

RECENZJA ROZPRAWY DOKTORSKIEJ
DLA KOMISJI ds. stopni naukowych w DYSCYPLINIE INFORMATYKA
UNIwersytetu Łódzkiego
(z dnia 4 grudnia 2024 r.)

Tytuł rozprawy: „Nowe algorytmy optymalizacji wielokryterialnej”

Promotor pracy: prof. dr hab. Marcin Studniarski

Autor rozprawy: mgr Aisha Azeez Younus

I. Aktualność i ważność analizowanej tematyki

Wielokryterialna optymalizacja lub optymalizacja w sensie Pareto to obszar wielokryterialnego podejmowania decyzji, który dotyczy matematycznych problemów z optymalizacją, obejmującą jednocześnie więcej niż jedną funkcję celu. Optymalizacja wielokryterialna, która została zastosowana w wielu dziedzinach nauki, w tym w inżynierii, ekonomii i logistyce, w których należy podejmować optymalne decyzje w obecności kompromisów między dwoma lub więcej sprzecznymi celami jest bardzo ważnym obszarem badań. Minimalizacja kosztów przy jednoczesnej maksymalizacji komfortu przy zakupie samochodu i maksymalizacja osiągnięć przy jednoczesnej minimalizacji zużycia paliwa i emisji zanieczyszczeń pojazdu są przykładami wielu obiektywnych problemów z optymalizacją obejmującymi odpowiednio dwa i trzy cele. W praktycznych problemach mogą być więcej niż trzy cele.

W przypadku problemu optymalizacji z wieloma celami nie jest gwarantowane, aby jedno rozwiązanie jednocześnie zoptymalizowało każdy cel. Mówi się, że obiektywne funkcje są sprzeczne. Rozwiązanie nazywa się niezdominowanym, Pareto optymalnym, Pareto wydajnym lub nie gorszym wówczas, gdy żadna z obiektywnych funkcji nie może zostać poprawiona bez poniżania/pogarszania niektórych innych wartości obiektywnych. Bez dodatkowych subiektywnych informacji o preferencjach może istnieć (prawdopodobnie nieskończona) liczba optymalnych rozwiązań Pareto, z których wszystkie są uważane za równie dobre. Naukowcy badają wielocelowe (wielokryterialne) problemy optymalizacyjne z różnych punktów widzenia, a zatem istnieją różne filozofie i cele związane z ich rozwiązaniem podczas ich ustawiania i rozwiązywania. Celem może być znalezienie reprezentatywnego zestawu optymalnych rozwiązań Pareto i/lub ilościowe określenie kompromisów w celu spełnienia różnych celów i/lub znalezienie jednego rozwiązania, które spełnia subiektywne preferencje decydenta ludzkiego.

W ciągu ostatnich 20 lat ewolucyjna optymalizacja wielokryterialna (EMO) stała się popularną i użyteczną dziedziną badań i zastosowań w obrębie optymalizacji. Algorytmy

optymalizacji ewolucyjnej (EO) wykorzystują podejście oparte na populacji, w którym więcej niż jedno rozwiązanie uczestniczy w iteracji i ewoluuje nową populację rozwiązań w każdej kolejnej iteracji. Powodów ich popularności jest wiele: (i) EO nie wymagają żadnych informacji o pochodnych (ii) EO są stosunkowo proste w implementacji oraz (iii) EO są elastyczne i mają szerokie zastosowanie. Do rozwiązywania jednocelowych problemów optymalizacyjnych, w szczególności w celu znalezienia pojedynczego optymalnego rozwiązania, wykorzystanie populacji rozwiązań może wydawać się zbędne.

