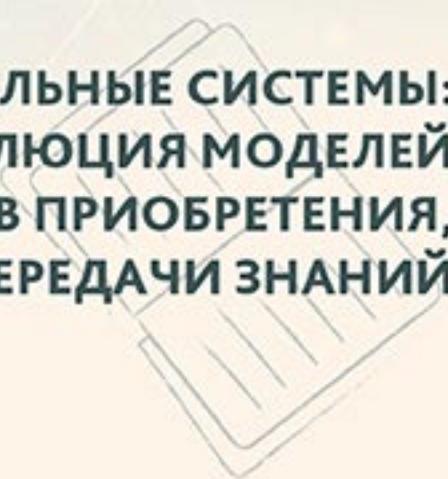


Ю. А. Кравченко
В. В. Курейчик
С. И. Родзин



} | Институт
Компьютерных
Технологий и
Информационной
Безопасности

**ИНТЕЛЛЕКТУАЛЬНЫЕ СИСТЕМЫ:
ЭВОЛЮЦИЯ МОДЕЛЕЙ
И МЕТОДОВ ПРИОБРЕТЕНИЯ,
УПРАВЛЕНИЯ И ПЕРЕДАЧИ ЗНАНИЙ**



**Ю. А. Кравченко
В. В. Курейчик
С. И. Родзин**

**ИНТЕЛЛЕКТУАЛЬНЫЕ СИСТЕМЫ:
ЭВОЛЮЦИЯ МОДЕЛЕЙ И МЕТОДОВ
ПРИОБРЕТЕНИЯ, УПРАВЛЕНИЯ
И ПЕРЕДАЧИ ЗНАНИЙ**

Монография

Чебоксары
Издательский дом «Среда»
2023

УДК 004
ББК 32.81
К78

Рецензенты:

д-р техн. наук, профессор, зав. кафедрой «Информационная безопасность» ФГАОУ ВО «Поволжский государственный технологический университет»

И. Г. Сидоркина;

д-р техн. наук, профессор, заместитель директора по науке Санкт-Петербургского филиала ФГБУН «Институт земного магнетизма, ионосферы и распространения радиоволн им. Н.В. Пушкова РАН»

А. Г. Коробейников

К78 Кравченко Ю. А.
Интеллектуальные системы: эволюция моделей и методов приобретения, управления и передачи знаний : монография / Ю. А. Кравченко, В. В. Курейчик, С. И. Родзин. – Чебоксары: Среда, 2023. – 192 с.

ISBN 978-5-907688-79-7

В книге рассматриваются вопросы, связанные с эволюцией информационных систем, моделей и методов приобретения и управления знаниями. Представлены концепция, базовые принципы и стратегия приобретения и управления знаниями, которые направлены на решение научной проблемы увеличения информационного объема семантически обработанных знаний в глобальном информационном пространстве. Полученные авторами научные результаты позволили повысить эффективность процессов приобретения и управления знаниями в условиях наличия эпистемологической информационной неопределенности и увеличить информационный объем качественно структурированных формальных знаний.

Монография адресована специалистам в области информационных технологий и систем, интеллектуальных систем поддержки принятия решений, приобретения и управления знаниями. Она может быть полезна студентам, магистрантам и аспирантам соответствующих специальностей.

© Кравченко Ю.А.,
Курейчик В.В.,
Родзин С.И., 2023

ISBN 978-5-907688-79-7
DOI 10.31483/a-10557

© ИД «Среда», оформление, 2023

ОБ АВТОРАХ

Кравченко Юрий Алексеевич – д.т.н., доцент, профессор
ФГАОУ ВО «Южный федеральный университет» (ЮФУ), г. Таганрог.

Курейчик Владимир Викторович – д.т.н., профессор, зав. кафедрой Систем автоматизированного проектирования (САПР)
ФГАОУ ВО «Южный федеральный университет» (ЮФУ), г. Таганрог.

Родзин Сергей Иванович – к.т.н., доцент, профессор
ФГАОУ ВО «Южный федеральный университет» (ЮФУ), г. Таганрог.

