



# ИНФОРМАЦИОННЫЙ АНАЛИЗ

УДК 001.5:519.17

С. О. Кузнецов

## ИНТЕРПРЕТАЦИЯ НА ГРАФАХ И СЛОЖНОСТНЫЕ ХАРАКТЕРИСТИКИ ЗАДАЧ ПОИСКА ЗАКОНОМЕРНОСТЕЙ ОПРЕДЕЛЕННОГО ВИДА

*Предложена интерпретация на графах задачи поиска закономерностей с помощью ДСМ-метода автоматического порождения гипотез. Эта интерпретация позволяет устанавливать связь между поиском ДСМ-гипотез и изучением некоторых классических комбинаторных объектов (двудольных графов и полных двудольных подграфов в них). Тем самым устанавливается связь и с некоторыми другими системами поиска закономерностей. Устанавливается ряд фактов относительно алгоритмической сложности (полиномиальная вычислимость, NP-полнота,  $\neq P$ -полнота) некоторых задач поиска закономерностей указанного вида (и, следовательно, поиски подграфов некоторого вида в двудольных графах).*

Одним из способов задания отношения сходства объектов как основы поиска закономерностей в данных может служить введение некоторой операции «выделения общей части» объектов. Такое понимание сходства лежит в основе целого ряда интеллектуальных систем и систем распознавания, в том числе в основе ДСМ-метода автоматического порождения гипотез [1—4].

В частности, когда объекты представлены множествами, то такой операцией может служить операция пересечения, а поиск сходства сводится к поиску всевозможных пересечений исходных множеств, удовлетворяющих некоторым дополнительным ограничениям, обусловленным особенностью решающих средств конкретной интеллектуальной системы (или системы распознавания). В ДСМ-методе, например, решающие средства основаны на особых признаках и правилах правдоподобного вывода, сформулированных на специальном языке, являющемся расширением языка логики предикатов первого порядка.

Первый вопрос, который будет рассмотрен в работе, касается интерпретации на графах задачи поиска закономерностей некоторого рода. Подобно тому, как геометрическая интерпретация (на булевых кубах) задачи минимизации булевых функций [5] помогает в ряде случаев быстро находить ответы на некоторые вопросы в указанной области, интерпретация на графах поиска закономерностей, о которых будет идти речь ниже, позволяет легко отвечать на некоторые вопросы, связанные с построением эффективных алгоритмов, находящихся эти закономерности.

В работе используется упрощенное понимание ДСМ-гипотезы (закономерности), связанное с использованием лишь примеров объектов, обладающих опреде-

ленным свойством (в отсутствии контрпримеров) одноэлементного множества свойств, и самого простого решающего предиката — предиката простого сходства  $Ma^+$ . Это упрощение имеет двойное обоснование.

Во-первых, при таком упрощении видна связь задачи поиска ДСМ-гипотез с задачами поиска гипотез в других системах (см. [6], а также список литературы, помещенный в этой книге). Упрощение выявляет комбинаторное ядро интеллектуальных систем и систем распознавания некоторого рода, позволяя интерпретировать результаты относительно алгоритмической сложности решения некоторых задач ДСМ-метода как результаты относительно алгоритмических характеристик классических комбинаторных объектов — двудольных графов и бинарных матриц.

Во-вторых, негативные результаты (об NP- и  $\neq P$ -полноте некоторых задач) в упрощенной постановке влекут аналогичные результаты в более общих постановках, использующих контрпримеры, более сильные решающие предикаты и более сложные структуры данных.


Итак, пусть заданы некоторые конечные множества  $U^1$  и  $\Omega \subseteq 2^{U^1}$ . Пару  $\langle U^1, \Omega \rangle$  будем называть входными данными ДСМ-задачи. (Множество  $U^1$  соответствует структурным элементам, а множество  $\Omega$  — объектам, обладающим некоторым интересующим нас свойством  $A$ .) ДСМ-гипотезой (о причине свойства  $A$ ) назовем пару  $\langle H(X_1, \dots, X_i) \rangle$ , где  $H = X_1 \cap \dots \cap X_i$ ,  $X_i \in \Omega$  для  $i=1, \dots, i$  и для любого  $X: X \in \Omega \setminus \{X_1, \dots, X_i\}$  выполняется  $H \cap X \neq H$ .

Обозначим также  $h = |H|$ .

