BIG DATA:
Технологии добычи данных

Кравченко Ю.А.

Цель исследования

- **повышение эффективности прикладных систем добычи данных на основе развития моделей, методов и алгоритмов семантического поиска, классификации, кластеризации, структурирования и интеграции данных.**

Объект и предмет исследования

Объект исследования

процессы добычи данных в условиях big data

Предмет исследования

теоретические основы разработки моделей, методов и алгоритмов добычи данных

Инфографика схемы роста объемов информации

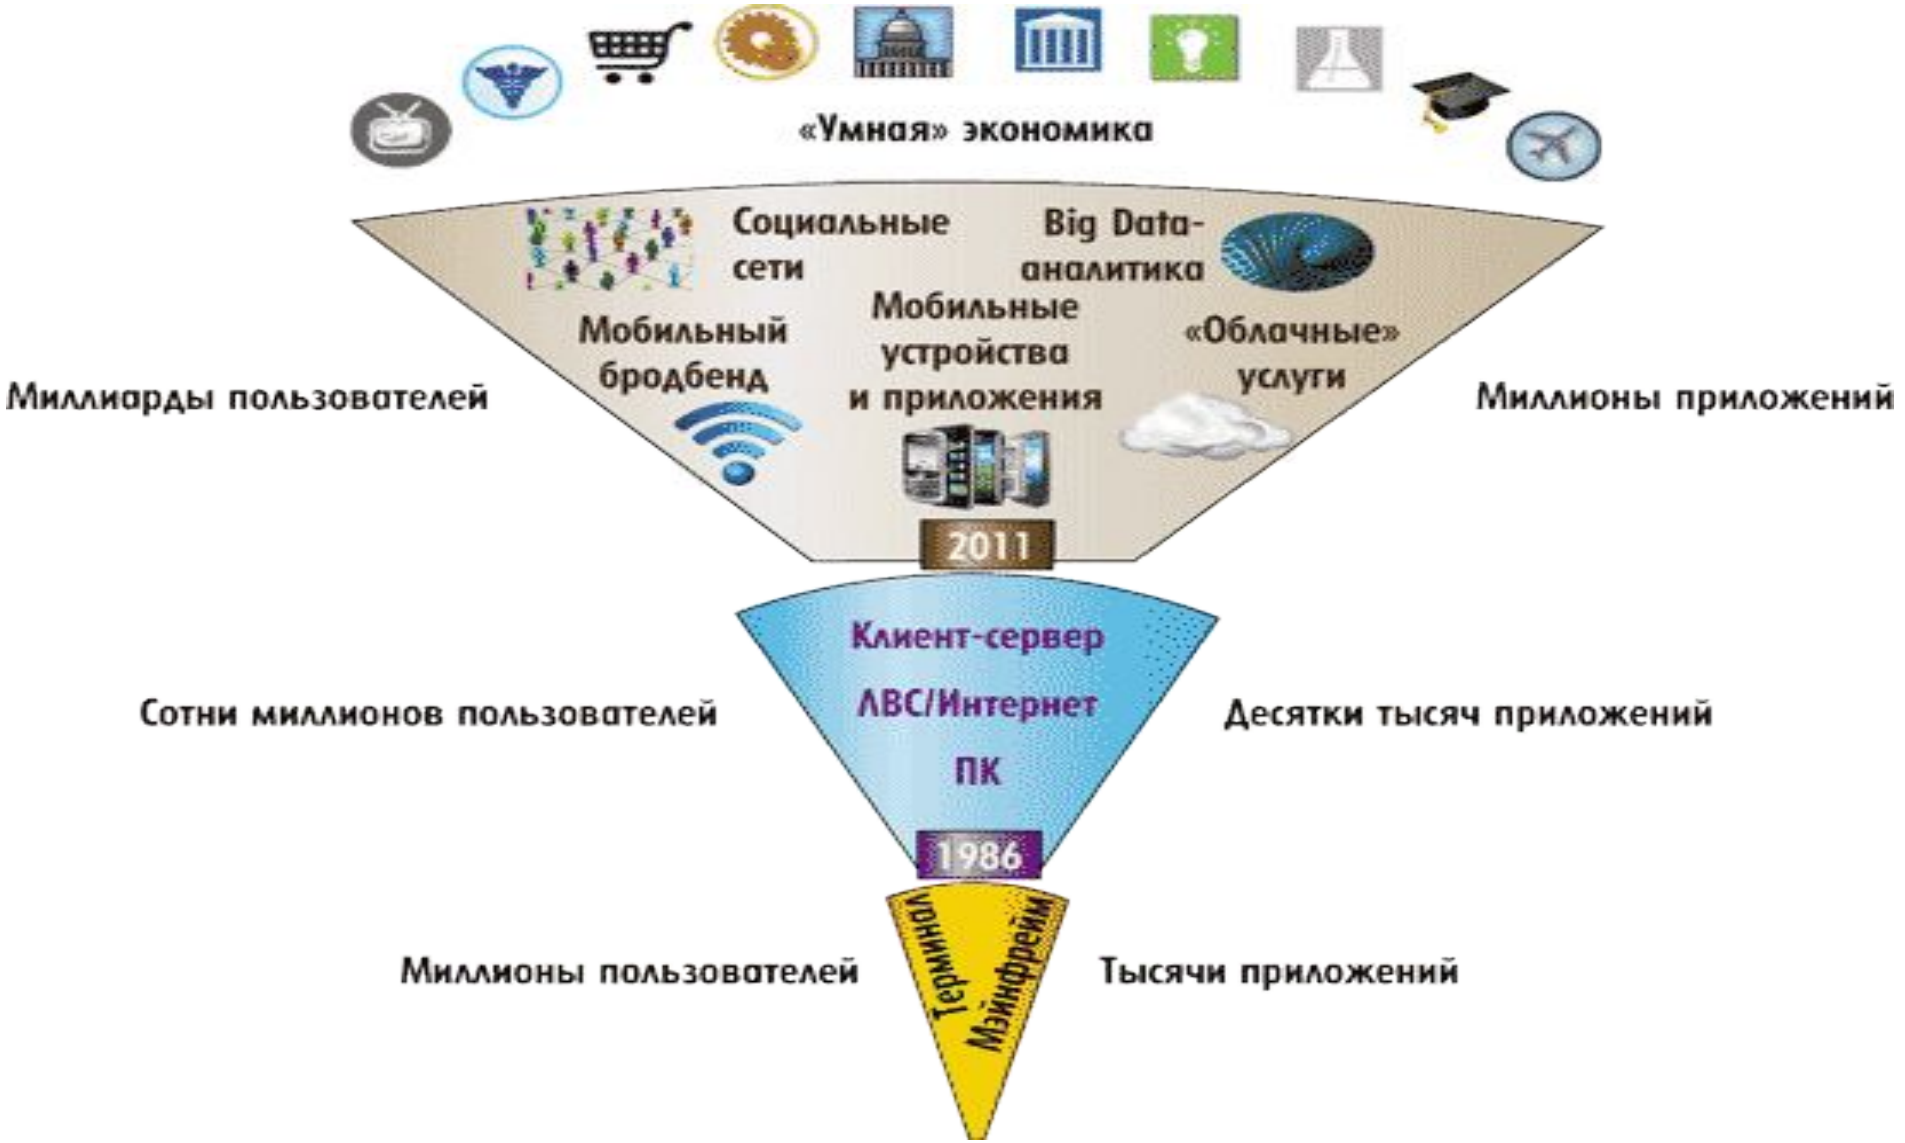

Рост объемов данных

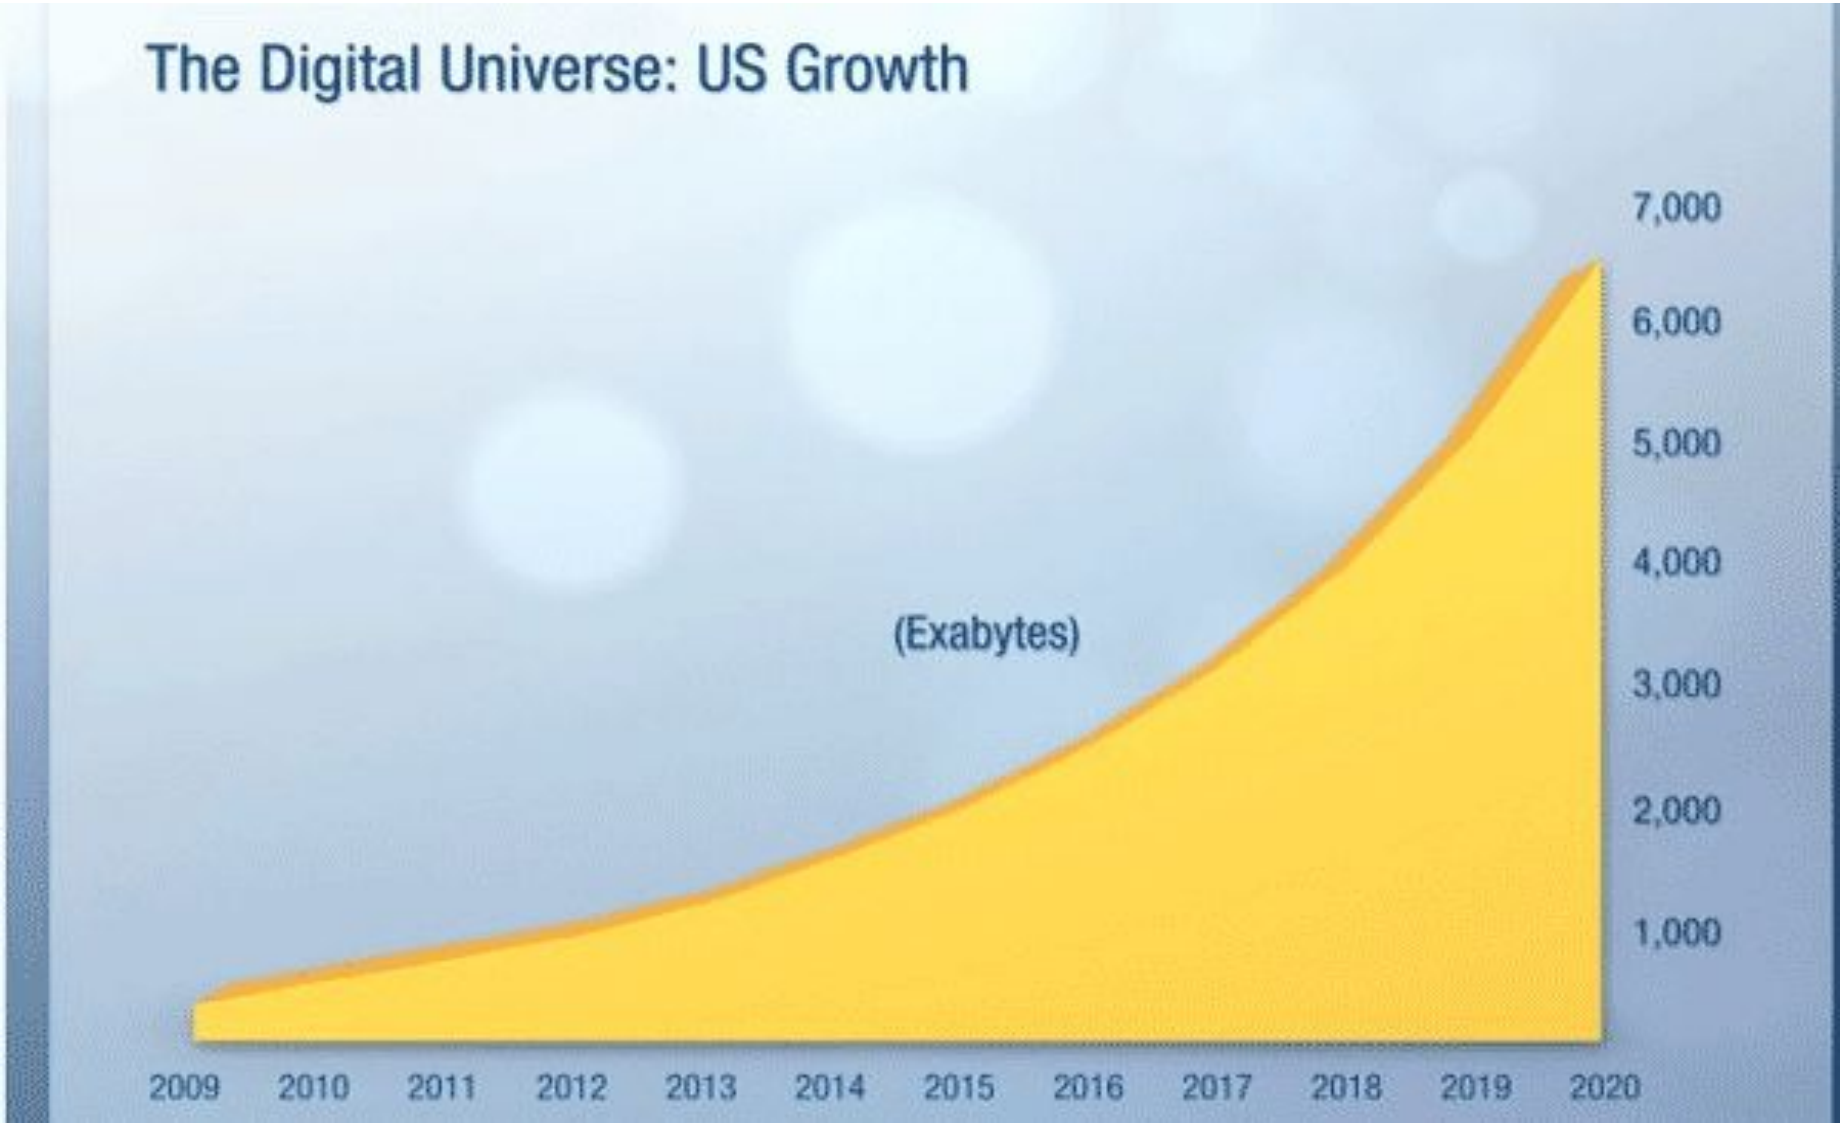

Векторная репрезентация слов

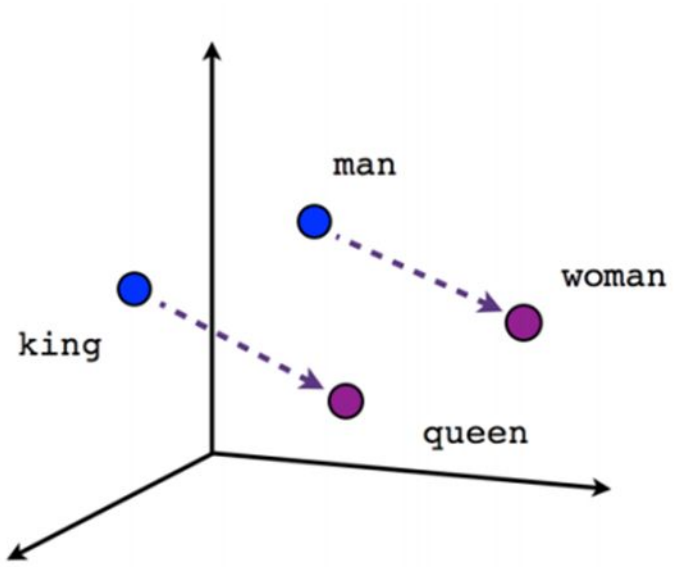

Male-Female

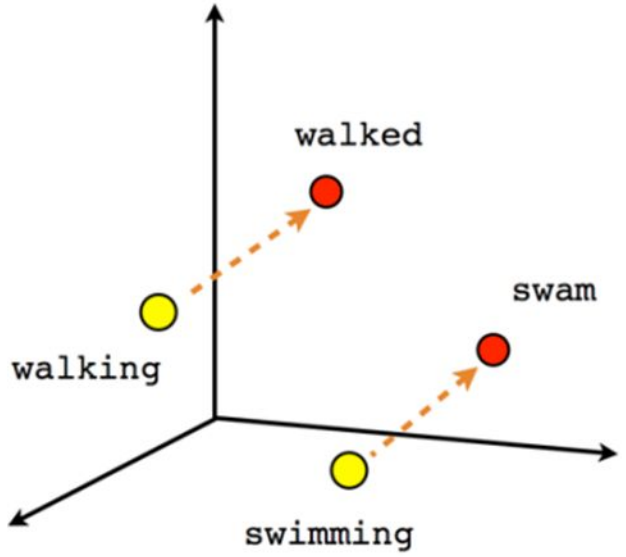

Verb tense

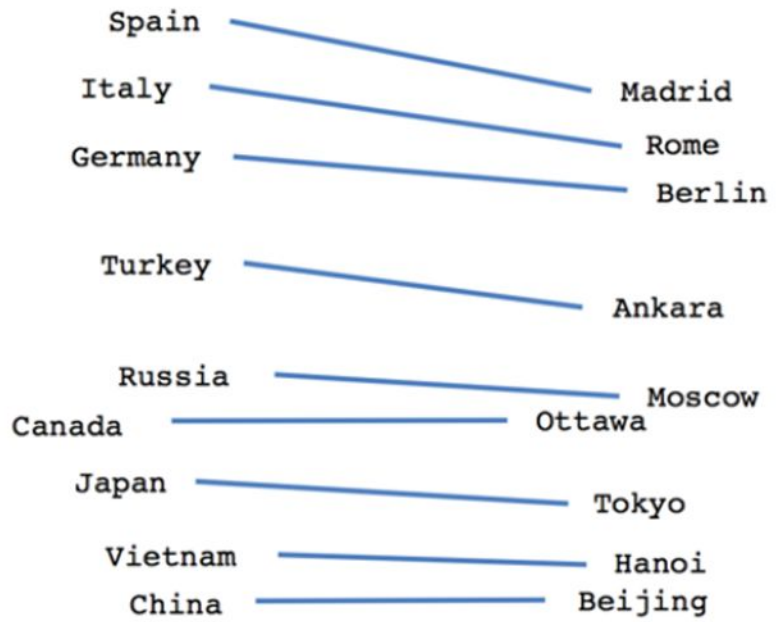

Country-Capital

Векторная репрезентация слов

Features:	is a word	is a noun	is singular	related to food	...
king	1	1	1	0	...
queens	1	1	0	0	...
eating	1	0	0	1	...

vector representation of words

Семантический вектор запроса и текста

Постановка задачи семантического поиска

- Идея семантического поиска заключается в описании поисковых запросов в виде набора триплетов. Пусть имеется запрос q, состоящий из набора триплетов $T(q)$. В таком случае результатом поиска в источнике знаний будет набор элементов знания $E = \{e_i \mid i \in [1,k]\}$, где k – количество элементов знания e_i, являющихся результатом поиска. Причем, семантические метаданные набора элементов знания $T(e)$ должны удовлетворять следующему условию семантической близости $sim(T(q),T(e))$ с описанием запроса $T(q)$: $sim(e,q) = sim(T(q),T(e)) > \varepsilon$, где $sim(e,q)$ близость запроса q и элемента знания e, а ε – установленное пороговое значение релевантности. Результаты поиска ранжируются по значениям их семантической близости к запросу.

Постановка задачи классификации

Пусть X – множество описаний элементов знаний, Y – множество наименований классов. Существует неизвестная целевая зависимость – отображение $y^*: X \to Y$, значения которой известны только на объектах конечной обучающей выборки $X^m = \{(x_1, y_1), \ldots, (x_m, y_m)\}$. Требуется построить алгоритм $a: X \to Y$, способный классифицировать произвольный объект $x \in X$.

