

УДК 519.714

О ПРОЦЕДУРАХ КЛАССИФИКАЦИИ, ОСНОВАННЫХ НА ПОСТРОЕНИИ ПОКРЫТИЙ КЛАССОВ¹⁾

© 2003 г. Е. В. Дюкова, А. С. Инякин

(119991 Москва, ул. Вавилова, 40, ВЦ РАН)

e-mail: djukova@ccas.ru, andre-w@mail.ru

Поступила в редакцию 28.02.2003 г.

Описывается подход к решению задачи кластеризации с целочисленной информацией, основанный на построении специальных наборов значений признаков, не содержащихся в признаковых описаниях объектов. Задача сводится к построению тупиковых покрытий целочисленных матриц, которое может быть осуществлено на основе построения неприводимых покрытий булевых матриц. Предлагается новый метод построения неприводимых и минимальных покрытий булевой матрицы, использующий геометрическую интерпретацию понятия покрытия. Изучаются метрические свойства близких к минимальным покрытиям целочисленных матриц. Библ. 13. Фиг. 5.

ВВЕДЕНИЕ

В ряде прикладных задач классификации зачастую возникает необходимость разбить совокупность объектов на “однородные” группы (классы) при условии отсутствия обучающей информации. Задачи такого типа называют задачами таксономии.

Итак, пусть имеется конечная выборка M , каждый элемент которой описывается конечным набором признаков (свойств). Требуется разбить данную выборку на однородные группы, число которых может быть заранее заданным, а может быть и неизвестным. Процесс деления на классы называют кластеризацией или кластерным анализом.

При постановке задачи необходимо описать правила, которым должны подчиняться объекты из одного класса и объекты из разных классов. В качестве такого правила можно рассматривать компактность объектов в заданном признаковом пространстве, т.е. правило, в соответствии с которым, например, “расстояние” между объектами, отнесенными в один класс, должно быть не более заданного. Может также использоваться “хорошая” взаимная удаленность классов, например, расстояние между объектами, отнесенными в разные классы, должно быть не менее заданного.

В данной работе рассматриваются некоторые подходы к решению задач таксономии с целочисленной информацией. Отличием предлагаемых методов от классических является то, что при решении указанных задач не нужно подбирать функцию расстояния, которая не всегда может быть достаточно простой для вычисления. В их основе лежат следующие соображения.

Рассмотрим ситуацию, когда определяется степень принадлежности объекта S к группе объектов M . Если описание объекта S содержит набор значений признаков, который не присутствует в описании ни одного объекта из M , то можно сказать, что объединение S и M нарушает внутреннюю структуру множества M . Рассматривая различные комбинации значений признаков, не содержащихся в описаниях объектов из M , можно оценить близость объекта S к множеству M . Таким образом, при определении степени близости объекта к множеству M информативными считаются такие наборы из допустимых значений признаков, которые отсутствуют в описаниях всех объектов из класса M .

На основе приведенных выше рассуждений был построен алгоритм, который в ряде случаев позволил значительно улучшить результаты кластеризации на модельных и реальных задачах по сравнению с такими известными алгоритмами, как алгоритмы, основанные на принципах “ближайший сосед”, “дальний сосед” и выбор центрального элемента, в которых в качестве функции расстояния используется расстояние Хемминга.

¹⁾Работа выполнена при частичной финансовой поддержке РФФИ (коды проектов 01-01-00575, 00-15-96064) и Программы Президиума РАН “Интеллектуальные компьютерные системы” (проект № 1.1).

В предложенном алгоритме кластеризации задача оценки близости объекта S к множеству M сводится к поиску так называемых тупиковых σ -покрытий целочисленной матрицы, образованной признаковыми описаниями объектов из M . Данное понятие является обобщением хорошо известного в дискретной математике понятия неприводимого покрытия булевой матрицы и первоначально было введено в [1], [2] в связи с задачами построения тупиковых представительных наборов в алгоритмах типа “Кора” (см. [3], [4]) и с изучением метрических свойств множества представительных наборов. В [5] показано, что задача построения (тупиковых) покрытий целочисленных матриц может быть сведена к задаче поиска (неприводимых) покрытий булевой матрицы. Наиболее полно подход к решению задач распознавания, основанный на построении покрытий булевых и целочисленных матриц, описан в [6], [7].

Более информативными считаются наборы значений признаков, порождаемые короткими σ -покрытиями, поэтому, как правило, строят не все σ -покрытия, а только те, длины которых не превосходят некоторой наперед заданной величины. В связи с этим в данной работе изучаются метрические (количественные) свойства σ -покрытий, по длине близких к минимальным σ -покрытиям. Получена асимптотика числа таких покрытий в типичном случае.

В статье предлагается геометрическая интерпретация понятий σ -покрытия и тупикового σ -покрытия матрицы L размера $m \times n$ с элементами из $\{0, 1, \dots, k-1\}$, $k \geq 2$. Пусть M_L – множество таких k -х наборов длины n (точек k -значного n -мерного куба), которые являются строками матрицы L . Показано, что задача построения (тупиковых) σ -покрытий матрицы L сводится к задаче построения (максимальных) подкубов в множестве $\bar{M}_L$, состоящем из всех k -х наборов длины n , не вошедших в матрицу L . Для случая $k = 2$ предложен алгоритм поиска максимальных подкубов в $\bar{M}_L$, соответствующих неприводимым покрытиям булевой матрицы L , и модификация этого алгоритма на случай поиска максимальных подкубов в $\bar{M}_L$, соответствующих минимальным по длине покрытиям матрицы L .

1. ОСНОВНЫЕ ОПРЕДЕЛЕНИЯ. ГЕОМЕТРИЧЕСКАЯ ИНТЕРПРЕТАЦИЯ ПОНЯТИЙ ПОКРЫТИЯ И ТУПИКОВОГО ПОКРЫТИЯ ЦЕЛОЧИСЛЕННОЙ МАТРИЦЫ

Введем следующие обозначения:

E_k^r , $k \geq 2$, – множество всех k -х наборов длины r , $r \leq n$; $E^r = E_2^r$; σ – набор из E_k^r вида $(\sigma_1, \dots, \sigma_r)$.

