

О МАТЕМАТИЧЕСКИХ ПРИНЦИПАХ КЛАССИФИКАЦИИ
ПРЕДМЕТОВ И ЯВЛЕНИЙ

А.Н.Дмитриев, Ю.И.Журавлев, Ф.П.Кренделев

Существует класс задач, в которых необходимо по ряду известных признаков предмета или явления установить, обладает ли данное явление или предмет некоторым свойством.

Так, в химии важной является задача прогноза — обладает ли данное соединение свойствами катализатора, в диагностике по ряду признаков важно установить — какой болезнью болен пациент и т.д.

В настоящей статье мы введем меру, оценивающую важность данного признака при изучении группы предметов или явлений. На основе введенной меры могут быть предложены способы классификации объектов, обладающих данным признаком, и способы отнесения нового объекта к одной из ранее изученных групп.

§ I. Допустимые таблицы

Пусть задано конечное множество $M = \{\tilde{x}_1, \tilde{x}_2, \dots, \tilde{x}_n\}$, которое в дальнейшем мы будем называть основным множеством, и на элементах M определены предикаты (свойства) $x_1, x_2, \dots, \dots, x_n, x_{n+1}$.

Предикат x_{n+1} назовем основным, предикаты x_1, \dots, x_n —

вспомогательными. В дальнейшем вспомогательные предикаты мы будем, если это не приводит к недоразумениям, называть просто предикатами.

Рассмотрим строки $\langle x_1(\tilde{\alpha}_i), x_2(\tilde{\alpha}_i), \dots, x_n(\tilde{\alpha}_i) \rangle$ значений вспомогательных предикатов на предмете $\tilde{\alpha}_i, i=1, 2, \dots, \kappa$.

Каждую строку $S_i = \langle x_1(\tilde{\alpha}_i), x_2(\tilde{\alpha}_i), \dots, x_n(\tilde{\alpha}_i) \rangle$ сопоставим с множеством строк $M(\tilde{\alpha}_i)$, которое составлено из всех строк, получающихся из S_i всевозможными заменами координат строки S_i на знак "-".

ОПРЕДЕЛЕНИЕ 1. Элементы множества $M(\tilde{\alpha}_i)$ назовем э т а л о н а м и (образами) предмета $\tilde{\alpha}_i, i=1, 2, \dots, \kappa$.

ОПРЕДЕЛЕНИЕ 2. Таблица T , заполненная символами $\{0, 1, -\}$, называется д о п у с т и м о й, если

1⁰. Существует множество \tilde{M} , $\tilde{M} \subset M$, $\tilde{M} = \{\tilde{\alpha}_{i_1}, \dots, \tilde{\alpha}_{i_2}\}$ такое, что каждая строка из T является элементом одного и только одного множества $M(\tilde{\alpha}_{i_j}), 1 \leq j \leq 2$, то есть эталоном одного и только одного предмета из \tilde{M} .

2⁰. Все строки таблицы $T = \{a_{ij}\}$ различны. Две строки S_i и S_j таблицы T называются различными, если существует столбец - номер столбца обозначим через ℓ - такой, что

$$a_{i\ell} \in \{0, 1\}, a_{j\ell} \in \{0, 1\} \text{ и } a_{i\ell} \neq a_{j\ell}.$$

ОПРЕДЕЛЕНИЕ 3. Таблица T называется д о п у с т и м о й в узком смысле, если T является допустимой и, кроме того, на всех элементах \tilde{M} (определение 2) предикат $x_{n+1} = 1$.

В дальнейшем мы будем рассматривать только допустимые или допустимые в узком смысле таблицы.

§ 2. Различающая мера признака

Пусть задана допустимая таблица T , строки которой являются образами элементов из множества \tilde{M} ; $\tilde{M} \subset M$; и для элементов множества \tilde{M} вычислено значение основного предиката x_{n+1} . Тогда

$$\tilde{M} = \tilde{M}_1 \cup \tilde{M}_0, \quad \tilde{M}_1 \cap \tilde{M}_0 = \emptyset$$

пусто, где \tilde{M}_1 - множество, на элементах которого предикат $x_{n+1} = 1$ (свойство x_{n+1} выполнено), \tilde{M}_0 - множество, на элементах которого предикат $x_{n+1} = 0$ (свойство x_{n+1} не выполнено).

