

УДК 004.89

Н.Г. Аксак, С.А. Коргут

Харьковский национальный университет радиоэлектроники, Харьков

МОДЕЛЬ КАТЕГОРИЗАЦИИ ИНТЕРНЕТ-ПОЛЬЗОВАТЕЛЕЙ НА ОСНОВЕ ДСМ-МЕТОДА

Рассмотрен подход к построению адаптивной информационно-поисковой системы при помощи категоризации пользователей. Разработана модель категоризации интернет-пользователей на основе метода автоматического порождения гипотез Джона-Стюарта-Милля (ДСМ-метод). Определены основные источники знаний о пользователе информационной системы. Рассмотрен пример отнесения пользователя к категориям при помощи предложенной модели.

Ключевые слова: категоризация, интернет-пользователь, ДСМ-метод.

Введение

Актуальность. На современных интернет-ресурсах наряду с общей информацией представлена и узко специализированная, необходимая только определенной категории посетителей сайта. Возникают сложности поиска актуальной информации на ресурсе, которые усложняются также большими объемами и разнородностью данных, содержащихся на веб-сайтах. Одним из вариантов решения данной проблемы предлагается категоризация интернет-пользователя, т.е. отнесение пользователя к той или иной категории и предоставление ему информации, связанной с ней. Под категорией будем понимать виртуальное множество пользователей, обладающих схожими свойствами. Категории формируются в зависимости от тематики ресурса, для посетителей которого проводится категоризация.

Например, одна из категорий состоит из множества пользователей одного пола, другая – из одной возрастной группы; для медицинского веб-ресурса целесообразно разделение пользователей на три категории: врачи, пациенты клиники и посетители, которые не относятся к первым двум категориям. Категоризация позволит получать данные с учетом информационных интересов, что в свою очередь повысит качество поиска информации в сети Интернет. Таким образом, актуальной является разработка модели, позволяющей строить гипотезы о принадлежности интернет-пользователя к определенной категории.

Постановка задачи. Дано: информация, передаваемая браузером посетителя интернет-ресурса (доступные данные о пользователе).

Требуется: разработать модель категоризации интернет-пользователей, вырабатывающую гипотезы о принадлежности пользователя к категории.

Решение задачи

Модель категоризации интернет-пользователей представим в виде:

$$D: I \rightarrow Y, \quad (1)$$

где D – отображающая функция, основанная на ДСМ-методе.

ДСМ-метод представим в виде структуры $J = \langle C, O, P, V, F, H \rangle$, где:

- C – непустое конечное множество доступных данных о пользователе;
 - $O = \subseteq \alpha(A)$ – непустое конечное множество пользователей, представленных в виде ИПП;
 - P – непустое конечное множество свойств пользователя;
 - $V = \{+1, -1, 0, \tau\}$ – множество внутренних истинностных значений (+1 – эмпирически истинно, -1 – эмпирически ложно, 0 – эмпирически противоречиво, τ – неопределенно);
 - $F: O \times P \rightarrow V$, отображение F будем называть функцией наличия свойства;
 - $H: \alpha(A) \times P \rightarrow V$, отображение H будем называть функцией причины свойства;
- I – область определения функции D , множество данных о пользователе $I\{i_1, i_2, i_3, i_4\}$, где
- i_1 – данные о браузере;
 - i_2 – данные об операционной системе;
 - i_3 – данные о мониторе;
 - i_4 – данные о сетевом соединении;
- Y – область значения функции D , множество категорий $Y\{y_1, y_2, y_3, y_4\}$.

ДСМ-метод автоматического порождения гипотез – это один из методов интеллектуального анализа данных, позволяющий с помощью анализа имеющейся базы фактов сделать предположения о причинах наличия или отсутствия определенных свойств у объектов предметной области. ДСМ-метод оперирует сущностями трёх сортов: объекты предметной области, свойства этих объектов, возможные причины свойств. Предполагается, что объекты имеют структуру и причинами свойств объектов являются фрагменты этой структуры.

