



**Systems Research Institute
Polish Academy of Sciences**

**Newelska 6, 01-447 Warszawa,
Poland**

Phone: (48) 22 38 10 100
Directors: (48) 22 38 10 275
Fax: (48) 22 38 10 105
E-mail: ibs@ibspan.waw.pl
Web: www.ibspan.waw.pl
Tax no.: 525 000 86 08

Prof. dr hab. inż. Janusz Kacprzyk, dr h.c. mult.

Fellow, IEEE, IET, IFSA, EurAI, SMIA
Członek rzeczywisty, Polska Akademia Nauk
Członek, Academia Europaea (Informatyka)
Członek, European Academy of Sciences and Arts
Członek zagraniczny, Bułgarska Akademia Nauk
Członek zagraniczny, Finnish Society of Sciences and Letters
Członek Zagraniczny, KVAB – Royal Flemish Academy of
Belgium for Sciences and the Arts
Członek zagraniczny, Hiszpańska Królewska Akademia Nauk
Ekonomicznych i Finansowych (RACEF)

Warszawa, 8 marca 2020 r.

Recenzja rozprawy doktorskiej mgr inż. Tomasza Rutkowskiego pt. „Explainable Artificial Intelligence Based on Neuro-Fuzzy Approach in Application to Recommender Systems”

Niniejsza recenzja została przygotowana w odpowiedzi na prośbę p. prof. Marii Elżbiety Orłowskiej, Przewodniczącej Rady Naukowej Dyscypliny Informatyki Polsko - Japońskiej Akademii Technik Komputerowych, wyrażoną w piśmie z dn. 27 lutego 2020 r.

Recenzowana rozprawa doktorska jest poświęcona ogólnie bardzo ważnemu zagadnieniu tzw. XAI (ang. explainable artificial intelligence). Ogólnie chodzi o to, że w tradycyjnych podejściach do sztucznej inteligencji, a zresztą także ogólniej, w wielu innych dziedzinach, przez wiele lat dominowało tradycyjne podejście, które można byłoby określić jako poszukiwanie podejść i metod, które pozwoliłyby na np. szybkie i efektywne wyznaczenie jakichś rozwiązań, np. optymalnych, które jakby z automatu przyjmowało się za dobre, możliwe do natychmiastowego zastosowania, ponieważ np. zastosowana metoda optymalizacji była znana z wielu dobrych wyników. Nietrudno zauważyć, że takie zadania są zadaniami prostymi w tym sensie, że koncepcja „dobrego rozwiązania” jest to dość prosta, np. maksymalizacja celu. Oczywiście, te zadania mogą być np. bardzo trudne obliczeniowo, ale to jest trudność na innym poziomie.

Od dłuższego jednak czasu punkt ciężkości w nauce przesunął się na zadania, problemy i systemy, w których człowiek jest elementem kluczowym, a więc pojęcie właściwego sformułowania zadania, a przede wszystkim właściwej oceny otrzymanych wyników, wraz z wy tłumaczeniem, skąd się one wzięły, jest zagadnieniem kluczowym, ponieważ to człowiek decyduje o ich akceptacji lub odrzuceniu.

W powyższym kontekście pojawiło się bardzo dużo nowych koncepcji, wśród których można przede wszystkim wspomnieć koncepcję „human centric systems” sformułowaną w latach dziewięćdziesiątych ubiegłego wieku przez Michaela Dertouzosa z MIT, wieloletniego dyrektora słynnego LCS (Laboratory for Computer Science), w którym powstała olbrzymia większość największych osiągnięć informatyki, od systemów wielodostępnych po arkusze kalkulacyjne, a które się potem przekształciło w CSAIL (Computer Science and Artificial Intelligence Laboratory), bez wątpienia jeden z najsilniejszych centrów badań nad sztuczną inteligencją. Potem, podobne koncepcje, które zakładały kluczową rolę człowieka, stały się bardzo popularne, np. human centered computing, human based computations, interactive evolutionary computation, humanistic intelligence, social computing, symbiotic intelligence, collaborative intelligence itp. aż do nowszych paradygmatów typu „human-in/on/out-of-the-loop”, „society-in-the-loop” i wiele innych. Nawiasem mówiąc, Autor pisze w wielu miejscach pracy w sposób jawny, że Jego praca jest w taki właśnie duchu, co jest już samo w sobie dużym plusem.

