Prof. dr hab. inż. **Jerzy Stefanowski,**
Instytut Informatyki Politechnika Poznańska

Poznań, 12.04. 2022

**Recenzja rozprawy doktorskiej mgra Grzegorza Góry pt. „Combining instance-based learning and rule-based methods for imbalanced data"**

Niniejsza recenzja jest sporządzona w odpowiedzi na pismo Przewodniczącego Rady Naukowej Dyscyplin Matematyka i Informatyka Uniwersytetu Warszawskiego (Wydział Matematyki i Informatyki. UW) prof. dr hab. Andrzeja Tarleckiego z lutego br. zawierającego prośbę o zrecenzowanie rozprawy doktorskiej mgra Grzegorza Góry.

Rozprawa jest zatytułowana „Combining instance-based learning and rule-based methods for imbalanced data" – z polskim odpowiednikiem tytułu „Łączenie metody bazującej na instancjach z metodą indukcji reguł dla danych niezbalansowanych" i została przygotowania pod kierunkiem profesora dr hab. Andrzeja Skowrona oraz złożona w grudniu 2021 roku. Maszynopis rozprawy jest napisany w języku angielskim, liczy 258 stron. Jest on podzielony na 6 rozdziałów, 3 załączniki. Zawiera także obszerny spis cytowań-literaturę, krótkie streszczenia w dwóch językach, zestawienia symboli, skrótów oraz indeks tematyczny - całość w sensie formatowanie tekstu wygląda na na złożoną w narzędziach LaTeX. Ponadto w przesłanych materiałach znajdowały się kilkunasto stronicowe autoreferaty rozprawy napisane zarówno w języku angielskim, jak i w języku polskim.

## 1. Uwagi ogólne nt. problematyki rozprawy i jej celów

Tematyka rozprawy, jak piszę sam Autor, dotyczy uczenia maszynowego (ang. machine learning - tłumaczone także systemy uczące się) i dokładniej wybranych **metod nadzorowanego uczenia klasyfikatorów.** Jest to jedno z najpopularniejszych i najintensywniej badanych zadań w tej problematyce. Dotychczas zaproponowano bardzo dużo algorytmów uczenia klasyfikatorów wykorzystujących różnorodne podstawy metodyczne, reprezentacje danych i samych form klasyfikatorów. Jak można łatwo zauważyć uczenie maszynowe, w szczególności sieci neuronowe są obecnie dominującą pod-dziedziną sztucznej inteligencji zarówno z uwagi na badania naukowe, jak i liczne zastosowania praktyczne.

Sam doktorant interesuje się **indukcją reguł klasyfikacyjnych** oraz podejść minimalno - odległościowych typu **klasyfikator k- najbliższego sąsiada**. Można stwierdzić, że indukcja reguł cieszyła się większym zainteresowaniem w poprzednim wieku, lecz sama reprezentacja reguł jest ciągle rozważana w różnych obszarach sztucznej inteligencji ze względu na jej potencjalną zrozumiałość dla człowieka. Historycznie (np. w pracach prof. Ryszarda Michalskiego lub Zdzisława Pawlaka) uznawano ją za bardziej naturalna i czytelniejszą dla człowieka niż inne reprezentacje wiedzy wykorzystywane w sztucznej inteligencji. Podkreśla się także jej modularność i przydatność do analizy pojedynczych wzorców regułowych przez eksperta. Ich forma prezentacji wykorzystywana jest do reprezentacji innych skuteczniejszych klasyfikatorów, w szczególności sieci neuronowych. Jest to obecnie widoczne w podejściach wyjaśniania działania modeli uczenia maszynowego typu „nieprzejrzyste czarne skrzynki".

