

СРАВНИТЕЛЬНЫЙ АНАЛИЗ МЕТОДА ВЫБОРА ВСПОМОГАТЕЛЬНЫХ КРИТЕРИЕВ И МЕТОДА СПУСКА СО СЛУЧАЙНЫМИ МУТАЦИЯМИ

М. В. Буздалов

ассистент кафедры компьютерных технологий Университета ИТМО

E-mail: mbuzdalov@gmail.com

А. С. Буздалова

студентка кафедры компьютерных технологий Университета ИТМО

E-mail: abuzdalova@gmail.com

Аннотация. Рассматривается ранее предложенный метод выбора вспомогательных критериев оптимизации EA+RL, предназначенный для повышения эффективности эволюционных алгоритмов и основанный на применении обучения с подкреплением. Формулируется модельная задача, на примере которой сравнивается время работы этого метода и метода спуска со случайными мутациями. Приводится схема доказательства, показывающего, что отношение времен работы рассматриваемых методов выражается как экспонента от параметра модельной задачи, что подтверждает эффективность метода EA+RL.

Введение

Эффективность однокритериальной оптимизации в некоторых случаях может быть повышена путем введения вспомогательных критериев [1]. Насколько известно авторам, в последнее время ведутся активные исследования по применению вспомогательных критериев в задачах дискретной оптимизации, решаемых с помощью эволюционных алгоритмов [2–6].

Использование вспомогательных критериев позволяет избежать остановку процесса оптимизации в локальных оптимумах целевого критерия [4, 5], а также расширяет исследуемую область пространства поиска [2], за счет чего оптимальное значение целевого критерия может быть найдено за меньшее число итераций эволюционного алгоритма.

Вспомогательные критерии, как правило, формулируются в ходе анализа задачи. Например, может проводиться декомпозиция целевого критерия на вспомогательные [6, 7]. Также существует пример автоматической генерации вспомогательных критериев для задачи о генерации тестов против решений олимпиадных задач [8].

Обычно об эффективности вспомогательных критериев довольно сложно судить заранее. Более того, один и тот же вспомогательный критерий на различных этапах процесса оптимизации может как ускорять поиск оптимального значения целевого критерия, так и замедлять его [7]. В связи с этим воз-




Рис. 1. Метод выбора критериев EA+RL,
 t — целевой критерий, j — номер итерации

никает задача автоматического выбора вспомогательного критерия, наиболее эффективного на данном этапе оптимизации, из заранее подготовленного набора критериев.

Автоматический выбор вспомогательных критериев может производиться с помощью ранее предложенного метода EA+RL [9], основанного на выборе критериев оптимизации для эволюционного алгоритма с помощью обучения с подкреплением (см. рис. 1) [10, 11]. Агент обучения на каждой итерации эволюционного алгоритма выбирает критерий оптимизации из списка, состоящего из вспомогательных критериев и целевого. Выбранный критерий используется при формировании очередного поколения эволюционного алгоритма. Затем формируется некоторое представление состояния эволюционного алгоритма, а также награда, зависящая от роста целевого критерия. Награда используется для обновления оценки ожидаемой награды в данном состоянии. Выбирается критерий, максимизирующий оценку ожидаемой награды. В случае, когда оценка одинакова, критерии выбираются равновероятно.

Эффективность метода EA+RL была подтверждена экспериментально на примере решения ряда модельных задач, а также практической задачи генерации тестов [8]. Также существует теоретический результат, показывающий на примере одной модельной задачи, что метод EA+RL позволяет игнорировать неэффективный вспомогательный критерий [12]. Цель данной работы — показать теоретически, что применение метода EA+RL может повысить эффективность оптимизации целевого критерия.

Постановка модельной задачи

Опишем модельную задачу $XdivK$ с одним вспомогательным критерием. Пространство поиска — битовые строки длины n . Пусть x — число единиц в битовой строке. Требуется максимизировать целевой критерий:

$$t = \left\lfloor \frac{x(s)}{k} \right\rfloor,$$

где k — целочисленный параметр, $n \bmod k = 0$. В качестве вспомогательного критерия будем использовать значение x .

Заметим, что оптимизация по вспомогательному критерию позволяет достичь оптимума целевого критерия за меньшее число итераций. Пусть есть две битовые строки a и b с числом единиц y и z соответственно, $y < z$ (см. рис. 2). Пусть также с точки зрения целевого критерия эти строки не различаются. Однако использование строки b с большим числом единиц позволяет улучшить значение целевого критерия с большей вероятностью,

чем использование строки a . Вспомогательный критерий ускоряет процесс оптимизации целевого критерия за счет того, что он позволяет выбрать строку b .

