



Politechnika Poznańska  
Wydział Informatyki i Telekomunikacji

*Streszczenie pracy doktorskiej w języku polskim*

Nowe kierunki w interaktywnej ewolucyjnej  
optymalizacji wielokryterialnej opartej na  
holistycznych przykładach preferencji

**Michał Tomczyk**

Promotor: dr hab. inż. Miłosz Kadziński

Poznań, 2020



## Wprowadzenie

Rzeczywiste problemy optymalizacji są często sformułowane jako problemy wielokryterialne. Tego typu problemy uwzględniają przynajmniej dwie funkcje celu, które powinny być optymalizowane jednocześnie. Niestety, założone kryteria optymalizacji są często sprzeczne. Na przykład w problemie konstrukcji zielonego łańcucha dostaw, emisja gazów cieplarnianych może być ograniczana poprzez inwestycję w droższe, lecz zarazem bardziej przyjazne środowisku środki transportu. Konfliktowość kryteriów sprawia, że zazwyczaj nie istnieje jedno, optymalne rozwiązanie problemu optymalizacji wielokryterialnej. Zamiast tego istnieje szereg rozwiązań kompromisowych, zwanych także rozwiązaniami Pareto optymalnymi. Rozwiązanie Pareto optymalne nie może zostać poprawione na żadnym z kryteriów, bez jednoczesnego pogorszenia jego jakości z punktu widzenia innego kryterium. Zbiór wszystkich takich rozwiązań stanowi front Pareto. Rozwiązań Pareto optymalnych może być w ogólności nieskończenie wiele. Z tego powodu przyjmuje się, że celem optymalizacji wielokryterialnej nie jest znalezienie wszystkich rozwiązań Pareto optymalnych, a uzyskanie dobrego przybliżenia frontu Pareto. Poprzez dobre przybliżenie rozumie się zbiór rozwiązań, które są blisko frontu Pareto (kryterium zbieżności) i są równomiernie rozłożone (kryterium rozmieszczenia).

W ostatnich latach na szczególnym znaczeniu zyskały – w kontekście rozwiązywania problemów optymalizacji wielokryterialnej – algorytmy ewolucyjne. Heurystyki te symulują naturalny proces ewolucji. Implementują one takie mechanizmy jak selekcja naturalna, czy reprodukcja. Jedną z wyróżniających się cech algorytmów ewolucyjnych jest to, że potrafią one optymalizować jednocześnie wiele rozwiązań – zwanych razem populacją – co jest szczególnie pożądaną cechą przy konstruowaniu dobrego przybliżenia frontu Pareto. Populacja rozwiązań jest sukcesywnie poprawiana w kolejnych iteracjach, to jest generacjach, algorytmu. Warto podkreślić, że w procesie ewolucyjnej optymalizacji rozwiązania potomne dziedziczą cechy swoich rodziców. W ten sposób rozwiązania optymalizowane są w sposób synergiczny. Przyczynia się to z kolei do wysokiej skuteczności algorytmu w konstruowaniu coraz lepszych rozwiązań. Co więcej, algorytmy ewolucyjne – jako heurystyki – mogą być stosunkowo łatwo przystosowane do rozwiązywania wielu klas problemów, również tych silnie nieliniowych.

Nadrzędnym celem optymalizacji wielokryterialnej jest konstrukcja zbioru wariantów, czyli potencjalnych rozwiązań problemu decyzyjnego. Spośród tak przygotowanych rozwiązań, decydent może wybrać jedno rozwiązanie, które najlepiej odpowiada jego preferencjom. Takie połączenie procesu optymalizacji z procesem wyboru jest nazywane podejściem *a posteriori*. Jest ono często krytykowane z dwóch powodów. Po pierwsze, rozmiar populacji jest na ogół ograniczony w stosunku do rozmiaru całego frontu Pareto, przez co uzyskany rozkład rozwiązań może być rzadki. Tym samym rozwiązania, które mogą być szczególnie istotne dla decydenta, mogą zostać nieodkryte przez algorytm. Po drugie, decydenta na ogół interesuje odnalezienie względnie małego podzbioru rozwiązań, które najbardziej odpowiadają jego preferencjom. W tym sensie algorytmy optymalizacji wielokryterialnej niepotrzebnie wykorzystują przydzielone im zasoby obliczeniowe na konstrukcję rozwiązań, które są nieistotne dla decydenta.