Итак, сопоставим множествам  $U^1 \Omega$  двудольный граф

$G(U^1\Omega)$  следующим образом: в правой доле каждой вершина взаимно-однозначно соответствует некоторому элементу из  $U^1$ , а в левой доле — некоторому множеству из  $\Omega$ . Вершины  $i$  и  $j$  связаны в  $G$  ребром тогда и только тогда, когда множество  $X_i \in \Omega$  содержит элемент  $s_j \in U^1$ .

Пример:



$$U^1 = \{A, B, C, D, E, F\},$$

$$\Omega = \{ABC, BCD, ADE, BF\}.$$

$\mathcal{H}$  — множество всех гипотез:  $\mathcal{H} = \langle BC, \{ABC, BCD\} \rangle, \langle A, \{ABC, ADE\} \rangle, \langle B, \{ABC, BCD, BF\} \rangle$ .


Нетрудно видеть, что каждая гипотеза соответствует максимальному по вложению полному двудольному подграфу  $R$  графа  $G$ , у которого в левой доле не меньше двух вершин, т. е. такому подграфу вида  $(V^1 \cup V^2, E)$ ,  $E = V^1 \times V^2$ ,  $|V^1| \geq 2$ , что при добавлении к любому  $V^1$ ,  $i \in \{1, 2\}$  какой-либо вершины  $v$  из той же доли  $G$  индуцированный подграф на вершинах  $V^1 \cup \{v\} \cup V^2$  не будет полным, т. е. для соответствующего множества  $E'$ :  $E' \subset (V^1 \cup \{v\}) \times V^2$  (если в качестве  $V^1$  взято  $V^1$ ).

Так, подграф, индуцированный вершинами  $ABC, BCD, B, C$ , является максимальным по вложению полным двудольным подграфом графа  $G$  из примера: добавление какой-либо другой вершины нарушает его полноту (например, при добавлении вершины  $BF$ , вершина  $C$  оказывается не связанной с  $BF$ ). И обратно, пусть имеется произвольный двудольный граф  $B = (V^1 \cup V^2, E)$ ,  $V^1 = \{1, \dots, r\}$ ,  $V^2 = \{b_1, \dots, b_s\}$ . Сопоставим правую долю  $B$  (вершины из  $V^2$ ) множеству  $U^1$ , а левую (вершины  $V^1$ ) — множеству  $\Omega$  некоторой задачи о ДСМ-гипотезах. Для каждой вершины  $i$  из  $V^1$  образуем новую вершину  $a_i$  и добавим ее к множеству  $V^2$ , и соединим ребром только с  $a_i$  (это нужно для того, чтобы в  $\Omega$  не было повторяющихся множеств). Теперь каждой вершине  $i$  из  $V^1$  сопоставим множество  $w_i = \{a_i, b_1, \dots, b_s\}$ , где  $\{b_1, \dots, b_s\}$  в точности множество тех вершин из  $V^2$ , которые связаны с вершиной  $i$ . Теперь двудольному графу  $(V^1 \cup V^2 \cup \{a_1, \dots, a_r\}, E \cup \{(1, a_1), \dots, (r, a_r)\})$  соответствуют входные условия задачи о ДСМ-гипотезах с  $U^1 = \{a_1, \dots, a_r, b_1, \dots, b_s\}$  и  $\Omega = \{w_1, \dots, w_r\}$ , а каждому максимальному по вложению полному двудольному подграфу  $R$  графа  $B$ , у которого в левой доле не меньше двух вершин, соответствует ДСМ-гипотеза для входных данных  $U^1, \Omega$ . Сведение в обе стороны осуществляется за линейное время. Поэтому верна следующая

**Лемма 1.** По входным данным  $\langle U^1, \Omega \rangle$  ДСМ-задачи за линейное от  $|U^1| \cdot |\Omega|$  время можно построить двудольный граф, максимальные полные по вложению двудольные подграфы (с числом вершин в одной из долей не меньшим двум), которые взаимно-однозначно соответствуют гипотезам ДСМ-задачи. И наоборот, по любому двудольному графу  $B = (V^1 \cup V^2, E)$  за линейное время можно построить двудольный граф  $B' = ((V^1 \cup V) \cup V^2, E)$ , по которому, в свою очередь, можно построить входные данные  $(U^1(B'), \Omega(B'))$  ДСМ-задачи, причем гипотезы взаимно-однозначно соответствуют полным максимальным по вложению

двудольным подграфам, содержащим не менее двух вершин из  $V^2$ .

