

С.Ю. Соловьев, Д.Е. Стельмашенко

Метод экспертной классификации как инструмент анализа формальных понятий

Аннотация: в статье рассматривается вариант задачи конструирования решетки формальных понятий и обсуждаются особенности алгоритма ее решения. Для повышения эффективности алгоритма предлагается использовать метод экспертной классификации.

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

Введение

Анализ формальных понятий (англ. Formal Concept Analysis; FCA) – отрасль интеллектуального анализа данных, в которой предполагается переход к понятийным структурам проблемных областей. Методология конструирования понятий из неколичественных данных составляет предмет и главную задачу FCA. В работе рассматривается разновидность главной задачи FCA, решение которой сводится к последовательности, вообще говоря, дорогостоящих итераций. На каждой итерации обрабатывается предварительно построенное множество кандидатов в понятия, и для некоторых из них принимаются положительные или отрицательные классификационные решения; процесс завершается, когда классификационные решения приняты для всех кандидатов. В интересах сокращения числа итераций в работе предлагается использовать метод экспертной классификации, позволяющий переносить классификационные решения, принятые для одних кандидатов на подмножества других кандидатов.

Систематическому изложению FCA и экспертной классификации посвящены монографии [1-4], здесь же приводится минимально необходимый набор сведений из FCA (п. 1), а также адаптированные под конкретную задачу (п. 2) основы экспертной классификации (п. 3). Результатом совмещения двух родственных методов стали новые подходы к обработке формальных понятий (п. 4) и постановки новых задач.

1. Некоторые определения FCA

FCA исходит из весьма общей модели данных, именуемой формальным контекстом. По определению, формальный контекст есть тройка множеств (G, M, I) , в которой элементы G называются объектами, элементы M – признаками, а I есть подмножество пар из $G \times M$. Если $(g, m) \in I$, то говорят “объект g обладает признаком m ” либо, что тоже самое, “признак m встречается в описании объекта g ”.

Для конечных множеств G и M – а в дальнейшем изложении рассматривается именно такой случай – 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 пересечении строки g и столбца m стоит $\boxed{\times}$, если $(g, m) \in I$.

Формальный контекст $K = (G, M, I)$ порождает формальные понятия. Пара непустых подмножеств (A, B) , где $A \subseteq G$ и $B \subseteq M$, называется формальным понятием, если (а) каждый объект из A обладает всеми признаками из B , и (б) никакая другая пара $(A \cup A', B \cup B')$ не удовлетворяет требованию (а). Кроме того, пары множеств (\emptyset, M) и (G, \emptyset) являются формальными понятиями по определению. Если (A, B) – формальное понятие, то A называется объемом понятия, B – его содержанием. Далее используются только формальные понятия и формальные контексты, а потому указания на их формальные статусы опускаются.

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

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

Решеткой также является множество содержаний $S(K) = \{ B \mid (A, B) \in C(K) \}$ с отношением частичного порядка \supseteq . Решетки $C(K)$ и $S(K)$ изоморфны, однако решетка $S(K)$ более удобна, так как охватывает все понятия контекста, но не зависит от наличия в контексте объектов-дубликатов, которым в $Tab(K)$ соответствуют строки, отличающиеся только кодами.

Контексты без объектов-дубликатов будем называть простыми контекстами. Не ограничивая общности, можно полагать, что в простом контексте (G, M, I) каждый объект g из G однозначно описывается подмножеством признаков¹, а $I = \varphi(G) \equiv \{ (g, m) \mid g \in G, m \in g \}$. При таком подходе для задания простого контекста достаточно перечислить описания его объектов.

Независимо от особенностей того или иного контекста $K = (G, M, I)$ для $S(K)$ всегда можно указать некоторое объемлющее его подмножество $U(K)$ элементов из 2^M . В простейшем случае $U(K) = 2^M$. $S(K) \subseteq U(K) \subseteq 2^M$. Ценность множества $U(K)$ состоит в том, что его элементы являются кандидатами в содержания формальных понятий. Кандидаты, не относящиеся к $S(K)$, образуют множество $S^\circ(K) = U(K) \setminus S(K)$. В свою очередь, элементы $S^\circ(K)$ подразделяются на запреты и все прочие.

