

Разработка Нечеткого OLAP-Куба в Хранилище Данных Системы Поддержки Принятия Решений

Гюльнара Набибекова
Институт Информационных Технологий НАНА
gulnarara58@mail.ru

Аннотация— В статье показана интеграция технологии OLAP (Online Analytical Processing) и нечеткой логики при разработке нечеткого OLAP-куба в поликубической OLAP-модели в системе поддержки принятия решений. С этой целью фаззифицированы измерения OLAP-куба. Показано формирование нечеткого среза в результате нечеткого запроса. Также представлено практическое применение данного подхода в системе поддержки принятия решений при решении задачи управления кадровыми ресурсами.

Ключевые слова— система поддержки принятия решений, хранилище данных, OLAP, OLAP-кубЮ, нечеткое множество, функция принадлежности, терм-множество, лингвистическая переменная, нечеткий запрос, нечеткий срез, индекс соответствия срезу

I. ВВЕДЕНИЕ

В процессе принятия решений можно столкнуться с множеством нечетких задач, вследствие чего в запросах к Хранилищам данных (ХД), которые формулирует аналитик, часто имеют место неточности и неопределенности. Кроме того, для лиц, принимающих решения, важен и полезен бывает не сам результат запроса, а то, является ли этот результат хорошим, средним или плохим, то есть им важна качественная сторона результата [1,2]. Все это требует, чтобы система поддержки принятия решений (СППР) могла использовать нечеткие и неопределенные рассуждения и поддерживала соответствующую технологию представления знаний [2]. В этом случае ХД должно обеспечивать ответы на запросы, которые используют лингвистические термины, являющиеся терм-множествами соответствующей лингвистической переменной.

Для решения данной задачи необходимо выполнить фаззификацию измерений OLAP-куба и затем в результате нечеткого запроса сформировать нечеткий срез.

II. ФАЗЗИФИКАЦИЯ ИЗМЕРЕНИЙ OLAP-КУБА

В настоящее время для комплексного многомерного анализа больших объемов накопленной в ХД информации активно применяется технология OLAP [3]. Технология OLAP основана на представлении данных ХД в виде многомерной модели – гиперкуба, или OLAP-куба, содержащего одно или более

измерений. Для фаззификации измерений OLAP-куба обратимся к получившему в настоящее время широкое распространение аппарату теории нечетких множеств в задачах поиска информации.

Нечеткое множество, включая функцию принадлежности, являющуюся его характеристикой, может быть задано экспертом. Но в некоторых случаях функцию принадлежности удобнее задать аналитической формулой и графически. Для задания функций принадлежности существуют различные типовые формы кривых, среди которых выберем треугольную и трапецеидальную кусочно-линейные формы. В общем случае треугольная функция принадлежности определяется тремя числами, а трапецеидальная – четырьмя, хотя их количество может и меняться в зависимости от условий задачи.

Для определения чисел, с помощью которых будет задана функция принадлежности, применим кластеризацию, на основании подхода, представленного в [1], согласно которому центры кластеров – медоиды, полученные в результате кластеризации соответствующих измерений, служат для определения функции принадлежности.

С целью выбора эффективного алгоритма кластеризации были рассмотрены неирархические алгоритмы, основанные на методе разбиения, а именно на методе k-medoids, так как медоид – это центр кластера, который принадлежит данному кластеру, что является главным условием задачи. Кроме того, методы k-medoids являются устойчивыми к наличию выбросов (outliers), т.е. точек, которые достаточно далеки от остальных точек, и могут работать достаточно эффективно с большими наборами данных.

Алгоритмы, основанные на методе разбиений, проходят два основных этапа [4]:

- начальный шаг, на котором k объектов выбраны в качестве медоидов;
- оценочный шаг, на котором происходит попытка минимизировать целевую функцию, обычно основанную на сумме общего расстояния между невыбранными объектами (значениями) и их медоидами, т.е.:

$$D(r, s) = \sum_{j=1}^n d(r_i, s_j)$$

где $s_j \in S$ (S – множество объектов (значений) для кластеризации) и $d(r_i, s_i) < d(r_c, s_j)$, $\forall r_i, r_c \in R$ (R – множество объектов (значений) из S , выбранных в качестве медоидов), $r_i \neq r_c$. Чем меньше сумма расстояний между медоидом и всеми другими объектами соответствующего ему кластера, тем лучше кластеризация.

