

УДК 004.89



СРАВНИТЕЛЬНЫЙ АНАЛИЗ ИММУННОГО И ГЕНЕТИЧЕСКОГО АЛГОРИТМОВ В ЗАДАЧАХ ОПТИМИЗАЦИИ НЕЛИНЕЙНЫХ ФУНКЦИЙ

Н.М. Кораблев¹, И.В. Овчаренко², В.В. Токарев³¹ ХНУРЭ, г. Харьков, Украина, korablev@kture.kharkov.ua² ХНУРЭ, г. Харьков, Украина, i.ovcharenko@kture.kharkov.ua³ ХНУРЭ, г. Харьков, Украина, tvv.v@mail.ru

В работе приводится сравнительный анализ иммунного алгоритма, основанного на принципе клонального отбора и теории иммунной сети, и простого генетического алгоритма в задачах глобальной и мультимодальной оптимизации нелинейных функций нескольких переменных. Показана эффективность применения иммунного алгоритма для нахождения глобальных и локальных экстремумов в задачах мультимодальной оптимизации. Рассмотрена вычислительная сложность приведенных алгоритмов.

ИСКУССТВЕННЫЕ ИММУННЫЕ СИСТЕМЫ, ИММУННЫЙ АЛГОРИТМ, ГЕНЕТИЧЕСКИЙ АЛГОРИТМ, МУТАЦИЯ, ГЛОБАЛЬНАЯ ОПТИМИЗАЦИЯ, МУЛЬТИМОДАЛЬНАЯ ОПТИМИЗАЦИЯ

Введение

При решении задачи оптимизации нелинейных функций нескольких переменных необходимо учитывать их свойства, что существенно влияет на выбор метода ее решения. Оптимальное решение задачи оптимизации может быть получено с использованием классических методов прямого поиска (методов сеток, покоординатного спуска, случайного поиска) либо градиентных методов, использующих значения первых производных. Однако недостатком этих методов является необходимость определения характера целевой функции (непрерывность, унимодальность, дифференцируемость функции), зависимость от начального приближения и, как следствие, большая вероятность «застывания» алгоритма в локальном экстремуме. Таким образом, в условиях отсутствия априорной информации о характере поведения целевой функции использование классических методов оптимизации является сложной, а часто нерешаемой задачей. В связи с этим встает задача использования таких методов оптимизации, которые были бы способны отыскивать решения практически при полном отсутствии предположений о характере исследуемой функции. К таким методам относятся методы, в основе которых лежат биологические процессы, существующие в природе, в частности, искусственные иммунные системы (ИИС) и генетические алгоритмы (ГА).

ИИС представляют собой направление искусственного интеллекта, эмулирующее естественную иммунную систему. В ИИС используется способность естественной иммунной системы вырабатывать новые типы антител и отбирать наиболее подходящие из них для взаимодействия с попавшими в организм антигенами. Иммунная система обладает свойствами разнообразия, памяти, распределенного обнаружения, сетевой организации, обучения,

распознавания, которые позволяют использовать ее для решения таких проблем как оптимизация, распознавание образов, поиск данных, компьютерная безопасность, обнаружение ошибок, классификация и других [1, 2].

ГА представляют собой эволюционные алгоритмы, реализующие адаптивные методы поиска. Эти алгоритмы обеспечивают выживание сильнейших решений из множества сгенерированных, формируя и изменяя процесс поиска на основе моделирования эволюции исходной популяции решений [3]. ГА применяются для решения многих конкретных научных и технических проблем, но одним из наиболее распространенных приложений генетических алгоритмов является их использование для оптимизации многопараметрических функций.

Применение ИИС и ГА позволяет решать многие проблемы классических методов оптимизации.

1. Постановка задачи

Рассматривается задача оптимизации нелинейных функций нескольких переменных:

$$F(x_1, x_2, \dots, x_n) \rightarrow \min, \quad x_1, x_2, \dots, x_n \in X.$$

Эта задача решается с использованием иммунного алгоритма (ИА), основанного на принципе клонального отбора и теории иммунной сети, и простого ГА. При этом антитела в ИА и хромосомы в ГА представляют собой строки фиксированной длины $S = \langle x_1, x_2, \dots, x_n \rangle$, состоящие из двоичных символов и представляющие вещественные значения переменных оптимизируемой функции. Для кодирования значений переменных используется код Грея.