Более полная постановка задачи нахождения ДСМ-гипотез, подразумевающая наличие в базе данных объектов, обладающих данным свойством (+-примеров), и объектов, не обладающих данным свойством (—примеров), также позволяющая рассматривать не только элементарные свойства, но и множества различных элементарных свойств, может интерпретироваться как поиск некоторых подграфов в четырехдольном графе  $Q$  следующего вида:



с множеством ребер  $E \subseteq U^1 \times \Omega^+ \cup U^1 \times \Omega^- \cup U^2 \times \Omega^+ \cup U^2 \times \Omega^-$ . Более точно, существованию гипотезы относительно наличия свойства  $W \subseteq U^2$  в этом случае (например, для ситуации, когда используется так называемый простой предикат сходства  $Mat^+[1]$ ) будет соответствовать существование в графе  $Q$  максимального по вложению полного двудольного подграфа, индуцированного вершинами из  $U^1, \Omega^+$  (пусть это будет подграф на множествах вершин  $V^3$  и  $V^4$ ,  $V^3 \subseteq U^1, V^4 \subseteq \Omega^+$ ), такого, что все вершины из  $V^4$  соединены ребрами со всеми вершинами из  $V^3$ . При этом в  $Q$  не должно существовать максимального по вложению полного двудольного подграфа, индуцированного вершинами из  $U^1, \Omega^-$  (пусть это будет подграф на множествах вершин  $V^5$  и  $V^6$ ,  $V^5 \subseteq U^1, V^6 \subseteq \Omega^-$ ), такого, что все вершины из  $V^6$  соединены ребрами со всеми вершинами из  $V^5$ .

Вернемся, однако, к упрощенной постановке ДСМ-задачи.

Другой возможной интерпретацией задачи нахождения ДСМ-гипотез может быть задача нахождения экстремальных единичных подматриц бинарных матриц. Об эквивалентности этой задачи задаче поиска полных двудольных подграфов двудольного графа упоминается, например, в монографии [7] в связи с проблемой Царанкевича\* (см. также [6]).

Рассмотрим теперь некоторые вопросы, связанные со сложностью порождения гипотез, и покажем, как интерпретация на графах помогает решать некоторые из них. Даже при указанных выше ограничениях задача порождения всех гипотез может иметь экспоненциальную сложность. В самом деле, при  $U^1 = \{a_1, \dots, a_n\}$  и  $\Omega = \{W_1, \dots, W_n\}$ , где  $W_i = U^1 \setminus \{a_i\}$ , число всех возможных ненулевых пересечений множество из  $\Omega$  составляет  $2^n - n - 2$  [8]. Эта величина является точной верхней оценкой числа пересечений. В дальнейшем условия задачи нахождения ДСМ-гипотез, представленные  $\bar{U}^1$  и  $\bar{\Omega}$ , будем называть  $n$ -базисом и обозначать  $\mathcal{B}(\bar{U}^1)$ . Экспоненциальная верхняя оценка числа гипотез говорит о том, что задача нахождения всех гипотез может быть в ряде случаев трудновыполнимой, поэтому целесообразна постановка вопроса о «быстром» нахождении

\* Проблема Царанкевича заключается в оценке числа  $k$ , для которого любая  $n \times n$  — бинарная матрица, содержащая  $k$  единичных элементов, содержит единичную подматрицу размера  $a \times a$ .

«хороших» гипотез. Показателем качества гипотезы  $\langle H, \{X_1, \dots, X_k\} \rangle$  могут служить, например, следующие функционалы:

- 1:  $h$  — мощность  $H$  (как некоторая мера информативности гипотезы);
- 2:  $l$  — число множеств, образующих гипотезу в качестве пересечения (как некоторая мера надежности гипотезы);
- 3:  $h+l$  — интегральная мера информативности и надежности.

В связи с выбором функционала качества  $f$  гипотезы встают следующие проблемы (для функционалов 1 и 2 они были поставлены в работе [8]):

Задача 1. Существует ли гипотеза, для которой значение функционала  $f$  не меньше  $k$  ( $f \geq k$ )?

Задача 2. Существует ли гипотеза, для которой значение функционала  $f$  не больше  $k$  ( $f \leq k$ )?

Задача 3. Существует ли гипотеза со значением функционала в точности  $k$  ( $f = k$ )?

На двудольных графах задачи 1—3 интерпретируются как задачи поиска максимальных по вложению полных подграфов с ограничениями на размер левой доли (функционал  $l$ ), правой доли (функционал  $h$ ) и всего подграфа (функционал  $h+l$ ).

В работе [8] было показано, что задачи 1 и 2 для функционалов  $h$  и  $l$  решаются за время  $O(n^3)$ .

