Warszawa, 2 marca 2026

dr hab. inż. Krzysztof Trojanowski, prof. uczelni
Wydział Matematyczno-Przyrodniczy. Szkoła Nauk Ścisłych
Uniwersytet Kardynała Stefana Wyszyńskiego w Warszawie

Recenzja pracy doktorskiej mgr inż. Marcina Zakidalskiego pt.
„Ewolucyjne sztuczne sieci neuronowe do wspomagania decyzji kredytowych w bankowych systemach informatycznych"

Przedstawiona do recenzji praca dotyczy metod optymalizacji heurystycznej. Autor rozwija algorytmy ewolucyjne optymalizujące sztuczne sieci neuronowe pełniące rolę klasyfikatorów stosowanych do wspomagania decyzji kredytowych w bankowych systemach informatycznych. Jakością rozwiązania jest trafność zaklasyfikowania wnioskodawców do odpowiednich grup. Takich grup może być dwie (ci którzy spłacą kredyt i pozostali) albo więcej (np. spłacający w terminach, spłacający nieregularnie, tj. czasem po terminie, a czasem w terminie oraz pozostali). Osobnikami w populacji algorytmu ewolucyjnego są zatem klasyfikatory w postaci sieci neuronowych, a wartością osobnika jest wynik klasyfikacji dla testowego zbioru wniosków. Oprócz trafności klasyfikacji wnioskodawców stosowane są też inne kryteria oceny decyzji kredytowej, które również są interesujące dla instytucji finansowych, takie jak np. poziom zysku instytucji, czy prognozowany stopień wspierania lokalnego biznesu. W takich przypadkach rozwiązanie jest oceniane na podstawie kilku kryteriów, które są traktowane oddzielnie. Wtedy optymalizacja klasyfikatorów jest optymalizacją wielokryterialną, a rozwiązania są reprezentowane nie tylko jako elementy z dziedziny, ale również przez punkty w wielowymiarowej przestrzeni funkcji oceny. Autor w pracy skupia się na metodach optymalizacji klasyfikatorów reprezentowanych przez sztuczne sieci neuronowe w zadaniach wielokryterialnych, gdzie występują trzy kryteria oceny klasyfikatora: *trafność*, *F1-score* oraz *pole pod krzywą ROC*. Tego właśnie dotyczy postawiona hipoteza badawcza, która brzmi: *równoczesne wykorzystanie wybranych metryk klasyfikacji typu trafność, F1-score oraz pole pod krzywą ROC w algorytmie neuro-ewolucyjnym, w którym modyfikuje się zarówno wagi, biasy, architekturę sieci neuronowej, funkcje aktywacji neuronów oraz algorytmy treningu umożliwia wyznaczenie reprezentacji optymalnych w sensie Pareto modeli klasyfikujących do oceny wiarygodności wniosków kredytowych, w tym modelu kompromisowego* (podkreślenie moje – wyróżniłem orzeczenie i dopełnienie w tym zdaniu).

Rozprawa doktorska mgr inż. Marcina Zakidalskiego liczy 121 stron i jest napisana w języku polskim. Składa się z: Wykazu ważniejszych oznaczeń, Wprowadzenia, pięciu rozdziałów, Podsumowania, Bibliografii, Wykazu rysunków, Spisu tabel, a także dwóch Dodatków. Ich zawartość została omówiona poniżej.

Wprowadzenie przedstawia motywację do badań w obszarze optymalizacji wielokryterialnej, cel pracy i hipotezę badawczą, oraz opis rozdziałów.

Pierwszy rozdział jest podzielony na 10 podrozdziałów. Rozdział 1.1 opisuje przykłady sztucznych sieci neuronowych, zasady ich uczenia i weryfikacji oraz podaje przykład uczenia ANN (Artificial Neural Network) szacowania wartości nieruchomości Na podstawie zbioru danych Boston Housing Data. Rozdział 1.2 opisuje zastosowania ANN do zadań oceny wiarygodności kredytowej. Rozdział 1.3 objaśnia budowę i działanie radialnych sieci neuronowych. W rozdziale 1.4 znajduje się opis uczenia ANN. Rozdział 1.5 prezentuje samoorganizujące się sieci Kohonena. Rozdział 1.6 omawia modele uczenia głębokiego oraz miary oceny wykonanej przez ANN klasyfikacji. Rozdział 1.7 prezentuje różne kryteria klasyfikacji ANN. W rozdziale 1.8 autor przechodzi do tematyki algorytmów ewolucyjnych (Evolutionary Algorithms – EA) i omawia ich ogólne zasady budowy i działania oraz różne wersje EA, takie jak kwantowe EA, równoległe i rozproszone EA, wielokryterialne EA. Przy okazji omawia też formalną definicję dominacji w zbiorze, ewolucję różnicową i algorytmy neuro-ewolucyjne, tj. EA działające na populacji ANN. W rozdziale 1.9 szczególną uwagę kieruje autor na zastosowania EA do zadań klasyfikacji kredytowych sytuacji decyzyjnych. W kolejnych akapitach omawia: zastosowania EA do klasyfikacji finansowych sytuacji decyzyjnych (pierwszy i drugi), różne miary jakości klasyfikatorów i ich ocena (trzeci), zastosowania EA do selekcji relewantnych atrybutów objaśniających dla klasyfikatora neuronowego (czwarty), zastosowania EA do selekcji relewantnych atrybutów objaśniających dla innych klasyfikatorów niż ANN: SVM (Support Vector Machine) i kNN (k-Nearest Neighbours) (piąty) albo dla klasyfikatorów k-nearest neighbours, sieci bayesowskiej, drzewa C4.5, regresji logistycznej, sieci RBF, metody SVM, a także klasyfikatorów zespołowych: AdaBoost, LogitBoost i MultiBoost (szósty), EA do optymalizacji parametrów "innych metod sztucznej inteligencji" i ANN (siódmy) i na końcu EA do optymalizacji klasyfikatora działającego w oparciu o reguły rozmyte (ósmy). Podsumowanie kończy ten rozdział. Ten rozdział pełni funkcję przeglądu literatury na temat ANN, EA oraz EA do zadań budowy i optymalizacji klasyfikatorów.

Drugi rozdział opisuje EA do tworzenia, optymalizacji budowy i parametrów sieci neuronowych, w tym EA działające na fragmentach sieci jako podstawowych elementach służących do budowy kompletnej sieci. Ten rozdział też pełni funkcję przeglądu literatury.

Trzeci rozdział można podzielić na trzy części. Na początku pierwszej autor omawia szczegóły związane z czynnością podejmowania decyzji kredytowej, dokonuje przeglądu sytuacji decyzyjnych, aby następnie przejść do wyjaśnienia, jakie informacje o kredytobiorcy i o wnioskowanym kredycie są wykorzystywane na wejściu metod tworzących klasyfikatory. W drugiej części rozdziału prezentowane są zbiory atrybutów objaśniających i atrybut decyzyjny oraz kryteria oceny wniosków kredytowych dla następujących, powszechnie dostępnych benchmarków z danymi opisującymi wiarygodność kredytową: German Credit Data (GCD), Japanese Credit Screening (JSC), Australian Credit Approval, Loan Default Prediction, Give Me Some Credit (GMSC), Lending Club (DLC), Fannie Mae Single Family Loan Performance Data (FM). Autor odnosi się do benchmarków jako reprezentantów różnych problemów klasyfikacji ocen

wiarygodności kredytowych, ponieważ każdy benchmark reprezentuje zbiór informacji o wielu sytuacjach rzeczywistych zakodowanych w przestrzeni modelu określającego listę atrybutów objaśniających i atrybut decyzyjny, przy czym benchmarki reprezentują różne zbiory sytuacji, a dane w każdym z benchmarków powstały z wykorzystaniem innego modelu odwzorowania rzeczywistości. W trzeciej części rozdziału autor prezentuje różne kryteria oceny klasyfikatorów oraz ograniczenia nałożone na dane wejściowe i kryteria cząstkowe. Należy zwrócić uwagę, że ograniczenia te dotyczą danych służących do oceny klasyfikatorów, a nie są ograniczeniami nałożonymi na klasyfikatory, dlatego zadanie optymalizacyjne nie jest zadaniem z ograniczeniami (constrained optimization). Rozdział kończy omówienie wybranych aspektów związanych z oceną wiarygodności kredytowej.

Czwarty rozdział ma tytuł "Optymalizacja klasyfikatorów do oceny wiarygodności kredytowej" i znajdujemy w nim opisy zbiorów danych GCD, JCS, GMSC, DLC i FM, listę kryteriów oceny wniosku, oraz przegląd literatury dotyczący wykorzystania algorytmów ewolucyjnych do optymalizacji klasyfikatorów oraz – dość niespodziewanie – trochę najważniejszych informacji na temat relacji dominacji obiektów w przestrzeni wielokryterialnej, częściowo powtarzając informacje już podane w rozdziale 1, oraz definicji zadania optymalizacji wielokryterialnej. Są tam też dwa twierdzenia, 4.1 i 4.2.

Piąty rozdział prezentuje neuro-ewolucyjny algorytm CENA (ang. Creditworthiness Evolutionary Neural Assessment), który ma reprezentować składnik nowatorski w pracy. Następnie omawiane są poszczególne kryteria oceny klasyfikatora oraz prezentowane wartości tych kryteriów dla testów eksperymentalnych przeprowadzonych na wybranych zbiorach danych testowych.

Zakończenie zawiera potwierdzenie autora o realizacji postawionego celu pracy i wnioski końcowe. Bibliografia zawiera 212 pozycji. W trzech z nich mgr inż. Marcin Zakidalski jest współautorem. Są to publikacje z 2014, 2016 i 2019 roku.

Czy w rozprawie przeprowadzono w sposób właściwy analizę źródeł (w tym literatury światowej, stanu wiedzy i zastosowań w przemyśle) świadczącą o dostatecznej wiedzy autora? Czy wnioski z przeglądu źródeł sformułowano w sposób jasny, przekonywujący?