Pisząc powyższe uwagi, wyrażam swoją opinię, że nadal warto się interesować indukcją reguł, zwłaszcza w przypadku rozważania złożonych danych i niestandardowych wersji zadania klasyfikacji nadzorowanej - co występuje w recenzowanej rozprawie. Doktorant zainteresował się danymi o **niezbalansowanej liczebności klas** (ang. class imbalanced data), w których jedna z klas (mniejszościowa) zawiera dużo mniej przykładów niż pozostałe klasy a jednocześnie prawidłowe rozpoznanie przykładów z tej klasy jest ważne w rozważanym problemie. Taka sytuacja występuje w wielu zastosowaniach praktycznych, np. w medycynie, bankowości, diagnostyce technicznej, filtrowaniu spamu i jest ciągle otwartym problem naukowym, gdyż większość algorytmów uczących się jest ukierunkowana na poprawne rozpoznawanie klas większościowych i ma trudności z klasyfikacją przykładów mniejszościowych. Dotyczy to także algorytmów regułowych, które są szczególnie czułe na ten tym trudności rozkładu danych. Przynajmniej od początku tego wieku

prowadzono wiele badań nad rozwojem nowych metod poprawy zdolności predykcyjnych klasyfikatorów uczonych z niezbalansowanych danych. Pomimo zaproponowania wielu metod, często bardzo heurystycznych, nie ma ciągle zbyt wielu specjalizowanych algorytmów indukcji reguł. W zasadzie najskuteczniejszym dotychczasowym rozwiązaniem jest algorytm BRACID zaproponowany około 10 lat temu przez Krystynę Napierałę i piszącego tą recenzje, więc ta problematyka badawcza nie jest bardzo „wyeksploatowana".

W swoich już dość dawnych badaniach mgr Grzegorz Góra zajmował się problematyką **indukcji reguł z przykładów w kontekście tzw. „leniwego" uczenia się z przykładów - w tym połączenia obu paradygmatów dla tworzenia dynamicznie lokalnego zbioru reguł dla nowo pojawiającego się obiektu.** Poprzednio wspólnie z panem Arkadiuszem Wojną wprowadził nowatorski algorytm RIONA budujący specjalne reguły na podstawie otoczenia klasyfikowanego przykładu w zbiorze uczącym. Było to dość skuteczne rozwiązanie, lecz dla danych zbalansowanych i miar oceny trafności właściwych dla tych danych, dlatego nie może być to zastosowane w przypadku danych niezbalansowanych.

Na podstawie tych doświadczeń oraz dokładnej analizy ograniczeń standardowych algorytmów indukcji reguł doktorant zaproponował **następujący cel swojej rozprawy**: Opracowanie algorytmu wykorzystującego połączenie uczenia się pojedynczych instancji (przykładów jak w podejściach k-NN) oraz reguł charakteryzującego się wysoką trafnością predykcji dla danych niezbalansowanych.

Takie sformułowanie celu badań jest oryginalne i nie było dotychczas rozważane w literaturze, zwłaszcza jeśli jego realizacja jest zaproponowana jako uogólnienie poprzednich doświadczeń z algorytmem RIONA i stworzenia jakościowo **nowej propozycji algorytmu o nazwie RIONIDA**.

Podsumowując ten fragment mojej oceny, uważam, że powyższa problematyka i cel rozprawy są przed wszystkim oryginalne, interesujące poznawczo i są warte prowadzenie badań oraz realizacji doktoratu. Mogą się one także przyczynić do stworzenia narzędzi programistycznych, które będą użyteczne praktyczne w zadaniach eksploracji trudnych, niezbalansowanych danych.

## 2. Ocena formy i struktury rozprawy

Recenzowana rozprawa jest napisana bardzo poprawnie w języku angielskim. Znalazłem tylko kilka drobnych literówek. Notacja matematyczna jest używana spójnie.

Konstrukcja kolejnych rozdziałów jest poprawna i typowa dla tego rodzaju rozpraw. Krótkie wprowadzenie, gdzie autor sensownie przedstawia motywacje i tzw. problem naukowy, oraz braki obecnych rozwiązań (podrozdział 1.1), w rezultacie formułuje cel badań i samej rozprawy (patrz podrozdział 1.2). Należy dodać, że doktorant zdecydował się zajmować binarną wersją danych niezbalansowanych (jedna klasa mniejszościowa vs. większościową). Istotne jest przedstawienie drogi rozwoju algorytmów od RIONA do RONIDA - w tym kontekście wyjaśnienie różnic oraz ograniczeń / wad pierwszego w stosunku do przetwarzania niezbalansowanych danych. Ważne jest także wyjaśnienie wcześniejszej współpracy doktoranta z panem Arkadiuszem Wojną nad tworzeniem pierwszego rozwiązania. W podrozdziale 1.3 autor dobrze dyskutuje powiązane trudności analizy danych niezbalansowanych oraz różne aspekty metodologiczne prowadzonych badań z wyjaśnieniem, które z powiązanych zagadnień ostatecznie zostaną pominięte.