Powyższe uwagi były w ostatnich latach motywacją do powstania wielu prac dotyczących ewolucyjnej optymalizacji wielokryterialnej opartej o informację preferencyjną decydenta. Algorytmy, które wykorzystują dodatkową informację preferencyjną, są w stanie ukierunkowywać przebieg ewolucji. Dzięki temu mogą one konstruować rozwiązania,

które są wysoce istotne dla decydenta. Ponadto, ze względu na zbieżny charakter takiego przeszukiwania, skuteczność algorytmu jest znacznie większa niż w przypadku, gdy stara się on odnaleźć wiele różnych, kompromisowych rozwiązań problemu.

Istniejące algorytmy, które integrują ewolucyjną optymalizację wielokryterialną z technikami wielokryterialnego wspomaganie decyzji, często nie wykorzystują metod oraz paradygmatów wywodzących się z aktualnego stanu wiedzy. Przeciwnie, nieraz używają one starszych, mniej efektywnych technik optymalizacji ewolucyjnej. Dodatkowo często są one oparte na nierealistycznych, bądź silnie kwestionowanych założeniach dotyczących elicytacji preferencji decydenta. W szczególności, niniejsza praca doktorska wyróżnia następujące główne problemy istniejących algorytmów, które integrują informację preferencyjną z procesem przeszukiwania przestrzeni rozwiązań:

**Wykorzystywanie nieefektywnych schematów ewolucji:** W literaturze wyróżnia się trzy główne klasy ewolucyjnych algorytmów optymalizacji wielokryterialnej: algorytmy oparte o relację dominacji, oparte o wskaźnik jakości populacji oraz algorytmy dekomponujące problem. Z tych trzech głównych klas, schemat oparty o relację dominacji jest najmniej efektywny. Większość istniejących algorytmów jest jednak oparta właśnie o ten schemat ewolucji.

**Brak możliwości ciągłej współpracy algorytmu i decydenta:** Ewolucyjne algorytmy optymalizacji wielokryterialnej mogą pobierać informację preferencyjną na trzech różnych etapach działania. Po pierwsze, informacja preferencyjna może zostać pobrana po zakończeniu procesu optymalizacji. Takie algorytmy nazywane są *a posteriori*. Wady takiego podejścia zostały wymienione wcześniej. Z drugiej strony, algorytm może uzyskać informację preferencyjną zanim proces optymalizacji się rozpocznie, to jest *a priori*. Niestety, takie podejście wydaje się mało realistyczne. Przyczyną tego jest fakt, że decydentowi może być trudno przedstawić swoje preferencje, jeżeli nie ma on żadnego wglądu w to, jak wyglądają potencjalne rozwiązania problemu.

Alternatywą do podejść *a priori* i *a posteriori* jest podejście interaktywne. Zakłada ona ciągłą współpracę algorytmu i decydenta w trakcie trwania ewolucji. Innymi słowy, algorytm oraz decydent prowadzą dialog, podczas którego algorytm może prosić decydenta o opinię na temat konstruowanych rozwiązań. Decydent może w ten sposób ciągle obserwować wpływ swoich decyzji na przebieg ewolucji. Z jednej strony, może on sukcesywnie utwierdzać się w słuszności swoich opinii, jeżeli proces optymalizacji przebiega w pożądanym kierunku. W przeciwnym wypadku, jeżeli decydent widzi, że konstruowane rozwiązania nie spełniają jego oczekiwań, może w każdym momencie zmienić swoje wcześniej przedstawione opinie.

Spośród 3 wymienionych schematów pobierania informacji preferencyjnej, podejście interaktywne jest najbardziej korzystne z punktów widzenia zarówno procesu modelowania preferencji decydenta – i tym samym konstruowania istotnych dla niego rozwiązań – jak i samego decydenta, który ma większą kontrolę nad przebiegiem ewolucji. Niemniej jednak większość istniejących algorytmów opartych o preferencję decydenta nie jest interaktywna.

**Modelowanie preferencji w oparciu o formy informacji preferencyjnej, które są trudne do przedstawienia:** Informacja preferencyjna może być wyrażona wprost

przez decydenta w formie wartości dla pewnych technicznych parametrów założonego modelu preferencji, takich jak, na przykład, wagi dla kryteriów bądź współrzędne punktu aspiracji. Jednak wiarygodność metod opartych o taki typ informacji preferencyjnej może zostać zakwestionowana przez praktyków wspomagania decyzji. Po pierwsze, aby wiarygodnie wyznaczyć dokładne wartości dla parametrów modelu, decydent musi rozumieć, w jaki sposób algorytm modeluje jego preferencje, na przykład jak interpretowane są dostarczone przez niego wagi, bądź w jaki sposób punkt aspiracji jest wykorzystywany do ewaluacji rozwiązań. Po drugie, decydent musi wiedzieć jak wygląda przestrzeń rozwiązań problemu. Nie zawsze uzyskanie takiego obrazu jest możliwe. Ponadto kompleksowa analiza potencjalnych rozwiązań może być trudna dla decydenta, jeżeli problem optymalizacji uwzględnia dużą liczbę kryteriów. Ze względu na powyższe zastrzeżenia, wyrażanie preferencji wprost jest często uznawane za poznawczo wymagające. Tym samym skuteczność tak zaimplementowanej metody jest obciążona dużym marginesem błędu.

