

Алгоритм креативного обучения для настройки нечеткого классификатора

П.А. Ковчунов

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

г. Томск, ТУСУР

Проект ГПО КИБЭВС-1211 – Нечёткие системы

Введение

Огромное количество задач, встречающихся в различных отраслях точных наук, связаны с таким вычислительным аппаратом, как непрерывная глобальная оптимизация. Эти задачи отличает крайняя вычислительная сложность при попытке решить их аналитическим методом. [1] Начиная с 80-х годов XX века разрабатываются стохастические алгоритмы оптимизации, предназначенные для решения именно таких задач. [2] В этой статье рассмотрен метаэвристический алгоритм, вдохновленный механизмом человеческого мышления.

Цель работы

Целью данной работы является настройка параметров нечеткого классификатора. Основная идея нечеткого классификатора состоит в описании предполагаемого кластера нечетким прототипом, размерность которого определена размерностью пространства исследуемых данных. Таким образом, i -й кластер определяется нечетким правилом следующего вида:

$$R_{ij}: \text{ЕСЛИ } x_1 = A_{1i} \text{ И } x_2 = A_{2i} \text{ И } x_3 = A_{3i} \text{ И } \dots \text{ И } x_n = A_{ni} \text{ ТО } class = c_j,$$

где $\mathbf{x} = (x_1, x_2, x_3, \dots, x_n)$ – вектор признаков классифицируемого объекта;

A_{ki} – нечеткий терм, характеризующий k -ый признак в i -том правиле ($i \in [1, R]$), R – число правил;

c_j – идентификатор j -того уровня, $j \in [1, m]$.

Задача традиционной классификации может быть описана функцией

$$f: \mathfrak{X}^n \rightarrow \{0,1\}^m,$$

где $f(\mathbf{x}) = (c_1, c_2, \dots, c_m)$ причем $c_i = 1$, а $c_j = 0$ ($j \in [1, m]$, $i \neq j$), когда объект, заданный вектором \mathbf{x} , принадлежит к классу c_i .

Нечеткая классификация описывается функцией

$$f: \mathfrak{X}^n \rightarrow [0,1]^m,$$

которая относит классифицируемый объект к каждому классу с определённой степенью принадлежности, вычисленной следующим образом:

$$\beta_j(\mathbf{x}) = \sum_{R_{ij}} \prod_{k=1}^n A_{ki}(x_k), j = \overline{1, m}.$$

Выходом классификатора является класс, определяемый следующим образом:

$$class = c_{j^*}, j^* = \arg \max_{1 \leq j \leq m} \beta_j.$$

Нечеткий классификатор может быть представлен как функция

$$c = f(\mathbf{x}; \boldsymbol{\omega})$$

где $\boldsymbol{\omega}$ – вектор, описывающий базу правил.

Пусть дано множество обучающих данных (таблица наблюдений) $\{(\mathbf{x}_p: c_p), p = \overline{1, z}\}$, определим следующую функцию

$$\text{delta}(p, \boldsymbol{\omega}) = \begin{cases} 1, & \text{если } c_p = f(\mathbf{x}_p, \boldsymbol{\omega}), p = \overline{1, z}, \\ 0, & \text{иначе} \end{cases}$$

тогда численный критерий качества классификации выражается следующим образом:

$$E(\boldsymbol{\omega}) = \frac{\sum_{p=1}^z \text{delta}(p, \boldsymbol{\omega})}{z}$$

На основе таблицы наблюдений формируются нечеткие термы на области определения каждой входной переменной. В данной работе термы представляются в виде треугольников и каждая переменная описывается тремя термами – A_{p1}, A_{p2}, A_{p3} .




Рисунок 1 – Нечёткий терм для k -го признака

Проблема идентификации сводится к проблеме поиска максимума заданной функции в многомерном пространстве, координаты которого соответствуют параметрам нечеткого классификатора.

Базу правил нечеткого классификатора можно представить в виде вектора $\boldsymbol{\omega}$, обозначенном в таблице 1, который и будет обрабатываться нашим алгоритмом. В где $\omega_{j,i}^p$ – i -й параметр j -го терма p -й признака

Таблица 1 – Вектор, описывающий базу правил

$E(\boldsymbol{\omega})$	$\omega_{1,1}^1$	$\omega_{2,1}^1$	$\omega_{3,1}^1$	$\omega_{1,2}^1$	$\omega_{2,2}^1$	$\omega_{3,2}^1$...	$\omega_{i,j}^p$...	$\omega_{1,j}^k$	$\omega_{2,j}^k$	$\omega_{2,j}^k$
--------------------------	------------------	------------------	------------------	------------------	------------------	------------------	-----	------------------	-----	------------------	------------------	------------------

Описание алгоритма

Алгоритм креативного обучения – это метаэвристический алгоритм поиска. В данной работе будут описаны основные составляющие алгоритма, представление решения, процесс дивергентного, конвергентного и креативного мышления.

