycznych. Zostały opracowane i przebadane dwie kategorie sieci neuronowo-rozmytych: przyrostowa sieć neuronowo-rozmyta (IFNN) i sumująca sieć neuronowo-rozmyta (AFNN).

##### 4.1 Przyrostowa sieć neuronowo-rozmyta

Klasyfikatory skonstruowano za pomocą pakietu MATLAB Fuzzy Logic Toolbox i sprawdzono na zebranych danych. Systemy zostały początkowo trenowane na zbiorze uczącym, a później ich zdolności generalizacji testowano na zbiorze testującym. Zbiór uczący zawierał 200 rekordów a testujący 645 rekordów.

Podstawową strukturę IFNN przedstawiono na Rys. 2. Parametry wejściowe zostały podzielone na  $M$  zbiorów, z których każdy jest podłączony do indywidualnego modułu, odpowiadający pojedynczemu cyklowi pracy ANFIS. W rezultacie, stworzono i połączono szeregowo  $M$  pojedynczych modułów ANFIS. Wnioskowanie przeprowadzono w sposób etapowy [5]. Parametr  $y^{(k)}$  ( $k < M$ ) jest parametrem pośrednim, który prezentuje wyjście z etapu  $k$  i wejście do etapu  $k+1$ . Decyzja jest dostrajana przy uwzględnieniu kolejnych parametrów echa.



Rys. 2. Podstawowa struktura systemu wieloetapowego Sugeno IFNN

Fig. 2. Basic structure of the Sugeno IFNN adopted for a multistage system

Ponieważ struktura ta jest oparta na modelu rozmytym typu Sugeno, postać  $j^{\text{tej}}$  rozmytej reguły wygląda następująco:

$$\text{Regula}_j^{(k)}: \text{If } (x_1^{(k)} \text{ is } A_{1,j}^{(k)} \dots \text{and } x_{n_k}^{(k)} \text{ is } A_{n_k,j}^{(k)}) \text{ and } (y^{(k-1)} \text{ is } B_j^{(k-1)}) \quad (1)$$

$$\text{THEN } y^{(k)} = c_{n_k+1,j}^{(k)} y^{(k-1)} + \sum_{i=1}^{n_k} c_{i,j}^{(k)} x_i^{(k)} + c_{0,j}^{(k)}$$

gdzie  $A_{i,j}^{(k)}$  - zbiór rozmyty od  $i^{\text{tej}}$  zmiennej wejściowej  $j^{\text{tej}}$  reguły,  $n_k$  - kolejność zmiennej wejściowej w etapie  $k$ ,  $B_j^{(k-1)}$  - zbiór rozmyty od  $y^{(k-1)}$  od  $j^{\text{tej}}$  reguły i  $c_{i,j}^{(k)}$  - parametr wynikowy.

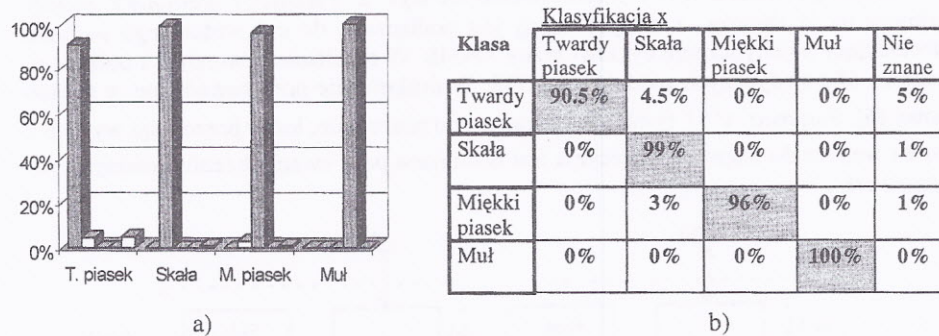
Decyzja o kolejności parametrów wejściowych jest podejmowana na podstawie metody selekcji wejść. Metoda ta wyznacza stopień ważności dla wszystkich parametrów wejściowych. Stopień ważności jest rozumiany jako procent poprawnych odpowiedzi dla

danego parametru po klasyfikacji w pojedynczym cyklu ANFIS.

W eksperymencie, parametry wejściowe systemu podzielono na cztery zbiory ( $k=4$ ), co dało 24 kombinacje ich kolejności  $\{E1(38kHz), E1(120kHz), A2(38kHz), A2(120kHz)\}$ . Oznacza to, że w pierwszym etapie, decyzja jest podejmowana na podstawie jednego parametru a w następnych etapach na podstawie dwóch parametrów (w tym jeden parametr jest wyjściem z poprzedniego etapu). Każdy system zawiera 76 reguł i 224 parametrów wynikowych.

Za pomocą metody selekcji wejść, wyznaczono kolejność parametrów wejściowych, która jest następująca: E1(120kHz) jest podłączony do pierwszego etapu, E1(38kHz) do drugiego etapu, A2(38kHz) do trzeciego etapu i A2(120kHz) do czwartego etapu.

