

# Кластеризация семантических знаний в задаче распознавания ситуаций смысловой эквивалентности.

Д. В. Михайлов, Г. М. Емельянов

Новгородский Государственный Университет имени Ярослава Мудрого

## Цель.

*Разработка и исследование методов формирования прецедентов для классов Семантической Эквивалентности (СЭ) высказываний Естественного Языка (ЕЯ).*

## Задачи исследования.

- 1) Разработка и исследование методик формализации смысла слова как характеристики его Лексического Значения (ЛЗ) для заданного класса СЭ.
- 2) Построение формального аппарата математического моделирования процесса обобщения независимых формализованных описаний толкований ЛЗ слова как основы выделения его смысла.
- 3) Разработка математической модели процесса выявления и обобщения Смыслового Отношения (СО) в рамках Расщепленного Значения при формировании прецедентов СЭ для ситуаций использования Лексических Функций-параметров.
- 4) Разработка и совершенствование методов анализа корректности толкований ЛЗ как исходных данных для формирования прецедентов.
- 5) Апробация полученных методик для известных в лингвистике классификаций СЭ.

# Формирование классов СЭ для ситуаций синонимии в рамках стандартных Лексических Функций.

**Дано :**

$\Pi^R$  — множество правил синонимических преобразований ЕЯ-высказываний;

$L^\Pi$  — множество пар ЕЯ-высказываний, между которыми возможно установление синонимии (относительно  $\Pi^R$ );

$r(\pi)$  — условие применимости  $\pi \in \Pi^R$ . Для  $T = \{T_1, T_2\} : T \in L^\Pi$   $r(\pi)$  есть совокупность требований к  $\forall w_i \in W, W = W_1 \cup W_2, W_1 \subset T_1, W_2 \subset T_2, W_1$  и  $W_2$  — совокупности слов, заменяемых посредством  $\pi$ ;

$Lm^W$  — множество формализованных толкований ЛЗ слов  $w_i \in W$  в виде теорий.

**Требуется :**

- Применительно к  $\forall r(\pi)$  выделить множество значимых признаков для  $\forall w_i \in W$  анализом  $Lm(w_i), Lm(w_i) \in Lm^W$ ;
- На основе выделенных признаков либо отнести предъявляемую произвольную пару  $T$  к одному из известных классов  $\pi \in \Pi^R$  СЭ, либо образовать с помощью  $T$  новый класс.

## Ситуация СЭ на основе расщепленного значения.

**Определение 1.** *Расщепленное Значение (РЗ) :*

- Описывается комплексом  $W_j, j \in \{1, 2\}$  лексических единиц :  $\forall w_i \in W_j$  либо является значением некоторой Лексической Функции (ЛФ)  $F$  для ключевого слова  $C0$ , определяющего ситуацию СЭ, либо есть само  $C0$ ;
- $\exists w_i \in W_j : w_i = F_i(C0)$  и  $F_i$  относится к классу Лексических Функций-параметров;
- Может быть выражено одним словом, представляющим собой значение некоторой ЛФ-замены для данного  $C0$ , либо само  $C0$ .

**Замечание.** *Формирование  $r(\pi)$  для ситуации СЭ на основе РЗ предполагает наряду с формализацией требований к смыслу слов из  $W$ , выявление и обобщения Смыслового Отношения между  $\forall w_i \in W$  и  $\forall w_m \in W, w_m \neq w_i$  :*

- $w_i = F_i(C0)$ , где  $F_i$  — некоторая ЛФ-параметр для заданного  $C0$ ;
- $w_m = F_m(C0)$ , где  $F_m$  — некоторая ЛФ-замена для заданного  $C0$ , либо  $w_m = C0$ .

**Пример.** *РЗ «осуществлять эксперимент», где значением ЛФ  $Oper_1$  задается  $C0$  типа «операция с...» между 1-м участником ситуации СЭ (кто осуществляет эксперимент) и ее названием («эксперимент»). Данное РЗ эквивалентно ЛЗ «экспериментировать».*

# Смысл как набор формальных атрибутов Лексического Значения.

Пусть для  $\forall w_i \in W_j, W_j \subset T_j, T_j \in T, T \in L^\Pi$  имеется описание теории ЛЗ :

$$Lm(w_i) = (w_i, L^M), \quad (1)$$

совокупностью бинарных отношений  $R_2$  между понятиями  $C_1$  и  $C_2$  :

$$M_p = (R_2, C_1, C_2), \quad (2)$$

а также рекурсивно определяемых отношений произвольной арности :

$$M'_p = (R_n, C, L^M) \text{ и} \quad (3)$$

$$M''_p = (R_c, L^M) \quad (4)$$

Здесь  $L^M$  — список структур (2), (3) и (4),  $R_c \in \{\vee, \&, \neg\}$ . Посредством  $L^M$  в (3) задается связь понятия  $C$  с другими словами и понятиями.

