

Recenzja rozprawy doktorskiej
mgr. inż. Mateusza Zaborskiego

zatytułowanej:

Efektywne zastosowania metamodeli w algorytmach populacyjnych przeznaczonych do rozwiązywania problemów optymalizacji ciągłej

1. Problem badawczy i jego znaczenie

Recenzowana rozprawa dotyczy zastosowania metamodeli w algorytmach populacyjnych przeznaczonych do optymalizacji ciągłej w rozwiązywaniu problemów czarnoskrzynkowych, tj. takich w których wiedza o funkcji celu polega jedynie na możliwości obliczenia wartości tej funkcji dla poszczególnych argumentów. Kryterium czarnoskrzynkowości stosowane w rozprawie ma charakter operacyjny a jego celem jest uzyskanie uniwersalności opracowywanych metod, gdyż jak sam Autor zauważa, w praktyce w przypadku niewielu funkcji celu nie są dane żadne intuicje odnośnie ich kształtu.

Algorytmy populacyjne bazują na losowości metodami niedeterministycznymi, których każdorazowy przebieg prowadzi do znalezienia innego rozwiązania obciążonego stosownym błędem. Ponadto algorytmy populacyjne na ogół charakteryzują się stosunkowo dużymi budżetami optymalizacji, tzn. pozwalają na obliczenie wartości funkcji celu dla relatywnie dużej liczby jej argumentów. Istnieje jednak klasa problemów dla których czas pojedynczej ewaluacji funkcji celu (obliczania jej wartości dla zadanego argumentu) jest znaczący – optymalizacja dla problemów tej kategorii jest nazywana optymalizacją kosztowną. Za jej przykład mogą posłużyć symulacje procesów fizycznych dla których ewaluacja funkcji celu dla pojedynczego wektora argumentów często trwa kilka godzin a w skrajnych przypadkach dochodząc do stu kilkudziesięciu godzin, przykładowo symulacje możliwych scenariuszy rozwoju pożaru w budynku publicznym prowadzone przy akceptacjach projektów architektonicznych. Aby podołać wyzwaniom optymalizacji kosztownej w literaturze zaproponowano wykorzystywanie metamodeli będących reprezentacjami przybliżającymi funkcję celu dla których obliczenie wartości w danym punkcie jest o wiele szybsze od ewaluacji funkcji celu dla tego punktu.

Obecnie dużym wyzwaniem w dziedzinie uczenia maszynowego są problemy związane z koniecznością szybkiej eksploracji bardzo dużych i dynamicznie przyrastających zbiorów danych. Tematyka ta jest niezwykle istotna, zarówno pod kątem podstaw teoretycznych, jak i zastosowań praktycznych metod uczenia maszynowego a odpowiedzią na te wyzwania są badania mające na celu zwiększanie wydajności opracowywanych metod, zmniejszanie ich złożoności obliczeniowej. W ten nurt badań wpisuje się swoją rozprawą Doktorant prezentując w niej badania teoretyczne i eksperymentalne dotyczące osiągnięcia akceptowalnych kosztów obliczeniowych dla poszczególnych typów optymalizacji.

Wiodącą metodą rozwiązującą problemy optymalizacji kosztownej jest optymalizacja bayesowska wspierana metamodelem Kriginga. W swoich badaniach teoretycznych Autor zestawia optymalizację bayesowską z algorytmami populacyjnymi (algorytmami ewolucyjnymi i algorytmami rojowymi) wskazując m.in. na znaczącą lukę w kontekście zakładanych przez nie budżetów pomiędzy budżetem optymalizacji kosztownej a budżetem optymalizacji taniej, co skutkowało zaproponowaniem nowej kategorii optymalizacji nazwanej przez Doktoranta optymalizacją semikosztowną. W analizach empirycznych Autor wykorzystał metamodel Kriginga jako jeden z punktów odniesienia dla opracowywanych przez siebie metod, skutkując wyborem regresji wielomianowej jako metamodelu wykorzystywanego w optymalizacji. W swoich badaniach Autor skupił się na algorytmach ewolucyjnych, mianowicie na metodach bazujących na ewolucji różnicowej i metodach bazujących na adaptacji macierzy kowariancji jako metodach dominujących obecnie ze względu na wyniki osiągnięte na używanych współcześnie zbiorach testowych. Ujmując rzecz obrazowo, w zagadnieniu optymalizacji Autor otworzył czarną skrzynkę i ulokował w niej algorytmy ewolucyjne wspierane regresją wielomianową jako metamodelem uzyskując bardzo dobre wyniki w analizie danych.