Интерпретация задачи поиска ДСМ-гипотез на графах позволяет моментально установить алгоритмическую эквивалентность задач 1—3 с функционалом  $h$ , а задач 1—3 — с функционалом  $l$ . (Этот факт двойственности был установлен в работе [8].) В самом деле, алгоритму нахождения экстремальных полных двудольных подграфов безразлично, накладывается ли ограничение на размер левой доли или на размер правой (с точностью до поправки в  $O(n^2)$  во времени, из-за проверки на экстремальные полные подграфы с единственной вершиной в одной из долей — в пересечении не может участвовать менее двух множеств).

Сложность решения задачи 3 для функционалов  $h$ ,  $l$  не была известна, сложность решения задач 1—3 для функционала  $h+l$  ранее не исследовалась.

Сначала покажем, что задача 3 с функционалом  $h$  (а, следовательно, и с функционалом  $l$ )  $NP$ -полна. С этой целью докажем полиномиальную сводимость к ней задачи «трехмерное сочетание» (3-С) [9]. Напомним формулировку (3-С): дано множество  $M \subseteq W \times X \times Y$ , где  $W, X$  и  $Y$  — непересекающиеся множества, содержащие одинаковое число элементов  $q$ . Верно ли, что  $M$  содержит трехмерное сочетание, т.е. подмножество  $M' \subseteq M$ , такое, что  $|M'| = q$ , и никакие два разных элемента  $M'$  не имеют ни одной равной координаты?

Теорема 2\*. Задача 3 с функционалом  $h$  является  $NP$ -полной.

**Доказательство.** Пусть нам дана индивидуальная задача из (3-С) с параметрами  $M$  ( $|M| = N$ ),  $W, X, Y$  ( $|W| = |X| = |Y| = q$ ). Построим следующую бинарную матрицу  $\mathcal{D}$

		3q+1			3q+1			3q+1			3q		
		w <sub>1</sub> x <sub>1</sub> y <sub>1</sub>			w <sub>2</sub> x <sub>2</sub> y <sub>2</sub>			w <sub>3</sub> x <sub>3</sub> y <sub>3</sub>			w <sub>q</sub> x <sub>q</sub> y <sub>q</sub>		
N	0	1	1	1	1	1	1	1	1	1	1	1	
	1	0	1	1	1	0	1	1	1	1	1	1	
	1	1	0	1	1	1	0	1	1	1	1	1	
	1	1	1	0	1	1	1	0	1	1	1	1	

\* Доказательство теоремы 2 одновременно и независимо было получено А. А. Разборным. Впоследствии еще одно доказательство было предложено М. И. Забейкало.

В правой части матрицы —  $3q$  правых позиций — каждая строка соответствует элементу  $m \in M$  так, что нуль в столбцах  $w_i, x_j, y_k$  означает наличие соответствующей компоненты, а единица — отсутствие. В левой части матрицы —  $N(3q+1)$ -левых позиций в  $i$ -й строке нули стоят в позициях  $(i-1)(3q+1)+1$  по  $i \cdot (3q+1)$ , а остальные позиции заполнены единицами. Если задача (3-С) имеет решение, то в матрице  $\mathcal{D}$  найдется  $q$  строк, таких, что в правой части матрицы в каждом столбце будет стоять по одному нулю, и произведение всех  $q$  строк будет строкой, содержащей ровно  $q(3q+1)+3q$  нулей и, соответственно,  $N(3q+1)+3q - (q \cdot 3q+1)+3q = (N-q) \cdot (3q+1)$  единиц ( $3q$  нулей даст правая часть, а  $q \cdot (3q+1)$  нулей — левая часть матрицы). Таким образом, каждому решению задачи 3-С с параметрами  $q, N$  соответствует решение задачи 1 с матрицей вида  $\mathcal{D}$  и параметрами  $N(3q+1)+3q$  (максимальная длина строки),  $N$  (число строк),  $q(3q+1)+3q$  (интересующее нас число единиц булевого вектора, являющегося произведением некоторого подмножества строк).