**Определение 2.** Если  $\exists Lm(w_i) = (w_i, L^M)$  (1), то смысл  $\forall w_i \in T$  определяется набором Характеристических Функций (ХФ)  $\{ChF_{hi}\}$  :

- $\exists M_p = (R_2, C_1, C_2) =: ChF_{Val} : M_p \in L^M$  (2),  $ChF_{hi}(w_i) = C_2 : C_2$  — обозначение известного системе понятия (Семантического Класа (СК)).  $L^M$  может быть третьим аргументом (3);
- $\exists M_p = (ChF_{hi}, C'_1, C'_2) =: ChF_{Name}$ , либо  $\exists M'_p = (ChF_{hi}, C, L^M) =: ChF_{Name} : ChF_{hi}$  — имя известного СК или СО;
- $ChF_{Name}$  — первое из удовлетворяющих вышеуказанному условию при обратном просмотре  $L^M$  от  $ChF_{Val}$ . Обозначим  $L^{M'} \in L^M$  : либо  $L^{M'} = \{(ChF_{hi}, C'_1, C'_2), \dots, (R_2, C_1, ChF_{hi}(w_i))\}$ , либо  $L^{M'} = \{(ChF_{hi}, C, L^M)\}$ ,  $M_p = (R_2, C_1, ChF_{hi}) \in L^M$ ;
- каждое последующее утверждение в  $L^{M'}$  должно иметь как минимум один общий аргумент, являющийся обозначением некоторой переменной, с предыдущим утверждением.

# Пример формирования набора ХФ для заданного ЛЗ.



Рис. 1. Анализируемый вариант теории ЛЗ



Рис. 2. Характеристические Функции и формальные признаки их значений

Здесь  $Var\_SomeBody$  обозначает переменную для слова, интерпретируемого посредством  $\bar{1}$ . Она же является вторым аргументом для  $ChF_{Name}$ .

## Модель системы независимых теорий Лексического Значения.

$$K = (G, M, V, I) \quad (5)$$

Здесь :

$G$  — множество объектов.  $\forall g \in G : g = Lm_j(w_i)$  есть  $j$ -й вариант толкования ЛЗ  $w_i$  в форме (1);

$M$  — множество признаков.  $M = M_1 \cup M_2$ , где  $\forall m \in M_1 : m = ChF_{hi}(w_i)$ , а  $\forall m \in M_2 : \exists ChF_{hi}(w'_i) : Lm(w'_i) = (w'_i, L^{M'}) : \exists (R''_2, C''_1, C''_2) \in L^{M'}$ , где  $R''_2$  — имя известного СК или СО, причем  $m = R''_2$ ;

$V$  — множество значений признаков.  $V = V_1 \cup V_2$ , где  $\forall v \in V_1$  есть имя Характеристической Функции  $ChF_{hi}$ , причем задано ее значение  $ChF_{hi}(w_i)$  для  $w_i$ , а  $\forall v \in V_2$  есть значение  $ChF'_{hi}(w'_i)$  Характеристической Функции  $ChF'_{hi}$  для  $w'_i$ ;

Тернарное отношение  $I \subseteq G \times M \times V$  задает частичное отображение  $G$  на  $V : m(g) = v$ , ставит в соответствие каждой ХФ ее значение для заданного  $w_i$ .

# Решетка Формальных Понятий для Лексического Значения.

**Определение 3.** Под Формальным Понятием (ФП) для (5) понимается пара  $(X, Y) : X \subseteq G, Y \subseteq M \times V, X = Y', Y = X'$ , причем

$$X' = \{(m, v) : m \in M, v \in V \mid \forall g \in X : m(g) = v\},$$

$$Y' = \{g \in G \mid \forall (m, v) \in Y : m(g) = v\}$$

**Определение 4.** ФП  $(X_1, Y_1)$  является подпонятием для ФП  $(X_2, Y_2)$ , если  $X_1 \subseteq X_2$ , а  $Y_2 \subseteq Y_1 : (X_1, Y_1) \leq (X_2, Y_2)$ . При этом  $(X_2, Y_2)$  называют суперпонятием для ФП  $(X_1, Y_1)$ , а отношение  $\leq$  — отношением порядка для ФП.

**Определение 5.** Множество  $\mathfrak{R}(G, M, V, I)$  всех ФП контекста (5) вместе с отношением  $\leq$  называется решеткой Формальных Понятий.

**Определение 6.** Пусть  $N \subset \mathfrak{R}(G, M, V, I)$ . ФП  $(X, Y)$  называется Наименьшим Общим Суперпонятием (НОСП) для  $N$ , если  $(X_i, Y_i) \leq (X, Y)$  для  $\forall (X_i, Y_i) \in N$  и  $\nexists (X_1, Y_1) \in \mathfrak{R}(G, M, V, I) \setminus N : (X_1, Y_1) \leq (X, Y)$  и  $(X_i, Y_i) \leq (X_1, Y_1)$  для  $\forall (X_i, Y_i) \in N$ . Аналогично определяется Наибольшее Общее Подпонятие (НОПП) для  $N$ .

**Определение 7.** Под областью в решетке Формальных Понятий для (5) понимается набор ФП, связанных отношением  $\leq$  с одним НОПП и/или одним НОСП.

**Замечание.** В настоящей работе для областей вводится требование единственности как НОПП, так и НОСП.

Пример построения формального контекста для независимых толкований заданного Лексического Значения выделением множества Характеристических Функций.