Hipotezy badawcze rozprawy dotyczą aspektów wydajnościowych opracowywanych w rozprawie metod. Dwie pierwsze hipotezy dotyczą zastosowań metamodeli w algorytmach populacyjnych w celu poprawy wyników algorytmów w optymalizacji taniej bądź semikosztownej. Trzecia hipoteza dotyczy zastosowania preselekcji rozwiązań w sposób niewymagający przekształcania mechanizmu adaptacji parametrów. Natomiast czwarta hipoteza dotyczy możliwości powiązania metamodelu z algorytmem populacyjnym pozwalającej na rekurencyjną estymację algorytmu skutkującą brakiem konieczności budowy archiwum próbek. Wszystkie hipotezy znalazły potwierdzenie w trakcie badań empirycznych przeprowadzonych w ramach przygotowywania rozprawy i w niej sprawozdawanych. O wadze i znaczeniu uzyskanych przez doktoranta rezultatów świadczy fakt, że znalazły one uznanie międzynarodowego grona badaczy i zostały przedstawione w dziewięciu międzynarodowych publikacjach, w tym w sześciu pracach przedstawionych na dobrych międzynarodowych konferencjach i trzech artykułach opublikowanych w wiodących czasopismach informatycznych publikujących prace z zakresu uczenia maszynowego.

2. Wkład autora

Wśród osiągnięć przedstawionych w rozprawie znajdują się zarówno wyniki teoretyczne jak i empiryczne. Do osiągnięć teoretycznych należy wprowadzenie kategorii optymalizacji semikosztownej. Przegląd literatury przeprowadzony przez Doktoranta wykazał niejednoznaczne rozumienie pojęć optymalizacji kosztownej i optymalizacji taniej wynikające z różnorodności problemów optymalizacji oraz ujawnił znaczącą lukę pomiędzy granicami optymalizacji kosztownej i taniej. Dla zapełnienia tej luki Doktorant wprowadza nowy rodzaj optymalizacji, mianowicie optymalizację semikosztowną jednocześnie opierając podział na dostępnym budżecie optymalizacji w przeciwieństwie do dominującego do tej pory w literaturze określenia optymalizacji kosztownej i optymalizacji taniej na podstawie kosztu ewaluacji. Oczywiście oba te kryteria są ze sobą powiązane, przykładowo im większa złożoność czasowa ewaluacji funkcji celu, tym mniejszy budżet optymalizacyjny tej ewaluacji, jednakże proponowane podejście nie jest tylko arbitralnym przesunięciem akcentu. Przeciwnie, jest ono podyktowane przez dążenie Doktoranta do opracowania metod uniwersalnych jako bardziej adekwatnych do rozwiązywania problemów czarnoskrzynkowych.

Do istotnych osiągnięć teoretycznych rozprawy należy zaliczyć również zdefiniowanie efektywnego zastosowania metamodelu w algorytmie populacyjnym. Definicja składa się z czterech kryteriów: (1) zastosowanie metamodelu pozwala na osiągnięcie budżetów optymalizacji semikosztownej lub taniej, (2) narzut obliczeniowy metamodelu skutkujący dłuższym wykonaniem algorytmu pozostaje na akceptowalnym poziomie, (3) algorytm populacyjny wspierany danym metamodelem osiąga lepsze wyniki względem innego algorytmu populacyjnego wspieranego metamodelem lub względem algorytmu bazowego, (4) proponowany algorytm populacyjny wspierany metamodelem jest możliwie uniwersalny, tzn. uzyskuje zadowalające wyniki w rozwiązywaniu szerokiej klasy problemów czarnoskrzynkowych. W proponowanej definicji efektywności zastosowania metamodelu bazowym algorytmem populacyjnym jest wybrany algorytm z rodziny algorytmów ewolucji różnicowej lub z rodziny algorytmów opartych o strategię ewolucyjną wykorzystującą adaptację macierzy kowariancji. Proponowana definicja pozwala ujednoclić ocenę efektywności zastosowania metamodeli w metodach wprowadzonych w empirycznej części rozprawy a poprzez to pozwala na uniknięcie oceny ad hoc każdego z algorytmów z osobna. Ponadto wprowadzone pojęcie jest propozycją ustandaryzowania rozumienia efektywności zastosowań metamodeli w algorytmach populacyjnych.