Analiza źródeł w podstawowym zakresie pracy, tj. dotyczącym metod sztucznej inteligencji, jest wykonana niewystarczająco dobrze. Poniżej zamieszczam uwagi do odniesień w tekście do pozycji bibliograficznych dla dwóch podrozdziałów: 1.8 i 19 (stosowane skróty dla algorytmów i typów klasyfikatorów są zgodne z ich anglojęzycznymi nazwami).

Uwagi do referencji bibliograficznych w podrozdziale 1.8

1. Sekcja 1.8, str. 31, pierwsze zdanie: *Algorytmy ewolucyjne są stosowane zarówno w uczeniu maszynowym, jak i w rozwiązywaniu problemów optymalizacji [15, 53].* Wskazane w zdaniu pozycje bibliograficzne wspierające stwierdzenia zawarte w zdaniu to:

   [15] Balicki J., Korłub W., Szymanski J., Zakidalski M., Big data paradigm developed in volunteer grid system with genetic programming scheduler, International Conference on Artificial Intelligence and Soft Computing 2014, Springer, 771-782.

   [53] Fogel L. J., Owens A. J., Walsh M. J., Artificial intelligence through simulated evolution, New York, Wiley, 1966.

Dlaczego [15], która nie ma charakteru przeglądowego, tj. taka publikacja, w której czytelnik mógłby zapoznać się szerzej z tematem, została wybrana jako referencja dla dziedziny zastosowań EA w uczeniu maszynowym, a [53], która jest jedną z pierwszych książek o symulowanej ewolucji komputerowej nie będącej wtedy jeszcze metodą optymalizacji w pełnym tego słowa rozumieniu – o zastosowaniach w optymalizacji? Ani jedna, ani druga praca nie jest przeglądem, czego należałoby się spodziewać od autora przy wskazywaniu po raz pierwszy w tekście określonych dziedzin badawczych. Z jakiego więc klucza zostały dokonane wybory tych właśnie publikacji?

2. Sekcja 1.8, str. 31, drugi akapit: informacja o składniku algorytmu ewolucyjnego, którym jest *funkcja przystosowania*, odnosi się do pozycji [9]: Arabas J., Wykłady z algorytmów ewolucyjnych, WNT, Warszawa, 2004. Jest to nieprawidłowa referencja. Zanim napiszę dlaczego, zacznę od pewnego wyjaśnienia, z którym autor powinien się zapoznać. W tekstach technicznych, zdarzają się sytuacje, kiedy autor po raz pierwszy w tekście wprowadza pojęcie, które nie jest nowatorskim wkładem autora, ale zostało wprowadzone wcześniej w innej publikacji i o którym do tej pory nie było wzmianki w autora tekście. Jeżeli autor chce wtedy podać informacje o pochodzeniu tego pojęcia, referencja bibliograficzna nie powinna odnosić się do opracowań przeglądowych, ale do pracy oryginalnej, w której to pojęcie zostało wprowadzone i opisane po raz pierwszy. Referencja w tekstach technicznych to nie tylko informacja, gdzie znaleźć opis, ale także komu autor tekstu technicznego przypisuje daną ideę. Referencja do publikacji ma znaczenie w ocenie dorobku publikacyjnego każdego naukowca, który jest mierzony między innymi liczbą cytowań jego publikacji. Na liczbie cytowań opierają się wskaźnik Hirscha (h-index) naukowców, impact factor czasopism oraz citation index artykułów. Nie oddanie uznania za stworzenie metody czy udowodnienie twierdzenia oryginalnemu twórcy, ale oddanie go innej osobie, która napisała przeglądowe opracowanie lub po prostu wykorzystała istniejące pojęcie lub metodę w swoich zupełnie czego innego dotyczących badaniach, jest odbieraniem uznania temu twórcy. Może nawet być w tym pewna zamierzona nieuczciwość, jeżeli ktoś myli cytowania świadomie. Dla odmiany referencje do opracowań mogą i powinny być stosowane przy odnoszeniu się do dziedzin badań, w których powstało już wiele prac. Te referencje reprezentują miejsca, gdzie czytelnik może zapoznać się szerzej ze wskazanym tematem. W takich przypadkach można odnosić się nawet do kilku opracowań, jeżeli każde z nich z innej perspektywy opisuje dziedzinę. Wracając do wprowadzania pojęć, np. metod czy definicji, i wskazywania dla nich cytowań, referencje do przeglądów są uznawane za złą praktykę, której należy unikać z wyżej wymienionych powodów i która jest metodologicznym błędem wyboru pozycji bibliograficznych w tekście. Brak wiedzy autora pracy o takich zasadach dotyczących cytowań, potwierdzony przez wiele źle wybranych odniesień w recenzowanej pracy, oznacza, że jego umiejętność pisania tekstów technicznych nie jest wysoka. Publikacja [9] jest właśnie przeglądem i dodatkowo również podręcznikiem kursowym. Autor popełnił jeszcze jeden błąd w tym miejscu tekstu: wprowadził niepotrzebnie odniesienie bibliograficzne dla pojęcia, które obecnie stało się wiedzą powszechną w dziedzinie optymalizacji ewolucyjnej. Ta sama uwaga odnosi się do pojęcia *nacisk selektywny* będącego wiedzą powszechną, która nie wymaga referencji do publikacji, a jeżeli już, to na pewno nie do referencji [9]. W następnym zdaniu, objaśniając rozkład prawdopodobieństwa w selekcji ruletkowej autor popełnił ten sam

błąd, co w przypadku pojęcia *funkcja przystosowania*. Referuje do [144]: Sivanandam S. N., Deepa S. N, Introduction to genetic algorithms, Springer, Berlin, Heidelberg, 2008., która to pozycja również jest przeglądem. Tu również autor wprowadził niepotrzebne odniesienie dla pojęcia, które stało się wiedzą powszechną w dziedzinie.

3. Str. 33, zdanie *Wyróżnia się następujące rodzaje cyfrowych algorytmów genetycznych [7, 75, 144].* (na marginesie – po co autorowi przymiotnik *cyfrowych*, którego ani nie używał wcześniej, ani nie używa później?) odnosi się do trzech publikacji, [7]: Angeline P. J., Saunders G. M., Pollack J. B., An evolutionary algorithm that constructs recurrent neural networks, IEEE Transactions on Neural Networks, 5, 1, 1994, 54-65, [75]: Haflidason S., Neville R., On the significance of the permutation problem in neuroevolution, Proceedings of the 11th Annual Conference on Genetic and Evolutionary Computation, 2009, oraz do wcześniej wspomnianego przeglądu [144]. Struktura dalszej części zdania sugeruje, że [7] miałoby być referencją dla *simple genetic algorithm*, [75] – dla *parallel and distributed genetic algorithm*, a [144] – dla *migration PGA* (Parallel Genetic Algorithm). Artykuł [7] nie jest artykułem oryginalnym dla *simple genetic algorithm*, ale dużo nowszym, prezentującym algorytm GNARL, więc nie powinien być referencją dotyczącą klasy prostych algorytmów genetycznych. Co więcej, w [7] GA jest akurat antyprzykładem dobrego algorytmu dla pewnej klasy zadań. To jest powiedziane już w abstrakcie [7], gdzie autorzy piszą *This paper argues that genetic algorithms are inappropriate for network acquisition and describes an evolutionary program, called GNARL, that simultaneously acquires both the structure and weights for recurrent networks.* Artykuł [75] jest również złą referencją, ponieważ w ogóle nie dotyczy ani równoległych GA, ani rozproszonych GA (*parallel and distributed genetic algorithm*). Ponadto w zdaniach "*Natomiast rozproszony i równoległy algorytm genetyczny (ang. paralel and distributed genetic algorithm) jednocześnie wykonywany jest na wielu węzłach obliczeniowych. Zazwyczaj niezależnie generowane są populacje początkowe w węzłach, na których realizowane są obliczenia przez ten sam algorytm. Ponadto algorytm genetyczny z migracją rozwiązań (ang. migration PGA) umożliwia przeniesienie wysokiej klasy rozwiązań między węzłami*" autor zdradza się z niezrozumieniem tematu: miesza model równoległy w GA, którego dotyczą pojęcia *parallel and distributed genetic algorithm* i *migration PGA*, z równoległą implementacją oprogramowania, tj. taką gdzie aplikacja komputerowa korzysta z wielu maszyn w sieci aby zrównoleglić i tym samym przyspieszyć obliczenia.
4. Str. 34, zdanie *Z optymalizacją wielokryterialną jest związane pojęcie dominacji w sensie Pareto [8]* odnosi się do publikacji [8]: Ameljańczyk A., Wprowadzenie do optymalizacji, Wyd. WAT, Warszawa 2021. Ta pozycja jest przeglądem (całkiem nowym).
5. Str. 34, pierwsze zdanie drugiego akapitu, dotyczące warunków braku dominacji między dwoma punktami, odnosi się do publikacji [135]: Schrum J., Miikkulainen R., Evolving agent behavior in multiobjective domains using fitness-based shaping, Proceedings of the 12th Annual Conference on Genetic and Evolutionary Computation, 2010, 439-446. Ta referencja jest niewłaściwa, ponieważ odnosi się do publikacji dotyczącej pewnej metody stosowanej dla zadań wielokryterialnych, a nie takiej, gdzie wprowadzono pojęcie dominacji w sensie Pareto ani w rozumieniu ogólnym, ani w zastosowaniach o charakterze technicznym. To odniesienie jest

zbędne ponieważ definicja dominacji jednego punktu nad drugim stała się obecnie wiedzą powszechną w dziedzinie optymalizacji wielokryterialnej.