Для контекста $K = (G, M, I)$ собственное подмножество признаков H , $H \subset M$, будем называть запретом, если в описаниях объектов признаки из H вместе никогда не встречаются:

¹ то есть $g \subseteq M$

$\forall g \in G \exists b \in H : (g, b) \notin I$. Множество всех запретов контекста K обозначим $P(K)$. Кроме того, обозначим $P^\circ(K)$ множество $S^\circ(K) \setminus P(K)$. Таким образом, для произвольного кандидата A из $U(K)$ возможны следующие классификационные решения:

- либо $A \in S(K)$,
- либо $A \in S^\circ(K)$ и дополнительно: либо $A \in P(K)$,
либо $A \in P^\circ(K)$.

Наличие дополнительной классификации элементов $S^\circ(K)$ позволяет более тонко анализировать кандидатов в содержания.

2. Задача совмещения формальных контекстов

Любой нетривиальный контекст K способен порождать некоторые производные контексты методом вычеркивания из $Tab(K)$ отдельных строк-объектов и/или столбцов-признаков. Прямая задача построения контекстов, производных от заданного, затруднений не вызывает. Иначе обстоит дело с обратной задачей, которая (в несколько ослабленной формулировке) состоит в построении решетки $S(K)$ неизвестного контекста K по заданным контекстам K_1 и K_2 , производным от K . При всех различиях в дополнительных предположениях и целевых установках многие известные подходы [1, 5, 6] к решению задачи совмещения не претендуют на точное построение решетки $S(K)$. Для случая простых контекстов строгое, хотя и трудоемкое решение задачи совмещения обеспечивает метод @FC [7,8]. Представим этот метод.

Назовем глобальным контекстом неизвестный простой контекст $K = (G, M, \varphi(G))$. Заданную проекцию множества G на фиксированное подмножество признаков M_T назовем локальным контекстом. Формально, локальный контекст K_T есть производный контекст вида

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

На практике получение K_T может быть связано, например, со снаряжением дорогостоящей экспедиции к местам обитания изучаемых объектов G , причем исследовательские возможности экспедиции позволяют установить для этих объектов признаки из относительно ограниченного множества M_T .

Для глобального контекста K и пары локальных контекстов $K_1 = (G_1, M_1, I_1)$ и $K_2 = (G_2, M_2, I_2)$ в случае $M_1 \cup M_2 = M$ метод @FC предлагает сначала построить множество кандидатов²

$$V = \{ B_1 \cup B_2 \mid B_1 \in S(K_1), B_2 \in S(K_2) \}, \quad (1)$$

² кандидатов в содержания понятий глобального контекста K

а затем пошагово выделить из V элементы $S(K)$. На каждом шаге построения принимается решение о запросе нового локального контекста³, и по итогам его специальной обработки для некоторых кандидатов принимаются классификационные решения. Процесс формирования $S(K)$ заканчивается, когда классификационные решения приняты для всех кандидатов. Доказано, что $S(K) \subseteq V$, и метод @FC позволяет построить множество $S(K)$ за конечное число шагов. Запрос нового локального контекста, оформленный в виде множества его признаков M_T , формируется автоматически или в диалоге с пользователем. При этом возможные варианты запросов рассчитываются заранее, и задача сводится к выбору лучшего варианта.

В части обработки локальных контекстов K_T метод @FC использует классификационные правила, которые позволяют относить некоторые элементы v множества V к классам $S(K)$ или $S^\circ(K)$. Типичные классификационные правила выглядят так:

(K1) Если $v \in P(K_T)$, и $v \cup v' \in V$ для некоторого v' , то $v \cup v' \in P(K)$.

(K2) Если $v \in P^\circ(K_T)$, то $v \in P^\circ(K)$.

(K3) Если $v \in P^\circ(K_T)$, и $v \cup v' \in V$ для некоторого v' из $M \setminus M_T$, то $v \cup v' \in S^\circ(K)$.

(K4) Если $v \in P^\circ(K_T)$, $\{v' \mid v \cup v' \in V\} = \{\emptyset, v'\}$, и $v' \neq \emptyset$, то $v \cup v' \in S(K)$.