Jedną z kluczowych kwestii recenzowanej rozprawy jest wybór metamodelu, który zostanie wykorzystany do opracowania nowych algorytmów populacyjnych wspieranych metamodelem. W wyniku analizy literatury dotyczącej algorytmów populacyjnych wspieranych metamodelem Doktorant stwierdził brak spójnej metodologii badania narzutu obliczeniowego metamodeli. Wyboru metamodelu nie dokonał jednak arbitralnie, lecz zaplanował i przeprowadził własne badanie eksperymentalne czasu estymacji parametrów metamodelu. W badaniu tym zostały porównane metamodel Kriginga, w którym za model regresji przyjęto liniową regresję wielomianową, radialna funkcja bazowa $h(r) = r^3$, kwadratowa regresja wielomianowa (RW) oraz kwadratowa regresja wielomianowa z interakcjami. Należy podkreślić, że z punktu widzenia teoretycznej analizy złożoności obliczeniowej metamodeli prezentowanej w rozdziale 4, taki eksperyment okazał się konieczny, gdyż kwadratowa regresja wielomianowa oraz wybrana do badań radialna funkcja bazowa lokują się w tej samej klasie złożoności. Analizy teoretyczne i eksperymentalne przeprowadzone przez Doktoranta stanowią dobrą podstawę do dalszych badań mających na celu opracowanie spójnej metodologii badania narzutu obliczeniowego tudzież metodologii wyboru między różnymi metamodelami wykorzystywanymi do opracowania nowych algorytmów. Wyniki tych badań prezentowane są w rozdziale 5 w tabelach 5.1 i 5.2. Wyniki przedstawione w tabeli 5.1 ukazują, że dla zbiorów uczących o liczności większej niż 100 czas estymacji parametrów RBF jest istotnie większy niż czas estymacji parametrów kwadratowej RW i kwadratowej RW z interakcjami. Przełożyło się to na wybór kwadratowej RW i kwadratowej RW z interakcjami do zastosowania jako metamodele w algorytmach populacyjnych wprowadzonych i przebadanych w rozdziale 7 rozprawy.

Ponadto wyniki przedstawione w tabelach 5.1 i 5.2 mają również walor edukacyjny, ilustrujący odmienność teoretycznych i eksperymentalnych sposobów określania złożoności obliczeniowej algorytmów. Przykładowo, tabela 5.2 pokazuje, że przy niewielkiej liczbie wymiarów kwadratowa RW i kwadratowa RW z interakcjami w eksperymentach uzyskują te same bądź zbliżone wartości w przypadku czasu estymacji ich parametrów, choć należą do różnych klas złożoności obliczeniowej (patrz ostatnie akapity podrozdziału 4.3.1).

W części empirycznej rozprawy przedstawiono i przeanalizowano eksperymentalnie pięć algorytmów populacyjnych wykorzystujących metamodel mianowicie M-GAPSO, SHADE-LM, LQ-R-SHADE, psLSHADE oraz rmmLSHADE. Poza algorytmem SHADE-LM Autor rozprawy stworzył koncepcję opracował i zaimplementował pozostałe cztery algorytmy oraz przeprowadził badania eksperymentalne ich działania. Autor w rozprawie zaproponował cztery sposoby zastosowania metamodeli do wsparcia algorytmów ewolucyjnych: (1) inicjalizację metamodelem, (2) lokalną optymalizację metamodelem, (3) preselekcję rozwiązań na podstawie wartości metamodelu oraz (4) rekurencyjną estymację parametrów metamodelu. Algorytmy M-GAPSO, SHADE-LM, LQ-R-SHADE, psLSHADE oraz rmmLSHADE powstały na bazie wprowadzonych wcześniej algorytmów populacyjnych GAPSO, SHADE, R-SHADE i L-SHADE poprzez integrację tych algorytmów z metamodelami przeprowadzoną na różne sposoby. Nowowprowadzone algorytmy w testach wykazały się skutecznością i były bardziej efektywne od ich algorytmów bazowych.