W powyższej liście pięciu uwag występują różne przypadki pozycji bibliograficznych niewłaściwych merytorycznie albo formalnie. Niektóre z nich są reprezentantami większej liczby powtórzeń określonego błędu. Można też znaleźć w tekście korzystanie z pojęć wyglądające tak, jakby autor już wcześniej je objaśnił i podał właściwe odniesienia bibliograficzne. Jednak w rzeczywistości w tekście nie pojawiły się takie informacje. Korzystanie w tekście z nie należących do wiedzy powszechnej pojęć bez objaśnienia ich przy pierwszym pojawieniu się w tekście jest uznawane za złą praktykę. Takie objaśnienie oraz podanie właściwego cytowania jest konieczne, aby nie doszło do sytuacji, kiedy kolejne nowe pojęcia objaśniamy poprzednimi, jednak dotychczas nieobjaśnionymi. Np. mimo że już we wcześniejszych podrozdziałach istnieją zdania, które zawierają pojęcie *rozwiązanie kompromisowe* (w tym np. hipoteza badawcza zamieszczona na str. 7), to objaśnienie pojęcia wraz z cytowaniem pojawia się dopiero w podrozdziale 5.3, str. 98, kiedy autor zaczyna omawiać wyniki optymalizacji wielokryterialnej pisząc *W celu wyboru jednego klasyfikatora można zastosować metodę punktu idealnego do selekcji rozwiązania kompromisowego [8].* W rozdziale 1.8 na str. 35 po omówieniu wielu wariantów EA autor nagle zamieszcza akapit podsumowujący: *Algorytm ewolucyjny może również działać na populacji sztucznych sieci neuronowych Hopfielda w celu wyznaczenia wag, biasów oraz początkowych aktywacji neuronów, które minimalizują funkcję energetyczną sieci [14]. Można zatem wyróżnić kilka interesujących rodzajów algorytmów ewolucyjnych: algorytmy genetyczne, strategie ewolucyjne, ewolucja różnicowa, algorytmy koewolucyjne czy też programowanie genetyczne. Dodatkowo można rozważać kwantowe lub rozproszone wersje powyższych algorytmów.* W tym akapicie obok omówionych przez autora wariantów EA pojawia się *programowanie genetyczne*, którego działania autor nie omawiał ani nie podawał dla niego odniesień do bibliografii. Zacytowany powyżej akapit prezentuje też przy okazji przykład nieuporządkowania zawartości rozdziałów, ponieważ po tym podsumowaniu, w następnym akapicie jak gdyby nigdy nic, autor wraca do analizy wariantów EA działających na populacji ANN, którą zasygnalizował w w pierwszym zdaniu akapitu podsumowującego i prowadzi ją przez kolejne cztery akapity aż do końca tego podrozdziału.

Uwzględniając fakt, że podrozdział jest zatytułowany "Algorytmy ewolucyjne", można spodziewać się, że pierwotnym powodem jego napisania było przedstawienie podstaw dziedziny. Oceniając ten podrozdział pod względem wyboru cytowanych źródeł, jego obecna postać nie spełnia tego celu.

Uwagi do referencji bibliograficznych w podrozdziale 1.9 W tym podrozdziale autor prezentuje informacje dotyczące zastosowań algorytmów ewolucyjnych do klasyfikacji kredytowej podparte odniesieniami do pozycji bibliograficznych stanowiących wskazanie, komu autor przypisuje te osiągnięcia. Informacje te, można pogrupować pod względem wkładu badawczego i roli EA w tych badaniach wg trzech kryteriów: (1) informacja, do jakiego zadania zastosowano EA, przy czym przedmiotem zadania mogą być zarówno testy porównawcze efektywności EA na różnych zbiorach danych jak i optymalizacja klasyfikatorów przez EA, (2) informacja, jaki wariant algorytmu, o jakiej budowie i działaniu był stosowany (z większym lub mniejszym sukcesem) oraz (3) informacja, na jakich zbiorach danych przeprowadzono eksperymenty. Poniżej zamieściłem pełną listę odniesień bibliograficznych z tego podrozdziału zawierającą informacje dla kryteriów nr 1 i 2. Ponadto

– w niektórych przypadkach – na końcu opisu dodałem ewentualne korekty informacji podanych przez autora o rodzaju zadania, a także opisu metody, bądź opisu badań z uwzględnieniem danych testowych. Porządek pozycji bibliograficznych w liście odpowiada kolejności pojawiania się tych pozycji w tekście.

[107] artykuł to przykładowa pozycja przeglądowa,

[177] autorzy badają pewien rodzaj zadania: klasyfikacja opóźnienia w spłatach w zadanym okresie za pomocą GA,

[85] artykuł reprezentuje tylko przykład użycia przez GA zbiorów danych: German Credit Data oraz Australian Credit Approval,

[49] artykuł potwierdza skuteczność GA względem alternatywnych metod: sztuczna sieć neuronowa, metoda najmniejszych kwadratów oraz regresja logistyczna,

[30] autorzy badają pewien rodzaj zadania: minimalizacja liczby wniosków niesłusznie zakwalifikowanych jako niewiarygodne przez GA,
komentarz: autor błędnie podaje, że wykorzystano programowanie genetyczne, podczas gdy w referowanym artykule jest mowa o GA,

[195] link do zbioru danych (podany ponownie, ponieważ o zbiorze danych Australian Credit Approval mowa jest już w podrozdziale 1.2),

[19] autorzy badają pewien rodzaj zadania: podział wniosków na wiarygodne i niewiarygodne za pomocą GA,

[86] prezentuje nowy wariant algorytmu: dwustopniowe PG,

[47] autorzy badają pewien rodzaj zadania: identyfikacja za pomocą programowania genetycznego atrybutów objaśniających relewantnych dla danych reprezentujących kredytobiorców;
komentarz: autor błędnie podaje, że wykorzystano GA, podczas gdy w referowanym artykule jest mowa o programowaniu genetycznym,

[104] autorzy badają pewien rodzaj zadania: identyfikacja za pomocą GA atrybutów objaśniających relewantnych w klasyfikacji danych reprezentujących wnioski kredytowe,

[138] autorzy badają pewien rodzaj zadania: identyfikacja za pomocą GA atrybutów objaśniających relewantnych w klasyfikacji, przy czym autor podkreśla, że konsekwencją redukcji liczby atrybutów objaśniających jest mniejszy rozmiar sieci neuronowej,

[197] link do zbioru danych (podany ponownie, ponieważ o zbiorze danych Japanese Credit Screening mowa jest już w podrozdziale 1.2),

[116] autorzy badają pewien rodzaj zadania: identyfikacja za pomocą GA atrybutów objaśniających relewantnych dla zaprojektowania zespołu klasyfikatorów,

[156] autorzy badają pewien rodzaj zadania: identyfikacja za pomocą GA atrybutów objaśniających relewantnych dla wielowarstwowych sieci neuronowych,

[124] prezentuje nowy algorytm: DHNL (deep genetic hierarchical network of learners) działający na hierarchicznej strukturze węzłów, które mogą być różnego typu (SVM, kNN, PNN, fuzzy systems) i dla której GA najpierw identyfikuje zbiór atrybutów objaśniających relewantnych w klasyfikacji danych, a później również optymalizujący strukturę i parametry węzłów;
komentarz: autor niepoprawnie upraszcza pisząc, że GA optymalizuje parametry wielowarstwowych sieci radialnych,

[85] autorzy badają pewien rodzaj zadania: selekcja relewantnych atrybutów objaśniających oraz optymalizacja parametrów SVM za pomocą GA,

[137] prezentuje nowy wariant algorytmu: dwu-etapowy algorytm optymalizacyjny, w którym w głównej pętli wykonywane są kolejno etapy: (1) strojenie parametrów SVM za pomocą GA, oraz (2) identyfikacja atrybutów objaśniających relewantnych dla wyniku aktualnie zestrojonej SVM za pomocą GA;
komentarz: autor nieprecyzyjnie podaje, że wykorzystano SVM dla klasyfikacji danych Lending Club,

[192] link do zbioru danych (podany ponownie, ponieważ o zbiorze danych Lending Club mowa jest już w podrozdziale 1.2),

[180] prezentuje nowy wariant algorytmu: współpracująca para dwóch algorytmów: GA i k-średnich, gdzie algorytm k-średnich usuwa zaszumione przypadki w danych wejściowych, a GA redukuje redundantne atrybuty objaśniające, przy czym wynik działania potem stanowi wejście dla algorytmu C4.5 tworzącego model klasyfikacyjny;
komentarz: autor nieprecyzyjnie podaje, że identyfikowano za pomocą GA atrybuty objaśniające mające największe znaczenie dla modelu drzew decyzyjnych C4.5,

[106] autorzy badają pewien rodzaj zadania: optymalizacja klasyfikatorów kNN za pomocą algorytmów heurystycznych, w tym GA;
komentarz: autor nieprecyzyjnie podaje, że chodzi o selekcję cech klasyfikatora kNN,

[87] prezentuje nowy wariant algorytmu: GA identyfikuje atrybuty objaśniające relewantne dla różnych klasyfikatorów ewaluowanych na tym samym zbiorze danych,

[119] autorzy badają pewien rodzaj zadania: iteracyjne wykonanie GA optymalizującego parametry klasyfikatora ANN oraz atrybutów objaśniających relewantnych dla tego klasyfikatora oraz uczenie klasyfikatora ANN na podstawie wybranych atrybutów i ewaluacja jego działania na danych testowych;
komentarz: autor błędnie upraszcza, że do selekcji cech w ANN wykorzystano GA,

[25] autorzy badają pewien rodzaj zadania: optymalizacja parametrów klasyfikatora za pomocą GA,

[196] link do zbioru danych (podany ponownie, ponieważ o zbiorze danych German Credit Data mowa jest już w podrozdziale 1.1)

[99] autorzy badają pewien rodzaj zadania: optymalizacja parametrów wielowarstwowych sieci radialnych za pomocą GA,

Na koniec podrozdziału 1.9 podane są razem pozycje [58, 103, 171, 173, 186], które autor skomentował tekstem *Zazwyczaj modyfikacji podlegały parametry funkcji radialnych, a także wagi połączeń synaptycznych.* Jednak na tym nie zakończył i w ostatnim akapicie zdecydował się omówić jeszcze jedną publikację, [9], w której zaprezentowano wykorzystanie wielokryterialnych EA do optymalizacji klasyfikatora, działającego w oparciu o logikę rozmytą, przy czym postać klasyfikatora przed optymalizacją jest otrzymywana za pomocą analizy skupień.