(K5) Если $v \in S(K_T)$ и $\{v' \mid v \cup v' \in V\} = \{\emptyset\}$, то $v \in S(K)$.

С одной стороны, классификационные правила представляют собой строго доказанные достаточные условия [8], а с другой стороны – они вполне пригодны для использования в программах. Обработка очередного локального контекста заканчивается, когда все классификационные правила оказываются неприменимыми.

При высокой стоимости локальных контекстов возникает потребность в технологиях, позволяющих при их обработке классифицировать как можно больше кандидатов в содержания из V . Аналогичная потребность исследовалась в 1980-х научным коллективом под руководством О.И.Ларичева. Результатом этой работы стал метод экспертной классификации, позволяющий при незначительных дополнительных, но контролируемых предположениях существенно увеличить количество классификационных решений.

3. Основы экспертной классификации в терминах FCA

Метод экспертной классификации позволяет в диалоге с экспертом построить неизвестное множество объектов G^E некоторого целевого простого контекста $(G^E, M, \varphi(G^E))$. При этом множество признаков M , задействованных в описаниях объектов, считается (а) известным, (б) состоящим из k непересекающихся подмножеств M_1^E, \dots, M_k^E и (с) порождающим универсум

³ то есть решение о снаряжении новой экспедиции

$$U_k^E = M_1^E \times \dots \times M_k^E \quad (2)$$

такой, что $G^E \subseteq U_k^E$. Собственно говоря, на эксперта возлагается обязанность последовательно относить предъявляемые ему элементы универсума либо к G^E , либо к $U_k^E \setminus G^E$.

В интересах скорейшего построения множества объектов метод экспертной классификации постулирует гипотезу, согласно которой элементы каждого множества M_i^E различаются по степени характерности для объектов G^E . Принимая эту гипотезу, эксперт способен заранее построить на элементах множества M_i^E асимметричное, антирефлексивное и транзитивное отношение характерности $<_i$; запись “ $m_{i1} <_i m_{i2}$ ” означает, что признак m_{i1} менее характерен для объектов G^E , чем признак m_{i2} . Экспериментально установлено, что фраза “быть характерным для объектов G^E ” понятна эксперту без разъяснений, и он вполне способен построить k штук отношений характерности – по одному для каждого множества M_i^E .

Заметим, что в оригинальном описании экспертной классификации предполагается линейность всех отношений характерности. В настоящей работе вместо линейного порядка предполагается наличие частичного порядка, что сказывается на методе хранения данных и на организации диалога с экспертом при извлечении знаний об отношениях характерности.

Совокупность построенных экспертом отношений характерности $<_1, \dots, <_k$ порождает рефлексивное, антисимметричное и транзитивное отношение доминирования \leq на всевозможных элементах универсума U_k^E . По определению, пара подмножеств u_1 и u_2 связана отношением $u_1 \leq u_2$, если для любого $i = 1, \dots, k$ выполняется одно из двух: либо $m_{i1} = m_{i2}$, либо $m_{i1} <_i m_{i2}$, где $u_1 \cap M_i^E = \{m_{i1}\}$, $u_2 \cap M_i^E = \{m_{i2}\}$.

Если отношение доминирования удастся построить, то механизм переноса классификационных решений, полученных для некоторого объекта g из U_k^E , описывается двумя вполне разумными правилами:

(П1) Если $g \in G^E$, и $g \leq u$, то $u \in G^E$;

(П2) Если $g \in U_k^E \setminus G^E$, и $u \leq g$, то $u \in U_k^E \setminus G^E$.

4. Экспертная классификация и задача совмещения контекстов

Метод @FC решения задачи совмещения простых контекстов оперирует локальными контекстами $K_1 = (G_1, M_1, I_1)$ и $K_2 = (G_2, M_2, I_2)$ в интересах построения решетки $S(K)$ неизвестного глобального контекста K . Дополнительно потребуем

$$M_1 \cap M_2 = \emptyset \quad (3)$$

и положим $M_1^E = S(K_1)$ и $M_2^E = S(K_2)$.