Szczególną uwagę przyciąga lokalna optymalizacja metamodelem, w której metamodel ingeruje w miejsce gdzie algorytm populacyjny próbkuje otoczenie. Optymalizację metamodelem zastosowano w M-GAPSO i w SHADE-LM, w algorytmach tych zastosowano również inicjalizację metamodelem. M-GAPSO zakłada wykorzystanie dwóch metamodeli, mianowicie metamodelu kwadratowego i metamodelu wielomianowego. Topologicznie rzecz ujmując, w metamodelu kwadratowym w konstruowaniu zbioru uczącego wykorzystuje się kule euklidesowe w przestrzeni wielowymiarowej. Natomiast w konstruowaniu zbioru uczącego w metamodelu wielomianowym stosuje się kule euklidesowe w przestrzeniach jednowymiarowych wyznaczonych przez poszczególne wymiary zbioru uczącego a następnie kule te nakładają się na siebie – ta matematyczna różnica została przez Autora przejrzysto przedstawiona na rysunku 6.1. Algorytm SHADE-LM powstał z algorytmu R-SHADE poprzez zastosowanie w R-SHADE mechanizmu lokalnej optymalizacji metamodelem. Testy eksperymentalne wykazały, że zastosowanie lokalnej optymalizacji metamodelem polepszyło wyniki uzyskane przez M-GAPSO i SHADE-LM względem algorytmów bazowych GAPSO i R-SHADE, szczególnie dla większych wymiarów. Narzut czasowy wykonania M-GAPSO i SHADE-LM okazał większy niż dla GAPSO i SHADE-LM ale pozostał na wystarczająco akceptowalnym poziomie pozwalającym zachować budżet obliczeniowy na niewielkim poziomie. Pozwala to uznać lokalną optymalizację metamodelem za przykład **optymalizacji taniej co potwierdza hipotezę pierwszą rozprawy**. Należy również podkreślić, że w badaniach nad M-GAPSO i SHADE-LM nastąpił zasadniczy zwrot metodologiczny w rozprawie. Algorytm M-GAPSO powstał na bazie algorytmu GAPSO, który jest algorytmem hybrydowym, rojowo-ewolucyjnym, jeśli można tak powiedzieć, natomiast w algorytmie SHADE-LM i w kolejnych wprowadzonych i badanych w rozprawie algorytmach metamodele zastosowano do wspierania wyłącznie algorytmów ewolucyjnych.

Cechą wspólną algorytmów LQ-R-SHADE, psLSHADE oraz rmmSHADE jest wykorzystywanie mechanizmu preselekcji rozwiązań na podstawie wartości metamodeli. Warto również dodać, iż algorytmy LQ-R-SHADE, psLSHADE oraz rmmSHADE bazują na algorytmie SHADE, który zakłada adaptację dwóch parametrów, mianowicie czynnika skalującego oraz prawdopodobieństwa krzyżowania, dziedzicząc po SHADE ten mechanizm.

Algorytm LQ-R-SHADE jest rozszerzeniem algorytmu R-SHADE o mechanizm **lokalnej** preselekcji rozwiązań oparty o zaczerpniętą z algorytmu lq-CMA-ES kaskadę metamodeli złożoną z liniowej regresji wielomianowej (RW), kwadratowej RW oraz kwadratowej RW z interakcjami, tzn. gdy liczność zbioru uczącego jest niewystarczająca do estymacji parametrów kwadratowej RW z interakcjami, to stosowana jest kwadratowa RW i analogicznie, gdy liczność zbioru uczącego jest niewystarczająca dla estymacji parametrów kwadratowej RW, to stosowana jest liniowa RW. Dodatkowo w LQ-R-SHADE początkową populację generuje się z godnie z mechanizmem inicjalizacji metamodelem.