На вход ДСМ-метод получает некоторое множество изучаемых объектов $O = \{O_1, O_2, \dots, O_n\}$ (информационный портрет пользователя – ИПП) и сведения об их структуре (параметры ИПП), о наличии или отсутствии у них определенных свойств (социальный статус, пол, возраст), а также, в некоторых случаях, о связи между структурой объектов и их свойств (социальный статус определяется типом процессора, разрешением монитора, скоростью соединения). Кроме того, имеется ряд целевых признаков (социальный статус «высокий»), каждый из которых разбивает исходное множество объектов на четыре непересекающихся подмножества

$$O = O_1 \cup O_2 \cup O_3 \cup O_4 :$$

- объекты O_1 , про которые известно, что они обладают данным признаком (другими словами, пользователи, уровень социального статуса которых известен);
- объекты O_2 , про которые известно, что они не обладают данным признаком;
- объекты O_3 , для которых существуют аргументы как за, так и против того, что они обладают данным признаком;
- объекты O_4 , о которых неизвестно, обладают они этим признаком или нет.

Результатом применения ДСМ-метода являются гипотезы двух типов:

- гипотезы о связи определенных структурных фрагментов (данных ИПП и их комбинаций) изучаемых объектов (ИПП) со свойствами, которыми они обладают;
- гипотезы о наличии или отсутствии целевых признаков у объектов, для которых изначально это было неизвестно, формируемые на основании установленной взаимосвязи между свойствами объектов и их структурными компонентами.

Таким образом, сущностями модели категоризации интернет-пользователей являются:

- O – множество ИПП;
- P – множество свойств объектов (3 уровня социального статуса);
- C – множество возможных причин свойств объектов (операционная система, разрешение монитора, скорость соединения);
- V – множество оценок.

Введём функцию $F: O \times P \rightarrow V$, представляющую начальную ситуацию.

- $F(o, p) = +1$ – известно, что объект o обладает свойством p ;
- $F(o, p) = -1$ – известно, что объект o не обладает свойством p ;
- $F(o, p) = 0$ – есть аргументы как за, так и против того, что объект o обладает свойством p ;

- $F(o, p) = \tau$ – неизвестно, обладает ли объект o свойством p .

Использование ДСМ-метода позволяет определить, например, какими значениями параметров ИПП должен обладать пользователь, чтобы можно было сделать предположение о социальном статусе «низкий», «средний», «высокий».

Множество объектов:

- o_1 – ИПП 1;
- o_2 – ИПП 2;
- ...
- o_{10} – ИПП 10.

Таблица 1

Исходные данные для ДСМ-метода

	O_1	O_2	O_3	O_4	O_5	O_6	O_7	O_8	O_9	O_{10}
p_1	+	+	+	-	-	-	-	-	-	τ
p_2	-	-	-	+	+	+	-	-	-	τ
p_3	-	-	-	-	-	-	+	+	+	τ
c_1	-	+	-	+	-	-	-	-	+	+
c_2	+	-	+	-	+	-	-	-	-	-
c_3	-	-	-	-	-	+	+	+	-	-
c_4	+	+	-	-	-	-	-	-	-	-
c_5	-	-	+	-	-	+	+	-	-	-
c_6	-	-	-	+	+	-	-	+	+	+
c_7	+	-	+	-	-	+	-	-	-	-
c_8	-	+	-	-	+	-	-	-	-	-
c_9	-	-	-	+	-	-	+	-	-	+
c_{10}	-	-	-	-	-	-	-	+	+	-

Для этих объектов выберем следующий набор структурных фрагментов C :

- c_1 – ОС Windows Vista;
- c_2 – ОС Windows XP;
- c_3 – ОС Unix;
- c_4 – разрешение 800×600 и меньше;
- c_5 – разрешение 1024×768;
- c_6 – разрешение 1200×800 и больше;
- c_7 – скорость соединения меньше 56 kbit/s;
- c_8 – скорость соединения от 56 kbit/s до 256 kbit/s;
- c_9 – скорость соединения от 256 kbit/s до 512 kbit/s;
- c_{10} – скорость соединения выше 512 kbit/s.

Множество целевых признаков:

- p_1 – соц. статус «низкий»;
- p_2 – соц. статус «средний»;
- p_3 – соц. статус «высокий».

