

Prof. dr hab. Urszula Boryczka  
Instytut Informatyki  
Wydział Nauk Ścisłych i Technicznych  
Uniwersytet Śląski w Katowicach

Katowice, 12.06.22

### Recenzja rozprawy doktorskiej

Tytuł rozprawy: **REAL-VALUED ANTICIPATORY CLASSIFIER SYSTEM**

Autor rozprawy: **mgr Norbert Kozłowski**

Przewód doktorski: w dziedzinie nauk technicznych, w dyscyplinie *Informatyka*  
Promotor rozprawy: **prof. dr hab. Olgierd Unold**

Recenzja wykonana na podstawie zlecenia Rady Naukowej Dyscypliny Informatyka Techniczna i Telekomunikacja Politechniki Wrocławskiej, pismo z 4 maja 2022r.

#### 1. Obszar problemowy pracy

Rozprawa została napisana w języku angielskim i składa się z sześciu rozdziałów, bibliografii oraz wykazu skrótów. Rozdział pierwszy stanowi wstęp do tematyki rozprawy. Autor przedstawił motywacje do podjęcia badań dotyczących systemów klasyfikatorów antycypacyjnych.

W badaniach naukowych zaczęto wspominać o antycypacjach już ponad sto lat temu. Na przykład William James stwierdził, że: "Antycypacyjny obraz zmysłowych konsekwencji ruchu oraz (w pewnych sytuacjach) przecucie, że konsekwencje te staną się rzeczywiste, jest jedynym faktem, stanem psychicznym, kiedy introspekcja pozwala nam rozpoznać (traktowana jako zapowiedź) nasze akty dobrowolne". (W. James, 1890). Kilku innych psychologów i filozofów w tym czasie miało podobne spostrzeżenia. Przewidywanie rzeczywistego efektu działania/akcji podejmowanej przez agenta uczącego się wydaje się determinować wybór i wykonanie odpowiedniej akcji w określonej strategii zachowania.

Mimo pewnych zastrzeżeń, hipoteza ta była dalej badana na początku XX wieku. Psycholog E. Tolman twierdził, że popularny w tamtym czasie behawioryzm *bodziec-reakcja* był zbyt ograniczony, ponieważ wybierał odruch warunkowy jako jednostkę nawyku (E. Tolman, 1932). Główne przeciwieństwo prawa skutku umiejscowił w manifestacji utajonego uczenia się, co pojawiło się w kilku przeprowadzonych eksperymentach. We wszystkich tych eksperymentach zwierzęciu prezentowano początkowo alternatywne sytuacje w warunkach braku nagrody lub, co najwyżej, stosunkowo niewielkiej nagrody za jedną odpowiedź/reakcję w porównaniu z innymi. W rezultacie nabywa ono (zwierzę) „pozornie” jedynie bardzo niewielką skłonność do wybierania tego, co później okaże się prawidłową drogą (E. Tolman, 1932)

Tolman zaproponował własną teorię motywacji i wprowadził do psychologii uczenia się pojęcie popędu. Wprowadził również koncepcję behawioryzmu celowościowego, według której powinna ona zajmować się badaniem całego działania totalnego organizmu z punktu widzenia celu, do którego dąży jednostka. W przeciwieństwie do J. B. Watsona, uważał, że związki pomiędzy bodźcem i reakcją nie są jednoznaczne. To znaczy, że przyczyną jednej reakcji mogą być różne bodźce i odwrotnie: jeden bodziec może wywoływać różne reakcje. Wprowadził pojęcie uczenia utajonego. To punkt widzenia psychologów czy behawiorystów.

WPLYNĘŁO

17-06-2022

RSN-117/193/2022

Kanoniczny, uczący się system klasyfikujący będący przedmiotem recenzowanej rozprawy (ang. Learning Classifier System, *LCS*) zaproponowany przez J. Hollanda (1980, 1986), jest w istocie wersją systemu produkcji tj. systemu obliczeniowego, używającego reguł w postaci *jeżeli..., to ...*, umożliwiających reagowanie agentów uczących się na zmiany środowiska. Na system klasyfikujący można tu patrzeć jak na model uczenia się ze wzmocnieniem.