ОГЛАВЛЕНИЕ

ВВЕДЕНИЕ	6
ГЛАВА 1. УПРАВЛЕНИЕ ЗНАНИЯМИ КАК РЕЗУЛЬТАТ ЭВОЛЮЦИИ ИНФОРМАЦИОННЫХ ТЕХНОЛОГИЙ	11
1.1. Проблема структурирования знаний в глобальном информационном пространстве	11
1.2. Эволюционная модель развития информационных технологий	20
1.3. Эволюция знаний	25
1.4. Экосистема знаний.....	32
1.5. Самоорганизация информационных систем.....	37
ГЛАВА 2. ИНФОРМАЦИОННЫЕ МОДЕЛИ И ЗАДАЧИ ПРИБРЕТЕНИЯ И УПРАВЛЕНИЯ ЗНАНИЯМИ.....	42
2.1. Эволюция процессов управления знаниями	42
2.2. Модифицированные модели представления и управления знаниями	49
2.3. Онтологическая модель представления знаний	54
2.4. Постановка и описание задач приобретения и управления знаниями	60
ГЛАВА 3. ЭЛЕМЕНТЫ ТЕОРИИ ПРИОБРЕТЕНИЯ И УПРАВЛЕНИЯ ЗНАНИЯМИ.....	71
3.1. Элементы теории, концепция и стратегии интеллектуальной поддержки приобретения новых знаний	71
3.2. Онтологическая структура междисциплинарного пространства знаний.....	89
3.3. Комплексный подход к решению задачи классификации знаний	92
3.4. Событийная имитационная модель рассуждений коалиций агентов при решении задачи классификации знаний.....	102
ГЛАВА 4. МОДЕЛИ И МЕТОДЫ ПОСТРОЕНИЯ ИНФОРМАЦИОННЫХ ПРОЦЕССОВ ПРИОБРЕТЕНИЯ ЗНАНИЙ.....	110
4.1. Метод построения траектории приобретения знаний на основе графовой модели онтологии.....	110

4.2. Онтологическая модель и модифицированный метод силовой релаксации для решения задачи интеграции знаний.....	113
4.3. Информационные модели фильтра знаний на основе подхода совместного семантического поиска.....	119
ГЛАВА 5. БИОИНСПИРИРОВАННЫЕ МЕТОДЫ ОЦЕНКИ СЕМАНТИЧЕСКОЙ БЛИЗОСТИ.....	125
5.1. Онтологические размерности семантических зависимостей понятий	125
5.2. Модель интеграции знаний на основе оценок семантической близости концептов при отображении онтологий	126
5.3. Модифицированный метод бактериальной оптимизации для решения задачи семантического поиска знаний	130
5.4. Разработка модифицированного обезьяньего метода для решения задачи семантического поиска знаний	135
5.5. Разработка модифицированного кукушкиного метода для решения задачи семантического поиска знаний	140
5.6. Программное приложение и вычислительный эксперимент ...	143
ГЛАВА 6. МЕМЕТИЧЕСКАЯ ПЕРЕДАЧА МАШИННОГО ЗНАНИЯ ПРИ РЕШЕНИИ ЗАДАЧ ПОИСКОВОЙ ОПТИМИЗАЦИИ.....	150
6.1. Эволюция алгоритмов поисковой оптимизации, инспирированных мемами	150
6.2. Проблема выбора мемов при решении задач поисковой оптимизации	157
6.3. Меметический автомат для передачи машинного знания при поисковой оптимизации.....	160
6.4. Последовательный оптимизатор передачи мемов.....	167
6.5. Параллельный оптимизатор передачи мемов.....	171
ЗАКЛЮЧЕНИЕ.....	175
СПИСОК ИСПОЛЬЗУЕМЫХ СОКРАЩЕНИЙ	180
СПИСОК ИСПОЛЬЗУЕМОЙ ЛИТЕРАТУРЫ.....	182

ВВЕДЕНИЕ

Основными задачами информационных технологий являются разработка информационных процессов, оптимальных методов преобразования информации, поддержка проектной деятельности, перспективных направлений интеллектуальной обработки, приобретения и управления знаниями. Объем информации, скорость ее прироста и многообразие растут экспоненциально. Основными источниками «информационного переполнения» признаются интернет вещей, внутренняя информация предприятий, социальные медиа, медицина, биоинформатика, а также информация от измерительных устройств. Однако не вся информация представляет интерес и может быть интегрирована в знания. Проблема состоит в определении сценариев по приобретению, сбору, накоплению, сохранению, распределению и применению знаний, а также основ их создания и эволюции. Перспективным решением этой проблемы является создание информационных моделей на основе технологий многоагентного, нечеткого, имитационного, семантического, эволюционного и меметического моделирования [1, 2].

В настоящее время создание нового знания – это в первую очередь построение эффективных процессов выбора и интеграции множества альтернатив на основе процедур управления знаниями. При этом основой этого знания является информация. Поэтому изучение свойств информации, процедуры ее представления, преобразования, обработки, а также извлечение знаний из нее являются основой информационного процесса. При этом он должен обладать такими характеристиками как: достоверность, надежность, релевантность и интерпретируемость. Заметим, что необходимо снижать уровень неопределенности в информационных потоках в процессе приобретения знаний для этого использовать средства интеллектуального анализа информации и эффективные алгоритмы оптимизации знаний.