W jednym miejscu źródeł brak: str. 34, pierwszy akapit: zdanie *Do najpopularniejszych algorytmów wielokryterialnych należą MOGA, NPGA oraz NSGA-II [37]* zawiera referencję bibliograficzną tylko dla NSGA-II. MOGA i NPGA są tu wspomniane po raz pierwszy w całym tekście i nie ma dla nich referencji bibliograficznych. A szkoda, bo skrót NPGA reprezentuje dwa różne podejścia

opisane dwóch artykułach: (1) J. Li and H. Su, "NPGA: A Unified Algorithmic Framework for Decentralized Constraint-Coupled Optimization," in IEEE Transactions on Control of Network Systems, vol. 11, no. 3, pp. 1655-1666, Sept. 2024, doi: 10.1109/TCNS.2024.3354882, oraz (2) Horn, Jeffrey D. et al. "A niched Pareto genetic algorithm for multiobjective optimization." Proceedings of the First IEEE Conference on Evolutionary Computation. IEEE World Congress on Computational Intelligence (1994): 82-87 vol.1.

Podrozdział 1.9 ma tylko częściowo uporządkowaną strukturę. W tym podrozdziale, który w założeniu miał stanowić krytyczny przegląd literatury, kolejne przykłady zastosowań podparte referencjami bibliograficznym podawane są w kolejności trochę przypadkowej, bez widocznego planu. Autor popełnia w tym rozdziale też błędy dotyczące wyboru właściwych cytowań dla używanych przez niego pojęć. Dodatkowo, na 25 wybranych i skomentowanych nieco bardziej szczegółowo pozycji bibliograficznych, cztery mają błędny opis, trzy – opis dostatecznie nieprecyzyjny, aby poważnie poddać w wątpliwość, czy autor zapoznał się z tymi publikacjami. W dwóch miejscach brak odpowiednich referencji bibliograficznych.

Ponadto w podrozdziale 1.10 zatytułowanym "Wnioski i uwagi" autor niesłusznie kwalifikuje algorytmy ewolucyjne oraz algorytmy neuro-ewolucyjne do obszaru metod uczenia maszynowego. Choć EA, adaptując swoje parametry w trakcie działania, pośrednio "uczą się" optymalizowanego zadania, a także chociaż bywają narzędziem wykorzystywanym w metodach uczenia maszynowego, to jednak nie są metodami uczenia. Autor zamieszcza też zdania *Ponadto kluczowy jest wybór rodzaju algorytmu ewolucyjnego. Algorytm genetyczny, strategia ewolucyjna, ewolucja różnicowa, algorytm koewolucyjny czy programowanie genetyczne opierają się na innych regułach działania. Ważne są rodzaje zastosowanych operatorów: selekcji, mutacji, krzyżowania oraz sukcesji*, mimo że część zawartych w nich pojęć nie ma swojego potwierdzenia w przeglądzie zamieszczonym w podrozdziale 1.9 dotyczącym istniejących zastosowań EA do klasyfikacji kredytowych sytuacji decyzyjnych. W tym przeglądzie autor nie wymienia przykładów zastosowań strategii ewolucyjnych ani ewolucji różnicowej. Nie ma tam też analizy zastosowań operatorów w klasyfikacji.

Wyżej wymienione wady świadczą o brakach w umiejętności pisania tekstów technicznych, a także budzą wątpliwości co do wiedzy z dziedziny, której dotyczy przedłożona praca, oraz badawczej rzetelności autora.

W kontekście doboru cytowań należy też zauważyć, że choć w Bibliografii występują trzy pozycje, których współautorem jest mgr inż. Marcin Zakidalski, to jednak do żadnej z nich nie odnosi się, kiedy opisuje zaproponowany przez siebie algorytm neuro-ewolucyjny. Do pozycji [12] odnosi się, kiedy w podrozdziale 1.2 stwierdza, że *Sztuczne sieci neuronowe zastosowano także w prognozowaniu finansowym [12]*. Do pozycji [13] i [15] odnosi się w podrozdziale 1.8, gdzie do [13] odnosi się opisując algorytm ewolucji różnicowej, a do [15] – kiedy pisze o tym, że *Algorytmy ewolucyjne są stosowane zarówno w uczeniu maszynowym* [..]. Publikacji [15] dotyczy moja pierwsza uwaga do referencji bibliograficznych w podrozdziale 1.8 (tekst powyżej).

Czy autor rozwiązał postawione zagadnienia, czy użył właściwej do tego metody, i czy przyjęte założenia są uzasadnione?

Informację o postawionych zagadnieniach znajdujemy we Wstępie, gdzie autor zamieszcza informacje o tym, (1) jaki jest cel pracy, (2) na czym polega problem badawczy oraz (3) prezentuje

hipotezę roboczą, czyli hipotezę badawczą. Poniżej znajdują się ich pełne treści przepisane z pracy ze str. 7. Pogrubione zostały przeze mnie słowa reprezentujące ten fragment zdań, który określa zakres prac.

cel pracy — **opracowanie efektywnych zasad wykorzystania** wielokryterialnych algorytmów ewolucyjnych operujących na populacji sztucznych sieci neuronowych do wyznaczania reprezentacji Pareto-optymalnych modeli klasyfikujących (klasyfikatorów) stosowanych do oceny wiarygodności kredytowej wniosków w odniesieniu do wybranych sytuacji decyzyjnych określonych za pomocą publicznie dostępnych zbiorów danych.

problem badawczy — **opracowanie modelu sytuacji decyzyjnej, sformułowanie problemu oraz algorytmu neuro-ewolucyjnego** do konstruowania reprezentacji Pareto-optymalnych klasyfikatorów neuronowych odnośnie szacowania wiarygodności kredytowej klientów banków dla wybranych datasetów.

hipoteza badawcza — **Równoczesne wykorzystanie wybranych metryk klasyfikacji** typu trafność, F1-score oraz pole pod krzywą ROC **w algorytmie neuro-ewolucyjnym**, w którym modyfikuje się zarówno wagi, biasy, architekturę sieci neuronowej, funkcje aktywacji neuronów oraz algorytmy treningu, **umożliwia wyznaczenie reprezentacji optymalnych w sensie Pareto modeli klasyfikujących** do oceny wiarygodności wniosków kredytowych, w tym modelu kompromisowego.

W Podsumowaniu autor zamieszcza potwierdzenia, że wszystkie trzy wyżej wymienione składowe, tj. cel, problem i hipoteza zostały zrealizowane (str. 105 i 106). Potwierdzenia można streścić następująco:

— Jako osiągnięcie celu pracy, autor wskazuje opracowanie algorytmu Creditworthiness Evolutionary Neural Assessment, CENA (str. 105, środkowy akapit na tej stronie).

— Rozwiązaniem problemu badawczego jest opracowanie algorytmu CENA wraz z badaniami eksperymentalnymi na publicznie dostępnych zestawach danych. W wyniku przeprowadzonych eksperymentów znaleziono niezdominowane rozwiązania – sieci neuronowe pełniące funkcje klasyfikatorów (str. 105, dolny akapit na tej stronie).

— Brak zdania deklarującego wprost wykazanie prawdziwości hipotezy badawczej, autor formułuje tylko zdanie *Nie podważono zatem postawionej na wstępie hipotezy naukowej.* (str. 106, pierwszy akapit od góry strony). Autor twierdzi tak, ponieważ wykazał w badaniach eksperymentalnych, że CENA umożliwia wygenerowanie niezdominowanych klasyfikatorów do wniosków kredytowych, których jakość przewyższa jakość klasyfikatorów wyznaczonych za pomocą innych metod.

Odnosząc się do postawionego celu pracy nie mogę zgodzić się z autorem, że cel został osiągnięty, tj. że opracowanie metody CENA jest tożsame z "opracowaniem efektywnych zasad wykorzystania wielokryterialnych algorytmów ewolucyjnych operujących na populacji sztucznych sieci neuronowych do wyznaczania reprezentacji Pareto-optymalnych modeli klasyfikujących (klasyfikatorów) stosowanych do oceny wiarygodności kredytowej wniosków w odniesieniu do wybranych sytuacji decyzyjnych określonych za pomocą publicznie dostępnych zbiorów danych". Uzasadnienie mojej oceny zacznę od tego, że określenie *Pareto-optymalny model klasyfikujący* nie funkcjonuje w słownictwie naukowym polskim ani anglojęzycznym (jako np. "Pareto-optimal classification

model"). Żeby więc zrozumieć postawiony cel, usuwam to egzotyczne określenie z definicji celu, a zostawiam tylko część zrozumiałą, zamieniając po drodze określenie "Pareto-optymalny" na jego synonim "niezdominowany", tj. *opracowanie efektywnych zasad wykorzystania wielokryterialnych algorytmów ewolucyjnych operujących na populacji sztucznych sieci neuronowych do wyznaczania reprezentacji niezdominowanych klasyfikatorów stosowanych do oceny wiarygodności kredytowej wniosków w odniesieniu do wybranych sytuacji decyzyjnych określonych za pomocą publicznie dostępnych zbiorów danych.*

Nadal jest to zawile zdefiniowany cel pracy, który wymaga analizy, dlatego dla ułatwienia dokonałem rozbioru tego równoważnika zdania:

— opracowanie (*czego?..*)
— efektywnych zasad wykorzystania wielokryterialnych algorytmów ewolucyjnych (*jakich?..*)
— operujących na populacji sztucznych sieci neuronowych (*zasad wykorzystania do czego?..*)
— do wyznaczania reprezentacji niezdominowanych klasyfikatorów (*jakich?..*)
— stosowanych do oceny wiarygodności kredytowej wniosków w odniesieniu do wybranych sytuacji decyzyjnych (*jakich sytuacji decyzyjnych?..*)
— określonych za pomocą publicznie dostępnych zbiorów danych

Mówienie w opisie celu autora o zasadach wykorzystania MOEA (Mulit-Objective Evolutionary Algorithm) do wyznaczania *reprezentacji niezdominowanych klasyfikatorów stosowanych do oceny wiarygodności kredytowej wniosków etc.* może oznaczać dwie rzeczy.