Данный алгоритм предложили Xiang Feng, Ru Zou и Huiqun Yu [3] в 2014 г. Алгоритм моделирует мышление человека в процессе решения им прикладной задачи. Предполагается, что мы найдем такую идею-вектор, фитнес-функция от которой будет всегда меньше либо

равна фитнес-функции от любого другого вектора. (рассматриваем задачу глобальной минимизации).

Рассмотрим алгоритм подробнее:

Шаг 1. Для каждой идеи генерируется вектор $\omega_i = (\omega_{i1}, \omega_{i2}, \dots, \omega_{in})$.

Чтобы начать процесс дивергентного мышления, случайным образом генерируется вектор

$$\Delta\omega_i = (\Delta\omega_{i1}, \Delta\omega_{i2}, \dots, \Delta\omega_{in})$$

$$\omega'_i = \omega_i + \Delta\omega_i,$$

где $\Delta\omega_{ij}$ – величина, распределенная по нормальному закону, с математическим ожиданием, равным нулю и дисперсией δ^2 , которая называется новизной идеи и выбирается в зависимости от исследуемой области.

Шаг 2. Сравниваем $E(\omega)$ и $E(\omega')$

Если $E(\omega')$ меньше, то $\delta^2 = \delta^2 * Sfactor$, здесь $Sfactor \in (0..1)$ – заранее заданный коэффициент масштабирования, предназначенный для того, чтобы уменьшить дисперсию и искать оптимум в более тесной окружности вокруг точки.

Иначе $\delta^2 = \delta^2 / Sfactor$, таким образом переходы становятся дальше.

Шаг 3. Вычисляем для каждой пары векторов из популяции:

$$O(\bar{\omega}_i) = \begin{cases} |\bar{\omega}_i, \bar{\omega}_t|, & \text{если } E(\bar{\omega}_i) < E(\bar{\omega}_t) \\ 0, & \text{иначе} \end{cases}$$

$$i = 1, 2, \dots, DNum$$

$$\bar{\omega}_{t+1} = \begin{cases} \bar{\omega}_k & \text{если } O(\bar{\omega}_k) > 0 \\ \bar{\omega}_t, & \text{иначе} \end{cases}$$

$$k = \arg \max O(\bar{\omega}_i)$$

Шаг 4. Строим элементы матрицы α следующим образом, используя вспомогательную матрицу:

$$M_{i,j} = \begin{cases} 0, & \text{если } i = j \\ \frac{E(\bar{\omega}_j) - E(\bar{\omega}_i)}{|E(\bar{\omega}_j)|}, & \text{если } i \neq j \end{cases}$$

$$\alpha_{i,j} = \frac{M_{i,j}}{\sum_{i=1}^n |M_{i,j}|}$$

Шаг 5. Вычислим новую идею U_i для каждого вектора на основе матрицы влияния α и двух случайно взятых векторов ω_a и ω_b :

$$U_i = \begin{cases} \bar{\omega}_a + \alpha_{a,i} * (\bar{\omega}_a - \bar{\omega}_i) + (\alpha_{b,i} - \alpha_{r,i}) * (\bar{\omega}_b - \bar{\omega}_r), & \text{если } \alpha_{a,i} > 0 \\ \bar{\omega}_i + \alpha_{a,i} * (\bar{\omega}_a - \bar{\omega}_i) + (\alpha_{b,i} - \alpha_{r,i}) * (\bar{\omega}_b - \bar{\omega}_r), & \text{иначе} \end{cases}$$

$$\text{Шаг 6. } \omega_i = \begin{cases} U_i, & \text{если } E(U_i) < E(\omega_i) \\ \omega_i & \text{иначе} \end{cases}$$

Шаг 7. Отсортировать идеи по возрастанию ошибки и вывести лучшее решение (максимальное значение фитнес-функции $E(\omega)$).

Заключение

Алгоритм креативного обучения – это популяционный алгоритм, берущий свои корни из жизни. Также, как и другие метаэвристические алгоритмы, данный алгоритм относится к числу эволюционных и способен решать ряд оптимизационных проблем, в числе которых нелинейность, недифференцируемость, высокая размерность пространства поиска с большой скоростью схождения. Ещё одно преимущество описываемого алгоритма заключается в том, что данный алгоритм регулируется малым числом параметров, делая его достаточно лёгким для реализации.

Литература

1. Карпенко А. П. Популяционные алгоритмы глобальной поисковой оптимизации. Обзор новых и малоизвестных алгоритмов // «Информационные технологии», — 2012 — №7 — С. 1-3.
2. И.А. Ходашинский, И.В. Горбунов – Построения нечетких классификаторов на основе алгоритма пчелиной колонии // Автометрия. – 2012. – Т. 48, № 1. – С. 45–71.
3. Xiang Feng, Ru Zou, Huiqun Yu. A novel optimization algorithm inspired by the creative thinking process // Springer-Verlag Berlin Heidelberg. – 2014 — С. 1-12.