Разобьем таблицу T на две подтаблицы T_1 и T_0 :

T_1 составим из всех строк таблицы T , которые являются образами элементов из \tilde{M}_1 ; T_0 - из строк, которые являются образами элементов из \tilde{M}_0 .

ОПРЕДЕЛЕНИЕ 4. Набор (i_1, \dots, i_t) столбцов таблицы T и соответствующий ему набор $(x_{i_1}, \dots, x_{i_t})$ назовем тестором для (T_1, T_0) , если после удаления из T всех столбцов, не вошедших в число (i_1, \dots, i_t) , все строки таблицы T_1 будут различны со всеми строками таблицы T_0 .

ОПРЕДЕЛЕНИЕ 5. Тестор для (T_1, T_0) называется тупиковым, если после удаления из него любого столбца он перестает быть тестором для (T_1, T_0) .

ПРИМЕР 1. Пусть

$$T = \begin{matrix} & \begin{matrix} 1 & 2 & 3 & 4 & 5 \end{matrix} \\ \begin{matrix} 1 \\ 2 \\ 3 \\ 4 \\ 5 \end{matrix} & \begin{pmatrix} 1 & 1 & 0 & 1 & 1 \\ 0 & 1 & 0 & 1 & 1 \\ 1 & 0 & 1 & 0 & 1 \\ 1 & 1 & 1 & 1 & 1 \\ 0 & 0 & 0 & 1 & 1 \end{pmatrix} \end{matrix}, T_1 = \begin{matrix} & \begin{matrix} 1 & 2 & 3 & 4 & 5 \end{matrix} \\ \begin{matrix} 1 \\ 2 \\ 3 \\ 4 \\ 5 \end{matrix} & \begin{pmatrix} 1 & 1 & 0 & 1 & 1 \\ 0 & 1 & 0 & 1 & 1 \\ 1 & 0 & 1 & 0 & 1 \end{pmatrix} \end{matrix}, T_0 = \begin{matrix} & \begin{matrix} 1 & 2 & 3 & 4 & 5 \end{matrix} \\ \begin{matrix} 1 \\ 2 \\ 3 \\ 4 \\ 5 \end{matrix} & \begin{pmatrix} 1 & 1 & 1 & 1 & 1 \\ 0 & 0 & 0 & 1 & 1 \end{pmatrix} \end{matrix}.$$

Набор столбцов за номерами 2 и 3, соответственно (x_2, x_3) , является тупиковым тестором для (T_1, T_0) . Действительно, после удаления из T столбцов с номерами 1, 4, 5 таблица T_1 переходит в T'_1 , T_0 в T'_0 и

$$T'_1 = \begin{pmatrix} 1 & 0 \\ 1 & 0 \\ 0 & 1 \end{pmatrix}, \quad T'_0 = \begin{pmatrix} 1 & 1 \\ 0 & 0 \end{pmatrix}.$$

Все строки таблицы T'_1 отличны от всех строк таблицы T'_0 , следовательно, набор (x_2, x_3) является тестором для (T_1, T_0) . Тупиковость (x_2, x_3) очевидна.

Пусть κ - число тупиковых тесторов таблицы T относительно (T_1, T_0) и κ_i - число тупиковых тесторов, в которые вошел столбец, соответствующий признаку x_i .

ОПРЕДЕЛЕНИЕ 6. Число $R(x_i) = \frac{\kappa_i}{\kappa}$, $i=1, 2, \dots, n$, назовем различающим весом предиката x_i .