Наоборот, пусть в построенной матрице  $\mathcal{D}$  произведение некоторого подмножества строк  $M_2$  содержит  $q(3q+1)+3q$  нулей. Число строк в  $M_2$  не может быть меньше  $q$ , так как тогда левая часть матрицы дала бы не более  $(q-1) \cdot (3q+1)$ , а правая не может быть более  $3q$ , и в сумме  $(q-1) \cdot (3q+1)+3q < q(3q+1)+3q$ . Число строк в  $M_2$  не может быть больше  $q$ , так как тогда левая часть матрицы дала бы в произведении не менее  $(q+1)(3q+1)$  нулей, а  $(q+1)(3q+1) > q(3q+1)+3q$ . Таким образом, число строк в  $M_2$  равно  $q$ , число нулей в левой части суммы строк из  $M_2$  должно быть  $q(3q+1)$ . Значит, число нулей в правой части произведения строк есть  $q(3q+1)+3q - q(3q+1)$ , а это возможно, когда в каждом столбце правой части матрицы  $\mathcal{D}$ , соответствующей строкам из  $M_2$ , стоит ровно один нуль, т.е.  $\mathcal{D}$  содержит трехмерное сочетание, соответствующее множеству правых частей строк из  $M_2$ .

Следствие. Задача 3 с функционалом  $l$  является  $NP$ -полной. Путем сведения задачи (3-С) к задаче 3 для функционала  $h+l$  покажем, что верна следующая

**Теорема 3.** Задача 3 для функционала  $h+l$   $NP$ -полна.  
**Доказательство.** По индивидуальной задаче (3-С) построим матрицу  $\mathcal{D}'$ , устроенную так же, как матрица  $\mathcal{D}$ , с тем лишь отличием, что каждый участок левой подматрицы с нулями в определенной строке имеет ширину не  $3q+1$ , а  $q^3+1$ .

Если для задачи (3-С), представленной матрицей  $\mathcal{D}'$ , есть решение, т.е. трехмерное сочетание в  $\mathcal{D}'$ , то произведение соответствующих  $q$  строк в правой части ( $3q$  позиций) не будет содержать ни одной единицы, а в левой — будет содержать  $N(q^3+1) - q(q^3+1)$  единиц. Сумма числа строк и числа единиц в их произведении будет  $q + (N-q) \cdot (q^3+1)$ .

И наоборот, пусть для некоторого подмножества  $M_2$  множества всех строк матрицы  $\mathcal{D}'$  сумма числа строк и числа единиц в их произведении будет  $q + (N-q) \cdot (q^3+1)$ . При этом число строк  $k = |M_2|$  не может быть меньше  $q$ , так как в противном случае число единиц в произведении строк было бы не больше  $(N-q+1)(q^3+1)$ : так как  $k \leq q-1$ , то  $k + (N-k) \cdot (q^3+1) \geq (N-q+1)(q^3+1) > q + (N-q) \cdot (q^3+1)$ . Число строк  $k$  не может быть больше  $q$ , так как тогда бы число единиц в произведении строк было бы не больше  $(N-q-1)(q^3+1)$ : так как  $q+1 \leq k \leq N \leq q^3$ , то  $k + (N-k)(q^3+1) \leq k + (N-k) \cdot (q^3+1) = (k-q^3-1) + (N-q) \cdot (q^3+1) < q + (N-q) \cdot (q^3+1)$ .

В любом случае (при  $k > q$  или  $k < q$ ) сумма не могла бы совпадать с  $q + (N-q) \cdot (q^3+1)$ . Значит, сумма может быть такой только при числе строк  $q$ . При этом  $(N-q) \cdot (q^3+1)$  единиц должно приходиться на левую часть ( $N \cdot (q^3+1)$  позиций) произведения строк, а сумма числа строк  $k$  и числа единиц  $n$ , правой части про-

изведения ( $3q$  позиций) есть  $k+n$ . Так как  $k=g$ , то  $n_g=0$ , а это возможно только тогда, когда в каждом столбце правой части подматрицы  $\mathcal{D}$ , соответствующей строкам из  $M_3$ , стоят ровно по одному нулю. Значит,  $M_3$  соответствует трехмерному сочетанию.

Построение алгоритма для решения задачи 1 для функционала  $h+l$  сводится к построению алгоритма, находящего размер максимального по числу вершин полного двудольного подграфа двудольного графа.

Назовем слабым дополнением двудольного графа  $G$  двудольный граф  $\bar{G}$ , у которого вершины совпадают с вершинами  $G$ , а пара вершин из разных долей соединена ребром тогда и только тогда, когда она не соединена ребром в графе  $G$ . Максимальному по числу вершин полному двудольному подграфу в графе  $\bar{G}$  будет соответствовать максимальное независимое (несвязное) множество вершин в  $G$ . Одним из следствий теоремы [10, с. 119], доказанной Кеннигом, является утверждение о том, что в произвольном двудольном графе  $G$  число ребер в максимальном паросочетании и размер максимального независимого множества в сумме дают число вершин графа  $G$ .