Были рассмотрены три известных алгоритма, основанных на методе k-medoids: PAM (Partitioning Around Medoids), CLARA (Clustering LARge Applications) и CLARANS (Clustering Large Applications based on RANdomized Search) [5, 6].

PAM является одним из первых алгоритмов, основанных на методе k-medoids. В работах [7, 8] представлен основной принцип процесса кластеризации PAM, заключающийся в переборе всех объектов, не являющихся медоидами, для вычисления расстояния от них до выбранных медоидов. Действие алгоритма PAM приводит к высокому качеству кластеров, но поскольку он пробует все возможные комбинации, он эффективен для небольших наборов данных. И в связи с его вычислительной сложностью его применение непрактично для кластеризации больших наборов данных.

Вычислительная сложность алгоритма PAM явилась мотивацией для разработки алгоритма CLARA – алгоритма кластеризации на основе выборки [7]. CLARA выделяет из множества данных несколько выборок данных, применяет PAM на каждой выборке и находит ее медоиды. Поскольку выборка произведена случайным образом, то медоиды выборки можно считать медоидами всего набора данных. Чтобы выбрать лучшие приближения, CLARA создает несколько выборок и на выходе выдает лучшую кластеризацию. В работе [7] также экспериментально показано, что пять выборок размером $(40+2k)$, где k – количество кластеров, дают удовлетворительные результаты.

CLARANS был разработан в рамках пространственного анализа данных. При поиске лучшего медоида на шаге оценки CLARANS случайным образом выбирает объекты из $(n-k)$ объектов (n – количество объектов в множестве, k – заданное количество кластеров, или количество медоидов). Количество объектов, перебираемых на этом этапе, ограничены параметром *maxneighbor*, заданным пользователем. Если после *maxneighbor* попыток не будет найдено лучшее решение, то локальный оптимум считается достигнутым. Процедура продолжается до тех пор, пока не найдено *numloc* локальных оптимумов.

Алгоритм CLARANS использует стратегию рандомизированного (случайного) поиска для облегчения кластеризации большого количества

данных. Наличие большого количества данных позволяет гарантированно достичь *numloc* локальных оптимумов [8].

В результате исследования вышеупомянутых алгоритмов на предмет их достоинств и недостатков, для получения чисел, с помощью которых затем будет выполнена фазификация, был выбран алгоритм CLARA, являющийся наиболее приемлемым для использования в данной задаче, с точки зрения сложности вычислений, размера множеств и затраченного времени.

Предположим, A является множеством измерений из всех измерений которые надо фазифицировать.

Для каждого $j \in A$ применим алгоритм CLARA и найдем в нем k медоидов $a_{1j}, a_{2j}, \dots, a_{kj}$ для k кластеров.

Пусть J – множество значений j -го измерения;

$F_{ij}(x)$ – функция принадлежности для получения значений принадлежности всех значений j -го измерения в i -ом нечетком множестве. Рассмотрим случай, когда количество терм-множеств равно 3, т.е. $i=3$. Отметим, что второе терм-множество считается средним, т.е. расположенным между первым и последним терм-множествами.

Для всех $x \in J$ выполняется:

1) для первого нечеткого множества (т.е. при $i=1$)

$$F_{1j}(x)=1, \text{ если } x \leq a_{1j};$$

$$F_{1j}(x)=(a_{2j}-x)/(a_{2j}-a_{1j}), \text{ если } a_{1j} < x < a_{2j};$$

$$F_{1j}(x)=0, \text{ если } x \geq a_{2j}.$$

2) для второго нечеткого множества (т.е. при $i=2$)

$$F_{2j}(x)=0 \text{ если } x \leq a_{1j};$$

$$F_{2j}(x)=(x-a_{1j})/(a_{2j}-a_{1j}), \text{ если } a_{1j} < x < a_{2j};$$

$$F_{2j}(x)=1, \text{ если } x = a_{2j};$$

$$F_{2j}(x)=(a_{3j}-x)/(a_{3j}-a_{2j}), \text{ если } a_{2j} < x < a_{3j};$$

$$F_{2j}(x)=0, \text{ если } x \geq a_{3j}.$$

3) для третьего нечеткого множества (т.е. при $i=3$)