Представим вероятностную постановку задачи классификации знаний, которая считается более общей. Предполагается, что множество пар «элемент знания, класс» $X \times Y$ является вероятностным пространством с неизвестной вероятностной мерой P. Имеется конечная обучающая выборка наблюдений $X^m = \{(x_1, y_1), \ldots, (x_m, y_m)\}$, сгенерированная согласно вероятностной мере P. Требуется построить алгоритм $a: X \to Y$, способный классифицировать произвольный объект $x \in X$.

Постановка задачи структуризации

Все системно значимые признаки элементов знания из определенной предметной области разобьем на m классов. Сформируем множество необходимых признаков системной значимости $F = \{F_1 \cup F_2 \cup \ldots \cup F_m\}$.

$F_1 = \{f_{11}, f_{12}, \ldots, f_{1(i-1)}, f_{1i}\}$,

где $f_{11}, f_{12}, \ldots, f_{1(i-1)}, f_{1i}$ – элементы множества F_1, задающие 1-ый класс системно значимых признаков для элементов знания некоторой предметной области;

$F_2 = \{f_{21}, f_{22}, \ldots, f_{2(j-1)}, f_{2j}\}$,

где $f_{21}, f_{22}, \ldots, f_{2(j-1)}, f_{2j}$ – элементы множества F_2, задающие 2-ой класс системно значимых признаков для элементов знания некоторой предметной области;

$F_m = \{f_{m1}, f_{m2}, \ldots, f_{m(k-1)}, f_{mk}\}$,

где $f_{m1}, f_{m2}, \ldots, f_{m(k-1)}, f_{mk}$ – элементы множества F_m, задающие m класс системно значимых признаков для элементов знания некоторой предметной области.

Постановка задачи структуризации

Зададим для каждого анализируемого элемента знания $q_z \ (z = 1...n)$ множество имеющихся у него системно значимых признаков $Q_z = \{Q_{11} \cup Q_{12} \cup \ldots \cup Q_{nm}\}$, где $Q_{11} \subset F_1, Q_{12} \subset F_2, Q_{nm} \subset F_m$.

Тогда выражение определения соответствия элемента знания системно значимым требования предметной области представим в виде:

$$M_0 = Q_z \cap F.$$

А целевая функция в таком случае примет вид:

$$M_0 = F.$$

Отсутствие заданного тождества указывает на неполное соответствие элемента требованиям, выдвигаемым к системно значимым признакам.