В работе ставится задача проведения сравнительного анализа применения ИА и ГА для решения задач оптимизации по следующим направлениям: глобальная оптимизация, мультимодальная оптимизация, вычислительная сложность алгоритмов.

2. Решение задачи оптимизации

2.1. Иммунный алгоритм

Исследуемый ИА для решения задачи оптимизации основан на принципе клонального отбора и теории иммунной сети и включает следующие шаги [4]:

Шаг 1. Генерация популяции антител Ab .

Шаг 2. Вычисление аффинности популяции антител Ab к выбранному антигену Ag_i .

Шаг 3. Клонирование n лучших по популяции антител N_c раз, формирование популяции клонов C .

Шаг 4. Мутация клонов, формирование популяции C_m .

Шаг 5. Определение аффинности клонов, подвергавшихся мутации.

Шаг 6. Клетки популяции C_m с лучшей аффинностью к выбранному антигену формируют популяцию клеток памяти M .

Шаг 7. Определение аффинности антител внутри популяции, супрессия антител.

Шаг 8. Количество антител N_d с худшими значениями аффинности заменяется новыми.

Шаг 9. Если достигнуто правило останова, то осуществляется переход к шагу 10, в противном случае — переход к шагу 2.

Шаг 10. Конец работы.

2.2. Генетический алгоритм

Простой ГА поиска оптимальных решений включает следующие этапы процесса эволюции [3]:

Шаг 1. Генерация начальной популяции хромосом.

Шаг 2. Вычисление приспособленности хромосом популяции (целевая функция) и средней приспособленности всей популяции.

Шаг 3. Выбор двух родителей (хромосом) для кроссовера пропорционально приспособленности хромосом.

Шаг 4. Формирование генотипа потомка. Применение с заданной вероятностью операторов кроссовера и мутации.

Шаг 5. Обновление текущей популяции путем замены случайно выбранной хромосомы.

Шаг 6. Пересчет средней приспособленности популяции.

Шаг 7. Если достигнуто правило останова, то осуществляется переход к шагу 8, в противном случае — переход к шагу 3.

Шаг 8. Конец работы.

3. Экспериментальные исследования

Сравнительный анализ иммунного и генетического алгоритмов проводился на примере тестовых функций, приведенных в табл. 1.

3.1. Глобальная оптимизация

В процессе работы иммунного алгоритма при поиске глобального минимума тестовых функций

среднее по популяции значение аффинности стремится к минимальному значению, так как антитела сосредотачиваются в одном пике, образуя клетки памяти. Таким образом, выполнение алгоритма прекращается при приближении среднего по популяции значения функции цели к минимальному значению (рис. 1а, 2а, 3а).

Таблица 1

№	Функция	Область поиска
1	$F_1(x_1, x_2) = x_1^2 + x_2^2$	$x_1, x_2 \in [-5, 5]$
2	$F_2(x_1, x_2) = 3(1 - x_1)^2 \times \exp(-x_1^2 - (x_2 + 1)^2) - 10\left(\frac{x_1}{5} - x_1^3 - x_2^5\right) \exp(-x_1^2 - x_2^2) - \frac{1}{3} \exp(-(x_1 + 1)^2 - x_2^2)$	$x_1, x_2 \in [-3, 3]$
3	$F_3(x_1, x_2) = x_1^2 + x_2^2 - \cos(18x_1) - \cos(18x_2)$	$x_1, x_2 \in [-1, 1]$


В случае работы генетического алгоритма критерием останова может служить только заранее заданное количество поколений, так как в процессе выполнения алгоритма поддерживается высокое разнообразие хромосом, которые не сосредотачиваются в одной точке, а продолжают поиск (рис. 1б, 2б, 3б). Результатом будет минимальное по популяции значение функции приспособленности хромосомы.

3.2. Мультимодальная оптимизация

ИА позволяет выполнять мультимодальную оптимизацию функций, используя принципы клонального отбора и сетевого сжатия (рис. 4а, 5а).