Rozdział drugi jest w miarę typowym zestawieniem podstawowych pojęć, metod z uczenia klasyfikatorów, ich miar oceny oraz dość zwartym opisem metod specjalizowanych dla poprawy klasyfikacji niezbalansowanych danych. Doktorant wykazał się znajomością literatury w zakresie prowadzonych badań oraz dobrego ich podsumowania oraz przedstawienia najważniejszych elementów (tzw. ang. related works), które są później mu potrzebne do konstruowania własnych algorytmów (np. pseudometryk B, wyborów CSVDM do poszukiwania bliskich sąsiadów, heurystyk rozstrzygania zbioru konfliktowego reguł w trakcie klasyfikowania nowych obiektów). Szczególnie autor wskazuje inspiracje do tworzenia swojego algorytmu RIONA z wcześniejszej propozycji J.Bazana algorytmu SimRules i LAZY.

Kolejne rozdziały są najważniejsze dla oceny oryginalności propozycji metod. Autor rozpoczął opis od prezentacji wcześniejszego algorytmu RIONA a następnie dokładniejszego opisu najważniejszej propozycji rozprawy, czyli algorytmu RIONIDA. Ze względu na to, że RIONIDA „dziedziczy"ogólnie pewien schemat generowania sąsiedztwa z wcześniejszej RIONA, logiczne jest przedstawienie dostatecznie dokładnie algorytmu RIONA w rozdziale 3tym. W szczególność czytelnie i dobrze jest wyjaśnione generowanie reguł w sposób „leniwy" w k-otoczeniu klasyfikowanego obiektu, idea zliczenia tzw. wsparć na podstawie niesprzecznych reguł oraz bardzo ważny pomysł na dobieranie eksperymentalne rozmiaru k-sąsiedztwa. W tle opisu tych najważniejszych elementów dla rozprawy mgr G.Góra przedstawił także kilka powiązanych zagadnień, oraz twierdzeń o związku z generowanymi pełnymi zbiorami reguł. Ważne dla dalszych propozycji jest także wprowadzenie i przedyskutowanie modyfikacji RIONA do odmiany algorytmu k-NN ze strojeniem optymalnego sąsiedztwa k, tj. ONN.

Rozdział 4ty jest jeszcze bardziej oryginalny w zakresie wprowadzenia głównego osiągnięcia rozprawy, czyli algorytmu RIONIDA. Autor właściwie przedstawia niemożność zastosowania RIONA dla danych o niezbalansowanych liczebnościach klas i wskazuje kierunki uogólnień i nowych propozycji. Najważniejszą częścią rozdziału jest opis nowego sposobu definiowania reguł wraz z możliwością sprowadzenia klasyfikacji do pojedynczych instancji (sg-rules) oraz uogólnień tworzenia sąsiedztwa z balansowaniem oceny miar sensitivity oraz specificity (w tle można odnaleźć rozważania bardziej teoretyczne). Ciekawie przedstawiono zmianę strategii klasyfikacyjnej i rozstrzygania konfliktów użycia reguł z wykorzystaniem kalibrowanego oszacowania prawdopodobieństwa p. Dość obszernie omawia się różne aspekty poszukiwania najlepszych wartości parametrów algorytmu RIONIDA. Rozdział kończy oszacowanie funkcji złożoności obliczeniowej. Ten rozdział jest dobrze napisany.