W naszym kontekście, w którym mieści się recenzowana praca doktorska, a więc w kontekście sztucznej inteligencji, dokonała się podobna jak powyżej „zmiana technologiczna” w następującym sensie. Otóż, w pierwszym okresie, niektóre metody, na przykład różne metody uczenia maszynowego, głębokie sieci neuronowe, metody rozpoznawania obrazów itp. okazały się bardzo efektywne w sensie technicznym, np. dokładności. Wydawać by się mogło, że zastosowanie tych metod będzie sprawą oczywistą, że nikt nie zakwestionuje ich możliwości. Niestety, nie sprawdziło się to w praktyce, ponieważ rozpatrywane zagadnienia są tu wyraźnie typu „human centric systems”, tzn. człowiek jest elementem kluczowym. A człowiek, by jakieś rozwiązanie zaakceptować, musi rozumieć, co ono znaczy, jak zostało otrzymane, a nawet jakie są argumenty za i przeciw przyjęciu jego. Jest to sprawa oczywista z punktu widzenia np. psychologii, ale też i formalnych podejść do argumentacji i wyjaśniania, i nic dziwnego, że dość szybko pojawiła się koncepcja i konieczność tzw. wyjaśnialnej sztucznej inteligencji, lepiej znanej jako explainable artificial intelligence (XAI).

Recenzowana praca doktorska dotyczy właśnie niektórych aspektów tak rozumianej XAI, przy czym proponuje się nowe i oryginalne rozwiązanie, czyli zastosowanie systemów neuro-rozmytych. Autor podaje jako cel pracy zaproponowanie i zaimplementowanie wyjaśnialnych algorytmów w zastosowaniu do systemów rekomendacyjnych, a jako tzw. tezy, że użycie podejścia neuronowo-rozmytego w systemach rekomendacyjnych opartych o informacje

o obiekcie daje możliwość generowania zrozumiałych wyjaśnień dla każdej rekomendacji, a jednocześnie takie podejście może być transparentne i zrozumiałe, a także dokładne. Jest to bardzo dobrze ujęte, a przede wszystkim skoncentrowanie się na systemach rekomendacyjnych jest uzasadnione ze względu na ich ważność, ale też konstruktywności podejścia w tym sensie, że ogólniejsze podejście do wyjaśnialności w AI wymagałoby innych analiz, np. uwzględnienia wspomnianych powyżej wyników formalnych podejść do argumentacji i wyjaśniania. Ponadto, zastosowanie systemu neuro-rozmytego jest ciekawe, bo jest to w końcu raczej nowe podejście w dziedzinie XAI, a doświadczenia z takimi systemami są pozytywne w innych zastosowaniach, a do tego wyniki Autora są bardzo dobre.

Omówię teraz poszczególne rozdziały, co pozwoli dobrze uzasadnić moją bardzo wysoką ocenę rozprawy.

Rozdział 1, pt. „Introduction” (zachowam tu oryginalne tytuły części, choć recenzja jest po polsku), jest ważnym rozdziałem, ponieważ Autor precyzuje w nim tematykę i zakres rozprawy, do tego podając dość dobry przegląd literatury, choć raczej dotyczący rozwiązań technicznych, nie omawiając np. aspektów związanych z różnymi podejściami do formalizacji wyjaśniania i argumentacji.

Na początku zawarte zostały uwagi na temat sztucznej inteligencji (AI) i uczenia maszynowego (ML), oczywiście z punktu widzenia konieczności zapewnienia interpretowalności, transparentności, wyjaśnialności itp. modeli, które nie mogą być tylko „czarnymi skrzynkami”. Autor używa tu określenia „algorytmy”, choć – moim zdaniem – lepszym określeniem byłoby, ze względu na skomplikowanie zadania, mówienie o modelach, ale nie ma to wielkiego znaczenia. Zresztą, Autor potem w wielu miejscach pisze o modelach.

