

Michał Charlak¹⁾, Marek A. Jakubowski²⁾

PORÓWNANIE SYSTEMÓW ROZMYTYCH I SZTUCZNYCH SIECI NEURONOWYCH

Streszczenie. W pracy opisano podstawowe pojęcia dotyczące podstawowego modelu matematycznego systemów neurorozmytych potraktowanych jako tzw. „czarna skrzynka” oraz różnych jego wersji. W skrócie przedstawiono wybrane kierunki badań dotyczących fuzji obu technologii. Praca zawiera elementarny opis nowej klasy systemów tzw. inteligencji obliczeniowej.

WSTĘP

Nazwa system rozmyty oznacza przede wszystkim modele procesów zdefiniowanych w sposób niepełny (tzw. procesy źle definiowalne lub mało rozpoznawalne). Liczba możliwych modeli rozmytych (w tym neurorozmytych i sztucznych sieci neuronowych) możliwych do zastosowania w konkretnej sytuacji bywa zwykle duża. Poszczególne modele różnią się pomiędzy sobą niekiedy znacznie.

W literaturze rzadko spotyka się systematykę modeli rozmytych oraz ich porównanie z systemami neurorozmytymi oraz sztucznymi sieciami neuronowymi. Sztuczne sieci neuronowe możemy rozważać jako „uniwersalne aproksymatory” systemów ciągłych.

Systemy rozmyte możemy uważać jako szczególny przypadek ogólnej teorii systemów. Zgodnie z koncepcją rewolucji naukowych Thomasa S. Kuhna można stwierdzić, że teoria systemów ogólnych stanowiła rewolucję w nauce. Pojawienie się ogólnej teorii systemów doprowadziło do gruntownej zmiany teoretycznego układu odniesienia i sposobu postrzegania badanych obiektów i procesów. Należy podkreślić fakt, że ogólna teoria systemów zrodziła się przede wszystkim z dążenia do integracji nauk. Szczególną pozycję ojca ogólnej teorii systemów zajmuje Ludwik von Bertalanffy. Zadaniem ogólnej teorii systemów było ujawnienie i opisanie w sposób teoretyczny prawidłowości budowy, zachowania się, funkcjonowania i rozwoju systemów. Natomiast współczesne badania systemowe są niezmiernie wielostronne. Prawie każda poszczególna część tych badań przekształciła się obecnie w odrębną dyscyplinę naukową np. Ogólna teoria systemów, matematyczna teoria systemów itd. Powstały też odrębne

¹⁾ Katedra Podstaw Techniki, Politechnika Lubelska.

²⁾ Katedra Metod i Technik Nauczania, Politechnika Lubelska.

kierunki w tradycyjnych naukach, przykładowo: ujęcie systemowe w biologii, lingwistyce, psychologii, socjologii, itp.

Pojęcie podzbioru rozmytego może być przypisane bezpośrednio L.A. Zadehowi, gdyż wywodzi się z inspiracji jego pracy z roku 1965.

Celem modelu jest uchwycenie funkcjonowania pewnego systemu. Na konstrukcję modelu można patrzeć jak na proces, w którym bada się relacje pomiędzy zbiorem obiektów zwanych zmiennymi i parametrami modelu i pewnych innych obiektów zwanych spójnikami lub funktorami modelu. Zmienne modelu odpowiadają pewnym charakterystykom modelowanego układu. Mówiąc inaczej dwie klasy modeli można zidentyfikować i rozróżnić za pomocą typów spójników stosowanych w procesie modelowania. Pierwszą klasę modeli, wykorzystującą operacje algebraiczne, takie jak dodawanie, odejmowanie, różniczkowanie, nazywamy modelami matematycznymi. Zarówno parametry, jak i wartości zmiennych tych modeli są zasadniczo określone przez wartości liczbowe.