Абстрактный пример структуризации

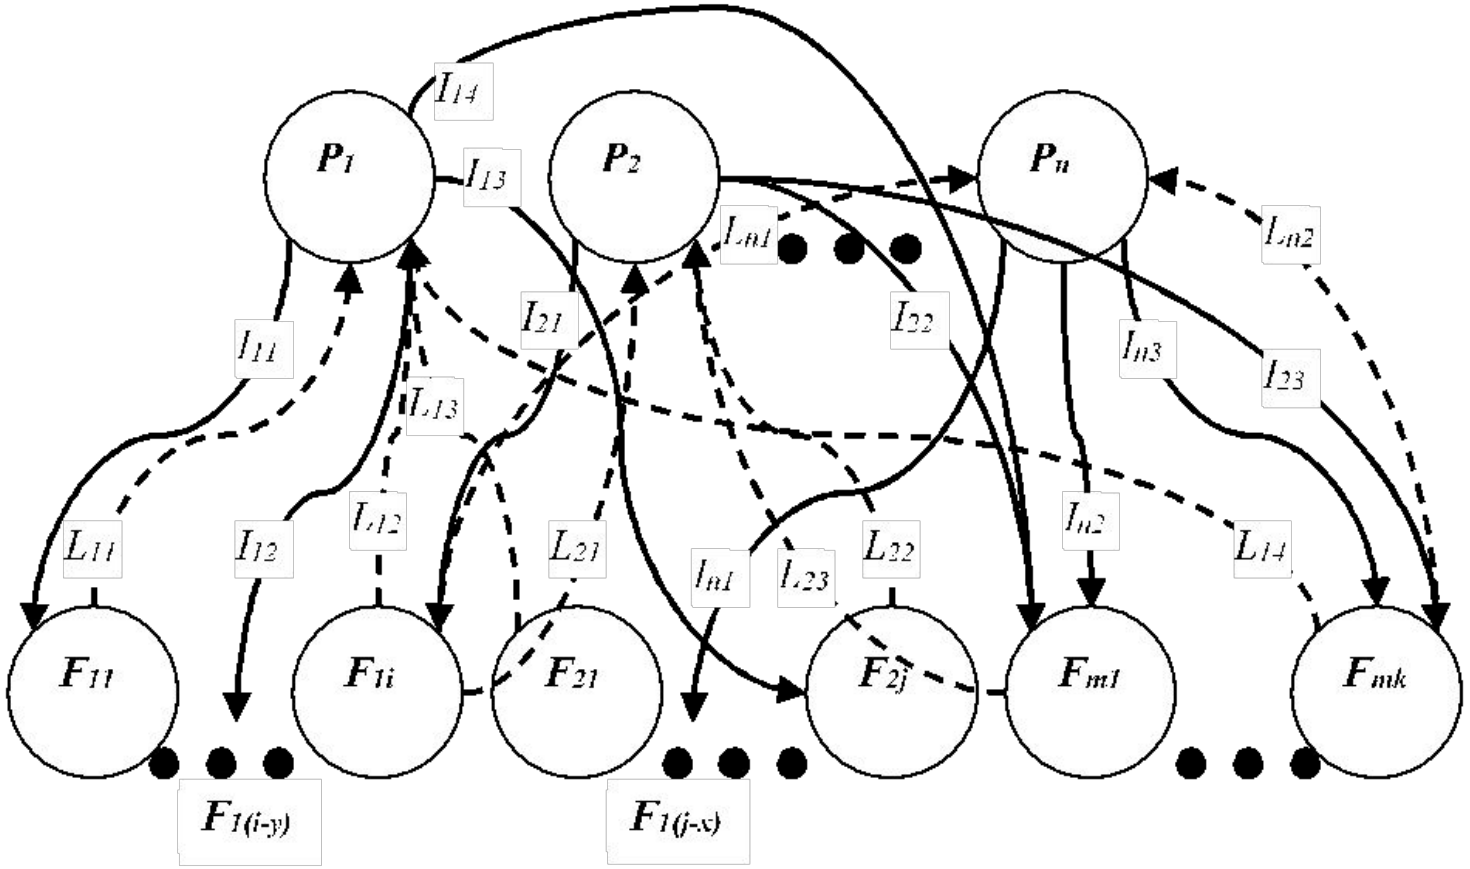

Постановка задачи интеграции

Представим постановку задачи системной ***интеграции знаний*** множества онтологий в виде следующего выражения:

$$O^{\Sigma} = \bigcup_{i} O_i, \; i = \overline{1, N}$$

где O_i – онтограф (ОГ); i – номер предметной области; N – количество предметных областей.

При простой древовидной структуре выражение определения объема знаний в предметной области имеет следующий вид:

$$O = \sum_{p} \sum_{d} \sum_{j} Z_{p,d} Z_{p,d,j},$$

где $Z_{p,d}$ – степень инцидентности вершины под номером d; $p = \overline{1, P}$ – количество уровней ОГ; $d = \overline{1, D_p}$ – номер вершины на p-ом уровне ОГ.

Учёт типов отношений и сложность функций интерпретации приводит к ОГ со взвешенными вершинами и ребрами. Выражение определения объема знаний в этом случае имеет вид:

$$O = \sigma_{\gamma} \sigma_{\delta} \gamma_d \delta_{d,j} + \sigma_{\delta} \delta_{d,j},$$

где γ_d и $\delta_{d,j}$ – значения весовых функций отношений и интерпретации.

Путь исследования

Коалиции интеллектуальных агентов

Онтологическая модель информационного пространства знаний

Биоинспирированные алгоритмы решения задач приобретения и управления знаниями

Информационные модели приобретения и управления знаниями

Модель переходов агента

***G* = <*B*, *E*, *P*, *U*>**

B – вершина начала функционирования агента;

E – вершина конца функционирования агента;

P – множество вершин процессов функционирования агента;

U – множество ребер переходов состояния агента.

Задание гиперграфа на множестве вершин процессов функционирования агента ***P*** отображает режимы функционирования агента ***R***.