Набор H из r различных столбцов матрицы L назовем σ -покрытием, если подматрица L^H матрицы L , образованная столбцами набора H , не содержит строку $(\sigma_1, \dots, \sigma_r)$.

Набор столбцов H , являющийся σ -покрытием матрицы L , назовем тупиковым σ -покрытием, если для любого $p \in \{1, 2, \dots, r\}$ подматрица L^H содержит хотя бы одну строку вида $(\beta_1, \dots, \beta_r)$, где $\beta_p \neq \sigma_p$ и $\beta_i = \sigma_i$ при $i = \overline{1, r}$ и $i \neq p$, т.е. L^H содержит подматрицу вида

$$\begin{pmatrix} \beta_1 & \sigma_2 & \sigma_3 & \dots & \sigma_{r-1} & \sigma_r \\ \sigma_1 & \beta_2 & \sigma_3 & \dots & \sigma_{r-1} & \sigma_r \\ \dots & \dots & \dots & \dots & \dots & \dots \\ \sigma_1 & \sigma_2 & \sigma_3 & \dots & \sigma_{r-1} & \beta_r \end{pmatrix}.$$

Такую подматрицу назовем σ -подматрицей.

В случае $k = 2$ и $\sigma = (0, \dots, 0)$ понятие тупикового σ -покрытия совпадает с известным понятием неприводимого покрытия булевой матрицы (см. [8]), при этом σ -подматрица является единичной подматрицей.

Обозначим через $C(L, \sigma)$, $B(L, \sigma)$ и $S(L, \sigma)$, соответственно, множество σ -покрытий матрицы L , множество тупиковых σ -покрытий матрицы L и множество σ -подматриц матрицы L . Положим

$$C(L) = \bigcup_{r=1}^n \bigcup_{\sigma \in E_k^r} C(L, \sigma), \quad B(L) = \bigcup_{r=1}^n \bigcup_{\sigma \in E_k^r} B(L, \sigma), \quad S(L) = \bigcup_{r=1}^n \bigcup_{\sigma \in E_k^r} S(L, \sigma).$$

Покажем, что задачи построения множеств $C(L)$ и $B(L)$ можно свести, соответственно, к задачам построения $(0, \dots, 0)$ -покрытий и тупиковых $(0, \dots, 0)$ -покрытий (неприводимых покрытий) булевой матрицы, которая специальным образом строится по L .

Пусть матрица L имеет вид

$$\begin{bmatrix} x_{11} & \dots & x_{1n} \\ \dots & \dots & \dots \\ x_{1m} & \dots & x_{mn} \end{bmatrix},$$

где каждый элемент столбца с номером j может принимать k_j ($k_j \leq k$) значений (для дальнейших рассуждений удобно считать, что элементы столбца с номером j принимают значения от 1 до k_j).

Положим

$$\delta(x_{ij}, a) = \begin{cases} 1, & x_{ij} \neq a, \\ 0, & x_{ij} = a, \end{cases}$$

где $i = \overline{1, m}, j = \overline{1, n}$.

Построим матрицу L^B , состоящую из m строк, в которой строка с номером $i, i \in \{1, 2, \dots, m\}$, имеет вид

$$(\delta(x_{i1}, 1), \dots, \delta(x_{i1}, k_1), \delta(x_{i2}, 1), \dots, \delta(x_{i2}, k_2), \dots, \delta(x_{in}, 1), \dots, \delta(x_{in}, k_n)).$$

Нетрудно заметить, что столбцу с номером $j, j \in \{1, 2, \dots, n\}$, исходной матрицы соответствует группа, состоящая из k_j столбцов бинарной матрицы L^B , обозначаемая далее через g_j . В группе g_j столбцы будем нумеровать числами от 1 до k_j .

Обозначим через (j, i) столбец матрицы L^B из группы g_j с номером $i, j \in \{1, 2, \dots, n\}, i \in \{1, 2, \dots, k_j\}$.

Очевидным является

Утверждение 1. Набор столбцов матрицы L^B вида $((j_1, i_1), \dots, (j_r, i_r)), r \in \{1, 2, \dots, n\}, j_l \in \{1, 2, \dots, n\}, i_l \in \{1, 2, \dots, k_{j_l}\}, j_{l_1} \neq j_{l_2} \text{ при } l_1 \neq l_2, l_1, l_2 = 1, 2, \dots, r$, является (неприводимым) покрытием тогда и только тогда, когда набор столбцов с номерами (j_1, j_r) является (тупиковым) (j_1, j_r) -покрытием матрицы L .

Множество E_k^n можно рассматривать как k -значный n -мерный куб. Обозначим через M_L множество точек куба E_k^n , задаваемых строками матрицы L . Положим $\overline{M}_L = E_k^n \setminus M_L$. Набору столбцов H с номерами $(j_1, \dots, j_r)$, являющимся σ -покрытием матрицы L , поставим в соответствие множество точек $E^{(\sigma, H)} = \{(\alpha_1, \dots, \alpha_n) | \alpha \in E_k^n, \alpha_{j_i} = \sigma_i, i = \overline{1, r}\}$. Очевидно, $E^{(\sigma, H)}$ является $(n-r)$ -мерным подкубом куба E_k^n и целиком принадлежит множеству $\overline{M}_L$. В случае, когда $r = n$ множество точек $E^{(\sigma, H)}$ является 0-мерным подкубом, состоящим из одной точки σ . Таким образом, множеству $C(L)$ взаимно однозначно соответствует множество всех подкубов, содержащихся в $\overline{M}_L$. Отметим, что $E^{(\sigma_1, H_1)}$ является подкубом $E^{(\sigma_2, H_2)}$ тогда и только тогда, когда $\sigma_2 \subset \sigma_1, H_2 \subset H_1$.

Пусть M – некоторое подмножество множества E_k^n . Будем говорить, что подкуб $E' \subset M$ является максимальным в M , если не существует другого подкуба $E'' \subset M$ такого, что $E' \subset E''$. Множество всех максимальных подкубов в M будем обозначать через $E^{\max}(M)$. Нетрудно видеть, что множеству $B(L)$ взаимно однозначно соответствует множество $E^{\max}(\overline{M}_L)$. Следовательно, задачу построения множества $B(L)$ можно свести к задаче построения множества всех максимальных подкубов в $\overline{M}_L$.