Drugą klasę modeli, wykorzystujących spójniki typu logicznego, takie jak *i*, *lub* oraz *jeżeli- to*, będziemy nazywali modelami logicznymi. Zawierają one przeważnie parametry natury lingwistycznej. Do roku 1970 większość modeli, które stosowali projektanci systemów, była typu matematycznego. Począwszy od roku 1970 przede wszystkim na podstawie prac w dziedzinie sztucznej inteligencji i baz danych zaczęto poważnie traktować modele typu logicznego jako narzędzie tworzenia systemów. Logika rozmyta była i jest z powodzeniem stosowana przy obu typach modelowania. O ile podzbiory rozmyte mogą być wykorzystane przy obu sposobach modelowania, o tyle obecnie stosuje się je głównie w klasie modeli logicznych, zwanych modelami na podstawie reguł lub modelami na podstawie wiedzy [1].

Współcześnie prowadzone są badania dotyczące opracowania metod identyfikacji systemów rozmytych (szczególnie z wykorzystaniem rozmytych równań relacyjnych i sztucznych sieci neuronowych), analizy reguł uczenia się sieci neuronowych jako podstawy identyfikacji systemów których podstawą są rozmyte reguły oraz badania dotyczące wykorzystania sztucznych sieci neuronowych do prowadzenia rozmytych wnioskowań.

MODELE SYSTEMÓW ROZMYTYCH I NEURO-ROZMYTYCH

Przedstawione poniżej modele i porównania zostały zaczerpnięte z artykułu Blanco A., Delgado M., Requena I., „Relating fuzzy systems and neural networks” [2].

Ogólnie możemy traktować system jako tzw. „czarną skrzynkę” do której wchodzi sygnały wejściowe (tworzą one zbiór sygnałów wejściowych) natomiast wychodzą z niej sygnały wyjściowe, które tworzą zbiór sygnałów wyjściowych. W terminach klasycznej teorii modeli matematycznych można sformułować następujący opis matematyczny zachowania się systemu:

$$y = F(x); F: X \rightarrow Y; x: \text{input}, x \in X \subseteq R^p; y: \text{output}, y \in Y \subseteq R^q \quad (1)$$

Model matematyczny systemu przedstawiony powyżej stanowi numeryczne odwzorowanie relacji wejście-wyjście, nazwiemy go modelem „rzeczym” (crisp model – CS).

W zbiorze modeli CS można wyróżnić podzbiór „ciągłych systemów rzeczowych” (CCS).

Modele CCS posiadają ciągłe relacje typu wejście-wyjście (najczęściej ze względu na określone normy w przestrzeni euklidesowej). W tym modelu może wystąpić tylko skończona liczba nieciągłości. Modele CS nie opisują ani relacji typu wejście-wyjście w przypadku źle zdefiniowanych sygnałów ani „nie w pełni” znanych sygnałów. Nie opisują także źle zdefiniowanych ani „nie w pełni znanych” zachowań systemu. W celu opisu zachowania systemów rozmytych wprowadzimy model FS (system rozmyty).

System rozmyty rozważamy jako „czarną skrzynkę” dla której zarówno sygnały wejściowe jak i wyjściowe stanowią zbiory rozmyte (definiowane w rozmytych przestrzeniach sygnałów). Z dotychczasowych rozważań wynika fakt, że każdy system CS może posiadać wersję rozmytą (przede wszystkim lingwistyczną). Wersję rozmytą systemu CS można skonstruować poprzez operacje „fuzyfikacji” (rozmycia) sygnałów wejściowych i/lub wyjściowych. W tym przypadku można zastosować po pierwsze: operacje odwzorowania stosownych sygnałów do postaci zmiennych lingwistycznych. Druga metoda to odwzorowanie systemu oryginalnego do postaci rozmytych relacji (głównie typu wejście-wyjście). W obu przypadkach system CS (system „rzeczowy”) będzie stanowił część systemu FS (systemu rozmytego). Ponadto podobnie jak w przypadku systemów typu CCS możliwość konstrukcji użytecznych modeli matematycznych w celu rozmycia systemu CS jest ograniczona wyłącznie do przypadku przestrzeni R^p i R^q . To znaczy, że rozmyte wejścia i wyjścia muszą stanowić odpowiednie podzbiory przestrzeni R^p i R^q .