System klasyfikatorów antycypacyjnych zaś (ang. Anticipatory Classifier System – *ACS*) zaproponowany w 1997 roku przez W. Stolzmana, łączy ramy systemu klasyfikatorów uczących się z kognitywną teorią uczenia się antycypacyjnej kontroli zachowania. W rezultacie powstaje system ewolucyjny, który buduje kompletny i uogólniony model przewidywania środowiska. Techniki uczenia się przez wzmocnienie są stosowane do tworzenia polityki zachowań, reprezentowanej w modelu takiego systemu.

Po przedstawieniu kontekstu i celów takiego systemu, Autor wyjaśnia szczegółowo wszystkie zachodzące w nim procesy. Ponadto analizuje niedostatek nadmiernej specjalizacji w procesie uczenia się antycypacyjnego (*ALP* – zaproponowany przez Hoffmanna), który jest głównym mechanizmem uczenia się w systemie *ACS*. W związku z tym wprowadzono do *ACS* algorytm genetyczny (*GA*), którego zadaniem jest generalizacja nadmiernie wyspecjalizowanych klasyfikatorów. Okazuje się, że możliwe jest stworzenie symbiozy między mechanizmem ukierunkowanej specjalizacji a mechanizmem generalizacji genetycznej, dzięki czemu powstaje mechanizm uczenia się, który rozwija kompletny, dokładny i zwarty opis postrzeganego środowiska.

Jak można zauważyć, definicja systemu klasyfikującego, jako regułowego systemu adaptującego się do otoczenia, w którym działa, jest bardzo pojemna. Dlatego też funkcjonujących dzisiaj modeli, różniących się czasami drobnymi (choć należy dodać najczęściej istotnymi) szczegółami, jest już kilkadziesiąt.

*ACS2* Butza (kolejny z trzech analizowanych w pracy systemów klasyfikujących, 2000) z pewnością nie jest nowym, rewolucyjnym podejściem, ale raczej konsekwencją i długo oczekiwaną koniecznością w obszarach badań nad przewidywaniem, zachowaniami adaptacyjnymi, uczeniem wzmacniającym i systemami uczących się klasyfikatorów.

Podsumowując tę część recenzji stwierdzam, że Autor podjął ważny, aktualny a zarazem trudny problem naukowy. Przeprowadził analizę istniejących podejść, zaproponował autorskie rozwiązania, przedstawił ich zastosowania w wybranych projektach naukowych oraz zweryfikował ich skuteczność, co pozwoliło ocenić i zweryfikować opracowane rozwiązania.

## **2. Kompozycja i zawartość pracy**

Praca doktorska napisana w języku angielskim składa się z 5 rozdziałów oraz ze wstępu i zakończenia. Stanowi to 130 stron maszynopisu. We wstępie Autor zawarł hipotezę oraz etapy prac badawczych prowadzące do osiągnięcia zamierzonego celu. Przedstawiona została struktura pracy i Autor wprowadził poprzez wybrane zagadnienia *LCS* do tematyki systemów klasyfikatorów antycypacyjnych.

Rozdział 2 („Wybrane zagadnienia *LCS*”) wprowadza w wybrane zagadnienia systemów klasyfikatorów uczących się z wejściami rzeczywistoliczbowymi, reprezentującymi środowisko. Omówiono podejście Michigan i Pittsburgh i scharakteryzowano reprezentatywne *LCS* (*CS-1*, *ZCS*, *XCS* oraz najnowsze *LCS*). Opisano też fazę eksperymentalną, włączając w to również weryfikację osiągniętych

rezultatów wraz ze wskaźnikami efektywności działania dla różnych analizowanych problemów.