2. АЛГОРИТМЫ ПОИСКА НЕПРИВОДИМЫХ И МИНИМАЛЬНЫХ ПОКРЫТИЙ БУЛЕВОЙ МАТРИЦЫ, ИСПОЛЬЗУЮЩИЕ ГЕОМЕТРИЧЕСКУЮ ИНТЕРПРЕТАЦИЮ ПОНЯТИЯ ПОКРЫТИЯ

В [9] построен асимптотически оптимальный алгоритм поиска всех неприводимых покрытий булевой матрицы в случае, когда число строк матрицы существенно меньше числа столбцов. Описываемые в данном разделе алгоритмы предназначены в основном для поиска неприводимых и минимальных по длине покрытий булевой матрицы в случае, когда число строк матрицы существенно больше числа столбцов (в этом случае они работают достаточно быстро).

Пусть $k = 2$. Очевидно, что если точка $\tilde{0} = (0, \dots, 0)$ принадлежит M_L , то в матрице L нет ни одного неприводимого покрытия, поэтому далее будем полагать, что $\tilde{0} \in \bar{M}_L$.

Легко видеть, что $(0, \dots, 0)$ -покрытию булевой матрицы L соответствует подкуб в $\bar{M}_L$, одной из вершин которого является точка $\tilde{0}$. Неприводимому покрытию матрицы L соответствует максимальный подкуб в $\bar{M}_L$, одной из вершин которого является точка $\tilde{0}$. Таким образом, множеству всех неприводимых покрытий булевой матрицы L соответствует пучок всех максимальных подкубов в $\bar{M}_L$, исходящий из точки $\tilde{0}$.

Будем говорить, что точка $\tilde{\alpha} = (\alpha_1, \dots, \alpha_n)$, $\tilde{\alpha} \in E^n$, охватывает точку $\tilde{\beta} = (\beta_1, \dots, \beta_n)$, $\tilde{\beta} \in E^n$, и обозначать это через $\tilde{\alpha} > \tilde{\beta}$, если $\alpha_i \geq \beta_i$, $i = \overline{1, n}$. Через $M(\tilde{\alpha}, \tilde{\beta})$ будем обозначать подкуб минимальной размерности в E^n , содержащий точки $\tilde{\alpha}$ и $\tilde{\beta}$. Будем говорить, что подкуб $M(\tilde{\alpha}, \tilde{\beta})$ является покрывающим для M_L , если $M(\tilde{\alpha}, \tilde{\beta}) \subseteq \bar{M}_L$.

Очевидным является

Утверждение 2. Если $\tilde{\alpha} \in \bar{M}_L$, то $M(\tilde{\alpha}, \tilde{0})$ не содержится в $\bar{M}_L$ тогда и только тогда, когда в M_L можно указать точку $\tilde{\beta}$ такую, что $\tilde{\alpha} > \tilde{\beta}$.

Алгоритм построения всех неприводимых покрытий матрицы L

Шаг 1. Из $\bar{M}_L$ удаляются все точки $\tilde{\alpha}$ такие, что в M_L найдется точка $\tilde{\beta}$ для которой $\tilde{\alpha} > \tilde{\beta}$.

Шаг 2. Пусть $\tilde{\alpha}' \in \bar{M}_L$ и $\rho(\tilde{\alpha}', \tilde{0}) = \max_{\tilde{\alpha} \in \bar{M}_L} \rho(\tilde{\alpha}, \tilde{0})$ (здесь и далее $\rho(\tilde{\alpha}, \tilde{\beta})$ – расстояние Хемминга между точками $\tilde{\alpha}$ и $\tilde{\beta}$). Очевидно, $M(\tilde{\alpha}', \tilde{0})$ – максимальный покрывающий подкуб для M_L . Пусть $j_1, \dots, j_r$ – координаты, в которых точки $\tilde{\alpha}'$ и $\tilde{0}$ совпадают, тогда набор столбцов с номерами $j_1, \dots, j_r$ является неприводимым покрытием матрицы L , соответствующим максимальному подкубу $M(\tilde{\alpha}', \tilde{0})$. Положим $\bar{M}_L = \bar{M}_L \setminus M(\tilde{\alpha}', \tilde{0})$.

Шаг 3. Если $\bar{M}_L \neq \emptyset$, то перейти к шагу 2, иначе конец работы алгоритма.

Алгоритм построения всех минимальных покрытий матрицы L

Шаг 1. Из $\bar{M}_L$ удаляются все точки $\tilde{\alpha}$ такие, что в M_L найдется точка $\tilde{\beta}$ для которой $\tilde{\alpha} > \tilde{\beta}$.

Шаг 2. Пусть $\tilde{\alpha}' \in \bar{M}_L$ и $\rho(\tilde{\alpha}', \tilde{0}) = \max_{\tilde{\alpha} \in \bar{M}_L} \rho(\tilde{\alpha}, \tilde{0})$. Положим

$$Q_L = \{\tilde{\alpha} \mid \tilde{\alpha} \in \bar{M}_L, \rho(\tilde{\alpha}, \tilde{0}) = \rho(\tilde{\alpha}', \tilde{0})\}.$$

Шаг 3. Пусть $\tilde{\alpha}' \in Q_L$, $j_1, \dots, j_r$ – координаты, в которых точки $\tilde{\alpha}'$ и $\tilde{0}$ совпадают, тогда набор столбцов с номерами $j_1, \dots, j_r$ является минимальным покрытием матрицы L , соответствующим максимальному подкубу $M(\tilde{\alpha}', \tilde{0})$. Положим $Q_L = Q_L \setminus \tilde{\alpha}'$.

Шаг 4. Если $Q_L \neq \emptyset$, то перейти к шагу 3, иначе – конец работы алгоритма.

Заметим, что описанный алгоритм поиска неприводимых покрытий может быть модифицирован на случай поиска тупиковых σ -покрытий.