By ułatwić decydentowi wyrażanie swoich opinii, metoda może zostać oparta na holistycznych przykładach preferencji takich jak, na przykład, przydział wariantu do klasy preferencji bądź porównania parami dwóch rozwiązań. Takie pośrednie przykłady informacji preferencyjnej nie nakładają na decydenta znaczących obciążeń poznawczych. Przykładowo, gdy decydent wskazuje preferowane rozwiązanie z pary, nie musi się odwołać do żadnych technicznych aspektów założonego modelu preferencji. Przeciwnie, jego subiektywna opinia ma charakter głównie jakościowy, a nie ilościowy. Algorytm dalej może wykorzystać tak uzyskaną informację preferencyjną w procesie dezagregacji informacji preferencyjnej celem zbudowania bardziej szczegółowej, matematycznej reprezentacji systemu preferencji decydenta. Pomimo iż holistyczne formy preferencji są uznawane za bardziej przyjazne i naturalne do wyrażenia przez decydenta, większość istniejących algorytmów oparta jest o bezpośrednią informację preferencyjną

**Brak implementacji analizy odporności dla konstruowanych rozwiązań:** Preferencje decydenta, wraz z założonym modelem preferencji, mogą być eksploatowane przez metodę na wiele sposobów. Jeżeli, na przykład, metoda jest oparta o informację preferencyjną wyrażoną wprost, metoda może wykorzystać ją, aby sparametryzować założony model preferencji. Tak utworzona, na przykład funkcja preferencji, może dalej być użyta podczas procesu ewolucji do ewaluacji konstruowanych rozwiązań. W ten sposób populacja może zbiec do pewnego, z założenia preferowanego, rozwiązania Pareto optymalnego. Jeżeli natomiast decydent podaje swoje przykłady w formie holistycznej, na przykład w postaci porównań parami, jego przykłady preferencji mogą zostać użyte jedynie do ograniczenia przestrzeni parametrów założonego modelu preferencji. Tak ograniczona przestrzeń parametrów musi zostać poddana dalszej analizie. W tym celu, na przykład, niektóre metody wyodrębniają pewien zbiór reprezentatywnych wartości dla parametrów i konstruują reprezentatywną funkcję preferencji. Reprezentatywna funkcja może być użyta podczas procesu ewolucji w sposób analogiczny jak w przypadku bezpośredniej parametryzacji funkcji preferencji.

Obydwa wyżej wymienione przykłady eksploatacji założonego modelu preferencji są obciążone dużym marginesem błędu. W pierwszym przypadku skuteczność algorytmu jest uzależniona od prawidłowej parametryzacji założonej funkcji preferencji przez decydenta. Natomiast w przypadku wykorzystania holistycznych przykładów preferencji do ograniczenia dozwolonych wartości dla parametrów takiej funkcji, warto zauważyć, że istnieje nieskończenie wiele możliwości jej parametryzacji. Każda funkcja, która spełnia

narzucone ograniczenia, jest zwana funkcją spójną. Funkcje spójne dobrze reprezentują potencjalne preferencje decydenta. Jednocześnie, każda z nich może oceniać warianty w inny sposób. Tym samym podejścia oparte o reprezentatywną funkcję preferencji są mało wiarygodne, ponieważ ignorują potencjalne rezultaty uzyskane przy użyciu pozostałych, to jest nieuwzględnionych, funkcji spójnych. Ostatecznie należy przyjąć, iż parametryzacja funkcji preferencji w obydwu przypadkach odbywa się w sposób arbitralny i podatny na błędy, co może skutkować zbieżnością algorytmu w kierunku mniej preferowanych przez decydenta rozwiązań Pareto optymalnych.