Представим каждый из объектов набором структурных компонентов, которыми этот объект обладает:

- O_1 { c_2, c_4, c_7 };
- O_2 { c_1, c_4, c_8 };
- O_3 { c_2, c_5, c_7 };
- O_4 { c_1, c_6, c_9 };
- O_5 { c_2, c_6, c_8 };

- $o_6 \{c_3, c_5, c_7\}$;
- $o_7 \{c_3, c_5, c_9\}$;
- $o_8 \{c_3, c_6, c_{10}\}$;
- $o_9 \{c_1, c_6, c_{10}\}$;
- $o_{10} \{c_1, c_6, c_9\}$.

В данном случае положительными примерами для целевого свойства p_1 является объект o_1, o_2, o_3 , отрицательными – $o_4, o_5, o_6, o_7, o_8, o_9$, и один (τ)-пример – o_{10} :

p_1 : (+) o_1, o_2, o_3 ; (-) $o_4, o_5, o_6, o_7, o_8, o_9$; (τ) o_{10} ;

p_2 : (+) o_4, o_5, o_6 ; (-) $o_1, o_2, o_3, o_7, o_8, o_9$; (τ) o_{10} ;

p_3 : (+) o_7, o_8, o_9 ; (-) $o_4, o_5, o_6, o_7, o_8, o_9$; (τ) o_{10} .

Задача состоит в том, чтобы, используя правдоподобные рассуждения, выяснить, обладают ли (τ)-примеры целевым свойством p_1, p_2, p_3 .

Применение правил первого рода. В качестве возможных причин одного из свойства p_1, p_2, p_3 у объектов рассмотрим некоторые непустые подмножества множества структурных фрагментов C .

(+)-условию p_1 удовлетворяют множества:

- $C_1 = \{c_2, c_7\}$; $\Omega = \{o_1, o_3\}$;
- $C_2 = \{c_4\}$; $\Omega = \{o_1, o_2\}$.

(-)-условию p_1 удовлетворяют множества:

- $C_3 = \{c_1\}$; $\Omega = \{o_4, o_9\}$;
- $C_4 = \{c_3\}$; $\Omega = \{o_6, o_7, o_8\}$;
- $C_5 = \{c_5\}$; $\Omega = \{o_6, o_7\}$;
- $C_6 = \{c_3, c_5\}$; $\Omega = \{o_6, o_7\}$;
- $C_7 = \{c_6\}$; $\Omega = \{o_4, o_5, o_8, o_9\}$;
- $C_8 = \{c_9\}$; $\Omega = \{o_4, o_7\}$;
- $C_9 = \{c_{10}\}$; $\Omega = \{o_8, o_9\}$;
- $C_{10} = \{c_1, c_6\}$; $\Omega = \{o_4, o_9\}$;
- $C_{11} = \{c_6, c_{10}\}$; $\Omega = \{o_8, o_9\}$.

Теперь необходимо выяснить, являются ли найденные множества возможными причинами наличия или отсутствия целевых свойств p_1, p_2, p_3 у объектов, то есть определить функцию H для данного шага. Как говорилось ранее, правила определения данной функции могут иметь различный вид в зависимости от выбранной стратегии – с запретом (или без запрета) на контр-примеры.

Множество $C_i \subseteq C$ будем доопределять как

- возможную причину наличия свойства p , если C_i удовлетворяет (+)-условию для p , то есть вкладывается как подмножество в два и более (+)-примера и при этом не вкладывается ни в один (вкладывается не более чем в один) (-)-пример;

- возможную причину отсутствия свойства p , C_i удовлетворяет (-)-условию для p , то есть вкладывается как подмножество в два и более (-)-примера и при этом не вкладывается ни в один (вкладывается не более чем в один) (+)-пример;

- противоречивую гипотезу, если существуют как (+)-пример, так и (-)-пример, в который вкладывается C_i .

Возможные причины наличия свойства p_1 :

- $C_1 = \{c_2, c_7\}$;

- $C_2 = \{c_4\}$.

Все множества, удовлетворяющие (-)-условию для p_1 , доопределяются как возможные причины отсутствия свойства p_1 :

- $H(C_1, p_1) = +1$;
- $H(C_2, p_1) = +1$;
- $H(C_3, p_1) = -1$;
- $H(C_4, p_1) = -1$;
- $H(C_5, p_1) = -1$;
- $H(C_6, p_1) = -1$;
- $H(C_7, p_1) = -1$;
- $H(C_8, p_1) = -1$;
- $H(C_9, p_1) = -1$;
- $H(C_{10}, p_1) = -1$;
- $H(C_{11}, p_1) = -1$.