Rozdział 5ty jest bardzo rozbudowanym opisem szerokich badań eksperymentalnych. Autor bardzo poprawnie, w sposób dość typowy do obecnych artykułów, przedstawił cele eksperymentów, niezwykle dokładnie opisał wybrane zbiory danych i przede wszystkim dobrze uzasadnił ich wybór (co niestety nie jest częste w wielu pracach) - tutaj zauważam podążanie śladem moich wcześniejszych prac, gdzie wspólnie z dr Krystyną Napierałą zidentyfikowaliśmy i lansujemy te akurat dane z uwagi na ich zróżnicowana charakterystykę (patrz doktorat Pani K.Napierały oraz artykuł pt. „Types of minority class examples and their influence on learning classifiers from imbalanced data"). Wybór porównywanych ze sobą algorytmów jest także w dużym stopniu następstwem Naszych wcześniejszych badań opisanych w powyższym artykule. Trochę dyskusyjne jest dla mnie rozważanie aż tylu konfiguracji parametrów dla wielu porównywanych algorytmów z filtrami, a przede wszystkim strategie późniejszego wyboru najlepszych wyników (zwłaszcza dyskusyjna jest strategia max - do czego powrócę w uwagach dyskusyjno-krytycznych). Niestety muszą tutaj wyrazić trochę krytyki - ta część rozdziału jest ewidentnie przegadana - np. opis trzech metod wyboru wyników w rozdziale 5.2.6 jest rozwleczony niepotrzebnie na aż 10 dziesięciu stronach (str 153-162) - podczas, gdy zasadniczy pomysł można było wyjaśnić na jednej stronie. Pozostała część rozdziała zawiera bardzo obszerne i szczegółowe zestawienie wyników eksperymentalnych. Najważniejsze są wyniki eksperymentów porównawczych z innymi algorytmami (rozdział 5.3; str. 163-183), gdyż one wyraźnie pokazują przewagę propozycji autora, co jest też wsparte wykonanie popularnych testów statystycznych (rangowego Friedmana z analizą post-hoc). W dalszej części rozdziału słusznie zawarto także analizę eksperymentalna wpływu poszczególnych elementów algorytmu RIONIDA, średnie wartości strojonych parametrów k, p oraz s); czasów uczenia i testowania. Wszystkie te wyniki z rozdziału 5.4 są ważne dla lepszego zrozumienia działania zaproponowanego algorytmu. Dalsze eksperymenty z rozdziału 5.5. są dla mnie trochę nadmiarowe w zakresie szczegółowości prezentacji - uważam, że wiele z nich można było przesunąć do załączników. Lecz jak odczytuje dobrze intencje autora, chciał on najprawdopodobniej pokazać, że przewaga RIONIDA nad wcześniejszą RIONA nie zależy od dodatkowego używania filtrów „re-sampling" w przetwarzaniu wstępnym lub podstawowe dobrze wystrojone parametry (k,p,s) są wystarczające i nie warto rozważać wielu innych ew. rozszerzeń. Odniosłem niestety wrażanie, że autor niektóre interpretacje wyników nadmiernie rozbudowuje.

Wiele z wyników eksperymentów przedstawionych w tabelach „sama się tłumaczy" i nie potrzebuje aż tak rozbudowanych komentarzy. Całość rozdziału jest ważna dla pozytywnej weryfikacji propozycji algorytmu.

Szósty rozdział końcowy jest bardzo dobrze, krótko i przekonująco napisany. Zgadzam się z wieloma poglądami wyrażonymi przez autora.

Podsumowując struktura rozprawy jest poprawna. Praca jest napisana dobrym językiem i dostatecznie czytelna dla zrozumienia pomysłów i dokonań autora. Subiektywnie wolałbym jednak większą zwięzłość niektórych opisów i interpretacji oraz uważam że objętośc rozprawy mogłaby być jednak trochę mniejsza.