ПРИМЕР 2.

$$T = \begin{matrix} & \begin{matrix} 1 & 2 & 3 & 4 & 5 \end{matrix} \\ \begin{matrix} 0 & 1 & 0 & 1 & 0 \\ 1 & 0 & 1 & 1 & 1 \\ 1 & 0 & 1 & 1 & 0 \\ 1 & 0 & 0 & 0 & 1 \\ 0 & 1 & 0 & 0 & 0 \\ 1 & 1 & 1 & 1 & 0 \end{matrix} & \end{matrix}, \quad T_1 = \begin{matrix} & \begin{matrix} 1 & 2 & 3 & 4 & 5 \end{matrix} \\ \begin{matrix} 0 & 1 & 0 & 1 & 0 \\ 1 & 0 & 1 & 1 & 1 \\ 1 & 0 & 1 & 1 & 0 \end{matrix} & \end{matrix}, \quad T_0 = \begin{matrix} & \begin{matrix} 1 & 2 & 3 & 4 & 5 \end{matrix} \\ \begin{matrix} 1 & 0 & 0 & 0 & 1 \\ 0 & 1 & 0 & 0 & 0 \\ 1 & 1 & 1 & 1 & 0 \end{matrix} & \end{matrix}.$$

Тупиковыми тесторами здесь являются наборы (1,2,4) и (2,3,4).

Поэтому $R(x_1)=R(x_3)=\frac{1}{2}$, $R(x_2)=R(x_4)=1$, $R(x_5)=0$.

При исследовании предмета, для которого еще не вычислен основной признак (предикат) x_{n+1} , следует в первую очередь выяснить — выполняются ли для этого предмета признаки с высоким разделяющим весом.

Вычисление разделяющего веса производится по значениям вспомогательных признаков на ранее изученных предметах, для которых значение основного признака x_{n+1} известно (или выяснено в предыдущих исследованиях).

§ 3. Алгоритмы вычисления разделяющего веса признаков

Первый алгоритм. Введем операцию АоВ под элементами множества $\{0, 1, -\}$ при помощи таблицы:

$\begin{matrix} A \\ B \end{matrix}$	0	1	-
0	1	0	1
1	0	1	1
-	1	1	1

Тогда $S_i \circ S_j$, где $S_i = (\alpha_1, \alpha_2, \dots, \alpha_n)$, $S_j = (\beta_1, \beta_2, \dots, \beta_n)$, $\alpha_i \in \{0, 1, -\}$, $\beta_i \in \{0, 1, -\}$, $i=1, 2, \dots, n$, определяется следующим образом:

$$S_i \circ S_j = (\alpha_1 \circ \beta_1, \alpha_2 \circ \beta_2, \dots, \alpha_n \circ \beta_n).$$

Пусть таблица T_1 состоит из строк S_1, S_2, \dots, S_ℓ , таблица T_0 — из строк $\tilde{S}_1, \tilde{S}_2, \dots, \tilde{S}_m$.

Составим строки $S_{ij} = S_i \circ S_j$, $i=1, 2, \dots, \ell$, $j=1, 2, \dots, m$. В строке S_{ij} выделим номера τ_1, \dots, τ_q координат, равных едини-

це, и сопоставим S_{ij} с набором $\{x_{\tau_1}, \dots, x_{\tau_q}\} = \tilde{x}_{ij}$. Рассмотрим множество наборов $x = \{\tilde{x}_{ij}\}$, $i=1, 2, \dots, \ell$, $j=1, 2, \dots, m$.

Удалим из x все наборы \tilde{x}_{ij} , для которых существуют наборы \tilde{x}'_{ij} такие, что $\tilde{x}_{ij} \subset \tilde{x}'_{ij}$. После такой операции множество x перейдет в $x' = \{\tilde{x}'_{ij}\}$.

Из множества S всех наборов, составленных из некоторых букв x_1, \dots, x_n , удалим все поднаборы наборов из x' .

После такой операции S перейдет в S' . Оставим в S' только наборы, все сужения которых не входят в S' . Множество всех таких наборов образует множество \tilde{T} всех тупиковых тесторов для (T_1, T_0) . Доказательство этого факта следует из построения. Имея \tilde{T} , нетрудно построить различающие веса всех признаков x_1, \dots, x_n .

ПРИМЕР 3. Рассмотрим таблицы T_1 и T_0 из примера 2. Пусть $S_1 = (01010)$, $S_2 = (10111)$, $S_3 = (10110)$, $\tilde{S}_1 = (10001)$, $\tilde{S}_2 = (01000)$, $\tilde{S}_3 = (11110)$.