Pierwsza, że wyznaczony cel może dotyczyć wykonania koniecznego i nowatorskiego dostosowania reprezentacji rozwiązania. Określenie *reprezentacja* odnosi się bowiem do sposobu, w jaki kodujemy rozwiązanie i obejmuje reguły dotyczące porządku podawania cząstkowych wartości, dozwolone przedziały dla każdej z tych wartości, struktury ich zapisu, np. reprezentacja grafowa, albo liniowa, interpretacja wynikająca ze struktury, etc. Opracowanie reprezentacji na potrzeby wielokryterialnych EA skutkuje potrzebą opracowania też właściwych dla tej reprezentacji operatorów perturbujących. Takie stwierdzenie to truizm: od dawna wiemy, że np. kodowanie binarne wymaga innych operatorów niż kodowanie rzeczywistoliczbowe. Stąd gdyby autor chciał skupić się na nowych formach kodowania sieci neuronowej jako nowych efektywnych zasadach wykorzystania EA, należałoby się spodziewać badań dotyczących tych reprezentacji i odpowiednich dla nich operatorów, tj. np. opracowania nowych operatorów perturbacji lub adaptacji istniejących i oceny efektywności każdego z nich np. w eksperymentach. Jednak dalsza lektura pracy pozwala stwierdzić, że nie tego dotyczyły zamiary autora.

Pozostaje więc drugie wyjaśnienie, że celem pracy jest po prostu *opracowanie efektywnych zasad wykorzystania wielokryterialnych algorytmów ewolucyjnych* [..], a więc zasad innych, niż ogólnie przyjęte, ale za to bardziej efektywnych. Opracowanie nowych zasad wykorzystania MOEA może być nietrywialnym zadaniem, gdy przyjęta przez autora specyficzna ocena klasyfikatora jest dwu- lub trzykryterialna i gdy w przypadku różnych zestawów kryteriów oceny mogą tworzyć się różne, nieraz bardzo wymagające fronty Pareto. Dlatego opracowanie nowych zasad wykorzystania MOEA byłoby ciekawym wkładem w dziedzinę naukową. Algorytmów MOEA istnieje wiele, więc materiał do badań jest bogaty. Obecne w literaturze MOEA dzielą się na trzy grupy. Pierwsza, których działanie jest oparte o zależności dominacji w rozumieniu Pareto, to takie znane algorytmy

jak np. MOGA, SPEA2, SPEA3, NSGA-II, NSGA-III. Reprezentantem algorytmów z drugiej grupy, tj. opartych o wskaźniki jakości, jest np. SMS-EMOA. W trzeciej grupie mamy algorytmy oparte na dekompozycji, których reprezentantem może być np. MOEA/D. Opracowując najlepiej dopasowane zasady użycia dla różnych MOEA, autor mógłby wyróżnić np. zasady, które są wspólne dla wszystkich, po czym objaśnić ich działanie przyczyniające się do uzyskania efektywnych wyników. Dalszy tekst pracy nie zawiera jednak takich badań. Autor deklaruje, że cel pracy został osiągnięty przez opracowanie algorytmu CENA, jednak to nie jest tożsame z *opracowaniem efektywnych zasad wykorzystania wielokryterialnych algorytmów ewolucyjnych*. Opracowanie CENA nie skutkuje wskazaniem zasad, które byłyby dedykowane do zadań ze specyficzną, wielokryterialną oceną klasyfikatora stosowanego do oceny wiarygodności kredytowej wniosków i które byłyby rezultatem jego badań. W prezentowanych badaniach nie dokonuje porównań potwierdzających znaczenie korzystania z tych zasad. Nie demonstruje np. w postaci wyników badań eksperymentalnych, że brak ich zastosowania sprawia, że uzyskane wyniki są gorsze, niż wtedy, kiedy te zasady są stosowane. Nie dokonuje analizy ich działania, aby wyjaśnić, skąd brałaby się poprawa skuteczności algorytmów.

Poza dwoma wyżej wymienionymi, nie widzę innych wyjaśnień, na czym polegałoby osiągnięcie celu pracy. Dlatego wracam do stwierdzenia, od którego zacząłem. Nie mogę napisać, że sformułowany przez autora cel pracy został osiągnięty.

Odnosząc się do postawionego problemu badawczego nie zgadzam się z autorem, że rozwiązał problem badawczy taki, jaki wskazał we Wstępie. Postawiony przez autora problem badawczy został zdefiniowany jako złożenie trzech podproblemów:

Opracowanie modelu sytuacji decyzyjnej to opracowanie nowego, uproszczonego i sformalizowanego odwzorowania pewnej rzeczywistości. Przyjmuje się, że określenie "nowy model" odnosi się do nowej formalnej reprezentacji pewnej rzeczywistej sytuacji wymagającej podjęcia odpowiednich działań (tj. poszukiwania rozwiązania tej sytuacji) i celem jego opracowania jest znalezienie znanymi lub nowymi metodami takiego rozwiązania zadania postawionego w przestrzeni modelu, które będzie użyteczne, tj. kiedy wdrożenie tego rozwiązania w rzeczywistej sytuacji przynosi korzyści. Autor korzystał tylko z publicznie dostępnych zbiorów danych, które nie mogły powstać bez opracowania takiego właśnie odpowiedniego odwzorowania. Te modele, które posłużyły do utworzenia zbiorów danych, nie są więc nowatorskim pomysłem autora, ale zostały wyspecyfikowane już wcześniej, na etapie opracowania zbiorów danych. W rozdziale 4. autor wskazuje element nowatorski pracy: *Nowością są sformułowane w rozdziale zagadnienia optymalizacji jednokryterialnej z punktu widzenia zarządu banku oferującego kredyty odbiorcom detalicznym. Znaczącą innowacją jest również sformułowanie zagadnienia wyznaczania reprezentacji klasyfikatorów Pareto-optymalnych.* W tym rozdziale autor niewiele wspomina o budowaniu modelu sytuacji decyzyjnej, za to zaczyna często używać słowa *zagadnienie* w kontekście optymalizacji. Jest to nieoczywiste, ponieważ słowo *zagadnienie* używa się do szerszych pojęć, np. "wybrane zagadnienia informatyki technicznej"[1]. Słowo *model* jeżeli już pada w tekście, to tylko w zdaniach typu *Niech w wyniku uczenia na zbiorze treningowym zostanie zaprojektowany klasyfikujący model predykcyjny* M, *którego wyjście przyjmuje wartości*

[1] Wybrane zagadnienia informatyki technicznej. Modelowanie i optymalizacja, Ireneusz Mrozek (red. naukowy), Oficyna Wydawnicza Politechniki Białostockiej

$F_1 : X \to \{0, 1\}$. Autor już nie wspomina o nowym modelu dla wybranych klas produktów kredytowych. Teraz autor skupia się na *sformułowaniu zagadnienia optymalizacji jednokryterialnej z punktu widzenia zarządu banku*. Rozdział 4 ma niewiele, a może nawet nic wspólnego z opracowaniem modelu sytuacji decyzyjnej. W podrozdziale 4.3 zawierającym podsumowanie rozdziału 4. pada za to interesujące zdanie *Optymalizacja wielokryterialna pozwala na jednoczesne uwzględnienie wielu różnych aspektów, co prowadzi do bardziej zrównoważonego modelu*. Modelu czego? Rozdziały 3. i 4. w których spodziewałem się informacji o ewentualnym opracowaniu modelu sytuacji decyzyjnej nie zawierają nic na ten temat, a napisane są tak nieprecyzyjnie, że nie wiadomo właściwie, o czym autor chciał w nich napisać. Nie mogę więc stwierdzić, że ta składowa problemu badawczego została zrealizowana. Mam wrażenie, że deklarowany podproblem w ogóle nie zaistniał w planach badawczych autora pracy.

Sformułowanie problemu enigmatycznie określa tę składową przyjętego przez autora problemu badawczego. Użyte słowo *problem* sprawia, że możliwe są różne interpretacje. Jeżeli autor ma na myśli sformułowanie problemu badawczego, którym chce się zająć w swojej pracy, to zwrot ten tworzy rodzaj rekurencji opisowej: jedną ze składowych problemu badawczego jest sformułowanie tego problemu badawczego. Tego bym się nie spodziewał. Jeżeli natomiast pisząc słowo *problem* miał na myśli *zadanie*, to doszło do nieprecyzyjnego i niejednoznacznego wyrażenia, przy czym stało się to w szczególnie newralgicznym momencie pracy, kiedy autor definiuje to, z czego będzie oceniana jego praca przez recenzentów. Określeń *problem* i *zadanie* nie można stosować zamiennie, ponieważ reprezentują dwie różne rzeczy. Problem wymaga najpierw analizy sytuacji, jej zamodelowania, a w ostatnim kroku zidentyfikowania metody rozwiązania, natomiast zadanie ma jasno określony cel i kryteria oceny jakości rozwiązań, oraz pozwala na przypisanie do konkretnej klasy zadań, co może pomóc zawęzić wybór odpowiedniej metody ze zbioru metod służących do jego rozwiązania. Nie mogę więc napisać, że ten podproblem został rozwiązany, bo nie jestem pewien, co autor miał na myśli.

Sformułowanie algorytmu neuro-ewolucyjnego zostało wykonane, a algorytm został zaimplementowany i przetestowany na benchmarkowych zbiorach danych. Mogę więc stwierdzić, że ta składowa problemu badawczego została zrealizowana.

Odnosząc się do hipotezy badawczej uważam, że autor sformułował ją podobnie zawile, co cel pracy. Dlatego dla ułatwienia również dokonałem rozbioru tego zdania:

— Równoczesne wykorzystanie (*czego i gdzie?..*) ⟵*podmiot*
— wybranych metryk klasyfikacji typu trafność, F1-score oraz pole pod krzywą ROC w algorytmie neuro-ewolucyjnym (*jakim?..*)
— w którym modyfikuje się zarówno wagi, biasy, architekturę sieci neuronowej, funkcje aktywacji neuronów oraz algorytmy treningu,
— umożliwia wyznaczenie (*czego?..*) ⟵*orzeczenie i dopełnienie*
— reprezentacji niezdominowanych klasyfikatorów (*służących do czego?..*)
— do oceny wiarygodności wniosków kredytowych, w tym modelu kompromisowego.

przy czym określenie *reprezentacja optymalnych w sensie Pareto modeli klasyfikujących* od razu zastąpiłem w analizie zdania powyżej wypracowanym już wcześniej, przy okazji analizy celu pracy, określeniem *reprezentacja niezdominowanych klasyfikatorów*.

