

<https://doi.org/10.26160/2474-5901-2024-41-70-73>

ОСОБЕННОСТИ ПРИМЕНЕНИЯ РОЙНОГО ИНТЕЛЛЕКТА В ОПТИМИЗАЦИИ НЕЙРОННЫХ СЕТЕЙ

Инкижеков А.А., Дулесов А.С.

Хакасский государственный университет им. Н.Ф. Катанова, Абакан, Россия

Ключевые слова: ройный интеллект, оптимизация, нейронные сети, обучение с подкреплением, гиперпараметры, алгоритмы оптимизации, машинное обучение.

Аннотация. Ройный интеллект представляет собой область исследований, основанную на поведении коллективов индивидуальных агентов, которые взаимодействуют друг с другом и окружающей средой. В данной статье рассматривается роевой алгоритм и его комбинации с методами обучения с подкреплением, а также их применение для настройки гиперпараметров и структуры нейронных сетей.

FEATURES OF THE APPLICATION OF SWARM INTELLIGENCE IN THE OPTIMIZATION OF NEURAL NETWORKS

Inkizhekov A.A., Dulesov A.S.

N.F. Katanov Khakass State University, Abakan, Russia

Keywords: swarm intelligence, optimization, neural networks, reinforcement learning, hyperparameters, optimization algorithms, machine learning.

Abstract. Swarm intelligence is a field of research based on the behavior of collectives of individual agents that interact with each other and the environment. This article discusses the swarm algorithm and its combinations with reinforcement learning methods, as well as their application to configure hyperparameters and the structure of neural networks.

Оптимизация нейронных сетей представляет собой сложную задачу, требующую тщательного подбора гиперпараметров и архитектуры для достижения высокой производительности. С появлением глубокого обучения, ростом объема данных, нейронные сети должны наращивать мощь и становиться более сложными. Тем самым должны повышаться требования к методам их оптимизации. Такие традиционные методы как градиентный спуск и случайный поиск, часто сталкиваются с проблемой проталкивания оптимума и затухания градиента в глубоких сетях [1].

Устранение такого рода недостатков видится в применении ройного интеллекта (SI). Это многообещающая альтернатива для решения задачи оптимизации нейросетей. Положительным фактором SI является способностью обучаться на основе коллективного поведения агентов и динамически адаптироваться к изменяющимся условиям. Это делает его привлекательным инструментом для оптимизации сложных нелинейных систем, к которым относят нейронные сети.

Далее в работе предлагается в краткой форме рассмотреть особенности применения ройного интеллекта в контексте оптимизации нейронных сетей, когда процесс обучения с подкреплением использует ройные частицы (RL-PSO).

В качестве математической основы применения RL-PSO отметим следующее. SI основан на наблюдении за поведением коллективов в природе, таких как рой пчел или стая птиц [2]. Созданные математические модели SI, такие как Оптимизация Ройных Частиц (PSO), имитируют поведение роевых частиц в поисках оптимальных решений. Предусмотрено, что в процессе работы PSO, каждая частица движется по пространству решений, обмениваясь информацией с другими частицами и обновляя свое положение на основе лучшего результата, достигнутого всем роем. Это позволяет алгоритму находить оптимальные решения в многомерных и нелинейных пространствах [3].

Формула обновления позиции частицы в PSO выглядит следующим образом:

$$x_i = x_i(t) + v_i(t+1),$$

где $x_i(t)$ текущая позиция частицы i в момент времени t ; $v_i(t+1)$ – скорость частицы i в момент времени $t+1$.

Скорость обновляется на каждом шаге итерации следующим образом:

$$v_i(t+1) = \omega \cdot v_i(t) + c_1 \cdot r_1 \cdot (p_i(t) - x_i(t)) + c_2 \cdot r_2 \cdot (p_g(t) - x_i(t)),$$

где ω – инерционный вес, c_1 и c_2 – коэффициенты ускорения, r_1 и r_2 – случайные числа в интервале $[0,1]$, $p_i(t)$ – лучшая позиция частицы i на предыдущих шагах, $p_g(t)$ – лучшая позиция в рое на предыдущих шагах [4].

Что касается обучения с подкреплением при использовании ройных частиц, оно объединяет методы ройного интеллекта и обучения с подкреплением. В RL-PSO каждая частица роя представляет собой агента, который исследует пространство гиперпараметров и архитектур нейронной сети. Каждая частица получает вознаграждение (или штраф) в зависимости от того, насколько хорошо ее текущая конфигурация сети решает поставленную задачу. Это вознаграждение обратно подается в алгоритм PSO, где оно используется для обновления скорости и позиции частицы в пространстве решений [4, 5].

Процесс обучения в RL-PSO включает в себя следующее.