Максимальное паросочетание в двудольном графе может быть найдено за время  $O(n^{2.5})$  с помощью алгоритма Карпа и Хопкрофта (см. [13], а также, например, [12, с. 512]). Следовательно, и ответ для задачи 1 с функционалом  $h+l$  находится полиномиально быстро. Указание на быстроразрешимость задачи о размере максимального полного двудольного подграфа двудольного графа сведением ее к задаче о максимальном паросочетании имеется в книге [9, с. 244]. Описание полиномиального  $O(n^3)$  алгоритма нахождения максимального полного двудольного подграфа двудольного графа содержится в работе [11], что позволяет быстро находить наилучшие в смысле функционала  $h+l$  гипотезы.

В традиционных постановках задачи распознавания, связанных с нахождением оптимальной в некотором смысле функции, «покрывающей» множество исходных значений, бывает достаточно найти одну такую функцию (гипотезу). В ДСМ-методе ищутся по возможности либо все гипотезы, либо те из них, которые удовлетворяют ограничениям на значения каких-либо функционалов. Следовательно, важным вопросом при исследовании алгоритмических свойств ДСМ-метода являются вопросы о числе гипотез, и о сложности алгоритма его нахождения. До последнего времени не удавалось получить нетривиальных оценок этого числа при заданных  $U^1, \Omega$  общего вида. Попытаемся доказать  $\#P$ -полноту этой задачи и тем самым обосновать трудность получения интересных оценок такого рода.

Понятие  $\#P$ -полноты было введено в работах [14, 15] в связи с исследованием трудности перечислительных задач, т. е. тех, в которых требуется указать число решений задачи распознавания [9]. Будем использовать определение, использующее понятие недетерминированной машины Тьюринга, как это делается в работе [14].

**Определение.** Считающей машиной Тьюринга (СМТ) называется недетерминированная машина Тьюринга, дополнительно печатающая на особой ленте двоичную запись числа решений индивидуальной задачи  $T$ . Временная сложность СМТ есть  $g(n)$ , если самое долгое принимающее вычисление СМТ для задачи  $T$  на всех индивидуальных задачах размера  $n$  есть  $g(n)$ .

**Определение.**  $\#P$  есть класс перечислительных задач, вычисляемых СМТ за полиномиальное время.

**Определение.** Перечислительная задача является  $\#P$ -полной, если к ней сводима, по Тьюрингу, любая задача из класса  $\#P$ .

В работе [16] были доказаны результаты о  $\#P$ -полноте большого числа перечислительных задач, соответствующих известным  $NP$ -полным задачам, в

частности, задачам о клике, гамильтоновом цикле, выполнимости 3-КНФ, 3-сочетании и др. В работе [16] использовалась так называемая «консервативная» сводимость  $\alpha_P$ , при которой  $A \alpha_P B$  подразумевает, что каждое решение задачи  $A$  взаимно-однозначно соответствует решению задачи  $B$  и, тем самым, число решений совпадает, а задачи нахождения этих чисел полиномиально эквивалентны. В работе [14] была доказана  $\#P$ -полнота задачи вычисления перманента матрицы, что позволило доказать  $\#P$ -полноту ряда перечислительных задач, для которых соответствующие задачи распознавания разрешимы за полиномиальное время.

В ДСМ-методе задачей такого рода является задача о числе всех ДСМ-гипотез для входных данных  $U^1$  и  $\Omega$ . Полиномиальность алгоритма соответствующей задачи распознавания: «существует ли гипотеза при данных  $\langle U^1, \Omega \rangle$ » доказывается тривиально (см., например, [8]).

Докажем  $\#P$ -полноту задачи о числе всех гипотез, сведя к ней задачу о выполнимости монотонной 2-КНФ.  $\#P$ -полнота последней задачи была установлена в [15]. Приведем формулировку задачи о 2-КНФ.

Дано: множество переменных  $Y = \{y_1, \dots, y_n\}$  и конъюнкция  $\mathcal{F}(Y) = C_1 \wedge \dots \wedge C_r$ , где  $C_i$  имеет вид  $C_i = (y_{i_1} \vee y_{i_2}), y_{i_j} \in Y$ .

Найти: число булевых наборов, выполняющих  $\mathcal{F}(Y)$ .  
Теорема 4. Задача «найти число всех гипотез»  $\#P$ -полна.