Jak już pisałem, autor w pracy nic nie wspomniał na temat proponowanych przez niego różnych reprezentacji rozwiązań dla postawionych zadań wielokryterialnych. Przeciwnie, w opisie CENA unikał podania informacji na temat, jak kodowane są osobniki. Z treści pracy wynika natomiast, że CENA poszukuje konkretnych rozwiązań, tj. klasyfikatorów. Dlatego odniosę się do tej hipotezy tak, jakby brzmiała *Równoczesne wykorzystanie wybranych metryk* [..] *umożliwia wyznaczenie* [–] *niezdominowanych klasyfikatorów* [..] (skróty oznaczone przez [..] służą lepszemu wyeksponowaniu głównych części zdania, natomiast znak [–] wskazuje miejsce, gdzie wcześniej stało słowo *reprezentacja*). Hipoteza sformułowana przez autora nie jest dobra, ponieważ jest ona z definicji prawdziwa, tzn. nie wymaga dodatkowego wykazania jej prawdziwości, więc nie można jej podważyć. Dla poprawnie zdefiniowanego problemu wielokryterialnego, jeżeli tylko w ogóle istnieje niepusty zbiór jego rozwiązań dopuszczalnych, to po odwzorowaniu elementów z dowolnego niepustego podzbioru tego zbioru do przestrzeni funkcji oceniających musi istnieć przynajmniej jeden taki punkt w tej przestrzeni, który jest niezdominowany lub słabo zdominowany względem pozostałych, tj. jest rozwiązaniem optymalnym w sensie Pareto. Proponowana przez autora hipoteza ujawnia braki w umiejętności precyzyjnego, jednoznacznego wysławiania się, przy czym stało się to w najbardziej newralgicznym momencie pracy, w sformułowaniu hipotezy badawczej. Budzi to podejrzenia, że autor nie wie, co chciał wykazać w swojej pracy i jaki miał być jego oryginalny wkład w rozwój dyscypliny.

Na czym polega oryginalność rozprawy, co stanowi samodzielny i oryginalny dorobek autora, jaka jest pozycja rozprawy w stosunku do stanu wiedzy czy poziomu techniki reprezentowanych przez literaturę światową?

W Streszczeniu znajduje się zdanie *Opracowano oryginalny algorytm wielokryterialnej oceny wiarygodności kredytowej CENA (ang. Creditworthiness Evolutionary Neural Assessment), która jest oparta na algorytmie ewolucyjnym modyfikującym populację sztucznych sieci neuronowych.* Algorytm ten jest opisany w rozdziale 5, str. 88-92. Pseudokod tego algorytmu znajduje się na rys. 5.1, str. 89.

Zrozumienie działania CENA na podstawie rozdziału 5 jest szczególnie trudne, ponieważ opis jest chaotyczny i niekompletny, a schemat blokowy pobieżny. Jest to algorytm iteracyjny, w którym w pętli głównej wykonują się następujące kroki:

1. obliczenie fitness dla wszystkich sieci neuronowych w populacji roboczej,
2. wsteczna propagacja błędu dla sieci, w których dodano lub usunięto warstwę,
3. krzyżowanie i mutacja osobników (tj. sieci),
4. obliczenie fitness dla sumy zbiorów osobników rodzicielskich i potomnych,
5. ustalenie nowego składu populacji roboczej.

Gdzieś w trakcie tych kroków następuje zapis do i odczyt z archiwum wybranych rozwiązań.

Aby określić szczegóły dopasowania CENA do wybranego przez autora zadania optymalizacyjnego, zamieściłem poniżej listę pięciu głównych komponentów algorytmu ewolucyjnego[2]. Ta lista posłuży mi do opisu szczegółów CENA dokładnych na tyle, na ile udało mi się dowiedzieć z tekstu pracy:

---

[2] Z. Michalewicz, Genetic Algorithms + Data Structures = Evolution Programs. Third Edition. Springer Berlin Heidelberg, 1996. doi: 10.1007/978-3-662-03315-9. str. 17

1. reprezentacja rozwiązania — autor nic nie wspomina o sposobie kodowania rozwiązania reprezentującego sieć neuronową. Zakładam, nie wiem czy słusznie, że genotyp jest taki sam jak fenotyp; potwierdzają to wymienione dalej operatory perturbacji,
2. sposób tworzenia populacji początkowej — brak precyzyjnego opisu sposobu tworzenia populacji początkowej; w schemacie blokowym na rys. 5.1, w bloku operacyjnym START jest tylko jeden równoważnik zdania zawierający pewne informacje o inicjalizacji populacji początkowej *Wygenerowanie początkowej populacji sieci o losowych wagach*,
3. funkcja ewaluacji — trzy funkcje oceny: trafność, AUC ROC oraz F_1-$score$,
4. operatory perturbacji:
   krzyżowanie — brak opisu działania krzyżowania i parametrów kontrolujących jego działanie, czy choćby nawet wskazania, które krzyżowanie z istniejących w literaturze zostało zastosowane; to dziwi, ponieważ we wcześniejszych rozdziałach autor omawia operatory krzyżowania pary sieci neuronowych przy okazji opisu innych algorytmów, np. dla algorytmu EPNet (str. 40), czy dla algorytmu NEAT (str. 43, rys. 2.2),
   mutacja — lista operatorów poniżej (brak szczegółów o tym, jak działają te operatory na reprezentacji rozwiązania i jakie parametry kontrolują ich działanie):
   a) mutacja polegająca na zamianie funkcji aktywacji w neuronie (autor wskazuje tę mutację, jako nowatorską),
   b) mutacja polegającą na dodaniu warstwy neuronów (str. 90, rys. 5.2),
   c) mutacja polegającą na usuwaniu losowo wybranej warstwy neuronów ukrytych,
   d) mutacja, która umożliwia dodanie połączenia synaptycznego między dwoma neuronami z dwóch kolejnych warstw sieci,
   e) mutacja, która dodaje neuron,
   f) mutacja, która usuwa neuron,
   g) mutacja, która dodaje połączenie synaptyczne,
   h) mutacja, która usuwa połączenie synaptyczne,
5. hiperparametry[3] — *FullBackpropagationEpoch*, *FullBackpropagationIter*, *InitialEpochsWithoutBackpropagation*, *populationmax*, *CrossoverRate*, *InterspeciesCrossoverRate*, *MultipointCrossoverRate*, *MutationRate*, *maxLayerNum*, a także wagi dla różnych rodzajów mutacji. Po nazwach można domyślać się, że dotyczą operatorów perturbacji, oraz kroku wstecznej propagacji błędu dla sieci, w których dodano lub usunięto warstwę, nie ma jednak precyzyjnej informacji, jak są wykorzystywane. Szersza lista parametrów CENA znajduje się w Dodatku A, ale to też nie jest kompletna lista, ponieważ sam autor w tytule informuje o tym czytelnika "DODATEK A. Wybrane parametry algorytmu CENA" (podkreśliłem słowo "Wybrane").

Wiadomo na pewno, że jest to algorytm z grupy opierającej swoje działanie o zależności dominacji w rozumieniu Pareto, ponieważ do porównania rozwiązań względem siebie używana jest ranga dominacji (*dominance rank*, zaproponowany przez autorów: Carlos M. Fonseca i Peter J. Fleming w ich publikacji z 1993). Nie jest to pomysł najnowszy, od tego czasu pojawiły się inne, takie jak *dominance depth* (NSGA and NSGA-II) czy *dominance count and rank* (SPEA i SPEA2). Brak uzasadnienia dla tego wyboru w treści pracy i brak w ogóle dyskusji na ten te-

[3] Parametry algorytmu ewolucyjnego, których wartości są określane przez użytkownika przed rozpoczęciem eksperymentu.

mat. CENA posługuje się dwoma zbiorami rozwiązań: populacją roboczą i archiwum, do którego w każdej generacji trafiają rozwiązania niezdominowane z bieżącej populacji roboczej. Jest to więc rodzaj elityzmu, jednak nie takiego jak w NSGA-II, tylko raczej mającego na celu gwarantowaną ochronę na bieżąco aktualizowanych najlepszych rozwiązań, taką jak w PAES (1999) czy SPEA2 (2001). Skutkiem dołączenia nowego rozwiązania do archiwum może być dla niektórych rozwiązań w archiwum zmiana stanu z niezdominowanych na zdominowane. W takim przypadku najprawdopodobniej rozwiązania zdominowane są usuwane, choć autor nie pisze o tym wprost. Mimo tego mechanizmu, archiwum po uzupełnieniu nadal może mieć rozmiar większy niż przyjęty limit (oczywiście, jeżeli archiwum ma taki limit). W schemacie blokowym autor zamieszcza blok operacyjny zawierający tekst *Zweryfikuj archiwum klasyfikatorów Pareto-optymalnych za pomocą klasyfikatorów lokalnie zdominowanych w nowej populacji;* co może oznaczać, że na nowo obliczane są rangi rozwiązań niezdominowanych przechowywanych w archiwum. Akapit na dole str. 91 może opisywać działanie procedury usuwania nadmiarowych rozwiązań z archiwum. Na początku dla wszystkich rozwiązań w archiwum obliczane są dwa parametry: geometryczna miara zagęszczenia β (ang. geometric crowding distance), która jak pisze autor *jest średnią odległością Euklidesa w zbiorze ocen* co rozumiem jako średnią odległość Euklidesową danego rozwiązania od pozostałych liczoną w przestrzeni funkcji celu (wzór 5.7). Jakość rozwiązania, która zostanie wykorzystana do wyboru rozwiązań do usunięcia, nazywana sprawnością sieci i określana symbolem *fitness*, jest liczona za pomocą wzoru 5.8, korzystającego zarówno z wcześniej policzonych wartości β jak i rang rozwiązań. Na podstawie wartości *fitness* budowany jest ranking rozwiązań niezdominowanych i za pomocą strategii elitarystycznej wybierany jest ostateczny skład. Z ostatniego akapitu, po którym zaczyna się podrozdział 5.1 (str. 92) można wnioskować że procedura eliminacji nadmiarowych rozwiązań w populacji jest stosowana do populacji roboczej, a nie ma wzmianki na temat stosowania do populacji w archiwum. Jednak gdyby archiwum miało limit, stosowanie jakiejś procedury eliminacji byłoby konieczne i mogłaby to być właśnie wskazana wyżej procedura. Brak też informacji, jak wykorzystywane jest archiwum, tj. według jakich reguł rozwiązania z archiwum trafiają do populacji roboczej.