Następnie podaje się dobry przegląd bardziej znanych opracowań, czy tzw. manifestów o XAI, np. opracowanie DARPA (Defense Advanced Research Projects Agency), które odegrało dużą rolę dla rozpropagowania ważności tej tematyki dla nauki i praktyki. Wśród wielu aspektów AI, które tam się omawia, jak np. interpretowalność, zrozumiałość, odpowiedzialność, transparentność, etyka, bezpieczeństwo, przyczynowość, możliwość symulacji itp. są oczywiście aspekty, które są rozpatrywane w pracy, czyli głównie zrozumiałość, transparentność, interpretowalność itp. Na pewno bierze się też pod uwagę, może nie w sposób jawny, możliwości symulacji, natomiast postulowane w raporcie DARPA istnienie relacji przyczynowo – skutkowej (a nie tylko relacyjnej) może być dość ryzykowne, na pewno mogłoby być kwestionowane przez filozofów czy specjalistów nauk systemowych, którzy są bardzo ostrożni z zakładaniem, czy nawet postulowaniem, istnienia zależności przyczynowo - skutkowych. Oczywiście, w większości przypadków użycie takich określeń np. w kontekście XAI jest to rozumiane nieformalnie.

W tym kontekście może warto wspomnieć o tym, że takie podejście do ogólnie rozumianej budowy modeli zrozumiałych dla człowieka nie jest niczym nowym, także w uczeniu maszynowym. Trzeba tu wspomnieć o „polskim śladzie”, że jeden z ojców uczenia

maszynowego, chyba najbardziej znany polski informatyk, Prof. Ryszard Michalski, który zmarł ok. 10 lat temu, a wyjechał z Polski w 1970 r. (z Instytutu Automatyki PAN, teraz Instytutu Badań Systemowych PAN), sformułował w 1982 r. tzw. postulat zrozumiałości (ang. postulate of comprehensibility), który brzmiał następująco: "... The results of computer induction should be symbolic descriptions of given entities, semantically and structurally similar to those a human expert might produce observing the same entities. Components of these descriptions should be comprehensible as single 'chunks' of information, directly interpretable in natural language, and should relate quantitative and qualitative concepts in an integrated fashion ...". Oczywiście, niektóre słowa są inne niż obecnie używane, ale sens jest taki sam. Warto też wspomnieć, że bardzo znani specjaliści w dziedzinie uczenia maszynowego, Craven i Shavlik w pracy z 1995 r. pisali: "...the main reasons for the importance of comprehensiveness of machine learning algorithms: (1) To be confident in the performance and usefulness of the algorithms, and hence to be willing to use them, the users have to understand how the result is obtained and what it says..", Oczywiście, jest to całkowicie zgodne z ideą XAI. Michalski, a także inni czołowi specjaliści z tej dziedziny, wskazuje też na wielką rolę języka naturalnego, co potem zostało rozwinięte np. w postaci tzw. podsumowań lingwistycznych, zwłaszcza generowanych metodami NLG (natural language generation) zarówno w pracach Yagera, Kacprzyka i Zadożnego, jak Ehuda Reitera, a które znalazły liczne zastosowania biznesowe, np. generuje się komercyjnie miliony podsumowań lingwistycznych danych giełdowych, pogodowych itp. Jeśli spojrzeć na język naturalny jako na „jedyną w pełni naturalny sposób artykulacji i komunikacji człowieka”, to widać siłę tych modeli lingwistycznych właśnie w kontekście wyjaśnialności. Zresztą, pewne elementy tych podejść do zrozumiałości stosuje także Autor, o czym wspomnę dalej. To wszystko świadczy o ważności tematyki pracy.

W dalszej części rozdziału podaje się krótki, ale bardzo dobry przegląd podstawowych aspektów systemów rekomendacyjnych, a zwłaszcza sprawy konfliktu między dokładnością działania a interpretowalnością oraz wyjaśnialnością. Ciekawe i celne są uwagi na temat stosowania podejść opartych na logice rozmytej, Ponadto, uwagi o ratingu i predykcji są ważne dla pracy.

Rozdział kończą uwagi o interpretowalności modeli uczenia maszynowego, a zwłaszcza uwagi o metodach niezależnych od modelu i zależnych od modelu są ważne. Autor dobrze uzasadnia, że dla pracy ważniejsze są metody zależne od modelu. W szczególności, dobre jest uzasadnienie użycia modeli regułowych, które są w naturalny sposób interpretowalne. Następnie wskazuje się na trudność w automatycznej generacji reguł ze zbioru danych, tak aby nie stracić na dokładności.