Podsumowując tradycyjne metody optymalizacji wielokryterialnej są ciągle bardzo popularne. Jest to spowodowane tym, że dają one dobre rezultaty w znajdowaniu potencjalnych rozwiązań (dla niewielkiej liczby rozwiązań w sensie Pareto), a także ponieważ wiedza na ich temat i dostępność materiałów jest dzisiaj szeroka. Niemniej jednak metody te nie pozostają bez wad. O ile dla niewielkiej ilości zbioru Pareto-optymalnego spisują się całkiem nieźle, to już większy zbiór powoduje w znacznym stopniu wzrost kosztu obliczeń. Dzieje się tak bowiem zazwyczaj metody tradycyjne wymagają wielokrotnego uruchomienia w celu wyznaczenia zbioru Pareto-optymalnego. Ponadto niektóre techniki takie jak na przykład metoda ważonych kryteriów, są wrażliwe na kształt frontu Pareto-optymalnego. Pomimo ciągłej popularności tradycyjnych metod optymalizacji wielokryterialnej, coraz częściej ich alternatywą w wielu problemach stają się algorytmy ewolucyjne. Jest to spowodowane tym iż lepiej one radzą sobie w przypadku gdy mamy odczynienia z potencjalnie dużą liczbą rozwiązań w sensie Pareto.

Algorytm ewolucyjny przeszukuje przestrzeń alternatywnych rozwiązań problemu w celu odnalezienia rozwiązań najlepszych lub potencjalnie najlepszych. Zalicza się go do klasy algorytmów heurystycznych. Przeszukiwanie odbywa się za pomocą mechanizmów ewolucji oraz doboru naturalnego. W praktyce te słowa oznaczają, że wykorzystujemy ewolucję, aby poprzez krzyżowanie i mutację stworzyć z grupy losowych zestawów danych to, co nas będzie satysfakcjonować. Pierwszy algorytm ewolucyjny został zaproponowany przez Johna Hollanda w 1975 roku, który bardzo interesował się biologią, genetyką i często czerpał z niej inspirację w swych pracach informatycznych.

Algorytm ewolucyjny przetwarza populację osobników, z których każdy jest propozycją rozwiązania postawionego problemu. Działa on w środowisku, które można zdefiniować na podstawie problemu rozwiązywanego przez algorytm. W środowisku każdemu osobnikowi jest przyporządkowana określona wartość, którą cechuje jakość reprezentującego przez niego rozwiązania; wartość ta jest nazwana przystosowaniem osobnika. Każdy osobnik jest wyposażony w informację stanowiącą jego genotyp, na podstawie którego tworzony jest fenotyp – czyli zestaw cech, który podlega ocenie środowiska. Właśnie ta ocena jest przystosowaniem osobnika opisywanym wcześniej. Sposób oceniania fenotypu opisujemy za pomocą funkcji przystosowania, która w sposób całkowity opisuje środowisko. Funkcja ta może być stacjonarna, zmienna w czasie bądź podlegać randomizacji. Genotyp osobnika jest budowany przez chromosomy. Natomiast każdy chromosom składa się z zestawu genów, których wartościami są allele. Działanie algorytmu ewolucyjnego sprowadza się do wykonywania pętli, w której następują po sobie: reprodukcja, operacje genetyczne, ocena, sukcesja.

W optymalizacji wieloobiektowej/kryterialnej procedura EO jest doskonałym wyborem. Problemy optymalizacji wieloobiektowej, z natury, prowadzą do powstania zbioru rozwiązań Pareto-optymalnych, które wymagają dalszego przetwarzania w celu uzyskania jednego preferowanego rozwiązania. Aby osiągnąć pierwsze zadanie, całkiem naturalną propozycją staje się użycie EO, ponieważ użycie populacji w iteracji EO w jednoczesnym znalezieniu wielu niezdominowanych rozwiązań, które przedstawiają kompromis między celami w jednym przebiegu symulacji staje się bardzo pomocne. Należy zauważyć, że tematyka wybrana przez Doktorantkę jest ważna i aktualna, niezależnie od tego, że techniki ewolucyjne mają już swoją historię i bogatą różnorodną algorytmiczną strukturę.