Основными отличительными особенностями при построении современных интеллектуальных информационных систем управления знаниями являются распределенность, адаптивность, асинхронность и наличие способности интеллектуального анализа данных и извлечения знаний при принятии решений. Причем акцент развития средств искусственного интеллекта делается на переход от изолированных систем искусственного интеллекта, от индивидуальных систем к распределенному интеллектуальному анализу

информации и разработке многоагентных интеллектуальных систем (МАИС) [3, 4]. При взаимодействии агентов устанавливаются двусторонние и многосторонние динамические отношения, что является необходимым условием формирования виртуальных коллективов и искусственных сообществ в качестве основы самоорганизации как самих агентов, так и отношений между ними.

Основной проблемой реализации подобных моделей на основе построения многоагентных систем является то, что в реальной ситуации многосторонние динамические отношения часто остаются неявными. С другой стороны, улучшение интеллектуальных характеристик информационных систем приобретения и управления знаниями возможно на основе представления тех отношений между элементами информации, которые часто остаются неявным. В этом случае используется онтология, которая формализует неявные отношения [5, 6]. Декларативное представление в онтологиях концептуализации на основе семантических отношений и аксиоматики позволяют считать системы приобретения и управления знаниями интеллектуальными. Для этого необходимо разрабатывать методы и алгоритмы, которые в автоматическом режиме позволят извлекать знания из распределенных и разнородных информационных ресурсов. Заметим, что чем точнее структура онтологии, тем проще её использовать, для распознавания в тексте того или иного компонента категориального аппарата, при построении информационных моделей междисциплинарного пространства знаний (МПЗ).

В настоящее время, несмотря на наличие высоких вычислительных возможностей сетевых аппаратных платформ создание интеллектуальных информационных систем приобретения и управления знаниями (ИИСПУЗ) затруднено. При этом главным фактором, сдерживающих их развитие, является отсутствие теоретических основ для разработки эффективных моделей, методов и алгоритмов семантического поиска, классификации, структуризации и интеграции знаний из распределенных разнородных источников.

Отсутствие данных методов связано со следующими важными фундаментальными проблемами:

- развитие средств моделирования рассуждений, что позволит структурировать неструктурированные данные;
- обработка больших объемов различных знаний в условиях информационной неопределенности.

Восполнить данный пробел и должна монография авторов.

Проблема извлечения и приобретения знаний, включая повышение эффективности процесса построения рассуждений и принятия решений при управлении знаниями из распределенных разнородных источников на основе преодоления информационной неопределенности, требует междисциплинарного подхода, основанного на имеющихся достижениях в области *методов оптимизации, интеллектуального анализа данных и приобретения знаний, искусственного интеллекта, биоинспирированного поиска и принятия решений, нечеткой логики, многоагентных систем, онтологического и имитационного моделирования.*

Данное исследование основано на работах Н. Амосова, П. Анохина, Д. Белла, А. Богданова, М. Бонгарда, И. Букатовой, В. Вагина, Н. Винера, А. Гапоненко, Р. Гиляревского, В. Глушкова, Д. Гольдберга, А. Еремеева, В. Иноземцева, И. Каляева, В. Лефевра, М. Маклюэна, Ё. Масуды, Б. Мильнера, К. Ньюэлла, Г. Осипова, Э. Попова, Д. Поспелова, И. Пригожина, Л. Растригина, А. Смирнова, Д. Смита, А. Стефанюка, Э. Тоффлера, В. Финна, Л. Фогеля, Г. Хакена, Дж. Холланда, В. Цетлина, А. Шрейдера и других российских и зарубежных ученых.

Монографическое исследование состоит из 6 глав.

В 1 главе монографии авторы исследуют теоретические основы получения знаний, опираясь на биологические принципы. В тексте представлены ключевые определения, а также представлено описание процессов приобретения и управления знаниями в глобальной информационной среде. Предложена математическая модель глобальной информационной среды для применения в контексте приобретения знаний. Также в этой главе рассмотрена концепция приобретения знаний, представленная в виде стратегии и основных принципов для решения задач, поставленных в исследовании.

Во 2 главе авторы углубляются в изучение основ приобретения и управления знаниями, предлагают новый образ знаний, объединяющий в едином системном элементе модифицированные модели представления и управления знаниями. Также в данной главе описана формализованная онтологическая модель представления знаний. Сформулированы основные постановки задач исследования.

В 3 главе авторами описана концепция, предложены базовые принципы и стратегия приобретения и управления знаниями, позволяющие увеличить объемную долю семантически обработанных знаний в глобальном информационном пространстве и интенсифицировать их совершенствование и применение. Построена комплексная модель интеллектуального агента, позволяющая учесть возможность реализации различных режимов поведения при одинаковом наборе функций агента. Предложен новый подход определения и усиления когнитивных свойств интеллектуальных агентов. На основе предложенных когнитивных свойств построена событийная имитационная модель рассуждений коалиций агентов при решении задачи классификации знаний. Разработан комплексный подход решения задачи классификации на основе применения оптимальных разделяющих гиперповерхностей.