3. АЛГОРИТМ КЛАСТЕРИЗАЦИИ, ОСНОВАННЫЙ НА ПОСТРОЕНИИ ТУПИКОВЫХ σ -ПОКРЫТИЙ

Меру близости множества $M'' \subset E^n$ к множеству $M' \subset E^n$ определим следующей величиной:

$$P(M', M'') = \frac{|E^{\max}(E^n \setminus M') \cap E^{\max}(E^n \setminus (M' \cup M''))|}{E^{\max}(E^n \setminus M')},$$

здесь $|A|$ – мощность множества A .

Зададим некоторое число $p, p \in (0, 1)$. Будем говорить, что множество M'' близко к M' по порогу p , если $P(M', M'') \geq p$.

Пусть задача кластеризации решается для множества объектов $M = \{S_1, \dots, S_m\}$.

Формирование первого класса M_1 осуществляется следующим образом.

Шаг 1. Положить $M_1 = S$, где S – произвольный элемент из множества M . Если $M \setminus M_1 = \emptyset$, то алгоритм заканчивает работу. В противном случае перейти к шагу 2.

Шаг 2. Если в $M \setminus M_1$ существует элемент S' такой, что

$$P(M_1, \{S'\}) = \max_{S \in \Omega \setminus M_1} P(M_1, \{S\}) \text{ и } P(M_1, \{S'\}) \geq p,$$

то положить $M_1 = M_1 \cup \{S'\}$ и повторить шаг 2. В противном случае перейти к формированию следующего класса.

Пусть построены классы $M_1, \dots, M_{i-1}, i \geq 2$, и пусть

$$\tilde{M}_i = M \setminus \bigcup_{j=1}^{i-1} M_j.$$

Если $\tilde{M}_i = \emptyset$, то алгоритм заканчивает работу, в противном случае осуществляется формирование класса M_i . Процедура построения класса M_i полностью аналогична процедуре построения класса M_1 при условии, что за исходное множество вместо M берется $\tilde{M}_i$.

В данном алгоритме для определения близости объектов или групп объектов используется понятие максимального подкуба множества точек, что дает возможность не вводить функцию расстояния между объектами.

Решение практических задач показало, что число p целесообразно выбирать из интервала $(0.5, 0.9)$. Чем больше величина p , тем, соответственно, большее число классов образуется при кластеризации.

Описание алгоритма без использования геометрического языка приведено в [5].

4. РЕЗУЛЬТАТЫ ТЕСТИРОВАНИЯ НА МОДЕЛЬНЫХ И РЕАЛЬНЫХ ЗАДАЧАХ

Приведем результаты тестирования на модельных и реальных задачах алгоритмов кластеризации, основанных на принципах дальний сосед (алгоритм A_1), ближайший сосед (алгоритм A_2), выбора центрального элемента (алгоритм A_3) и алгоритма кластеризации, основанного на построении тупиковых σ -покрытий (алгоритм A_4).

Алгоритмы A_1, A_2 и A_3 относятся к классу так называемых иерархических методов группировки, суть которых состоит в следующем. Рассматривается последовательность разделений m объектов на группы. Первый шаг последовательности – разделение на m групп таких, что каждая группа содержит в точности по одному объекту. Следующий шаг – разделение на $m - 1$ группу, затем на $m - 2$ групп и т.д., до m -го шага, в котором все объекты образуют одну группу. Таким образом, k -му шагу соответствует разделение на $m + 1 - k$ групп, где $k = 1, 2, \dots, m$. Последовательность разделений называется иерархической группировкой, если любые два объекта S_1 и S_2 , объединенные в одну группу на k -м шаге, содержатся в одной группе и на всех последующих шагах.

Пусть требуется разделить m объектов S_1 и S_m на l классов. Основные этапы иерархической группировки описываются следующей процедурой.

1. Пусть $\tilde{l} = m$ и $\Omega_i = \{S_i\}$, $i = \overline{1, m}$.
2. Если $\tilde{l} \leq l$, то выход из процедуры.
3. Найти такие две группы Ω_i, Ω_j , для которых справедливо

$$\rho(\Omega_i, \Omega_j) = \min_{u \neq v} \rho(\Omega_u, \Omega_v),$$

где $\rho(\Omega_u, \Omega_v)$ – расстояние между группами Ω_u и Ω_v (см. ниже).

4. Объединить Ω_i и Ω_j , уничтожить Ω_i и уменьшить $\tilde{l}$ на единицу. Перейти к шагу 2.

Процедура заканчивает работу, когда достигнуто заданное число групп, т.е. при $\tilde{l} = l$.

Заметим, что в случае, когда число групп, на которое нужно разбить множество, не задано, применяются различные условия окончания процедуры группировки, в частности если наименьшее расстояние между группами на i -м шаге более чем в p раз превосходит наименьшее расстояние на $(i-1)$ -м шаге (число $p > 1$ задано заранее, обычно $p > 1.5$).

Заметим также, что результат работы описанной выше процедуры сильно зависит от выбора используемой функции расстояния между группами. Для тестирования использовались перечисленные ниже функции.

1. Расстояние, измеряемое по принципу ближайший сосед:

$$\rho(\Omega_u, \Omega_v) = \min_{S_i \in \Omega_u, S_j \in \Omega_v} \rho(S_i, S_j), \quad (u, v) = \overline{1, l}.$$

2. Расстояние, измеряемое по принципу дальний сосед:

$$\rho(\Omega_u, \Omega_v) = \max_{S_i \in \Omega_u, S_j \in \Omega_v} \rho(S_i, S_j), \quad (u, v) = \overline{1, l}.$$

3. Расстояние между центральными элементами классов:

$$\rho(\Omega_u, \Omega_v) = \rho(\bar{S}_u, \bar{S}_v),$$


где $\bar{S}_u$ – центральный элемент класса Ω_u , а $\bar{S}_v$ – центральный элемент класса Ω_v . В частности, в качестве центрального элемента класса можно выбрать центр тяжести класса.

В перечисленных выше формулах расстояние $\rho(S_i, S_j)$ между объектами $S_i = (x_{i1}, \dots, x_{in})$ и $S_j = (x_{j1}, \dots, x_{jn})$ вычислялось по формуле


$$\rho(S_i, S_j) = \sum_{k=1}^n |x_{ik} - x_{jk}|.$$

Сравнение алгоритма A_4 с алгоритмами A_1, A_2 и A_3 проводилось на модельных множествах данных, изображенных на фиг. 1.