Тогда $S_{11} = (00100)$, $S_{12} = (11101)$, $S_{13} = (01011)$, $S_{21} = (10001)$, $S_{22} = (00000)$, $S_{23} = (10110)$, $S_{31} = (11000)$, $S_{32} = (00001)$, $S_{33} = (10111)$.

Поэтому $\tilde{x}_{11} = (x_3)$, $\tilde{x}_{12} = (x_1, x_2, x_3, x_5)$, $\tilde{x}_{13} = (x_2, x_4, x_5)$, $\tilde{x}_{21} = (x_1, x_2, x_5)$, $\tilde{x}_{22} = (\text{пустой набор})$, $\tilde{x}_{23} = (x_1, x_3, x_4)$, $\tilde{x}_{31} = (x_1, x_2)$, $\tilde{x}_{32} = (x_5)$, $\tilde{x}_{33} = (x_1, x_3, x_4, x_5)$.

Наборы \tilde{x}_{11} , \tilde{x}_{21} , \tilde{x}_{22} , \tilde{x}_{23} , \tilde{x}_{31} , \tilde{x}_{32} удаляем, так как они содержатся в более широких наборах. Например, $\tilde{x}_{21} \subset \tilde{x}_{12}$. Выписываем наборы, составленные из букв, содержащихся в множестве $\langle x_1, x_2, x_3, x_4, x_5 \rangle$, и удаляем из них все поднаборы \tilde{x}_{12} , \tilde{x}_{33} .

В результате выполнения такой операции останутся наборы:

$$(x_1, x_2, x_4), (x_2, x_3, x_4), (x_1, x_2, x_3, x_4), (x_1, x_2, x_4, x_5), (x_2, x_3, x_4, x_5), (x_1, x_2, x_3, x_4, x_5).$$

Из них тупиковые тесторы образуют (x_1, x_2, x_4) и (x_2, x_3, x_4) . Поэтому $R(x_1) = \frac{1}{2}$, $R(x_2) = 1$, $R(x_3) = \frac{1}{2}$, $R(x_4) = 1$, $R(x_5) = 0$.

Второй алгоритм. Сопоставим строкам S_{ij} , $i=1, 2, \dots, \ell$, $j=1, 2, \dots, m$, наборы $\tilde{x}_{ij} = \{x_{\tau_1}, \dots, x_{\tau_q}\}$. Пусть строке S_{ij} сопоставлен набор $\{x_{ij}^1, \dots, x_{ij}^{K(i,j)}\}$. Рассмотрим выражение:

$$\prod_{i=1}^{\ell} \prod_{j=1}^m (x_{ij}^1 \vee \dots \vee x_{ij}^{K(i,j)}),$$

здесь символы x_{ij}^z рассматриваются как булевы переменные, \vee - знак дизъюнкции, \wedge - знак конъюнкции. Полученное выражение приведем к виду $\sum \prod$ и выполним все упрощения типа:
 $A \vee A = A$, $\bar{A} \cdot A = A$, $A \vee AB = A$. В результате имеем

$$\vee x_{i_1 j_1}^{z_1} \dots x_{i_t j_t}^{z_t} \quad (I)$$

Тогда все тупиковые тестеры для (T_i, T_o) исчерпываются наборами $(x_{i_1 j_1}^{z_1}, \dots, x_{i_t j_t}^{z_t})$, соответствующими слагаемым в (I). Этот алгоритм является незначительной модификацией алгоритма С.В.Яблонского [1].

Третий алгоритм. Задача построения всех тупиковых тестеров может быть сведена к задаче расшифровки [2] специальной монотонной функции.

Сопоставим набору $(x_{i_1}, \dots, x_{i_k})$ вершину $\tilde{\alpha} = (\alpha_1, \dots, \alpha_n)$ n -мерного единичного куба, положив $\alpha_{i_i} = \dots = \alpha_{i_k} = 1$ и остальные координаты равными нулю.