Zgodnie z drugą metodą odwzorowania sygnałów wejścia i wyjścia systemu CS (postać rozmytych relacji) podstawę opisu stanowi zbiór rozmytych relacji. Będzie to zatem „system oparty na regułach” (system based on rules SBR). Najprostszą postacią reguły rozmytej przedstawia następująca reguła R :

$$R: \text{jeżeli } x \text{ jest } A \text{ wtedy } y \text{ jest } B \quad (2)$$

gdzie A i B stanowią odpowiednio podzbiory (labels) przestrzeni sygnałów wejściowych i wyjściowych. Ogólnie rzecz ujmując stanowią one rozmytą wersję zdań logicznych na temat związków pomiędzy zmiennymi x i y . Mechanizm działania systemu SBR jest następujący: w przypadku dowolnego wejścia rozmytego A' (rozmyty podzbiór przestrzeni sygnałów wejściowych) system SBR „produkuje” rozmyte wyjście B' z wykorzystaniem modułu rozmytych wnioskowań. W literaturze przedmiotu (literatura z zakresu logiki rozmytej) występują opisy zastosowań w praktyce dwóch głównych metod wnioskowań (tzw. ogólne opisy wnioskowań- general approximations to inference in fuzzy logic).

Pierwszą metodę stanowi tzw. „złożona reguła wnioskowań” (the compositional rule of inference), natomiast drugą metodę stanowi tzw. „mechanizm wnioskowań ograniczony do wartości prawdy” (mechanism of inference restricted to truth values).

Należy podkreślić fakt, że „złożona reguła wnioskowań”, jako najprostsze rozszerzenie logiki klasycznej jest obecnie najczęściej używaną metodą wnioskowań. Natomiast techniki, których podstawę stanowi druga z wymienionych metod w praktyce są używane bardzo rzadko. Pomimo tego posiadają one te zalety, że mogą być na bieżąco uaktualniane oraz istnieje możliwość wprowadzenia zależności funkcjonalnych pomiędzy poprzednikami i konkluzjami reguł. Współcześnie obie główne metody wnioskowań są wspomagane technologiami sztucznych sieci neuronowych. Przykładowo A. Blanco, Delgado M., Requena I. [2] przedstawili już w 1994 r. nową metodę wnioskowań w oparciu o kombinację logiki rozmytej i sztucznych sieci neuronowych w celu ekstrapolacji złożonych relacji pomiędzy poprzednikami i konkluzjami rozmytych reguł. Metoda ta nie wymaga wiedzy *a priori* na temat reguł. Natomiast Nafarieh A., Keller J. w 1991 roku opisali nowy „mechanizm wnioskowań ograniczony do wartości prawdy” [3].

Kolejny podsystem systemu rozmytego FS, który krótko zostanie scharakteryzowany to system rozmytych równań relacyjnych FRE (fuzzy relational equations).

W systemie FRE relacje pomiędzy zbiorami sygnałów typu wejście-wyjście są opisane z wykorzystaniem rozmytych równań relacyjnych. Wzór 3 przedstawia prosty zapis systemu rozmytych równań relacyjnych:

$$B_i = A_i \oplus R_i, \quad i = \{1, 2, \dots, I\}, \quad (3)$$

gdzie: R_i są to rozmyte relacje pomiędzy przestrzenią sygnałów wejściowych i wyjściowych systemu, natomiast operację \oplus stanowi złożenie dwóch operacji, *t-conorm/t-norm* (obie operacje są typu ciągłego). Jednakże w systemach rozmytych stosowanych w praktyce mamy do czynienia z dyskretnymi reprezentacjami zmiennych wejściowych i wyjściowych.