Результаты работы алгоритма A_1 изображены на фиг. 2. Заметим, что алгоритм A_1 дает “правильное”, т.е. наиболее естественное на интуитивном уровне восприятия разбиение множества, изображенного на фиг. 1а, при произвольном порядке следования объектов в исходной выборке (вообще говоря, результаты работы рассматриваемых алгоритмов зависят от этого порядка).




Фиг. 1.




Фиг. 2.



Фиг. 3.



Фиг. 4.



Фиг. 5.

На фиг. 3 изображены результаты работы алгоритма A_2 . Применение алгоритма A_2 существенно “улучшает” разбиение множества, изображенного на фиг. 1б, но “ухудшает” разбиение множеств, изображенных на фиг. 1а и 1в.

На фиг. 4 изображены результаты работы алгоритма A_3 . Алгоритм, основанный на выборе центрального элемента, демонстрирует некое усреднение методов ближайший сосед и дальний сосед.

На фиг. 5 изображены результаты работы алгоритма A_4 . Алгоритм, основанный на построении тупиковых σ -покрытий, в отличие от предыдущих алгоритмов показывает лучшие результаты.

Алгоритмы кластеризации A_3 и A_4 были также протестированы на реальной информации социологического опроса. Анкета социологического опроса состояла из 21 вопроса, каждый содержал от 2 до 15 вариантов ответов. Всего в опросе приняло участие 799 респондентов. Множество респондентов было разбито на классы по ключевому вопросу анкеты: “Ваше отношение к партии А”. На этот вопрос было предложено четыре варианта ответа: симпатия, равнодушие, неприязнь и трудно сказать. Таким образом, было выделено 4 класса. Для каждого эксперимента случайным образом выбиралась небольшая группа (от 4 до 20) респондентов из каждого класса. Информация о принадлежности к какому-либо классу исключалась. Затем на полученном множестве проводилась кластеризация алгоритмом, основанным на построении тупиковых σ -покрытий (алгоритм A_4), и алгоритмом, основанным на вычислении расстояния Хемминга с выбором центрального элемента (алгоритм A_3). Всего было проведено 32 эксперимента. Разбиения, полученные в результате работы указанных алгоритмов, сравнивались с исходным разбиением на классы. Качество работы алгоритма характеризовалось отношением числа “правильно” классифицированных пар объектов к общему числу пар. При этом классификация считалась правильной, если выполнялось одно из условий: пара объектов, принадлежавших одному классу в исходном разбиении, после кластеризации также оказывалась в одном классе; пара объектов, принадлежавших различным классам в исходном разбиении, после кластеризации также не попадала в один класс.

Точность кластеризации, показанная алгоритмом A_3 при проведении экспериментов, лежала в пределах от 60% до 80%. Точность кластеризации, показанная алгоритмом A_4 , лежала в пределах от 70% до 90%.

Результаты сравнения на модельных и реальных задачах свидетельствуют о том, что алгоритмы, основанные на вычислении расстояния Хемминга, отличаются высокой скоростью счета. Эти методы используются в основном для решения задач с бинарной информацией. Их можно применять и в задачах с признаками большей значности, но в этом случае они плохо работают со специфическими множествами исходных данных, например с множествами данных, изобра-

женных на фиг. 1–3. Алгоритм A_4 обладает большей трудоемкостью, но он не ограничен бинарными признаками и показывает в этом случае более качественные результаты.

5. МЕТРИЧЕСКИЕ СВОЙСТВА БЛИЗКИХ К МИНИМАЛЬНЫМ ПОКРЫТИЙ ЦЕЛОЧИСЛЕННЫХ МАТРИЦ

Традиционно рассмотрение вопросов повышения качества и быстродействия алгоритмов распознавания, основанных на построении покрытий булевых и целочисленных матриц, связано с получением асимптотических оценок типичных значений важнейших количественных характеристик этого множества. Такими характеристиками являются, например, число покрытий и длины покрытия. Особый интерес и наибольшую трудность представляет изучение метрических свойств тупиковых покрытий.

В [1], [2], [6] и [7] были получены асимптотики числа покрытий из $B(L)$ и длины покрытия из $B(L)$ для почти всех матриц L размера $m \times n$ с элементами из $\{0, 1, \dots, k-1\}$, $k \geq 2$ при условиях $n \rightarrow \infty$ и $m^\alpha \leq n \leq k^{m^\beta}$, $\alpha > 1$, $\beta < 1$. Показано, что в данном случае число покрытий из $B(L)$ почти всегда асимптотически совпадает с числом всех подматриц из $S(L)$ и по порядку меньше числа покрытий из $C(L)$.

В [11] был рассмотрен прямо противоположный случай, а именно, когда $n^\alpha \leq m \leq k^{n^\beta}$, $\alpha > 1$, $\beta < 1$. Получены асимптотики типичных значений величины $S(L)$ и порядка подматрицы из $S(L)$ и установлено, что в случае, когда $n^\alpha \leq m \leq k^{n^\beta}$, $\alpha > 1$, $\beta < 1/2$, почти всегда число подматриц из $S(L)$ по порядку больше числа покрытий из $B(L)$. Кроме того, для практически общего случая в [11] получены асимптотики типичных значений числа покрытий из $C(L)$ и длины покрытия из $C(L)$ и показано, что при $r \leq \log_k m - (\log_k m \times \ln n)$ и $n \rightarrow \infty$ у почти всех матриц L размера $m \times n$ отсутствуют покрытия из $C(L)$ длины r .

Остался открытым вопрос: при каких условиях число тупиковых покрытий асимптотически совпадает с числом покрытий. Одним из ответов на этот вопрос является теорема 1, приводимая ниже.