(+)-условию p_2 удовлетворяют множества:

- $C_{12} = \{c_6\}$; $\Omega = \{o_4, o_5\}$;

(-)-условию p_2 удовлетворяют множества:

- $C_9 = \{c_{10}\}$; $\Omega = \{o_8, o_9\}$;
- $C_{11} = \{c_6, c_{10}\}$; $\Omega = \{o_8, o_9\}$;
- $C_{13} = \{c_1\}$; $\Omega = \{o_2, o_9\}$;
- $C_{14} = \{c_2\}$; $\Omega = \{o_1, o_3\}$;
- $C_{15} = \{c_3\}$; $\Omega = \{o_7, o_8\}$;
- $C_{16} = \{c_4\}$; $\Omega = \{o_1, o_2\}$;
- $C_{17} = \{c_5\}$; $\Omega = \{o_3, o_7\}$;
- $C_{18} = \{c_6\}$; $\Omega = \{o_8, o_9\}$;
- $C_{19} = \{c_7\}$; $\Omega = \{o_1, o_3\}$;
- $C_{20} = \{c_2, c_7\}$; $\Omega = \{o_1, o_3\}$.

Возможные причины наличия свойства p_2 отсутствуют. Таким образом,

- $H(C_9, p_2) = -1$;
- $H(C_{11}, p_2) = -1$;
- $H(C_{13}, p_2) = -1$;
- $H(C_{14}, p_2) = -1$;
- $H(C_{15}, p_2) = -1$;
- $H(C_{16}, p_2) = -1$;
- $H(C_{17}, p_2) = -1$;
- $H(C_{18}, p_2) = -1$;
- $H(C_{19}, p_2) = -1$;
- $H(C_{20}, p_2) = -1$.

(+)-условию p_3 удовлетворяют множества:

- $C_{21} = \{c_3\}$; $\Omega = \{o_7, o_8\}$;
- $C_{22} = \{c_6\}$; $\Omega = \{o_8, o_9\}$;
- $C_{23} = \{c_{10}\}$; $\Omega = \{o_8, o_9\}$.

(-)-условию p_3 удовлетворяют множества:

- $C_{20} = \{c_2, c_7\}$; $\Omega = \{o_1, o_3\}$;
- $C_{24} = \{c_5, c_7\}$; $\Omega = \{o_3, o_6\}$;
- $C_{25} = \{c_1\}$; $\Omega = \{o_2, o_4\}$;
- $C_{26} = \{c_2\}$; $\Omega = \{o_1, o_3, o_5\}$;
- $C_{27} = \{c_4\}$; $\Omega = \{o_1, o_2\}$;
- $C_{28} = \{c_5\}$; $\Omega = \{o_3, o_6\}$;
- $C_{29} = \{c_6\}$; $\Omega = \{o_4, o_5\}$;
- $C_{30} = \{c_7\}$; $\Omega = \{o_1, o_3, o_6\}$;
- $C_{31} = \{c_8\}$; $\Omega = \{o_2, o_5\}$.

Возможные причины наличия свойства p_3 :

- $C_{21} = \{c_3\}$;
- $C_{23} = \{c_{10}\}$.

Получаем:

- $H(C_{21}, p_3) = +1$;
- $H(C_{23}, p_3) = +1$;
- $H(C_{20}, p_3) = -1$;
- $H(C_{24}, p_3) = -1$;
- $H(C_{25}, p_3) = -1$;
- $H(C_{26}, p_3) = -1$;
- $H(C_{27}, p_3) = -1$;
- $H(C_{28}, p_3) = -1$;
- $H(C_{29}, p_3) = -1$;
- $H(C_{30}, p_3) = -1$;
- $H(C_{31}, p_3) = -1$.

Применение правил второго рода. Используем полученные на предыдущем шаге (+)- и (-)-гипотезы для определения τ -примеров. Такой пример всего один: $o_{10} \{c_1, c_6, c_9\}$.

