

# ПРИМЕНЕНИЕ ПРИНЦИПОВ ЭКСПЕРТНОЙ КЛАССИФИКАЦИИ ДЛЯ АНАЛИЗА ФОРМАЛЬНЫХ ПОНЯТИЙ

**С.Ю. Соловьев,**

доктор физико-математических наук, профессор кафедры алгоритмических языков, факультет вычислительной математики и кибернетики Московского государственного университета им. М.В. Ломоносова

**Д.Е. Стельмашенко,**

инженер факультета вычислительной математики и кибернетики Московского государственного университета им. М.В. Ломоносова

*E-mail: soloviev@glossary.ru, dashanikolaeva@gmail.com*

*Адрес: г. Москва, ГСП-1, Ленинские горы, МГУ имени М.В. Ломоносова, 1, стр. 52*

*В статье рассматривается вариант задачи конструирования решетки формальных понятий и обсуждаются особенности алгоритма ее решения. Для повышения эффективности алгоритма предлагается использовать принципы экспертной классификации.*

**Ключевые слова:** анализ формальных понятий, метод экспертной классификации, принцип доминирования по характерности, шкала характерности.

## 1. Введение

В последнее время анализ формальных понятий (англ. Formal Concept Analysis; FCA) выступает своеобразным собирателем различных методов обработки неколичественных данных. В работе рассматривается вопрос о применении основных принципов экспертной классификации для одной задачи анализа формальных понятий. Систематическому изложению этих родственных направлений искусственного интеллекта посвящены монографии [1-4], здесь же приводится мини-

мально необходимый набор сведений из FCA (п. 2), а также адаптированные под конкретную задачу (п. 3) основы экспертной классификации (п. 4). Результатом такого «симбиоза» стали новые подходы к обработке формальных понятий (п. 5) и формулировки новых задач.

## 2. Некоторые определения FCA

Формальный контекст есть тройка множеств  $(G, M, I)$ , в которой элементы  $G$  называются объектами, элементы  $M$  – признаками, а  $I$  есть подмно-

жество из  $G \times M$ . Если  $(g, m) \in I$ , то говорят «объект  $g$  обладает признаком  $m$ » либо, что то же самое, «признак  $m$  встречается в описании объекта  $g$ ». При переходе от традиционных неколичественных моделей проблемных областей (первичных моделей) к формальным контекстам (вторичным моделям) каждый атрибут-свойство  $X$  с конечным числом значений  $X_1, \dots, X_n$  кодируется набором  $(0,1)$ -признаков  $m_{x1}, \dots, m_{xn}$  по принципу «одно значение атрибута – один признак контекста».

Формальный контекст  $K = (G, M, I)$  порождает так называемые формальные понятия. Пара непустых подмножеств  $(A, B)$ , где  $A \subseteq G$  и  $B \subseteq M$ , называется формальным понятием, если (1) каждый объект из  $A$  обладает всеми признаками из  $B$ , и (2) никакая другая пара  $(A \cup A', B \cup B')$  не удовлетворяет требованию (1). Пары множеств  $(\emptyset, M)$  и  $(G, \emptyset)$  являются формальными понятиями по определению. Если  $(A, B)$  – формальное понятие контекста  $K$ , то  $A$  называется объемом понятия,  $B$  – его содержанием. В дальнейшем изложении будем полагать, что множества  $G$  и  $M$  конечны, а все термины «контекст», «понятие» и «содержание» автоматически подразумевают спецификацию «формальный».

Множество  $C(K)$  всех понятий контекста  $K$  образует полную решетку, с отношением частичного порядка

$$(A_1, B_1) \prec (A_2, B_2) \Leftrightarrow B_1 \supseteq B_2.$$

Соответственно, решеткой также является множество  $S(K) = \{B | (A, B) \in C(K)\}$  с отношением частичного порядка  $\supseteq$ . Решетки  $C(K)$  и  $S(K)$  изоморфны; располагая одной из них, можно построить другую решетку. Рассмотрим подробнее те наборы признаков, которые не относятся к  $S(K)$  и образуют множество  $S^\circ(K) = 2^M \setminus S(K)$ .

