



AKADEMIA GÓRNICZO-HUTNICZA IM. STANISŁAWA STASZICA W KRAKOWIE
WYDZIAŁ INFORMATYKI

Dr hab. inż. Rafał Dreżewski, prof. AGH

Instytut Informatyki
Wydział Informatyki
Akademia Górniczo-Hutnicza
im. Stanisława Staszica w Krakowie
al. Mickiewicza 30, 30-059 Kraków
e-mail: drezew@agh.edu.pl

Kraków, 26.03.2025

Recenzja rozprawy doktorskiej Pani mgr Aishy Azeez Younus zatytułowanej
„New Algorithms for Multi-objective Optimization”

Promotorem recenzowanej rozprawy doktorskiej „New Algorithms for Multi-objective Optimization” jest Prof. dr hab. Marcin Studniarski. Praca przygotowana została na Wydziale Matematyki i Informatyki Uniwersytetu Łódzkiego.

W ramach rozprawy doktorskiej zaproponowane zostały nowe wielokryterialne algorytmy ewolucyjne wykazujące w większości zbadanych przypadków lepszą wydajność niż znany z literatury algorytm NSGA-II. Zaproponowanych zostało w sumie pięć algorytmów. Dwa z nich (Non-dominated Sorting with Dissimilarity and Similarity of Chromosomes — NSDSC oraz Non-dominated Sorting with Dynamic Schema Dissimilarity and Similarity of Chromosomes — NS-DSDSC) wykorzystują operatory odmienności i podobieństwa chromosomów (ang. *dissimilarity and similarity of chromosomes* — DSC) zaproponowane w publikacji, której Doktorantka była współautorką oraz wybrane mechanizmy z algorytmu NSGA-II (*nondominated sorting* oraz *crowding distance*). Algorytm NS-DSDSC wykorzystuje ponadto mechanizm dynamicznych schematów (ang. *dynamic schema* — DS) również zaproponowany we wspomnianej powyżej publikacji, której Doktorantka była współautorką.

Kolejnymi z zaproponowanych algorytmów są algorytmy hybrydowe. Pierwszy z nich łączy NSDSC oraz NSGA-II (ang. *Hybrid NSDSC with NSGA-II* — *Hybrid NSDSC-NSGA-II*), natomiast drugi (ang. *Hybrid First Big Population NSDSC with NSGA-II* — *Hybrid-FBP-NSDSC-NSGA-II*) jest wersją rozbudowaną o zaproponowany mechanizm dużej populacji początkowej (ang. *big initial population*).

Ostatni z opracowanych algorytmów wykorzystuje zaproponowaną w literaturze ideę wielozadaniowych (ang. *multitasking*) algorytmów ewolucyjnych. W oryginalnych pracach, do

których odwołuje się Autorka, podejście to było stosowane do wielokryterialnego problemu z ograniczeniami (algorytm rozwiązywał oddzielnie dwa zadania: wielokryterialny problem z ograniczeniami oraz wielokryterialny problem bez uwzględniania ograniczeń). Doktorantka zastosowała to podejście w nieco inny sposób — jednym zadaniem było rozwiązanie problemu wielokryterialnego, natomiast pozostałe zadania polegały na optymalizacji oddzielnie każdej z funkcji kryterialnych. Zaproponowany algorytm nosi nazwę *wielozadaniowej optymalizacji wielokryterialnej* (ang. *Multitasking on Multi-Objective Optimization — MMOO*).

Recenzowana praca doktorska ma formę klasycznej rozprawy i składa się z sześciu rozdziałów, dodatku, w którym przedstawiono 14 wielokryterialnych problemów testowych wykorzystywanych w trakcie eksperymentów, bibliografii, streszczenia w języku angielskim i polskim, listy akronimów oraz spisów treści, tabel, rysunków i algorytmów. Rozprawa została napisana w języku angielskim.