Важным параметром ИА при выполнении мультимодальной оптимизации является вероятность мутации pm . Большая вероятность мутации поддерживает разнообразие антител в иммунной системе на достаточно высоком уровне, делая случайные скачки по всей области поиска, и позволяет находить глобальный экстремум, не застревая в точках локального оптимума. Небольшая вероятность мутации позволяет иммунной системе исследовать локальную область вокруг антитела, делая небольшие шаги в поиске антител с лучшей аффинностью, ведущие к оптимальному значению. Данный процесс позволяет помимо нахождения глобального экстремума создавать клетки памяти в точках локального оптимума. Механизм мутации необходимо регулировать в процессе работы ИА.

Большая скорость мутации необходима для быстрой сходимости ИА, однако, большинство изменений могут привести к нефункциональным антителам с плохой аффинностью. Так, для антител с улучшенной в результате мутации аффинностью необходимо



Размер начальной популяции – 100, количество поколений – 50, кодирование переменных – двоичное, вероятность мутации – 0,1


a



Размер начальной популяции – 100, количество поколений – 50, кодирование переменных – двоичное, вероятность мутации – 0,01, вероятность кроссовера – 0,7


б

Рис. 1. Глобальная оптимизация унимодальной функции $F1$ с помощью иммунного (*a*) и генетического (*б*) алгоритмов



Размер начальной популяции – 100, количество поколений – 200, кодирование переменных – двоичное, вероятность мутации – 0,3


a



Размер начальной популяции – 100, количество поколений – 200, кодирование переменных – двоичное, вероятность мутации – 0,01, вероятность кроссовера – 0,7


б

Рис. 2. Глобальная оптимизация мультимодальной функции $F2$ с использованием иммунного (*a*) и генетического (*б*) алгоритмов



Размер начальной популяции – 100, количество поколений – 200, кодирование переменных – двоичное, вероятность мутации – 0,3


a



Размер начальной популяции – 100, количество поколений – 200, кодирование переменных – двоичное, вероятность мутации – 0,01, вероятность кроссовера – 0,7


б

Рис. 3. Глобальная оптимизация мультимодальной функции $F3$ с использованием иммунного (*a*) и генетического (*б*) алгоритмов



Размер начальной популяции – 100, количество поколений – 300, кодирование переменных – двоичное, вероятность мутации – 0,01


a



Размер начальной популяции – 100, количество поколений – 300, кодирование переменных – двоичное, вероятность мутации – 0,01, вероятность кроссовера – 0,7


б

Рис. 4. Оптимизация мультимодальной функции $F2$ с использованием иммунного (*a*) и генетического (*б*) алгоритмов



Размер начальной популяции – 300, количество поколений – 300, кодирование переменных – двоичное, вероятность мутации – 0,01

a



Размер начальной популяции – 300, количество поколений – 300, кодирование переменных – двоичное, вероятность мутации – 0,01, вероятность кроссовера – 0,7

б

Рис. 5. Оптимизация мультимодальной функции $F3$ с использованием иммунного (*a*) и генетического (*б*) алгоритмов

уменьшать вероятность мутации в последующих поколениях работы ИА, чтобы не потерять полученные преимущества. ГА позволяет находить лишь глобальный экстремум (рис. 4б, 5б), не останавливаясь в точках локальных экстремумов, за счет постоянного поддержания разнообразия хромосом операторами отбора и кроссовера. Механизм мутации в случае использования ГА применяется случайным образом с низкой вероятностью для обеспечения сходимости алгоритма и восстановления утерянных в результате механизмов отбора и кроссовера хромосом с высокими значениями приспособленности.

Для выделения нескольких экстремумов функции с помощью ГА необходимо экспериментировать с различными операторами кроссовера и мутации, различными подходами к воспроизводству и отбору, но и в этом случае хромосомы, сгруппировавшиеся вокруг локальных экстремумов, будут постепенно вытесняться хромосомами, близкими к глобальному экстремуму, так как генетические алгоритмы не обладают памятью, свойственной иммунным системам. Отсутствие механизмов сетевого взаимодействия хромосом внутри популяции также является недостатком ГА при мультимодальной оптимизации.

