

АНАЛИЗ РАЗНОТИЧНЫХ ДАННЫХ  
(Вычислительные системы)

1983 год

Выпуск 99

УДК 519.95

КОНЬЮНКЦИЯ - ПРОГРАММА ПОСТРОЕНИЯ ЛОГИЧЕСКИХ ОТДЕЛИТЕЛЕЙ

В.Г. Устюжанинов

Пусть  $x_1, \dots, x_n$  - система порядковых признаков;  $z_1, \dots, z_n$  - конечные множества их градаций;  $M_1, M_2$  - конечные непересекающиеся множества объектов 1-го и 2-го классов, описываемых этими признаками. Образуем список  $\mathcal{P}$  всевозможных предикатов  $P$  вида  $x \leq a$  и  $x > a$ , где  $a \in z_1 \cup \dots \cup z_n$ . Пусть  $k$  - конъюнкция некоторых предикатов из  $\mathcal{P}$  и  $M_1(k), M_2(k)$  - множества объектов 1-го и 2-го классов, на которых она истинна. Требуется построить такую дизъюнкцию  $D = k_{v_1} \vee \dots \vee k_{v_s}$ , состоящую из конъюнкций  $k_{v_1}, \dots, k_{v_s}$  предикатов из  $\mathcal{P}$ , что

$$M_1(D) = M_1, \quad (1)$$

число  $v$  минимально и для всех  $i = 1, \dots, s$  имеет место

$$M_2(k_{v_i}) = \emptyset. \quad (2)$$

Эта задача универсально переборна, и точное ее решение [1] требует непомерно большого машинного времени. Ниже излагается градиентная схема, дающая приближенное решение задачи.

Пусть  $Q(\alpha) = \{k / \alpha \in M_1(k), M_2(k) = \emptyset\}$ . Алгоритм работает в два этапа: на 1-м - выделяется такой список конъюнкций  $K \subseteq \bigcup_{x \in M_1} Q(x)$ , что  $K \cap Q(\alpha) \neq \emptyset$  для всех  $\alpha \in M_1$ . Назовем этот список результирующим; на втором, - используя список  $K$  и градиентную процедуру С.В. Яблонского, И.А. Чегис, строится дизъюнкция  $D$ , удовлетворяющая (1).

Метод получения списка  $K$  заключается в преобразовании списка конъюнкций, именуемого буфером. Зафиксируем объект  $\alpha \in M_1$ . Пусть уже построен буфер, состоящий из некоторых конъюнкций, истинных на

$\alpha$ , и  $k_1$  – одна из конъюнкций буфера. Составим полный список предикатов  $\mathcal{P}(\alpha)$ , истинных на  $\alpha$  и ложных по крайней мере на одном объекте из  $M_2 \setminus M_2(k_1)$ . Для каждого  $P \in \mathcal{P}(\alpha)$  вычислим величину  $B(P) = \text{ВЕС} \cdot \|M_1(k_1 \& P)\| + (1 - \text{ВЕС}) \cdot \|M_2 \setminus M_2(k_1 \& P)\|$ , где  $0 \leq \text{ВЕС} \leq 1$ . Среди  $P \in \mathcal{P}(\alpha)$  найдем  $P^*$ , для которого  $B(P^*) = \max B(P)$ .

Пусть  $0 \leq \text{ПР} \leq 1$  и  $P_{\mu_1}, \dots, P_{\mu_n}$  – те предикаты, для которых справедливо  $B(P_{\mu_i}) \geq B(P^*) \cdot \text{ПР}$ . Исключим из буфера конъюнкцию  $k_1$  и пополним его конъюнкциями  $k_1 \& P_{\mu_1}, \dots, k_1 \& P_{\mu_n}$ . Из полученного буфера извлечем конъюнкции, удовлетворяющие (2), и поместим их в результирующий список  $K$ . Если после этого буфер оказался пуст, то переходим к следующему объекту из  $M_1$ . В противном случае процесс повторяется.

Программа КОНЪЮНКЦИЯ, реализующая этот метод, имеет следующие механизмы, предназначенные для экономии памяти и машинного времени. Структура буфера древообразна. Из конъюнкций, подлежащих введению в буфер, включаются в буфер только те, для которых  $M_1(k_i \& P_{\mu_j}) \neq M_1(k_j)$ , где  $k_j$  – произвольная конъюнкция из образованного к этому моменту результирующего списка. Назовем конъюнкцию  $k_j \in K$  тупиковой, если удаление из нее любого предиката приводит к конъюнкции, нарушающей требование (2). В каждой  $k_j \in K$  выделяется тупиковая конъюнкция, которой она заменяется в списке  $K$ .

Программа КОНЪЮНКЦИЯ успешно применялась для решения задач распознавания образов в органической химии, горном деле, геологии. В частности, в геологии требовалось получить простейшее правило, отделяющее класс месторождений с промышленным содержанием полезного ископаемого от класса месторождений, не представляющих интереса для промышленности. Методами многомерного статистического анализа эта задача решалась И.Л.Добрецовым и др. в [2]. Ими отмечается, что полученные правила для распознавания месторождений представляют очень трудную задачу, которая обычными методами решается плохо. В этой связи интересно было посмотреть как справится с этой задачей программа КОНЪЮНКЦИЯ. Подробное изложение результатов этого эксперимента дается в [3]. Здесь же будем предельно кратки. Информация по задаче, любезно предоставленная лабораторией геологии и геофизики Новосибирского государственного университета, состояла из 46 объектов обучающей выборки. Объекты были разбиты на два класса: 14 – в первом классе и

32 - во втором. Каждый объект описывался 14 признаками. Программой было построено правило, состоящее всего из двух кеньенций и безошибочно разделяющее классы объектов обучавшей выборки. Для оценки эффективности этого правила было образовано множество из 34 контрольных объектов. Все они относились ко второму классу.

В отличие от объектов обучавшей выборки контрольные объекты для построения отделяющего правила не использовались. После применения к контрольным объектам отделяющего правила, 4 из них были отнесены к первому классу, а остальные 30 - ко второму. По мнению геологов, полученный процент ошибки в 0.12 для решавшейся задачи - рекордно низкий.

Существуют другие программы построения логических отделителей, например, описанные в [4]. Сравнение эффективности этих программ с программой, представленной в настоящей заметке, - дело будущего.

#### Л и т е р а т у р а

1. ЖУРАВЛЕВ Ю.И. Об отделимости вершин  $n$ -мерного единичного куба. - Труды МИ АН СССР, 1958, т. 51, с. 143-157.
2. ДОБРЕЦОВ Н.Л., ХАРЬКИВ А.Д., ШЕМЯКИН М.Л. Применение многомерного статистического анализа для решения прогнозных задач на примере алмазоносности кимберлитов. - Геология и геофизика. 1966, № 8, с. 15-22.
3. УСТОЮЖАНИНОВ В.Г. Исследование алгоритмов, решающих дискретные задачи распознавания образов: Дис. на соиск. учен. степ. канд. физ.-мат. наук, - Москва, 1980.
4. ЛБОВ Г.С., КОТОКОВ В.И., МАШАРОВ Ю.П. Метод обнаружения логических закономерностей на эмпирических таблицах. - В кн.: Эмпирическое предсказание и распознавание образов (Вычислительные системы, вып. 67). Новосибирск, 1976, с. 29-42.

Поступила в ред.-изд.отд.  
10 марта 1982 года