Dodatkowym, rozszerzeniem algorytmu (względem MOGA), specyficznym dla tego konkretnego zadania optymalizacyjnego, jest wykonanie dla klasyfikatorów w populacji roboczej dodatkowego kroku wstecznej propagacji błędu w odniesieniu do zbioru uczącego jeszcze przed wykonaniem krzyżowania i mutacji. Autor nie napisał, że jest to rozszerzenie oryginalne (tak, jak to zrobił w przypadku jednego z operatorów mutacji), ale też nie wskazał publikacji, skąd miałoby pochodzić.

Możliwe, że punktem wyjścia dla autora był algorytm MOGA, który w trakcie autorskiej rozbudowy został dodatkowo wyposażony w archiwum, oraz w którym etap ustalania nowego składu populacji roboczej i archiwum korzysta z zaproponowanej przez autora funkcji *fitness*. Oryginalność tej funkcji polega na tym, że korzysta ona z dwóch parametrów rozwiązania: rangi liczonej tak jak w MOGA, oraz geometrycznej miary zagęszczenia. Można powiedzieć, że algorytm reprezentuje względnie aktualny poziom badań, ponieważ zawiera główną ramę i komponenty z algorytmów proponowanych w latach 90-ych oraz na początku lat dwutysięcznych.

Zamieszczony w pracy opis algorytmu w żaden sposób nie pozwala na jego reimplementację.

Za pomocą CENA wykonano pięć eksperymentów optymalizacyjnych na danych ze zbiorów: German Credit Data, Give Me Some Credit oraz Lending Club.

1. jednokryterialna maksymalizacja AUC ROC dla German Credit Data,
2. jednokryterialna maksymalizacja F_1-$score$ dla German Credit Data,
3. dwukryterialna optymalizacja funkcji AUC ROC i F_1-$score$ dla German Credit Data,
4. dwukryterialna optymalizacja funkcji *trafność* i F_1-$score$ dla Give Me Some Credit,
5. dwukryterialna optymalizacja funkcji *trafność*, F_1-$score$ i AUC ROC dla Lending Club.

Każdy eksperyment polegał na jednokrotnym uruchomieniu CENA dla różnego maksimum liczby generacji (do podania liczby generacji autor używa specyficznego zwrotu: Algorytm CENA wyznaczył *n* populacji). Dla eksperymentu 1 było to 1400 generacji, dla eksperymentu 2 – 700, dla eksperymentu 3 – 500, dla eksperymentu 4 – 1300 i dla eksperymentu 5 – 600 generacji (tabela 5.1, str. 104). Taka liczba uruchomień algorytmu dla każdego z eksperymentów jest niewystarczająca. Stochastyczny (losowy) charakter algorytmów ewolucyjnych nakazuje wykonywanie serii powtórzeń każdego z eksperymentów oraz stosowanie metod statystycznych w celu udowodnienia prawdziwości wniosków pochodzących z tych eksperymentów.

Czy autor wykazał umiejętność poprawnego i przekonywującego przedstawienia uzyskanych przez siebie wyników (zwięzłość, jasność, poprawność redakcyjna rozprawy)?

Autor nie wykazał umiejętności poprawnego i przekonywującego przedstawienia uzyskanych przez siebie wyników ani też metod i algorytmów, które stosował aby te wyniki osiągnąć. Opis CENA (rozdział 5) jest niewystarczający. Porównania uzyskanych wyników z wynikami innych autorów dotyczą optymalizacji jednokryterialnej (eksperymenty 1 i 2) i zostały wykonane, jednak ze względu na powtórzenie każdego z eksperymentów z CENA tylko raz, ich wyniki nie są miarodajne. Prezentacja wyników obejmuje wizualizacje znalezionych zbiorów punktów niezdominowanych, autor nie dokonał porównań, tj. nie tylko nie skorzystał z żadnego wskaźnika jakości (np. *hypervolume*), ale nawet nie użył porównań graficznych, wizualizujących znalezione zbiory rozwiązań niezdominowanych dla ustalonej, tej samej liczby wywołań funkcji celu dla kilku (dwóch) algorytmów. Opis wyników w podrozdziale 5.6 – za wyjątkiem jednego akapitu – zawiera zdania zawierające stwierdzenia, których prawdziwości nie sposób ocenić. Przykładowo zdanie *Zwraca uwagę elastyczność algorytmu ewolucyjno-neuronowego CENA polegająca na niezależności od liczby i rodzajów kryteriów cząstkowych, które użytkownik preferuje w sytuacji decyzyjnej związanej z uczeniem klasyfikatorów.* nie jest jasne, ponieważ nie wiemy, czym dla autora jest *niezależności od liczby i rodzajów kryteriów cząstkowych*. Autor nie zamieścił wyników eksperymentów porównawczych, które by potwierdzały tezę, że niezależnie od liczby i rodzajów kryteriów cząstkowych CENA radzi sobie tak samo szybko, a wyniki są tak samo dobre (wcześniej należałoby ustalić, jakie współczynniki chcemy porównać i w jakich warunkach, aby porównanie było uczciwe). Zdanie zawiera nietrywialną deklarację, ponieważ starsze MOEA radziły sobie dobrze jedynie z niewielką liczbą funkcji oceny. Dla zadań, w których zdefiniowano więcej niż trzy funkcje oceny, wyniki były istotnie gorsze. Dlatego została wyodrębniona oddzielna kategoria problemów zwana Many Objective Optimization Problems (MaOP) i dla tej kategorii rozwijane były algorytmy optymalizacyjne oparte na nieco innych zasadach działania. Gdyby autor rzeczywiście wykazał niezależność wyników CENA od liczby i rodzajów kryteriów cząstkowych, byłby to znaczący wkład

w dyscyplinę badawczą. Inne zdanie *Istotną zaletą algorytmu CENA jest jego uniwersalność rozumiana jako zdolność do przetwarzania różnorodnych zbiorów wniosków kredytowych.* też nie wiem, jak traktować: o jakie przetwarzanie chodziło i o jak bardzo różnorodne zbiory?

Jakie są słabe strony rozprawy i jej główne wady?

Na początek listę słabych stron i wad pracy należałoby zacząć od złego sformułowania hipotezy badawczej, celu pracy i zadania badawczego. Hipotezą musi być zdanie, którego prawdziwość dopiero należy udowodnić poprzez przeprowadzone i zaprezentowane w pracy badania dające nowy wkład w dziedzinę badawczą. Ma też na koniec służyć recenzentom jak najważniejsze kryterium oceny pracy: czy autor zdołał czy nie zdołał wykazać prawdziwości tej hipotezy. Obecna postać hipotezy nie daje takiej możliwości.

Oceniając od strony merytorycznej przywiązuję największą wagę do proponowanego algorytmu ewolucyjnego, w tym do proponowanego wkładu autorskiego, oraz wyników badań eksperymentalnych i wniosków, ponieważ tytuł pracy stawia w środku zainteresowań tematykę algorytmów ewolucyjnych, a praca należy do dyscypliny "informatyka techniczna i telekomunikacja". Przeprowadzony zakres badań, już niezależnie od tego, jakiej hipotezy badawczej dotyczy, jest niewielki. Autor zaproponował nowy algorytm MOEA opierając się na schemacie działania MOGA ale też wprowadzając w nim własne propozycje zmian. Wprowadził też nowe funkcje oceny do zadań wielokryterialnych. Wykonał eksperymenty, które miały pokazać, że na różnych zbiorach danych CENA znajduje zbiory rozwiązań niezdominowanych, przybliżających się w kolejnych iteracjach do frontu Pareto. Poza tym, nie było żadnego innego planu eksperymentów, tj. takiego którego celem było zbadanie elementów nowatorskich. Niestety, liczba przeprowadzonych eksperymentów nawet w tym niewielkim zakresie jest stanowczo za mała. W dzisiejszych czasach, kiedy można korzystać z maszyn wirtualnych w chmurze nawet bezpłatnie[4], nie ma wymówki dla tak znikomego zbioru testów eksperymentalnych. Nie opisano żadnych eksperymentów mających na celu np. znalezienie najkorzystniejszych ustawień parametrów CENA, czy też badań nad znaczeniem wprowadzonych w algorytmie oryginalnych rozszerzeń (choćby np. testy z włączonym i wyłączonym krokiem wstecznej propagacji, albo z różnymi długościami cyklu stosowania tego kroku), brak też porównań z wynikami innych algorytmów MOEA, choćby np. z oryginalnym MOGA. Pewne obserwacje porównawcze można znaleźć w pracy dla eksperymentów optymalizacji jednokryterialnej, jednak porównania dotyczą jakości rozwiązań z dziedziny, tj. trafności klasyfikatorów, w porównaniu z wynikami dla innych klasyfikatorów opublikowanych w literaturze. Nie ma tam dyskusji nad znaczeniem tych elementów w algorytmie CENA, które są nowe względem MOGA, w kontekście oceny jakości znalezionego zbioru rozwiązań niezdominowanych.

Ocena zawartości rozdziałów wygląda następująco:

Do wystarczających składowych pracy należą: opis algorytmów neuro-ewolucyjnych obecnych w literaturze oraz podstaw sieci neuronowych (rozdział 2), opis wybranych publicznie dostępnych zbiorów danych (rozdział 3). Także wystarczająca jest zawartość rozdziału 4 (niezależnie od tego, jaki ma tytuł), który jest zbiorem różnych informacji. Znajdujemy tam opis benchmarków testowych reprezentujących zadania klasyfikacji wniosków kredytowych, opis sposobu traktowa-

[4] np. https://cloud.pionier.net.pl/

nia tych danych jako zadania wielokryterialnego (niepotrzebnie przekombinowany) z przykładami z literatury, oraz opis relacji Pareto miedzy punktami w przestrzeni wielowymiarowej.