Зададим функцию $F_{T, T_o}(x_1, x_2, \dots, x_n)$:

$$F_{T, T_o}(x_1, x_2, \dots, x_n) = \begin{cases} 1, & \text{если набор } (x_{i_1}, \dots, x_{i_k}) \text{ сопоставлен} \\ & \text{вершине } (\alpha_1, \dots, \alpha_n), \text{ образует тестер для } (T_1, T_o); \\ 0 & \text{в противном случае.} \end{cases}$$

Функция $F_{T, T_o}(x_1, \dots, x_n)$ является монотонной. Это следует из очевидных утверждений:

1⁰, если набор $(x_{i_1}, \dots, x_{i_k})$ есть тестер, то всякое расширение $(x_{i_1}, \dots, x_{i_k})$ также образует тестер;

2⁰, если набор $(x_{i_1}, \dots, x_{i_k})$ не является тестером, то сужение наборов $(x_{i_1}, \dots, x_{i_k})$ также не является тестером.

Очевидно, наборам, образующим тупиковые тестеры, соответствуют нижние единицы функции $F_{T, T_o}(x_1, \dots, x_n)$.

Построение нижних единиц монотонной функции F_{T, T_o} можно проводить методом В.К.Коробкова [2].

§ 4. Отнесение эталона к классам \tilde{M}_0, \tilde{M}_1

Пусть заданы таблицы T_1, T_o эталонов определенных предметов, у которых основной признак равен соответственно единице, нулю.

Задан допустимый эталон S , для которого значение основного признака неизвестно и вычисление этого значения затруд-

нено.

Тогда в ряде случаев для отнесения S к T_1 или к T_o можно пользоваться следующей процедурой.

Пусть

$$T_1 = \begin{pmatrix} \alpha_{11} \alpha_{12} \dots \alpha_{1n} \\ \alpha_{21} \alpha_{22} \dots \alpha_{2n} \\ \dots \dots \dots \dots \\ \alpha_{m1} \alpha_{m2} \dots \alpha_{mn} \end{pmatrix}, T_o = \begin{pmatrix} \beta_{11} \beta_{12} \dots \beta_{1n} \\ \beta_{21} \beta_{22} \dots \beta_{2n} \\ \dots \dots \dots \dots \\ \beta_{\ell 1} \beta_{\ell 2} \dots \beta_{\ell n} \end{pmatrix}, S = (\gamma_1, \dots, \gamma_n).$$

Для каждого признака x_1, \dots, x_n вычисляется разделяющий вес $R(x_i)$, $i = 1, 2, \dots, n$.

Вычисляется значение величины:

$$\rho_1 = \frac{\sum_{i=1}^m \sum_{j=1}^n (\alpha_{ij} \circ \gamma_j)}{m}, \quad \rho_2 = \frac{\sum_{i=1}^{\ell} \sum_{j=1}^n (\beta_{ij} \circ \gamma_j)}{\ell}.$$

Если $\rho_1 > \rho_2$, делается прогноз: основной признак для предмета, которому соответствует эталон S , не выполнен. Если $\rho_1 < \rho_2$, то делается прогноз: основной признак для предмета, которому соответствует эталон S , выполнен.

Области применимости и точность описанного метода будут исследованы в дальнейших публикациях.

§ 5. Информационный вес признака

Пусть задана допустимая в узком смысле таблица T (см. определение 3), то есть на всех предметах, эталонами которых являются строки таблицы T , основное свойство x_{n+1} выполнено.

При решении различных задач бывает необходимо расклассифицировать вспомогательные признаки x_1, \dots, x_n по степени ценности их для изучения свойства x_{n+1} , иными словами, необходимо установить последовательность выявления признаков для оценки явления.

Ниже мы введем меру ценности (информационный вес) признака x_i .

ОПРЕДЕЛЕНИЕ 4'. Набор (i_1, \dots, i_e) , соответственно $(x_{i_1}, \dots, x_{i_e})$, называется тестом таблицы T , если после удаления из T всех столбцов, за исключением (i_1, \dots, i_e) , получается таблица, все строки которой различны.

ОПРЕДЕЛЕНИЕ 5. Тест (i_1, \dots, i_ℓ) соответственно $(x_{i_1}, \dots, x_{i_\ell})$, называется тупиковым для таблицы T , если из него нельзя удалить ни одного столбца без того, чтобы он перестал быть тестом.

Понятие "тест" впервые было введено С.В.Яблонским в связи с изучением методов контроля электрических схем [1].

Пусть κ — число тупиковых тестов таблицы T , κ_i — число тупиковых тестов таблицы T , в которое входит столбец, соответствующий признаку (предикату) x_i .