Proces dyskretyzacji może być przedstawiony w następujący uproszczony sposób. (opis w przestrzeni jednowymiarowej tzn. $p = q = 1$). Przypadek jednowymiarowy może być łatwo rozszerzony do przypadku ogólnego.

Niech A oznacza zbiór rozmyty scharakteryzowany przez funkcję przynależności, której podstawę stanowi przedział liczb rzeczywistych $[u_0, u_1] \subseteq \mathbb{R}$. Niech k będzie liczbą całkowitą, która oznacza, że podstawa zbioru A jest podzielona na $k-1$ przedziałów w celu otrzymania k punktów ekstremalnych:

$$s_i = u_0 + [(i - 1) (u_1 - u_0)] / (k - 1), \quad i = \{1, 2, \dots, k\}. \quad (4)$$

Z wektorem $s = (s_1, s_2, \dots, s_k)$ związany jest następujący wektor:

$$a = (a_1, a_2, \dots, a_k) = (A(s_1), \dots, A(s_k)), \quad a_i = A(s_i) \in [0, 1].$$

Łączne reprezentacje różnych zmiennych wejściowych i wyjściowych mogą być przedstawione jako wektory $(x_1, x_2, \dots, x_i, \dots, x_n)$ oraz $(y_1, y_2, \dots, y_i, \dots, y_m)$, gdzie


odpowiednio $x_p, y_j \in [0, 1]$. Wynika stąd ważny wniosek, że dowolny system FS może być opisany matematycznie jako odwzorowanie pomiędzy $[0, 1]^n$ oraz $[0, 1]^m$ [2].

Należy podkreślić fakt, że dyskretyzacja opisana powyżej nie jest jedyną możliwą. Można np. użyć tzw. α -przecięć. Wybór sposobu dyskretyzacji zależy od konkretnych zastosowań systemu rozmytego.

Podkreślimy, że dla określonych konkretnych przypadków dyskretnej reprezentacji stosowny system FS może stanowić część systemu CS (crisp systems).

W związku z powyższym nazwa system ciągły (Continuous System) powinna oznaczać systemy zarówno crisp lub fuzzy, gdzie mamy do czynienia z odwzorowaniem ciągłym zmiennych wejście-wyjście. Dopuszczalna jest w tym przypadku skończona liczba nieciągłości. Wspomniany przypadek wymaga dalszej analizy.

Należy wprowadzić nowy typ systemu rozmytego „rozmyty system aproksymacji” (FSA – fuzzy system approximator). Systemy FSA będą stanowiły część systemów CS. Są one reprezentowane przez zbiór mierzalnych relacji pomiędzy zmiennymi wejściowymi i wyjściowymi, które posiadają wartości (crisp) ściśle. Rozważany przypadek przedstawia rysunek 1.



Rys. 1. Architektura rozmytego systemu aproksymacji [2]

Jak wynika z rysunku 1 system FSA posiada moduły fuzyfikacji – rozmywania i defuzyfikacji – antyrozmywania. Ponadto relacje pomiędzy zmiennymi wejściowymi, a wyjściowymi systemu są ciągłe.

W wyniku dotychczasowych rozważań można wyróżnić bardziej ogólny typ systemu rozmytego. Nazwiemy go UA (uniwersalny aproksymator). Do systemów typu UA zaliczymy np. systemy FSA działające w oparciu o system RBS. Ogólnie rzecz ujmując zawsze istnieje możliwość konstrukcji konkretnego systemu FSA w celu aproksymacji danego systemu CS z określoną dokładnością. Szczegóły można znaleźć w literaturze [4].

Ponadto z punktu widzenia zastosowań inżynierskich ten typ systemów rozmytych można zaliczyć do systemów typu „rozmyty sterownik” (fuzzy controller – FC).

Należy podkreślić fakt bujnego rozwoju teorii oraz udanych implementacji tego typu rozmytych systemów.

W celu porównania wyróżnionych dotychczas typów systemów rozmytych i systemów sztucznych sieci neuronowych wprowadzimy system typu NN (sztuczna sieć neuronowa).

