



В.В. Муравьев, И.А. Лёзин

ПРИМЕНЕНИЕ ГЕНЕТИЧЕСКОГО АЛГОРИТМА ДЛЯ ОБУЧЕНИЯ НЕЧЕТКОЙ МНОГОВЫХОДОВОЙ НЕЙРОННОЙ СЕТИ ВАНГА-МЕНДЕЛЯ

(Самарский государственный аэрокосмический университет)

Генетический алгоритм (англ. genetic algorithm) — это эвристический алгоритм поиска, используемый для решения задач оптимизации и моделирования путём случайного подбора, комбинирования и вариации искомых параметров с использованием механизмов, аналогичных естественному отбору в природе. Является разновидностью эволюционных вычислений, с помощью которых решаются оптимизационные задачи с использованием методов естественной эволюции, таких как наследование, мутации, отбор и кроссовер. Отличительной особенностью генетического алгоритма является акцент на использование оператора «скрещивания», который производит операцию рекомбинации решений-кандидатов, роль которой аналогична роли скрещивания в живой природе.

Целью работы было обучение нейронной сети с помощью генетического алгоритма на примере нечеткой многовыходовой нейронной сети Ванга-Менделя.

Основные задачи:

1. Исследовать эффективность алгоритма обучения от количества правил вывода.
2. Исследовать эффективность алгоритма обучения от размера популяции.
3. Исследовать эффективность алгоритма обучения от выбранного вида кроссовера.
4. Сравнить генетический алгоритм и алгоритм обратного распространения ошибки.

Так как в нейронных сетях используются вещественные коэффициенты, использовался генетический алгоритм вещественного кодирования.

Алгоритмы вещественного кодирования работают, в общем случае, с непрерывной областью допустимых значений переменных. Данный класс алгоритмов позволяет уменьшить объём вычислительных процедур на каждом шаге эволюции за счёт отсутствия двоично-десятичных преобразований при расчёте значений функций приспособленности и уменьшения размеров хромосом.

Мутация в генетических алгоритмах вещественного кодирования проводится в заданном проценте (доле) от всех генов особей текущего поколения популяции.

$$\tilde{p} = p \cdot (1 + (-1)^\alpha \cdot \Delta),$$

где α – случайное двоичное значение (0 или 1); Δ – заданная величина в пределах (0; 1).



Наиболее важными генетическими операторами вещественного кодирования следует считать разновидности вещественного кроссовера.

Пусть $P = (p_1, p_2, \dots, p_n)$ и $Q = (q_1, q_2, \dots, q_n)$ – две особи популяции, выбранные для проведения кроссовера, причём приспособленность первой особи лучше, чем приспособленность второй.

В данной работе использовались следующие виды кроссовера:

– Плоский кроссовер:

$$h_i \in [\min(p_i, q_i), \max(p_i, q_i)] \forall i = \overline{1, n}$$

– Арифметический кроссовер (λ – заданная константа):

$$h_i = \lambda \cdot p_i + (1 - \lambda) \cdot q_i,$$

$$g_i = \lambda \cdot q_i + (1 - \lambda) \cdot p_i,$$

– Дискретный кроссовер:

$$h_i \in \{p_i, q_i\} \forall i = \overline{1, n}$$

– Расширенный кроссовер (α – заданная константа):

$$h_i \in [\min(p_i, q_i) - D_i \cdot \alpha, \max(p_i, q_i) + D_i \cdot \alpha], \quad D_i = |p_i - q_i|$$

– Эвристический кроссовер (α – заданная константа)

$$h_i = \alpha \cdot (p_i - q_i) + p_i,$$

В данной работе генотипом сети считался вектор коэффициентов всех нейронов сети, записанных в определенном порядке.

Тестирование проводилось на тестах классификации ирисов Фишера.

1. Количество продукционных правил вывода.

Характеристики системы при тестировании: кроссовер – расширенный с коэффициентом 0.5, размер популяции – 10, алгебры – Гёделя и Гогена.

Были протестированы следующие количества продукционных правил вывода: 3, 5, 7. Выяснено, что при увеличении количества продукционных правил растет время обучения сети, но минимальное значение СКО тестирования практически не изменяется, из чего сделан вывод о целесообразности использования количества продукционных правил вывода, равного 3.

2. Размер популяции

Характеристики системы при тестировании: кроссовер – расширенный с коэффициентом 0.5, количество правил вывода – 3, алгебры – Гёделя и Гогена.

Были протестированы следующие размеры популяции: 5, 10, 20. Выяснено, что при малых размерах популяции наблюдается нестабильность результатов, при увеличении размера популяции результаты стабилизируются. Увеличение размеров популяции положительно влияет на СКО тестирования, но увеличение размера популяции с 10 до 20 не является выгодным, так как при небольшом уменьшении минимального СКО время обучения увеличивается в 2 раза, поэтому целесообразным выглядит использование размера популяции, равного 10.

3. Вид кроссовера и его коэффициент.



Характеристики системы при тестировании: размер популяции - 10, количество правил вывода - 3, алгебры – Гёделя и Гогена.

Были протестированы все виды описанных выше кроссоверов, лучший результат показал расширенный кроссовер с коэффициентом 0.5, чуть выше результат показал дискретный кроссовер. Остальные кроссоверы показали результат хуже, но практически одинаковый для всех.

4. Сравнение алгоритмов обучения

Характеристики системы при тестировании:

- Генетический алгоритм: кроссовер – расширенный с коэффициентом 0.5, размер популяции – 10, количество правил вывода – 3, алгебры – Гёделя и Гогена.
- Алгоритм обратного распространения ошибки (ОРО): шаг обучения – 0.01, количество правил вывода – 3, алгебры – Гёделя и Гогена.

Сеть обучалась в течение 10000 итераций. Выяснено, что генетический алгоритм не уступает «стандартному» алгоритму обратного распространения ошибки, но ведет себя более стабильно: графики значений на выходах сети при обучении генетическим алгоритмом состоят из практически ровных линий с несколькими крупными скачками, обозначающими ошибки тестирования. При обучении с помощью ОРО графики значений на выходах нестабильны, колебания могут составлять до 30%.

Литература

1. Осовский С., Нейронные сети для обработки информации [Текст] /С.Осовский, пер. с польского И.Д. Рудинского. – М.: Финансы и статистика, 2002. – 344с.
2. Рутковская Д., Пилиньский М., Рутковский Л. Нейронные сети, генетические алгоритмы и нечёткие системы [Текст] /Д. Рутковская, пер. с польского И.Д. Рудинского. - М.: Горячая линия – Телеком, 2007. – 452 с.
3. Новак В., Перфильева И., Мочкорж И. Математические принципы нечеткой логики [Текст] /В. Новак, пер с англ.; под ред. Аверкина А. Н. – М.:Физматлит, 2006. – 352 с.
4. Борисов В. В., Круглов В. В., Федулов А. С. Нечеткие модели и сети [Текст] – М.:Горячая линия – Телеком, 2007. – 284 с.
5. Солдатова О.П. Многофункциональный имитатор нейронных сетей [Текст] / О.П.Солдатова.– Международный журнал «Программные продукты и системы» – Тверь, 2012. – Вып. 3. – С. 27-31.
6. UCI Machine Learning Repository [Электронный ресурс] – – <http://archive.ics.uci.edu>.
7. Дударов С. П. Математические основы генетических алгоритмов: учеб. Пособие [Текст] / С. П. Дударов. – М.: РХТУ им. Д. И. Менделеева, 2012. – 56 с.