W końcowej części rozdziału podano krótki spis treści ze wskazaniem istoty zagadnień rozpatrywanych w poszczególnych rozdziałach.

Ogólnie biorąc, moja ocena Rozdziału 1 jest bardzo wysoka, ponieważ Autor wykazał się zarówno wiedzą dziedzinową i erudycją, jak też bardzo dobrze wskazał na podstawowe

wyzwania, które skłoniły Go do zajęcia się tematyką rozprawy, a także na najbardziej obiecujące podejścia i modele, które potem zastosował.

Rozdział 2, pt. „Neuro-Fuzzy Approach in Recommender Systems” jest poświęcony, przede wszystkim, przedstawieniu głównej idei nowego systemu rekomendacyjnego zaproponowanego w pracy.

Jak wspomniałem, jako nową architekturę zaproponowanego systemu rekomendacyjnego zaproponowano system neuro-rozmyty, w którym wnioskowanie jest oparte na regułach typu IF-THEN. Takie systemy mają lepsze zdolności uczenia, a także są oczywiście interpretowalne, jako systemy regułowe.

Pierwszym problemem, który Autor rozwiązuje, jest oczywiście zamiana danych wejściowych i wyników, które w systemach rekomendacyjnych mogą być zarówno numeryczne jak logiczne, kategoriowe, nominalne itp., natomiast w systemach neuro-rozmytych muszą być numeryczne (liczby rzeczywiste). Autor stosuje tu ciekawą metodę kodowania, którą dokładniej omawia a dalszej części pracy.

Jeśli chodzi o reguły, to Autor zakłada ich dość podstawową postać, co jest wystarczające dla rozpatrywanego zastosowania. Przyjmuje słusznie gaussowskie postaci funkcji przynależności i podaje uwagi na temat sposobów identyfikacji ich parametrów.

Ciekawe są uwagi na temat interpretowalności i wyjaśnialności przyjętych w pracy systemów neuro-rozmytych. Nie ma problemu z interpretowalnością, bo są reguły. Zakłada się przy tym, że reguły są znane i mogą być generowane z danych. Jednocześnie zakłada się, że reguły są semantycznie zrozumiałe, co jest założeniem oczywistym, na co zresztą zwracał już uwagę Michalski.

Rozpatruje się następnie generację reguł z danych, stosując metodę pochodzącą od Wanga i Mendla. Jest to metoda często stosowana w przypadku reguł typu Mamdaniego i dająca dobre wyniki, polegająca na granulacji zbiorów danych wejściowych i wyjściowych poprzez przedziały wartości. Autor przedstawia też zbliżoną metodę, dla reguł z klasy Takagiego, Sugeno i Kanga, działającą na podobnej zasadzie, którą się w pracy nazywa metodą Nozakiego, Ishibushiego i Tanaki. Te metody, które odgrywają kluczową rolę w implementacji podejścia z pracy, są dobrze przedstawione. Ponadto, ciekawe są uwagi na temat redukcji liczby generowanych reguł poprzez przypisywanie im ważności. Cenne jest też wyjaśnienie dotyczące użycia reguł uproszczonych, które zachowują się wystarczająco dobrze przy aproksymacji funkcji nieliniowych.

W dalszej części rozdziału Autor wskazuje na dalszy niezbędny krok do zastosowania wspomnianych reguł w systemach rekomendacyjnych, a mianowicie proponuje metodę kodowania (zamieniania na wartości rzeczywiste) danych nominalnych.

Rozdział 3, pt. „ Novel Explainable Recommenders Based on Neuro-Fuzzy Systems” zawiera przedstawienie trzech typów systemów rekomendacyjnych, zwanych w pracy "Recommender A", "Recommender B" i "Recommender C", które stanowią oryginalny wkład Autora.

Ogólnie biorąc, dla systemu rekomendacyjnego Recommender A, do generacji reguł systemu typu Takagiego, Sugeno i Kanga z danych stosuje się metody Wanga i Mendla oraz Nozakiego, Ishibushiego i Tanaki, a do optymalizacji stosuje się metaheurystykę typu „szarego wilka (ang. grey wolf)”, testując wyniki na zbiorze MovieLens 10M, używając 6 systemów rekomendacyjnych oznaczonych w pracy jako WM-T, NIT-T, NIT-S, WM-T+S, NIT-T+S, NIT-S+S, co wskazuje na zastosowane metody generacji z danych.

