

Wiele wydajnych algorytmów optymalizacyjnych bazuje na pewnego rodzaju procesie uczenia się. Na przykład algorytm mrówkowy (ACO - Ant Colony Optimization) wykorzystuje ideę oznaczania feromonem ścieżek grafu, po którym wirtualne mrówki wędrują w poszukiwaniu drogi. Mrówki monitorują ilość feromonu i wykorzystują te informacje podczas wyboru kolejnych kroków.

Współczesne badania związane z algorytmami optymalizacyjnymi (zwłaszcza w zakresie algorytmów ewolucyjnych) zwykle koncentrują się na podejściach elitarnych. W szczególności najpopularniejsze warianty ACO uczą się tylko na podstawie najlepszych wygenerowanych rozwiązań. Uproszczone pozyskane informacje stają się szczególnie problematyczne w przypadku optymalizacji wielokryterialnych, ponieważ w takich problemach zwykle nie ma jednego najlepszego rozwiązania.

W tym projekcie planujemy rozszerzyć algorytm mrówkowy, w celu lepszego wykorzystania wiedzy zawartej we wszystkich znajdowanych rozwiązaniach, aby przekształcić ją w bardziej wszechstronną strukturę i docelowo poprawić wyniki optymalizacji. Dzięki takiemu podejściu algorytm będzie mógł lepiej wykorzystać czas obliczeniowy poświęcony przygotowaniu rozwiązań i uzyskać więcej informacji, bazując również na przykładach negatywnych.

Algorytmy typu Ant Colony Optimization są bardzo naturalnymi metodami rozwiązywania globalnych problemów optymalizacyjnych, w szczególności trudnych i ważnych problemów transportowych, takich jak problem komiwożera (Travelling Salesman Problem - TSP) czy różne warianty problemu planowania tras pojazdów (Vehicle Routing Problems - VRP). Dzięki intuicyjnemu modelowaniu problemów transportowych i logistycznych algorytmy mrówkowe mają liczne zastosowania przemysłowe, co czyni je ważnym obiektem badań. Problemy transportowe stają się jeszcze trudniejsze i ważniejsze, gdy weźmie się pod uwagę wiele kryteriów (np. można zminimalizować czas podróży, wydatki lub liczbę przesiadek, a zmaksymalizować liczbę oglądanych zabytków po drodze).

Klasyczny ACO (również w aplikacjach optymalizacji wielokryterialnej) wykorzystuje zwykły feromon i wymaga istnienia pewnego rodzaju elitarnego repozytorium rozwiązań. Ważną informację o dominacji (prowadzącą do włączenia pewnych rozwiązań do repozytorium) można dostrzec dopiero po zbudowaniu przez mrówki kompletnych rozwiązań.

W tym projekcie proponujemy:

- Wprowadzić do ACO dwuwymiarowy feromon, kodujący więcej informacji o już skonstruowanych rozwiązaniach (nawet tych zdominowanych), pomagając mrówkom w wykorzystaniu relacji dominacji już podczas konstruowania ich rozwiązań.
- Rozszerzyć repozytorium znalezionych rozwiązań (używane do aktualizacji feromonów), aby zatrzymać więcej kandydatów niż klasyczne podejścia bazujące na pojedynczym froncie Pareto i na podstawie większej ilości informacji wydobytej z takiego repozytorium uaktualniać dwuwymiarowy feromon.
- Zastosować ideę dwuwymiarowego feromonu do rozszerzenia różnych wersji ACO (np. AS, MMAS itd.).
- Zweryfikować skuteczność nowych algorytmów ACO, porównując je do najnowocześniejszych algorytmów optymalizacji wielokryterialnej (np. SPEA, NSGA, MACS, MOEA/D, MOPSO dla problemów TSP i VRP).
- Rozszerzyć stosowalność proponowanego algorytmu poprzez rozważenie innych ważnych problemów, np. problemu pakowania (Bin Packing Problem) czy problemu alokacji maszyn wirtualnych (Virtual Machine Placement Problem).