Niech system typu NN dla potrzeb niniejszych rozważań oznacza sztuczną wielowarstwową sieć neuronową z „wnioskowaniem do przodu” (feedforward), która posiada n neuronów w warstwie wejściowej oraz m neuronów w warstwie wyjściowej. Jak wynika z literatury przedmiotu [5] sieci neuronowe wielowarstwowe z „wnioskowaniem do przodu” stanowią doskonałe aproksymatory funkcji (proces uczenia poprzez algorytm wstecznej propagacji błędów).

Ogólnie rzecz ujmując topologię rozmytych sieci neuronowych FNN [Fuzzy neural networks] można opisać w następujący sposób: występują pary sygnałów typu wejście- wyjście $(x_1, \dots, x_i, \dots, x_r)$ oraz $(out_1, \dots, out_2, \dots, out_s)$ odpowiednio. Wyjścia out_j są określone poprzez operacje max-min typu: $out_j = \max[\min(x_i, w_{ij})]$, gdzie w_{ij} są to elementy macierzy wag W . Sieci tego typu tworzą odwzorowanie sygnałów wejście-wyjście typu: $[0, 1]^n$ do $[0, 1]^m$.

PORÓWNANIE SYSTEMÓW ROZMYTYCH I SIECI NEURONOWYCH

Opis relacji pomiędzy poszczególnymi typami systemów

Rysunek 2 przedstawia w formie graficznej porównanie opisanych typów systemów rozmytych i sieci neuronowych. Schemat na rysunku 2 stanowi rodzaj diagramu Venna. Występuje tutaj relacja inkluzji zbiorów (zgodnie z treścią rozważań poprzedniego punktu). Natomiast strzałki reprezentują następujące typy relacji pomiędzy modelami:

$$\text{model-1} \rightarrow \text{model-2},$$

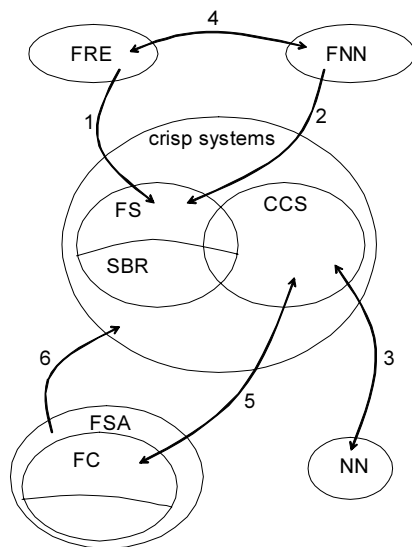
oznacza sytuację, gdzie model-1 formalnie stanowi przypadek szczególny modelu-2 lub, że każdy przykład modelu-1 może być aproksymowany poprzez zastosowanie odpowiedniego typu modelu-2:

$$\text{model-1} \leftrightarrow \text{model-2}.$$

Należy podkreślić fakt, że powyższe relacje są symetryczne tzn., że oba modele mogą być formalnie równoważne oraz co najmniej zastępowalne w zastosowaniach praktycznych.

Zgodnie z rysunkiem 2 można wyróżnić następujące typy relacji pomiędzy modelami systemów rozmytych i sieci neuronowych (numeracja relacji jest zgodna z numerami strzałek – rys. 2):

1. Relacja typu: model rozmytych równań relacyjnych \rightarrow model systemu rozmytego. Jest to relacja typu: przyczynowo – skutkowego. System rozmytych równań relacyjnych zawsze jest również systemem rozmytym. Natomiast przypadek odwrotny nie zawsze jest słuszny. Twierdzenie typu: „dowolny system rozmyty może być opisany poprzez układ stosownych równań relacyjnych” jest w ogólnym przypadku fałszywe. Istnieją bowiem systemy rozmyte dla których układ stosownych rozmytych równań relacyjnych nie posiada rozwiązań!