Имитационные модели прецедентов

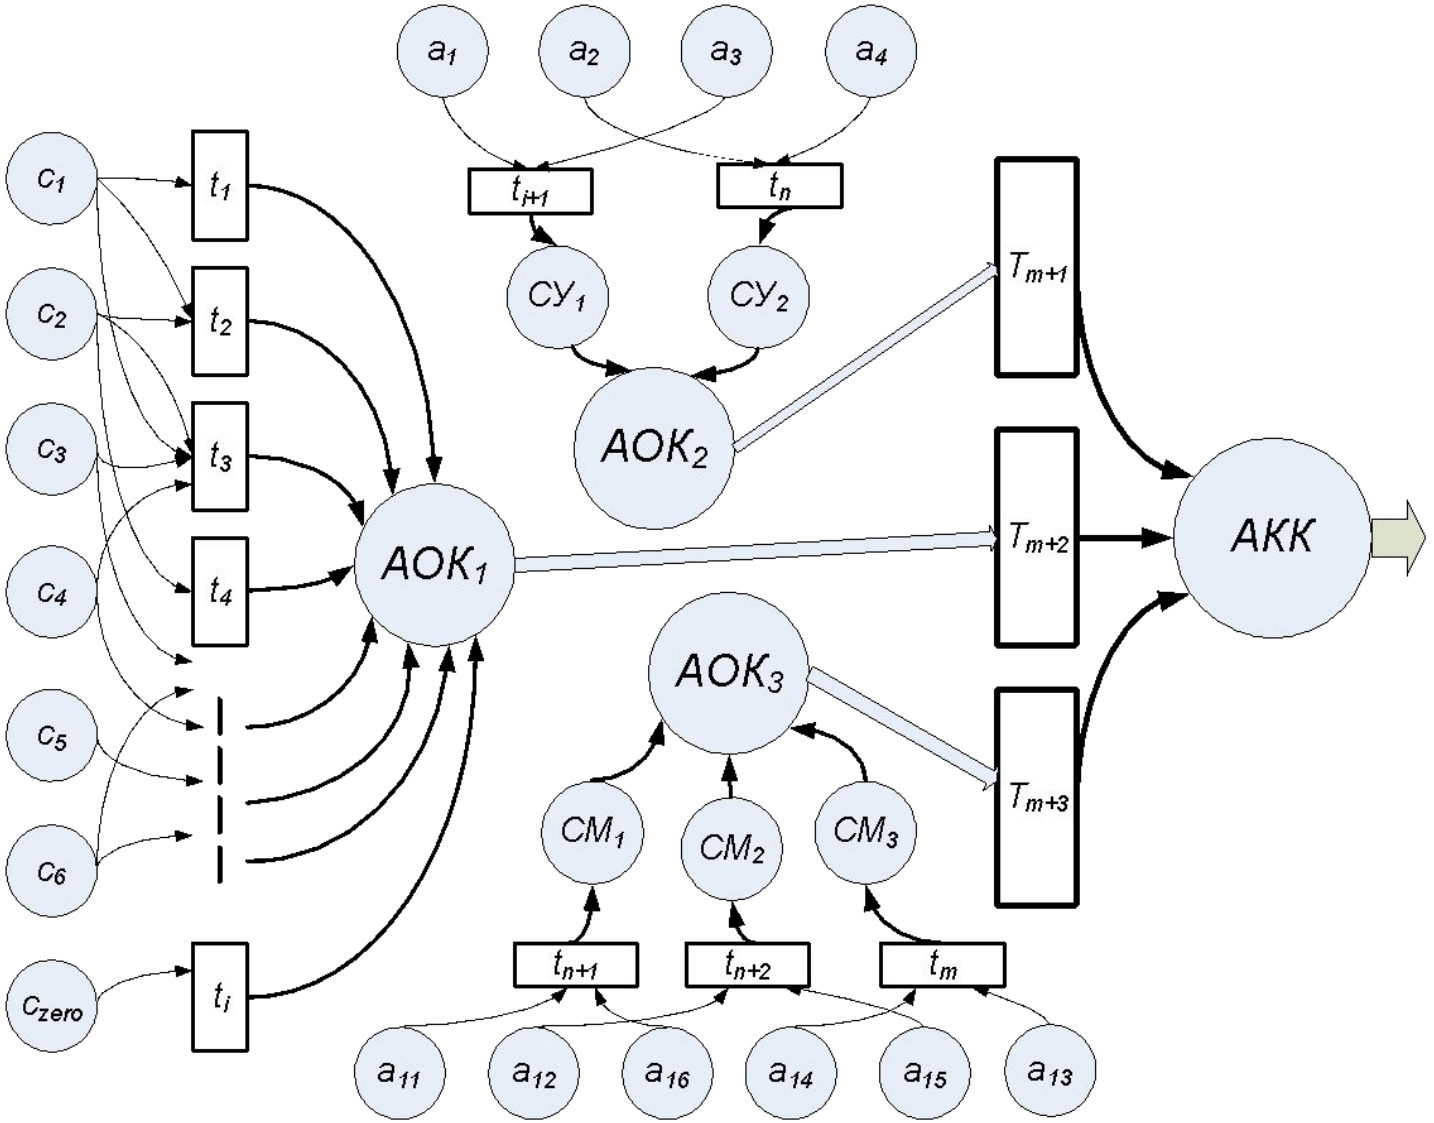

Выполнение условий достижимости

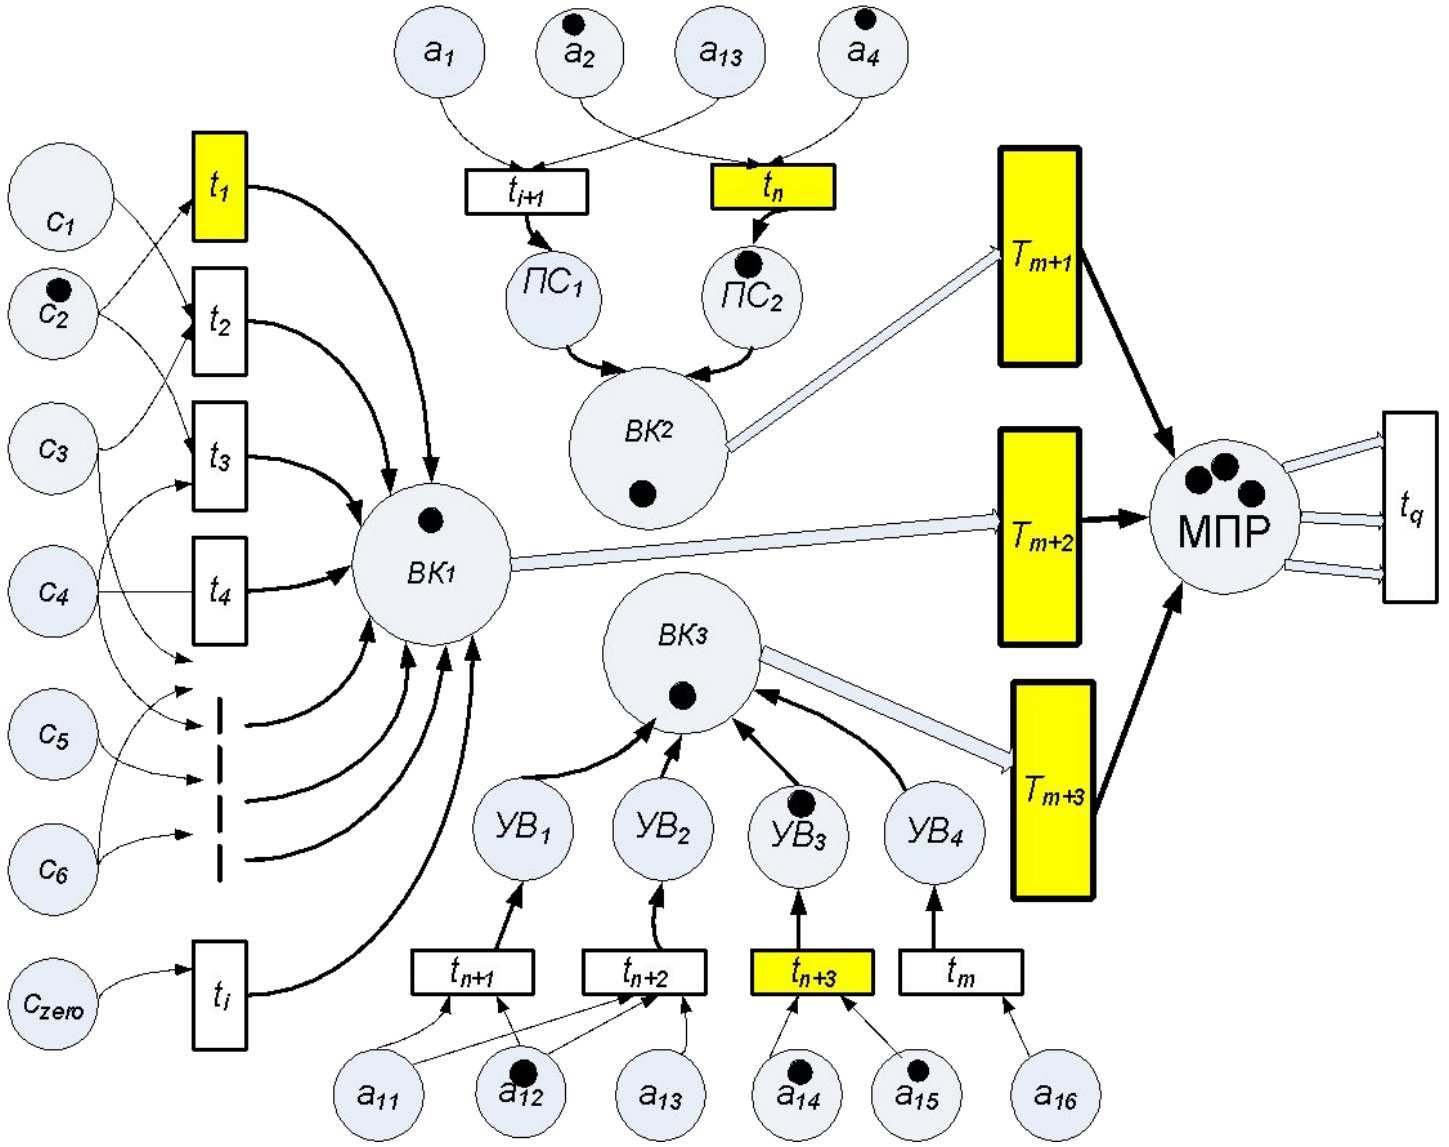

Нарушение условий достижимости

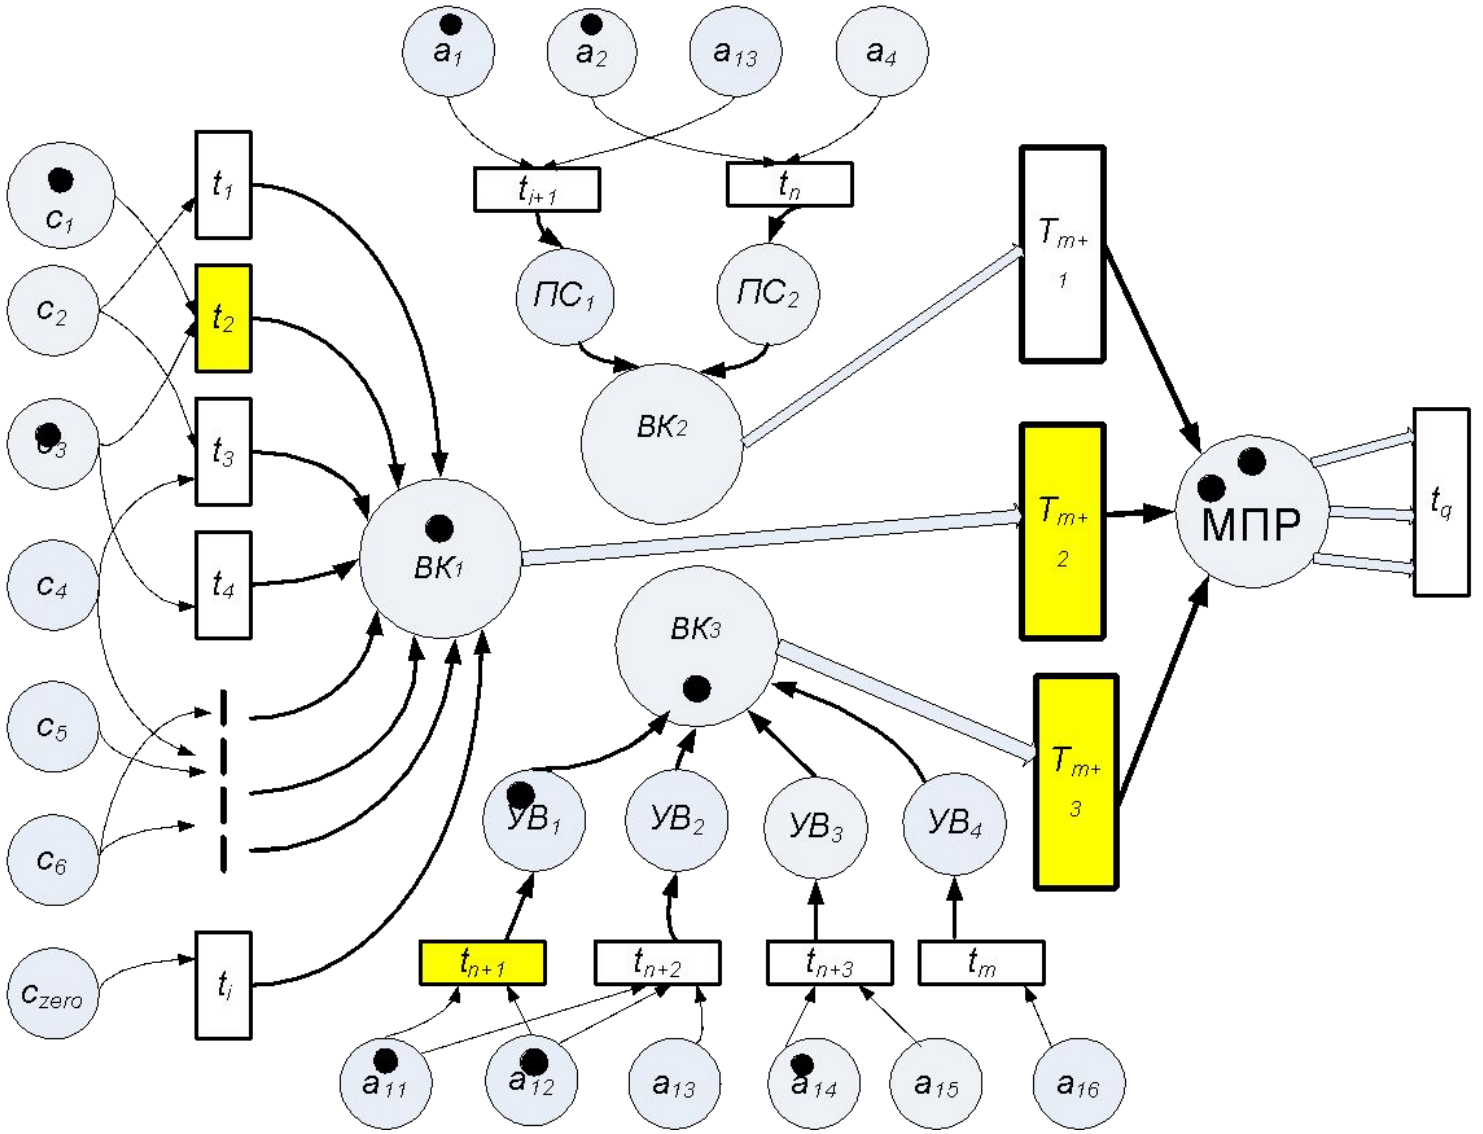

Модели поведения

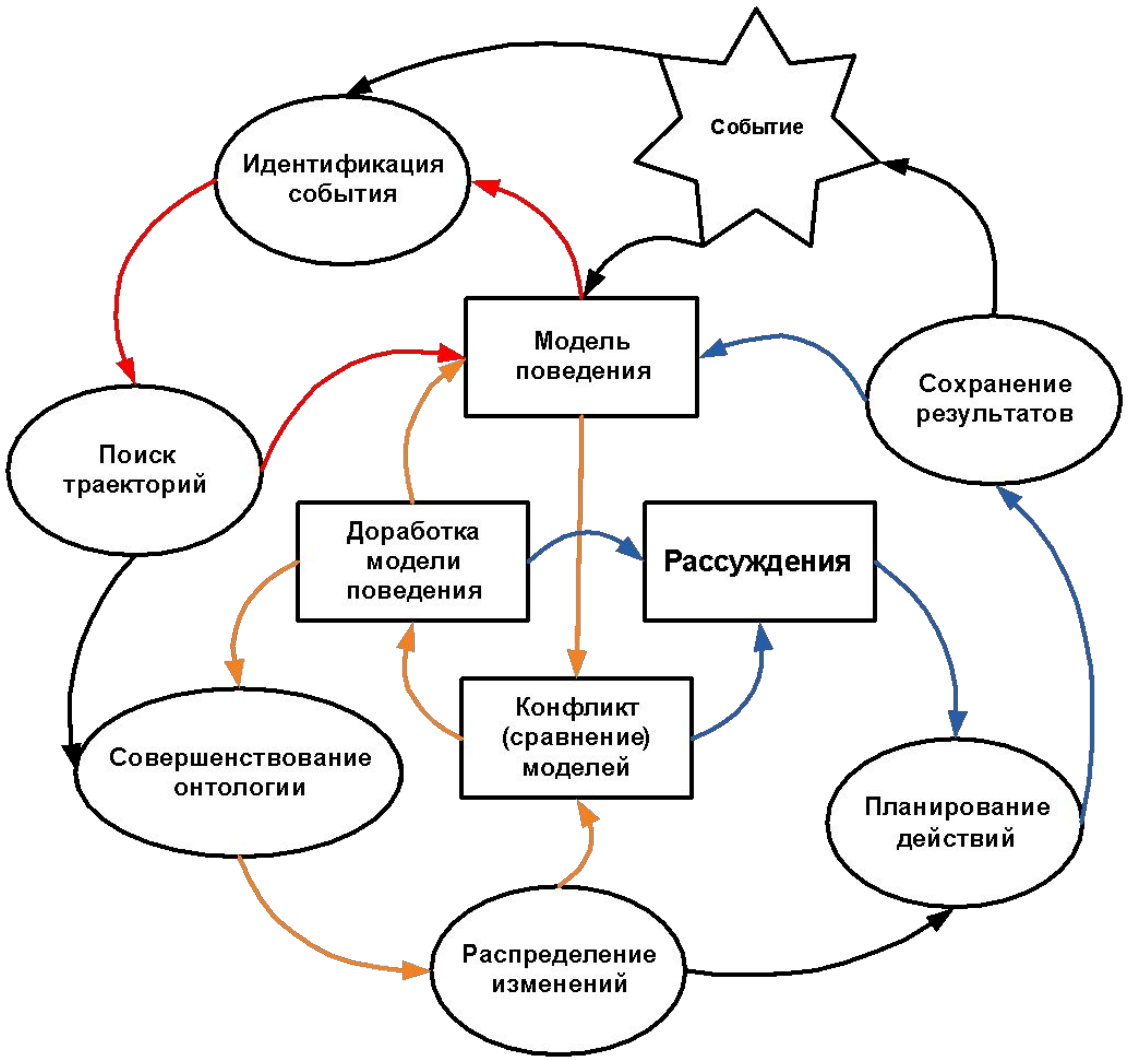

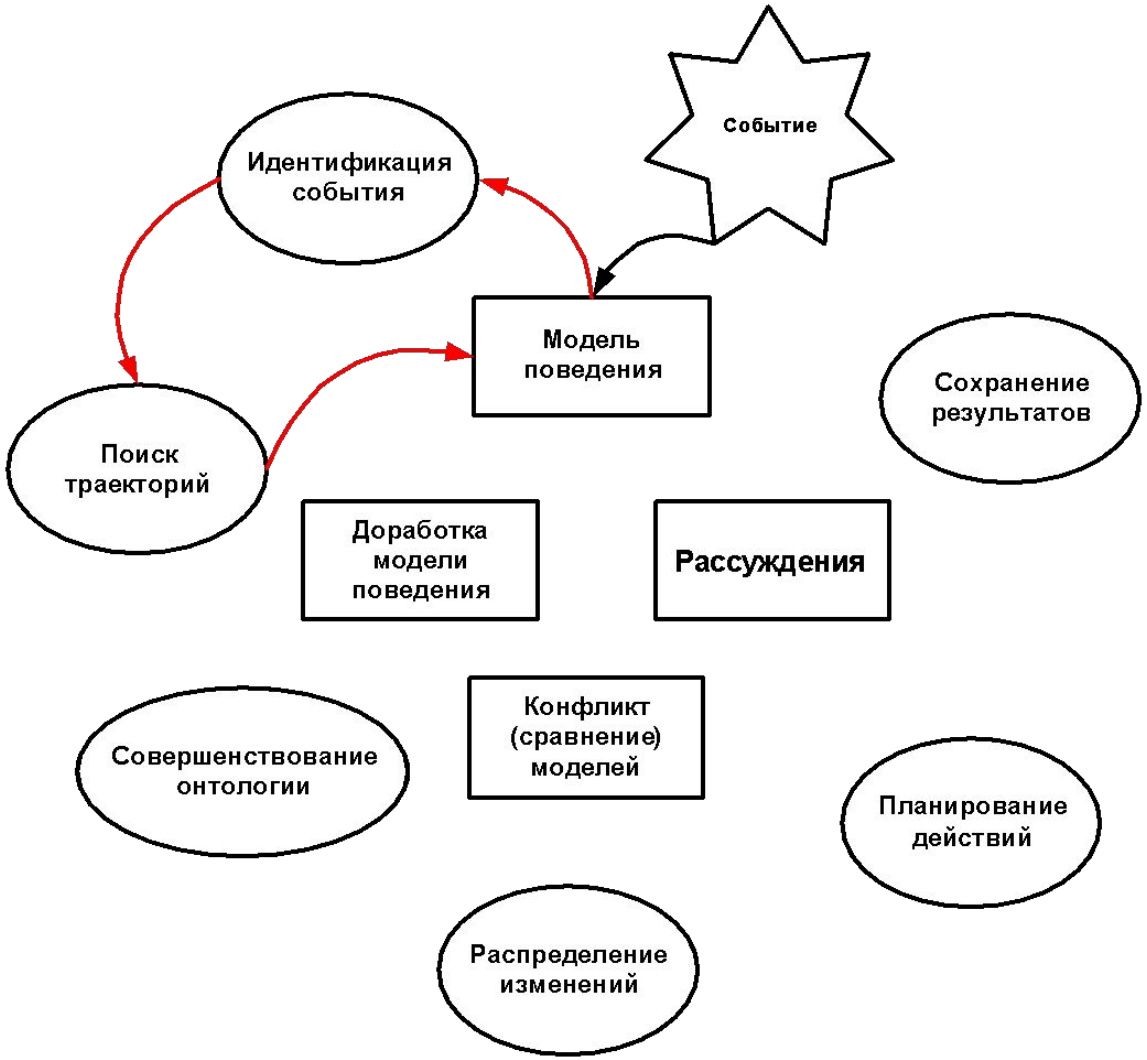

Модели поведения

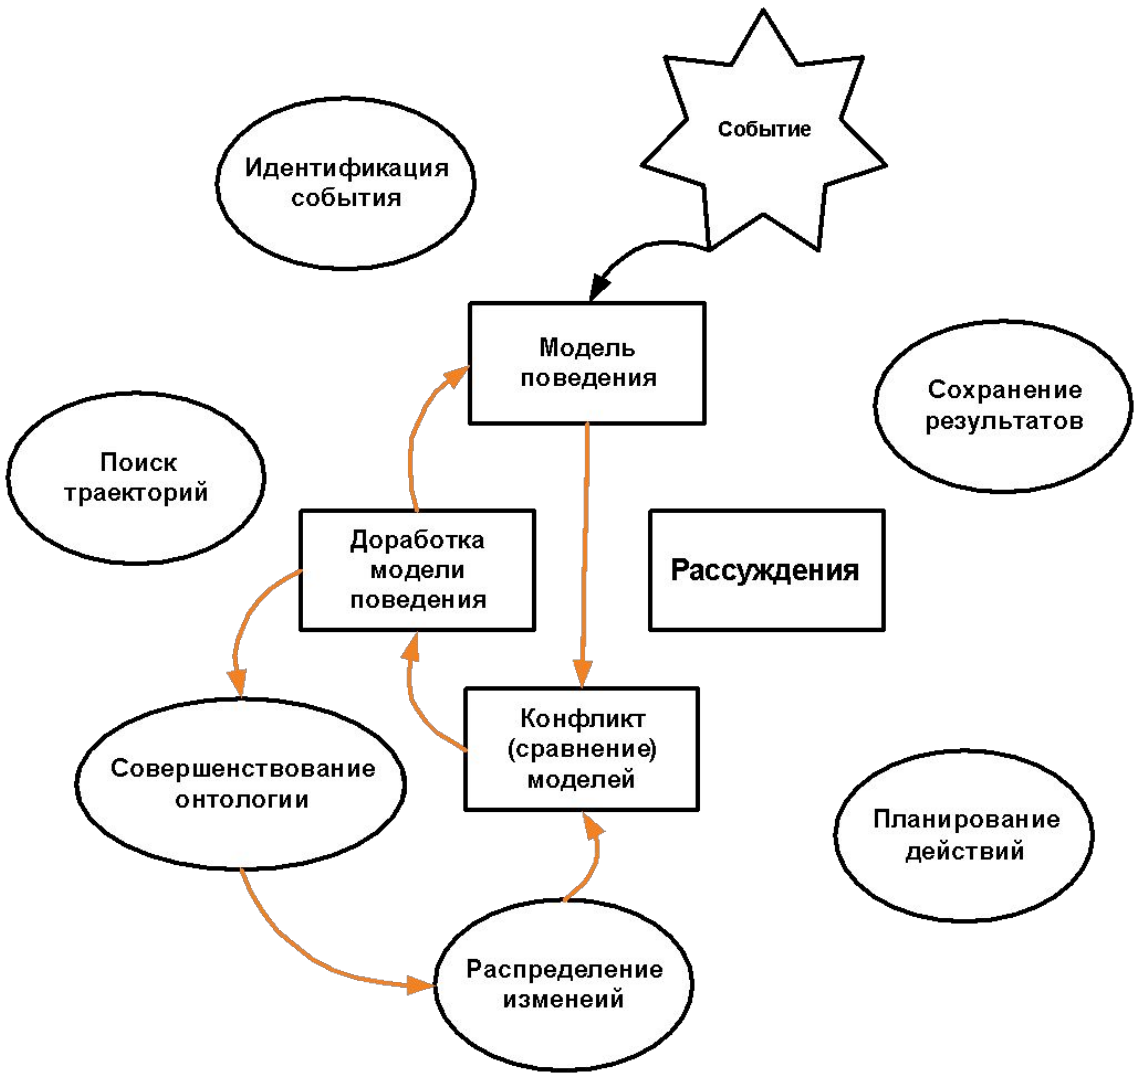

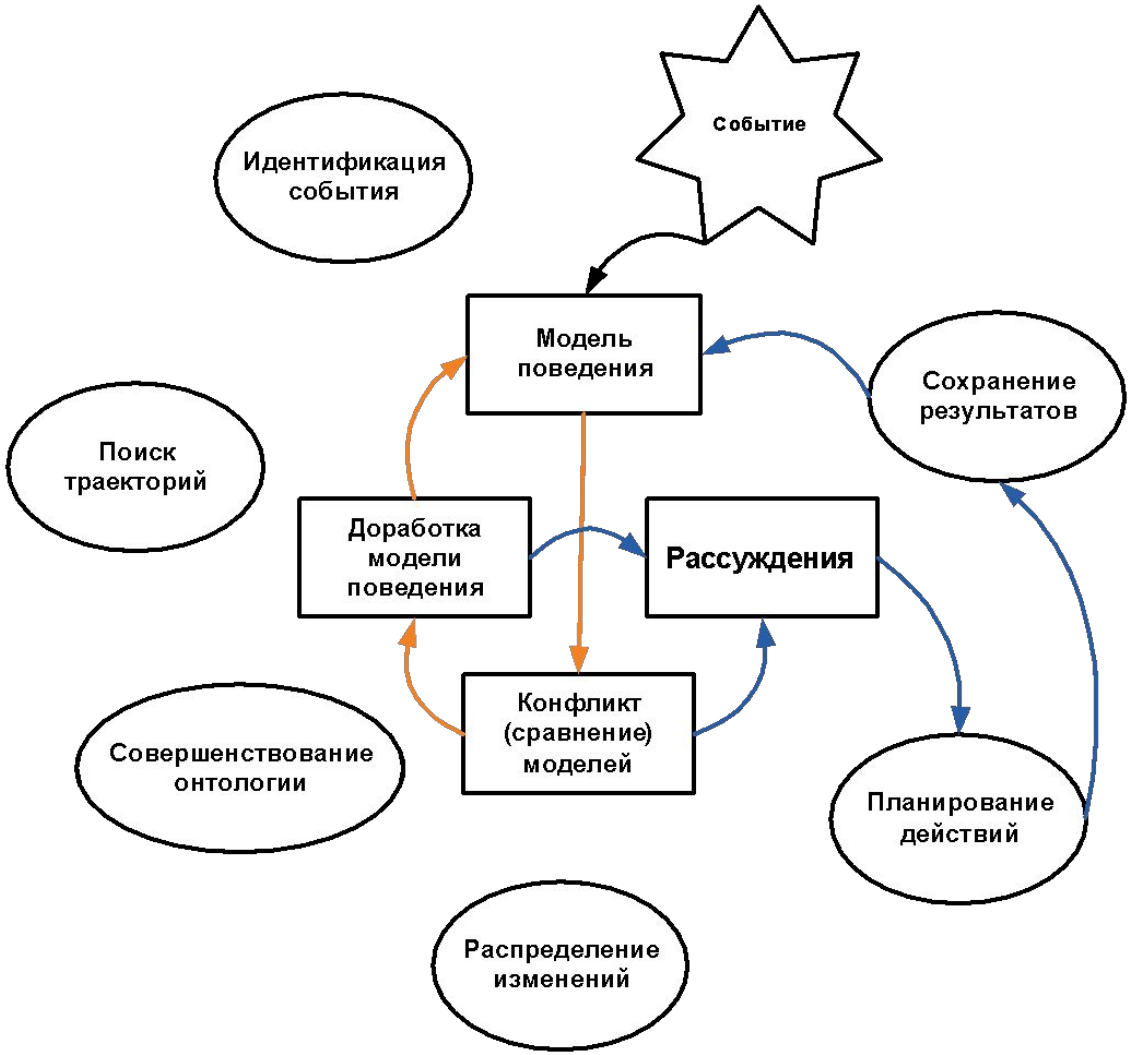