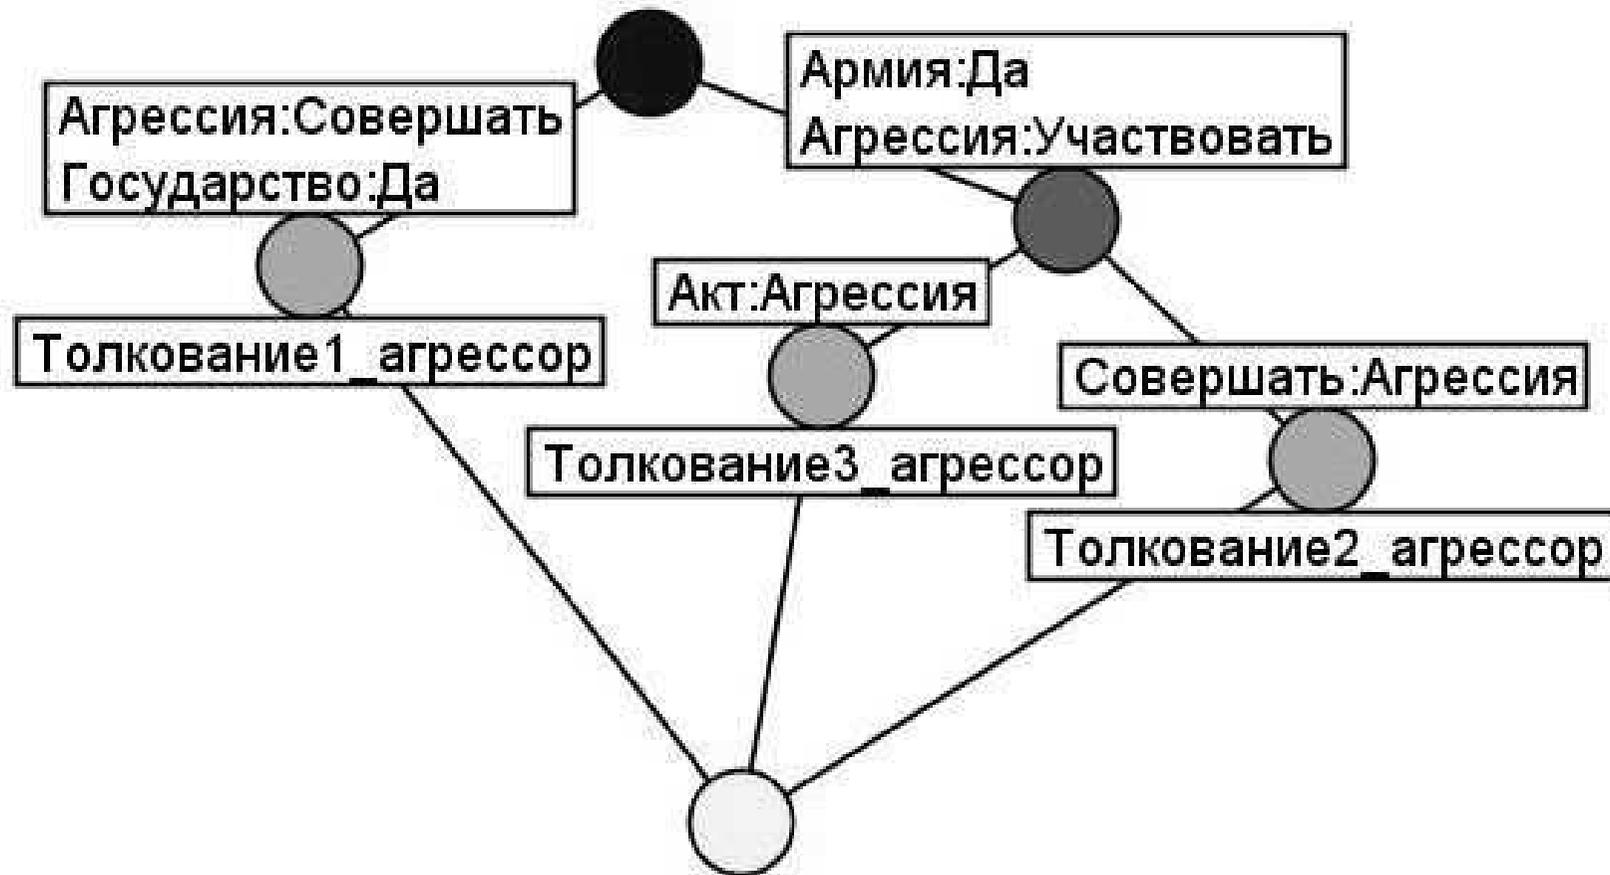


Рис. 3. Формализованные толкования для ЛЗ «агрессор»

## Обобщение утверждений независимых теорий ЛЗ.

**Утверждение 1.** Утверждения  $(R_n, C, L_1^M)$  и  $(R_n, C, L_2^M)$  вида (3) могут быть представлены одним утверждением :

$$(R_n, C, \{(\text{«или»}, L_3^M)\}),$$

если наборы ФП, полученные на основе  $L_1^M$ ,  $L_2^M$  и  $L_3^M$  образуют области  $\mathfrak{R}(G_1, M_1, V_1, I)$ ,  $\mathfrak{R}(G_2, M_2, V_1, I)$  и, соответственно,  $\mathfrak{R}(G_3, M_3, V_1, I)$  с НОСП, которое имеет  $R_n$  в качестве значения признака. При этом :

$$G_1 = \{(w'_i, L_1^M)\}, G_2 = \{(w''_i, L_2^M)\}, M_1 \neq M_2, M_3 = M_1 \cup M_2,$$

$$\mathfrak{R}(G_3, M_3, V_1, I) = \mathfrak{R}(G_1, M_1, V_1, I) \cup \mathfrak{R}(G_2, M_2, V_1, I).$$