**3. Osiągnięcia badawcze doktoranta**

W mojej opinii głównym i oryginalnym osiągnięciem rozprawy jest przedstawienie algorytmu RIONIDA, specjalizowanego do jak najskuteczniejszej klasyfikacji tabelarycznych danych uczących o niezbalansowanych liczebnościach binarnych klas. Doktorant projektując ten algorytm twórczo skorzystał z analizy ograniczeń poprzednich algorytmów indukcji reguł oraz właściwie wybrał niektóre dobre rozwiązania z wcześniej zaproponowanego algorytmu RIONA. Należy dostrzec takie rozwiązania jak:

1. Wybór reprezentacji lokalnie generowanych reguł oraz pojedynczych przykładów, co wraz z tworzeniem ich „leniwie" w sąsiedztwie klasyfikowanego przykładu może pozwolić na lepsze uwzględnienie bardzo złożonych i trudnych rozkładów przykładów z klasy mniejszościowej. O ile postulat stosowania podwójnej reprezentacji reguły i pojedynczych przykłady oraz zwracanie specjalnej uwagi na lokalne sąsiedztwo przykładów były już rozważane (np. w algorytmie BRACID), to jednak wykorzystanie go poprzez twórcze uogólnienie schematu „leniwego" generowania wsparcia klasyfikacji w odpowiednio dostrojonym sąsiedztwie nowo nadchodzącego obiektu jest zupełnie nowym rozwiązaniem.
2. Zaproponowanie zupełnie nowej strategii klasyfikacyjnej dostosowanej do specyfiki niezbalansowania klas (gdzie przy poprzednio stosowanych algorytmach, w tym RIONA, reguły wskazujące klasę większościową miały wyższe wsparcie i przegłosowywały poprawne wskazanie na klasę mniejszościową). Autor zaproponował wprowadzenie specjalnego progu p dla oszacowania częstości wsparcia dla klasy mniejszościowej. Jak pokazuje w rozdziale 4tyn jego wartość powinna być mniejsza niż 0,5 co pozwala na ukierunkowanie rozstrzygania wskazań między klasami silniej w stronę klasy mniejszościowej. W rozważaniach teoretycznych autor pokazuje związek wartości tego progu z prawdopodobieństwiem a'priori klasy mniejszościowej przy pewnych założeniach. Patrząc na sposób estymacji tego parametru mam skojarzanie z operacjami kalibracji progu wyjścia klasyfikatora „scoringowego" (lub probabilistycznego w wersji uczenia się z kosztami) - co jest jedną z metod dla rozwiązania zadań binarnych niezbalansowanych klas.
3. Zmiana reprezentacji generowanych reguł (w stosunku do poprzedniej z RIONA) - w tym wprowadzenie parametru s, które pozwalają na przełączenie klasyfikacji na pojedyncze instancje (s = -0,1) lub modyfikacje poziomu sprzeczności pokrycia reguł. Są one dostrajane w fazie pre-uczenia. To w mojej opinii, i patrząc na wyniki eksperymentalne, jest jednym ze źródeł sukcesu nowej propozycji algorytmu.
4. Stosowanie strategii dostrajania wartości trzech kluczowych (powyższych) elementów i ich parametrów: rozmiaru sąsiedztwa k, progu decyzji wsparć p oraz stopnia s reguł, w sposób eksperymentalny dla konkretnego zbioru danych. Doktorant wykorzystuje mechanizm podobny do techniki wewnętrznej oceny „leaving-one-out" na zbiorze uczącym, lecz jest to rozwiązane efektywniej obliczeniowo (w podobny sposób jak programowanie dynamiczne). Decyzja o dostrajaniu wszystkich tych kluczowych parametrów (zwłaszcza k oraz s) pozwala na zwiększenie „elastyczności" proponowanego algorytmu oraz dostosowania się do trudności konkretnego zbioru. Takiej możliwości nie mają inne konkurencyjne algorytmy omawianie przez autora i wykorzystane w eksperymentach obliczeniowych.

5. W strojeniu powyższych parametrów podjęto sensowną decyzje przejścia na miary oceny zdolności predykcyjnej dla danych niezbalansowanych, to jest G-mean albo F-miarę.

W rozprawie można też znaleźć wiele dodatkowych wyników teoretycznych, interpretacji działania lub strojenia parametrów oraz „tricków" mających przyspieszyć działanie algorytmu.