Глава 4 посвящена вопросам построения информационных моделей, описывающих значимые для проводимого исследования параметры и переменные величины процессов решения основных задач приобретения и управления знаниями. Для решения задачи интеграции на метауровне знаний, авторами предложена модифицированная модель онтологии, позволяющая построить многоуровневую информационную модель среды интеграции знаний. Для определения устойчивых междисциплинарных связей использован принцип силовой релаксации. Построена математическая модель диффузии знаний как основы информационного процесса семантической фильтрации. Разработана интегрированная модель структурирования знаний, позволяющая реализовать настройку весовых коэффициентов при моделировании рассуждений на метауровне знаний.

В 5 главе построена информационная модель оценки эквивалентной семантической близости, которая позволяет определить степень сходства предикатов понятий разных онтологий на основе процедуры их отображения. Авторами разработан комплекс модифицированных биоинспирированных методов (бактериального, обезьяньего и кукушкиного поиска) с децентрализованной схемой управления для решения задачи семантического поиска знаний при отображении онтологических структур. Предложенные методы имеют полиномиальную сложность, что позволяет масштабировать их для достаточно больших размерностей информационного пространства поиска реше-

ний. Эффективность разработанных модифицированных биоинспирированных методов обусловлена введением в механизмы поиска элементов диверсификации информационного пространства, что повысило аттрактивность применяемых процедур.

Глава 6 посвящена разработке моделей обучения и передачи знаний за счет использования меметических вычислений, облачных технологий и Интернета вещей (*Internet of Things, IoT*) при решении задач поисковой оптимизации. Меметические вычисления являются новой парадигмой компьютеринга, в основе которой лежит понятие мема в качестве своеобразного строительного блока знаний. Анализируется эволюция алгоритмов поисковой оптимизации, инспирированных мемами, проблемы выбора мемов из базы знаний. Рассматривается модель меметического автомата для передача машинного знания с целью повышения производительности интеллектуальных эволюционных систем при решении задач поисковой оптимизации. Предлагаются последовательный и параллельный оптимизатор передачи мемов.

Слова признательности авторы адресуют директору Института компьютерных технологий и информационной безопасности Южного федерального университета д-ру технических наук Г.Е. Веселову за поддержку издания книги.

Авторы выражают искреннюю благодарность рецензентам пособия – доктору технических наук, профессору И.Г. Сидоркиной, доктору технических наук, профессору А.Г. Коробейникову, а также своим коллегам по работе в Институте компьютерных технологий и информационной безопасности, которые взяли на себя нелегкий труд ознакомления с рукописью и высказали немало ценных советов и конструктивных замечаний, способствовавших устранению неточностей и улучшению содержания монографии.

ГЛАВА 1. УПРАВЛЕНИЕ ЗНАНИЯМИ КАК РЕЗУЛЬТАТ ЭВОЛЮЦИИ ИНФОРМАЦИОННЫХ ТЕХНОЛОГИЙ

1.1. Проблема структурирования знаний в глобальном информационном пространстве

Большинство методов инженерии знаний, а также теории управления знаниями в XX веке были направлены на извлечение так называемых неявных знаний, которые плохо поддаются формализации, и требуют решения задач поиска, представления и обработки неструктурированной информации. Данные задачи решались методами полного перебора, что требовало привлечения мощных вычислительных ресурсов, которые до некоторого времени справлялись с ростом объема формализованных знаний.

К неспособности вычислительных ресурсов эффективно обрабатывать весь объем ценной информации привел экспоненциальный рост информационного объема формализованных знаний в глобальном информационном пространстве. В результате к 2008 году это привело к появлению нового научного направления «Технологии *Big Data*», а позднее – к созданию вычислительных кластеров, имеющих параллельные серверные архитектуры большой мощности. Но, несмотря на это эксперты считают, что в настоящее время достаточно проблемно реализовать качественный поиск и обработать 99,5% ценных знаний в неструктурированных объемах информации глобальной сети. Поэтому актуальной проблемой сегодня стало эффективное решение задач приобретения и управления формальными знаниями, что позволит сократить избыточность и повысить достоверность знаний в глобальном информационном пространстве.

Заметим, что увеличение объема ценной информации не является гарантией повышения эффективности ее идентификации и применения. Более того, информационные источники имеют сложную многоуровневую иерархию. Особый интерес представляют информационные мета-каналы, содержательной составляющей которых, помимо непосредственно информации и знаний, являются явные и неявные закономерности, возникающие между элементами информации и знаний, на уровне междисциплинарных отношений.