Абстрактная модель среды поиска данных

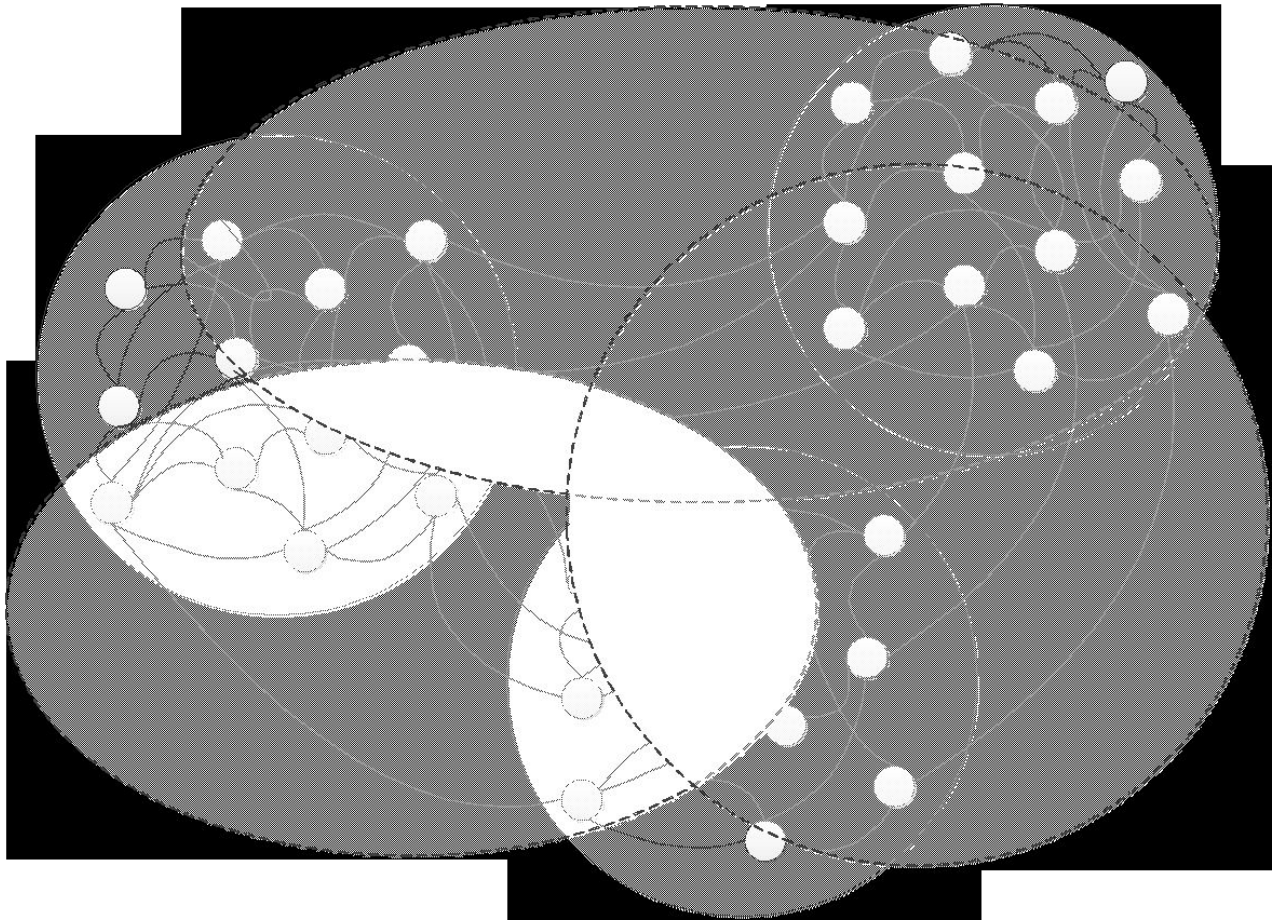

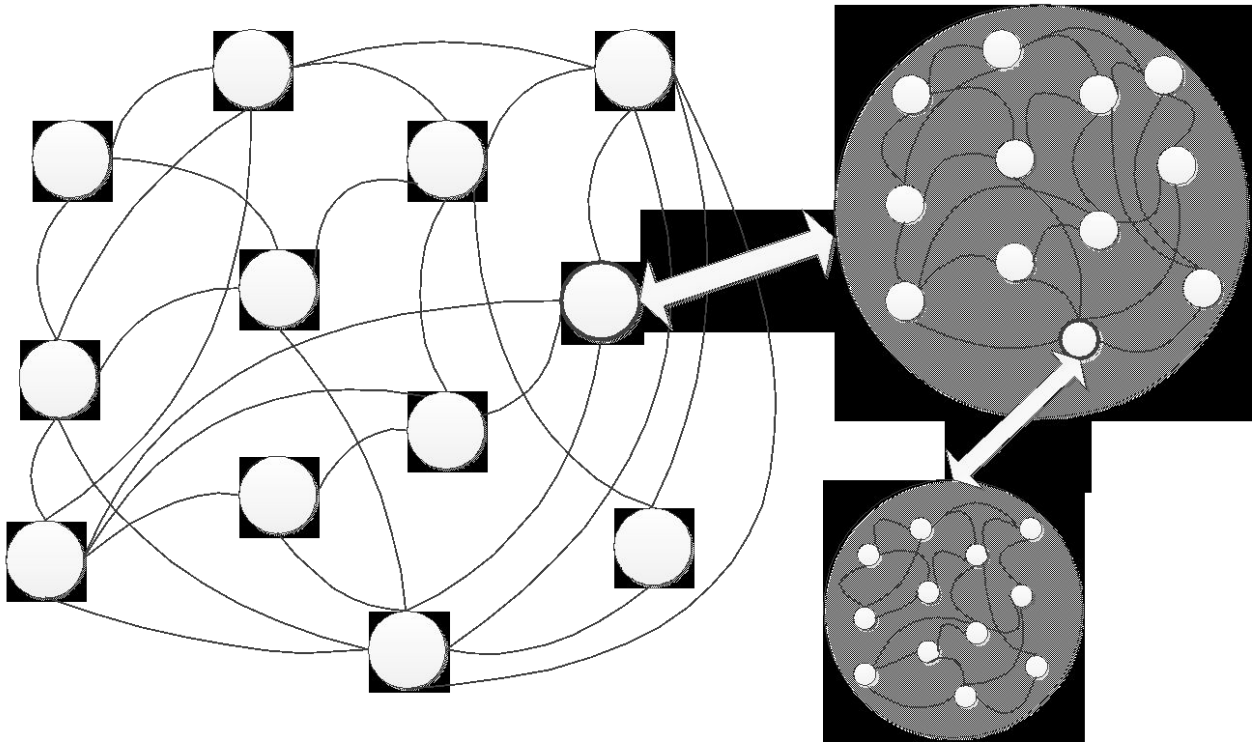

Модель онтологии

- **Онтология O представляет собой знаковую систему $O = <P,V,R,C>$, где P – множество понятий (концептов); V – множество экземпляров понятий; R – множество предикатов – атрибутов понятий; C – множество отношений, которые задают следующие виды связи между сущностями:**

- **1. Частичный порядок на множествах P и R, задающий отношения *is-a* – «подкласс-суперкласс».**

- **2. Отношение между понятиями, которое представляет собой триплет вида $<p_1 – r_1 – p_2>$, где $p_1, p_2 \in P$; $r_1 \in R$.**

- **3. Отношение между экземплярами, которое представляет собой триплет вида $<v_1 – r_1 – v_2>$, где $v_1, v_2 \in V$; $r_1 \in R$.**

- **4. Отношение между предикатами, которое представляет собой триплет вида $<r_1 – r_i – r_2>$, где $r_1, r_2, r_i \in R$.**

