

УДК 004.652:004.658

## МОДЕЛИРОВАНИЕ ВЕРСИОННЫХ СТРУКТУР С ПОМОЩЬЮ АНАЛИТИЧЕСКОЙ МОДЕЛИ СХЕМЫ ДАНЫХ

*Трофимов Б.Ф., Малахов Е.В.*

*Одесский национальный политехнический университет*

Все больше современных технологий позволяют сохранять последовательную промежуточную историю изменения данных. К числу таких относятся транзакционные СУБД, системы контроля версий, текстовые процессоры, менеджеры файловых систем. Однако современные модели представления данных (реляционная, иерархическая и др.) не предназначены для учета их версииности. С этой целью разработана аналитическая модель схемы данных, особенностью которой является ее функциональное представление схемы данных. В рамках модели определены абстрактная модель схемы данных, ее версии, операции над версиями.

Для задания модели введены следующие обозначения и определения:

1. Пусть дано некоторое выражение  $v$  над элементами и переменными из  $X$ , множество параметров-переменных выражения  $v$  обозначено через  $|v|$ .
2. Функция интерпретирования  $I_{AC}$  — функция отображения элементов из некоторого множества  $A$  в множество  $C$ .  $I_{AA}$  — тождественная функция из  $A$  в  $A$ .

*Определение 1.* Пусть даны множества  $A_i, G_i$  такие, что пары  $(A_i, G_i)$  образуют алгебры, при  $i=1..n$ . Пусть  $I_{A_i-A_j}$  - функция интерпретирования из  $A_i$  в  $A_j$ , тогда аналитической моделью схемы данных (далее схемой) называется конечное множество кортежей вида (рис. 1):

$$s = \{ \langle a_p, v_p \rangle, \dots, \langle a_n, v_n \rangle, \dots, \langle a_k, f_1(\dots, f_2(\dots, f_n(p_p, \dots, p_m), \dots), \dots) \rangle, \dots \},$$

где  $f_i \in \{I_{A_i-A_j}\} \cup G_j$ ,  $a_i$  — идентификаторы кортежей, такие что выполнено условие уникальности:  $\neg \exists a_i, a_j \in s : a_i = a_j$  при  $j \neq i$ ;

$v_i \in A_1 \cup \dots \cup A_N$ ;  $p_i$  – идентификаторы, для которых выполнено условие замкнутости:  $\forall p_i, \exists$  кортеж из  $s$  с идентификатором  $p_i$ .

*Определение 2.* Классом схем называется множество всех потенциально построенных схем над зафиксированными параметрами  $A_1 \dots A_n$ ,  $G_1 \dots G_n$ ,  $I_{A_i-A_j}$  и обозначено через:

$$MS(\{A_1 \dots A_n\}, \{G_1 \dots G_n\}, \{I_{A_i-A_j}\}) \quad (1)$$

*Определение 3.* Пусть дано некоторое множество  $A$ , тогда элементарной схемой называется конечное множество кортежей вида  $s = \{(a_1, v_1), (a_2, v_2), \dots, (a_n, v_n)\}$ , где  $v_i \in A$ ,  $a_i$  — идентификаторы кортежей с выполнением условия уникальности  $\neg \exists a_i, a_j \in s : a_i = a_j$ , при  $i \neq j$ .

*Определение 4.* Классом элементарных схем называется множество всех потенциально построенных элементарных схем над параметром  $A$  и обозначено через  $S(A)$ ; по построению  $S(A_n) \subseteq MS(\{A_1, \dots, A_N\}, \{G_1, \dots, G_N\}, \{I_{A_i-A_j}\})$ .

Для схемы из (1) предложен метод ее вычисления в элементарную схему, заданный в виде функции интерпретирования  $I_{P, MS \rightarrow S}$ . Для схемы из (1) предложен метод ее вычисления в элементарную схему, заданный в виде функции интерпретирования  $I_{P, MS \rightarrow S}$ .