Пусть $r_1 = [\log_k m - \log_k \ln \log_k m - 1]$ (здесь $[x]$ – целая часть числа x); φ – интервал $(\log_k m - \log_k(\log_k m \times \ln n), \log_k m - \log_k \ln \log_k m - 1]$; $a_n \approx b_n$ означает, что $\lim_{n \rightarrow \infty} a_n/b_n = 1$; $a_n \geq b_n$ означает, что $a_n \geq b_n$ при всех достаточно больших n ; M_{mn}^k , $k \geq 2$, – множество всех матриц размера $m \times n$ с элементами из $\{0, 1, \dots, k-1\}$; $C_\varphi(L)$ и $B_\varphi(L)$ – соответственно, совокупность покрытий из $C(L)$, длины которых принадлежат интервалу φ , и совокупность покрытий из $B(L)$, длины которых принадлежат интервалу φ , $C_{r_1}(L)$ и $B_{r_1}(L)$ – соответственно, совокупность покрытий из $C(L)$ длины r_1 и совокупность покрытий из $B(L)$ длины r_1 .

Теорема 1. Если $m \leq k^{n^\beta}$, $\beta < 1/2$, то для почти всех матриц L из M_{mn}^k при $n \rightarrow \infty$ справедливо соотношение

$$|B_\varphi(L)| \approx |C_\varphi(L)| \approx |C_{r_1}(L)| \approx |B_{r_1}(L)| \approx k^{r_1} C_n^{r_1} (1 - k^{-k_1})^m.$$

Доказательство теоремы опирается на приводимые ниже леммы 1–6.

Обозначим через W_r^n , $r \leq n$, – множество всех упорядоченных наборов вида $(j_1, \dots, j_r)$, где $j_l \in \{1, 2, \dots, n\}$, при $l = \overline{1, r}$ и $j_1 < \dots < j_r$.

Пусть $w \in W_r^n$, $\omega \in E_k^r$. Обозначим через $M_{(w, \sigma)}$ множество матриц L из M_{mn}^k таких, что подматрица матрицы L , образованная столбцами набора w , не содержит строку σ .

Будем считать $M_{mn}^k = \{L\}$ пространством элементарных событий, в котором каждое событие L происходит с вероятностью $|M_{mn}^k|^{-1}$. Математическое ожидание случайной величины $X(L)$ будем обозначать через $\mathbf{M}X(L)$, дисперсию – через $\mathbf{D}X(L)$.

Лемма 1 (см. [12]). Пусть для случайных величин $X_1(L)$ и $X_2(L)$, определенных на M_{mn}^k , выполнено неравенство $X_1(L) \geq X_2(L) \geq 0$ и при $n \rightarrow \infty$ верно $\mathbf{M}X_1(L) \approx \mathbf{M}X_2(L)$, $\mathbf{D}X_2(L)/(\mathbf{M}X_2(L))^2 \rightarrow 0$. Тогда для почти всех матриц L из M_{mn}^k имеет место соотношение $X_2(L) \approx X_1(L) \approx \mathbf{M}X_2(L)$, $n \rightarrow \infty$.

На множестве элементарных событий $M_{mn}^k = \{L\}$ рассмотрим случайные величины:

$$\xi_{w,\sigma}(L) = \begin{cases} 1, & \text{если набор столбцов с номерами из } w \text{ является } \sigma\text{-покрытием матрицы } L, \\ 0 & \text{в противном случае,} \end{cases}$$

и

$$\eta_{w,\sigma}(L) = \begin{cases} 1, & \text{если набор столбцов с номерами из } w \text{ является тупиковым } \sigma\text{-покрытием матрицы } L, \\ 0 & \text{в противном случае.} \end{cases}$$

Положим

$$\begin{aligned} \xi_r(L) &= \sum_{w \in W_r^n} \sum_{\sigma \in E_k^n} \xi_{w,\sigma}(L), & \xi_\varphi(L) &= \sum_{r \in \Phi} \sum_{w \in W_r^n} \sum_{\sigma \in E_k^n} \xi_{w,\sigma}(L), \\ \eta_r(L) &= \sum_{w \in W_r^n} \sum_{\sigma \in E_k^n} \eta_{w,\sigma}(L), & \eta_\varphi(L) &= \sum_{r \in \Phi} \sum_{w \in W_r^n} \sum_{\sigma \in E_k^n} \eta_{w,\sigma}(L). \end{aligned}$$

Заметим, что $\eta_\varphi(L) = B_\varphi(L)$ и $\xi_\varphi(L) = C_\varphi(L)$.

Пусть $\mathbf{P}(\xi_{w,\sigma}(L) = 1)$ – вероятность того, что $\xi_{w,\sigma}(L) = 1$, $\mathbf{P}(\eta_{w,\sigma}(L) = 1)$ – вероятность того, что $\eta_{w,\sigma}(L) = 1$.

Очевидно, что

$$\begin{aligned} \mathbf{P}(\xi_{w,\sigma}(L) = 1) &= |M_{(w,\sigma)}| |M_{mn}^k|^{-1} = (1 - k^{-r})^m, \\ \mathbf{P}(\eta_{w,\sigma}(L) = 1) &\leq \mathbf{P}(\xi_{w,\sigma}(L) = 1) = (1 - k^{-r})^m. \end{aligned} \quad (5.1)$$

Согласно формуле включений и исключений имеем

$$\mathbf{P}(\eta_{w,\sigma}(L) = 1) = (1 - k^{-r}) - C_r^1(1 - 2k^{-r})^m + C_r^2(1 - 3k^{-r})^m - \dots + (-1)^r C_r^r [1 - (r+1)k^{-r}]^m. \quad (5.2)$$

Отсюда при $r \leq r_1$ имеем

$$\mathbf{P}(\eta_{w,\sigma}(L) = 1) = (1 - k^{-r})^m [1 - r \exp(-2mk^{-r})] \geq (1 - k^{-r})^m (1 - 1/\log_k^{k-1} m).$$

Лемма 2. Имеет место неравенство

$$\mathbf{M}\xi_{r_1}(1 - 1/\log_k^{k-1} m) \leq \mathbf{M}\eta_{r_1} \leq \mathbf{M}\xi_{r_1}.$$