Каждый вид источника информации и знаний в процессе развития достигает максимума востребованности, после чего стабилизируется

на данном уровне, а затем, по прошествии определенного времени, начинает постепенно терять свою ценность и значимость. Отметим, что в большинстве случаев максимума источник информации и знаний достигает быстро, а процесс потери значимости зачастую занимает длительное время (годы и десятилетия) [7]. Данное перераспределение ценности информации как основы формирования элементов знания в глобальной сети является эволюционным процессом, математическую модель которого представим далее.

Обозначим ценность знаний V_y в глобальном информационном пространстве в текущем году y . Пусть значение данного параметра измеряется в условных единицах стоимости всех ценных знаний [8, 9]. Допустим, что в $(y-1)$ году имелось N видов мета-каналов поступления формальной информации для получения нового знания в глобальной сети с ценностью $S_{y-1}^i, i = 1, \dots, N$. В таком случае ценность знаний

Ву-1 опишем следующей формулой [8]:

$$V_{y-1} = S_{y-1}^1 + S_{y-1}^2 + \dots + S_{y-1}^N = \sum_{i=1}^N S_{y-1}^i. \quad (1.1)$$

Смоделируем ситуацию потери значимости мета-канала с индексом l в году y , с одновременным появлением нового информационного мета-канала с индексом $N+1$. Данную ситуацию опишем следующей формулой [8]:

$$V_y = V_{y-1} - S_{y-1}^1 + S_y^{N+1}, \quad (1.2)$$

тогда из формулы (1.2) получим следующие уравнения [8]:

$$S_y^{N+1} = \Delta V + S_{y-1}^1; \quad (1.3)$$

$$V_y = V_{y-1} + \Delta V. \quad (1.4)$$

Представим ΔV в виде следующего уравнения [8]:

$$\Delta V = \alpha_y V_{y-1} + \beta_y V_{y-1}, \quad (1.5)$$

где α_y – коэффициент изменения ценности знаний при вводе S_y^{N+1} , а β_y – коэффициент изменения ценности знаний при выводе S_{y-1}^1 . Тогда, исходя из уравнений (1.4) и (1.5), получим следующую формулу [8]:

$$V_y = V_{y-1} + \alpha_y V_{y-1} + \beta_y V_{y-1} = V_{y-1}(1 + \alpha_y + \beta_y). \quad (1.6)$$

Очевидным является то, что в условиях экспоненциального роста информационного объема глобальной сети суммарный коэффициент в формуле (1.6) $1 + \alpha_y + \beta_y > 1$.

Актуальной и значимой научной проблемой также является создание моделей эволюции состояний глобального информационного

пространства для построения достоверных прогнозов его развития. Для решения данной проблемы необходимо применение математической теории динамических систем, позволяющей сформулировать закон эволюции параметров и задать состояние динамической системы в виде последовательности величин, характеризующих ее в определенный момент времени. Исследование динамики изменения источников знаний и информационного объема глобальной сети в рамках решения задач приобретения и управления знаниями соответствует эволюционному подходу. С точки зрения анализа роста объемов неструктурированного знания изменение состояния информационного пространства во времени не поддается точному прогнозу. Динамические процессы, происходящие в нем, демонстрируют стремление к достижению состояния равновесия между вычислительными ресурсами и информационными объемами системы.

Построим эволюционную математическую модель изменения состава информационных источников в глобальной сети на основе применения системы обыкновенных нелинейных дифференциальных уравнений.

Рассмотрим интервал времени $[Y_1, Y_N]$. Допустим, что в каждый момент Y_1, Y_2, \dots, Y_N возникает как минимум один новый вид информационного мета-канала, имеющий условную ценность $s_i(y)$, причем, каждый новый вид мета-канала (кроме первого) изменяет ценность остальных k ($k = 1, 2, \dots, N-1$) видов мета-каналов с меньшими порядковыми номерами, как это было показано в уравнении (1.5) на основе введения коэффициента β_y . Доля изменения ценности остальных мета-каналов D определяется по следующей формуле [8]:

$$D = \beta_{y_i}^* \sum_{k=1}^{N-1} s_k(y), 0 < \beta_{y_i}^* < 1. \quad (1.7)$$

Новый вид информационного мета-канала использует данную долю в качестве своего ресурса. Исходя из формулы (1.7) сформируем разностное уравнение, моделирующее поведение i -го вида мета-канала в период усиления его значимости в глобальном информационном пространстве [8]:

$$s_i(y+1) = s_i(y) + \left[q_i s_i(y) \left(1 - \frac{s_i(y)}{r_i} \right) + \beta_{y_i}^* \sum_{k=1}^{N-1} s_k(y) \right], \quad (1.8)$$

где q_i – пропускная способность канала; r_i – информационно-технологический потенциал канала (данный параметр определяется на основе числовых метрик матриц попарных сравнений признаков и альтернатив в методе анализа иерархий). Отметим, что $\beta_1^* = 0, s_0(y) = 0$.

