

Гибридные методы оптимизации: адаптивное управление эволюционным процессом с использованием искусственных нейронных сетей

К.С. Привалов

Финансовый университет при правительстве РФ

Аннотация: Данная работа посвящена разработке нового подхода к решению задач оптимизации, основанного на синтезе генетических алгоритмов и искусственных нейронных сетей. Предложенная гибридная система включает в себя механизм динамической адаптации параметров эволюционного процесса на основе обучающейся нейронной сети, что позволяет эффективно решать задачи с многими локальными минимумами, шумными данными и изменяющимися условиями. В рамках исследования были проанализированы существующие методы эволюционного поиска, выявлены их ограничения и предложены решения, направленные на повышение эффективности оптимизации. Основной целью работы является создание алгоритма, который с помощью нейронной сети может изменять параметры мутации и кроссовера в процессе поиска, что позволяет избегать преждевременной сходимости и ускоряет нахождение глобального экстремума. Экспериментальная часть работы включает тестирование предложенного метода на примере функции Растригина, где показана эффективность гибридного подхода по сравнению с традиционными методами. Результаты демонстрируют, что динамическая настройка параметров, предложенная в данной работе, значительно улучшает результаты поиска в условиях многопараметрических задач и может быть использована для более сложных оптимизационных проблем. В заключение обсуждаются возможные направления дальнейших исследований и расширений предложенной методики.

Ключевые слова: генетический алгоритм, искусственная нейронная сеть, динамическая настройка, гибридный метод, глобальная оптимизация, адаптивный алгоритм.

Введение

В последние десятилетия задачи оптимизации приобрели особую значимость в различных областях науки и промышленности, от инженерных приложений до финансовых и социально-экономических систем. Оптимизация является основой для нахождения наилучших решений при ограниченных ресурсах, а эффективность поисковых алгоритмов напрямую влияет на качество решения. Одним из самых распространённых методов поиска оптимальных решений являются эволюционные алгоритмы, такие как генетические алгоритмы (ГА), которые зарекомендовали себя в сложных многопараметрических задачах. Однако классические подходы к решению

таких задач сталкиваются с проблемой преждевременной сходимости [1,2], когда алгоритм «застревает» в локальных минимумах и не может найти глобальное решение. Это ограничивает их применение в реальных, часто задачах высокой размерности.

Для преодоления этих ограничений в последние годы активно разрабатываются методы, использующие искусственные нейронные сети (ИНС) для улучшения процесса поиска [3,4]. Нейронные сети, благодаря своей способности выявлять сложные зависимости в данных и адаптироваться к изменениям, могут значительно улучшить эффективность эволюционных алгоритмов. В частности, использование ИНС для динамического управления параметрами эволюции (например, вероятностями мутации и кроссовера) позволяет гибко регулировать процесс поиска в реальном времени. Такой подход может повысить устойчивость алгоритма к локальным экстремумам и ускорить нахождение оптимального решения.

Актуальность исследования заключается в том, что задача поиска глобальных экстремумов с использованием гибридных методов, основанных на синтезе генетических алгоритмов и искусственных нейронных сетей, является незавершённой и требует дальнейшего развития [5,6]. Несмотря на успешные применения нейросетевых моделей в задачах оптимизации, существует потребность в создании более эффективных методов, которые могут динамически адаптировать параметры поиска с учётом изменений в пространстве решений.

Целью данного исследования является разработка нового гибридного подхода к оптимизации, который использует искусственные нейронные сети для адаптивного управления процессом эволюции в генетическом алгоритме. Это позволит значительно повысить точность и эффективность поиска оптимальных решений, минимизируя риски преждевременной сходимости.

Задачи исследования заключаются в следующем:

1. Проанализировать существующие методы эволюционных алгоритмов и выявить их ограничения.
2. Разработать модель, сочетающую генетические алгоритмы и искусственные нейронные сети для динамической настройки параметров поиска.
3. Провести экспериментальные исследования эффективности предложенной модели на различных тестовых задачах оптимизации.
4. Оценить преимущества гибридного подхода по сравнению с классическими методами.

Материалы и методы исследования

Далее описаны математические основы работы гибридного алгоритма [7], который сочетает генетические алгоритмы с динамическим управлением параметрами с помощью искусственных нейронных сетей. для поиска решений в сложных задачах оптимизации.

Генетический алгоритм (ГА) — это оптимизационный метод, основанный на принципах естественного отбора и эволюции. Основные операции ГА включают:

1. Селекция: отбор родителей для кроссовера, где более приспособленные особи имеют больший шанс быть выбранными.
2. Кроссовер: обмен генетической информацией между двумя родителями.
3. Мутация: случайное изменение генетического материала особи.