Модель среды поиска данных

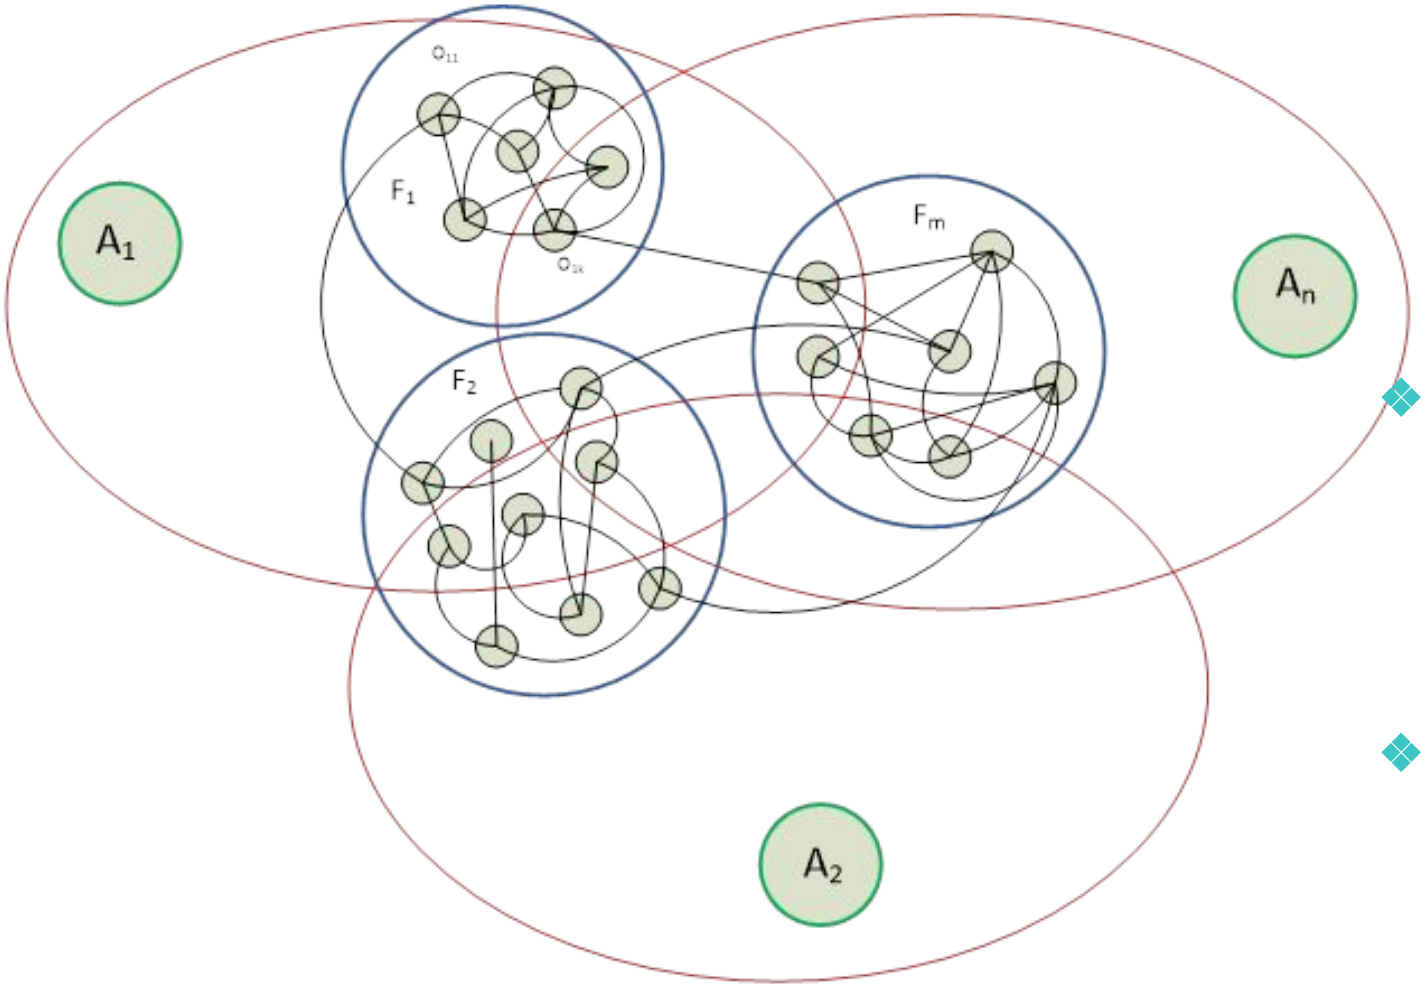

- 1) **акторы (A) – фильтры знаний, представляющие активные элементы (агенты), создающие предметную область на основе поиска междисциплинарных отношений между разными функциональными областями, способные активизировать, выполнять или управлять информационным процессом;**
- 2) **функциональная область (F), представляющая определенный информационный процесс, состоящий из последовательности операций и направленный на достижение поставленной цели;**
- 3) **объекты (O), представляющие пассивные сущности, с которыми работает информационный процесс, обладающие собственными атрибутами (измеримыми свойствами) и отношениями между собой.**

Модель фильтра данных семантического поиска

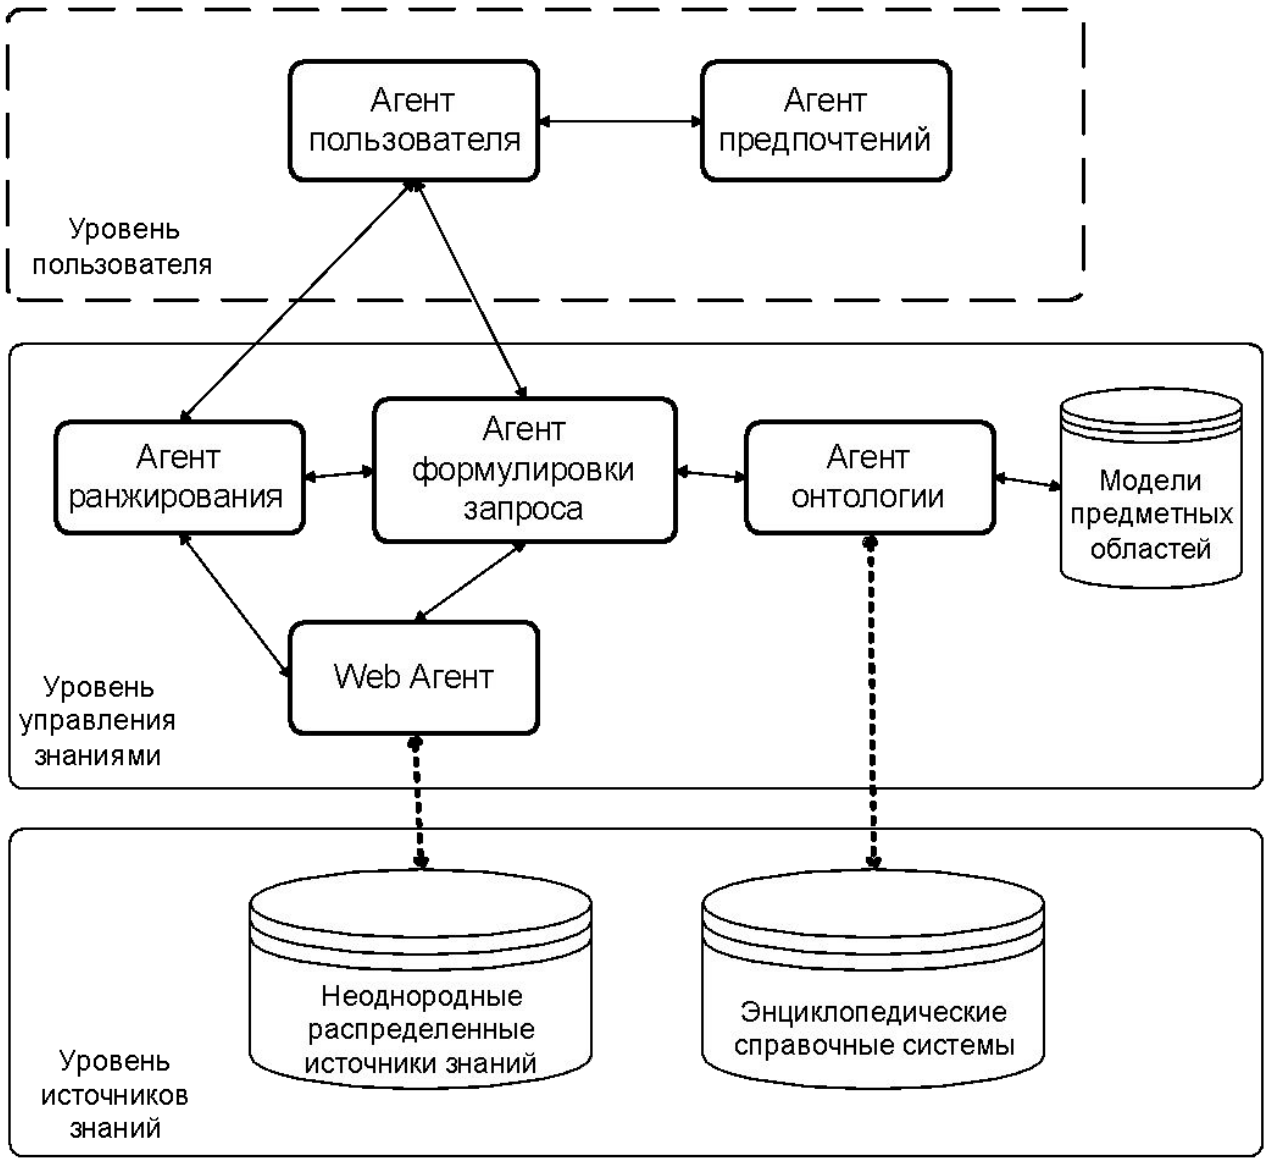

Основными достоинствами предлагаемой модели являются:

1) поддержка семантического поиска релевантных знаний на основе онтологических моделей;

2) использование информационных энциклопедических справочных систем различной функциональности для усовершенствования формы поискового запроса;

3) повышение эффективности запроса пользователя на основе использования репозитория прецедентов.