Rys. 2. Porównanie systemów rozmytych i sieci neuronowych [2]

Ponadto należy podkreślić fakt, że zadanie identyfikacji (uczenia) systemu rozmytego poprzez układ rozmytych równań relacyjnych typu wejścia-wyjścia nie jest wykonalne bez znajomości t -conorm/ t -norm dla stosownych par w relacji. Zadanie identyfikacji może dotyczyć tylko rozmytych systemów np. max-min, max-produkt, itp.

2. Relacja typu model rozmytych sieci neuronowych \rightarrow system rozmyty.

Przypadek analogiczny do poprzedniego. Dowolny system rozmytych sieci neuronowych jest systemem rozmytym. Odwrotna zależność jest możliwa pod warunkiem znajomości specyficznych t -norm i t -conorm stosownych par relacji. W literaturze przedmiotu można znaleźć szczegółowe badania w/w zagadnienia (identyfikacji rozmytych systemów z wykorzystaniem rozmytych sieci neuronowych). Jednakże współcześnie w literaturze przedmiotu brak jest ogólnych dowodów twierdzenia, że FNS jest uniwersalnym aproksymatorem funkcji [2].

3. Relacja typu model rozmytych równań relacyjnych \leftrightarrow rozmyte sieci neuronowe.


Ogólnie jest to relacji typu równoważności. Dla danego układu rozmytych równań relacyjnych możliwa jest jego identyfikacja z wykorzystaniem rozmytych sieci neuronowych. Relacja odwrotna również jest możliwa. Warunek konieczny w/w równoważności to znajomość t -norm/ t -conorm dla stosownych par wejść-wyjść!

4. Relacja typu model systemu ciągłego \leftrightarrow sieć neuronowa.

Dowolna funkcja może być aproksymowana przez wielowarstwową sieć neuronową z „wnioskowaniem do przodu” zgodnie z powszechną zasadą uniwersalnego aproksymatora [2]. Ponadto dowolna sieć neuronowa wielowarstwową jest systemem ciągłym. Zatem omawiana relacja jest typu równoważności.

5. Relacja typu model systemu ciągłego → rozmyty sterownik.
Każdy system FC jest systemem CS. Zgodnie z literaturą przedmiotu [2] aproksymatory systemów rozmytych są aproksymatorami uniwersalnymi. Tzn., że dla danego systemu typu CCS zawsze można znaleźć odpowiedni system FSA (z dowolną dokładnością).
6. Relacja typu model systemu FSA → model CS.
System FSA jest zgodnie z definicją (wzór 1) systemem rzeczowym (Crisp System).

Fuzja obu technologii (sztuczne sieci neuronowe, systemy rozmyte) w ramach systemów inteligencji obliczeniowej



Rys. 3. Koncepcja systemu inteligencji obliczeniowej [6]

Geneza terminu „inteligencja obliczeniowa” – rys historyczny

W ostatnich latach ogromnym zainteresowaniem cieszy się problematyka dotycząca sieci neuronowych, algorytmów genetycznych i systemów rozmytych. Zagadnienia te są częścią nauki określanej w literaturze angielskiej terminem Computational Intelligence. Wzajemne powiązania (rys. 3) między sieciami neuronowymi, algorytmami genetycznymi i systemami rozmytymi były powodem zorganizowania przez IEEE (Institute of Electrical and Electronics Engineers – USA) Światowego Kongresu „Computational Intelligence”. Na Kongres ten złożyły się 3 konferencje, które odbyły się w dniach od 26 czerwca do 2 lipca 1994 r. w Orlando na Florydzie:

- a) IEEE International Conference on Neural Networks,
- b) IEEE International Conference on Fuzzy Systems,
- c) IEEE International Conference on Evolutionary Computation.