By zaradzić powyższym problemom, metoda może wykorzystać analizę odporności, to jest stabilności uzyskanych rekomendacji. Przykładowo, zamiast konstruować jedną reprezentatywną funkcję do oceny jakości rozwiązań, metoda może w pewien sposób agregować możliwe rezultaty uzyskane dzięki wszystkim funkcjom spójnym. Przykładem takiej agregacji jest relacja koniecznej preferencji, która zachodzi, gdy jedno rozwiązanie jest koniecznie preferowane ponad drugie, jeżeli tak wskazują wszystkie funkcje spójne. Innym przykładem jest identyfikacja rozwiązań potencjalnie optymalnych dla decydenta. Rozwiązanie jest potencjalnie optymalne, kiedy uzyskuje najlepszy wynik dla przynajmniej jednej funkcji spójnej. Obie relacje oparte są o pewne skrajne wyniki dla analizy przeprowadzonej na wszystkich funkcjach spójnych. Wyniki pośrednie, to jest ilościowe, można uzyskać dzięki użyciu technik stochastycznej wielokryterialnej analizy akceptowalności. Techniki te pozwalają porównywać rozwiązania wykorzystując pewne stochastyczne wyznaczniki. Przykładem takiego wyznacznika jest stochastyczna relacja preferencji, która określa prawdopodobieństwo zajścia relacji preferencji dla pary wariantów. W porównaniu do analizy odporności opartej o skrajne wyniki, np. relację koniecznej preferencji, stochastyczna wielokryterialna analiza akceptowalności pozwala na lepsze zróżnicowanie rozwiązań względem preferencji decydenta.

Technik odporności mogą zostać wykorzystane w ewolucyjnej optymalizacji wielokryterialnej do poprawy stabilności procesu przeszukiwania przestrzeni rozwiązań, tym samym do skuteczniejszego odnajdywania wysoce preferowanych przez decydenta rozwiązań Pareto optymalnych. Niestety większość istniejących algorytmów nie implementuje takich metod, tym samym pogarszając wiarygodność konstruowanych przez nie rekomendacji.

Powyższe cztery problemy związane z istniejącymi algorytmami opartymi o preferencje decydenta stały się motywacją do niniejszej pracy doktorskiej. Praca ta była więc w głównej mierze skupiona na integracji nowoczesnych, opartych o aktualny stan wiedzy, technik i paradygmatów związanych z ewolucyjną optymalizacją wielokryterialną i wielokryterialnym wspomaganiami decyzji. W ramach tej pracy doktorskiej powstało dziewięć publikacji – z czego jedna jest na dzień 1 czerwca 2020 r. w recenzji – które, jako całość, dotyczą eksploracji dziesięciu oryginalnych celów badawczych. W następujących rozdziałach cele te oraz rezultaty uzyskanych wyników są omówione w zwięzłej formie. Wartym zaznaczenia jest fakt, że wszystkie algorytmy, które powstały w ramach tej pracy doktorskiej, są interaktywne oraz bazują na holistycznych przykładach preferencji decydenta.

## **1. Implementacja algorytmów opartych o nowoczesne schematy ewolucyjne**

W ramach tej pracy doktorskiej zaproponowano dwa nowe algorytmy oparte o nowoczesne schematy ewolucyjne. Pierwszym z zaproponowanych algorytmów jest IEMO/D, który jest oparty o schemat dekompozycji. Podczas procesu ewolucji, IEMO/D konstruuje zbiór funkcji spójnych z preferencjami decydenta, który jest dalej bezpośrednio wykorzystany do ukierunkowania przeszukiwania przestrzeni rozwiązań. Drugą z metod jest IEMO/I, która wykorzystuje jedną funkcję, zwaną wskaźnikiem, do całościowej oceny jakości populacji. Rozwiązania są następnie indywidualnie oceniane na podstawie ich ogólnego wkładu w jakość całej populacji.

Przedstawione algorytmy zostały eksperymentalnie porównane z ich odpowiednikami opartymi o relację dominacji. Wyniki eksperymentów ukazały wysoką skuteczność zaproponowanych algorytmów. Tym samym udowodniły one, że wykorzystanie nowoczesnych schematów ewolucji może nieść z sobą poprawę jakości konstruowanych dla decydenta rekomendacji.

## **2. Implementacja algorytmów wykorzystujących techniki analizy odporności**

Jednym z głównych zadań tej pracy doktorskiej było wdrożenie nowoczesnych technik analizy odporności w interaktywną ewolucyjną optymalizację wielokryterialną. W tym celu zaproponowany został szereg algorytmów opartych o następujące procedury:

- wykorzystanie funkcji spójnych, jako kierunków optymalizacji w algorytmie IEMO/D opartym o dekompozycję,
- wykorzystanie stochastycznej wielokryterialnej analizy akceptowalności w algorytmie EMOSOR do oceny rozwiązań w populacji,
- wykorzystanie stożków preferencji w algorytmach CDEMO oraz DCEMO do identyfikacji preferowanych przez decydenta obszarów w przestrzeni rozwiązań,
- sortowanie oparte o fronty rozwiązań potencjalnie optymalnych, co zostało zaimplementowane w algorytmie IEMO/I oraz w części algorytmów z rodziny NEMO-GROUP.