В него не вкладывается ни одна из возможных причин наличия свойств p_1, p_2, p_3 и вкладывается четыре возможных причины отсутствия свойства p_1 (C_3, C_7, C_8, C_{10}), две возможных причины отсутствия свойства p_2 (C_{13}, C_{18}) и две возможных причины отсутствия свойства p_3 (C_{25}, C_{29}). Таким образом, τ -пример o_{10} с большей уверенностью обладает свойством p_2 или p_3 , чем p_1 , т.е. посетитель с информационным портретом o_{10} скорее имеет «средний» или «высокий» социальный статус, чем «низкий».

Проверка каузальной полноты. Проверка каузальной полноты осуществляется рассуждениями типа: условие выполняется, если в каждый исходный (+)-пример вкладывается хотя бы одна возможная причина наличия целевого свойства, а в каждый (-)-пример – хотя бы одна возможная причина его отсутствия. В данном случае каждый исходный положительный и отрицательный пример является объясненным.

Таким образом, получено правдоподобные достаточные условия для того, чтобы пользователю был присвоен определенный социальный статус:

1. Социальный статус «низкий»: ОС Windows XP и скорость соединения меньше 56 kbit/s или разрешение 800×600 и меньше.

2. Социальный статус «высокий»: ОС Unix или скорость соединения выше 512 kbit/s.

Для более точного определения социального статуса посетителя сайта необходимо увеличить количество структурных фрагментов C (добавить данные обратной связи с пользователем, время посещения, разделить пользователей стационарных компьютеров и ноутбуков и т.д. – факторы, тем или иным образом зависящие от социального статуса) и количество объектов O (увеличить количество ИПП, участвующих в порождении гипотез).

Выводы

Предложена модель категоризации интернет-пользователей на основе ДСМ-метода, позволяющая разделить посетителей сайта на категории с целью предоставления им актуальной информации, что в свою очередь позволяет повысить качество поиска информации в сети Интернет.

Список литературы

1. Обьедков С.А. Алгоритмические аспекты ДСМ-метода и формального анализа понятий / С.А. Обьедков. – М.: РГГУ, 1999.
2. Финн В.К. Базы данных с неполной информацией и новый метод автоматического порождения гипотез / В.К. Финн // Диалоговые и фактографические системы информационного обеспечения. – М., 1981.
3. Виноградов Д.В. Несимметричный ДСМ-метод с учетом контекста / Д.В. Виноградов // Пятая национальная конференция с международным участием. Искусственный интеллект-96. – Казань: 1996. – КИИ-96: Сб. науч. тр.: В 3 т. – Казань: Ассоц. искусств. Интел., 1996.
4. Cooley Robert. Data Preparation for Mining World Wide Web Browsing Patterns / Robert Cooley, Bamshad Mobasher, Jaideep Srivastava // Knowledge and Information Systems. – 1, 1999.

Поступила в редколлегию 17.02.2010

Рецензент: д-р техн. наук, проф. Г.Г. Четверяков, Харьковский национальный университет радиоэлектроники, Харьков.

МОДЕЛЬ КАТЕГОРИЗАЦІЇ ІНТЕРНЕТ-КОРИСТУВАЧІВ НА ОСНОВІ ДСМ-МЕТОДУ

Н.Г. Аксак, С.А. Коргут

Розглянутий підхід до побудови адаптивної інформаційно-пошукової системи за допомогою категоризації користувачів. Розроблена модель категоризації інтернет-користувачів на основі методу автоматичного породження гіпотез Джона-Стюарта-Мілля (ДСМ-метод). Визначені основні джерела знань про користувача інформаційної системи. Розглянутий приклад віднесення користувача до категорій за допомогою запропонованої моделі.

Ключові слова: категоризація, інтернет-користувач, ДСМ-метод.

MODEL OF CATEGORIZING OF INTERNET-USERS ON THE BASIS OF DSM-METHOD

N.G. Axak, S.A. Korgut

Approach is considered to the construction of the adaptive information storage and retrieval system through categorizing of users. The model of categorizing of Internet-users is developed on the basis of method of automatic generation of hypotheses of Dzhoa-Styuart-Mill (DSM-method). The basic sources of knowledges are certain about the user of the informative system. The example of taking of user is considered to the categories through the offered model.

Keywords: categorizing, Internet-users, DSM-method.