Представим полученное разностное уравнение непрерывным аналогом, а именно следующим дифференциальным уравнением [8]:

$$\dot{s}_i = q_i s_i \left(1 - \frac{s_i}{r_i}\right) + \beta_{y_i}^* \sum_{k=1}^{N-1} s_k(y). \quad (1.9)$$

Данное уравнение описывает поведение определенного вида информационного мета-канала глобальной сети на интервале времени $[Y_{i-1}, Y_i]$. Ситуация, смоделированная данным уравнением, изменится вместе с появлением следующего нового вида информационного мета-канала, в этом случае разностное уравнение примет следующий вид [8]:

$$s_i(y+1) = (1 - \beta_{y_i+1}^*) \times \left(s_i(y) + \left[q_i s_i(y) \left(1 - \frac{s_i(y)}{r_i}\right) + \beta_{y_i}^* \sum_{k=1}^{N-1} s_k(y) \right] \right). \quad (1.10)$$

$$\dot{s}_i = q_i (1 - \beta_{y_i+1}^*) s_i \left(1 - \frac{s_i}{r_i} - \frac{1}{q_i} \times \frac{\beta_{y_i+1}^*}{1 - \beta_{y_i+1}^*}\right) + \beta_{y_i}^* (1 - \beta_{y_i+1}^*) \sum_{k=1}^{N-1} s_k(y), \quad Y_i \leq y \leq Y_{i+1}. \quad (1.11)$$

При возникновении события, при котором $y = Y_{i+1}$, в соответствии с принятыми начальными условиями происходит появление нового вида информационного мета-канала, после чего i -ый канал передает ему часть своей ценности $\beta_{y_i+2}^*$. Тогда, общий вид системы, описывающей процесс жизненного цикла N каналов во временном интервале $[Y_1, Y_N]$, выглядит следующим образом [8]:

$$\dot{s}_i = q_i V_{y_i} s_i \left(1 - \frac{s_i}{r_i} - \frac{X_i}{q_i}\right) + \beta_{y_i}^* V_{y_i} \sum_{k=1}^{N-1} s_k(y), \quad (1.12)$$

где начальными условиями являются следующие формулы [8]:

$$s_1(Y_0) = W_0 > 0, s_i(Y_0) = 0, i \neq 1. \quad (1.13)$$

$$V_{y_i} = \prod_{k=i+1}^N (1 - 2\beta_{y_k}); \quad (1.15)$$

$$X_i = \sum_{k=i+1}^N \frac{2\beta_{y_k}}{\prod_{j=k+1}^N (1 - \beta_{y_j})}. \quad (1.16)$$

Таким образом, математическая модель эволюционного процесса перераспределения ценности информации как основы формирования элементов знания в глобальной сети содержит следующий набор основных параметров:

- 1) общее число видов информационных мета-каналов на заданном временном интервале с учетом моментов их возникновения;
- 2) пропускная способность и информационно-технологический потенциал видов информационных мета-каналов;

3) коэффициенты изменения ценности информационных мета-каналов;

4) значение ценности информации и знаний в глобальном информационном пространстве в момент времени Y_l .

При этом исчерпывание информационно-технологического потенциала существующих каналов и появление новых информационных источников приводит к возникновению новых видов информационных мета-каналов [8]:

$$ds_i(Y_i)/dy = \varepsilon, \quad (1.17)$$

где ε – малая положительная величина. Именно в этот момент в соответствии с построенной математической моделью появляется $i+1$ информационный мета-канал.

Важной особенностью исследуемых информационных процессов является то, что неконтролируемый поиск и накопление значительного объема ценных знаний не гарантирует их эффективного использования в контексте предметных и функциональных областей определенных сегментов глобальной сети [10]. Зачастую ценность указанных неструктурированных или слабоструктурированных знаний будет рассеиваться с течением времени [11]. Данный недостаток исключает появление синергетического эффекта от приобретения новых знаний. Это делает очевидной необходимость увеличения объема доли глобального информационного пространства, содержащей только качественно структурированные знания [12]. Для обоснования описанной проблемы построим *математическую модель приобретения новых знаний в глобальном информационном пространстве*. При этом ее графическое представление приведено на рис.1.1.