Wszystkie zaproponowane algorytmy zostały porównane z ich odpowiednikami opartymi o konstrukcję reprezentatywnej funkcji preferencji. Wyniki przeprowadzonych eksperymentów wykazały znacząco poprawę jakości konstruowanych rekomendacji, gdy proces oceny ewaluacji rozwiązań w populacji oparty był o analizę odporności, udowadniając tym samym skuteczność zaproponowanych algorytmów.

## **3. Implementacja nowych strategii interakcji z decydem**

Skuteczność interaktywnych algorytmów zależy w dużej mierze od tego, kiedy algorytm decyduje się odpytać decydenta, to jest uzyskać kolejny przykład jego preferencji. W ramach tej pracy doktorskiej przedstawiony został szereg strategii elicitacji informacji preferencyjnej, które mogą zostać podzielone na dwie grupy:

- strategię statyczne, wywołujące interakcję z decydentem w zadanych, predefiniowanych momentach, to jest generacjach,
- strategię dynamiczne, które podejmują decyzje o interakcji z decydentem, bazując na postępie procesu ewolucji w danej generacji.

Wpływ zaproponowanych strategii elicytacji informacji preferencyjnej na skuteczność interaktywnych algorytmów został zweryfikowany eksperymentalnie. Wyniki przeprowadzonych badań sugerują, że najkorzystniejsze rezultaty uzyskiwane są najczęściej wtedy, gdy interakcje z decydentem rozłożone są równomiernie w toku optymalizacji. W ten sposób algorytm ma dość czasu pomiędzy kolejnymi interakcjami z decydentem, aby możliwie najlepiej wykorzystać jego ostatnio uzyskaną informację preferencyjną. Wyjątkiem od tej reguły okazała się sytuacja, gdy problem optymalizacji był silnie niezbalansowany. W takiej sytuacji algorytm wykazywał najlepszą skuteczność, gdy odpowiednio regulował on częstość interakcji w zależności od poziomu skomplikowania aktualnie eksplorowanego obszaru w przestrzeni rozwiązań.

#### **4. Implementacja algorytmu akceptującego różne formy holistycznych przykładów preferencji**

Istniejące algorytmy zazwyczaj są przystosowane do pracy z jednym typem informacji preferencyjnej, co w znaczącym stopniu ogranicza decydenta w możliwości wyrażenia swoich opinii odnośnie konstruowanych rozwiązań. Ta obserwacja stała się główną motywacją do implementacji algorytmu współpracującego z wieloma typami informacji preferencyjnej. W tym celu algorytm IEMO/D, wcześniej współpracujący tylko z porównaniami parami, został dodatkowo rozszerzony o możliwość wykorzystania przykładów intensywności preferencji, kompletnych rankingów rozwiązań, oraz wyborów najbardziej preferowanych rozwiązań spośród zbioru wariantów.

W przeprowadzonych eksperymentach główna uwaga była skupiona na analizie wpływu każdego z powyższych typów preferencji – z osobna – na efektywność algorytmu IEMO/D. Przeprowadzone eksperymenty pokazały, że IEMO/D wykazał się najlepszą skutecznością w sytuacji, gdy pobierał od decydenta informację preferencyjną w postaci porównań parami oraz intensywności preferencji. Mimo iż oba typy informacji preferencyjnej wydają się nieść z sobą mniej informacji o preferencjach decydenta niż pozostałe dwie formy, to jednak ze względu na ich niski koszt poznawczy, były one częściej dostarczane do algorytmu w przeprowadzonych eksperymentach. W ten sposób, informacja preferencyjna dostarczona przez decydenta dotyczyła bardziej zróżnicowanego zbioru rozwiązań, co pozytywnie wpłynęło na proces uczenia się jego preferencji, tym samym na jakość konstruowanych rozwiązań. Dodatkowo warto zaznaczyć, że IEMO/D oparty o przykłady intensywności preferencji, okazał się nieznacznie skuteczniejszy niż w przypadku, gdy pracował z porównaniami parami.

#### **5. Implementacja procedur wyboru rozwiązań przeznaczonych do ewaluacji przez decydenta**

Skuteczność uczenia się preferencji decydenta w systemach opartych na holistycznych przykładach preferencji zależy w dużej mierze od tego, które rozwiązania zostaną zaprezentowane decydentowi do oceny. W niniejszej pracy doktorskiej zaimplementowany



został szereg procedur służących do selekcji takich rozwiązań. Zaproponowane procedury zostały oparte o koncepcję maksymalizacji potencjalnego zysku informacji na temat systemu preferencji decydenta. Metody te wykorzystują w tym celu analizę przestrzeni funkcji spójnych, bądź dokonują analizy rozkładu wariantów w przestrzeni rozwiązań.

