

УДК 004.415  
ББК 32.973.202-018.2

## **УПРАВЛЕНИЕ ЛОГИЧЕСКИМИ ВЫВОДАМИ В СЕМАНТИЧЕСКИХ БАЗАХ ДАННЫХ**

**Хоанг Ван Куэт**

*(Национальный Исследовательский Томский Политехнический Университет)*

*Предлагается метод контроля доступа пользователей к семантическим базам данных. Выделены две задачи контроля доступа: контроль прямого доступа к данным и контроль логических выводов на получаемых данных. Рассмотрены основные свойства отношений между объектами в семантических данных. Предложен метод контроля логических выводов несанкционированных пользователей.*

**Ключевые слова:** Семантические данные, триплет, управление логическими выводами, несанкционированный доступ.

### **1. Введение**

При повышении возможности взаимодействия между источниками данными, увеличении количества баз данных и упрощении способов использования данных пользователями очень важной становится проблема защиты данных в несанкционированном использовании. В связи с этим задачи контроля доступа к данным и их использования с учетом заданных прав пользователей являются очень актуальными.

В тоже время, в последние годы очень активно развивается такое новое направление информатики, как семантические технологии, которые начинают играть важную роль в разработке информационных систем организаций. Применяемые в этих технологиях семантические данные отличаются от реляционных данных тем, что на их основе может выполняться логический вывод, позволяющий получать новую информацию. Для обес-

печения безопасности по работе с такими данными предложены разные подходы [2], но они не предоставляют возможности контроля доступа к частям данных и проверки возможности выполнения пользователями на доступных данных не желательных логических выводов. Для безопасности семантических данных должен быть обеспечен контроль:

- прямого доступа пользователей к различным частям данных, определённых политиками доступа к данным для каждого пользователя (управление прямого доступа к данным);
- доступа к данным, на основе которых могут быть логически выведены данные, не доступные пользователю (управление возможными логическими выводами).

В данной статье рассмотрен метод контроля логических выводов пользователей с помощью алгоритма обнаружения их нарушений для решения второй задачи.

## **2. Управление логическими выводами**

В данном разделе даются основные определения логических правил и видов графов-данных, описывается предлагаемые алгоритмы обнаружения и контроля логических выводов в семантической базе данных.

### **2.1. ОСНОВНЫЕ ЛОГИЧЕСКИЕ ПРАВИЛА**

Обозначим множество всех ресурсов (объект или субъект) как множество  $P = \{A, B, C, \dots, Z\}$ , а множество всех бинарных отношений как  $X = \{X_1, X_2, \dots, X_n\}$ , где  $n \geq 1$ . Для получения логических выводов пользователи используют следующие логические правила:

- симметричность: если  $X_i \in X$  является симметричным бинарным отношением, то для любых объектов  $A, B \in P$  выполняется выражение:  $AX_iB \rightarrow BX_iA$ ;
- транзитивность: если  $X_i \in X$  является транзитивным бинарным отношением, то для любых объектов  $A, B, C \in P$  выполняется выражение:  $(AX_iB \text{ и } BX_iC) \rightarrow AX_iC$ , где  $A \neq B \neq C$ ;
- импликация: если бинарное отношение  $X_i \in X$  заключает в себе отношение  $X_j \in X$ , то для любых объектов  $A, B \in P$  выполняется выражение:  $AX_iB \rightarrow AX_jB$ ;

- корреляция: если  $X_i \in X$  является корреляционным бинарным отношением, то для любых объектов  $A, B, C, D \in P$  выполняется выражение:  $(AX_iB, CX_iD) \rightarrow AX_iC, A \neq C, B \neq C, A \neq D, B \neq D;$
- декомпозиция: если  $X_i \in X$  является разложимым бинарным отношением, то для любых объектов  $A, B \in P$  выполняется выражение:  $AX_iB \rightarrow AX_iA, BX_iB$ , где  $A \neq B$ ;
- левая импликация: если  $X_i \in X$  лево заключает в себе отношение  $X_j \in X$ , то любых объектов  $A, B \in P$  выполняется выражение:  $AX_iB \rightarrow AX_jA, A \neq B$ ;
- правая импликация: если  $X_i \in X$  справа заключает в себе отношение  $X_j$ , то любых объектов  $A, B \in P$  выполняется выражение:  $AX_iB \rightarrow BX_jB, A \neq B$ .