Далее на примере описанной модельной задачи будет сравнено время работы метода EA+RL и эволюционного алгоритма, не использующего вспомогательный критерий. Требуется показать, что метод EA+RL позволит использовать преимущества вспомогательного критерия и найти оптимальное значение целевого критерия за меньшее число итераций.

В качестве эволюционного алгоритма будем рассматривать метод спуска со случайными мутациями. В качестве обучения с подкреплением используется алгоритм Q -обучения [10, 11], поддерживающий текущую оценку ожидаемой награды, которая обновляется в соответствии с формулой: $Q(s, f) = Q(s, f) + \alpha (r + \gamma \max_{f'} Q(s', f') - Q(f, a))$, где f — выбранный критерий, состояние s — значение целевого критерия, награда r — разность значений целевого критерия на двух последовательных итерациях. Изначально Q инициализируется нулями.

Анализ времени работы метода EA+RL и метода спуска со случайными мутациями

В данном разделе представлена общая схема доказательства оценки времени работы метода EA+RL при решении рассматриваемой задачи. Полную версию доказательства можно прочитать в статье [13].

Представим процесс оптимизации как цепь Маркова (см. рис. 3). Общий вид цепи одинаков как для метода EA+RL, так и для метода спуска со случайными мутациями. Вершины цепи соответствуют числу единиц в строке. Цветом выделены вершины, в которых x нацело делится на k . Заметим, что из этих вершин отсутствуют переходы в вершины с меньшим значением x , так как эволюционный алгоритм выбирает строки с большим или равным значением текущего критерия.




Рис. 2. Целевой и вспомогательный критерии в задаче $XdivK$




Рис. 3. Процесс оптимизации в виде цепи Маркова

Рассмотрим число итераций, необходимое для перехода из вершины x в вершину $x + 1$. Пусть $Z_E(x)$ — математическое ожидание числа итераций метода спуска, $Z_R(x)$ — математическое ожидание числа итераций метода EA+RL. На рис. 4 для метода спуска и метода EA+RL рядом с каждым переходом цепи Маркова подписаны выбранный критерий, мутация и вероятность соответствующего перехода.

Оценим вероятности переходов в случае использования метода спуска (см. рис. 4, слева). Для состояний, в которых x делится нацело на k ($x \bmod k = 0$), выполняется соотношение:

$$Z_E(x) = \frac{n-x}{n} + \frac{x}{n} (1 + Z_E(x)) = \frac{n}{n-x},$$

в то время как для остальных состояний выполняется:

$$Z_E(x) = \frac{n-x}{n} + \frac{x}{n} (1 + Z_E(x-1) + Z_E(x)) = \frac{n}{n-x} + Z_E(x-1) \frac{x}{n-x}.$$

Рассмотрим теперь вероятности переходов в случае использования метода EA+RL, выбирающего на каждой итерации вспомогательный или целевой




Рис. 4. Вероятности переходов в методе спуска (слева) и в методе EA+RL (справа)

критерий и передающий этот критерий в метод спуска со случайными мутациями (см. рис. 4, справа). В этом случае вероятность перехода в состояние с меньшим числом единиц ниже, так как при выборе вспомогательного критерия переход в строку с меньшим числом единиц осуществляться не будет.

Для состояний, в которых x делится нацело на k ($x \bmod k = 0$), выполняется соотношение:

$$Z_R(x) = \frac{n-x}{n} + \frac{x}{n} (1 + Z_R(x)) = \frac{n}{n-x},$$

для остальных состояний выполняется:

$$Z_R(x) = \frac{n-x}{n} + \frac{x}{2n} (1 + Z_R(x)) + \frac{x}{2n} (1 + Z_R(x-1) + Z_R(x)),$$

$$Z_R(x) = \frac{n}{n-x} + Z_R(x-1) \frac{x}{2(n-x)}.$$

Приведенные выражения представляются как:

$$Z_E(x) = \sum_{i=0}^{x \bmod k} \frac{\binom{n}{x-i}}{\binom{n-1}{x}}, \quad Z_R(x) = \sum_{i=0}^{x \bmod k} 2^{-i} \frac{\binom{n}{x-i}}{\binom{n-1}{x}},$$

что можно доказать по индукции.