**Утверждение 2.** Утверждения  $(R_n, C, L_1^M)$  и  $(R_n, C, L_2^M)$  вида (3) могут быть представлены одним утверждением :

$$R_n, C, \{(\text{«и»}, L_3^M)\},$$

если на основе  $L_1^M$ ,  $L_2^M$  и  $L_3^M$  определяются ФП  $(X, Y_1)$ ,  $(X, Y_2)$  и  $(X, Y_3)$  :  $Y_3 = Y_1 \cup Y_2$ .

**Замечание.** Согласно Определению 2, внешне различные описания теорий (1) одного и того же ЛЗ задают единое множество Характеристических Функций. Следовательно, мощность  $n$  множества ХФ для заданного ЛЗ не зависит от количества  $k$  обобщаемых теорий. Вычислительная сложность процесса обобщения теорий для заданного ЛЗ составляет  $O\left(\frac{n}{k}\right)^k$ . Поскольку  $k \in [1, \dots, n]$ , то  $O\left(\frac{n}{k}\right)^k = n$  при  $k = 1$  и  $O\left(\frac{n}{k}\right)^k = 1$  при  $k = n$ .

# Пример обобщения независимых теорий заданного ЛЗ.

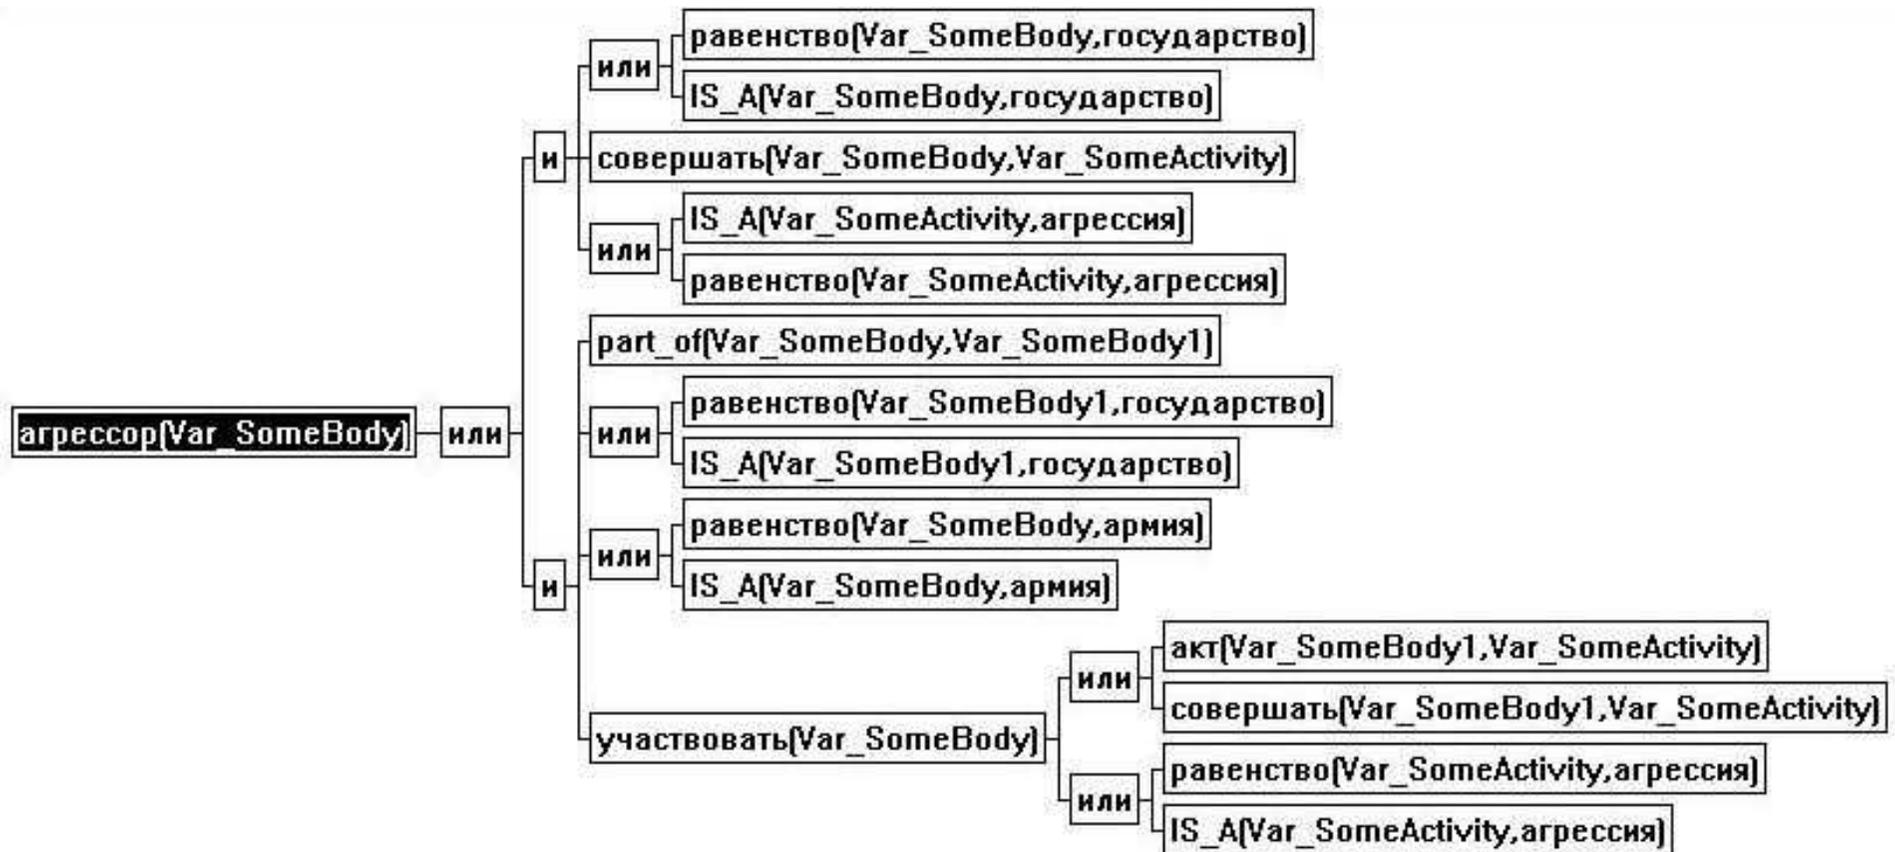