Analogicznie do LQ-R-SHADE rozszerzającego R-SHADE, **algorytm psLSHADE** jest rozszerzeniem algorytmu L-SHADE o mechanizm **lokalnej** preselekcji rozwiązań, natomiast w przeciwieństwie do LQ-R-SHADE zrezygnowano w psLSHADE z mechanizmu inicjalizacji metamodelem oraz z kaskady metamodeli w miejsce której zastosowano kwadratową RW z interakcjami poszerzoną o dwa nieliniowe komponenty. Rezygnacja z kaskady metamodeli podyktowana była eksperymentalną ewaluacją algorytmu LQ-R-SHADE, która pokazała, że inicjalizacja metamodelem ma marginalne znaczenie przy uwzględnieniu całego budżetu optymalizacji semikosztownej. W rezultacie zastosowanych modyfikacji uzyskano algorytm mniej złożony od LQ-R-SHADE lecz z bardziej zaawansowanym metamodelem (poszerzonym o dwa nieliniowe komponenty) co jest wyrazem zasadniczej idei recenzowanej rozprawy polegającej na poszukiwaniu efektywnych zastosowań metamodeli poprawiających wyniki algorytmu populacyjnego przy zachowaniu jego uniwersalności.

Algorytm rmmSHADE podobnie jak algorytmy LQ-R-SHADE oraz psLSHADE jest algorytmem populacyjnym wykorzystującym mechanizm preselekcji rozwiązań oraz podobnie do psLSHADE algorytm rmmSHADE jest rozwinięciem L-SHADE. Natomiast w odróżnieniu od psLSHADE w algorytmie rmmSHADE preselekcja rozwiązań jest realizowana w sposób **globalny** co ma na celu dalsze upraszczanie logiki rozwiązań. Ponadto w algorytmie rmmSHADE w charakterze metamodelu wykorzystano kwadratową RW z interakcjami natomiast rekurencyjna estymacja parametrów metamodelu wykorzystuje rekursywny filtr najmniejszych kwadratów (filtr RLS; Recursive Least Squares filter) co powoduje, że konstruowanie zbioru uczącego jest niepotrzebne.

W badaniach eksperymentalnych algorytmy LQ-R-SHADE, psLSHADE, rmmSHADE wykorzystujące mechanizm preselekcji rozwiązań z wykorzystaniem metamodelu globalnego osiągnęły w **przedziale optymalizacji semikosztownej** wyniki lepsze od ich algorytmów bazowych co **dostarczyło potwierdzenia drugiej hipotezy**. Ponadto, w trakcie badań eksperymentalnych nad algorytmami LQ-R-SHADE, psLSHADE, rmmSHADE zastosowanie mechanizmu preselekcji rozwiązań zarówno w wariancie lokalnym (LQ-R-SHADE, psLSHADE) jak i w wariancie globalnym (rmmSHADE) **nie wpłynęło** na konstrukcję mechanizmu adaptacji parametrów co **dostarczyło potwierdzenia hipotezy trzeciej**. Następnie badania eksperymentalne pokazały, że w algorytmie rmmSHADE estymacja parametrów kwadratowej regresji wielomianowej **odbywa się za pomocą** filtra RLS i tym samym wykorzystywanie archiwum próbek **jest niepotrzebne co dostarczyło potwierdzenia hipotezy czwartej**.

3. Poprawność

Rozprawę czyta się z dużą przyjemnością ze względu na klarowność pojęciową analiz prowadzonych w rozprawie oraz ze względu na jej elegancję językową. Zarówno zagadnienia przytaczane z literatury jak i własne wyniki Autor prezentuje przejrzyście i dogłębnie, za przykład mogą posłużyć klarowne opisy algorytmów występujące w rozprawie. Eksperymenty są zaprojektowane i przeprowadzone poprawnie a ich plany są właściwie dobrane względem testowanych hipotez badawczych. Rozstrzygnięcia teoretyczne i dobór metod empirycznych są właściwie uzasadniane. Autor dba również o czytelnika wzbogacając tekst główny rozprawy umiejętnie dobranymi rysunkami, wykresami i tabelami.