Rozdział 3 jest propozycją 2 procedur uruchomionych w *ACS2* i *ALCS* a związanych z wejściem rzeczywistoliczbowym. Jego tytuł brzmi po przetłumaczeniu „Przyswojenie wiedzy poprzez zwiększenie przestrzeni wejściowej”. Skupiono się na reprezentacji interwałowej (przedziałowej) i różnych ich formach realizacji. Podstawowym pytaniem, które zadaje sobie Autor pracy jest, czy *rvACS* algorytm tworzy właściwy model wewnętrzny środowiska i czy umiejętnie z niego korzysta? Przeanalizowane zostały pewne modyfikacje *rvACS*. Analizowano również proces dyskretyzacji wejść rzeczywistoliczbowych w *ALCS*.

Rozdział 4 pt. „Zrównoważona eksploracja” omawia problem autonomicznego algorytmu uczącego się z samoadaptacją. Autor odpowiada na ważne pytanie dotyczące balansowania między eksploracją a eksploatacją przestrzeni stanów i skupia się na mechanizmach planowania akcji. Tu również zawarto proces porównania eksperymentalnego 4 strategii eksploracji proponowanych przez Butza. Głównym problemem było czy ww mechanizmy znacząco przyspieszą proces uczenia się agenta. Jednocześnie warto zauważyć, że podjęto się badania wpływu rozmiaru populacji systemu klasyfikatorów na tę efektywność.

Rozdział 5 pt. „Optymalizacja podziału nagród w długim łańcuchu akcji” dotyczy omówienia problemu kryterium średniej nagrody wprowadzonej przez Putermana a zaimplementowanego w systemie *XCS* przez Tharakunnela i Goldberga. Omówiono algorytm z opóźnionymi nagrodami RL i kwestię dyskutowania nagród odległych w czasie. Problemem staje się stosowanie pewnych kryteriów przypisywania nagród w środowiskach dyskretnych, wielokrokowych, gdzie ważna jest eksploatacja wiedzy. Jak zwykle rozdział kończy się fazą eksperymentalną i zajmuje się jej omówieniem.

W podsumowaniu Autor przedstawia swoje konkluzje i wyraża nadzieję na kontynuację prac w zakresie *ALCS*. Struktura pracy jest w moim odczuciu dość nietypowa, bowiem po każdej części tzw. teoretycznej, Autor od razu przechodzi do części eksperymentalnej i testuje swoje tezy, czy pytania badawcze. To skłania czytelnika do ciągłego wysiłku pamięciowego, bowiem tak rozproszony obszar badań (przy tym dość rozległy) musi być wciąż pod czujną kontrolą.

### **3. Opinia o rozprawie i oryginalność osiągnięć**

Rozprawa doktorska koncentruje się na wykorzystaniu antycypacyjnych uczących się systemów klasyfikujących *ACS* (ang. Anticipatory Classifier Systems) w problemach, w których stan opisywany jest (reprezentowany jest) z wykorzystaniem liczb rzeczywistych. Wiele podobnych badań zostało dotychczas wykonanych dla innych uczących się systemów klasyfikujących *LCS* (ang. Learning Classifier Systems), jednak żaden z nich nie posiadał możliwości budowania wewnętrznej reprezentacji środowiska z użyciem mechanizmu antycypacji.

Uczące się systemy klasyfikujące reprezentują wewnętrznie wiedzę tworząc zbiór klasyfikatorów. Jako klasyfikator określa się logiczną regułę określającą stan środowiska, w którym jest ona stosowana, (z możliwością uogólnienia) oraz zestaw metadanych (np. miara dostosowania, czy przewidywana nagroda). Klasyfikatory tworzone są w procesie iteracyjnym, uwzględniającym dwa główne elementy: - odkrywczy (generowanie nowych klasyfikatorów i ulepszanie już istniejących) oraz uczący (dostosowywanie metadanych). Zasadniczą kwestią odróżniającą systemy *LCS* od uczenia ze wzmocnieniem jest możliwość generalizacji reguł, gdzie określona część przestrzeni rozwiązań może być zawarta w jednej regule. W pracy rozważana

była odmiana antycypacyjna, w której główną różnicą jest rozszerzona struktura reguły klasyfikatora, określająca przewidywany stan środowiska po wykonaniu określonej akcji oraz adaptacja elementów składowych definiujących system, z uwzględnieniem teorii psychologicznych, dotyczących uczenia się.

