

Wykorzystanie idei „linkage learning” w rozwiązywaniu ciągłych problemów optymalizacyjnych

Streszczenie

Skuteczne i efektywne rozwiązywanie problemów optymalizacyjnych jest ważne z punktu widzenia praktyki. W przypadku trudnych problemów optymalizacyjnych, często stosuje się w tym celu algorytmy ewolucyjne. W ostatnich latach rozwój algorytmów ewolucyjnych skupia się m.in. na wykorzystaniu idei „linkage learning” podczas ich działania. Pojedynczym rozwiązaniem zadanego problemu optymalizacyjnego może być wektor zmiennych decyzyjnych. Techniki typu „linkage learning” starają się wskazać, które zmienne decyzyjne warto przetwarzać wspólnie, a które niekoniecznie ze względu na ich niezależność. Głównym zastosowaniem tego typu technik w rozwiązywaniu ciągłych problemów optymalizacyjnych są ich wielowymiarowe instancje, które posiadają co najmniej 500 zmiennych decyzyjnych. Poprawna identyfikacja zależnych zmiennych decyzyjnych przez strategie dekompozycji, które są przykładem technik typu „linkage learning”, pozwala na dekompozycję zadanego problemu optymalizacyjnego na mniejsze podproblemy, które mogą być następnie niezależnie optymalizowane zmniejszając tym samym wymiarowość rozważanego problemu.

Niniejsza praca skupia się głównie na strategiach dekompozycji wielowymiarowych problemów optymalizacyjnych o ciągłej przestrzeni przeszukiwań oraz na wykorzystaniu informacji dostarczonych przez te strategie w dalszym procesie optymalizacji. Na podstawie przeprowadzonego przeglądu literatury wskazano wady aktualnie wiodących strategii dekompozycji, które bazują na grupowaniu różnicowym lub sprawdzaniu monotoniczności, m.in. niepoprawna klasyfikacja zmiennych decyzyjnych jako zależnych i niewykrywanie wielu z istniejących zależności pomiędzy zmiennymi decyzyjnymi. Celem niniejszej pracy było zatem zaproponowanie nowej strategii dekompozycji, która będzie eliminować wskazane wady. Wyniki eksperymentów, które zostały przeprowadzone na typowym zbiorze problemów testowych, jego dwóch zaproponowanych w ramach niniejszej pracy modyfikacjach oraz problemie praktycznym z dziedziny sieci komputerowych i komunikacyjnych wskazują, że cel pracy został osiągnięty. Nowo zaproponowana strategia dekompozycji dekomponuje rozważane problemy optymalizacyjne przeważnie z lepszą dokładnością niż aktualnie wiodące strategie dekompozycji. Dokładniejsza dekompozycja wiązała się ze zwiększonym kosztem jej uzyskania. Był on jednak ciągle niewielkim odsetkiem całego budżetu obliczeniowego, dlatego głównym czynnikiem wpływającym na jakość otrzymanych wyników optymalizacji była prawie zawsze dokładność dekompozycji.

25.04.2023r.

Marcin Komarnicki

Linkage learning in continuous problem optimization

Abstract

Solving optimization problems effectively and efficiently is important in terms of real-world applications. To this end, evolutionary algorithms are commonly applied when hard optimization problems are considered. Some recent advances in evolutionary algorithms focus on linkage learning techniques. A single problem solution may be a vector of decision variables. Linkage learning techniques try to mark those decision variables that are worth processing together and those that are not due to their independence. In continuous optimization, these techniques are mainly used to solve large-scale instances that consist of at least 500 decision variables. An accurate discovery of dependent decision variables by decomposition strategies, which are examples of linkage learning techniques, allows of the problem decomposition into smaller subproblems that can be optimized separately afterward. Thus, the problem size is reduced.

This paper focuses mainly on decomposition strategies for large-scale continuous optimization problems and how to utilize information provided by them in the subsequent optimization process. Based on a literature review made by the author, flaws of state-of-the-art decomposition strategies, which are derived from differential grouping or monotonicity checking, are pointed out. For instance, reporting independent variables as dependent and missing many of the existing interactions between variables. Thus, the main objective of this paper was to propose a new decomposition strategy that should not suffer from any of these flaws. According to experimental results for a typical set of test problems, its two modifications proposed in this paper, and a real-world optimization problem related to computer and communication networks, the objective of this paper was achieved. The new decomposition strategy can mostly decompose the considered optimization problems more accurately when compared with state-of-the-art decomposition strategies. The more accurate decomposition resulted in a higher cost. However, it was only a small part of the overall computational budget. Therefore, the main factor that influenced the optimization results was almost always the accuracy of decomposition.

25.04.2023~

Marcin Komarnicki