Wynik klasyfikacji w procesie testującym osiągał 52.5% po pierwszym etapie, 89.2% po drugim etapie i **95.7%** poprawnych odpowiedzi po trzecim i ostatnim etapie jak pokazano na Rys. 3.



Rys. 3. Schemat kolumnowy (a) i macierz niezgodności (b) po trzecim (A2 38kHz) i ostatnim etapie (A2 120kHz) systemu IFNN; procent poprawnych odpowiedzi: **95.7%**

Fig. 3. Box diagram (a) and confusion matrix (b) of the testing results after the third (A2 38kHz) and the last stage (A2 120kHz) of system IFNN; percentage of echoes correctly classified in total is **95.7%**

#### 4.2 Sumująca sieć neuronowo-rozmyta

W modelu AFNN, parametry wejściowe są przetwarzane w czterech podetapach połączonych równolegle w pierwszym etapie. Wynik klasyfikacji został oparty na podstawie wszystkich odpowiedzi wychodzących z pierwszego etapu. Podstawowa struktura AFNN jest przedstawiona na Rys. 4. Model składa się z dwóch etapów, gdzie pierwszy etap zawiera  $M$  podetapów. Każdy podetap występujący w pierwszym etapie i drugi etap odpowiadają pojedynczemu modelowi ANFIS. Parametry wejściowe podzielono na  $M$  podzbiorów  $x^{(k)}$  ( $k=1, \dots, M$ ), gdzie każdy z tych podzbiorów jest traktowany jako wejście do oddzielnego podetapu w etapie pierwszym. Parametr wyjściowy  $y^{(k)}$  ( $k=1, \dots, M$ ) jest parametrem pośrednim, który działa jednocześnie jako parametr wyjściowy z podetapu  $k$  w etapie pierwszym i parametr wejściowy do etapu drugiego. Wynik końcowy  $y^{(M+1)}$  jest rezultatem procesu wnioskowania w etapie drugim po uwzględnieniu wszystkich parametrów pośrednich.

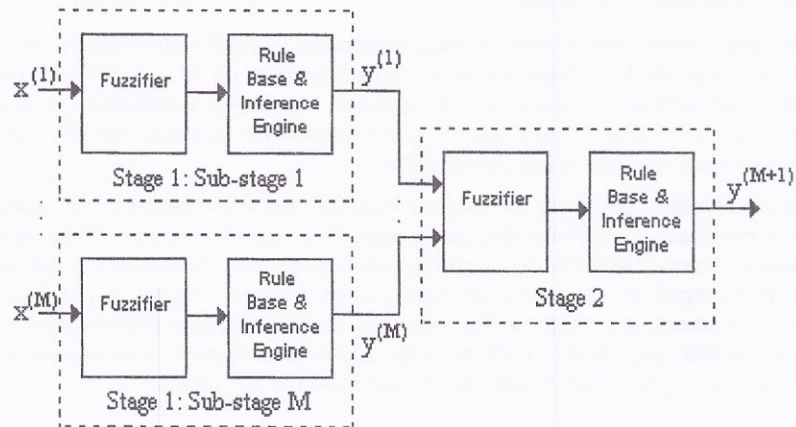
System jest oparty na rozmytym modelu typu Sugeno, więc  $j^{ta}$  reguła w  $k^{tym}$  podetapie z etapu pierwszego ma następującą formę:

$$\text{Regula}_j^{(k)}: \text{If } (x_1^{(k)} \text{ is } A_{1,j}^{(k)} \dots \text{ and } x_{n_k}^{(k)} \text{ is } A_{n_k,j}^{(k)}) \text{ THEN } y^{(k)} = \sum_{i=1}^{n_k} c_{i,j}^{(k)} x_i^{(k)} + c_{0,j}^{(k)} \quad (2)$$

i<sup>ta</sup> reguła w etapie drugim jest następująca:

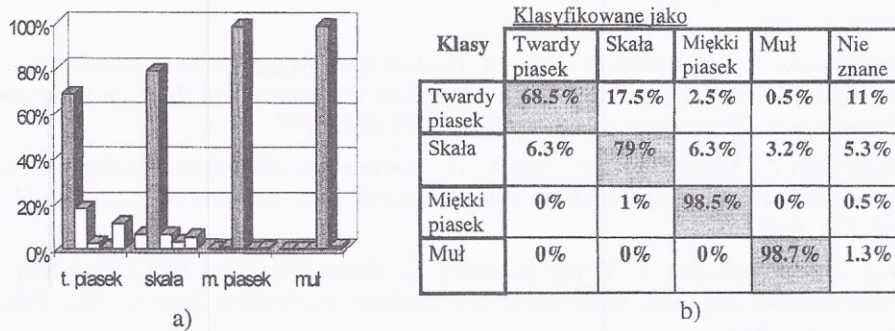
$$\text{Regula}_j: \text{If } (y^{(1)} \text{ is } B_j^{(1)} \dots \text{ and } y^{(M)} \text{ is } B_j^{(M)}) \text{ THEN } y^{(M+1)} = \sum_{i=1}^M c_{i,j}^{(M+1)} y^{(i)} + c_{0,j}^{(M+1)} \quad (3)$$