Рис. 4. Обобщенная теория ЛЗ «агрессор»

## Смысловое отношение в рамках Расщепленного Значения.

Пусть :

$\Pi^R$  — множество правил синонимических преобразований ЕЯ-высказываний;

$L^\Pi$  — множество пар ЕЯ-высказываний, между которыми возможно установление синонимии (относительно  $\Pi^R$ );

$T = \{T_1, T_2\} : T \in L^\Pi$ .

**Утверждение 3.** *Смысловое отношение  $F$ , значимое для формирования  $r(\pi)$ , между некоторым словом  $w_1 \in T_1$  и его лексическим коррелятом  $w_2 \in T_2$ , входящим в РЗ, будет иметь место тогда, когда*

$$L_1^M = L_{11}^M \cup \{(F, C, L_{22}^M)\} \cup L_{12}^M,$$

$$L_2^M = L_{11}^M \cup L_{22}^M \cup L_{12}^M,$$

$$L_{11}^M \cap L_{22}^M = \emptyset, L_{11}^M \cap L_{12}^M = \emptyset, L_{12}^M \cap L_{22}^M = \emptyset,$$

где  $L_1^M$  — набор утверждений теории ЛЗ для  $w_1$ , а  $L_2^M$  — для  $w_2$ .

Пример — теории ЛЗ «эксперимент» и «экспериментировать», Рис. 5.