Oczywiście, krokiem wstępnym jest kodowanie atrybutów, czyli zamiana ich na wartości rzeczywiste. Ogólnie, dla każdego użytkownika i atrybutu filmu podawanego ocenie tworzy się listę unikalnych wartości nominalnych. Wartości wprowadzone do systemu rekomendującego są obliczane jako wartości średnie preferencji wszystkich wartości pojawiających się dla danego atrybutu filmu. Ten zaproponowany sposób jest intuicyjnie uzasadniony i działa bardzo dobrze.

Jeśli chodzi o architekturę, to system neuro-rozmyty w Recommender A jest systemem typu Mamdaniego z singletonami we wniosku, co odpowiada systemowi Takagiego, Sugeno i Kanga zerowego rzędu w terminologii pracy.

Jeśli chodzi o uzyskane wyniki, to testowano je na zbiorze filmów MovieLens 10M, zakładając 3 i 5 zbiorów rozmytych (wartości lingwistycznych). Ma to uzasadnienie, chociażby dla uproszczenia, ale może warto byłoby dodać uwagę, że pierwsza z tych wartości jest mniejsza od szeroko znanej z psychologii i powszechnie używanej wartości tzw. magicznej liczby Millera 7 ± 2 , które określa, ile różnych wartości, np. lingwistycznych, człowiek może w sposób znaczący rozróżnić. Liczba 5 jest tu zgodna ze znanymi wynikami testów psychologicznych, natomiast liczba 3 może wzbudzić pewne wątpliwości, czy jest to wystarczające do dobrego rozróżnienia.

Zastosowanie gaussowskich funkcji przynależności jest zgodne z tym, co się zwykle robi, a metaheurystyka szarego wilka działa tu bardzo dobrze. Ocena za pomocą RSME (root mean square error) jest dobrym wyborem.

Wyniki symulacji są obiecujące i pokazują, że zaproponowane podejście jest ciekawe i korzystne numerycznie, przy czym poprzez zmiany parametrów można zmieniać dokładność. Uzyskano bardzo dokładną rekomendację typu „tak/nie” i wysoką dokładność klasyfikacji filmów.

W zaproponowanym w pracy systemie rekomendacyjnym Recommender B użyto systemu Mamdaniego z zastosowaniem metody Wanga i Mendla do generacji reguł z danych.

Wprowadzono dodatkowo wagi reguł. Zastosowane też redukcję liczby reguł. Do optymalizacji wag użyto metaheurystyki typu strategii ewolucyjnej. Kodowanie cech o wartościach nominalnych zrealizowano, jak poprzednio, w Recommender A.

Do oceny systemu rekomendacyjnego Recommender B zastosowano interesujące rozwiązanie, a mianowicie użyto jako kryteriów: kryterium informacyjnego Akaike (AIC – Akaike Information Criterion), ostatecznego błędu predykcji (FPE - Final Prediction Error) i kryterium Schwartza. Są to często stosowane kryteria dające ogólnie dobre wyniki.

Wyniki numeryczne w pełni potwierdzają efektywność systemu rekomendacyjnego Recommender B dla zbioru danych MovieLens 10M. Ponadto, lepsze wyniki otrzymano w przypadku dodatkowych wag poddawanych optymalizacji.

W trzecim, zaproponowanym typie systemu rekomendacyjnego, Recommender C, zaproponowano system regułowy typu Mamdaniego z nowym sposobem kodowania i wagami. Transformacji nominalnych wartości atrybutów na numeryczne jest dokonywana z użyciem współczynników korelacji Pearsona między wektorami i ratingami, które są atrybutem decyzyjnym. W przeciwieństwie do normy trójkątnej typu iloczynu algebraicznego, stosowanej w przypadku systemów rekomendacyjnych Recommender A i Recommender B, tu stosuje się parametryczną normę trójkątną Dombiego przy obliczeniach stopnia aktywacji reguły. Do optymalizacji parametrów stosuje się metaheurystykę typu strategii ewolucyjnych. Wyniki są dobre, lepsze niż dla prostszych typów systemów rekomendacyjnych.