Rozprawa jest napisana i zredagowana starannie zawierając niewiele literówek. Dwie z nich, występujące we wzorach wymagają wspomnienia. Mianowicie na stronie 26 w ostatniej linii we wzorze zamiast oznaczenia zbioru S powinno pojawić się oznaczenie wektora x . Analogiczny błąd pojawia się dwie strony dalej, w ostatnim akapicie podrozdziału 2.2 na stronie 28 z tą różnicą, że można go poprawić na dwa sposoby: zamieniając oznaczenie zbioru S na oznaczenie wektora x albo zamieniając symbol relacji należenia do zbioru na symbol relacji inkluzji zbiorów, zależnie od intencji Autora. Są to ewidentne literówki, ale należy je koniecznie poprawić aby nie konfundować przyszłych czytelników a szczególnie studentów stawiających pierwsze kroki w dziedzinie uczenia maszynowego.

Z edycyjnego punktu widzenia, należałoby zmienić nieco formę opisów grafiki i tabel, mianowicie zwiększyć ich marginesy, zmniejszyć nieco czcionkę tudzież zmienić czcionkę, tak by opisy te bardziej odróżniały się od tekstu głównego. Natomiast w przypadku rysunków grupujących kilka wykresów dobrze byłoby oznaczyć poszczególne wykresy, np. za pomocą liter, tak, aby ułatwić odnoszenie się do nich. Przy okazji, na diagramie na stronie 43 też można znaleźć literówki – „algortymy”.

Korekty wymaga również bibliografia recenzowanej rozprawy. Choć rozprawa napisana jest po polsku, a spis literatury zatytułowany jest słowem „Bibliografia”, to de facto jest on napisany po angielsku. W poszczególnych adresach bibliograficznych angielski przyimek „in” pojawia się w miejsce polskiego przyimka „w”, słowo „volumes” pojawia się w miejsce słowa „volumen”, które można by zastąpić skrótem „vol.” akceptowanym w obu językach, natomiast słowo „pages” pojawia się zamiast słowa „strony” tudzież skrótu „str.”.

Wskazane wyżej i dające się szybko poprawić uchybienia w niczym nie podważają zdecydowanie pozytywnej oceny rozprawy. Należy też podkreślić, że rozprawa mgr. Zaborskiego ma duże walory porządkujące i edukacyjne stanowiąc dobre wprowadzenie w dziedzinę optymalizacji funkcji i dobrze referując badania, w tym badania własne Autora, dotyczące efektywnego zastosowania metamodeli we wspieraniu działania algorytmów populacyjnych. Z metodologicznego punktu widzenia rozprawa może stanowić źródło dobrych praktyk i wzór do naśladowania dla magistrantów i doktorantów zainteresowanych prowadzeniem prac badawczych w dziedzinie uczenia maszynowego.

4. Wiedza kandydata

Rozprawa stanowi dobre wprowadzenie w dziedzinę optymalizacji ciągłej prezentując podstawowe pojęcia i zagadnienia optymalizacji funkcji oraz dostarczając dogłębny i szeroki opis stosowanych w niej metod. Autor skupia się na reprezentacji funkcji celu w optymalizacji ciągłej za sprawą rozmaitych metamodeli oraz na szerokiej prezentacji dziedziny algorytmów populacyjnych, w tym przedstawia ewolucję wybranych algorytmów ewolucyjnych dostarczając również ich szczegółowych opisów. Rozważania empiryczne prezentowane w rozdziale 5 oraz proponowane algorytmy w rozdziałach 6 i 7 wraz z ich eksperymentalną analizą wskazują na dojrzałość metodologiczną Doktoranta. W przedłożonej rozprawie Autor jawi się jako wysokiej klasy ekspert w dziedzinie optymalizacji funkcji prezentując zrozumienie podstaw teoretycznych, szeroką znajomość literatury oraz bardzo dobre przygotowanie metodologiczne do prowadzenia badań w zakresie uczenia maszynowego.