1. Инициализацию роя. Представляет собой начальную позицию, в которой скорость каждой частицы генерируются случайным образом в пространстве гиперпараметров и архитектур нейронной сети.

2. Итеративное обновление, когда на каждой итерации алгоритма каждая частица перемещается в новую позицию в пространстве решений в соответствии с текущей скоростью и ее лучшим предыдущим положением. Далее вычисляется значение функции цели (вознаграждения) для новой позиции. Если это значение наилучше, чем лучшее значение для данной частицы на предыдущих итерациях, то это положение становится новым лучшим для этой частицы.

3. Обновление глобального лучшего положения заключается в том, что если текущее положение частицы является лучшим среди всех частиц на данной итерации, то оно становится глобальным лучшим положением.

4. Обновление скорости и позиции заключается в том, что каждая из частиц обновляется на основе ее предыдущей скорости, текущего лучшего личного положения и текущего лучшего глобального положения, с учетом коэффициентов инерции и ускорения.

5. Проверка условия завершения является итеративным процессом. Он заканчивается при достижении заданного критерия сходимости или истечения максимального числа итераций [5].

Процесс обучения в RL-PSO позволяет быстро находить оптимальные конфигурации сети, обеспечивая высокую производительность на различных задачах машинного обучения. Тем самым сокращается время и ресурсы, необходимые для разработки и настройки нейронных сетей [4].

Применение RL-PSO как метода оптимизации нейронных сетей обладает следующими преимуществами.

1. Эффективность в исследовании пространства параметров связана с возможностями исследования больших и многомерных пространства гиперпараметров и архитектур нейронных сетей.

2. Скорость сходимости обусловлена комбинированием методов ройного интеллекта и обучения с подкреплением, что позволяет быстро находить оптимальное решение.

3. Адаптивность к изменяющимся условиям обеспечивает устойчивость и эффективность нейронных сетей в различных сценариях использования.

4. Автоматизация процесса настройки гиперпараметров и архитектуры сети освобождает пользователей от необходимости ручной настройки.

Применение RL-PSO открывает новые возможности для создания более эффективных и адаптивных моделей, способных успешно решать разнообразные задачи в различных областях, начиная от компьютерного зрения и обработки естественного языка до биоинформатики и финансовых анализов [5].

Дальнейшее развитие RL-PSO не исключает из рассмотрения таких направлений для дальнейших исследований как развитие гибридных методов, адаптация к сложным архитектурам сетей, разработка новых функций вознаграждения, применение в различных областях (медицина, финансы, биоинформатика и другие).

В заключении отметим следующее. использование ройного интеллекта, особенно в виде метода обучения с подкреплением с использованием ройных частиц (RL-PSO), представляет собой мощный и перспективный подход к оптимизации нейронных сетей. Этот метод объединяет в себе преимущества ройного интеллекта. Он способен исследовать пространство гиперпараметров и архитектур сетей, с принципами обучения с подкреплением, обеспечивающими эффективное обучение агентов на основе получаемого опыта.

В целом, использование RL-PSO представляет собой перспективный подход к оптимизации нейронных сетей, когда требуется значительно улучшить эффективность и адаптивность моделей машинного обучения, а также сделать процесс их разработки более эффективным и автоматизированным.

Список литературы / References

1. Sutton R.S., Barto A.G. Reinforcement Learning: An Introductionю – London, England: MIT Press, 2018. – 437 p.
2. Kennedy J., Eberhart R. Particle swarm optimization // Proceedings of ICNN'95 - International Conference on Neural Networks. 1995, vol. 4, pp. 1943-1948. doi.org/10.1109/ICNN.1995.488968.
3. Poli R., Kennedy J., Blackwell, T. Particle swarm optimization // Swarm Intelligence. 2007, vol. 1, pp. 33-57. doi.org/10.1007/s11721-007-0002-0.
4. Feng L., Wei W., Adaptive Particle Swarm Optimization Algorithm and its Application // Journal of Software Engineering. 2012, vol. 6(3), pp. 41-48. doi.org/10.3923/jse.2012.41.48.
5. Gad A.G. Particle Swarm Optimization Algorithm and Its Applications: A Systematic Review // Archives of Computational Methods in Engineering. 2022, vol. 29, pp. 2531-2561. doi.org/10.1007/s11831-021-09694-4.

Инкижеков Анатолий Анатольевич – аспирант	Inkizhekov Anatolii Anatolevich – postgraduate student
Дулесов Александр Сергеевич – доктор технических наук, доцент, профессор	Dulesov Aleksandr Sergeevich – doctor of technical sciences, associate professor, professor
inkizhekov@mail.ru	

Received 28.02.2024