Może warto tu nadmienić, że zastosowanie bardziej złożonych norm trójkątnych oraz innych operacji agregacji, może oczywiście polepszyć otrzymane wyniki. W przypadku Recommender A i Recommender B zastosowano normę trójkątną typu iloczynu algebraicznego. Zauważmy, że operacja iloczynu algebraicznego może być zrozumiała (w sensie jej działania) dla człowieka, chociażby dlatego, że jedną z przyjętych reprezentacji funkcji użyteczności w teorii decyzji, ekonomii itd. jest iloczynowa funkcja użyteczności. Można więc domniemywać, że człowiek jakby rozumie działanie iloczynu algebraicznego jako operacji agregacji, bo jego wybory można tak opisywać, poprzez funkcję użyteczności. Niestety, działanie normy trójkątnej Dombiego nie jest jasne w tym sensie, choć może dawać świetne wyniki! Jest to ważny aspekt w kontekście systemów typu „human centric”, w których człowiek ogrywa kluczową rolę.

Podsumowując, w Rozdziale 3 zaproponowano 3 rodzaje neuro-rozmytych systemów rekomendujących, w kolejności wzrastającej komplikacji, zarówno typu Mamdaniego jak Takagiego, Sugeno i Kanga. Zaproponowano metody transformacji na wartości numeryczne, optymalizacji parametrów, redukcji zbioru reguł itp. Przeprowadzono też w szerokiej skali testy numeryczne. Uzyskano bardzo zachęcając wyniki.

Zaznaczyć warto, że systemy rekomendacyjne zaproponowane w tym rozdziale można utożsamić z wieloklasowymi klasyfikatorami, np. dwuklasowymi.

Moja ocena tego rozdziału jest bardzo pozytywna. Autor zaproponował oryginalne podejście, a także rozwiązał – stosując prawidłowe i efektywne metody – wiele zagadnień bardziej technicznych niezbędnych do implementacji tych nowych systemów rekomendacyjnych.

Rozdział 4, p.t. „Explainable Recommender for One-Class Classification Problem”, zawiera bardzo ciekawą propozycję nowego wyjaśnialnego systemu rekomendacyjnego do klasyfikacji jednoklasowej. Jest to częsty przypadek w praktyce. Najlepszym przykładem jest tu głosowanie typu aprobującego (ang. approval voting) lub dezaprobującego (ang. disapproval voting), w którym (dla ustalenia uwagi przyjmijmy, że rozpatrujemy przypadek głosowania aprobującego) głosujący agent podaje te opcje, które aprobuje, natomiast nie wiadomo, czy niepodane opcje dezaprobuje czy się wstrzymuje od głosu. Inny przykład tego typu, rozpatrywany w pracy, dotyczy decyzji inwestycyjnych, gdy inwestor podaje (np. w sprawozdaniu), jakie walory ocenił pozytywnie i kupił, natomiast nie wiemy, dlaczego nie kupił innych walorów. Nietrudno zauważyć, że takie zadania mają wielkie znaczenie praktyczne, a są też wyzwaniem teoretycznym wychodząc niejako poza kanon przykładów pozytywnych i negatywnych.

W Rozdziale 4 Autor proponuje system rekomendacyjny powyższego typu, dla potrzeb właśnie doradztwa inwestycyjnego. Rozpatruje dwa przypadki, z 3 atrybutami i z ponad 20 atrybutami. Ze względu na fakt, że dane są wielowymiarowe, stosuje też odpowiednie przygotowanie danych, wzbogacenia danych o dane ze źródeł zewnętrznych, wizualizację danych i wyników itp.

Generuje się dwa typy reguł, reguły rekomendacyjne, służące do wyznaczenia rekomendacji, oraz reguły wyjaśniające, służące do generacji wyjaśnień otrzymanych rekomendacji. Reguły rekomendacyjne są oparte na punktach rozmytych reprezentujących przeszłe transakcje, a reguły wyjaśniające używają zbiorów rozmytych określonych na przedziałach rozmytych. Jest to ciekawe podejście.