II. Układ pracy

Rozprawa doktorska jest dziełem naukowym podejmującym nowe problemy badawcze. Z tego względu praca doktorska powinna spełniać podstawowe funkcje nauki, takie jak opis badanego problemu, jego wyjaśnienie i przewidywania dotyczące przyszłości. Jest trudniejsza do oceniania gdy nie zawiera w sobie pewnych szczególnych elementów, wymienionych poniżej:

- wstęp zawierający: przesłanki podjęcia tematu, cel zasadniczy i cele szczegółowe (cele naukowo-poznawcze i cele praktyczne), pytania i hipotezy badawcze, metody badawcze zastosowane w pracy, charakterystykę poszczególnych rozdziałów,
- numerowane rozdziały, mające układ wynikający z logiki prowadzonych prac i realizacji poszczególnych etapów wskazanych wcześniej, zwanych celami pobocznymi,
- zakończenie zawierające odniesienie do celu/celów pracy, jak również do hipotez/hipotezy badawczej określonych we wstępie, wnioski wynikające z rozważań teoretycznych
- oraz z części empirycznej pracy.

Dla oceny rozprawy doktorskiej kluczowe znaczenie ma jej teza, bowiem wysiłek wkładany w przygotowanie rozprawy doktorskiej winien zmierzać w kierunku udowodnienia postawionej tezy lub weryfikacji trafności hipotezy badawczej. Niestety w recenzowanej rozprawie nie znalazłam tego rodzaju informacji.

Do każdego problemu badawczego zwykle trzeba ułożyć przynajmniej jedną hipotezę – można więcej, ale nie można zostawić żadnego problemu badawczego bez hipotez. Najczęściej jednak jest tak, że liczba hipotez badawczych odpowiada liczbie problemów. Aby móc wykazać kompetencje ocenianego doktoranta, recenzent odnosi się do zrealizowanych a postawionych we wstępie: celu głównego i celów szczegółowych rozprawy. Jest to element ułatwiający pisanie a potem recenzowanie pracy w ciągu myślowym. Tu również takiego zapisu nie znalazłam.

W recenzowanej pracy skonstruowano (lub raczej opisano) pięć nowych metaheurystycznych algorytmów o charakterze ewolucyjnym i dokonano implementacji tych podejść przy użyciu programu Matlab. Zostały one zaprojektowane po to, aby wyszukiwać Pareto front dla problemów optymalizacji wielokryterialnej. Algorytmy te są oparte na zmodyfikowanym algorytmie genetycznym NSGA-II, o hybrydowej naturze, gdzie występuje duża liczebność populacji i dodatkowo wzięto pod uwagę wielozadaniowość.

Zastosowano algorytm DSC (z j. ang. Dissimilarity and similarity of Chromosomes), który bada podobieństwa i różnice między rozwiązaniami (gdzie chromosomy przedstawione są jako ciągi binarne). Zastosowano również efekt dużej populacji początkowej. Aby udowodnić skuteczność tych algorytmów, przetestowano je na czternastu funkcjach testowych. Użyto dziewięć funkcji testowych bez ograniczeń i pięć funkcji testowych z ograniczeniami. Jedna z nich jest z jedną zmienną, pięć funkcji z dwiema zmiennymi, jedna funkcja z trzema zmiennymi, jedna z czterema zmiennymi, jedna funkcja z sześcioma zmiennymi, dwie funkcje z dziesięcioma zmiennymi i trzy funkcje z 30 zmiennymi. Wyniki miały wykazać, że w większości przypadków, widoczna jest wyższość zaproponowanych podejść nad innymi, zaproponowanymi algorytmami, omawianymi w tej pracy.