Доказательство. Верхняя оценка величины $\mathbf{M}\eta_{r_1}$ очевидна. Покажем справедливость нижней оценки. Согласно (5.1) и (5.2) имеем

$$\begin{aligned} \mathbf{M}\xi_r(L) &= \sum_{w \in W_r^n} \sum_{\sigma \in E_k^n} \mathbf{P}(\xi_{w,\sigma}(L) = 1) = C_r^r k^r (1 - k^{-r})^m, \\ \mathbf{M}\eta_r(L) &= \sum_{w \in W_r^n} \sum_{\sigma \in E_k^n} \mathbf{P}(\eta_{w,\sigma}(L) = 1) = C_r^r k^r \sum_{i=0}^r (-1)^i C_r^i [1 - (i+1)k^{-r}]^m. \end{aligned}$$

Следовательно,

$$\mathbf{M}\xi_r - \mathbf{M}\eta_r = C_n^r k^r \sum_{i=0}^r (-1)^{i-1} C_r^i [1 - (i+1)k^{-r}]^m \leq C_n^r k^r r (1 - 2k^{-r})^m \leq r(1 - k^{-r})^m \mathbf{M}\xi_r.$$

Полагая $r = r_1$, получаем

$$\mathbf{M}\xi_{r_1} - \mathbf{M}\eta_{r_1} \leq r_1 \exp(-mk^{-r_1}) \mathbf{M}\xi_{r_1} \leq \mathbf{M}\xi_{r_1} / \log_k^{k-1} m.$$

Лемма доказана.

Лемма 3. При $m < k^{n^\beta}$, $\beta < 1$, имеет место соотношение

$$\mathbf{M}\xi_\varphi \approx \mathbf{M}\eta_\varphi \approx \mathbf{M}\xi_{r_1} \approx \mathbf{M}\eta_{r_1} \approx k^{r_1} C_n^{r_1} (1 - k^{-r_1})^m, \quad n \rightarrow \infty.$$

Доказательство. Имеем

$$\mathbf{M}\xi_\varphi(L) = \sum_{r \in \Phi} \sum_{w \in W_r^n} \sum_{\sigma \in E_k^n} \mathbf{P}(\xi_{w, \sigma}(1) = 1) = \sum_{r = \varphi} C_n^r k^r (1 - k^{-r})^m.$$

Положим $A_r = C_n^r k^r (1 - k^{-r})^m$. Пусть $r \leq r_1$. Тогда

$$\frac{A_{r-1}}{A_r} = \frac{C_n^{r-1} k^{r-1} (1 - k^{-r+1})^m}{C_n^r k^r (1 - k^{-r})^m} \leq \frac{r}{k(n-r+1)} \leq \frac{\log_k m - \log_k \ln \log_k m + 1}{n - (\log_k m - \log_k \ln \log_k m)} \leq \frac{\log_k m}{n - \log_k m} \leq o(1).$$

Следовательно,

$$\mathbf{M}\xi_\varphi \approx \mathbf{M}\xi_{r_1}, \quad n \rightarrow \infty. \quad (5.3)$$

Из леммы 2, оценки (5.3) и неравенства $\mathbf{M}\eta_{r_1} \leq \mathbf{M}\eta_\varphi \leq \mathbf{M}\xi_\varphi$ следует утверждение доказываемой леммы.

Лемма 4. При $m < k^{n^\beta}$, $\beta < 1/2$, имеет место соотношение

$$\mathbf{D}\xi_{r_1}(L) / [\mathbf{M}\xi_{r_1}(L)]^2 \rightarrow 0, \quad n \rightarrow \infty.$$

Доказательство. Пусть $r = r_1$. Имеем

$$\mathbf{D}\xi_r(L) = \mathbf{M}\xi_r^2(L) - [\mathbf{M}\xi_r(L)]^2.$$

Очевидно, что

$$\mathbf{M}\xi_r^2(L) = \sum_{w_1, w_2 \in W_r^n} \sum_{\sigma_1, \sigma_2 \in E_k^r} |M_{(w_1, \sigma_1)} \cap M_{(w_2, \sigma_2)}|.$$

Пусть наборы w_1 и w_2 пересекаются по $r-t$ элементам. Тогда

$$\begin{aligned} |M_{(w_1, \sigma_1)} \cap M_{(w_2, \sigma_2)}| &\leq (k^r - 1)^m (k^t - 1)^m k^{m(n-r-t)} = (k^{r+t} - k^t - k^r + 1)^m k^{m(n-r-t)} = \\ &= (k^r - 1 - k^{r-t} + k^{-t})^m k^{m(n-r)} \leq (k^r - 2 + k^{-t})^m k^{m(n-r)}. \end{aligned}$$

Следовательно,

$$\mathbf{M}\xi_r^2(L) \leq C_n^r k^r k^{-mr} \sum_{t=0}^{\min(r, n-r)} C_{n-r}^t C_r^t k^t (k^r - 2 + k^{-t})^m.$$

Так как

$$(k^r - 2 + k^{-t})^m = (k^r - 2)^m \left(1 + \frac{1}{(k^r - 2)k^t}\right)^m \leq (k^r - 2)^m \left(1 + \frac{1}{k^{r+t-1}}\right)^m \quad \text{при } r \geq 2,$$

то

$$\mathbf{M}\xi_r^2(L) \leq C_n^r k^r k^{-mr} \sum_{t=0}^{\min(r, n-r)} C_{n-r}^t C_r^t k^t (k^r - 2)^m \exp\left(\frac{m}{k^{r+t-1}}\right).$$

Пусть $a_t = C_{n-r}^t C_r^t k^t \exp(m/k^{r+t-1})$ и $t_0 = [\log_k \log_k m + \log_k \ln \log_k m]$.