## 2.2. ОСНОВНЫЕ ОПРЕДЕЛЕНИЯ ГРАФОВ

*Определение 1 (RDF-граф).* Семантическая база данных представляет собой RDF-граф  $G$ , который состоит из множества вершин  $P$  (множество субъектов и объектов) и множества рёбер  $E$  (множество предикатов), обозначается  $G = (P, E)$ , где: каждая вершина является субъектом или объектом, каждое ребро является предикатом (отношение между субъектом и объектом), существуют некоторые ребра между двумя вершинами [4].

*Определение 2 (видимый граф).* Видимый граф для пользователя, имеющего уровень доступа  $AC_s$ , является графом  $G_s$ , представляющим все триплеты, состоящие из троек: субъект, предикат, объект, к которым пользователь может иметь доступ, где  $G_s \subseteq G$ .

*Определение 3 (логический граф).* Логическим графом  $G^l_s$  является результат применения основных логических правил и добавления полученных результатов к графу  $G_s$ , где  $G_s \subseteq G^l_s$ .

*Определение 4 (поток информации вершины графа).* Потоком информации для вершины  $A$  является множество всех рёбер, непосредственно связанных с  $A$ . Данной поток обозначается как  $C(A)$ .


*Правило 1 (возможность выполнения логической операции между двумя вершинами).* Предположим, что в графе  $G^l_s$  вершины  $A$  и  $B$  имеют потоки информации  $C(A)$  и  $C(B)$ , где  $C(A) \cap C(B) \neq \emptyset$ .

$C(B) \subseteq G_s^1$ . Если  $C(A) \cap C(B) = \emptyset$ , то пользователь не может получить логические выводы из этих известных ему вершин и их связей [3]. Из вышесказанного можно составить алгоритм для определения возможности возникновения логических выводов из известных связей и вершин.

*Алгоритм 1* (алгоритм определения возможности получения логических выводов между двумя вершинами).

С использованием правила 1 для определения возможности получения логических выводов между двумя вершинами разработан алгоритм, показанный на рис. 2.

В соответствии с данным алгоритмом, если между вершинами А и В обнаружены связи, то пользователь может применить логические правила и получать логические выводы из данных вершин. В противном случае, пользователь не может получить логических выводов из вершин А и В. Входными данными алгоритма 1 являются множества всех вершин и рёбер графа. Выходными данными являются вершины, между которыми имеется возможность выполнять логический вывод.



*Рис. 2. Алгоритм определения возможности получения логических выводов из двух вершин*

*Алгоритм 2* (определение возможности получения логических выводов между двумя вершинами А и В, имеющимися разные максимальные уровни безопасности).

Предположим, что в графе  $G_s^1$  вершины А и В имеются потоки информации  $C(A)$  и  $C(B)$ , где  $C(A), C(B) \subseteq G_s^1$ .  $C(A)$  имеет

максимальный уровень  $m$ ,  $C(B)$  имеет максимальный уровень  $n$ , где  $n \geq m$ . Пользователь имеет уровень доступа  $AC_s = cl$  и не имеет доступа к какой-то части данных. Для определения возможности получения логических выводов между вершинами A и B был построен алгоритм, показанный на рис. 3.




Рис. 3. Алгоритм определения возможности получения логических выводов из двух вершин, имеющих разные уровни права доступа

В соответствие с данным алгоритмом выполняются следующие основные операции:

- поиск общего потока информации между А и В на уровнях, которые меньше, чем  $t$ . Если между ними обнаружены общий поток информации, то операция прекращается.
- поиск общего потока информации между А и В на уровнях, которые меньше, чем  $cl$ . Если между ними обнаружены общий поток информации, то операция прекращается.