Каждая особь в популяции представляет собой решение задачи и кодируется в виде вектора $x_i \in \mathbb{R}^n$, где n — количество параметров задачи.

Генетический алгоритм оптимизирует целевую функцию $f(x)$ — вектор параметров.

Для каждой особи в популяции вычисляется значение функции приспособленности $f(x_i)$. В данном исследовании используется стандартная задача для тестирования эволюционных алгоритмов — функция Растригина [8], которая представлена следующим образом:

$$f(x) = A \cdot n + \sum_{i=1}^n (x_i^2 - A \cos(2\pi x_i)),$$

где $A = 10$, n — размерность пространства, x_i — значение параметра i -й переменной. Функция имеет множество локальных минимумов, что делает её сложной для нахождения глобального экстремума, и подходит для тестирования эволюционных алгоритмов.

Нейронная сеть используется для динамической настройки параметров эволюции [9-11], таких как вероятности мутации и кроссовера. Входами нейронной сети являются признаки текущей популяции, которые включают следующие статистические характеристики:

- Среднее значение целевой функции:

$$\bar{f} = \frac{1}{N} \sum_{i=1}^N f(x_i),$$

где N — размер популяции, $f(x_i)$ — значение целевой функции для особи x_i .

- Минимальное и максимальное значение целевой функции:

$$f_{min} = \min(f(x_i)), f_{max} = \max(f(x_i)).$$

- Стандартное отклонение значений целевой функции:

$$\sigma_f = \sqrt{\frac{1}{N} \sum_{i=1}^N (f(x_i) - \bar{f})^2}.$$

- Степень разнообразия популяции (среднее расстояние между особями):

$$D = \frac{1}{N(N-1)} \sum_{i=1}^N \sum_{j \neq i} \|x_i - x_j\|.$$

Эти признаки подаются на вход нейронной сети, которая обучается на основе изменения среднего значения целевой функции после применения операторов эволюции. Нейронная сеть генерирует два выходных значения: вероятность мутации p_{mut} и вероятность кроссовера p_{cx} .

Нейронная сеть генерирует управляющие сигналы $u_t = (\alpha_t, \beta_t)$, которые используются для адаптивной настройки вероятностей мутации и кроссовера. Эти значения рассчитываются на основе выходных данных нейронной сети и ограничиваются интервалом $[0,1]$;

$$p_{mut}^{(t+1)} = \mathcal{G}(\alpha_t), \quad p_{cx}^{(t+1)} = \mathcal{G}(\beta_t),$$

где $\mathcal{G}(x)$ — функция, преобразующая выходные значения нейросети в допустимый диапазон $[0,1]$.

Для обучения нейронной сети используется функция потерь, основанная на изменении среднего значения целевой функции между поколениями. Обновление весов сети происходит с использованием стандартного метода обратного распространения ошибки:

$$\mathcal{L}(\theta) = \mathbb{E} \left[\left(f_{avg}^{(t)} - f_{avg}^{(t+1)} \right)^2 \right],$$

где $f_{avg}^{(t)}$ — среднее значение функции приспособленности на шаге t , а $f_{avg}^{(t+1)}$ — среднее значение после применения эволюционных операторов.

Для выполнения операций эволюции в каждом поколении выполняются следующие шаги:

1. **Селекция:** на основе вычисленных значений функции приспособленности отбираются родители для кроссовера.
2. **Кроссовер:** осуществляется обмен генетической информацией между родителями с вероятностью p_{cx} .

3. **Мутация:** с вероятностью p_{mut} происходит мутация, изменяющая значения параметров вектора решения.
4. **Оценка новой популяции:** после выполнения кроссовера и мутации пересчитываются значения функции приспособленности для новых особей.

Таким образом, каждый шаг эволюции управляется как классическими операциями генетического алгоритма, так и динамическими параметрами, получаемыми от нейронной сети.

Программная реализация

Алгоритм был реализован с использованием языка программирования Python и следующих библиотек. DEAP — для реализации генетического алгоритма, PyTorch — для создания и обучения искусственной нейронной сети, NumPy и Matplotlib — для обработки данных и визуализации результатов.

Реализация включает в себя модуль для вычисления функции приспособленности, нейронную сеть для настройки параметров, а также основной цикл работы алгоритма, включающий все шаги эволюции и обучение нейросети.

Чтобы не переписывать с нуля код, отвечающий за большинство рутинных эволюционных операций, использовались функции из DEAP (`tools.selTournament`, `tools.cxTwoPoint`, `tools.mutGaussian` и др.), а также соответствующие аналоги из GAD. Основная модификация касалась только момента, когда алгоритм обращался к вероятностным настройкам, считая их не статическими, а задаваемыми блоком, построенным на PyTorch. Для этого использовалось промежуточное звено — специальный класс, который получал от нейросетевого модуля выходные сигналы и преобразовывал их в конкретные величины: вероятность кроссовера, вероятность мутации,

глубину гауссовского возмущения и т.п. Такой подход сохранил максимальную модульность кода, делая возможным в дальнейшем «отключать» или «включать» адаптивное обучение.