Зададим основные параметры математической модели:

$C(y)$ – объем новых знаний, поступающих в исследуемый сегмент глобальной сети в момент времени y ;

$F(y)$ – количество фильтров в информационном ресурсе, отвечающих за оценку релевантности новых знаний;

$O(y)$ – объем используемых знаний, несоответствующих вновь приобретенным элементам знаний C по смыслу с учетом семантики контекста реализуемого информационного процесса в исследуемом сегменте глобальной сети;

$Z(y)$ – относительная характеристика определенного информационного процесса в исследуемом сегменте глобальной сети, которая содержит оценку интенсивности появления знаний, вновь приобретенных в момент времени y , вместо уже имеющихся [8,9]:

$$Z(y) = 1 - l^*/l, \quad (1.18)$$

где $l, \%$ – процентная доля уже имеющихся знаний; $l^*, \%$ – процентная доля знаний с учетом вновь приобретенных.

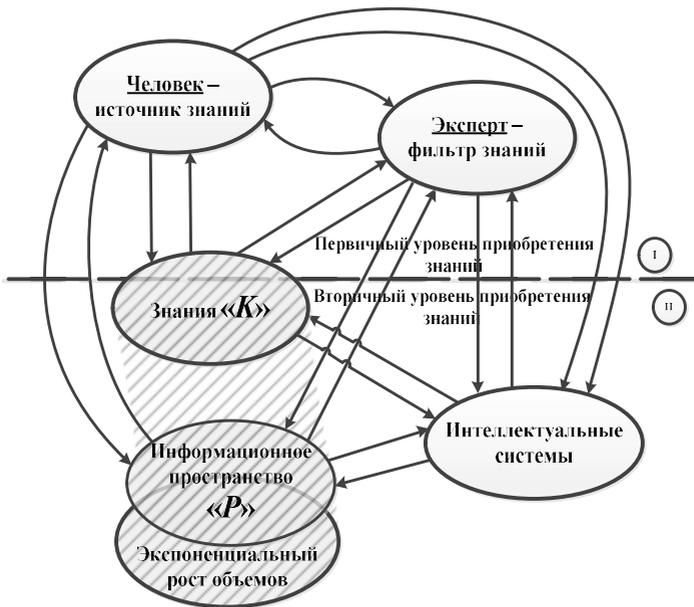


Рис. 1.1. Знания в глобальном информационном пространстве

В ситуации отсутствия сменяемости знаний $Z(y) = 0$, в противном случае – $Z(y) = 1$.

Запишем обыкновенное дифференциальное уравнение (1.19), отражающее динамику появления новых знаний в глобальном информационном пространстве [8]:

$$dC/dy = \gamma C - \delta OC. \quad (1.19)$$

В уравнении (1.19) скорость появления новых знаний C , способствующая проведению процессов их обработки, совершенствования, распределения и применения, прямо пропорциональна объему

этих знаний γC с учетом уменьшения их информационного объема из-за уже имеющихся знаний O , несоответствующих вновь приобретенным элементам знаний по смыслу с учетом семантики контекста δOC . При этом коэффициенты γ и δ отвечают за интенсивность появления новых знаний.

Заметим, что изменения активности F фильтров знаний, для отбора релевантных новых знаний из общего потока, по сравнению с уровнем предыдущей итерации F_* рассчитывается следующим образом (1.20) [8]:

$$dF/dy = \tau OC - \mu(F - F_*). \quad (1.20)$$

Некоторые настройки данных фильтров препятствуют идентификации новых ценных знаний, в случае низких показателей сходства между системно значимыми признаками семантических векторов. Это коэффициент μ , который принимает значение обратное времени применения неосновных ресурсов, и коэффициент τ , который дает информацию об особенностях поведения фильтров, что имеет важное значение в случае конфликта между имеющимися ценными знаниями и вновь полученными. В данном случае основная проблема заключается в сложности идентификации вида события, при котором, с одной стороны, возможно появление выброса, а с другой, изменение параметров исследуемого процесса. В первом случае новая выборка знаний является нерелевантной (выбросом), а во втором, напротив, является значимой для верной оценки хода протекания информационного процесса.

Тогда уравнение, описывающее баланс между этими знаниями при реализации исследуемого процесса, запишется (1.21) [8]:

$$dO/dy = \varphi F - \psi \delta OC - \lambda O. \quad (1.21)$$

При этом скорость роста объема применяемых знаний O и вновь полученных знаний C , будет напрямую зависеть от пропускной способности φF фильтров знаний, а параметр $\varphi \geq 0$ – средняя скорость фильтрации знаний в F . Элемент $\psi \delta OC$ раскрывает вариант воздействия на каналы новых знаний C , $\psi \geq 0$ – средней объем используемых знаний O для исключения возможности применения новых знаний C , несоответствующих семантике контекста исследуемого информационного процесса. Следующий элемент λO отражает особенности протекания процесса рассеивания ценности

применяемых знаний, $\lambda > 0$ – коэффициент, приобретающий значение обратно пропорциональное времени рассеивания ценности применяемых знаний O .