3.3. Вычислительная сложность алгоритмов

При решении задач оптимизации ИА и ГА реализуют механизм случайно направленного перебора. Поиск решения осуществляется не из единственной точки, а из популяции точек, то есть выполняется одновременный анализ различных областей пространства решений. При этом хоть и не выполняется полный перебор всех точек в пространстве поиска, но обрабатывается значительное число гиперплоскостей поискового пространства, отличающихся высокой приспособленностью, что приводит к определенным вычислительным затратам при использовании данных алгоритмов. На вычислительную сложность ИА значительное влияние оказывают параметры механизма клонирования антител. В процессе работы ИА n антител с лучшей аффинностью создают популяцию клонов, копируя себя N_c раз. В результате увеличения количества n антител для клонирования популяция клонов оказывается существенно большей в размерах, чем исходная популяция антител. С увеличением параметра N_c достигается более быстрая сходимость ИА, что приводит, однако, к увеличению времени вычисления для каждого поколения ИА. Таким образом, изменение параметров n и N_c ИА позволяет выбирать необходимое соотношение вычислительной сложности и скорости сходимости алгоритма.

Генетический алгоритм обладает меньшей вычислительной сложностью за счет отсутствия в каждом поколении значительной по размерам популяции клонов и сетевого взаимодействия, осуществляющего контроль увеличения популяции.

В табл. 2 приведены временные затраты при оптимизации унимодальной функции $F1$ и мультимодальных функций $F2$ и $F3$ для 300 поколений. Были использованы следующие параметры ИА и ГА: размер начальной популяции — 100; кодирование переменных — двоичное (точность — 22 бита); вероятность мутации — 0,1 (для ИА); вероятность мутации — 0,01 (для ГА); вероятность кроссовера — 0,7 (для ГА). Видно, что время работы алгоритмов для выполнения 300 поколений больше для ИА.

Таблица 2

№	Функция	Время выполнения 300 поколений	
		ИА	ГА
1	$F_1(x_1, x_2) = x_1^2 + x_2^2$	113,52	16,23
2	$F_2(x_1, x_2) = 3(1 - x_1)^2 \times \exp(-x_1^2 - (x_2 + 1)^2) - 10\left(\frac{x_1}{5} - x_1^3 - x_2^5\right) \exp(-x_1^2 - x_2^2) - \frac{1}{3} \exp(-(x_1 + 1)^2 - x_2^2)$	116,667	18,206
3	$F_3(x_1, x_2) = x_1^2 + x_2^2 - \cos(18x_1) - \cos(18x_2)$	116,938	26,949

Выводы

В работе проведен сравнительный анализ применения иммунного и генетического алгоритмов в задачах оптимизации нелинейных функций. Эффективность ИА и ГА для решения задач оптимизации заключена в способности отыскивать решения практически при полном отсутствии предположений о характере исследуемой функции, а также манипулировать одновременно многими параметрами.

Использование ГА в задачах оптимизации требует меньших вычислительных ресурсов. Однако преимуществом ИА является возможность реализации параллельного распределенного поиска, позволяющего одновременно с глобальным экстремумом выполнять мультимодальную оптимизацию и определять локальные экстремумы нелинейных функций.

Список литературы: 1. Искусственные иммунные системы и их применение / Под ред. Д. Дасгупты: Пер. с англ. / Под ред А.А. Романюхи. — М.: ФИЗМАТЛИТ, 2006. — 344 с. 2. De Castro L. N., Timmis, J. I. Artificial Immune Systems: A Novel Paradigm to Pattern Recognition // In Artificial Neural Networks in Pattern Recognition, SOCO-2002, University of Paisley, UK, 2002. — Р. 67-84. 3. Андрейчиков А.В., Андрейчикова О.Н. Интеллектуальные информационные системы. — М.: Финансы и статистика, 2004. — 424 с. 4. Кораблев Н.М., Овчаренко И.В., Токарев В.В. Применение искусственных иммунных систем в задачах восстановления и оптимизации нелинейных зависимостей // «Бионика интеллекта»: Науч.-техн. журнал. — 2007. — № 1 (66). — С. 126-129.

Поступила в редколлегию 11.10.2007