W rozdziale 1 („Introduction”) Autorka przedstawiła podstawowe zagadnienia związane z optymalizacją wielokryterialną. Omówiona została klasyfikacja problemów optymalizacyjnych, podstawowe zagadnienia związane z optymalizacją wielokryterialną, jak relacja dominacji, zbiór Pareto optymalny oraz front Pareto. Dalsza część rozdziału stanowi przegląd algorytmów optymalizacji wielokryterialnej. Omówione zostały również dwa podejścia wykorzystywane w tego rodzaju algorytmach, czyli skalaryzacja i podejście Pareto (wykorzystujące relację dominacji). Doktorantka omówiła również problemy występujące w wielokryterialnych algorytmach ewolucyjnych związane z koniecznością utrzymywania różnorodności populacji w celu równomiernego pokrycia osobnikami frontu Pareto, jak również zbieganiem się populacji do frontu Pareto. W rozdziale tym omówiono najważniejsze wielokryterialne algorytmy ewolucyjne. Przedstawione zostały również problemy optymalizacji jednokryterialnej oraz podstawowe informacje o algorytmie genetycznym. Nieco wątpliwości może budzić zaprezentowana klasyfikacja populacyjnych algorytmów metaheurystycznych — w szczególności wyodrębnienie dwóch grup związanych z algorytmami ewolucyjnymi (obliczenia ewolucyjne i algorytmy ewolucyjne). Podziałowi takiemu zaprzecza właściwie później sama Doktorantka w rozdziale 2, gdzie na str. 34 mowa jest już tylko o algorytmach ewolucyjnych („Including traditional GAs, evolutionary algorithms (EAs) are a big class of optimization techniques that draw their inspiration from the process of natural evolution.”). Również stwierdzenie, że algorytm genetyczny posiada mechanizmy unikania optimum lokalnych (str. 27, „The likelihood of local minimum trapping is reduced.”) może być mylące, ponieważ wymaga to wykorzystywania specjalnych technik niszowania i specjacji. Rozdział zawiera informacje wprowadzające w tematykę pracy, jednakże jego zawartość mogła zostać lepiej uporządkowana — aktualnie zarówno pojęcia podstawowe, jak i przegląd algorytmów znajdują się w kilku różnych częściach rozdziału. Przykładowo, przegląd wielokryterialnych algorytmów ewolucyjnych znajduje się przed wprowadzeniem pojęcia dominacji i frontu Pareto. Również ogólne omówienie metod optymalizacji wielokryterialnej znajduje się w dalszej części rozdziału. Rozdział kończy się przeglądem najważniejszych osiągnięć rozprawy doktorskiej oraz przeglądem zawartości pozostałych rozdziałów rozprawy.

Rozdział 2 („Literature Review”) jest przeglądem wybranych wielokryterialnych algorytmów ewolucyjnych. Doktorantka przedstawiła algorytmy NSGA-II i zmodyfikowany NSGA-II oraz algorytmy hybrydowe przeznaczone do optymalizacji jedno- i wielokryterialnej. Ogólnie omówione zostały również algorytmy ewolucyjne, jednakże dopiero w dalszej części rozdziału. W rozdziale tym przedstawione zostały również wybrane metryki oceny jakości rozwiązań przeznaczone dla optymalizacji wielokryterialnej, które w dalszej części pracy zostały wykorzystane do oceny proponowanych algorytmów. Doktorantka omówiła również zagadnienia związane z wpływem populacji początkowej na wydajność wielokryterialnych algorytmów

ewolucyjnych. W rozdziale tym Doktorantka wykazała się niewątpliwie znajomością aktualnego stanu wiedzy w dziedzinie i dokonała przeglądu zagadnień związanych z tematyką jej prac badawczych. Pominiętych zostało jednak kilka istotnych wielokryterialnych algorytmów ewolucyjnych. Przykładowo, algorytm SPEA2 został tutaj tylko wspomniany, natomiast brakuje zupełnie informacji o algorytmie NSGA-III i algorytmach przeznaczonych dla problemów optymalizacyjnych o dużej liczbie kryteriów (większej niż 3, czyli *many-objective optimization problems*). Również treść tego rozdziału mogła zostać lepiej uporządkowana.