Подмножество признаков  $H$  контекста  $K = (G, M, I)$  будем называть запретом, если  $H \neq M$  и в описаниях объектов признаки из  $H$  вместе никогда не встречаются:  $\forall g \in G \ \exists b \in H : (g, b) \notin I$ . Требование  $H \neq M$  объясняется лишь тем, что в сокращениях понятий – элементах множества  $S(K)$  – все признаки запретов встречаются исключительно в понятии  $(\emptyset, M)$ . Множество всех запретов контекста  $K$  обозначим  $P(K)$ . Кроме того, обозначим  $P^\circ(K)$  множество  $S^\circ(K) \setminus P(K)$ . Описанная классификация всевозможных наборов признаков представлена на *рис. 1*.

Эквивалентным представлением контекста  $K = (G, M, I)$  является объектно-признаковая таблица  $Tab(K)$ , в которой именами столбцов служат признаки из  $M$ , кодами строк – объекты из  $G$ , а на

$S(K)$	$P(K)$	$S^\circ(K) = P(K) \cup P^\circ(K)$
	$P^\circ(K)$	

Рис. 1. Строение множества  $2^M$  для контекста  $K$

пересечении строки  $g$  и столбца  $m$  стоит  $\square$ , если  $(g, m) \in I$ .

Общее определение контекста допускает наличие в нем объектов-дубликатов, которым в  $Tab(K)$  соответствуют строки, отличающиеся только кодами. Объекты-дубликаты не влияют на структуру решетки понятий, поэтому для многих приложений интерес представляют контексты без объектов-дубликатов, именуемые далее простыми контекстами. Не ограничивая общности, можно полагать, что в простом контексте  $(G, M, I)$  каждый объект  $g$  из  $G$  представляет собой подмножество признаков, а  $I = \varphi(G) \equiv \{(g, m) | g \in G, m \in g\}$ . При таком подходе для задания простого контекста достаточно перечислить описания его объектов.

### 3. Задача совмещения формальных контекстов

Очевидно, что любой нетривиальный контекст  $K$  способен порождать некоторые производные контексты посредством вычеркивания из  $Tab(K)$  отдельных строк-объектов и/или столбцов-признаков. На содержательном уровне задача совмещения контекстов состоит в конструировании решетки  $C(K)$  неизвестного контекста  $K$  по производным от него контекстам  $K_1 = (G_1, M_1, I_1)$  и  $K_2 = (G_2, M_2, I_2)$ . Известные подходы к решению задачи совмещения различаются дополнительными предположениями и целевыми установками.

Для контекстов общего вида в случае  $G_1 = G_2 = G$ ,  $M_1 \cup M_2 = M$  и  $M_1 \cap M_2 = \emptyset$  задача совмещения контекстов часто решается посредством так называемой «Nested Line» диаграммы [1]. Построение «Nested Line» диаграммы предполагает подстановку диаграммы Хассе решетки  $C(K_1)$  в каждый узел соответствующей диаграммы решетки  $C(K_2)$ . Считается, что построенная таким образом диаграмма более наглядна, чем диаграмма Хассе решетки  $C(K)$ .

Для контекстов общего вида в случае  $G_1 \cup G_2 = G$  и  $M_1 \cup M_2 = M$  искумую решетку  $C(K)$  предлагается [5] строить по контексту  $K = (G_1 \cup G_2, M_1 \cup M_2, I_1 \cup I_2)$ . Метод используется для пополнения баз знаний. Модификация метода [6] позволяет выявить в

объединенном множестве признаков дубликаты и модифицировать отношение  $I_1 \cup I_2$ .

Упомянутые подходы к решению задачи совмещения не претендуют на точное построение решетки  $C(K)$ . Иначе устроен метод @FC [7,8], о котором речь пойдет далее. Название метода происходит от первых букв ключевых слов его описания: Alternative design, Testing, Formal context, Concept. Метод @FC использует специальную терминологию простых контекстов.

Если  $K = (G, M, \varphi(G))$  – простой контекст, заданный множеством своих объектов  $G$  (глобальный контекст), то проекцию  $G$  на фиксированное подмножество признаков  $M_T$  будем называть локальным контекстом. Формально, локальный контекст  $K_T$  есть

$$(G_T, M_T, \varphi(G_T)), \text{ где } G_T = \{g \cap M_T \mid g \in G\}.$$

На практике получение  $K_T$  может быть связано, например, со снаряжением целой экспедиции к местам обитания изучаемых объектов  $G$ , причем исследовательские возможности экспедиции ограничены набором признаков  $M_T$ .