Niniejsza rozprawa składa się z sześciu rozdziałów. Rozdział pierwszy jest ogólnym wprowadzeniem do tematyki optymalizacji. Rozdział drugi zawiera przegląd literatury i dyskusję na temat mierników wydajności dla algorytmów optymalizacji wielokryterialnej (wybrano: Generational Distance GD, Error Ratio ER, Inverted Generational Distance IGD, Hyper Volume HV, Spacing Metric SP, Spread metric spread I Delta P metric). W kolejnym rozdziale opisano algorytm o nazwie NSDSC (z j. ang. Non-dominated Sorting Dissimilarity and Similarity of Chromosomes), który łączy użycie operatora odmienności i operatora

podobieństwa z losowością generowania części każdej nowej populacji i co za tym idzie, budowaniem frontów Pareto. Ponadto modyfikacja NSDSC, zwana NS-DSDSC została wprowadzona do dalszych analiz aby wykazać jej skuteczność. Czwarty rozdział wprowadza dwa nowe algorytmy, . pierwszy jako hybrydowy algorytm NSDSC z algorytmem NSGA-II, drugi NS-DSDSC jako nowe podejście algorytmu DSDSC (z j. ang. Non-dominated Dynamic Schema Dissimilarity and Similarity of Chromosomes). Piąty rozdział zawiera ewolucyjny algorytm wielozadaniowości, na koniec rozdział szósty zawiera pewne wnioski z tej pracy oraz uwagi końcowe.

III. Wkład Doktorantki w tematykę recenzowanej rozprawy

Cel główny prezentowanej pracy (otrzymany w korespondencji mailowej, w pracy podany jako teza, str. 28, rozdz. 1.11) można zredagować następująco:

Opracowanie i analiza nowych algorytmów ewolucyjnych dla optymalizacji wieloobietkowej, koncentrujących się na wydajnych i dokładnych rozwiązaniach frontu Pareto. Nowo opracowane (zaprezentowane) algorytmy (NSDSC, NS-DSDSC, hybrydowy NSDSC z NSGA-II, duża populacja z hybrydowym NSDSC z NSGA-II i wielozadaniowość w algorytmach wielocelowych) wykazały lepszą wydajność i krótszy czas obliczeń w porównaniu z klasycznym, niezmodyfikowanym podejściem NSGA-II dla większości badanych w pracy funkcji testowych.

Nasuwa się pytanie do Doktorantki:

Biorąc pod uwagę fakt, że zastosowane algorytmy są dobrze ugruntowane i zbadane, co jest rzeczywistym wkładem Doktorantki w rozwój, czy efektywność omawianych algorytmów?

[Given that the algorithms used in the work were already known, what is your contribution to the development of these new algorithms?](#)

Cele cząstkowe (otrzymane jak powyższy cel główny, drogą mailową) przedstawię w kolejnych punktach:

- Skonstruowanie algorytmów uwzględniających podobieństwo i odmiennność chromosomów (DSC) i jego dynamiczny wariant schematu (DSDSC).

Na czym polegał dynamiczny charakter tego schematu?

Czy stosowane oznaczenia w postaci gwiazdek wskazujących odległość pomiędzy fragmentami kodu genetycznego mają jakieś powiązania z teorią schematów J. Holanda a jeśli nie to dlaczego?

[The DSC algorithm uses specific coding with an asterisk to highlight distinctive sites in the chromosome. Is there any connection to John Holland theorem of schema/diagrams?](#)

W rozdziale trzecim przedstawiono dwa nowe algorytmy (NSDSC i NS-DSDSC), które zostały użyte zamiast algorytmu genetycznego (NSGA-II) i zastosowane do znalezienia frontu Pareto w optymalizacji wielokryterialnej. Wykresy od strony 53 do 57 może i są cenne, ale skąpy komentarz nie daje pełnego obrazu tej hybrydyzacji. Nie przeprowadzono też uzasadnienia (matematycznego, lub statystycznego), że podział populacji na grupy Q1, Q2...Q4 ma uzasadnienie identyczne w każdym z przeprowadzonych testów, niezależnie od złożoności problemu. Kuriozalne wydaje się stwierdzenie na stronie 62, że wykresy w dalszej części pracy są od numeru 3.21 do 3.34, gdy startuje się od 3.3, w środku mamy 3.27 a kończymy na 3.12. Wykresy nie są opatrzone legendą. Analiza porównawcza na stronie 67 z

kryterium czasu wydaje się być zestawieniem niefortunnym, gdy w wielu przypadkach nie osiągnięto frontu Pareto.