Wpływ wykorzystania zaproponowanych procedur na skuteczność interaktywnych metod został zbadany w kontekście algorytmu IEMO/D. Za punkt odniesienia została uznana skuteczność algorytmu IEMO/D sprzężonego z losowym wyborem rozwiązań referencyjnych. Wyniki przeprowadzonych eksperymentów pokazały, że każda z zaproponowanych procedur skutecznie poprawia jakość rozwiązań konstruowanych przez algorytm.

## **6. Analiza wpływu niespójności na skuteczność interaktywnych algorytmów**

Algorytmy oparte o holistyczne przykłady preferencji sukcesywnie uczą się systemu wartości decydenta w toku optymalizacji. W tym celu przyjmują one pewien model preferencji i starają się wyznaczyć wartości jego parametrów w procesie dezagregacji informacji preferencyjnej. Jednak założony model preferencji może okazać się niespójny z preferencjami decydenta. W takim przypadku może nie istnieć żaden zestaw wartości dla parametrów modelu, dla którego byłby on zdolny odtworzyć dostarczone przykłady preferencji. W przypadku wykrycia niespójności, istniejące algorytmy najczęściej zmieniają przyjęty model preferencji, bądź usuwają część z uzyskanej od decydenta informacji preferencyjnej celem przywrócenia spójności.

Wystąpienie niespójności negatywnie wpływa na skuteczność interaktywnego algorytmu. W tej pracy doktorskiej, poddany ocenie został wpływ takiej niespójności na jakość rozwiązań konstruowanych przez algorytm. W tym celu poddane analizie zostały algorytmy oparte o różne systemy preferencji. Co więcej, uruchomione one zostały dla szeregu decydentów zamodelowanych przy użyciu wielu, skrajnie różnych systemów wartości. Dzięki temu, niespójności między założonym modelem preferencji a informacją preferencyjną otrzymaną od decydenta miały szansę wystąpić podczas ewolucyjnego przeszukiwania. Wyniki tak zdefiniowanych eksperymentów pokazały, że skuteczność interaktywnego algorytmu jest tym gorsza, im słabiej wykorzystany w metodzie model preferencji przystaje do prawdziwego systemu preferencji decydenta. Ponadto wyniki pokazały, że modele preferencji, które są niezdolne do kompensacji kryteriów, znacznie lepiej potrafią reprezentować preferencje decydenta niż ich kompensacyjne odpowiedniki, co pozytywnie wpływa na skuteczność tak sparametryzowanych algorytmów.

## **7. Implementacja koewolucyjnego algorytmu opartego o wiele modeli preferencji**

Wyniki uzyskane w eksperymentach dotyczących analizy niespójności stały się główną motywacją do implementacji algorytmu zdolnego do adaptacji do różnych systemów preferencji. Algorytm ten, nazwany CIEMO/D, został oparty o paradygmat koewolucji. Zamiast jednej populacji, CIEMO/D koewoluują jednocześnie kilka pod-populacji, zwanych także gatunkami. CIEMO/D wiąże z każdym gatunkiem inny model preferencji. W trakcie procesu optymalizacji, podczas kolejnych interakcji z decydem, CIEMO/D analizuje poziom niespójności pomiędzy eksploatowanymi modelami preferencji a otrzymanymi od decydenta przykładami preferencji. Wiedza o niespójności jest dalej wykorzystana przez CIEMO/D do rozdystrybuowania potencjału obliczeniowego

pod-populacjom. Potencjał obliczeniowy jest tutaj wyrażony przez liczbę rozwiązań, które dany gatunek może ewoluować. Im mniej spójny jest model preferencji z preferencjami decydenta, tym mniej rozwiązań otrzymuje przypisany do niego gatunek. W ten sposób algorytm jest w stanie zaadaptować się do różnych systemów preferencji decydenta.

Skuteczność algorytmu CIEMO/D została zweryfikowana w serii eksperymentów dotyczących zarówno zdolności CIEMO/D do adaptacji do różnych systemów preferencji, jak i dotyczących analizy porównawczej z innymi, dedykowanymi dla danego decydenta algorytmami. Obie serie eksperymentów potwierdziły wysoki poziom adaptacji oraz konkurencyjności zaproponowanego algorytmu.

## **8. Implementacja algorytmów przeznaczonych do problemów grupowego podejmowania decyzji**

Większość istniejących interaktywnych algorytmów jest zdolna do współpracy tylko z jednym decydem. Jednakże wiele rzeczywistych problemów decyzyjnych uwzględnia wielu decydentów, którzy mogą mieć różne preferencje. Tym samym znalezienie jednego rozwiązania, które postrzegane byłoby przez wszystkich decydentów jako najbardziej satysfakcjonujące, może być niemożliwe. Zamiast tego algorytm musi znaleźć rozwiązanie, które stanowiłoby dobry konsensus.