Kolejne trzy rozdziały rozprawy przedstawiają główne osiągnięcia pracy, czyli pięć zaproponowanych wielokryterialnych algorytmów ewolucyjnych charakteryzujących się lepszą wydajnością od znanego z literatury algorytmu NSGA-II. W rozdziale 3 „The NSDSC and NS-DSDSC Algorithms” przedstawione zostały wspomniane na początku tej recenzji algorytmy *Non-dominated Sorting with Dissimilarity and Similarity of Chromosomes* (NSDSC) oraz *Non-dominated Sorting with Dynamic Schema Dissimilarity and Similarity of Chromosomes* (NS-DSDSC). Zaproponowane algorytmy zostały porównane eksperymentalnie z algorytmem NSGA-II z wykorzystaniem 14 standardowych 2-kryterialnych problemów testowych, z których 9 było problemami bez ograniczeń, a 5 z ograniczeniami. W trakcie tych eksperymentów (jak również wszystkich późniejszych) wykorzystane zostały implementacje algorytmów zrealizowane w środowisku Matlab. Niestety brakuje informacji o konfiguracji sprzętowej wykorzystywanego w eksperymentach środowiska obliczeniowego. W rozdziale 3 zaprezentowano wyniki jakościowe w postaci zwizualizowanych frontów Pareto zlokalizowanych przez poszczególne algorytmy, jak również wyniki ilościowe prezentujące czas obliczeń dla poszczególnych problemów i algorytmów. W przypadku prezentowanych czasów obliczeń nie jest jasne czy pochodzą one z wielu uruchomień algorytmów dla poszczególnych problemów. Jeżeli tak jest (a zasadniczo tak powinno być), to wyniki należało poddać analizie statystycznej. Przeprowadzone eksperymenty wskazują, że zaproponowane algorytmy NSDSC oraz NS-DSDSC uzyskały wyniki lepsze pod względem czasu obliczeń od algorytmu NSGA-II, jednakże w przypadku trudniejszych problemów testowych (z większą liczbą zmiennych) miały one problem ze znalezieniem rzeczywistego frontu Pareto. Otwartym pozostaje pytanie, jak zaproponowane w rozprawie algorytmy poradziłyby sobie z problemami o dużej (większej niż 3) liczbie kryteriów. Porównanie wyników zostało ograniczone również tylko do algorytmu NSGA-II, natomiast pominięty w eksperymentach został przykładowo algorytm SPEA2.

W rozdziale 4 „Hybrid NSDSC with NSGA-II algorithm and Applying a First Big Population with Hybrid algorithm” przedstawione zostały zaproponowane algorytmy hybrydowe *Hybrid NSDSC with NSGA-II* (Hybrid NSDSC-NSGA-II) oraz *Hybrid First Big Population NSDSC with NSGA-II* (Hybrid-FBP-NSDSC-NSGA-II). Algorytmy te zostały również porównane eksperymentalnie z algorytmem NSGA-II z wykorzystaniem tych samych co poprzednio wielokryterialnych problemów testowych. Zaprezentowane wyniki obejmowały wizualizacje znalezionych frontów Pareto dla poszczególnych problemów oraz czasy obliczeń dla poszczególnych algorytmów i problemów testowych. Również tutaj lepsze wyniki pod względem czasów obliczeń uzyskały dwa zaproponowane przez Doktorantkę algorytmy. W odróżnieniu od algorytmów NSDSC i NS-DSDSC zaproponowane algorytmy hybrydowe poprawnie zlokalizowały front Pareto dla wszystkich problemów testowych, jedynie w przypadku problemu ZDT4 wymagane było zwiększenie liczby iteracji tych algorytmów. Podobnie jak to miało miejsce w poprzednim rozdziale, również tutaj nie jest jasne czy zaprezentowane wyniki wydajnościowe pochodzą z wielu uruchomień algorytmów.