Case-модель фильтра данных

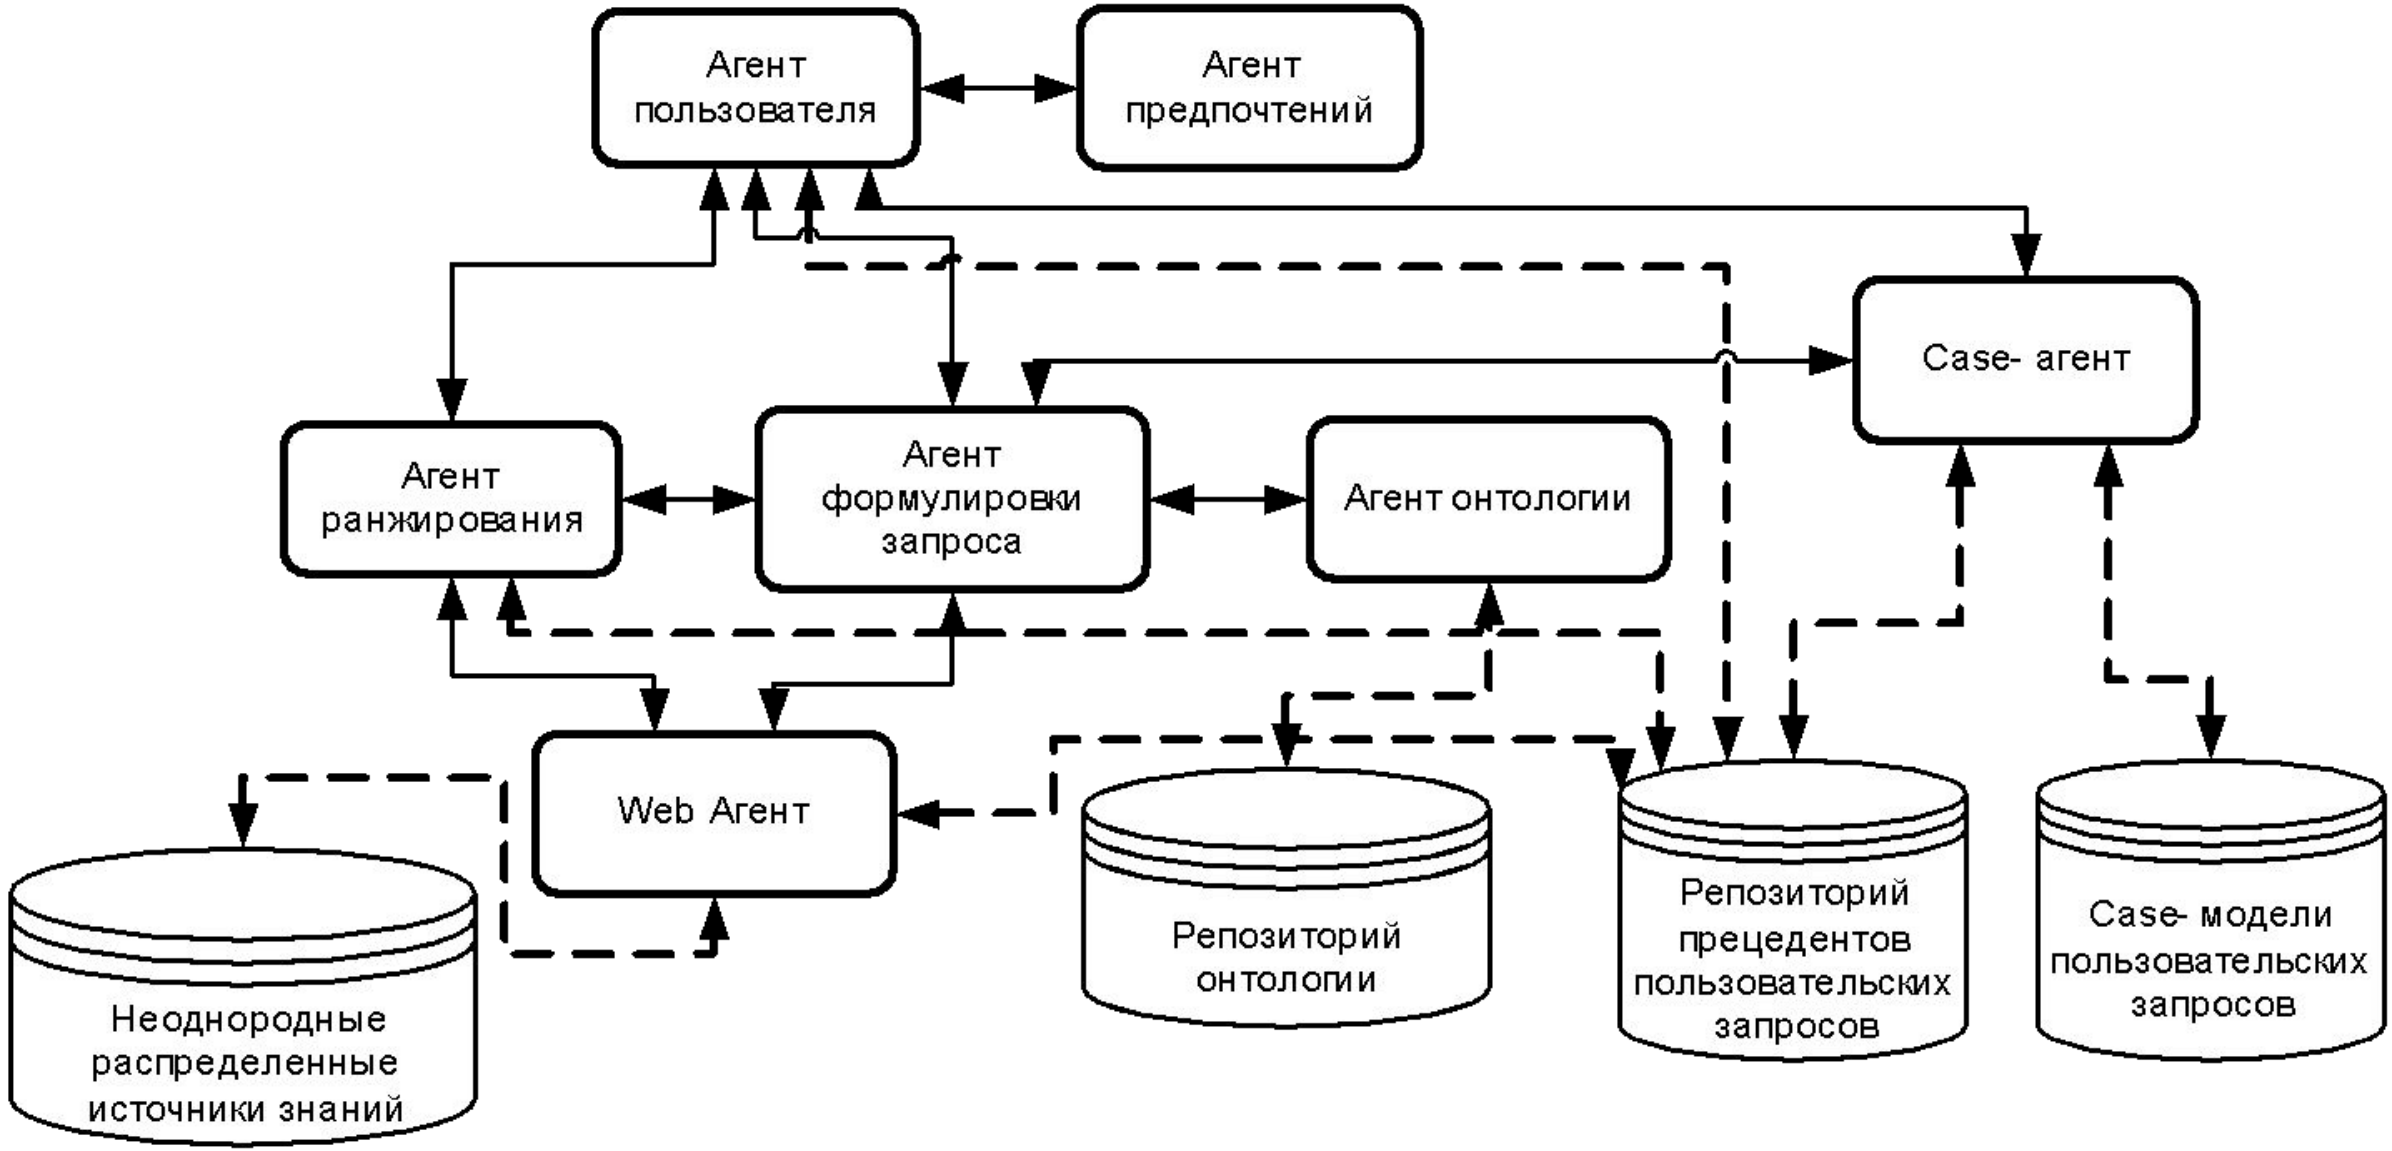

Нечеткая модель структуризации содержательной части данных

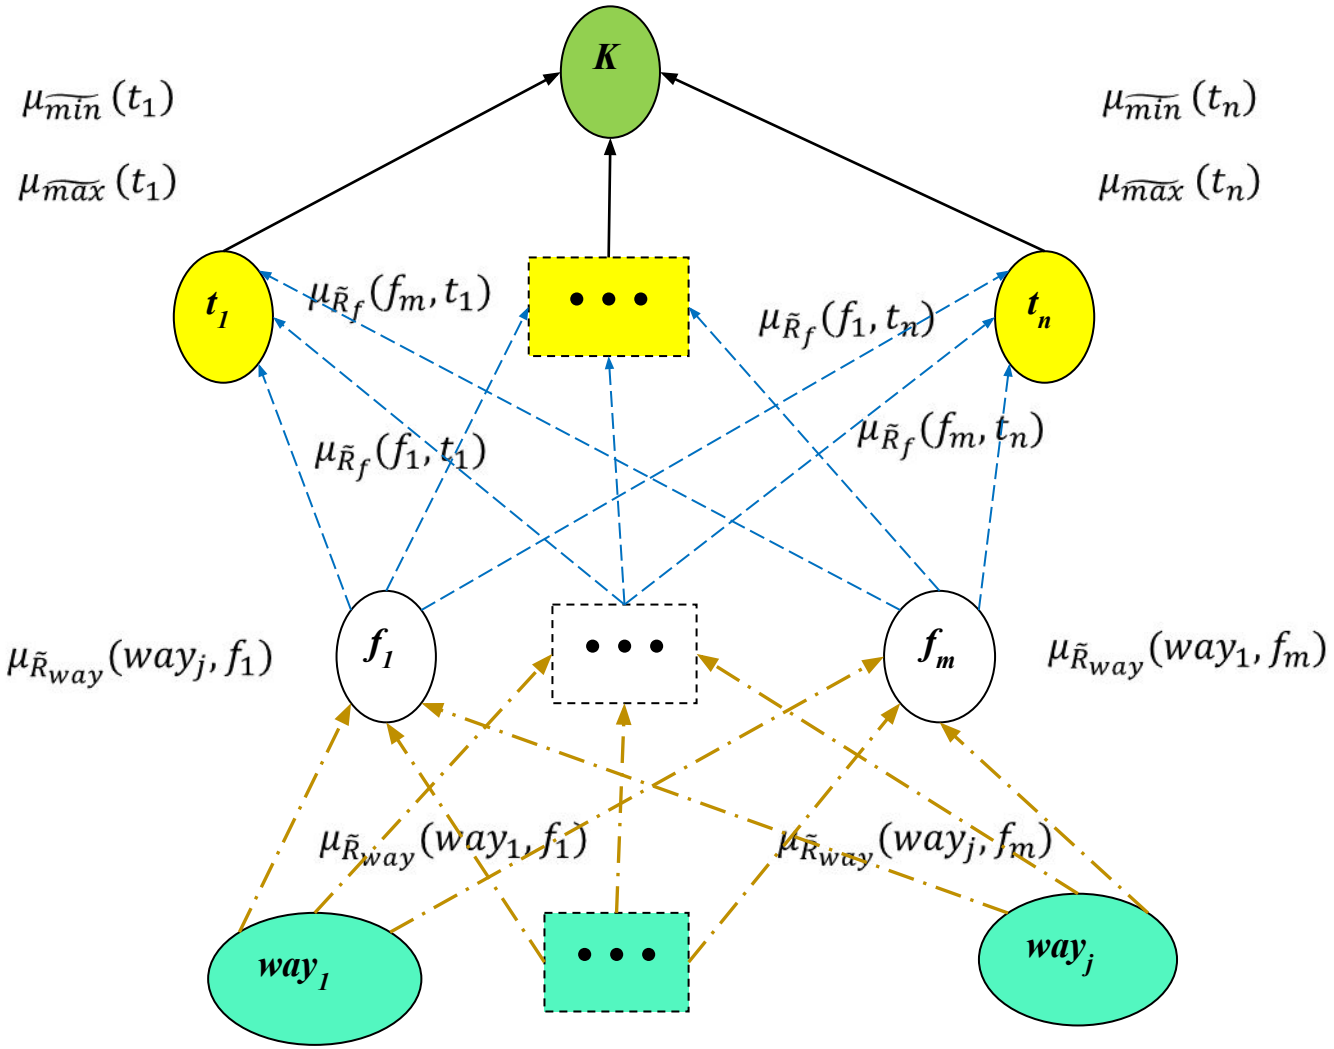

$R \subset D \times D$

$R_t \subset T \times T$, где $(t_i, t_j) \in R_t, i \in [1,n], j \in [1,n], i \neq j$

$\mu_{\widetilde{min}}: T \to P$ и $\mu_{\widetilde{max}}: T \to P$

$\widetilde{MIN} = \{t, \mu_{\widetilde{min}}(t)\}, \quad \widetilde{MAX} = \{t, \mu_{\widetilde{max}}(t)\}$

$\widetilde{MIN} \subset T$ и $\widetilde{MAX} \subset T$

$R_f \subset F \times T \quad (f,t) \in R_f,$

$\tilde{R}_f \subset R_f, \tilde{R}_f = \left\{(f,t), \mu_{\tilde{R}_f}(f,t)\right\}. \mu_{\tilde{R}_f}: R_f \to P$

$R_{way} \subset WAY \times F;\ (way, f) \in R_{way};\ \mu_{\tilde{R}_{way}}: R_{way} \to P,$

$\tilde{R}_{way} \subset R_{way}, \tilde{R}_{way} = \left\{(way, f), \mu_{\tilde{R}_{way}}(way, f)\right\}$

$D_1 = T \cup F \cup WAY$

$R_1 \subset D_1 \times D_1$

$V_1 = \{R_t, R_f, R_{way}\}$

$\tilde{G}_1 = \left(D_1, R_1, \mu_{\tilde{G}_1}(d_1), \mu_{\tilde{G}_1}(r_1)\right)$

Модель классификации данных на основе обобщенного критерия

$$Q_i = \left\{ {}^{\mu_{Q_i}(t_1)}/_{t_1}, {}^{\mu_{Q_i}(t_2)}/_{t_2}, \dots, {}^{\mu_{Q_i}(t_n)}/_{t_n} \right\}$$ нечеткое множество степени соответствия альтернатив t_n критерию Q_i

$$S = Q_1 \cap Q_2 \cap \cdots \cap Q_k$$ правило выбора наилучшей альтернативы

$$\mu_S(t_j) = \min \mu_{Q_i}(t_j), i = 1, \dots, k; j = 1, \dots, n$$

$$\mu_S(t^*) = max\, \mu_S(t_j), j = 1, \dots, n$$ лучшая альтернатива t*

$$Q_1 = \sum_{i=1}^{P} \sum_{k=1}^{S} \varepsilon_{ij}\, \delta_{ik}$$

$$Q_2 = \sum_{i=1}^{P} \sum_{y=1}^{S} \sum_{k=1}^{S} \gamma_{iy} \delta_{ik}, y \neq k$$

$$Q_3 = \sum_{k=1}^{S} \sum_{i=1}^{P} \varepsilon_{ij}\, \delta_{ik} \varphi_{ij}$$

$$Q_{int} = \tau_1 Q_1 + \tau_2 Q_2 + \tau_3 Q_3 \rightarrow max$$