В данном алгоритме используется переменная R для сохранения получаемого результата: если  $R = true$ , то можно получить связь между А и В; если  $R = false$ , то нельзя получить связь между А и В.

*Определение 5 (несанкционированный логический вывод).* В семантической базе данных для любого пользователя  $s$ , имеющего уровень доступа  $AC_s$ , несанкционированным логическим выводом является процесс добавления дополнительного ребра  $e$  к видимому графу  $G_s$ , где  $e \in G \setminus G_s$ .

Из этого определения следует, что вывод является нарушенным только в случае, когда полученная связь между вершинами находится в невидимой части данных.

*Определение 6 (обнаружение нарушения логических выводов).* Обнаружение нарушения логических выводов является процессом поиска всех связей, находящихся в невидимой части графа  $G \setminus G_s$ .

### 2.3. АЛГОРИТМ ОБНАРУЖЕНИЯ НАРУШЕНИЯ ЛОГИЧЕСКИХ ВЫВОДОВ

Для конкретного уровня права доступа пользователей, после обнаружения выводов, все связи будут разделены на два типа: раскрытые связи (могут являться несанкционированными логическими выводом) и безопасные связи (не могут являться несанкционированными логическими выводом).

Для обнаружения несанкционированных логических выводов был построен алгоритм (алгоритм 3), включающий следующие шаги:

1. Определение видимых частей графа пользователем: Определение связей, у которых уровень меньше, чем уровень доступа пользователя [1]. Определение связей, у которых

уровень больше, чем уровень доступа пользователя, эти связи будут отмечены.


2. Применение основных логических правил для получения логических графов  $G^l_s$ . Если логические выводы находятся в невидимых частях графа, то эти связи являются раскрытыми, и они будут отмечены. После этого процесса, остальные связи, имеющие высокий уровень безопасности (не находятся в невидимых частях графа), называются обычными связями.

3. Применение правил 1 для отмеченных вершин логического графа  $G^l_s$ , если существует одна или несколько связей между двумя вершинами, то возможно, с некоторой вероятностью, применять логические правила. Если невозможно получить вывод на более высоком уровне безопасности между двумя вершинами, то все связи между ними являются *безопасными*. Если возможно получить вывод на более высоком уровне безопасности между двумя вершинами, то все связи между ними являются *подозреваемыми*.

4. Если существуют *подозреваемые связи*, то необходимо использовать теорию вероятностей для расчёта вероятности их выполнения. Такая возможность называется *вероятностным выводом*. Если вероятность вывода больше или равна заданной вероятности  $p$  (пороговое значение), то эти подозреваемые связи помечены как раскрытые связи, в противном случае они помечаются как безопасные связи.

На рис. 4 показан алгоритм обнаружения нарушения логических выводов. В данном алгоритме множество всех связей, имеющих более высокие уровни безопасности, чем уровень доступа пользователя  $AC_s$ , обозначено, как  $E_h$ , где  $E_h = \{e_i : e_i \in G \setminus G_s, \text{ где } e_i \text{ является ребром}\}$ , а множества всех раскрытых и безопасных связей, имеющих высокие уровни безопасности, обозначаются, как  $E_d$  и  $E_{sa}$ .

С помощью данного алгоритма могут быть определены все безопасные и раскрытые связи. Пользователь не может получить логический вывод только в случае, когда все вершины, влияющие на данные связи, отмечены как невидимые.



*Рис. 4. Алгоритм обнаружения нарушения логических выводов*

### **3. Пример применения предложенного алгоритма для решения задачи**

Имеется семантическая база данных, которая содержит множество триплетов со своими индексами безопасности  $R = \{R^1_{AoB}(0100), R^5_A(0110), R^9_{AoB}(1100), R^8_{ABo}(0000), R^9_{AoE}(1111), R^1_{BoBE}(0000), R^2_{BCo}(1110), R^6_{CoB}(0100), R^3_{CoB}(1100), R^7_{DoC}(0110), R^{10}_D(1100), R^4_{DEo}(1110)\}$ , где  $R^y_{AoS}(S, P, PS, C)$  означает, что  $R$  является утверждением о том, что элемент  $A$  связан с элементом

В использованием бинарного отношения у, R имеет индекс безопасности AC = (S, P, PS, C), включающий следующие 4 показателя:

- *чувствительность S* – определяет уровень значимости или важности связи (предиката), а также её уязвимости перед несанкционированным лицом;
- *приватность P* – определяет права владельца на возможность передачи данной информации другим пользователям;
- *персональная безопасность PS* – определяет уровень защиты персональной информации человека или организации;
- *конфиденциальность C* – задаёт возможность совместного использования данной информации с другими ресурсами.