Zbiory danych dla poszczególnych funduszy inwestycyjnych pozwalają wyznaczyć wzorce odpowiadające strategiom inwestycyjnym realizowanym przez te fundusze, co pozwala systemowi rekomendacyjnemu na wydanie rekomendacji dla doradców inwestycyjnych.

W pracy zawarto bardzo dokładny opis zaproponowanego systemu rekomendacyjnego, z dość szczegółowymi opisami wszystkich kolejnych kroków implementacji systemu, jak np. sposobu generacji reguł z danych, postaci zbiorów rozmytych, zbioru wartości lingwistycznych (prawidłowo przyjęto 7 ± 2 , zgodnie z „żelazną” zasadą magicznej liczby Millera), statystyczną analizę historii transakcji, reguły oparte na przedziałach rozmytych, agregację stopni aktywacji reguł itp.

Jeśli chodzi o powyższą agregację, to poza normami trójkątnymi, stosowano tu średnią arytmetyczną i ważoną średnią arytmetyczną. A więc, zgodnie z uwagą, którą zawarłem w recenzji, tu wyraźnie widać, że agregacja odpowiada addytywnej funkcji użyteczności, bardzo często używanej. Może warto byłoby dodać krótki komentarz, dlaczego nie użyto normy trójkątnej Dombiego.

Jeśli chodzi o inne, bardziej techniczne elementy zaproponowane w pracy do rozwiązania konkretnych zadań, to wspomnieć można też o zastosowaniu poziomów odpalenia reguł jako miary podobieństwa nowej rekomendacji do przeszłych transakcji danego użytkownika. Jest to ciekawy wybór.

Wyniki uzyskane przez zaproponowany system rekomendacyjny są bardzo ciekawe, a zostały bardzo dobrze udokumentowane, poprzez zastosowanie całej gamy środków wizualizacji i analiz numerycznych.

Z punktu widzenia architektury, zaproponowany system rekomendacyjny jest tu typu sieci systemów i składa się z kilku systemów neuro-rozmytych działających równolegle. Jest to system dynamiczny, uwzględniający przeszłość, i adaptacyjny, bo jego architektura może być zmienna, co może się odbywać poprzez tworzenie nowego systemu neuro-rozmytego dla nowego użytkownika, usuwanie innego dla użytkownika nieaktywnego itp. Ta złożoność systemu zaproponowanego w pracy daje nową jakość i zasługuje na duże uznanie.

Podsumowując, w pracy zaproponowano wiele nowych elementów dotyczących systemów rekomendacyjnych. Po pierwsze, najogólniej biorąc, zaproponowano zastosowanie systemów neuro-rozmytych do budowy wyjaśniających systemów rekomendacyjnych, co jest niewątpliwą nowością. Po drugie, zaproponowano trzy różne rodzaje (architektury) neuro-rozmytych systemów rekomendacyjnych, Recommender A, Recommender B, Recommender C, oparte zarówno na systemach regułowych typu Mamdaniego, jak Takagiego, Sugeno i Kanga. Po trzecie, zaproponowano nowy koncepcyjnie system rekomendacyjny dla klasyfikacji jednoklasowej z funkcją wyjaśniania. Wszystkie powyższe systemy zrealizowano programowo i przeprowadzono wyczerpujące testy numeryczne.

Ponadto, aby efektywnie zrealizować nowe propozycje, rozwiązano kilka problemów technicznych typu kodowania wartości nominalnych i ich transformacji na wartości rzeczywiste, przetwarzanie wstępne danych, wyznaczanie zbiorów rozmytych na podstawie histogramów, wyznaczanie parametrów w reprezentacjach zbiorów rozmytych, redukcja liczby reguł, nowe metody wizualizacji itp.

Praca spełnia, moim zdaniem, wszelkie wymagania ustawowe i zwyczajowo przyjęte w polskim środowisku naukowym stawiane rozprawom doktorskim i wnoszę o jej przyjęcie oraz dopuszczenie do publicznej obrony. Ponadto, ze względu na powyższe nowe i oryginalne elementy zawarte w pracy, a także rzadko spotykaną kompletność implementacji i testowania zaproponowanych modeli, proponuję rozpatrzenie wyróżnienia pracy, zgodnie z zasadami przyjętymi w PJATK.



J. Kacprzyk