Problem badawczy przedstawiony w pracy dotyczył przypadku, w którym system opisuje swój aktualny stan (otrzymując od otoczenia informację) za pomocą liczb rzeczywistych. Istniejące algorytmy *LCS* zostały gruntownie przebadane w tej kwestii, jednak rodzina *ACS* wciąż testowana była na podstawie dyskretnej formy reprezentacji (często przedstawiana jako zbiór wektorów binarnych).

Celem pracy było naturalnie **oryginalne rozwiązanie problemu badawczego** poprzez pewne przypuszczenie, jakoby istnieje kilka możliwych realizacji integracji rzeczywistoliczbowego wejścia w systemach *ACS* z użyciem wybranych problemów testowych (środowisk). Opierając się na tych sugestjach, sformułowana została przez Doktoranta hipoteza badawcza, która zakładała, co następuje:

„Antycypacyjne uczące się systemy klasyfikujące są w stanie poprawnie zbudować wewnętrzny model rzeczywistoliczbowego środowiska.”

Hipoteza została udowodniona poprzez osiągnięcie kilku celów pośrednich, stanowiących szkielet pracy doktorskiej.

Przed wszystkim Autor uznał, że zaproponowanie modyfikacji wybranych systemów *ACS* umożliwiających obsługę danych wejściowych o wartościach rzeczywistych jest kluczowe dla osiągnięcia zamierzonego celu. Cel został osiągnięty i zweryfikowany na dwa różne sposoby:

- Użycie dozwolonych przedziałów wartości jako podstawowej jednostki służącej do reprezentacji danych - zaproponowano autorską wersję systemu *rvACS* (ang. real-valued Anticipatory Classifier System) - rozdział **3.1**,
- Dyskretyzację danych wejściowych - zaproponowano modyfikacje wybranych algorytmów *ACS* - rozdział **3.2**.

Pierwsze z zaproponowanych podejść zostało zainspirowane dotychczasowymi osiągnięciami uzyskanymi dla innych systemów uczących się, polegającymi na reprezentowaniu reguł za pomocą przedziałów. Nowy algorytm *rvACS*, w których granice są reprezentowane jako dyskretne wartości, osiąga zadowalające wyniki, jednak złożoność zarówno poziomu utworzonego rozwiązania, jak i interakcji jego wewnętrznych elementów składowych była zbyt wysoka. Spowodowane było to w głównej mierze fundamentalnymi regułami odpowiadającymi za proces generowania nowych klasyfikatorów, które nie były tworzone z uwzględnieniem takiej formy reprezentacji, oraz rozszerzoną strukturą klasyfikatora, wymagającą osobnego procesowania, zarówno dla części warunkowej, jak i antycypacyjnej (decyzyjnej).

Drugi sposób podejścia do omawianego problemu pozwalał na uwolnienie się od konieczności modyfikacji wpływających na sposób działania trzech testowanych antycypacyjnych systemów (*ACS*, *ACS2*, *YACS*). Dyskretyzacja sygnału wyjściowego środowiska, zanim zostanie on przetworzony przez algorytmy uczące, umożliwiło zachowanie ich charakterystyk działania. Zastosowanie zewnętrznego dyskretyzatora, ułatwiło także możliwość jego zmiany (aktualizacji) lub

dostosowania, bez konieczności ingerencji w główny kod systemu. Dodatkowo, otrzymane rezultaty badań były bardziej obiecujące i interpretowalne, niż w przypadku zastosowania reprezentacji z wykorzystaniem przedziałów wartości - *rvACS*.