Autorka zaobserwowała, że zaproponowany przez nią zmodyfikowany algorytm daje dobre wyniki w przypadku funkcji o liczbie zmiennych 1, 2, 3, 6, natomiast w przypadku funkcji o liczbie zmiennych 10 i 30 nie uzyskano dobrych wyników. Dwa nowe algorytmy (NSDSC i NS-DSDSC) szybciej dopasowały optymalne rozwiązania algorytmu NSGA-II. Dwa nowe algorytmy (NSDSC i NS-DSDSC) osiągnęły optymalne rozwiązanie w większości problemów testowych z wyjątkiem problemów A2-ZDT1, A5-ZDT2, A7-ZDT3, A8-ZDT4 i A9-ZDT6, które mają 10 lub 30 zmiennych.

Pytanie, czy jest to wystarczające świadectwo motywujące słuszność stosowanego podejścia, skoro do trudniejszych problemów jest nieskuteczne? Czy doktorantka starała się dokonać jakichś zmian, wprowadzić dodatkowe operatory genetyczne, w celu podniesienia skuteczności algorytmów?

[What are the suggestions to improve the quality of operation for test functions with dimensions 10 and 30 \(DSDSC, 2. Sub-objectives\).](#)

- Projektowanie algorytmów hybrydowych łączących NSDSC z NSGA-II.
Zbadanie wpływu dużych populacji początkowych na wydajność algorytmu:

W rozdziale czwartym użyto algorytmów hybrydowych (nie HYBIRD, jak napisano w pracy) łączących NSDSC z NSGA-II. Zauważono, że zastosowanie algorytmów hybrydowych daje lepsze wyniki, niż dwa poprzednie algorytmy NSDSC i NS-DSDSC, gdy testowano je na 14 problemach wspomnianych powyżej, w szczególności na problemach A2-ZDT1, A5-ZDT2, A7-ZDT, A8-ZDT4 i A9-ZDT6, dla których algorytmy NSDSC i NS-DSDSC miały trudności z osiągnięciem optymalnego rozwiązania. Zauważono pozytywny wpływ dużych populacji początkowych na wydajność algorytmu. Czy jednak nie jest to intuicja, która nam zawsze towarzyszy podczas stosowania algorytmów populacyjnych, że dla większej przestrzeni rozwiązań należy dobrać odpowiedni rozmiar populacji. Zastanawiające jest to, że po wstępnej fazie składającej się ze 100 iteracji algorytmem NSDSC, zaproponowano 250 (a nawet w niektórych przypadkach 450) iteracji NSGA-II, co z pewnością mogło poprawić złe wyniki początkowe. W zamieszczonych pseudokodach można było zamieścić numerację poszczególnych linii i odwoływać się do nich przy wyjaśnianiu nowości. Tabela .4.2 zawiera porównanie dwu podejść o nierównych wartościach parametru a dot. liczby iteracji i jest to niezrozumiałe.

Jakie czynniki/relacje w obrębie parametrów ilościowych (czy jakościowych?) wpływają na wybranie właściwego rozmiaru populacji?

[What are the relationships between the size of the population and the number of variables in the testable functions. If there are, how can this be used? \(the next point in 2. sub-objectives\)](#)

- Wprowadzenie wielozadaniowości w optymalizacji wielokryterialnej w celu dekompozycji złożonych problemów na łatwiejsze w zarządzaniu zadania.