*Определение 5.* Версией элемента  $a$  из схемы  $s$  называется элемент  $a' \in s$ , у которого  $a \in a'$ . Пусть даны  $a_1, \dots, a_n \in S$ , такие что  $a_{i+1}$  есть версия  $a_i$ , тогда схему  $s$  можно представить как содержащую всю историю изменения элемента  $a_i$ :

$$s = \{ \langle a_p, a \rangle, \langle a_2, f_1(a) \rangle, \dots, \langle a_i, f_{i-1}(a_1, \dots, a_{i-1}) \rangle, \dots, \langle a_n, f_{n-1}(a_1, \dots, a_{n-1}) \rangle \}.$$

Для оперирования элементами классов схем и элементарных схем определены множества операций. Операции над классом схем ( $F$ ) включают: операцию добавления элемента в схему (+), операцию удаления элемента из схемы (-), операцию переименования элемента (RENAME), операцию изменения выражения в элементе схемы (CHANGE). Операции над классом элементарных схем ( $H$ ) включают теоретико-множественные

Элементы схем данных

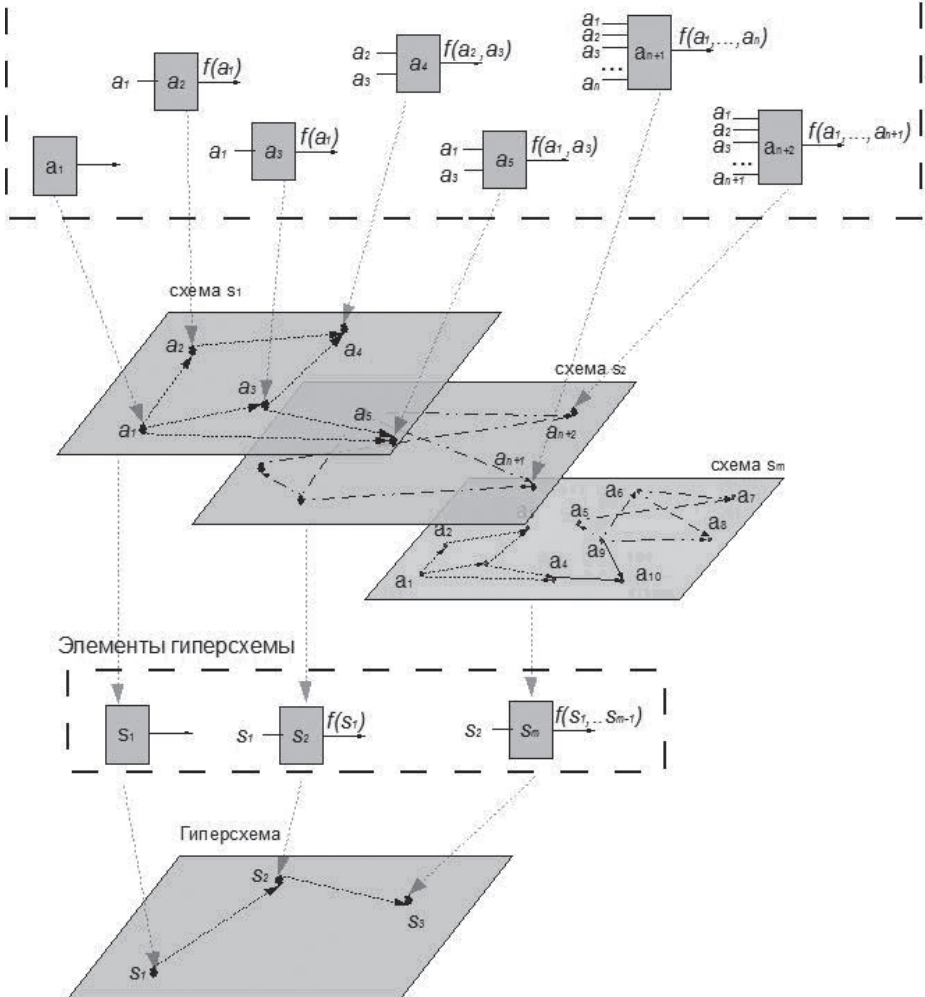


Рисунок 1 - Структурное представление и взаимосвязь элементов схемы, схемы и гиперсхемы

операции объединения ( $\cup$ ), пересечения ( $\cap$ ), вычитания ( $\setminus$ ), а также операцию выборки элементов из элементарной схемы по некоторому предикату (GET).

Для представления версии схем предложен класс

схем на основе (1) с определенными параметрами:

$$MS(\{MS', S'\}, \{F, H\}, \{I_{ms'-s'}, I_{s'-ms'}\}), \tag{2}$$

где  $MS'=MS(\{A_1...A_n\}, \{G_1...G_n\}, \{I_{A_i-A_j}\})$ ,  $S'=S(A_n)$ .