Oba sposoby zostały przetestowane m.in. dla wybranych problemów jednokrokowych (*rMPX*, *Checkerboard*) oraz wielokrokowych (*Corridor*, *Grid*). Porównanie odbywało się na zasadzie ewaluacji efektywności algorytmu (częstotliwość udzielania najlepszej odpowiedzi), jak i na zasadzie analizy wewnętrznej reprezentacji wiedzy (liczba, natura i jakość utworzonych reguł). W przypadku dyskretyzacji, metryki zostały także porównane z podstawowym algorytmem uczenia ze wzmocnieniem nie posiadającym możliwości generalizacji - *Dyna-Q*.

Kolejnym celem pośrednim było zaproponowanie środowisk testowych i metryk do oszacowania wydajności systemów *ACS*. Charakterystyka działania algorytmów antycypujących (oraz zaproponowanych modyfikacji) została poddana szczegółowej analizie wykorzystując sześć testowych problemów przedstawionych w rozdziale 2.5: (*Corridor*, *Grid*, *rMPX*, *Checkerboard*, *Cart Pole*, *Finite State World*), opisujących aktualny stan za pomocą wartości rzeczywistoliczbowych. Część z nich była już wykorzystywana wcześniej i omówiona w literaturze przedmiotu podczas badań uczących się systemów klasyfikujących.

Dodatkowo, po raz pierwszy w historii, znany problem uczenia ze wzmocnieniem, polegający na utrzymywaniu równowagi pręta umieszczonego na wózku (*Cart Pole*) został przetestowany przez systemy uczące (w tym przypadku przez wersję antycypacyjną systemu uczącego się). Otrzymane wyniki były szczególnie interesujące ze względu na wydajność i minimalistyczną postać otrzymanego rozwiązania.

Działania poszczególnych algorytmów zostały oceniane przez pięć metryk (rozdział 2.3) badających różne aspekty działania. Uwagę zwrócono na jakość generowanego rozwiązania (generalizacja, szybkość budowania wiedzy), jego rozmiar (liczba tworzonych klasyfikatorów) oraz praktyczne wykorzystanie wiedzy w badanym środowisku (wydajność działania w fazie eksploatacji, relatywny czas działania).

Następnym etapem prowadzonych prac było zaproponowanie optymalizacji działania systemów *ACS* w kontekście przetwarzania wejścia rzeczywistoliczbowego. Wstępne badania prowadzone w tym kierunku wskazały na dwa obszary dające możliwość optymalizacji działania systemów antycypacyjnych w przypadku interakcji ze środowiskami o reprezentacji rzeczywistoliczbowej.

Pierwszy obszar wskazał, że zastosowana reprezentacja wejścia znacząco zwiększyła dostęp do przestrzeni stanów, co miało znaczący wpływ na działanie każdego badanego algorytmu. Przetestowane zostały cztery strategie, skupiające się na inteligentnym przeszukiwaniu przestrzeni rozwiązań optymalizując tworzenie wewnętrznego modelu środowiska – rozdział 4.

Zaproponowane zostało także autorskie rozwiązanie, polegające na optymistycznym generowaniu nowych reguł, wzorowanym na algorytmach typu *bandit - OIQ* (ang. *Optimistic Initial Quality*). Badania zostały przeprowadzone dla środowisk *rMPX*, *Corridor*, *Grid* oraz *Cart Pole*. Wyniki potwierdziły, że zastosowanie wybranych metod inteligentnego wyboru akcji przyczyniło się do

poprawy jakości procesu uczenia się (np. zaprezentowano je na wykresach 4.4, 4.5 rozdziału 4).