**Доказательство.** Покажем, что, умея находить число гипотез, мы сможем найти число булевых наборов, выполняющих  $\mathcal{F}(Y)$ :  $\mathcal{F}(Y) = \bigwedge (C_1 \wedge \dots \wedge C_r) = \bigwedge C_1 \vee \dots \vee \bigwedge C_r = d_1 \vee \dots \vee d_r = D(Y)$ , где  $d_i = y_{i_1} \cdot y_{i_2}$ . Сопоставим множеству переменных  $Y$  множество  $U^1 = \{a_1, \dots, a_n\}$ , причем каждой переменной  $y_j$  будет взаимнооднозначно соответствовать элемент  $a_j$ .

Дизъюнктивному члену  $d_i$  дизъюнкции  $D(Y)$  сопоставим множество  $\mathcal{A}_{i_1 i_2} = U^1 \setminus \{a_{i_1}, a_{i_2}\}$ . Покажем, что каждому выполняющему набору функции  $D(Y)$  можно взаимно-однозначно сопоставить множество, являющееся пересечением некоторых пар индексов, соответствующих индексам переменных в конъюнкции  $\mathcal{F}(Y)$ . Возьмем произвольный выполняющий  $D(Y)$  набор  $\alpha = (\alpha_1, \dots, \alpha_n)$ . Положим  $A_\alpha = \{a_i \in U^1 \mid \alpha_i = 1\}$ . Очевидно, что  $A_\alpha$  принадлежит множеству пересечений, порождаемых  $U^1 \bigcup_{(i_1, i_2) \in I} (\mathcal{A}_{i_1 i_2} \cup \{a_{i_1}, a_{i_2}\}) = \Omega$ . Обратно, пусть мно-

жество  $A_\beta$  порождено пересечением множеств из  $\Omega$ , и для некоторых  $t_1, \dots, t_p$   $A_\beta = U^1 \setminus \{a_{t_1}, \dots, a_{t_p}\}$ . Выделим множество  $\mathcal{K}_\beta = \{\mathcal{A}_{i_1 i_2} \mid A_\beta \subseteq \mathcal{A}_{i_1 i_2}\}$ . Образует булев набор, у которого на  $i$ -м месте стоит нуль, если  $i \in \{t_1, \dots, t_p\}$ . Остальные позиции сделаем единичными. Этот набор будет выполнять те дизъюнктивные члены дизъюнкции  $D(Y)$ , в которые входят пары литералов с теми же парами индексов, что и у множеств  $\mathcal{A}_{i_1 i_2}$  из  $\mathcal{K}_\beta$ . Взаимно-однозначное соответствие выполняющих наборов функции  $\mathcal{D}(Y)$  и множеств, порождаемых пересечением множеств из  $\Omega$ , установлено. Значит,  $\#\{\alpha \mid D(\alpha) = 1\}$  совпадает с числом множеств, порождаемых пересечением множеств из  $\Omega$ , и число выполняющих наборов функции  $\mathcal{F}(Y)$  равно  $\#\{\eta \mid \mathcal{F}(\delta) = 1\} = 2^n - \#\{\alpha \mid D(\alpha) = 1\}$ . Тем самым задача по определению числа решений задачи «выполнимость монотонной 2-КНФ» сведена к задаче подсчета числа всевозможных пересечений семейства множеств, т. е. к задаче о числе ДСМ-гипотез. При сведении требуется построить  $r$  множеств  $\mathcal{A}_{i_1 i_2}$ , и для каждого  $\mathcal{A}_{i_1 i_2}$  — построить не более  $(n-2)$  множеств из  $\mathcal{K}(\mathcal{A}_{i_1 i_2})$ . Значит, сводимость по-

линомиальна (порядка  $O(r \cdot n^2)$ ) и задача «найти число всех гипотез»  $\neq P$ -полна.

Следствие. Перечислительные задачи, соответствующие задачам 1—3 с функционалами  $h$ ,  $l$ ,  $h+l$ ,  $\neq P$ -полны.

В самом деле принадлежность указанных задач классу  $\neq P$  очевидна. В то же время, умея находить число решений задачи 3, мы можем решать задачу «найти число всех гипотез», просуммировав числа решений задачи 3 по  $k$  для  $1 \leq k \leq |U^1|$  (для функционала  $h$ ), для  $1 \leq k \leq |\Omega|$  (для функционала  $l$ ) и  $1 \leq k \leq |U^1| + |\Omega|$  (для функционала  $h+l$ ). Перечислительная задача, соответствующая задаче 2, является более общей задачей, чем задача «найти число всех гипотез» (которая получается из указанной, когда  $k=1$ ).