ОПРЕДЕЛЕНИЕ 7. Число $\rho(i) = \frac{\kappa_i}{\kappa}$ называется информационным весом признака $x_i, i = 1, 2, \dots, n$.

Величина $\rho(i)$ оценивает важность признака x_i при изучении явления, описываемого основным предикатом x_{n+1} . Если расположить признаки $x_i, i = 1, 2, \dots, n$, в последовательность по убыванию $\rho(i)$, то признаки, получившие меньший номер, оказываются более важными при изучении предметов, обладающих свойством x_{n+1} .

При исследовании конкретных таблиц T , описывающих естественнонаучные эксперименты, обычно оказывается, что признаки распадаются по значениям $\rho(i)$ на группы, причем колебание между группами величины $\rho(i)$ велико по сравнению с колебанием внутри группы. Таким образом, признаки по информационной ценности часто распадаются на четко очерченные ранги. Признаки первого ранга оказываются наиболее существенными при изучении предметов, обладающих свойством x_{n+1} , второго ранга — менее существенными и т.д.

ЗАМЕЧАНИЕ. Таблицы, рассматриваемые в данном параграфе, должны обладать еще одним свойством; в каждом столбце таблицы имеется хотя бы один элемент, равный нулю, и хотя бы один элемент, равный единице.

ПРИМЕР 4. (иллюстрированный). В качестве основного множества M рассматривается совокупность книг. Основным признаком книги \tilde{x} является книга для детей.

Вспомогательные признаки:

- $x_1(\tilde{x})$ — \tilde{x} набрана крупным шрифтом;
- $x_2(\tilde{x})$ — в \tilde{x} много иллюстраций;
- $x_3(\tilde{x})$ — \tilde{x} издана на хорошей бумаге;
- $x_4(\tilde{x})$ — в \tilde{x} помещено хотя бы одно стихотворение;
- $x_5(\tilde{x})$ — сюжет \tilde{x} не представляет собой единого целого.

Рассматривается множество M , состоящее из шести книг

для детей (на элементах M основной предикат выполнен).

Таблица T соответствующих эталонов:

	x_1	x_2	x_3	x_4	x_5
s_1	1	0	0	1	1
s_2	1	1	0	1	1
s_3	1	0	1	1	0
s_4	1	1	1	0	0
s_5	0	1	1	0	1
s_6	0	1	1	1	0

Тупиковые тесты таблицы T :

$\langle x_1, x_2, x_5 \rangle, \langle x_2, x_4, x_5 \rangle, \langle x_1, x_2, x_3, x_4 \rangle$.

Откуда получаем возможность вычислить $\rho(i)$:

$$\rho(1) = \frac{1}{2}, \rho(2) = 1, \rho(3) = \frac{1}{3}, \rho(4) = \frac{1}{2}, \rho(5) = \frac{1}{2}$$

Наиболее важным для характеристики свойства книги быть детской оказывается признак $x_2(\tilde{x})$ в \tilde{x} много иллюстраций, наименее важным — признак $x_3(\tilde{x})$, характеризующий качество бумаги в \tilde{x} . По значениям $\rho(i)$ признаки распадаются на три группы:

- $\{x_2\}$ — группа первого ранга, $\rho(2) = 1$;
- $\{x_1, x_4, x_5\}$ — группа второго ранга, $\rho(1) = \rho(4) = \rho(5) = \frac{1}{2}$;
- $\{x_3\}$ — группа третьего ранга, $\rho(3) = \frac{1}{3}$.

ПРИМЕР 5. При решении задачи, возникшей в одной из областей естествознания, была получена группа семи эталонов, для которых основным признаком (принадлежность к определенному типу) был выполнен. Рассматривались вспомогательные признаки: x_1, x_2, \dots, x_{17} .