Drugie zagadnienie stanowiące pewne ograniczenie, dotyczyło środowisk wielokrokowych, wymagających wykonania wielu akcji w celu osiągnięcia stanu końcowego i zostało to przedstawione w rozdziale 5. Potencjalnym problemem związanym z podstawową wersją elementu składowego systemu uczenia maszynowego RL, jest zbieżność parametru określającego oczekiwaną nagrodę klasyfikatora w przypadku środowisk wymagających wykonania znaczącej liczby akcji w celu otrzymania końcowej nagrody. Zaproponowano wymianę ww elementu składowego, odpowiedzialnego za przypisywanie nagrody na wersję uśrednioną, tym samym przedstawiono autorską wersję systemu - AACS2 (ang. Average Anticipatory Classifier System 2), wykazującą wzrost wydajności w testowanych problemach (Corridor, Finite State World). System został zaimplementowany w dwóch wariantach różniących się sposobem aktualizacji średniej nagrody występującej w problemie oraz zestawiony z bazowymi algorytmami ACS2, Q-Learning oraz R-Learning w kontekście tempa zbieżności do optymalnego rozwiązania (wykresy 5.1, 5.3) oraz zestawienia podziału nagród dla poszczególnych par „stan-akcja” (wykresy 5.2, 5.4).

Czwartym celem pośrednim była eksperymentalna analiza przeprowadzonych badań. W celu zrozumienia natury przeprowadzanych eksperymentów, w każdym przypadku uwzględniony został aspekt czasowy, ilustrujący sposób ewolucji wybranych metryk w całym procesie uczenia. Zostały wykonane dodatkowo porównania pomiędzy poszczególnymi algorytmami bądź wersjami środowisk z wykorzystaniem technik modelowania probabilistycznego - analizę Bayesowską. Zaproponowana metodologia uwzględniała modelowanie wynikowych metryk stosując rozkład t-Studenta, opierając się na wynikach 50 niezależnych powtórzeń badań. Na podstawie wygenerowanego rozkładu prawdopodobieństwa porównane zostały ze sobą określone metryki statystyczne. Wybrane podejście do porównywania danych jest bardziej przejrzyste i niesie ze sobą więcej informacji od tradycyjnego podejścia do testowania hipotez opartego na wyliczeniu wartości  $p$ .

Eksperymenty przeprowadzono w pełni powtarzalny sposób stosując koncepcję interaktywnych notatników oraz udostępniając w całości kod wymagany do potencjalnej ponownej weryfikacji.


Ostatnim punktem pracy było stworzenie ogólnodostępnej biblioteki programistycznej. Efektem tego etapu pracy była ogólnodostępna biblioteka programistyczna w języku Python, implementująca szereg systemów uczących (np. ACS, ACS2, YACS, MACS, X-NCS). Znaczącym osiągnięciem było pełne odtworzenie dotychczasowych wyników badań wraz z dodaniem możliwości obsługi liczb rzeczywistych. Biblioteka zaprojektowana została zgodnie z aktualnymi trendami, umożliwiając szybką integrację i porównanie się z innymi rodzinami algorytmów. Biblioteka posiada pełne wsparcie dla dostępnej puli problemów (środowisk) uczenia ze wzmocnieniem (OpenAi Gym), znacząco skracając czas potrzebny na wdrożenie oraz przetestowanie działania algorytmów antycypacyjnych.

Podsumowując tę część recenzji uważam, iż praca jest interesująca i pokazuje dużą wiedzę Doktoranta. Widoczne jest naukowe podejście do realizowanego zadania.

Rozprawa przedstawia dużą wartość merytoryczną, w tym naukową oraz implementacyjną związaną z przedstawionymi zastosowaniami.

Przede wszystkim należy podkreślić, iż problem badawczy podejmowany w rozprawie jest bardzo ważny i złożony. Podsumowując uważam, że wykonana w ramach doktoratu praca stanowi istotny wkład w rozwój metod dotyczących systemów klasyfikatorów adaptacyjnych. Rozprawa prezentuje wysoki poziom naukowy i w pełni zasługuje na ocenę pozytywną.