Rozdział 5 „Multitasking on MOO” zawiera omówienie zaproponowanego algorytmu *Multitasking on Multi-Objective Optimization* (MMOO) oraz wyniki eksperymentalne porównujące ten algorytm zarówno z algorytmem NSGA-II, jak i z pozostałymi zaproponowanymi algoryt-

mami. W trakcie eksperymentów wykorzystane zostały te same co w poprzednich rozdziałach wielokryterialne problemy testowe. Wyniki zostały przedstawione w postaci wizualizacji znalezionych frontów Pareto (porównano w ten sposób algorytm MMOO z NSGA-II), uzyskanych czasów obliczeń oraz wartości siedmiu metryk (w ostatnich dwóch przypadkach porównanie dotyczyło algorytmu NSGA-II oraz wszystkich zaproponowanych w rozprawie algorytmów). Sześć z wykorzystanych metryk to standardowe wskaźniki jakości rozwiązań dla problemów wielokryterialnych (Inverted Generational Distance — IGD, Generational Distance — GD, Hyper Volume — HV, Spacing, Spread, oraz DeltaP), natomiast siódma metryka $s(x)$ została zaproponowana (w zastosowaniu do problemów wielokryterialnych) w artykule, którego współautorką była Doktorantka — metryka ta omówiona została również szczegółowo w rozdziale 5. Wyniki wydajnościowe przedstawione w tabeli 5.2 wskazują na to, że zawsze najlepszy wynik uzyskał któryś z zaproponowanych w pracy algorytmów (jednak nie wszystkie z nich uzyskiwały w przypadku każdego z problemów lepsze wyniki niż NSGA-II). W przypadku tabeli tej brakuje pierwszego wiersza z nazwami algorytmów, co nieco utrudnia jej analizę. W przypadku wyników zaprezentowanych w postaci metryk brakuje ich szczegółowego omówienia i analizy. Zaprezentowane zostały one w postaci tabel, jednakże brak zaznaczonych najlepszych uzyskanych wyników dla każdego z problemów skutecznie utrudnia ich samodzielną analizę przez czytelnika. Być może brak analizy ze strony Autorki był spowodowany tym, że faktycznie trudno wyciągnąć na podstawie tych wyników jakieś jednoznaczne wnioski — każdy z porównywanych algorytmów uzyskiwał najlepsze wyniki w przypadku niektórych metryk i dla niektórych problemów testowych. Podobnie jak to miało miejsce w poprzednich rozdziałach, również tutaj nie jest jasne czy wyniki prezentujące czasy obliczeń i wartości metryk pochodzą z wielu uruchomień algorytmów dla poszczególnych problemów.

Z wyjątkiem przedstawionych powyżej uwag krytycznych, praca ma poprawną strukturę. Strona językowa i redakcyjna nie budzą poważniejszych zastrzeżeń, jednak Autorka nie ustrzegła się pewnych błędów językowych i redakcyjnych (błędy interpunkcyjne, składniowe i literówki, natomiast w bibliografii brak numeru przy pozycji 109). Usterki te nie wpływają jednak znacząco na ocenę całości rozprawy.

Podsumowując, tematyka pracy wpisuje się w aktualne badania nad algorytmami ewolucyjnymi wchodzącymi w skład metod sztucznej inteligencji. Doktorantka w sposób oryginalny rozwiązała postawiony problem badawczy proponując 5 nowych wielokryterialnych algorytmów ewolucyjnych, których wydajność okazała się lepsza od algorytmu NSGA-II dla wybranego zestawu wielokryterialnych problemów testowych. Pani mgr Aisha Azeez Younus wykazała się przy tym rozległą wiedzą teoretyczną z obszaru optymalizacji wielokryterialnej i wielokryterialnych algorytmów ewolucyjnych. Opracowane algorytmy oraz przeprowadzone badania eksperymentalne wskazują na umiejętność samodzielnego prowadzenia pracy naukowej przez Doktorantkę. Wymienione powyżej usterki i uwagi krytyczne nie umniejszają istotnie znaczenia rezultatów badań przedstawionych w rozprawie.

Stwierdzam, że rozprawa Pani mgr Aishy Azeez Younus spełnia ustawowe i zwyczajowe wymagania stawiane rozprawom doktorskim. W związku z tym wnoszę o dopuszczenie jej Autorki do dalszych etapów postępowania o nadanie stopnia doktora, w tym do publicznej obrony.



Dr hab. inż. Rafał Dreżewski, prof. AGH