$$F_{3j}(x)=0, \text{ если } x \leq a_{2j};$$

$$F_{3j}(x)=(x-a_{2j})/(a_{3j}-a_{2j}), \text{ если } a_{2j} < x < a_{3j};$$

$$F_{3j}(x)=1, \text{ если } x \geq a_{3j}.$$

III. ФОРМИРОВАНИЕ НЕЧЕТКОГО СРЕЗА

В результате нечеткого запроса формируется нечеткий срез, состоящий из ячеек куба, соответствующих условиям запроса. Но для формирования итогового среза учитывают также и так называемый индекс соответствия срезу CI (Compliance Index), где $CI \in [0, 1]$, который определяет аналитик [9].

Пусть имеется запрос:

$\{(L_1 = L_{1j}, (j = \overline{1, k_1})) \cup (L_2 = L_{2j}, (j = \overline{1, k_2})) \cup \dots \cup (L_n = L_{nj}, (j = \overline{1, k_n}))\}$,
 где L_1, L_2, \dots, L_n – лингвистические переменные, а $L_{1j},$
 $(j = \overline{1, k_1}), L_{2j}, (j = \overline{1, k_2}), \dots, L_{nj}, (j = \overline{1, k_n})$ –
 соответствующие им терм-множества.

В каждой записи ХД, $\forall x \in L_i$, где $i = \overline{1, n}$, то
 есть для любого x лингвистической переменной,
 участвующей в запросе, найдем степень
 принадлежности $\mu_{L_{ij}}(x)$ этого x терм-множеству L_{ij} ,
 участвующему в запросе.

Находим степень принадлежности каждой записи
 итоговому срезу, то есть ее индекс соответствия срезу,
 по формуле:

$$CI = \min(\mu_{L_{mn}}(x)).$$

Для CI вводятся условия, например:

если $CI \leq 2$, то соответствие срезу «слабое»;

если $2 < CI < 5$, то соответствие срезу «среднее»;

если $CI \geq 5$, то принадлежность срезу «высокая».

IV. ПРАКТИЧЕСКОЕ ПРИМЕНЕНИЕ

В качестве примера создания нечеткого OLAP куба в
 поликубической OLAP-модели рассматривается
 подзадача управления кадровыми ресурсами в СППР,
 разработанной с целью определения степени
 интеграции стран. Данная СППР является
 многоцелевой, то есть помимо решения основной
 задачи, она может решать и побочные, в том числе и
 подзадачу управления кадровыми ресурсами,
 включающую решение таких вопросов, как анализ
 кадровых ресурсов, их размещение, обучение,
 планирование продвижения сотрудников и т.д. При
 решении такой подзадачи для лиц, принимающих
 решение, при формировании запроса к ХД часто бывает
 важен не конкретно возраст сотрудника, а то, является
 он *молодым, средним* или *пожилым*, или, например, не
 конкретно стаж работы, а является он *малым, средним*
 или *продолжительным*. Кроме того, его может
 интересовать не точная дата мероприятия, в котором
 сотрудник принимал участие, а то, когда произошло это
 событие - *давно* или *недавно*.

Пусть с целью создания нечеткого OLAP-куба на
 основании соответствующей витрины данных из всего
 множества измерений надо фаззифицировать 3
 измерения – ВОЗРАСТ, СТАЖ РАБОТЫ и ДАТА

В результате фаззификации измерения СТАЖ
 РАБОТЫ и ВОЗРАСТ становятся лингвистическими
 переменными, а полученные 3 кластера станут тремя
 терм-множествами. Для измерения СТАЖ РАБОТЫ это
 {малый, средний, продолжительный}, а для измерения
 ВОЗРАСТ это {молодой, средний, пожилой}.

На рис.1 и рис.2 дано графическое изображение
 терм-множеств соответствующих измерений. Отметим,

что номер j следует закреплять за соответствующим
 измерением. В данном случае $j=1$ – измерение
 “ВОЗРАСТ”, $j=2$ – измерение “СТАЖ РАБОТЫ”.




Рис. 1. Графическое изображение лингвистической переменной “ВОЗРАСТ”




Рис. 2. Графическое изображение лингвистической переменной “СТАЖ РАБОТЫ”

Измерение ДАТА будет разбит на 2 терм-
 множества (*недавно* и *давно*), поэтому для его
 фаззификации применим алгоритм CLARA, задав
 количество кластеров $k=2$. В результате будут получены
 2 кластера с центрами (медоидами) в точках a_{13} и a_{23} ,
 с помощью которых будет задана функция
 принадлежности.