# Пример использования Лексической Функции в качестве названия Смыслового Отношения в теории Лексического Значения.

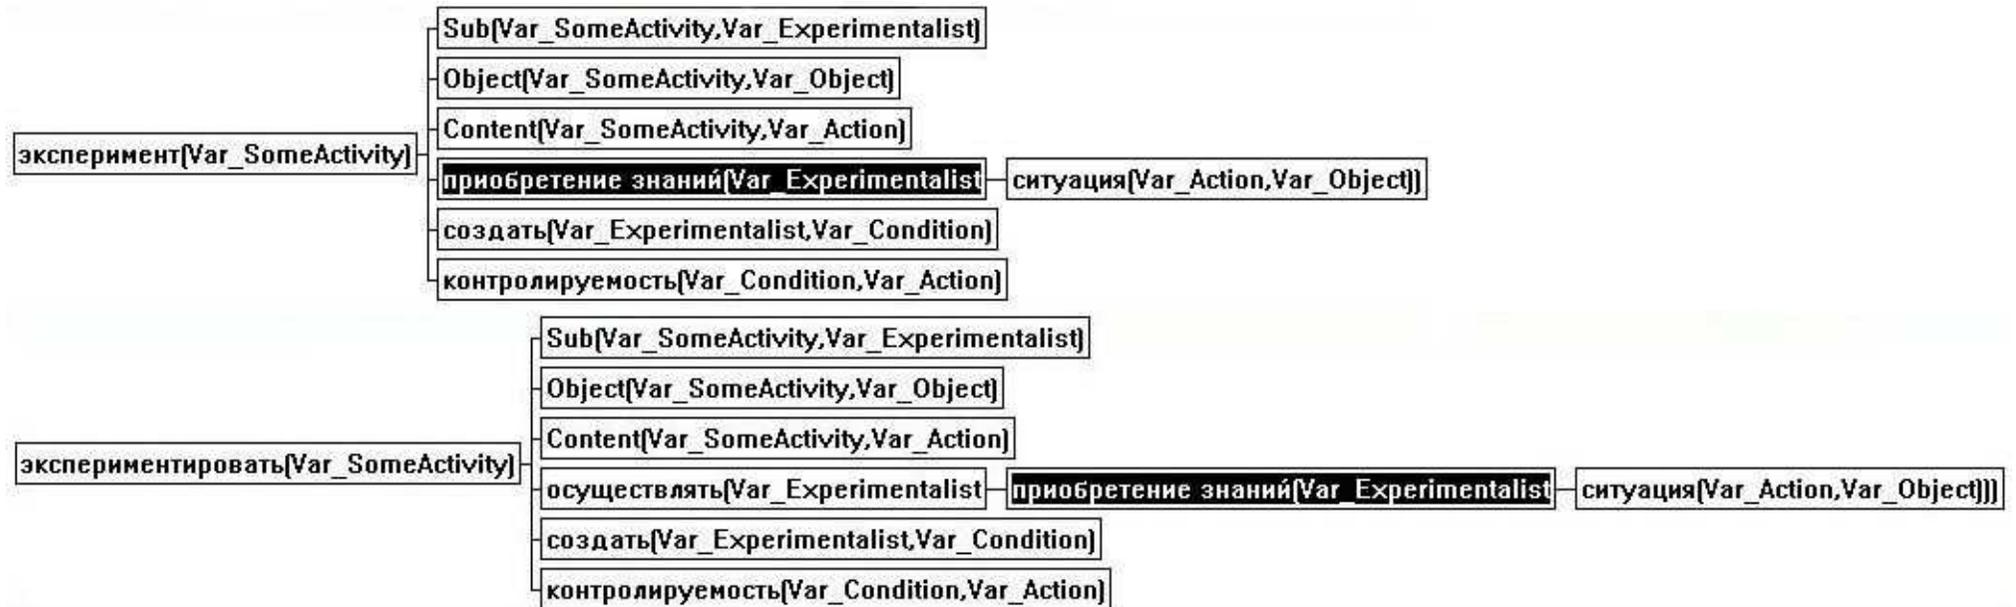


Рис. 5. Теории ЛЗ «эксперимент» и «экспериментировать»

## Формальный контекст для совокупности слов-аргументов Лексической Функции-параметра.

$$K^{LF} = (G^{LF}, M^{LF}, I^{LF}) \quad (6)$$

Здесь :

множество объектов  $G^{LF}$  есть множество ключевых слов-аргументов заданной Лексической Функции;

Множество формальных признаков  $M^{LF}$  есть множество слов-значений заданной Лексической Функции для слов из множества  $G^{LF}$ ;

Бинарное отношение  $I^{LF} \subseteq G^{LF} \times M^{LF}$  задает частичное отображение  $G^{LF}$  на  $M^{LF}$  и ставит в соответствие каждому ключевому слову  $C_0 \in G^{LF}$ , определяющему ситуацию СЭ, множество значений заданной Лексической Функции.



# Отношение порядка для Лексических Значений предикатных слов.

Пусть для  $\forall w_i$  (1) мы имеем описание ее СК  $C_i$  :

$$S_i^F = (C_i, L_i^{SF}, D_i, D'_i) : \quad (7)$$

- списком  $L_i^{SF}$  дескрипторов Семантических Характеристик (СХ) слова  $w_i$ , обозначающего сущность  $C_i$ , в последовательности «более общая СХ — более специфическая СХ»;
- дескрипторами таксономической категории  $D_i$  и ее подкласса  $D'_i$  для  $w_i$ .

Предположим также, что  $w_i$  обозначает некоторую ситуацию. При этом для  $w_i$  имеется описание характеризованного ролевого состава :

$$C^A = (C_i, L_i^R), \quad (8)$$

где  $\forall A_{ti} \in L_i^R$  включает название  $R_{ti}$  роли плюс список  $L_{ti}^C$  возможных Семантических Классов актанта :

$$A_{ti} = (R_{ti}, L_{ti}^C) \quad (9)$$

**Утверждение 4.** ЛЗ Семантического Класа  $C_1$  :

$$C_1^A = (C_1, L_1^R)$$

следует считать суперпонятием для ЛЗ Семантического Класа  $C_2$  :

$$C_2^A = (C_2, L_2^R)$$

при условии, что для  $\forall R_t : (R_t, L_{t2}^C) \in L_2^R \exists (R_t, L_{t1}^C) \in L_1^R$  : каждому  $C_{at1} \in L_{t1}^C$  можно поставить в соответствие  $C_{at2} \in L_{t2}^C$  : либо  $C_{at2} = C_{at1}$ , либо  $C_{at2}$  и  $C_{at1}$  связаны отношением  $IS\_A$ .

# Отношение порядка для случая зависимости между Семантическими Характеристиками предикатных слов.

**Утверждение 5.** ЛЗ  $w_i$  Семантического Класса  $C_i$  ( $\gamma$ ) :

$$S_i^F = (C_i, L_i^{SF}, D, D')$$

будет считаться суперпонятием для ЛЗ  $w_m$  Семантического Класса  $C_m$  :

$$S_m^F = (C_m, L_m^{SF}, D, D'), w_i \neq w_m,$$

если в дополнение к определенным Утверждением 4 условиям при отсутствии для  $A_{ai} = (R_{ai}, L_{ai}^C) : A_{ai} \in L_i^R, (8,9)$ , актанта подпонятия с показанным в Утверждении 4 соответствием набора возможных СК  $\exists A_{bm} = (R_{bm}, L_{bm}^C) : A_{bm} \in L_m^R$ , отвечающий нижеследующему требованию. При наличии