Заметим, что при доказательстве теоремы 4 мы могли бы погрузить  $U^1$  в множество  $U_+^1$ , большее по мощности в полиномиальное число раз, и либо добавить ко всем элементам из  $\mathcal{B}(\mathcal{S}_{ij})$  по одинаковому подмножеству из  $U^1$ , либо не делать этого, не нарушив при этом полиномиальности сводимости. Принимая во внимание это соображение, можно сформулировать более сильную, чем теорема 4, теорему.

**Теорема 5.**

1. Задача «найти число всех гипотез» со значением функционала  $h$ , не превышающим  $\alpha \cdot |U|^{\beta}$ , ( $0 < \alpha < 1$ ,  $0 < \beta \leq 1$ ), является  $\neq P$ -полной.

2. Задача «найти число всех гипотез» со значением функционала  $h$ , не меньшим  $\alpha \cdot |U|^{\beta}$  ( $0 < \alpha < 1$ ,  $0 < \beta \leq 1$ ), является  $\neq P$ -полной.

Аналогичные теоремы могут быть сформулированы для функционалов  $l$ ,  $h+l$  (с заменой  $|U^1|$  в формулировке на  $|\Omega|$  и  $|U^1| + |\Omega|$ , соответственно).

\* \* \*

В заключение автор хотел бы выразить признательность А. Ю. Когану и Д. П. Скворцову за ряд полезных указаний и внимание, проявленное к работе.

#### СПИСОК ЛИТЕРАТУРЫ

1. Финн В. К. Правдоподобные выводы и правдоподобные рассуждения // Итоги науки и техники. Сер. Теория вероятностей, математическая статистика, теоретическая кибернетика.— М.: ВИНТИ, 1988.— Т. 28.— С. 1—86.
2. Аншаков О. М. Скворцов Д. П. Финн В. К. Логические средства экспертных систем типа ДСМ // Семантика и информатика.— 1986.— Вып. 28.— С. 65—101.
3. Забейайло М. И. Финн В. К. и др. Об одном методе автоматического формирования гипотез и его программной реализации // НТИ. Сер. 2.— 1982.— № 4.— С. 20—26.
4. Михееенкова М. А. Финн В. К. Об одном классе экспертных систем с неполной информацией // Изв. АН СССР. Сер. Тех. киб.— 1986.— № 5.— С. 82—103.
5. Журавлев Ю. И. Алгоритмы построения минимальных дизъюнктивных форм для функции алгебры логики // Дискретная математика и математические вопросы кибернетики / Под общ. ред. С. В. Яблонского, О. Б. Лупанова.— М.: Наука, 1974.— С. 67—98.
6. Левит В. Е. Переверзев-Орлов В. С. Структура и поле данных при распознавании образов— М.: Наука, 1984.
7. Эрдеш П. Спенсер Д. Вероятностные методы в комбинаторике.— М.: Мир, 1976.
8. Забейайло М. И. О некоторых переборных задачах, возникающих при автоматическом порождении гипотез ДСМ-методом // НТИ Сер. 2.— 1988 — № 1.— С. 28—31.
9. Гэри М. Джонсон Д. Вычислительные машины и труднорешаемые задачи.— М.: Мир, 1982.— 416 с.
10. Харари Ф. Теория графов.— М.: Мир, 1973.— 302 с.
11. Левит В. Е. Алгоритм поиска подматрицы максимального периметра, состоящей из единиц на  $0-1$  матрице // Система передачи и обработки информации: Сб. тр. / ИППИ АН СССР.— М., 1988.— С. 42—45.
12. Пападимитриу Х. Стайглиц К. Комбинаторная оптимизация. Алгоритмы и сложность — М.: Мир, 1985.— 512 с.
13. Карп Р. Hopcroft G. A. 2.5-algorithm for maximum matching in bipartite graphs // SIAM J. Comput.— 1973.— Vol. 2, № 2.— P. 225—231.
14. Valiant L. G. The complexity of computing the permanent // Theoretical Comp. Sci.— 1979.— № 8.— P. 189—201.
15. Valiant L. G. The complexity of enumeration and reliability problems // SIAM J. Comput.— 1979.— Vol. 8, № 1.— 410—421.
16. Simon J. On the difference between one and many // Lect. Not. Comp. Sci.— 1977.— Vol. 52 — P. 480—491.

Материал поступил в редакцию 21.12.88.