При $t \leq t_0$ имеем

$$a_t \leq (knr)^{t_0} \exp(m/k^{r-1}) \leq (knr)^{t_0} \log_k^{k^2} m. \quad (5.4)$$

При $t > t_0$ имеем

$$a_t \leq k^t C_{n-r}^t C_r^t \exp(k^4 / \log_k m). \quad (5.5)$$

Отметим, что

$$\sum_{t=0}^{\min(r, n-r)} C_{n-r}^t C_r^t \leq C_n^r. \quad (5.6)$$

Из (5.4)–(5.6) следует

$$\sum_{t=0}^{\min(r, n-r)} a_t \leq C_n^r k^r \left[\frac{(t_0 + 1)(rn)^{t_0} \log_k^{k^2} m}{C_n^r} + \exp\left(\frac{k^4}{\log_k m}\right) \right]. \quad (5.7)$$

Пользуясь формулой Стирлинга, нетрудно показать, что

$$C_n^r = \frac{n!}{(n-r)!r!} \approx \sqrt{\frac{n}{n-r}} \times \frac{n^n}{(n-r)^{n-r} r^r \sqrt{2\pi r}}, \quad n \rightarrow \infty.$$

Так как $\sqrt{n/n-r} \rightarrow 1$ при $m < k^{n^\beta}$, $\beta < 1$, $n \rightarrow \infty$, то

$$\frac{(t_0 + 1)(rn)^{t_0} \log_k^{k^2} m}{C_n^r} \leq \frac{(n-r)^{n-r} r^r \sqrt{2\pi r} (t_0 + 1)(rn)^{t_0} \log_k^{k^2} m}{n^n}, \quad n \rightarrow \infty. \quad (5.8)$$

Оценим

$$\begin{aligned} (n-r)^{n-r} n^{-n} &= n^{n-r} \left(1 - \frac{r}{n}\right)^{n-r} n^{-n} \leq \exp\left(-\frac{r(n-r)}{n}\right) n^{-r} = \\ &= \exp\left(-r + \frac{r^2}{n}\right) n^{-r} \approx \frac{1}{\exp(r)n^r} \text{ при } m \leq k^{n^\beta}, \quad \beta < 1/2, \quad n \rightarrow \infty. \end{aligned} \quad (5.9)$$

Из (5.7)–(5.9) следует

$$\sum_{t=0}^{\min(r, n-r)} a_t \leq C_n^r k^r [1 + \delta(n)], \quad \text{где } \delta(n) \rightarrow 0, \quad n \rightarrow \infty.$$

Таким образом,

$$\mathbf{M}\xi_r^2(L) \leq C_n^r k^r k^{-mn} (k^r - 2)^m C_n^r k^r [1 + \delta(n)].$$

Имеем

$$\begin{aligned} [\mathbf{M}\xi_r(L)]^2 &= (C_n^r k^r)^2 (k^r - 1)^{2m} \frac{1}{k^{2mr}} = (C_n^r k^r)^2 (k^{2r} - 2k^r + 1)^m \frac{1}{k^{2mr}} = \\ &= (C_n^r k^r)^2 k^{rm} \left(k^r - 2 + \frac{1}{k^r}\right)^m \frac{1}{k^{1mr}} \geq (C_n^r k^r)^2 (k^r - 2)^m \frac{1}{k^{1mr}} \geq (C_n^r k^r)^2 (k^r - 2)^m k^{-mr}. \end{aligned}$$

Утверждение леммы доказано.

Лемма 5. При $m < k^{n^\beta}$, $\beta < 1/2$, справедливо соотношение

$$D\eta_{r_1}/(M\eta_{r_1})^2 \rightarrow 0, \quad n \rightarrow \infty.$$

Доказательство. Имеем

$$\frac{D\eta_{r_1}}{(M\eta_{r_1})^2} = \frac{M\eta_{r_1}^2}{(M\eta_{r_1})^2} - 1 \leq \frac{M\xi_{r_1}^2}{(M\xi_{r_1})^2} - 1.$$

Лемма доказана.

Из лемм 1, 3–5 сразу следует утверждение теоремы 1.

Замечание. При доказательстве лемм 2 и 4 использована техника доказательств соответственно утверждения 5 и леммы 3 из работы [13], в которой рассматривалась задача оценки числа максимальных интервалов частичной булевой функции и получена асимптотика логарифма числа максимальных интервалов.

СПИСОК ЛИТЕРАТУРЫ

1. Дюкова Е.В. О сложности реализации некоторых процедур распознавания // Ж. вычисл. матем. и матем. физ. 1987. Т. 27. № 1. С. 114–127.
2. Дюкова Е.В. Алгоритмы распознавания типа “Кора”: сложность реализации и метрические свойства // Распознавание, классификация, прогноз (матем. методы и их применение). М.: Наука, 1989. Вып. 2. С. 99–125.
3. Вайнцивайг М.Н. Алгоритм обучения распознаванию образов “Кора” // Алгоритмы обучения распознаванию образов. М.: Сов. радио, 1973. С. 82–91.
4. Баскакова Л.В., Журавлёв Ю.И. Модель распознающих алгоритмов с представительными наборами и системами опорных множеств // Ж. вычисл. матем. и матем. физ. 1981. Т. 21. № 5. С. 1264–1275.
5. Дюкова Е.В., Инякин А.С. Задача таксономии и тупиковые покрытия целочисленной матрицы // Сообщ. по прикл. матем. М.: ВЦ РАН, 2001.
6. Дюкова Е.В., Журавлёв Ю.И. Дискретный анализ признаков описаний в задачах распознавания большой размерности // Ж. вычисл. матем. и матем. физ. 2000. Т. 40. № 8. С. 1264–1278.
7. Djukova E.V., Zhuravlev Yu.L. Diskrete methods of information analysis and algorithm synthesis // J. Pattern Recognition and Image Analys. 1997. V. 7. № 2. P. 192–207.
8. Яблонский С.В. Введение в дискретную математику // М.: Наука, 1986.
9. Дюкова Е. В. Асимптотически оптимальные тестовые алгоритмы в задачах распознавания // Пробл. кибернетики. Вып. 39. М.: Наука, 1982. С. 165–199.
10. Дюкова Е.В. Асимптотические оценки некоторых характеристик множества представительных наборов и задача об устойчивости // Ж. вычисл. матем. и матем. физ. 1995. Т. 35. № 1. С. 122–134.
11. Дюкова Е.В., Песков Н.В. Поиск информативных фрагментов описаний объектов в дискретных процедурах распознавания // Ж. вычисл. матем. и матем. физ. 2002. Т. 42. № 5. С. 741–753.
12. Носков В. Н., Слепан В. А. О числе тупиковых тестов для одного класса таблиц // Кибернетика. 1972. № 1. С. 60–65.
13. Сапоженко А.А. Оценка длины и числа тупиковых д. н. ф. для почти всех не всюду определенных булевых функций // Матем. заметки. 1980. Т. 28. № 2. С. 279–300.