

Оптимизация параметров нечеткого аппроксиматора на основе алгоритма стаи ласточек

А. О. Слезкин

Научный руководитель И. А. Ходашинский, профессор каф. КИБЭВС

Томский государственный университет систем управления и радиоэлектроники

Кафедра комплексной информационной безопасности электронно-вычислительных систем

Проект ГПО КИБЭВС-1211 – Нечеткие системы

Введение

Нечеткие системы давно и успешно применяются в таких проблемных областях, как классификация, аппроксимация, интеллектуальный анализ данных, распознавание образов, прогнозирование и управление, в задачах принятия решений. Они встроены в огромное количество промышленных изделий, начиная с роботов и систем управления электропоездами, и заканчивая такими потребительскими товарами, как фото и видеокамеры, кондиционеры, стиральные машины и др. Достоинствами нечетких систем является невысокая стоимость разработки, гибкость, интуитивно понятная логика функционирования.

Целью работы является реализация метаэвристического алгоритма стаи ласточек (Swallow Swarm Optimization) [1] для оптимизации нечеткого аппроксиматора типа синглтон и сравнение результатов с результатами других алгоритмов [2] на наборах данных KEEL.

Постановка задачи

В данной работе рассматривается нечеткий аппроксиматор типа синглтон.

Построение нечеткой системы осуществляется на основе таблицы наблюдений:

$$T = \{t_1, t_2, \dots, t_M\},$$

где $t_k = (x_k, y_k)$ — строка таблицы наблюдений, $x_k = (x_1, x_2, \dots, x_n)$ — вектор значений входных переменных, y_k — выходное значение, M — число наблюдений, n — число входных переменных.

На основе таблицы наблюдений на области определения каждой входной переменной формируются нечеткие термы.

Исходя из разбиения переменных на нечеткие термы формируется база правил нечеткой системы. Нечеткое правило в нечеткой системе типа синглтон имеет вид:

$$IF x_1 = A_{1j} AND x_2 = A_{2j} AND \dots AND x_n = A_{nj} THEN y = r_j,$$

где r_j — действительное число, которым оценивается выход y , $j = \overline{1 \dots m}$, m — количество правил, A_{ij} — терм j -го правила i -ой переменной [3].

На основе сформированной базы правил нечеткая система осуществляет отображение $F: \mathfrak{R}^n \rightarrow \mathfrak{R}$, определяемое формулой:

$$F(\mathbf{x}) = \frac{\sum_{i=1}^m \mu_{A_{1i}}(x_1) \mu_{A_{2i}}(x_2) \dots \mu_{A_{ni}}(x_n) r_i}{\sum_{i=1}^m \mu_{A_{1i}}(x_1) \mu_{A_{2i}}(x_2) \dots \mu_{A_{ni}}(x_n)},$$

где $\mathbf{x} = [x_1, \dots, x_n] \in \mathfrak{R}^n$, $F(\mathbf{x}) \in \mathfrak{R}$, $\mu_{A_{ij}}$ — функция принадлежности, указывающая степень принадлежности x_i к множеству A_{ij} .

Нечеткий аппроксиматор может быть представлен как:

$$y = f(\mathbf{x}, \boldsymbol{\theta}, \mathbf{r}),$$

где \mathbf{x} — входной вектор $\boldsymbol{\theta}$ — вектор параметров антецедентов, N — число параметров, описывающих одну функцию принадлежности, y — скалярный выход системы, $\mathbf{r} =$

(r_1, \dots, r_m) — вектор параметров консеквентов. В качестве численного критерия адекватности модели используется среднеквадратическая функция ошибки, вычисляющаяся по формуле:

$$MSE(x_k, \theta, r) = \frac{1}{2} * \frac{\sum_{k=1}^M (y_k - f(x_k, \theta, r))^2}{M}.$$

Описание алгоритма

Алгоритм стаи ласточек является продолжением идеи роящихся частиц и основан на поведении стаи ласточек в привычной им среде обитания.

Главная идея алгоритма состоит в разделении всех частиц на три вида:

- частицы лидеры,
- частицы исследователи,
- бесцельные частицы.

Роли зависят от положения частицы. Считается, что чем меньше значение фитнес-функции MSE , тем лучше положение.

Частицы лидеры делятся на глобального лидера и локальных лидеров. Глобальным лидером является частица с самым лучшим положением в проблемном пространстве. Локальные лидеры — это l следующих за глобальным лидером частиц. Частицы исследователи — k худших частиц популяции. Все остальные частицы — исследователи.

Частицы лидеры во время итерации не двигаются, а служат ориентиром для исследователей.