Таблица T эталонов имеет следующий вид:

x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8	x_9	x_{10}	x_{11}	x_{12}	x_{13}	x_{14}	x_{15}	x_{16}	x_{17}
1	0	0	1	1	1	1	0	1	1	1	0	1	1	1	1	1
1	0	0	1	0	0	1	1	0	1	1	0	1	1	1	1	0
0	0	1	0	0	0	1	1	0	1	1	0	1	1	0	1	1
0	1	0	0	0	0	1	1	0	0	0	1	1	1	1	1	-
1	0	0	0	0	0	1	1	0	0	0	1	1	0	1	1	-
0	0	1	-	0	0	1	-	-	0	0	1	0	0	1	1	-
1	0	0	1	-	0	0	0	1	0	0	1	1	0	1	1	-

Оказалось, что таблица T характеризуется 406 тупиковыми тестами, для которых вычислено:

Признаки	$x_{16} \ x_7 \ x_{13} \ x_2 \ x_4 \ x_1 \ x_{14} \ x_{17} \ x_6 \ x_5 \ x_3$
Число тупиковых тестов, в которые входит данный признак	374 334 322 316 256 250 243 242 228 225 211
Информационный вес признака	097 087 083 082 066 065 063 063 059 058 054
Признаки	$x_5 \ x_{12} \ x_{10} \ x_{11} \ x_8 \ x_9$
Число тупиковых тестов, в которые входит данный признак	155 153 152 151 121 119
Информационный вес признака	040 040 039 039 032 030

Таким образом, признаки распались на группы:

- $\{x_{16}\}$ - группа первого ранга, $\rho(16)=0,97$;
- $\{x_7, x_{13}, x_2\}$ - группа второго ранга, $0,82 \leq \rho(i) \leq 0,87$;
- $\{x_4, x_1, x_{14}, x_{17}, x_6, x_5, x_3\}$ - группа третьего ранга, $0,54 \leq \rho(i) \leq 0,66$;
- $\{x_5, x_{12}, x_{10}, x_{11}\}$ - группа четвертого ранга, $0,39 \leq \rho(i) \leq 0,40$;
- $\{x_8, x_9\}$ - группа пятого ранга, $0,30 \leq \rho(i) \leq 0,32$.

Оказалось, что упорядоченность признаков по убыванию информационного веса соответствует упорядоченности по важности (в содержательном смысле).

Так, признаки x_{16}, x_7, x_{13}, x_2 наиболее характерны для данного типа эталонов.

§ 6. Вычисление информационного веса признака

Вычисление информационного веса $\rho(i)$ сводится к построению всех тупиковых тестов таблицы эталонов T .

Алгоритмы выделения всех тупиковых тестов имеют ту же природу, что и алгоритмы синтеза всех тупиковых тесторов для (T, τ) , описанные в § 3.

Рассмотрим аналоги второго и третьего алгоритмов из § 3.

1) Алгоритм С.В.Яблонского.

Пусть таблица T состоит из строк s_1, s_2, \dots, s_t . Для каждой пары i, j , $i \neq j$, составляем строку $s_{ij} = s_i \circ s_j$ и выделя-

ем набор x_{ij} переменных $x'_{ij}, \dots, x''_{ij}(\zeta_j)$, для которых соответствующая координата в s_{ij} равна нулю.

Составляем выражение:

$$\prod_{\substack{1 \leq i \leq t \\ 1 \leq j \leq t \\ i \neq j}} (x'_{ij} \vee \dots \vee x''_{ij}(\zeta_j)) . \quad (2)$$

Рассматривая символы x''_{ij} как булевы переменные, приводим (2) к виду $\sum \prod$ и производим все упрощения $A \cdot A = A$, $A \vee A = A$, $A \vee A \cdot B = A$. Пусть (2) переходит в

$$\vee x'_{i_1 j_1} \dots x'_{i_r j_r} . \quad (3)$$

Каждому слагаемому в (3) соответствует тупиковый тест $(x'_{i_1 j_1}, \dots, x'_{i_r j_r})$, и все тупиковые тесты получаются таким образом.

2) Сведение синтеза всех тупиковых тесторов к задаче расщиповки монотонной функции. Сопоставим набору $(x_{i_1}, \dots, x_{i_r})$ вершину $\tilde{\alpha} = (\alpha_1, \dots, \alpha_n)$, положив $\alpha_{i_1} = \dots = \alpha_{i_r} = 1$ и остальные координаты равными нулю.