Определение 6. Элементы множества (2) называются гиперсхемами (рис. 2), а (2) – классом гиперсхем.

В качестве абстракции управления версиями схемы из (1) в составе гиперсхем из (2) предложены следующие сценарии:

1. Создание версии схемы  $a$  в гиперсхеме  $s_j$ :  $s_1=ADD(s_1, a)$
2. Замена версии схемы с идентификатором  $id$  на новую  $a$  в гиперсхеме  $s_j$ :  $s_j=CHANGE(s_j, id, a)$
3. Удаление версии схемы с идентификатором  $id$  из гиперсхемы  $s_j$ :  $s_j=DEL(s_j, id)$
4. Модификация данных в схеме с идентификатором  $id_{i-1}$  в гиперсхеме  $s$ : добавление, редактирование, удаление эле-




Рисунок 2 Представление реляционного отношения  $r$  из версий  $V_k, \dots, V_{k+n}$

ментов схемы. Любая модификация существующих схем в составе гиперсхемы приводит к созданию новой версии схемы:  $CHANGE'(s, id_{i-p}, f(id_{i-l})) = ADD(ADD(s, <id_p, f(id_{i-l}) >), <id_p, I_{P,MS-S}(id_p) >)$

##### 5. Сокращение версии, упрощение гиперсхемы.

*Определение 7.* Пусть даны гиперсхемы  $s$  и  $s'$  из (2) для некоторых зафиксированных  $\{A_1 \dots A_n\}, \{G_1 \dots G_n\}, \{I_{ai-Aj}\}$ . Гиперсхема  $s$  является эквивалентной  $s'$ , если  $I_{MS \rightarrow S}(s) = (s')$ .

*Определение 8.* *Высотой* гиперсхемы  $s$  называется длина максимальной последовательности  $a_p \dots a_n$  из  $s$ , где  $a_{i+1}$  является версией  $a_i$ . Рассмотрен подкласс гиперсхем с высотой равным 2 (*двухуровневые гиперсхемы*).

Показано, что для любой произвольной гиперсхемы существует эквивалентная ей двухуровневая гиперсхема.

*Определение 9.* Схема  $s$  называется *корректной*, если функция интерпретирования  $I_{MS \rightarrow S}$  определена на  $s$  (существует  $I_{MS \rightarrow S}(s)$ ). Схема  $s$  называется *слабо-корректной*, если функция интерпретирования  $I_{MS \rightarrow S}$  вычислима на  $s$  (для алгоритма вычисления  $I_{MS \rightarrow S}$  на  $s$  всегда существует останов, однако не обязательно существует  $I_{MS \rightarrow S}(s)$ ).

Предлагается классификация ошибок, нарушающих корректность схем из класса (1):

- ошибки 1 рода: для схемы  $s$  существует последовательность идентификаторов  $id_p \dots id_n$ , таких, что  $id_i$  является версией  $id_{((n+i-2) \bmod n)+1}$ ;
- ошибки 2 рода: для схемы  $s \exists id_i \in s$  такой что при известных параметрах из  $|id_i|$  выражение  $id_i$  не вычислимо;
- ошибки 3 рода: для схемы  $s \exists id_i \in s$  такой что при известных параметрах из  $|id_i|$  выражение  $id_i$  вычислимо, но не определено.

Доказаны два критерия взаимосвязи слабо-корректных схем и ошибок 1-3 рода.

##### *Критерий 1.*

Пусть дано подмножество схем  $S$  из класса схем (1) с

зафиксированными параметрами  $\{A_1 \dots A_n\}, \{G_1 \dots G_n\}, \{I_{A_i-A_j}\}$ , у которого любой  $s \in S$  не содержит ошибок 2 рода.

Схема  $s \in S$  слабо-корректна тогда и только тогда, когда не содержит ошибок 1 рода.

*Следствие 1.*

Слабо-корректная схема  $s \in S$  может содержать ошибки 3 рода.

*Следствие 2.*

Схема  $s \in S$  корректна тогда и только тогда, когда она слабо-корректна и не содержит ошибок 3 рода.

Предложена методика построения орграфа для любой схемы из (1). Доказан критерий связи орциклов в орграфе и ошибок 1 рода.