$$S_{qai}^F = (C_{qai}, L_{qai}^{SF}, D_{qai}, D'_{qai})$$

для  $\forall C_{qai} \in L_{ai}^C$  и, соответственно,

$$S_{sbm}^F = (C_{sbm}, L_{sbm}^{SF}, D_{sbm}, D'_{sbm})$$

для  $\forall C_{sbm} \in L_{bm}^C$  наряду с вхождением в  $L_{sbm}^{SF}$  СК из списка  $L_{qai}^{SF}$  некоторым СК  $SF_{pqai} \in L_{qai}^{SF}$  ставятся в соответствие теории (1) :

$$Lm_{pqai} = (SF_{pqai}, L_{pqai}^M),$$

причем  $\exists L_{sbm}^{SF'} \subset L_{sbm}^{SF} : \forall SF_{osbm} \in L_{sbm}^{SF'}$  является в составе  $L_{pqai}^M$  либо одним из аргументов структуры (2), либо первым аргументом структуры (3).

Пример : валентность аспекта у ЛЗ «испытание»  
и валентность содержания у ЛЗ «тест».

Имеем :

$w_i = \text{«ТЕСТ»}$ ,  $w_m = \text{«ИСПЫТАНИЕ»}$

$S_{qai}^F = (\text{«ситуация»}, [\text{«SITUAT»}], \text{«LABL»}, \text{«SIT»})$ ,

$S_{sbm}^F = (\text{«свойство»}, [\text{«ATTR»}], \text{«ASP»}, \text{«Не определена»})$ .

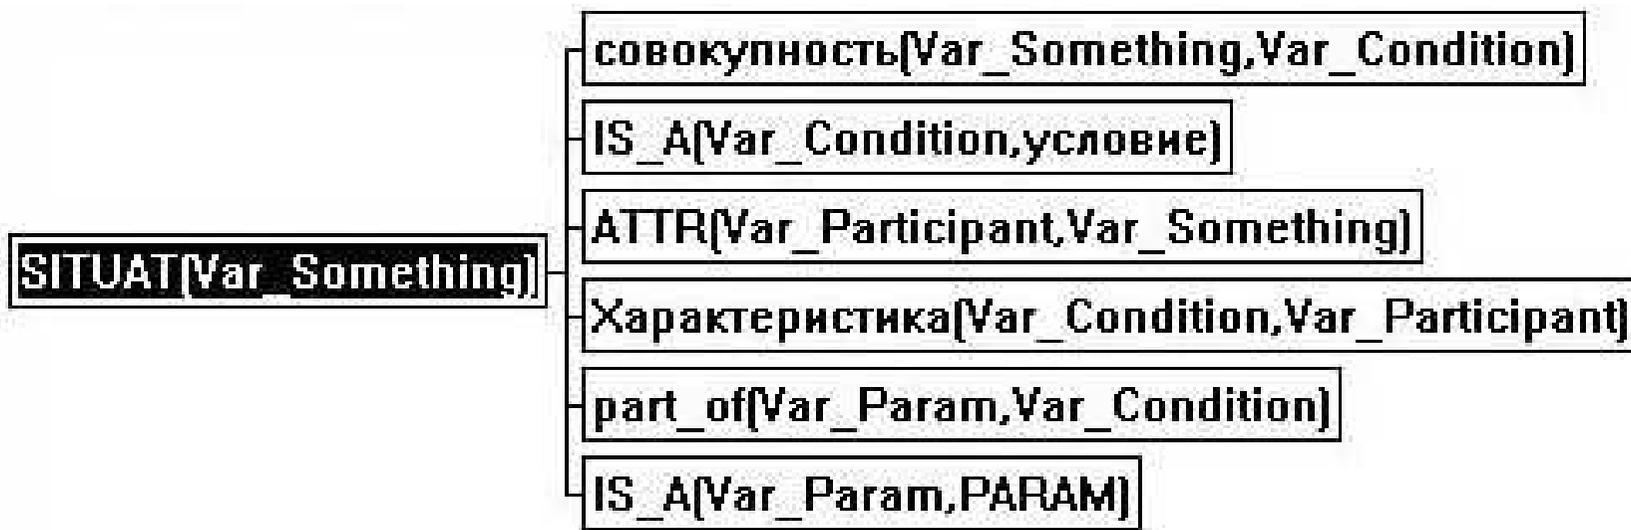


Рис. 7. Теория сорта «SITUAT»