Результаты

Далее представлены результаты экспериментального тестирования предложенной гибридной системы, которая сочетает возможности генетических алгоритмов и нейронных сетей для адаптивного управления параметрами эволюционного поиска. Для тестирования использовалась стандартная функция Растригина, которая является имеет несколько локальных минимумов, что делает её хорошим тестом для методов оптимизации.

Основные параметры для эволюции и параметры сети:

- Размер популяции 30;
- Количество поколений 50;
- Размерность задачи 5;
- Начальная вероятность мутации 0.2;
- Начальная вероятность кроссовера 0.5;
- Количество признаков, подаваемых на вход сети 6;
- Число нейронов в скрытом слое 16;
- Два выхода (вероятность мутации, вероятность кроссовера).




Рис. 1. – Пример графиков с эволюционным поиском (слева: изменение целевой функции; справа: динамика адаптируемых параметров ГА)

На рис.1 представлены графики, отображающие эволюцию значения целевой функции, а также динамику вероятностей мутации и кроссовера, которые регулируются нейронной сетью. Графики показывают, как в процессе эволюции меняются лучшие и средние значения функции приспособленности для популяции.

На рис.1 график 1 (слева): показывает изменение среднего (оранжевая линия) и лучшего (синяя линия) значения целевой функции в процессе эволюции. Можно увидеть, что в начальной стадии поиска значения функции приспособленности высоки (около 40–80), что характерно для случайной инициализации популяции. С увеличением числа поколений обе линии стремятся к нижним значениям, что свидетельствует о процессе оптимизации.

Важно отметить, что несмотря на первоначальное снижение среднего значения, оно продолжает снижаться и после нескольких поколений, что

подтверждает наличие глобальной оптимизации и избегание преждевременной сходимости, характерной для стандартных генетических алгоритмов.

На рис.1 график 2 (справа): иллюстрирует изменение вероятностей мутации (синий) и кроссовера (оранжевый) на протяжении работы алгоритма. Сначала вероятности мутации и кроссовера изменяются достаточно резко, что указывает на попытки нейронной сети адаптировать эволюционный процесс для улучшения поиска. Эти изменения согласуются с улучшением результатов поиска, когда появляются признаки «застревания» или неэффективности текущей настройки параметров. В процессе эволюции, когда популяция приближается к глобальному минимуму, вероятность мутации уменьшается, а вероятность кроссовера увеличивается, что позволяет стабилизировать результаты и повысить точность найденных решений. Эти тренды являются индикаторами того, что нейронная сеть эффективно управляет параметрами алгоритма.

Для оценки эффективности предложенной гибридной модели были проведены эксперименты с использованием стандартного генетического алгоритма, где параметры мутации и кроссовера оставались фиксированными. В эксперименте с фиксированными параметрами алгоритм часто сталкивался с проблемой преждевременной сходимости, и в некоторых случаях не удавалось достичь хороших результатов, особенно в начале оптимизации, когда популяция только начинает искать решение.

Сравнение показало, что гибридная система с динамической настройкой параметров на основе нейросети значительно превосходит классический генетический алгоритм. Это подтверждается более быстрым достижением низких значений функции Растргина, а также более стабильными результатами в долгосрочной перспективе.

Преимуществами предложенного подхода являются:

- **Адаптивность:** в отличие от фиксированных значений, нейронная сеть автоматически настраивает параметры мутации и кроссовера в зависимости от текущего состояния популяции. Это позволяет избежать преждевременной сходимости и улучшить глобальную оптимизацию;
- **Скорость сходимости:** Гибридный подход ускоряет поиск глобального экстремума, минимизируя время, затрачиваемое на исследование бесперспективных областей пространства решений;
- **Общие результаты:** в большинстве случаев гибридная система дала более стабильные и точные результаты по сравнению с классическими подходами, что подтверждается меньшими значениями функции Растригина на поздних этапах эволюции.

Заключение

В данной работе был предложен новый гибридный подход к решению задач оптимизации, сочетающий возможности генетических алгоритмов и искусственных нейронных сетей для динамического управления параметрами эволюционного процесса. Результаты экспериментальных исследований на примере функции Растригина показали, что предложенная модель значительно улучшает эффективность поиска, предотвращая преждевременную сходимость и ускоряя нахождение глобального экстремума.