W ramach tej pracy doktorskiej zaimplementowany został szereg algorytmów dedykowanych problemom grupowego podejmowania decyzji. Zaproponowane algorytmy zostały zbiorczo nazwane NEMO-GROUP. Wykorzystują one grupowy model preferencji do agregacji informacji preferencyjnej otrzymanej od wielu decydentów. Eksploatując taki model, zaproponowane algorytmy są w stanie ukierunkować przeszukiwanie przestrzeni rozwiązań w taki sposób, by maksymalizować istotność konstruowanych rozwiązań dla wszystkich decydentów jednocześnie. Przeprowadzone eksperymenty potwierdziły, że algorytmy z rodziny NEMO-GROUP są w stanie identyfikować rozwiązania, które stanowią dobry konsensus dla wszystkich decydentów zaangażowanych w proces optymalizacji.

## **9. Zastosowanie algorytmów ewolucyjnych do rozwiązania rzeczywistego problemu optymalizacji wielokryterialnej**

W ramach niniejszej pracy doktorskiej wybrane interaktywne oraz *a posteriori* algorytmy zostały zastosowane do rozwiązania rzeczywistego problemu optymalizacji wielokryterialnej. Nadrzędnym celem tej pracy było pokazanie, że algorytmy ewolucyjne mogą być skutecznym narzędziem w kontekście rozwiązywania rzeczywistych problemów, stanowiąc jednocześnie dobrą alternatywę do klasycznych metod opartych o programowanie liniowe.

Rozważany problem optymalizacji dotyczył konstrukcji zielonego łańcucha dostaw w Południowo-Wschodniej Europie. Problem ten uwzględniał trzy kryteria optymalizacji: całkowity koszt implementacji łańcucha dostaw, całkowitą emisję CO<sub>2</sub> wygenerowaną przez wszystkie środki transportu użyte w tak skonstruowanym łańcuchu, oraz, analogicznie, całkowitą emisję cząstek stałych. W ramach tej pracy zaproponowany został nowy sposób reprezentowania rozwiązania problemu w algorytmie ewolucyjnym – tak zwana reprezentacja genotypu – oraz związane z tym operatory mutacji oraz krzyżowania.

Przeprowadzone eksperymenty dotyczyły analizy algorytmów *a posteriori* jak i algorytmów interaktywnych. W pierwszym przypadku, wybrane algorytmy ewolucyjne: NSGA-II oraz SPEA2, zostały porównane z klasycznymi metodami optymalizacji wielokryterialnej: metodą sumy ważonej oraz metodą epsilon-ograniczeń. Wyniki pokazały, że wszystkie rozważane algorytmy były w stanie skutecznie uzyskać dobre przybliżenie frontu Pareto. Jednakże algorytmy ewolucyjne wymagały w tym celu mniejszych nakładów obliczeniowych. Następnie wybrane interaktywne algorytmy: NEMO-0 oraz wariant NEMO-0 bazujący na algorytmie SPEA2, zostały porównane z ich odpowiednikami *a posteriori*. Wyniki pokazały, że interaktywne algorytmy były w stanie wygenerować rozwiązania, które były znacznie bardziej istotne dla decydenta. Tym samym przeprowadzone eksperymenty dowiodły wysokiej użyteczności zastosowanych metod interaktywnych w kontekście rozwiązywania rzeczywistych problemów optymalizacji wielokryterialnej.

## 10. Zaproponowanie nowych technik do wizualizacji przebiegu optymalizacji wielokryterialnej

Wizualizacja odgrywa ważną rolę w zrozumieniu przebiegu optymalizacji ewolucyjnej. Istniejące prace na temat tej klasy algorytmów nie skupiały większej uwagi na samej wizualizacji. Po pierwsze, wiele prac, by udowodnić zbieżność zaprezentowanych algorytmów, ilustrowało tylko finalny zbiór rozwiązań, tym samym ignorując mnogość rozwiązań skonstruowanych przez algorytm na etapach pośrednich. Po drugie, często ilustrowany był tylko jeden przebieg algorytmu. Jako że algorytmy ewolucyjne są heurystykami – i tym samym przebieg ich działania jest podatny na losowe wahania – tak wygenerowana wizualizacja może nie być reprezentatywna.

Powyższe spostrzeżenia stały się motywacją w tej pracy doktorskiej do zaproponowania dwóch nowych technik wizualizacji przebiegu ewolucyjnej optymalizacji wielokryterialnej. Pierwsza technika wykorzystuje wykres oparty o współrzędne równoległe. Został on przekształcony do formy trójwymiarowej, gdzie trzeci wymiar związany jest z kolejnymi generacjami algorytmu. Na standardowych, pozostałych wymiarach odkładane są generowane rozwiązania w postaci linii łamanych. Tak zbudowany wykres pozwala więc zilustrować wszystkie rozwiązania jakie zostały wygenerowane podczas działania algorytmu.