# Расширенное отношение порядка для слов-аргументов ЛФ *Oper*<sub>1</sub>.

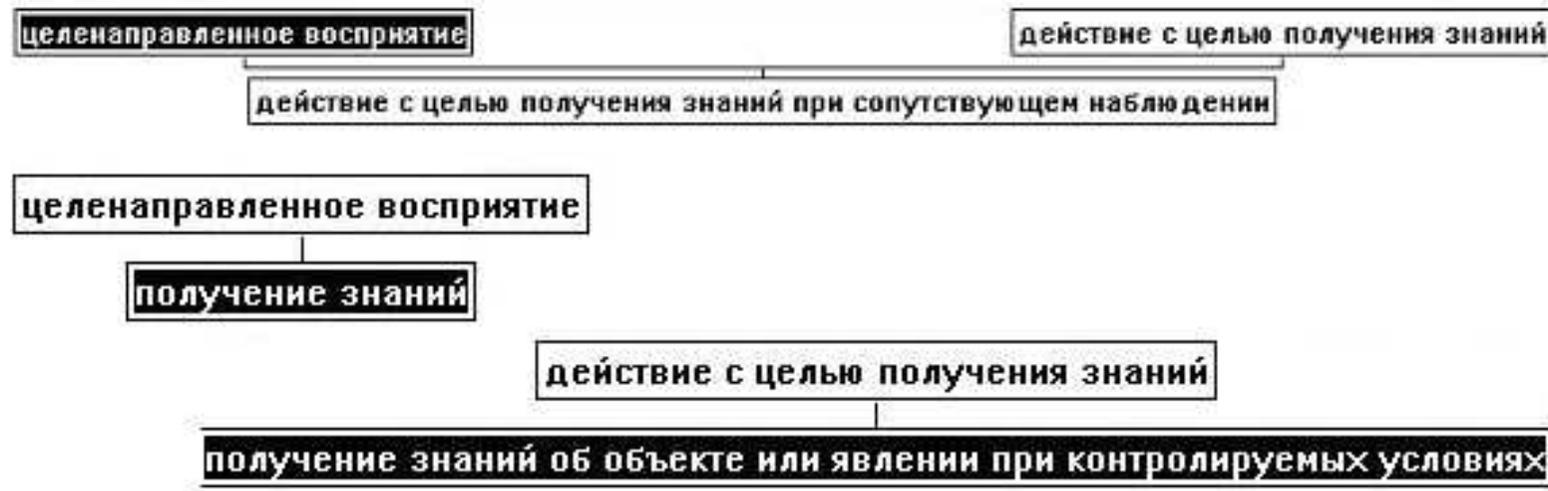


Рис. 8. СК слов окрестности ЛЗ «эксперимент»

Таблица 1. СК для слов окрестности ЛЗ «эксперимент»

| Слово       | Семантический класс   |
|-------------|---|
| эксперимент | получение знаний об объекте или явлении при контролируемых условиях |
| испытание   | действие с целью получения знаний при сопутствующем наблюдении      |
| изучение    | получение знаний  |
| тест        | действие с целью получения знаний                                   |
| наблюдение  | целенаправленное восприятие   |

## Критерий адекватности формирования прецедента.

Пусть для ЛЗ  $w_1 \in T_1$  и  $w_2 \in T_2 : T = \{T_1, T_2\}$ ,  $T \in L^\Pi$  имеются описания теорий  $Lm(w_1)$  и  $Lm(w_2)$  в соответствии с (1).

Кроме того, имеем :  $W^S : \forall w_i \in W^S$  обозначает некоторую ситуацию и  $w_i \in T_j$ ,  $j \in \{1, 2\}$ . Для  $\forall w_i \in W^S$  имеем описание характеризованного ролевого состава в форме (8).

**Утверждение 6.** Будем считать, что  $Lm(w_1)$  и  $Lm(w_2) : w_1 \in W^S, w_2 \in W^S$  адекватно задают  $r(\pi)$  в соответствии с Определением 1, если :

- на множестве  $W^S$  может быть определено отношение порядка в соответствии с условиями в Утверждениях 4 и 5;
- между  $w_1$  и  $w_2$  существует смысловое отношение  $F$  в соответствии с условиями, задаваемыми Утверждением 3;
- $F$  в составе формального контекста (6) принадлежит множеству формальных признаков того ЛЗ  $w_{Sup}$ , которое является в соответствии с Определением 6 Наименьшим Общим Суперпонятием для множества  $N^A$  слов верхней окрестности ЛЗ  $w_2$ ,  $N^A \subset \mathfrak{R}(G^A, M^A, V^A, I^A) :$

$G^A \supset W^S$  — множество ЛЗ предикатных слов,

$M^A$  — множество возможных ролевых ориентаций  $R_{ti}$  актантов (9) для обозначаемых предикатными словами  $w_m \in G^A$  ситуаций,

$V^A$  — множество всех множеств  $L_{ti}^C$  СК слов, способных замещать некоторую валентность  $R_{ti}$  (9) предикатного слова  $w_m \in G^A$ ,

$I^A \subseteq G^A \times M^A \times V^A$ .

Требования к РЗ с  $w_{Sup}$  определяются аналогично.

## Выводы.

- Описание смысла слова набором Характеристических Функций производится в шкале наименований. При обобщении утверждений независимых теорий одного и того же Лексического Значения посредством отношения «или» не учитывается статистическая значимость каждого признака. Значения Характеристических Функций, которые задаются объединяемыми утверждениями, полагаются равновероятными.
- Перспективным направлением дальнейших исследований является введение в рассмотрение распределений возможных значений Характеристических Функций. Это позволит вычислять меру близости между предикатами, описывающими Лексическое Значение слова в рамках  $r(\pi)$  и тем самым сократить объем обучающей выборки при формировании  $r(\pi)$ .
- Задействование Характеристических Функций при описании смысла слова и их выводимость из теории его Лексического Значения позволяет в перспективе ввести в рассмотрение родовидовые зависимости между теориями при описании  $r(\pi)$  для ситуаций СЭ на основе неточных синонимов, конверсивов и дериватов. Это позволит фиксировать различия в актантной структуре этих слов.