W rozdziale piątym zastosowano nowy algorytm o nazwie Multitasking on MOO, który obejmuje ideę łączenia optymalizacji jedno- i wielokryterialnej w celu rozwiązywania trudnych problemów. Algorytm pracował nad rozwiązaniem problemów MOO poprzez dekompozycję - podzielenie problemu na kilka podzadań jako SOO (z j. ang. Single-Objective Optimization), następnie Autorka zaproponowała umieszczanie pierwszych trzech najlepszych chromosomów w pierwszej ćwiartce populacji i potem generowano losowo 10% populacji i umieszczano je w drugiej ćwiartce, podczas gdy trzecie zadanie jest używane do rozwiązywania problemów

dwukryterialnych jako MOO. Wyniki pokazały, że algorytm wielozadaniowości w MOO był bardzo skuteczny i przewyższał NSGA-II w niektórych problemach. Weryfikacja algorytmów przy użyciu różnych funkcji testowych (zarówno ograniczonych, jak i nieograniczonych) i ocena ich wydajności przy użyciu ustalonych metryk. Nagromadzenie tabel (5.3 do 5.8) bez dogłębnej analizy nie jest przekonujące. Wykresy są dziwnie numerowane: od 5.1 do 5.15, a potem znów 5.7, 5.8, 5.9. Trudno w tym wszystkim się odnaleźć.

W rozdziale piątym zastosowano nową metrykę $s(x)$, która udowodniła swoją zdolność do mierzenia efektywności rozwiązań wynikających z dwóch algorytmów: Multitasking na MOO i NSGA-II na problemach SCH i FON. Metryka $s(x)$ jest uważana za nowy dodatek do istniejących miar wydajności (IGD, GD, HV, Spacing Metric, Delta P, Spread metric). Czytanie tekstu rozdziału 5 wskazuje już na spore zmęczenie Autorki tej pracy. Pozwolę sobie na przytoczenie jednego zdania: „We found Also we apply as on this metric...”, str. 108, podrozdział 5.7. Zestawienia wartości liczbowych w kolejnych tabelach: 5.9 – 5.16 pozostawione są sobie samym.

Czy przeprowadzona analiza porównawcza omawianych podejść powinna być wykonywana przy tych samych wartościach parametrów ilościowych, liczby iteracji itd.? Czy jest to podejście słuszne? Czy dokonano tuningu parametrów i przeprowadzono szczegółową analizę klasycznego podejścia ewolucyjnego?

Czy można wskazać znaczące różnice między omawianymi metrykami miar wydajności?

Jakie negatywne obserwacje, czy niekorzystne cechy można wymienić podczas dekomponowania systemu i wprowadzaniu pojedynczego kryterium optymalizacyjnego?

Brakuje testów statystycznych, które uwiarygodniłyby uzyskane rezultaty przy stosowaniu techniki przybliżonej, stochastycznej. Dlaczego ich nie przeprowadzono?

Nie dokonano analizy złożoności obliczeniowej zaproponowanych podejść oraz tych omawianych w pracy. Jedyne miejsce, gdzie podjęto taką próbę, była strona 30, rozdz. 2.2, gdzie omówiono złożoność algorytmu NSGA-II – $O(MN^3)$.

What significant differences between the above mentioned metrics (validation) can you underline and analyze

What are the dangers of decomposing complex problems into simple ones with a single optimization criterion? Who or what determines this choice? (multitasking)

Have any statistical tests been performed, taking into account the fact that evolutionary techniques are non-deterministic approaches and do not guarantee reproducibility of results?

There was no analysis of the computational complexity of the proposed approaches and those discussed in this dissertation.

IV. Krytyka metodologii proponowanej w niniejszej pracy

Autorka dokonując bardzo szerokiego przeglądu literaturowego zamieściła bardzo dużo krótkich opisów prac, bez zagłębiania się w szczegóły i idee, które kolejne pracy wносиły. Aby zrozumieć główny trzon podejścia algorytmicznego zaproponowanego w pracy, należałoby (według mnie) opisać w pierwszej kolejności algorytm zaproponowany przez Fonseca and Fleminga- Multiobjective Genetic Algorithm (FFGA). Algorytm ten został opracowany w 1993 r. przez Fonseca i Fleminga, niemniej koncepcja takiego podejścia została już wcześniej opracowana - bowiem w 1989 r. przedstawiona przez D. Goldberga. Bazuje ona na nadawaniu rang osobnikom, które następnie determinują wartość ich przystosowania. Rangi są nadawane w taki sposób, że z populacji bazowej wybierane są osobniki niezdominowane i przypisywana

jest im ranga o wartości jeden a następnie są one tymczasowo usuwane z populacji. Z pozostałych osobników wybieramy znowu te, które są niezdominowane i nadajemy im rangę równą dwa. Postępujemy tak dopóki nie nadamy rangę wszystkim osobnikom. Należy jednak pamiętać iż nie każda wartość rangi musi zostać nadana.