Каждый показатель S, P, PS, C может принимать значения из множества меток безопасности L = {неклассифицированный ( $L_U$ ), конфиденциальный ( $L_C$ ), секретный ( $L_S$ ) и сверхсекретный ( $L_{TS}$ )}, где  $L_U < L_C < L_S < L_{TS}$ . В данной задаче предлагается, что эти показатели могут принимать значение 0 (unclassified), 1 (confidential). Право доступа пользователей  $AC_s = (S_s, P_s, PS_s, C_s)$  к данным так же включает 4 показателя: чувствительность, приватность, персональная безопасность и конфиденциальность. В данной задаче предлагается, что пользователь имеет уровень доступа  $AC_s = (1100)$ .




Рис. 5. Граф связи между элементами триплетов в базе данных

На рис. 5 показан данный фрагмент RDF-графа. Элементы множества отношений  $\{X_1, X_2, \dots, X_{10}\}$  базы данных обладают следующими свойствами:  $X_1$  является симметричной связью,  $X_3$  является транзитивной связью,  $\langle X_6, X_8 \rangle$  является доминирующим правилом, (в данной задаче  $R^6_{BC} \rightarrow R^8_{BC}$ ).  $\langle X_9, X_5 \rangle$  левое доминирующее правило, т. е., если  $R_i$  левое доминирующее  $R_j$ , то  $xR_iy \rightarrow xR_jx, x \neq y$ ; (в данной задаче,  $R^9_{AoB} \rightarrow R^5_A$ ).

Требуется применить алгоритм 3 для решения задачи безопасности семантической базы данных.

#### Решение

Шаг 1: определение видимых триплетов (граф  $G_s$ ).

При прямой проверки права доступа пользователя, нельзя увидеть триплеты  $R^5_A(0110)$ ,  $R^9_{AoE}$  (1111),  $R^4_{DEo}(1110)$ ,  $R^7_{DoC}(0110)$ ,  $R^2_{BCo}(1110)$ , потому что их уровень доступа меньше, чем уровень безопасности триплетов.

Шаг 2: определение логических и видимых триплетов (граф  $G_s^1$ ).




Рис. 6. Логический граф

По заданным правилам  $A^9_{AB}$  доминирует над  $R^5_A$  и  $R^6_{CB}$  доминирует над  $R^8_{CB}$ , получим логический граф, представленный на рис 6.

Шаг 3: определение раскрытых, безопасных и подозреваемых триплетов.

Один из двух логических результатов  $R^5_A$  является нарушенным триплетом, потому что  $R^5_A \in G \setminus G_s$ . Тогда получаются: раскрытая связь  $R^5_A$  и неясные связи  $R^9_{AoE}(1111)$ ,  $R^4_{DEo}(1110)$ ,  $R^7_{DoC}(0110)$ ,  $R^2_{BC}(1110)$ . Для контроля неясных связей, необходимо проверить такие пары вершин, как:  $\{<A, E>, <D, E>, <D, C>, <C, B>\}$ .

Так как известно, что:

- $C(A) \cap C(E) \neq \emptyset$  (между вершинами A и E существует общая вершина B), значит из них могут следовать другой триплет;
- $C(D) \cap C(E) = \emptyset$ , значит из них не могут прямо следовать другой триплет;
- $C(D) \cap C(C) = \emptyset$ , значит из них не могут следовать другой триплет;
- $C(B) \cap C(C) \neq \emptyset$ , значит из них могут следовать другой триплет.