Za niewystarczający uważam przegląd literatury w rozdziale 1 w zakresie algorytmów ewolucyjnych (podrozdziały 1.8 i 1.9), który jest chaotyczny i sygnalizuje braki wiedzy autora nie tylko o tym, jak dobierać i gdzie wstawiać cytowania, ale także jak w formie przeglądu opisywać istniejące osiągnięcia badawcze. Nieudany jest opis algorytmu CENA (rozdział 5), który zawiera braki w opisie tak znaczne, że nie tylko nie pozwalają na odtworzenie algorytmu i przeprowadzonych badań, ale nie dają nawet szansy na wydedukowanie bądź zgadnięcie, jak mogłyby wyglądać nie opisane składowe algorytmu. Tu pozwolę sobie na przypomnienie, że jest to znacząca wada, ponieważ odtwarzalność (reproducibility) oraz powtarzalność (replicability) prezentowanych badań jest miarą oceny rzetelności naukowca i przeprowadzonych przez niego badań. Dołączenie na płycie DVD kodu programu CENA do pracy doktorskiej nie uzupełnia tych braków. Nie jest zadaniem recenzenta wyszukiwanie w kodzie tych fragmentów, które pozwalają na poznanie tego, co nie zostało opisane w pracy, ani też nie jest takim zadaniem dorobienie brakujących eksperymentów, których nie zrobił autor.

Poniżej szczegółowa lista uwag od strony merytorycznej:

1. Oceniając od strony merytorycznej należy zacząć od obrazu wiedzy autora o dziedzinie, której dotyczyły badania, i którą wykazał się w przeglądzie literatury. Ta wiedza jest niewielka. Przeglądy literatury dotyczące algorytmów ewolucyjnych są chaotyczne, niektóre opisy materiału prezentowanego w cytowanych publikacjach są błędne, a czasem cytowań brak, przez co mam wątpliwość, czy autor wie, o czym pisze i czy zapoznał się z wybranymi przez siebie publikacjami, zanim je zacytował. Miejscami autor ujawnia swoje braki w podstawowej wiedzy pisząc niezrozumiałe zdania o działaniu algorytmów ewolucyjnych, np. *Istotną rolę odgrywa nacisk selektywny, czyli własność algorytmu ewolucyjnego do poprawiania średniej wartości przystosowania populacji.* (str. 31) czy porównanie selekcji rankingowej i turniejowej *Przykładem selekcji rankingowej może być losowanie z jednakowym prawdopodobieństwem pary osobników, a następnie wyznaczenie zwycięzcy o wyższej pozycji w rankingu. Natomiast w wypadku selekcji turniejowej (ang. tournament selection) również jest losowana podpopulacja, ale następnie wybiera się osobnika o najwyższej wartości przystosowania.* (str. 32).
2. nowatorski wkład autora w algorytmie CENA określony na podstawie tego, co autor opisał (nowa funkcja *fitness* i jej reguły wykorzystania, dodatkowy krok propagacji wstecznej w algorytmie oraz ewentualnie zasady wykorzystania archiwum, o których jednak nic nie wiadomo) w ogóle nie został przebadany pod względem jego znaczenia dla poprawy jakości wyników.
3. Nie sposób traktować stworzenia reprezentacji sieci neuronowej do wykorzystania w algorytmie ewolucyjnym jako wkład nowatorski, nie tylko dlatego, że autor nic o tym nie pisze. Również dlatego, że reprezentacje sieci neuronowych w algorytmach ewolucyjnych były już proponowane, o czym sam autor pisze w rozdziale 1.8, str. 32, i jeżeli nowa reprezentacja miałby stanowić wkład nowatorski, należałoby ja zaprezentować i przedstawić argumenty (np. wyniki eksperymentów) za stosowaniem tej reprezentacji, a nie innych. Tego w pracy nie ma.

4. Również operatory krzyżowania i mutacji można byłoby uznać za nowatorskie pod warunkiem, że autor opisałby ich działanie w sposób precyzyjny i kompletny oraz wskazał i wykazał ich nowatorskość. Nie zrobił tego.
5. Być może jest więcej elementów algorytmu, które można byłoby uznać za nowatorskie, gdyby autor opisał go dokładnie. Opis jest jednak ogólnikowy i pozostawia wiele luk.
6. Brak jest opisu metodologii badań i planu eksperymentów w części opisującej badania eksperymentalne.
7. Autor nie dochował staranności przy stosowaniu zasad eksperymentu naukowego. Przeprowadzone eksperymenty są pod względem metodologii badań właściwej dla algorytmów optymalizacji heurystycznej niedostateczne, dlatego wnioski z tych eksperymentów nie mają umocowania w wiarygodności badań eksperymentalnych.
8. Zakres badań jest minimalny, autor uruchomił algorytm po razie dla każdego zestawu benchmarkowego chyba tylko po to, żeby zobaczyć, czy coś w ogóle zwraca.
9. Brak celu w badaniach eksperymentalnych, nic nie zostało przebadane, bo żadna teza nie była weryfikowana w badaniach eksperymentalnych (nie licząc hipotezy badawczej, która jednak, jak już pisałem wcześniej, nie wymagała żadnych badań eksperymentalnych do wykazania prawdziwości).
10. Algorytm CENA oraz uzyskane wyniki badań nie zostały zweryfikowane przez środowisko naukowe. Autor nie wskazuje żadnego artykułu, którego byłby autorem lub współautorem, i który prezentuje algorytm CENA i badania eksperymentalne na recenzowanej międzynarodowej konferencji czy w recenzowanym czasopiśmie.

W kontekście powyższych stwierdzeń nie mogę się zgodzić ze stwierdzeniem autora, że

Efektem rozprawy jest model matematyczny opisujący wybrane sytuacje udzielania kredytu, sformułowanie wielokryterialnego zadania optymalizacji klasyfikatorów kredytowych, a także opracowanie wielokryterialnego algorytmu do oceny wiarygodności kredytowej na wybranych zestawach danych. Algorytm ewolucyjnych sieci neuronowych został wszechstronnie i wielowariantowo zweryfikowany w wypadku treningu sieci neuronowych dla wybranych kryteriów skalarnych: trafność, powierzchnia pola pod krzywą ROC oraz F1 – Score. (str. 7)

Oceniając od strony formalnej, praca reprezentuje niski i raczej nieakceptowalny poziom. Autor nie potrafi w sposób uporządkowany przedstawić informacji pochodzących z przeglądu literatury oraz swoich badań, nieumiejętnie dobiera cytowania, późno zamieszcza objaśnienia i referencje bibliograficzne do niektórych pojęć. Choć praca zawiera rozdziały o tytułach bliskich poprawnej strukturze pracy doktorskiej, to treść niektórych z nich jest źle zorganizowana, słownictwo techniczne jest źle objaśnione albo w ogóle nie objaśnione i używane różnie w różnych kontekstach, czasem niezrozumiała jest kolejność podawania informacji, brak też czasem wręcz oczywistego podziału na dodatkowe podpodrozdziały. Autor niespodziewanie zmienia w kolejnych akapitach dotychczas stosowane określenia pojęć na ich synonimy, np. "rozwiązanie Pareto-optymalne" i "rozwiązanie niezdominowane", "algorytm ewolucyjnych sieci neuronowych" i "algorytm neuro-ewolucyjny", "polioptymalizacja" i "optymalizacja wielokryterialna" oraz "optymalizacja wektorowa". Miesza także użycie zwrotu "model klasyfikacji" i słów "klasyfikator" lub "rozwiązanie" względem bieżącego kontekstu. Nietrafne użycie zwrotu "model klasyfikacji" dobrze widać np. przy objaśnianiu

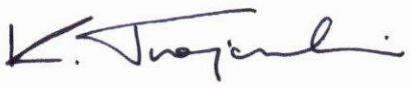
relacji dominacji na stronie 84. Generalnie autor w całej pracy nadużywa słów "model" i "reprezentacja", chyba nie całkiem rozumiejąc znaczenia tych słów. Przez to stworzył nie raz błędne określenia, albo nie te, które miał na myśli (w tym najprawdopodobniej również hipotezę badawczą). Z tych powodów praca jest szczególnie trudna w odbiorze.

Jaka jest przydatność rozprawy dla nauk technicznych?

Praca wpisuje się w dziedzinę nauk technicznych: obejmuje swoim zakresem badania nad podnoszeniem efektywności heurystycznych metod optymalizacji. Jednak ze względu na braki w opisie algorytmu, niewielki zakres badań eksperymentalnych oraz braki metodologiczne w tych badaniach mające znaczenie dla wiarygodności poczynionych obserwacji, nie sposób określić, czy uzyskane wyniki należy uznać za użyteczne dla nauk technicznych.

Konkluzja końcowa

Podsumowując uważam, że rozprawa doktorska mgr inż. Marcina Zakidalskiego nie spełnia wymagań stawianych rozprawom doktorskim przez obowiązującą ustawę o stopniach naukowych i tytule naukowym oraz o stopniach i tytule w zakresie sztuki z dnia 14 marca 2003 r. (Dz. U. Nr. 65 poz. 595 z późniejszymi zmianami) z późniejszymi zmianami w brzmieniu z dnia 15 września 2017 r. (Dz. U. 2017 r. poz. 1789.), zgodnie z Art. 175. 1. Ustawy z dnia 3 lipca 2018 r. Przepisy wprowadzające ustawę — Prawo o szkolnictwie wyższym i nauce (Dz.U. 2018 r. poz. 1669). W przedłożnej do recenzji rozprawie doktorant nie dowiódł posiadania wystarczającej ogólnej wiedzy teoretycznej z tego obszaru dyscypliny badawczej "informatyka techniczna i telekomunikacja", którego dotyczyła rozprawa, oraz kompetencji do samodzielnego prowadzenia pracy naukowej. Rozprawy nie można uznać za oryginalne rozwiązanie problemu naukowego w oparciu o opisany w rozprawie sposób przeprowadzenia badań oraz sposób ich zreferowania. Z tego powodu wnioskuję o niedopuszczenie mgr inż. Marcina Zakidalskiego do dalszego etapu przewodu doktorskiego.



dr hab. inż. Krzysztof Trojanowski