Частицы исследователи изучают проблемное пространство между ближайшим локальным лидером и глобальным лидером. Для изменения их положения используются формулы:

$$\begin{aligned} \theta_{e_{i+1}} &= \theta_{e_i} + V_{i+1}, \\ V_{i+1} &= VHL_{i+1} + VLL_{i+1}, \\ VHL_{i+1} &= VHL_i + \alpha_{HL} * rand(0,1) * (\theta_{e_{best}} - \theta_{e_i}) + \beta_{HL} * rand(0,1) * (HL - \theta_{e_i}), \\ VLL_{i+1} &= VLL_i + \alpha_{LL} * rand(0,1) * (\theta_{e_{best}} - \theta_{e_i}) + \beta_{LL} * rand(0,1) * (LL_i - \theta_{e_i}), \end{aligned}$$

где θ_{e_i} — положение i -ой частицы-исследователя, HL — положение глобального лидера, LL_i — положение ближайшего до θ_{e_i} локального лидера, $\theta_{e_{best}}$ — лучшее положение θ_{e_i} , α_{HL} , β_{HL} — параметры, контролирующие скорость приближения к HL , α_{LL} , β_{LL} — параметры, контролирующие скорость приближения к LL , V_i — вектор скорости θ_{e_i} , VHL — вектор скорости частицы относительно HL , VLL — вектор скорости частицы относительно LL .

Бесцельные частицы перемещаются в случайное место проблемного пространства. Для этого используется формула:

$$\theta_{o_{i+1}} = \theta_{o_i} + rand(\{-1; 1\}) * \frac{rand(min_s, max_s)}{1 + rand(0,1)},$$

где θ_{o_i} — положение i -ой бесцельной частицы, min_s , max_s — границы исследуемого пространства.

После каждой итерации частицы снова сортируются по возрастанию их фитнес-функции и их роли переопределяются. После выполнения условия останова алгоритма, его работа завершается и возвращается положение частицы с наименьшим значением фитнес-функции.

Возникшие при реализации проблемы

В ходе программной реализации данного алгоритма были обнаружены некоторые его проблемы. Коэффициенты α_{HL} , β_{HL} , α_{LL} , β_{LL} получались слишком большими, что приводило к хаотичному движению частиц, вместо приближения их к глобальному минимуму. Второй проблемой стало то, что использование оригинальной формулы алгоритма для изменения положения бесцельных частиц приводило к выходу этих частиц, в некоторый момент, за пределы исследуемого пространства.

Решение возникших проблем

Формула движения бесцельных частиц была изменена на:

$$\theta_{o_{i+1}} = rand(\{0,5; 1,5\}) * VSS$$

$$VSS = \frac{\sum_{i=1}^{N-k} \theta_i}{N - k}$$

где θ_i — i -ая частица популяции, N — количество всех частиц в популяции, k — количество бесцельных частиц.

Коэффициенты, контролирующие скорость приближения к лидерам, были приравнены к константам, подобранным опытным путем.

Полученные результаты

Для проведения тестирования работы алгоритма были выбраны следующие наборы данных из репозитория KEEL: plastic, ele-2, delta-ail, friedman, dee. Размер популяции был равен 50, количество локальных лидеров – 3, количество бесцельных частиц – 4, количество итераций – 100. После тестирования было проведено сравнение полученных результатов с результатами работы других алгоритмов (табл. 1) [2].

Таблица 1 – Сравнение результатов работы алгоритмов

Data	ANFIS-SUB		TSK-IRL		Linear-LMS		LEL-TSK		METSK-HD		SSO	
	trn	test	trn	test	trn	test	trn	test	trn	test	trn	test
pla	1,011	1,504	1,090	1,146	1,166	1,172	1,032	1,188	1,057	1,136	1,343	1,433
ele-2	8208	8525	17024	19786	13361	13541	2928	3752	2270	3192	17149	15589
delail	0,973	1,484	1,321	1,419	1,478	1,478	1,193	1,760	1,190	1,402	1,903	1,868
fried	0,085	3,158	0,433	1,419	3,653	435	0,322	1,070	1,075	1,888	1,566	2,089
dee	3087	2083	0,545	882,02	0,081	0,085	0,662	0,628	0,030	0,103	0,0824	0,0888

Заключение

Хоть ни по одному из опробованных наборов данных и не удалось получить самого лучшего результата, используя алгоритм стаи ласточек, уже сейчас, полученные результаты лучше результатов работы одних алгоритмов и сравнимы с результатами других. На это так же повлияло и то, что некоторые части алгоритма пришлось самостоятельно исправлять, ввиду их плохой работоспособности. Из вышесказанного можно сделать вывод, что при дальнейших улучшениях алгоритма и использовании его для оптимизации более сложных систем, чем аппроксиматор типа синглтон (например нечеткого аппроксиматора типа Такаги-Сугено), можно ожидать заметного улучшения выходных результатов.

Список литературы

1. Neshat M., Sepidnam G., Sargolzaei M. Swallow swarm optimization algorithm: a new method to optimization // Neural Computing and Application. – 2013. V. 23, N. 2. – P. 429–454.
2. Gacto M.J., Galende M., Alcalá R., Herrera F. METSK-HDe: A multiobjective evolutionary algorithm to learn accurate TSK-fuzzy systems in high-dimensional and large-scale regression problems // Information Sciences. – 2014. – V. 276. – P. 63–79.
3. Ходашинский И.А. Идентификация нечетких систем: методы и алгоритмы // Проблемы управления. – 2009. – № 4. – С. 15–23.