Mgr Grzegorz Góra przedstawił wyniki *bardzo obszernych eksperymentów obliczeniowych*, w których porównał swoją propozycje z wieloma alternatywnymi algorytmami indukcji reguł. Wybrano odpowiednie i zróżnicowane (co do trudności) benchmarkowe binarne niezbalansowane zbiory danych oraz inne algorytmy (poza RIONA - naturalny wybór do porównania inspiracji; wybrano najbardziej znany dotychczas algorytm BRACID oraz inne podstawowe algorytmy). Dodatkowo dla algorytmów nieprzeznaczonych dla danych niezbalansowanych autor wybrał jeden z tzw. podstawowych sposobów zmiany rozkładu przykładów uczących (SMOTE+ENN), co może poprawić ich trafność. Ocena porównawcza dla miar G-mean oraz F1-score wsparta wykonaniem testów statystycznych *jednoznacznie wskazuje* na to, że RIONIDA osiągnęła *najlepsze wyniki*. W mojej interpretacji jest to w dużym stopniu efektem wyboru rozwiązań omawianych powyżej, w szczególności możliwości dynamicznego dostrajania trzech najważniejszych parametrów k, p oraz s pod konkretny zbiór danych, czego nie ma żaden z porównywanych algorytmów, także BRACID - dlatego formułuje hipotezę, że to zdecydowało o sukcesie propozycji autora.

Ponadto dodatkowe eksperymenty wskazują, że koszty obliczeniowe działania algorytmu RIONIDA są akceptowalne i porównywalne z innymi algorytmami zarówno w fazie uczenia się, jak i testowania przykładów - co jest dodatkowym pozytywnym argumentem na rzecz tego algorytmu.

Za potrzebne i wartościowe uważam dodatkowe eksperymenty, gdzie mgr G.Góra przekonuje, że przewaga RIONIDA nad wcześniejszą RIONA nie zależy od dodatkowego używania filtrów „re-sampling" w przetwarzaniu wstępnym. Ponadto autor przeprowadził analizę wystrojenia parametrów (k,p,s) - średnie wartości z podziałów oceny krzyżowej dla każdego zbioru danych. Ta część rozszerza wiedzę o charakterystyce działania elementów składowych algorytmu RIONIDA, wpływu różnych parametrów - i jest w pełni zgodna z tzw. dobrymi praktykami oceny propozycji nowych algorytmów w uczeniu klasyfikatorów.

Implementacja wcześniejszej wersji algorytmu RIONA w Javie została już poprzednio udostępniona publicznie (open-source) jako część biblioteki rselib, a ciekawsza implementacji RIONIDA jest dopiero planowana do udostępnienia. Zalecałbym szersze przygotowanie zgodnie z obecnymi postulatem tzw. Reproducibility Machine Learning (patrz np. listy kontrolne J.Pineau).

Wyniki rozprawy były częściowo publikowane, zwłaszcza z pierwszej fazy badań, to jest algorytmu RIONA zarówno na konferencjach, jak i w czasopiśmie *Fundamenta Informaticae*. Za najcenniejszą uważam wspólną prace z A.Wojną na bardzo wymagającej konferencji *European Conference of Machinę Learning* (ECML). Sama propozycja propozycja algorytmu RIONIDA nie była jeszcze publikowana, co wynika ze zmiany drogi życiowej ojca G.Góry i innymi jego obowiązkami (co niewątpliwie wyjaśnia długą przerwę w prowadzeniu badań). Mam nadzieję, że te ciekawe wyniki zostaną jednak gdzieś opublikowane. W sensie interpretacji wymogów ustawowych liczba opisanych publikacji może być uznana za wystarczającą - zwłaszcza że sam maszynopis doktoratu jest wartościowy.

Podsumowując uważam, że omawiane osiągnięcia pozwalają uznać, że założony cel pracy doktorskiej został w pełni osiągnięty.

**4. Uwagi krytyczne i dyskusyjne**

Pomimo interesującej propozycji algorytmu RIONIDA i zauważenia wielu jego zalet formułuję drobne wątpliwości oraz otwarte pytania lub uwagi do dalszych badań lub ewentualnej publikacji wyników rozprawy. Niektóre mają też charakter dyskusji polemicznej z autorem oraz zachęty do dalszej dyskusji podczas samej obrony doktoratu.