W latach 1995–1997 każda z tych konferencji jest organizowana osobno, aby w roku 1998 powtórnie przyjąć formę Kongresu, tym razem zorganizowanego w Anchorage na Alasce. Jak wynika z rysunku 3, zagadnienia sieci neuronowych, algorytmów genetycznych i systemów rozmytych mogą być rozpatrywane niezależnie jedno od drugiego, ale niezwykle ważne są ich wzajemne powiązania. W szczególności algorytmy genetyczne można zastosować do znalezienia wag i topologii sieci neuronowej oraz bazy reguł i funkcji przynależności systemu rozmytego. Z kolei sieci neuronowe umożliwiają wyznaczenie odpowiednich parametrów właściwym algorytmom genetycznym (tzw. parametry krzyżowania i mutacji), a ponadto filozofię sieci neuronowych można wszczepić na grunt systemów rozmytych, które w ten sposób nabierają cechy systemów uczących się. Ponadto metody zbiorów rozmytych pozwalają odpowiednio dobrać zarówno wspomniane wyżej parametry algorytmów genetycznych, jak i współczynniki charakteryzujące szybkość uczenia sieci neuronowych.

Należy także podkreślić fakt, że w literaturze światowej znane są i cenione monografie autorów polskich. Dotyczą one dziedzin [6]:

- a) sieci neuronowych – książka profesora Jacka Żurady [7] oraz profesora Andrzeja Cichockiego (współautor [8]),
- b) systemów rozmytych – książka profesora Witolda Pedrycza [9],
- c) algorytmów genetycznych – książka profesora Zbigniewa Michalewicza [10].

Fuzja technologii: systemy rozmyte sztuczne sieci neuronowe – krótki przegląd badań

Sztuczne sieci neuronowe posiadają unikalne właściwości uczenia się maszynowego oraz przetwarzania informacji numerycznej. Natomiast systemy rozmyte posiadają unikalne właściwości przetwarzania informacji tzw. lingwistycznej. Nie budzi większego zdziwienia fakt, że fuzja obu technologii od dłuższego czasu stanowi przedmiot intensywnych badań w licznych ośrodkach na świecie. Wymienimy tylko najważniejsze kierunki badań:

- 1) M.M. Gupta i J. Qi rozwinęli trzy podstawowe modele tzw. rozmytego neuronu [11],
- 2) H. Ishibuchi ze współpracownikami wprowadzili miary możliwości i konieczności (possibility and necessity measures) do podstawowego algorytmu wstecznej propagacji błędów w sieci neuronowej [12] oraz architekturę sieci neuronowej, która uczy się na podstawie rozmytych reguł typu: „jeżeli-to” [13],
- 3) J.M. Keller, H. Tahani [14] oraz J.M. Keller, R.R. Yager, H. Tahani [15] badali przydatność algorytmu wstecznej propagacji błędów w systemach rozmytych,
- 4) K. Hirota, W. Pedrycz [16] oraz Y. Hayashi ze współpracownikami [17] badali zagadnienia projektowania sieci neuronowych z logiką rozmytą,
- 5) B. Kosko zbudował tzw. rozmytą pamięć asocjacyjną (ang. FAM – fuzzy associative memory) z wykorzystaniem rozmytego algorytmu Hebb’a (fuzzy Hebbian learning), współpracowała ona z rozmytą bazą reguł typu: „jeżeli-to” [18],

- 6) L.X. Wang, J.M. Mendel badali model neuro-rozmytego systemu eksperckiego [19].
- 7) Ze względu na nowe możliwości wynikające z wprowadzenia systemu rozmytego typu 2 przez J.M. Mendla nowy kierunek badań to analiza możliwości budowy systemu hybrydowego: „sieć neuronowa-system rozmyty typu 2” (pomysł autorów artykułu).