Praca napisana jest starannie, bez większych pomyłek językowych. Nie zostały jednak zawarte w rozprawie przykłady i ilustracje (jak pokazano na rysunku poniżej) pozwalające lepiej zobrazować (i wyjaśnić), a przy okazji zróżnicować działanie proponowanych metod i algorytmów.



Ponadto należy dodać, iż Pan Norbert Kozłowski jest autorem lub współautorem 5 wartościowych, punktowanych za minimum 100 pkt. artykułów a swoje osiągnięcia naukowe były prezentowane na 6 międzynarodowych konferencjach naukowych. Jego indeks Hirscha wynosi 3 (w Research Gate).

#### 4. Uwagi i problemy do dyskusji

Praca doktorska przedstawiona do recenzji jest opracowaniem bardzo szerokiej i zróżnicowanej tematyki, obejmującej nie tylko problem uczących się systemów klasyfikatorów, ale również kwestie związane z eksploracją danych i systemami podejmowania decyzji. Poprzez swą strukturę oddzielnie stawianych po każdym wstępie nowych pytań i celów badawczych, kilka kwestii jest wciąż dla mnie wartych przedyskutowania. Pozwolę je sobie poniżej przedstawić w kolejności zależnej od stopnia trudności:

- Podział przestrzeni rozwiązań na „Regiony” (1, 2, 3 i 4) nie jest do końca oczywisty. Na podstawie Rys. 3.6 nie jesteśmy w stanie wysnuć jakiegokolwiek wnioski. Potrzebny jest dodatkowy komentarz.
- W przypadku dyskretyzacji wartości określonych atrybutów, przyjmuje się założenie, że jest to przedział określonej długości, gdzie znamy początek i koniec tego przedziału. Jak radzić sobie z podejściem Wilsona w XCS/XCSI bez znajomości min i max tego przedziału?
- Przy tak różnorodnym środowisku badawczym trudno jest przyjąć jednoznaczne wartości parametrów badanego systemu klasyfikatorów. Czy między nimi istnieje jakaś zależność hierarchiczna? Czy kolejność doboru wartości parametrów ma tu również znaczenie?



- ACS2 był testowany z i bez algorytmu genetycznego. Czy rozmiary populacji w tych dwu przypadkach rzeczywiście nie miały wpływu na jakość i czas uczenia?
- W przypadku *Fuzzy-XCS* (autor Casillas, potem Kondziela 2021): jakie funkcje przynależności stosowano w tym przypadku, skoro 75% sytuacji zostało przewidzianych? Jakie funkcje przynależności z tych predefiniowanych są najefektywniejsze i sprawdzają się generalnie w analizowanych problemach? Jakie metody defuzyfikacji można zaproponować, czy tylko metoda centrum grawitacji jest tu efektywna?
- Jak powinna brzmieć po polsku nazwa badanego systemu: system klasyfikatorów antycypacyjnych, czy też antycypacyjny system klasyfikatorów? Czy do tego powinniśmy dodawać jeszcze: uczący? System klasyfikatorów czy system klasyfikujący? Antycypacja to przewidywanie, czy nie lepiej uprościć tę nazwę?

## 5. Wnioski

Pan Norbert Kozłowski przedstawił rozprawę doktorską stanowiącą oryginalne rozwiązanie problemu naukowego z zakresu wykorzystania wiedzy dziedzinowej w systemach klasyfikatorów antycypacyjnych. Opracowane metody zostały zastosowane i zweryfikowane dla różnych problemów rzeczywistych.

Autor wykazał się dużą wiedzą w zakresie tematyki rozprawy, umiejętnością pracy naukowej oraz znajomością metod badawczych. Osiągnięte wyniki świadczą o bardzo dobrym przygotowaniu Autora do pracy naukowej.

Recenzowana praca spełnia wszystkie wymagania stawiane rozprawom doktorskim przez ustawę o stopniach naukowych i tytule naukowym oraz o stopniach i tytule w zakresie sztuki. Zatem wnoszę, by mgr Norbert Kozłowski został dopuszczony do publicznej obrony.

*Anna Borjeska*