Для глобального контекста  $K$  и пары локальных контекстов  $K_1, K_2$  в случае  $M_1 \cup M_2 = M$  метод @FC предлагает строить множество  $S(K)$  в виде

$$V = \{B_1 \cup B_2 \mid B_1 \in S(K_1), B_2 \in S(K_2)\}$$

с последующей пошаговой классификацией элементов  $V$  на элементы  $S(K)$  и  $S^\circ(K)$ . Доказано, что метод @FC позволяет построить множество  $S(K)$  за конечное число шагов. На каждом шаге построения принимается решение о запросе нового локального контекста, и по итогам его специальной обработки для некоторых элементов  $V$  принимаются классификационные решения. Процесс формирования  $S(K)$  заканчивается, когда классификационные решения приняты для всех элементов множества  $V$ .

Запрос нового локального контекста в виде множества его признаков  $M_T$  формируется автоматически или в диалоге с пользователем. При этом варианты запросов известны заранее, и необходимо «лишь» выбрать лучший из них.

В части обработки локальных контекстов  $K_T$  метод @FC использует правила классификации, которые иногда позволяют относить элементы  $V$  к классам  $S(K)$  или  $S^\circ(K)$ . Приведем в качестве примера два классификационных правила:

(K1) Если  $v \in S(K_T)$  и  $\{v' \mid v \cup v' \in V\} = \{\emptyset\}$ , то  $v \in S(K)$ .

(K2) Если  $v \in P(K_T)$  и  $v \cup v' \in V$  для некоторого  $v'$ , то  $v \cup v' \in P(K)$ .

С одной стороны, классификационные правила представляют собой строго доказанные утверждения [8], а с другой стороны – их можно использовать в качестве условных операторов алгоритма реализации метода @FC. Обработка очередного локального контекста заканчивается, когда все правила классификации оказываются неприменимыми.

При высокой стоимости локальных контекстов возникает потребность в технологиях их «глубокой переработки», позволяющих на каждом шаге классифицировать как можно больше элементов  $V$ . Аналогичная потребность исследовалась в 1980-х научным коллективом под руководством О.И. Ларичева. Результатом этой работы стал метод экспертной классификации, позволяющий при неизначительных дополнительных, но проверяемых предположениях существенно увеличить количество классификационных решений в задаче совмещения формальных контекстов.

#### 4. Принципы экспертной классификации

В терминах FCA главная идея метода экспертной классификации состоит в обоснованном переносе классификационных решений, полученных для одного объекта, на некоторые другие объекты. Базой знаний для обоснования и переноса служит отношение доминирования, которое, в свою очередь, строится из отношений характерности. Считается, что контекст  $K = (G, M, I)$  представляет собой вторичную модель проблемной области, а в первичной модели используются атрибуты-свойства, принимающие конечное число значений. При этом контекст  $K$  наследует от первичной модели разбиение множества признаков  $M = M_1 \cup M_2 \cup \dots \cup M_k$ , в котором каждое подмножество  $M_i$  соответствует ровно одному атрибуту.

Теоретическую основу метода экспертной классификации составляет гипотеза, согласно которой «признаки каждого множества  $M_i$  различаются по степени характерности для объектов  $G$ ». Если для конкретной проблемной области гипотеза справедлива, то эксперт способен построить на элементах множества  $M_i$  асимметричное, антирефлексивное и транзитивное отношение характерности  $\prec$ ; запись « $m_{i1} \prec m_{i2}$ » означает, что признак  $m_{i1}$  менее характерен для объектов  $G$ , чем признак  $m_{i2}$ . Экспериментально установлено, что фраза «быть характерным

для объектов  $G$  и фразы, производные от нее, понятны эксперту без разъяснений, и он почти всегда способен построить  $k$  штук отношений характерности – по одному для каждого множества  $M_i$ .

Строго говоря, в оригинальном описании экспертной классификации предполагается линейность всех отношений характерности. Это обстоятельство существенно для представления данных и для организации диалога с экспертом при извлечении знаний об отношениях характерности. В настоящей работе вместо линейного порядка предполагается наличие частичного порядка. Соответственно, изменяется процедура опроса эксперта, в основу которой полагается сравнение на характерность в различных парах признаков из  $M_i$ .

Совокупность отношений характерности  $\leq_1, \dots, \leq_k$  порождает рефлексивное, антисимметричное и транзитивное отношение доминирования  $\leq$  на всевозможных подмножествах признаков из  $M$ . По определению, пара подмножеств  $b_1$  и  $b_2$  связана отношением  $b_1 \leq b_2$ , если для любого  $i = 1, \dots, k$  выполняется одно из двух: либо  $b_1 \cap M_i = b_2 \cap M_i$ , либо  $b_1 \cap M_i = \{m_{i1}\}$ ,  $b_2 \cap M_i = \{m_{i2}\}$  и  $m_{i1} < m_{i2}$ .