Rozpatrując tego typu metody, bazujące na dominacji rozwiązań, należy zwrócić szczególną uwagę na mogący się pojawić problem nierównomiernego pokrycia zbioru rozwiązań niezdominowanych. Problem ten ujawnia się zwykle przy niewielkich populacjach bazowych, gdzie większość osobników, reprezentujących poszczególne rozwiązania, jest zdominowana. Schemat selekcji preferujący niezdominowane osobniki prowadzi do intensywniejszego przeszukania ich sąsiedztwa. W efekcie pojawiają się skupiska osobników wokół uprzednio niezdominowanych. W skutek tego rozmieszczenie osobników w zbiorze punktów niezdominowanych jest bardzo nierównomierne. I należy zauważyć, że w recenzowanej pracy problem ten zauważono, jednak sposób prezentacji pozostawia wiele do życzenia. Jest nie zawsze zrozumiały.

Aby zapobiec temu zjawisku w powyższej metodzie zastosowano technikę optymalizacji wielomodalnej, podziału przystosowania (z j. ang. fitness sharing). Metoda ta została opracowana przez Goldberga i Richardsona w 1987 r. Główna idea tej metody polega na podzieleniu populacji na stabilne subpopulacje, zwane niszami. Funkcja podziału całej populacji na nisze określana jest poprzez zmniejszenie dopasowania osobnika w stosunku do sąsiada oddalonego o pewną miarę odległości i uzależniona jest od promienia niszy. Oznacza to, że kiedy sąsiaduje ze sobą wiele osobników, to wpływają one na liczebność (pojemność) niszy, w ten sposób obniżając własne wartości przystosowań. Dzięki temu ogranicza się właśnie niekontrolowany wzrost liczby osobników danej niszy i zapobiega nierównomiernemu pokryciu zbioru rozwiązań. Szkoda, że przy opisie tej metody Autorka nie odniosła się do niszowania, szczególnie, że w pewien sposób próbuje je tworzyć.

Podejście do rozwiązywania zadań wielokryterialnych zawarte w metodzie NPGA (Niche Pareto Genetic Algorithm) zostało przedstawione przez Horna i Nafpliotisa w 1993 r. Algorytm NPGA podobnie jak przedstawiony wcześniej algorytm FFGA bazuje na technice opartej na dominacji, z równocześnie wprowadzoną selekcją turniejową. W celu przeprowadzenia selekcji w odpowiedni sposób, tak aby zachować odpowiednią presję selektywną oraz kontrolę nad liczbą rozwiązań niezdominowanych, tworzy się losowy zbiór osobników porównawczych P_{dom} o liczebności określonej przez wartość nacisku dominacji t_{dom} . Ten osobnik, który zdominuje losowy zbiór P_{dom} wygrywa selekcję i zostanie przeniesiony do populacji tymczasowej P' . Selekcja jest jednym z ważniejszych czynników utrzymania presji selektywnej i równocześnie różnorodności populacji. Pojawia się słowo selekcja w pseudokodzie, ale nie znalazłam konkretnych.