*Критерий 2.*

Схема из (1) имеет ошибку 1 рода тогда и только тогда когда соответствующий ей ограф имеет орцикл.

На основе определения 9, критерия 1, его следствий и критерия 2 построен метод определения корректности схемы, который основан на сведении к задаче определения орцикла в орграфе.

Для определения орцикла в орграфе предложена модификация метода временного моделирования. В качестве узловой функции выбрана функция конъюнктивности входящих в

узел сигналов:  $F(x_i) = \bigwedge_{i=1}^n f(e_{ij})$ . Показано, что отсутствие орциклов

в орграфе связано с истинностью  $F = \bigwedge_{j=1}^k F(x_j)$ , где  $x_j$  – вершины,

чье множество исходящих ребер пусто.

На основе аналитической модели схемы данных и ее методов была разработана модель многоверсионного представления реляционной БД, которая позволяет моделировать БД с несколькими версиями структуры. Для этого введены следующие обозначения:

1. *SIG* — множество всех потенциальных сигнатур реляции-

- онных отношений (РО);
2.  $R$  — множество всех потенциальных РО над  $SIG$ ;  $R_0$  — подмножество  $R$ , у которых множество кортежей пусто;
  3.  $I_{SIG-R}: SIG \rightarrow R$  — функция интерпретирования по сигнатуре из  $SIG$  в элемент из  $R_0$ .
  4.  $O$  — множество операций реляционной алгебры  $\{\pi, \sigma, \gamma, \times, \alpha\}$ .

Предлагается расширение набора реляционных операций  $O$  над  $R$ :

$$O' = \{a, u, r, a_s, u_s, r_s, c_s, m_s\}, \quad (3)$$

где  $a, u, r, a_s, u_s, r_s, c_s, m_s$  — операции соответственно: добавления кортежа, изменение кортежа, удаление кортежа, добавление поля в сигнатуру РО, изменение домена поля в сигнатуре РО, удаление поля из сигнатуры РО, копирование поля сигнатуры из одного РО в другое, перенос поля сигнатуры из одного РО в другое.

Версию структуры БД предлагается представить в виде схемы данных из (1) с параметрами  $R, SIG, O, O', I_{SIG-R}$ :

$$MS' = MS(\{R, SIG\}, \{O \cup O'\}, \{I_{SIG-R}\}). \quad (4)$$

С учетом (4-6) модель БД с поддержкой многоверсионной структуры БД (ММП) предлагается представить в виде гиперсхемы из класса гиперсхем (2):

$$MS'' = MS(\{MS', S'\}, \{F, H\}, \{I_{ms'-s'}, I_{s'-ms'}\}), \quad (5)$$

где  $S' = S(R)$ .

Показано, что модель ММП является расширением традиционной модели БД.

В следствие многоверсионного определения структуры БД произвольное реляционное отношение  $r$  может быть по разному представлено в нескольких версиях БД  $v_k, \dots, v_{k+n}$  (рис. 2). Для

управления представлением кортежей между несколькими версиями БД разработаны соответствующие методы представления.

В качестве абстракции управления многоверсионной БД определены сценарии (выражены через сценарии управления схемой данных):

- чтение данных кортежей реляционных отношений;
- модификация кортежей реляционных отношений;
- модификация сигнатур реляционных отношений;
- модификация версии БД (добавление, удаление нового реляционного отношения);
- работа с версиями БД (сокращение, упрощение, приведение к двухуровневому виду).

Разработанные модели и методы управления позволили построить информационную технологию многоверсионного представления и управления БД для повышения эффективности модернизации информационных систем.

## Литература

- [1] Ю.Л. Ершов. Математическая логика [текст] / Ю.Л. Ершов, Е.А. Палютин — М.:Наука, 1987.
- [2] К. Дж. Дейт. [текст] Введение в системы баз данных — 8-е изд. — М.: «Вильямс», 2006. — С. 1328.
- [3] Малахов Е.В. Обзор модели расширения реляционных схем [текст] / Малахов Е.В., Трофимов Б.Ф // Восточно-европейский журнал передовых технологий. — Харьков: 3(33) — , 2008. — С. 35.
- [4] Catharine M. Wyss Relational Languages for Metadata Integration [текст] / Catharine M. Wyss, Edward L. Robertson // ACM Transactions on Database Systems — June 2005 — Vol. 30, No. 2 — С. 624–660.