Для вычисления общего числа итераций, необходимого для достижения максимального значения целевого критерия, следует просуммировать полученные выражения вдоль рассмотренной цепи Маркова:

$$T_E(x) = \sum_{x=0}^{n-1} Z_E(x) \quad \text{и} \quad T_R(x) = \sum_{x=0}^{n-1} Z_R(x).$$

Можно показать, что $T_E(n, k) = T_R(n, k) = \Omega(n^k) = O(n^{k+1})$, где k — константа. Также можно показать, что если $n \rightarrow \infty$ при фиксированном k , то

$$\frac{T_E(n, k)}{T_R(n, k)} \geq 2^{k-2} (1 - O(1)).$$

Последнее выражение означает, что метод EA+RL позволяет решить модельную задачу *XdivK* не менее, чем в 2^{k-2} раза быстрее, чем метод спуска со случайными мутациями. Был проведен численный эксперимент, который показал, что данную оценку можно попытаться улучшить до 2^{k-1} .

Заключение

Проведен сравнительный анализ времени работы метода выбора вспомогательных критериев оптимизации EA+RL и метода спуска со случайными мутациями. Показано, что метод EA+RL позволяет решить рассмотренную модельную задачу экспоненциально быстрее в зависимости от параметра задачи. В сформулированной задаче присутствует один вспомогательный критерий, эффективный на протяжении всего процесса оптимизации. В рамках дальнейших исследований целесообразно провести анализ времени работы метода EA+RL на примере задачи, где эффективность вспомогательных критериев зависит от этапа оптимизации.

Л и т е р а т у р а

1. *Евтушенко Ю. Г., Жадан В. Г.* Точные вспомогательные функции в задачах оптимизации // Журнал вычислительной математики и математической физики. № 1. Т. 30. 1990. С. 43–57.
2. *Neumann F., Wegener I.* Can single-objective optimization profit from multiobjective optimization? // Knowles J., Corne D., Deb K., Chair D. (Eds.), *Multiobjective Problem Solving from Nature*, Natural Computing Series, Springer Berlin Heidelberg. 2008. P. 115–130.
3. *Segura C., Coello C. A. C., Miranda G., Léon C.* Using multi-objective evolutionary algorithms for single-objective optimization / *4OR* 11 (3) . 2013. P. 201–228.
4. *Knowles J. D., Watson R. A., Corne D.* Reducing local optima in single-objective problems by multi-objectivization // *Proceedings of the First International Conference on Evolutionary Multi-Criterion Optimization, EMO'01*, Springer-Verlag, London, UK. 2001. P. 269–283.
5. *D. Brockhoff, T. Friedrich, N. Hebbinghaus, C. Klein, F. Neumann, E. Zitzler.* On the effects of adding objectives to plateau functions // *IEEE Trans. Evolutionary Computation* 13 (3). 2009. P. 591–603.
6. *Handl J., Lovell S., Knowles J.* Multiobjectivization by decomposition of scalar cost functions // *Rudolph G., Jansen T., Lucas S., Poloni C., Beume N. (Eds.), Parallel Problem Solving from Nature PPSN X, Vol. 5199 of Lecture Notes in Computer Science*, Springer Berlin Heidelberg. 2008. P. 31–40.
7. *Jensen M. T.* Helper-objectives: Using multi-objective evolutionary algorithms for single-objective optimisation: Evolutionary computation combinatorial optimization // *Journal of Mathematical Modelling and Algorithms* 3 (4). 2004. P. 323–347.
8. *Бuzдалов М. В.* Генерация тестов для олимпиадных задач по программированию с использованием генетических алгоритмов // *Научно-технический вестник СПбГУ ИТМО*. 2011. № 2 (72). С. 72–77.
9. *Buzdalova A., Buzdalov M.* Increasing Efficiency of Evolutionary Algorithms by Choosing between Auxiliary Fitness Functions with Reinforcement Learning // *Proceedings of the Eleventh International Conference on Machine Learning and Applications, ICMLA 2012*. Boca Raton: IEEE Computer Society. Vol. 1. 2012. P. 150–155.
10. *Sutton R. S., Barto A. G.* *Reinforcement Learning: An Introduction*. MIT Press, Cambridge, MA, 1998. 322 p.

11. *Николенко С. И., Тулупьев А. Л.* Самообучающиеся системы. М.: МЦНМО, 2009. 288 с.
 12. *Buzdalov M., Buzdalova A., Shalyto A.* First Step towards the Runtime Analysis of Evolutionary Algorithm Adjusted with Reinforcement Learning // Proceedings of the Twelve International Conference on Machine Learning and Applications, ICMLA 2013. Boca Raton: IEEE Computer Society, 2013. Vol. 1. P. 203–208.
 13. *Buzdalov M., Buzdalova A.* OneMax Helps Optimizing XdivK: Theoretical Runtime Analysis for RMHC and EA+RL // Proceedings of the Genetic and Evolutionary Computation Conference «GECCO-2014». Vol. 2. 2014. P. 201–202.
-