Зададим функцию $f_T(x_1, \dots, x_n)$.

$$f_T(\alpha_1, \dots, \alpha_n) = \begin{cases} 1 & \text{, если набор } (x_{i_1}, \dots, x_{i_r}) \text{, сопоставленный вершине } (\alpha_1, \dots, \alpha_n) \text{, образует тест для } T ; \\ 0 & \text{- в противном случае .} \end{cases}$$

ПРИМЕР 6. Пусть

$$T = \begin{pmatrix} 0 & 0 & 0 & 0 \\ 1 & 0 & 1 & 0 \\ 0 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 \end{pmatrix} .$$

Тогда функция $f_T(x_1, x_2, x_3, x_4)$ несущественно зависит от переменной x_3 ;

$$f_T(x_1, x_2, x_3, x_4) = \varphi(x_1, x_2, x_4) = x_1 \cdot x_2 \vee x_1 \cdot x_4 .$$

§ 7. Информационный вес эталона (строки)

Пусть информационный вес вспомогательных предикатов оказался равным $\rho(1), \dots, \rho(n)$.

Рассмотрим произвольный эталон S (строку таблицы T). Пусть в строке S на местах i_1, \dots, i_e стоят единицы, на местах j_1, \dots, j_z — прочерки. Обозначим через q_j^t число элементов, отличных от прочерка, в столбце j_t , $t=1, 2, \dots, z$; через \tilde{q}_j^t — число элементов (равных единице) в столбце j_t , $t=1, 2, \dots, z$.

Обозначим:

$$\frac{\tilde{q}_j^t}{q_j^t} = q(j_t), \quad t=1, 2, \dots, z.$$

$$\sum_{i=1}^n \rho(i) = \rho.$$

ОПРЕДЕЛЕНИЕ 8. Величина $\mathcal{I}(S) = \frac{1}{\rho} \left(\sum_{j=1}^e \rho(i_j) + \sum_{t=1}^z q(j_t) \cdot \rho(j_t) \right)$ называется информационным весом эталона S .

Если число эталонов в таблице T невелико, вместо величины $\mathcal{I}(S)$ можно рассматривать более грубую характеристику:

$$\tilde{\mathcal{I}}(S) = \frac{1}{\rho} \left(\sum_{j=1}^e \rho(i_j) + \frac{1}{2} \sum_{t=1}^z \rho(j_t) \right).$$

В приложениях часто возникают задачи классификации эталонов (предметов), для которых выполнен предикат α_{n+1} по степени проявления свойства α_{n+1} (степени активности вещества, степени опасности данной инфекции и т.д.).

Оказалось, что в ряде задач упорядоченность предметов по убыванию величины $\mathcal{I}(S)$ совпадает (или сильно коррелирована) с упорядоченностью по степени проявления свойства α_{n+1} . Таким образом, значения $\mathcal{I}(S)$ могут послужить основой для построения классификации предметов или явлений по степени проявления свойства α_{n+1} .

ПРИМЕР 7. В таблице примера 4 имеем:

$$\rho = \frac{17}{6}; \quad \mathcal{I}(S_1) = \frac{6}{17} (\rho(1) + \rho(4) + \rho(5)) = \frac{9}{17}; \quad \mathcal{I}(S_2) = \frac{15}{17};$$

$$\mathcal{I}(S_3) = \frac{8}{17}; \quad \mathcal{I}(S_4) = \mathcal{I}(S_5) = \mathcal{I}(S_6) = \frac{11}{17}.$$

Таким образом, среди книг, эталонами которых являются $S_1, S_2, S_3, S_4, S_5, S_6$, наиболее типичная детская книга представлена эталоном S_3 .

Характеристика S_3 : книга набрана крупным шрифтом, в ней

много иллюстраций, качество бумаги — невысокое, в книге есть стихи, содержание книги не представляет собой единого целого.

Л и т е р а т у р а

1. И.А.Чегис, С.В.Яблонский. Логические способы контроля электрических схем. — Труды Математического института им. В.А.Стеклова, 1958, т. 51. стр.270—360.
2. В.К.Коробков. О монотонных функциях алгебры логики. — Проблемы кибернетики, 1965, вып. 13, стр. 5.

Поступила в редакцию
8.IV.1966 г.