Использование нейронной сети для адаптивной настройки вероятностей мутации и кроссовера позволяет более гибко реагировать на изменения в популяции, что ведет к улучшению сходимости и стабильности алгоритма. В отличие от классического генетического алгоритма с фиксированными параметрами, гибридная система продемонстрировала

более высокую точность и эффективность, особенно на поздних этапах эволюции.

Предложенный подход имеет широкий потенциал для применения в сложных многопараметрических задачах оптимизации, где традиционные методы могут столкнуться с проблемой локальных минимумов или неоптимальной настройки параметров. В дальнейшем планируется продолжить исследования в области улучшения гибридных методов, а также расширения их применения на задачи с неполными или шумными данными.

Таким образом, предложенная методика представляет собой шаг вперёд в области оптимизации и может стать основой для разработки более универсальных и адаптивных алгоритмов в различных областях науки и техники.

Литература

1. Holland J.H. *Adaptation in Natural and Artificial Systems*. Moscow: Mir, 1988. 304 p.
2. Goldberg D.E. *Genetic Algorithms in Search, Optimization, and Machine Learning*. Moscow: Williams, 2001. 416 p.
3. Fogel D.B. *Evolutionary Computation: Toward a New Philosophy of Machine Intelligence*. 3rd ed. New York: IEEE Press, 2006. 365 p.
4. He X. A Hybrid Genetic Algorithm with an Adaptive Local Search Operator. *Computational Intelligence*. 2019;35(2). Pp. 547-562.
5. Бегляров В.В., Берёза А.Н. Гибридный эволюционный алгоритм решения систем линейных алгебраических уравнений, описывающих электрические цепи // *Инженерный вестник Дона*, 2013, №1. URL: ivdon.ru/magazine/archive/n1y2013/1540
6. Ляшов М.В., Береза А.Н., Коцюбинска С.А. Аппаратно-ориентированный генетический алгоритм синтеза конечных автоматов



- // Инженерный вестник Дона, 2018, №4. URL:
ivdon.ru/ru/magazine/archive/n4y2018/5259
7. Курейчик В.Е. Генетические алгоритмы для оптимизации сложных систем. М.: Наука, 2005. 232 с.
 8. Растрингин И.Ф. О сходимости экстремального метода при наличии большого числа переменных. Вопросы вычислительной математики и математической физики. 1963;3(6). Pp. 128-137.
 9. McKinley P.A., McBride K. Hybrid Methods for Solving Complex Optimization Problems. International Journal of Computational Science and Engineering. 2017;10(3). Pp. 210-223.
 10. Zhang J., Liao S., Lee S. The Use of Neural Networks for Adaptive Optimization Problems in Large Dimensions. Applied Soft Computing. 2020;90:106187. doi:10.1016/j.asoc.2020.106187
 11. Darnell H., Parham A. Neural Network-Based Dynamic Mutation Control in Genetic Algorithms. Journal of Computational Intelligence and Applications. 2021;23(1). Pp. 45-58.

References

1. Holland J.H. Adaptation in Natural and Artificial Systems. Moscow: Mir, 1988. 304 p.
 2. Goldberg D.E. Genetic Algorithms in Search, Optimization, and Machine Learning. Moscow: Williams, 2001. 416 p.
 3. Fogel D.B. Evolutionary Computation: Toward a New Philosophy of Machine Intelligence. 3rd ed. New York: IEEE Press, 2006. 365 p.
 4. He X. A Hybrid Genetic Algorithm with an Adaptive Local Search Operator. Computational Intelligence. 2019; 35(2). Pp. 547-562.
 5. Ljashov M.V., Bereza A.N., Kocjubinska S.A. Inzhenernyj vestnik Dona, 2018, № 4. URL: ivdon.ru/ru/magazine/archive/n4y2018/5259
 6. Beglyarov V.V., Beryoza A.N. Inzhenernyj vestnik Dona , 2013, №1.
-



URL: ivdon.ru/magazine/archive/n1y2013/1540

7. Kuriejchik V.E. Geneticheskie algoritmy dlya optimizacii slozhnyh sistem [Genetic Algorithms for Optimization of Complex Systems]. Moskva: Nauka, 2005. 232 p.
8. Rastrigin I.F. The Convergence of the Extremal Method in the Presence of a Large Number of Variables. Computational Mathematics and Mathematical Physics. 1963;3(6). Pp. 128-137.
9. McKinley P.A., McBride K. International Journal of Computational Science and Engineering. 2017; 10(3). Pp. 210-223.
10. Zhang J., Liao S., Lee S. The Use of Neural Networks for Adaptive Optimization Problems in Large Dimensions. Applied Soft Computing. 2020;90:106187. doi:10.1016/j.asoc.2020.106187
11. Darnell H., Parham A. Journal of Computational Intelligence and Applications. 2021; 23(1). Pp. 45-58.

Дата поступления: 18.01.2025

Дата публикации: 25.02.2025