1. Decyzja rozważania aż trzech różnych sposobów wyboru wyników (def., opt., max) eksperymentów porównawczych wielu metod (tzw. AF-learner) jest w mojej opinii dyskusyjna, gdyż doktorant w dwóch ostatnich wybiera najlepsze wyniki z wielokrotnych uruchomień.

Rozumiem intencje pokazanie tzw. najsilniejszego przeciwnika, lecz dla wersji opt. i przede wszystkim max. jest to dokonane na podstawie dostępu do przykładów testowych, czyli w mamy dostrojenie się pod pełne dane. Jak sam doktorant zauważa w maszynopisie - w literaturze uważa się za wystarczające wybranie jednego zestawu parametrów. Jeśliby iść, trochę na siłę, drogą strojenia parametrów, to wydaje mi się, że lepsze byłoby strojenie poprzez wewnętrzną „walidacje" wyłącznie w zbiorze uczącym. Ponadto wybrany sposób „zaciera" różnice pomiędzy dalszymi porównywanymi algorytmami, podczas gdy wcześniejsza literatura wskazywała na ich różnice.

2. W przypadku raportowania wyników eksperymentów autor wykonał pełne testy statystyczne wobec miary G-mean. Natomiast dla miary F podano tylko wynik rangowy testu Friedmana bez post-hoc analizy - moim zdaniem powinno się je także spójnie podać, choć i tak widać zwycięstwo algorytmu RIONIDA. W tym kontekście chciałbym skomentować, że obecnie w przypadku oceny klasyfikatorów dla danych niezbalansowanych większą wagę i tak przypisuje się mierze G-mean a F-miara jest krytykowana przez cześć badaczy (także przez piszącego tą recenzję). Oprócz większej trudności interpretacji, jej zachowanie dla niektórych układów wartości w macierzy pomyłek oraz zmiany wartości F1-score przy niektórych niskich wartościach prawdopodobieństwa a'priori klasy mniejszościowej są niepożądane. Można spojrzeć do pracy D. Powers, What the F-measure Doesn't Measure: Features, Flaws, Fallacies And Fixes, a przede wszystkim do ostatnich badań D.Brzezińskiego i in., Visual-based analysis of classification measures and their properties for class imbalanced problems.
3. Niezwykle interesująca jest analiza dostrojenia parametrów algorytmu RIONIDA przedstawiona w rozdziale 5.4.3 (str 185). Zaskakujące dla mnie jest relatywnie wysoka wartość sąsiedztwa k dla wielu ze zbiorów danych. Spójrzmy, np. na zbiór cleveland - ma on 303 przykłady, a k jest dostrojone na 62 - co prawie 25% liczności. Podobna sytuacja występuje dla relatywnie wielu innych zbiorów, co jest trochę zaskakująco dużo jak na tzw. podejście leniwe, które powinno wykorzystywać tzw. lokalne sąsiedztwa (zwłaszcza dla klasyfikatorów k-najbliższych sąsiadów). Czy doktorant zastanawiał się nad tym i dokonał interpretacji tego zjawiska?
4. Inna ciekawe obserwacja wyników z tabeli 5.15 - to że wartość parametru s jest najcześciej bliska 0,5-0,6 oraz relatywnie wiele razy s=-0,1 (czyli klasyfikowanie z najbliższymi instancjami). Świadczy to z jednej stronach o sensowności zaproponowania tego rozwiązania (i dodatkowo wyjaśnia przewagę RIONIDA nad wcześniejszą RIONA), lecz też prowadzi mnie do pytania. W niektórych miejscach rozprawy autor pisał o „miękkim" przechodzeniu pomiędzy regułami i instancjami przy pomocy tego parametru s. Jednak w moim rozumieniu parametr ten jest strojony globalnie pod konkretny zbiór (proszę o ew. zweryfikowanie). W tym kontekście zastanawiałbym się nad dalszym rozszerzeniem RIONIDA, tak aby s było dynamiczniej dostrajane bardziej lokalnie w różnych obszarach zbioru danych i dla testowanego przykładu - co można też powiązać ze złożonością i różnorodnością rozkładu przykładów w niezbalansowanych danych (tzw. źródła trudności, dekompozycja klasy na pod-pojęcia, nakładanie się obszarów klas, itd).
5. W przypadku rozdziału 5.4.4. byłbym wdzięczny za komentarz doprecyzowujący, czy raportowane czasy uczenia RIONIDA obejmują pełne strojenie optymalnych wartości parametrów (k, p oraz s) w całym zakresie (KxPxS).
6. W kilku miejscach pracy napisano o zaletach reguł z uwagi na ich intepretowalność reguł oraz wyjaśnialności - objaśnialności systemów klasyfikacyjnych. Niestety nie zajęto się tymi aspektami w ocenie eksperymentalnej i nie przedstawiono, np., średniej liczby tworzonych reguł. Domyślam się, że ich liczba przy większych sąsiedztwach (rozmiar k) może być jednak większa niż się oczekuje dla potencjalnej interpretacji? W ogólności RIONIDA może wspierać tylko lokalne wyjaśnienie predykcji nowego obiektu, natomiast nie jest możliwe stworzenie wyjaśnienia globalnego dla całego modelu. Odnosząc się do konkurencyjnego BRACID-a taka możliwość jest realna z dodatkowym „post-processing" zbyt licznego zbioru reguł (patrz np.