Если отношение доминирования удается построить, то механизм переноса классификационных решений применительно к объектам контекста – элементам множества  $G$  – описывается двумя постулированными, но вполне разумными правилами:

- (П1) Если  $g_1 \in G, g_1 \in 2^M$  и  $g_1 \leq g$ , то  $g \in G$ ;
- (П2) Если  $g_1 \neq G, g_1 \in 2^M$  и  $g \leq g_1$ , то  $g \neq G$ .

## 5. Метод доминирования для формальных контекстов

Метод @FC, в отличие от оригинальной версии экспертной классификации, оперирует не только описаниями объектов, но и другими подмножествами признаков. В связи с этим возникает необходимость корректного обобщения правил П1 и П2 на случай подмножеств из  $V$ , и главная роль в таком обобщении отводится формальной интерпретации

отношения характерности.

Простейшая, хотя и не единственная теоретико-множественная интерпретация отношений  $\leq_i$  имеет вид:

$$m_{i1} \leq_i m_{i2} \Leftrightarrow \{g \in G \mid m_{i1} \in g\} \subseteq \{g \in G \mid m_{i2} \in g\}.$$

Доказано, что при таком подходе к отношениям характерности правила П1 и П2 превращаются в формальные утверждения, а кроме того, справедливы также утверждения

- (П3) Если  $v_1 \in S(K), v \in V$  и  $v_1 \leq v$ , то  $v \in S(K)$ ;
- (П4) Если  $v_1 \in S^\circ(K), v \in V$  и  $v \leq v_1$ , то  $v \in S^\circ(K)$ ;
- (П5) Если  $v_1 \in P(K), v \in V$  и  $v \leq v_1$ , то  $v \in P(K)$ ;
- (П6) Если  $v_1 \in P^\circ(K), v \in V$  и  $v \leq v_1$ , то  $v \in P^\circ(K)$ .

В доказательствах утверждений П3–П6 существенно используются свойства объектов глобального контекста, однако в окончательных формулировках объекты не фигурируют, что позволяет использовать утверждения П3–П6 в качестве дополнительных правил распространения классификационных решений метода @FC.

## 6. Заключение

Представленная модификация метода совмещения @FC применима для глобальных контекстов, удовлетворяющих гипотезе доминирования в ее простейшей интерпретации. Проверка гипотезы по решетке содержаний  $S(K)$  представляет собой самостоятельную теоретическую задачу, способную в перспективе породить новую версию алгоритма совмещения локальных контекстов. Кроме того, один из принципов экспертной классификации состоит в обязательном исследовании наборов признаков на границах классов. Адаптация этого принципа для задач FCA также представляется весьма перспективной.

Предложенный и намеченные алгоритмы могут использоваться при решении практических задач бизнес-информатики, сводимых к обработке формальных понятий. ■

## Литература

1. Ganter B., Wille R. Formal Concept Analysis: Mathematical Foundations. – Springer, 1999.
2. Гуров С.И. Булевы алгебры, упорядоченные множества, решетки: Определения, свойства, примеры. – М.: ЛИБРОКОМ, 2013.
3. Ларичев О.И. Теория и методы принятия решений, а также Хроника событий в Волшебных Странах. – М.: Логос, 2000.

4. Ларичев О.И., Мечитов А.И., Мошкович Е.М., Фуремс Е.М. Выявление экспертных знаний. — М.: Наука, 1989.
5. Li G.Y., Liu S.P., Zhao Y. Formal Concept Analysis based Ontology Merging Method // Proceeding of 3rd IEEE International Conference on Computer Science and Information Technology. — 2010 — volume 8 — P. 279-282.
6. Bendaoud R., Napoli A., Toussaint Y. A proposal for an Interactive Ontology Design Process based on Formal Concept Analysis// Frontiers in Artificial Intelligence and Applications. — 2008 — volume 183: Formal Ontology in Information Systems — P. 311-323.
7. Стельмащенко Д.Е. Алгоритм восстановления глобального контекста // Сборник статей молодых научных факультета ВМК МГУ. — 2012 — выпуск 9 — С.191-209.
8. Соловьев С.Ю., Стельмащенко Д.Е. Подходы к исследованию формальных контекстов // Информационные процессы. — 2011 — том 11 — № 2 — С. 277-290.