После этого шага получается множество нарушенной связи  $\{R^5_A\}$ , множество безопасных связей  $\{R^4_{DEo}(1110), R^7_{DoC}(0110)\}$  и множество подозреваемых связей  $\{R^9_{AoE}(1111), R^2_{BC}(1110)\}$ .

Шаг 4: контроль наследованных триплетов.

Контроль первой подозреваемой связи  $R^9_{AoE}(1111)$  между вершинами A и E:

Основными триплетами, не влияющими на подозреваемую связь  $R^9_{AoE}(1111)$ , являются  $\{R^3_{CB}, R^6_{CB}, R^8_{CB}\}$ . Основными триплетами, влияющими на подозреваемую связь  $R^9_{AoE}(1111)$ , являются  $\{R^1_{AB}, R^9_{AB}, R^8_{AB}, R^8_{BE}\}$ .

Тогда можно определить пары наследования  $\{R^1_{AB}, R^1_{BoE}\}$ ,  $\{R^9_{AB}, R^1_{BoE}\}$ ,  $\{R^8_{AB}, R^1_{BoE}\}$ . Из этих пар пользователь может наследовать  $R^9_{AoE}$ , с некоторой вероятностью.

Для того, чтобы пользователь абсолютно не смог наследовать  $R^9_{AoE}$ , в этих парах не должен присутствовать один из

элементов. В этом случае, пользователю нельзя видеть триплет  $R_{\text{BoE}}^1$ , или триплеты  $\{R_{\text{AB}}^1, R_{\text{AB}}^9, R_{\text{ABo}}^8\}$ .

Контроль второй подозреваемой  $R_{\text{BC}}^2$ :

Связи  $R_{\text{AB}}^1, R_{\text{AB}}^8, R_{\text{AB}}^9, R_{\text{BC}}^1$  являются не связанными с подозреваемой связью  $R_{\text{BC}}^2$ . Связи  $R_{\text{CB}}^3, R_{\text{CB}}^6, R_{\text{CB}}^8$  являются триплетами, связанными с подозреваемой связью  $R_{\text{BC}}^2$ . Из этих триплетов пользователь может наследовать  $R_{\text{BC}}^2$  с какой-то вероятностью. Для того чтобы пользователь абсолютно не мог наследовать  $R_{\text{BC}}^2$ , для него должны быть невидимыми триплеты  $R_{\text{CB}}^3, R_{\text{CB}}^6, R_{\text{CB}}^8$ .

## ***Выводы***

Сложность работы с семантическими базами данных заключается в том, что на основе полученных результатов можно делать логические выводы, позволяющие пользователям получать не разрешенные для него данные. В связи с этим при поддержке работы пользователей с такими базами данных необходимо выполнять управление логическими выводами на получаемых результатах.

Решение данной задачи возможно путем использования предложенного в статье алгоритма определения возможности получения логических выводов из двух вершин, имеющих разные уровни права доступа. Корректное использование разработанного алгоритма гарантирует защиту информации семантических баз данных

## ***Литература***

1. ДЕВЯНИН П. Н. *Анализ безопасности управления доступом и информационными потоками в компьютерных системах*. — М.: Радио и связь, 2006. — 176 с.
2. ДЕВЯНИН П. Н. *Модели безопасности компьютерных систем*. — М.: Академия, 2005. — 144 с.
3. MORGESTERN, M. A. Controlling logical inference in multilevel database systems - On Security and privacy, 1998. — 245 p.

4. THURAISINGHAM, B. H. *Building trustworthy semantic webs, Technical Report*, University of Texas – Department of Computer Science, 2008. – 434 p.

## CONTROL INFERENCE IN SEMANTIC DATABASES

**Hoang Van Quyet:** National Research Tomsk Polytechnic University, postgraduate (student8050@sibmail.com).

*Abstract: This paper proposes method for controlling access to semantic database. Two problems of access control were identified: direct access control and inference control. The basic definitions of relations between objects in the semantic data are concerned. A method of controlling unauthorized inferences is created.*

Keywords: Semantic data, triple, inference control, unauthorized access.