Druga technika, nazwana ViPEMO, skupia się na ilustracji zbieżności populacji, biorąc pod uwagę wielokrotne, niezależne uruchomienie analizowanego algorytmu. ViPEMO konstruuje wykres w postaci dyskretnej mapy cieplnej. Każde pole na tej mapie odpowiada jednemu obszarowi w przestrzeni rozwiązań. Podczas kolejnych uruchomień algorytmu, ViPEMO identyfikuje rozwiązania, które znajdują się w tych obszarach. Następnie oblicza dla nich pewne wcześniej zdefiniowane statystyki, takie jak, na przykład, moment odkrycia danego regionu przez algorytm. W ten sposób, ViPEMO jest w stanie wiarygodnie i kompleksowo zilustrować oczekiwany przebieg działania algorytmu.

## Podsumowanie

Niniejsza praca doktorska dotyczyła integracji nowoczesnych technik ewolucyjnej optymalizacji wielokryterialnej z zaawansowanymi metodami wspomaganie decyzji. Nadrzędnym celem tej pracy była implementacja efektywnych, interaktywnych algorytmów opartych

o holistyczne przykłady preferencji decydenta. Efektem tej pracy było powstanie dziesięciu oryginalnych publikacji, które dotyczyły dziesięciu nowatorskich i zróżnicowanych kierunków badań.

Wkład przedstawionej pracy doktorskiej w rozwój algorytmów opartych o preferencje decydenta może być oceniony z dwóch perspektyw. Z jednej strony, zaimplementowane procedury zorientowane były na poprawę ogólnej jakości rozwiązań konstruowanych w toku ewolucji. Przykładem tutaj mogą być badania dotyczące wykorzystania nowoczesnych schematów ewolucji, wdrożenia analizy odporności, implementacji nowych strategii interakcji, jak i również procedur wyboru rozwiązań przeznaczonych do holistycznej oceny przez decydenta. Z drugiej strony, zaprezentowane algorytmy zostały oparte o naturalne, wiarygodne i przyjazne decydentowi sposoby elicytacji jego preferencji, będąc tym samym w zgodzie z postulatami teorii wspomaganiania decyzji. Po pierwsze, wszystkie przedstawione algorytmy pozwalają decydentowi na wyrażanie swoich opinii w formie holistycznych przykładów preferencji. Wartym tutaj przypomnienia jest praca dotycząca oparcia dialogu z decydem o wiele takich form preferencji, co w praktyce daje mu większą swobodę w formułowaniu opinii. Po drugie, zaprezentowane algorytmy są w pełni interaktywne. Pozwalają one tym samym decydentowi na lepsze zrozumienie wpływu wyrażanych przez niego opinii na przebieg ewolucji.

W ramach niniejszej pracy doktorskiej wykonano również kilka badań uzupełniających. Pozwoliły one poszerzyć wiedzę na temat ewolucyjnej optymalizacji wielokryterialnej opartej o preferencje decydenta, oraz przedstawiły nowe, unikatowe koncepcje rozwiązywania problemów tej klasy. Po pierwsze, zbadany został wpływ niespójności zastosowanego modelu preferencji z przykładami preferencji dostarczonymi przez decydenta, na skuteczność działania interaktywnych algorytmów. Po drugie, wiedza uzyskana w tych badaniach przyczyniła się do implementacji nowatorskiego algorytmu koewolucyjnego, zdolnego do adaptacji do różnych systemów preferencji. Po trzecie, zaprezentowane zostały algorytmy dedykowane problemom grupowego podejmowania decyzji. Są one jednymi z pierwszych algorytmów takiej klasy, co pozwoliło zbudować podwaliny pod dalsze badania w tym zakresie. Po czwarte, by lepiej wyjaśnić przebieg działania algorytmów ewolucyjnych, zaprezentowane zostały nowe techniki wizualizacji, które pozwalają – w sposób kompleksowy – przedstawić rozwiązania skonstruowane przez algorytm w toku ewolucji.

Eksperymenty przeprowadzone w niniejszej pracy doktorskiej miały również charakter praktyczny. Badania przeprowadzone w pracy dotyczącej problemu konstrukcji zielonego łańcucha dostaw udowodniły wysoką skuteczność algorytmów ewolucyjnych – zarówno tych *a posteriori*, jak i ich interaktywnych wariantów – w kontekście rozwiązywania rzeczywistych problemów optymalizacji wielokryterialnej.