gdzie:  $A_{i,j}^{(k)}$  - zbiór rozmyty  $i^{\text{tego}}$  parametru wejściowego w  $j^{\text{tej}}$  regule i  $k^{\text{tym}}$  podetapie w etapie 1,  $n_k$  - kolejność zmiennej wejściowej w  $k^{\text{tym}}$  podetapie etapu pierwszego,  $c_{i,j}^{(k)}$  - wynikowy parametr w  $k^{\text{tym}}$  podetapie etapu pierwszego,  $B_j^{(k)}$  - zbiór rozmyty dla  $y^{(k)}$  występujący w  $i^{\text{tej}}$  regule w drugim etapie i  $c_{i,j}^{(M+1)}$  - wynikowy parametr w etapie 2.



Rys. 4. Podstawowa struktura systemu wieloetapowego Sugeno AFNN

Fig. 4. Basic structure of the Sugeno AFNN adopted for a multistage system



Rys. 5. Schemat kolumnowy (a) i macierz niezgodności (b) po drugim etapie systemu AFNN; procent poprawnych odpowiedzi: 86.4%

Fig. 5. Box diagram (a) and confusion matrix (b) of the testing results after the stage 2 of the four-stage AFNN; percentage of echoes correctly classified in total is 86.4%

Należy tutaj podkreślić, że wszystkie wyjścia etapu pierwszego są podłączone do etapu drugiego, co czasami może spowodować nadmiar parametrów wejściowych. W tym przypadku, należy zaprojektować sieć składającą się z większej liczby etapów.

W eksperymencie, wszystkie parametry wejściowe są połączone oddzielnie ze wszystkimi wejściami podetapów etapu pierwszego. Etap drugi zawiera cztery wyjścia odpowiadające czterem wyjściom z etapu pierwszego. System składa się z 272 reguł i 1312 parametrów wynikowych. W procesie testowania, uzyskano 58% poprawnie klasyfikowanych ech po E1(38kHz) podetapie, 40.2% po A2(38kHz) podetapie, 52.3% po E1(120kHz) podetapie, 62.6% po A2(120kHz) podetapie etapu pierwszego i **86.4%** po drugim etapie (Rys. 5).

## 5. WNIOSKI

Głównym celem przedstawionych badań było stworzenie automatycznego narzędzia do klasyfikacji typu dna morskiego poprzez wieloetapowy system neuronowo-rozmyty operujący na danych wieloczęstotliwościowych.

Zostały zbudowane dwie wersje systemu wieloetapowego. W czteroetapowym systemie IFNN, procent poprawnie klasyfikowanych ech osiągał poziom od 82% do 95%, w zależności od kolejności parametrów wejściowych. W ustaleniu kolejności parametrów wejściowych pomocne jest użycie metody selekcji wejść. W dwuetapowym systemie AFNN, procent poprawnie klasyfikowanych ech osiągał poziom 86%.

Uzyskane rezultaty pokazują, że proponowany system wieloetapowy jest obiecującym rozwiązaniem problemu klasyfikacji dna morskiego. W przypadku modelu IFNN, system nie tylko daje lepsze wyniki, lecz również redukuje wymaganą moc obliczeniową. Jak łatwo zauważyć, rezultat klasyfikacji poprawia się znacząco po drugim i trzecim etapie, lecz nie poprawia po czwartym etapie z czego można wnioskować, że jeden etap procesu można zlikwidować. W przypadku, gdy model IFNN nie daje satysfakcjonującego wyniku, można zastosować wieloetapowe hybrydowe modele składające z sieci IFNN i AFNN.

## LITERATURA

- [1] Stepnowski A., Moszyński M., Bakiera D., Komendarczyk R., Burczyński J., Visual Real-time Bottom Typing System and Neural Network Experiment for Seabed Classification, *Proceedings of 3<sup>rd</sup> European Conference on Underwater Acoustics*, Heraklion, 869-875, 1996.
- [2] Maciołowska J., Stepnowski A., Tran. V. D., Fish Schools and Seabed Identification Using Neural Networks and Fuzzy Logic Classifiers, *Proceedings of the Fourth European Conference on Underwater Acoustics*, Rome, 275-280, 1998.
- [3] Stepnowski A., Maciołowska J., Tran V. D., Bottom type identification using combined neuro-fuzzy classifier operating on multi-frequency data, *Archives of Acoustic*, 24 (3), 365-378, 1999.
- [4] Jang, J. S. R. and Sun, C. T. and Mizutani, E., *Neuro-Fuzzy and Soft Computing – A Computational Approach to Learning and Machine Intelligence*, Prentice-Hall International, Inc., 1997
- [5] Dung T. V. Maciołowska J., Stepnowski A., Sea Bottom Typing Using Neuro-Fuzzy Classifier Operating on Multi-Frequency Data, *Proceedings of the 2<sup>nd</sup> EAA International Symposium on Hydroacoustics*, Gdańsk-Jurata, 79-84, 1999.