praca: Increasing the interpretability of rules induced from imbalanced data by using Bayesian confirmation measures. K Napierała, i in. ECMLPKDD 2016).

7. Analizując liczenie wsparć obiektów dla strategii klasyfikacji nowych obiektów {tst} (zwłaszcza dla RIONA Algorytm 5 oraz 6) dodaje się pojedyncze przykłady uczące {trn}. Zastanawiam się w kontekście rozszerzeń, czy nie uwzględniać ich różnej wagi, tzn. niektóre przykłady {trn} mogą stworzyć reguły o większym pokryciu, a inne przykłady tworzyć bardziej specyficzne reguły.
8. Oszacowanie wartości kandydata na wartość parametru p opiera się na założeniach ogólnego losowego rozkładu prawdopodobieństwa (Tw. 4.1). Nie jest dla mnie jasne czy to będzie się przenosiło na praktyczne dużo bardziej złożone rozkłady typów obiektów (które występują w większości zbiorów danych badanych później w eksperymentach). Na przykład część autorów już wskazało, że w danych eksperymentalnych nie zachodzi zjawisko opisane jako „procent klasy mniejszościowej w obszarze brzegu między klasami, jest taki sam jak w całym zbiorze" (str. 114), lecz oba stopnie niezbalansowania różnią się.

## 5. Konkluzja końcowa

Podsumowując uważam, że przedstawiona rozprawa charakteryzuje się dobrym poziomem merytorycznym i zawiera interesujące rezultaty badawcze, w tym oryginalnie sformułowany algorytm RIONIDA. Bardzo obszerna ocena eksperymentalna jednoznacznie pokazała na jego skuteczność w porównaniu do innych konkurencyjnych rozwiązań oraz dostarczyła wiedzy na temat działania jego elementów składowych. Niewątpliwie przedstawiona propozycja tego algorytmu wnosi wkład do obecnych badań na budową efektywnych klasyfikatorów wykorzystujących połączenie tzw. „leniwego" uczenia się z przykładów z indukcją lokalnych reguł. Wyniki rozprawy mogą być przydatne dla efektywniejszej realizacji zdań eksploracji niezbalansowanych danych, oraz użyte w zastosowaniach praktycznych. Uważam, że doktorant wykazał się umiejętnościami prowadzenia badań naukowych, rozwiązywania problemów oraz pracowitością.

W mojej opinii rozprawa pana mgra Grzegorza Góry spełnia warunki stawiane przez stosowną ustawę w odniesieniu do rozpraw doktorskich i może być dopuszczona do publicznej obrony.

prof. dr hab. inż. Jerzy Stefanowski