После выполнения фаззификации будут получены 2
 терм-множества. На рис. 3 показано графическое
 изображение лингвистической переменной “ДАТА”.




Рис. 3. Графическое изображение лингвистической переменной “ДАТА”.

В результате фаззификации измерений куба
 рассматриваемой СППР можно выполнять нечеткие
 запросы, используя термины *молодой, зрелый, пожилой*
 (касательно возраста), *малый, средний, продолжитель-*
ный (касательно стажа работы), *недавно и давно*
 (касательно даты мероприятия).

Приведены примеры типовых нечетких запросов, которые могут сыграть не последнюю роль в управлении кадровыми ресурсами:

1. *Молодые* сотрудники, посетившие *недавно* Турцию;

2. Сотрудники, имеющие *продолжительный* стаж работы, которые посетили *недавно* Турцию в связи с мероприятиями в медицинской сфере;

3. Страны, где *молодые* сотрудники прошли *недавно* тренинги в военной сфере и т.д.

ЗАКЛЮЧЕНИЕ

Данная СППР реализована для персональных компьютеров, работающих в среде WindowsXP, Windows7, Windows8 и т.д., допускающей сетевое многопользовательское использование технологии клиент-сервер. В качестве платформы используется система управления базами данных MS SQL сервер [10]. Среда реализации OLAP - Microsoft Visual Studio 2008 (Analysis Services). Клиентская часть реализована на языке программирования Object Pascal [11] с применением среды разработки приложений Delphi 2010 [12] и предназначена для обращения к серверу, обработки и представления полученных данных. Используемый язык запросов – T-SQL [13].

ЛИТЕРАТУРА

- [1] K. Kumar et al. Fuzzy OLAP Cube for Qualitative Analysis / 3rd International Conference on Intelligent Sensing and Information Processing (ICISIP), 2005, p. 290 - 295. http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=1529464&tag=1
- [2] Sh. Wang. Application of Decision Support System in E-government / International Conference “Management and Service Science”, 2009, (MASS'09). <http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=5302532>
- [3] E. F. Codd, S. B. Codd, C.T. Salley. Providing OLAP (Online Analytical Processing) to User-Analysts: An IT Mandate. San Jose: Codd & Date, Inc., 1993, p. 31. www.minet.uni-jena.de/dbis/lehre/ss2005/sem_dwh/lit/Cod93.pdf

- [4] M.-C. N. Barioni et al. An efficient approach to scale up k-medoid based algorithms in large databases. XXI Brazilian Symposium on Databases. 2006. www.lbd.dcc.ufmg.br:8080/colecoes/sbbd/2006/018.pdf
- [5] L. Kaufman, P. J. Rousseeuw Finding Groups in Data: an Introduction to Cluster Analysis. John Wiley & Sons, 2005,
- [6] R.T. Ng, J. Han. Clarans: A method for clustering objects for spatial data mining // IEEE Transactions on Knowledge and Data Engineering (TKDE), 2002, 14(5), pp. 1003-1016.
- [7] Г. Набибекова. Об одном методе фаззификации атрибутов хранилища данных в системах поддержки принятия решений в сфере внешней политики // Информационные технологии. №1, 2014, с.36-41.
- [8] Г. Набибекова Об одном подходе к разработке нечеткого OLAP-куба в системах поддержки принятия решений в сфере внешней политики / Материалы IV Международной научно-практической конференции “Проблемы кибернетики и информатики” PCI2012, 2012, с.86-89.
- [9] Н. Б. Паклин, В. И. Орешков. Бизнес-аналитика: от данных к знаниям. Учебное пособие, Питер, 2013, 703 с.
- [10] R. Dyer Learning MySQL and MariaDB: Heading in the Right Direction with MySQL and MariaDB. O'Reilly Media, 2015, 408 p.
- [11] M. Cantu Object Pascal Handbook. CreateSpace Independent Publishing Platform, 2015, 552 p.
- [12] N. Hodges. More Coding in Delphi. Nepeta Enterprises, 2015, 246 p.
- [13] I. Ben-Gan. T-SQL Fundamentals. Microsoft Press, 2016, 464 p.