5. Podsumowanie

Biorąc pod uwagę opinie zaprezentowane w poprzednich punktach i wymagania zdefiniowane przez artykuł 13 ustawy z dnia 14 marca 2003 r. o stopniach naukowych i tytule naukowym (z późniejszymi zmianami)¹ moja ocena rozprawy pod względem trzech podstawowych kryteriów jest następująca:

A. Czy rozprawa zawiera oryginalne rozwiązanie problem naukowego? (wybierz jedną opcję stawiając znak X)?

<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
Zdecydowanie TAK	Raczej TAK	Trudno powiedzieć	Raczej NIE	Zdecydowanie NIE

B. Czy po przeczytaniu rozprawy zgadzasz się, że kandydat posiada ogólną wiedzę teoretyczną w dyscyplinie Informatyka lub Automatyka i Robotyka?

<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
Zdecydowanie TAK	Raczej TAK	Trudno powiedzieć	Raczej NIE	Zdecydowanie NIE

C. Czy kandydat posiada umiejętność samodzielnego prowadzenia pracy naukowej?


<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
Zdecydowanie TAK	Raczej TAK	Trudno powiedzieć	Raczej NIE	Zdecydowanie NIE

Podsumowując, uważam, że opiniowana rozprawa spełnia wymagania stawiane przez ustawę o tytule naukowym i stopniach naukowych w odniesieniu do rozpraw doktorskich i może być dopuszczona do publicznej obrony.



Podpis

¹ http://www.nauka.gov.pl/g2/oryginal/2013_05/b26ba540a5785d48bee41aec63403b2c.pdf



Rysunek. Krata pojęć przedstawiająca plan badań rozprawy (badane algorytmy i mechanizmy wykorzystane w ich konstrukcji) wraz z wynikami dotyczącymi kosztowności optymalizacji (Tania i Semikosztowna). Obiektami w kracie są algorytmy z rozprawy a ich nazwy są etykietowane na biało natomiast atrybutami są mechanizmy wykorzystane w konstrukcji algorytmów oraz własności optymalizacji taniej i optymalizacji semikosztownej, wszystkie etykietowane na szaro.

Lista publikacji prezentujących wyniki osiągnięte w rozprawie

1. M. Uliński, A. Żychowski, M. Okulewicz, M. Zaborski, H. Kordulewski, (2018), Generalized Self-Adapting Particle Swarm Optimization algorithm. W *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, vol. 3242, str. 29–40. Springer, Cham, 2018.
2. M. Zaborski, M. Okulewicz, J. Mańdziuk (2019) Generalized Self-Adapting Particle Swarm Optimization algorithm with model-based optimization enhancements. W *2nd PP-RAI Conference (PPRAI-19)*, str. 380–383, 2019.
3. **M. Zaborski, M. Okulewicz, J. Mańdziuk, (2020) Analysis of statistical model-based optimization enhancements in Generalized Self-Adapting Particle Swarm Optimization framework. *Foundations of Computing and Decision Sciences*, 45(3):233–254, 2020.**
4. M. Okulewicz, M. Zaborski, (2021) Benchmarking SHADE algorithm enhanced with model based optimization on the BBOB noiseless testbed. W *Proceedings of the Genetic and Evolutionary Computation Conference Companion*, pages 1259–1266, 2021.
5. M. Zaborski, J. Mańdziuk (2022): Improving LSHADE by means of a pre-screening mechanism. W *Proceedings of the Genetic and Evolutionary Computation Conference, GECCO '22*, page 884–892, New York, NY, USA, 2022. Association for Computing Machinery.
6. **M. Okulewicz, M. Zaborski, J. Mańdziuk (2022), Generalized Self-Adapting Particle Swarm Optimization algorithm with archive of samples. *Applied Soft Computing*, 131:109722, 2022.**
7. **M. Zaborski, M. Woźniak, J. Mańdziuk (2022), Multidimensional Red Fox meta- heuristic for complex optimization. *Applied Soft Computing*, 131:109774, 2022.**
8. M. Zaborski, J. Mańdziuk (2022): Surrogate-assisted LSHADE algorithm utilizing Recursive Least Squares filter. W *International Conference on Parallel Problem Solving from Nature*, pages 146–159. Springer, 2022.
9. M. Zaborski, J. Mańdziuk (2022): LQ-R-SHADE: R-SHADE with quadratic surrogate model. W *Lecture Notes in Artificial intelligence*, vol. 13588, str. 265 – 276, Springer, 2022.