WNIOSKI

1. Zgodnie z rozważaniami tej pracy każdy system FSA jest systemem CS. W praktyce zastąpienie modelu FSA przez model CS jest możliwe poprzez wykorzystanie odpowiednich założeń teoretycznych i metod rozmywania i antyrozmywania funkcji przynależności elementu do podzbioru rozmytego.
2. Bujny rozwój systemów „inteligencji obliczeniowej” (badania teoretyczne i implementacje softwarowe) świadczy o wysokiej użyteczności fuzji obu technologii: systemów rozmytych i sztucznych sieci neuronowych.
3. Nowy kierunek badań to analiza możliwości budowy systemu hybrydowego: „sieć neuronowa-system rozmyty typu 2”.

PIŚMIENNICTWO

1. Yager R.R., Filew D.P. Podstawy modelowania i sterowania rozmytego. WNT, J. Wiley, Warszawa 1995.
2. Blanco A., Delgado M., Requena I. Relating fuzzy systems and neural networks. *Badania Operacyjne i Decyzje*, 4/1995: 5–11.
3. Nafarieh A., Keller J. A new approach to inference in approximate reasoning. *Fuzzy Sets and Systems*, 1991, 41: 17–37.
4. Castro J. Delgado M. Fuzzy systems with defuzzification are universal approximators. Submitted to *IEEE Transaction on Systems, Man and Cybernetics*, 1994.
5. Hornik K., Stinchcombe M., White H. Multilayer feedforward networks are universal approximators. *Neural networks*, 1989, 2: 359–366.
6. Rutkowska D., Piliński M., Rutkowski L. *Sieci neuronowe, algorytmy genetyczne i systemy rozmyte*. Wydawnictwo Naukowe PWN, Warszawa 1997.
7. Żurada J. *Introduction to artificial neural systems*. West Publishing Company, Boston 1992.
8. Cichocki A., Unbehauen R. *Neural networks for optimization and signal processing*. Wiley, Chichester 1993.
9. Pedrycz W. *Fuzzy control and fuzzy systems*. Wiley, New York 1993.
10. Michalewicz Z. *Genetic algorithms + data structures = evolution programs*. Springer Verlag, Berlin 1994.
11. Gupta M.M., Qi J. On fuzzy neuron models. [in:] *Fuzzy logic for the management of uncertainty*, L.A. Zadeh, J. Kacprzyk, Eds. John Wiley & Sons Inc., New York 1992.

12. Ishibuchi H., Fujioka R., Tanaka H. Possibility and necessity pattern classification using neural networks. *Fuzzy Sets and Systems*, 48, 1992: 331–340.
13. Ishibuchi H., Fujioka R., Tanaka H. Neural networks that learn from fuzzy if-then rules. *IEEE Transactions on Fuzzy Systems* 1(2), 1993: 85–97.
14. Keller J.M., Tahani H. Back-propagation neural networks for fuzzy logic. *Information Sciences* 62, 1992: 205–221.
15. Keller J.M., Yager R.R., Tahani H. Neural network implementation of fuzzy logic. *Fuzzy Sets and Systems*, 45, 1992: 1–12.
16. Hirota K., Pedrycz W. Fuzzy logic neural networks: design and computations. [in:] *Proceedings of the IJCNN'91* (2), Singapore 1991: 1588-1593.
17. Hayashi Y., Czogała E., Buckley J.J. Fuzzy neural controller. [in:] *Proceedings of the 1st International Conference on Fuzzy Systems and neural Networks*, San Diego, 1992: 197–202.
18. Kosko B. *Neural networks and fuzzy systems*. Prentice Hall, Englewood Cliffs, 1992
19. Wang L.X., Mendel J.M. Generating fuzzy rules by learning from examples. *IEEE Transactions on Systems, Man, and Cybernetics*, 22 (6), 1992: 1414–1427.

COMPARISON OF FUZZY LOGIC SYSTEMS AND ARTIFICIAL NEURAL NETWORKS

Summary

In this article we short describe fundamental mathematical model of neuro-fuzzy system treat as 'black box' known in cybernetic and various version of this fundamental model. Short we characterize some direction in the research about fusion two technology: fuzzy systems and artificial neural systems. In our article we short describe elementary notion: new technology: computational intelligence.