Algorytm NSGA (Nondominated Sorting Genetic Algorithm) po raz pierwszy został zaimplementowany w 1994 r. przez Srinivasa i Deba. Metoda ta podobnie jak algorytm przedstawiony powyżej bazuje na koncepcji Goldberga z 1989 r. Idea takiego podejścia skupia się na podzieleniu osobników w subpopulacje, ze względu na nadane im rangi, następnie korzystając z metody niszowej zapewnia się równomierne pokrycie zbioru rozwiązań. Jeszcze przed selekcją populacja jest porządkowana pod względem dominacji. Wszystkie osobniki niezdominowane zalicza się do pierwszego frontu (przydzielając im sztuczną wartość funkcji przystosowań proporcjonalną do liczebności populacji, aby zapewnić tym osobnikom równy potencjał reprodukcyjny). Dla utrzymania różnorodności populacji stosuje się dzielenie tej sztucznej funkcji przystosowań. Następnie tę grupę osobników niezdominowanych ignoruje się tymczasowo, resztę populacji poddaje się temu samemu mechanizmowi i wyznacza się drugą warstwę rozwiązań niezdominowanych. Nowemu zbiorowi osobników przypisuje się nową

wartość sztucznego przystosowania, która jest trochę mniejsza od poprzedniej. Ten proces jest powtarzany tak długo, dopóki cała populacja nie zostanie sklasyfikowana

Wg mnie właściwym byłoby przedstawienie tych wcześniejszych podejść w szerszym kontekście, niż to zaproponowała Doktorantka a następnie opisanie różnic, które to pozwalają na tytułowe NOWE algorytmy w optymalizacji wielokryterialnej, bo jak wskazano w opisie powyżej większość z nich znana jest do lat 80. poprzedniego wieku.

V. Uwagi do części eksperymentalnej i przeprowadzenia analizy

Opinii recenzenta uczestniczącego w postępowaniu o nadanie tytułu doktora podlega zgodność tematu z treścią pracy oraz jasny i logiczny układ pracy, który dotyczy celu, problemów badawczych, metod badań, ale także umiejętności scharakteryzowania tematyki szczegółowej, badawczej, organizacji badań i sposobów opracowania materiału empirycznego. Niestety w tej kwestii czuję wielkie nieukontentowanie. Wielość tabel jest imponująca, zawierają one dane liczbowe, z dużą dokładnością, nawet do 6 miejsc po przecinku. Uważam również, że poszczególne tabele powinny mieć stosowny nagłówek, pokazujący znaczenie odpowiednich wyników, nie zaś formę opisową, co zawierają lub co ilustrują. Jednakże brak odpowiednich analiz, czy komentarzy czyni tę pracę niezrozumiałą. Wykresy zbiorcze - najmniej przemyślany fragment pracy są trudno interpretowalne, tym bardziej, że parametry ilościowe i jakościowe omawianych algorytmów nie są identyczne. Więc jak wyciągać z tego wnioski dotyczące 14 testowych funkcji o zupełnie odmiennych charakterystyce? Ocenie podlega również umiejętność formułowania wniosków i w tym przypadku czuję wielki niedosyt. Ten aspekt na nikłe znaczenie w kontekście znalezienia plusów tej pracy. Ważne jest także to, czy i w jakim zakresie praca doktorancka stanowi nowe ujęcie problemu. W moim odczuciu ostatni cel szczegółowy dotyczący tzw. multitasking, wskazany jako osobisty wkład doktorantki, nie wystarczy, aby mówić tu o nowym ujęciu tematyki badawczej. Oceniana jest poprawność językowa i estetyka pracy oraz dobór i sposób wykorzystania źródeł. W tej materii nie chciałabym się wypowiadać, bowiem nie jestem filologiem angielskim. Jednakże tłumaczenie na j. polski streszczenia pracy pozostawia wiele do życzenia.

VI. Wniosek końcowy

W podsumowaniu z przykrością stwierdzam, że wobec znaczących uchybień przedstawionych powyżej, rozprawa doktorska Pani mgr Aishy Azeez Younus nie spełnia wymagań obowiązujących obecnie i zawartych w przepisach dotyczących zawartości i formy rozpraw doktorskich. Wnoszę zatem o niedopuszczenie Pani mgr Aishy Azeez Younus do następnej fazy postępowania o nadanie tytułu doktora.

Urszula Boryska