Между множеством кандидатов в содержания V и формально построенным универсумом $U_2^E = M_1^E \times M_2^E$ (см. формулы (1) и (2) при $k=2$) существует взаимно однозначное соответствие

$$\Psi(v) = (v \cap M_1, v \cap M_2).$$

С учетом требования (3) отображение Ψ представляет собой утверждение о возможности однозначной раскраски всех кандидатов из V двумя цветами: признаки из M_1 окрашиваются, скажем, красным цветом, а признаки M_2 – зеленым.

При таком подходе отношение доминирования \leq , построенное для целевого простого контекста $(S^E, M_1^E \cup M_2^E, \varphi(S^E))$, где $S^E = \Psi(S(K))$, оказывается весьма полезным для решения задачи совмещения. Сконструированное экспертом/экспертами на универсуме U_2^E отношение \leq естественным образом порождает отношение доминирования \leq на множестве V , а также модификации правил П1 и П2:

$$v_1 \leq v_2 \Leftrightarrow \Psi(v_1) \leq \Psi(v_2),$$

(П1м) Если $v' \in S(K)$, и $v' \leq v$, то $v \in S(K)$;

(П2м) Если $v \in S^\circ(K)$, и $v' \leq v$, то $v' \in S^\circ(K)$.

Вновь полученные классификационные правила П1м и П2м расширяют области действий правил типа К1 – К5. Так, в случае исполнения правила К3 все кандидаты из $\{x \mid x \leq v \cup v'\}$ зачисляются в $S^\circ(K)$. Аналогично, в случае срабатывания правила К5 все кандидаты из $\{x \mid v \leq x\}$ зачисляются в $S(K)$.

Замечание 1. Успех описанного подхода к усовершенствованию метода @FC за счет привлечения правил П1м и П2м находится в прямой зависимости от количества экземпляров отношений характерности $<_1$ и $<_2$, выявленных экспертом на множествах $S(K_1)$ и $S(K_2)$.

Замечание 2. Задача построения отношения характерности $<_1$, определенного на $S(K_1)$, осложняется большим⁴ количеством элементов в $S(K_1)$, а также сложно устроенными описаниями этих элементов. В связи с этим наиболее перспективным “лобовым” подходом к построению отношений характерности является метод балльных оценок, выставляемых элементам $S(K_1)$.

Замечание 3. Если множество признаков M_1 допускает разбиение $M_1^1 \cup \dots \cup M_1^m$ на подклассы значений некоторых однозначных атрибутов, то отношение характерности $<_1$, определенное на $S(K_1)$, можно сконструировать из отношения доминирования \leq_1 ,

⁴ нетипично большим для традиционных задач экспертной классификации

определенного на $M_1^1 \times \dots \times M_1^m$, путем удаления из \leq_1 всех пар вида $u \leq_1 u$. Замечания 2 и 3 в равной степени относятся к отношению $<_2$, определенному на $S(K_2)$.

Замечание 4. В ходе решения задачи совмещения контекстов помимо первоначально построенного отношения доминирования \leq , полученного при посредничестве универсума U_2^E , могут появиться и другие пригодные для использования отношения доминирования. Организация непротиворечивого сосуществования двух и более отношений доминирования составляет предмет самостоятельной задачи.

Заключение

По большому счету, отношение доминирования, построенное методом экспертной классификации, является эвристикой, сокращающей перебор кандидатов в содержания понятий. В связи с этим возникает необходимость хранить для каждого принятого классификационного решения историю его вывода с тем, чтобы иметь возможность отказаться от неподтвердившихся решений. По завершении итерационного процесса истории выводов позволяют вывести итоговую оценку достоверности построенного множества содержаний.

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. Guan-yu L., Shu-peng L., Yan Z. Formal Concept Analysis based Ontology Merging Method // Proceeding of 3rd IEEE International Conference on Computer Science and Information Technology. Vol. 8, 2010. 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., Vol. 183, Formal Ontology in Information Systems, 2008. P. 311-323.
7. Стельмашенко Д.Е. Алгоритм восстановления глобального контекста // Сборник статей молодых ученых факультета ВМК МГУ. Вып. 9, 2012. С.191-209.
8. Соловьев С.Ю., Стельмашенко Д.Е. Подходы к исследованию формальных контекстов // Информационные процессы. Том 11, № 2, 2011. С. 277-290.