Представим уравнение (1.22) для задания относительной характеристики скорости смены устаревающих знаний новыми в момент времени y при протекании некоторого информационного процесса в рассматриваемой части глобальной сети [8]:

$$dZ/dy = \omega C - \xi Z. \quad (1.22)$$

Таким образом, скорость смены устаревающих знаний новыми прямо пропорциональна объему вновь приобретенных знаний C , имеющих коэффициент пропорциональности $\omega > 0$. Более того, в уравнении (1.22) применяется коэффициент инертности этого процесса $\xi \geq 0$, который поддерживает процедуру периодического возвращения ранее используемых и исключенных из рассмотрения знаний O . Описанная система дифференциальных уравнений (1.19) – (1.22) имеет следующий вид [8]:

$$\begin{aligned} dF/dy &= \tau OC - \mu(F - F_*), \\ dO/dy &= \varphi F - (\psi \delta C + \lambda)O, \\ dC/dy &= (\gamma - \delta O)C, \\ dZ/dy &= \omega C - \xi Z. \end{aligned} \quad (1.23)$$

Введем начальные условия для выполнения данной системы дифференциальных уравнений [8]:

$$F(y_0) = F_0 \geq 0; O(y_0) = O_0 \geq 0; C(y_0) = C_0 \geq 0; Z(y_0) = Z_0 \geq 0. \quad (1.24)$$

Система дифференциальных уравнений (1.23) с начальными условиями (1.24) представляет собой *математическую модель извлечения новых знаний в глобальной информационной сети*. Рассмотрим первые три уравнения данной системы (1.24), после чего используем полученные результаты для $Z(y)$, учитывая то, что эта переменная имеет место только в четвертом уравнении системы.

Введем вектор-функцию $X(y) = (F(y), O(y), C(y), Z(y))$. Исследуем особенности изменения компоненты вектор-функции $X(y)$ при полученных в (1.23) связях. Будем учитывать параметры рассматриваемой системы дифференциальных уравнений, а также начальные условия X_0 . Система дифференциальных уравнений имеет два стационарных решения и находится при них в состоянии

покоя. Компоненты вектор-функции $X(y)$ принимают следующие значения [8]:

$$X_1 = (F_1, O_1, C_1, Z_1) = (F_*, \varphi F / \lambda, 0, 0), X_2 = (F_2, O_2, C_2, Z_2),$$

где

$$\begin{aligned} F_2 &= \frac{\tau\lambda\gamma - \psi\mu\delta^2 F_*}{\delta(\tau\varphi - \mu\psi\delta)}, \\ O_2 &= \frac{\gamma}{\delta}, \\ C_2 &= \frac{\mu(\lambda\gamma - \delta\varphi F_*)}{\gamma(\tau\varphi - \mu\psi\delta)}, \\ Z_2 &= \frac{\omega\mu(\lambda\gamma - \delta\varphi F_*)}{\xi\gamma(\tau\varphi - \mu\psi\delta)}. \end{aligned}$$

Представленные стационарные решения принимают положительные значения, что указывает на применимость в следующих двух областях исследуемых нами величин [8]:

$$\begin{aligned} \Theta_1 &: \begin{cases} \delta\varphi F_* > \lambda\gamma \\ \mu\psi\delta > \tau\varphi \end{cases}, \\ \Theta_2 &: \begin{cases} \delta\varphi F_* < \lambda\gamma \\ \mu\psi\delta < \tau\varphi \end{cases}. \end{aligned}$$

Полученные в указанных областях стационарные решения системы дифференциальных уравнений имеют абсолютно различные признаки. Характерной особенностью для использования области Θ_2 является исключение каких-либо барьеров интеграции вновь приобретенных знаний в рассматриваемую часть сети, поэтому смысл имеет только анализ математической модели (1.23), (1.24) в области параметров Θ_1 .

Для описания динамики появления новых знаний и их последующего использования в процессах интеграции или замещения потерявших свою ценность знаний применим следующую дополнительную двумерную систему дифференциальных уравнений [8]:

$$\begin{aligned} dO/dy &= \varphi F - (\psi\delta C + \lambda)O, \\ dC/dy &= (\gamma - \delta O)C. \end{aligned} \quad (1.25)$$

Система (1.25) представляет собой редукцию (1.23) в случае, если $\tau = 0$ и $F = F_*$. Опишем для системы (1.25) в Θ_1 имеющиеся место стационарные решения [8]:

$$X_1 = (O_1, C_1) = \left(\frac{\varphi F_*}{\lambda}, 0 \right),$$
$$X_2 = (O_2, C_2) = \left(\frac{\gamma}{\delta}, \frac{\delta \varphi F_* - \lambda \gamma}{\gamma \psi \delta} \right).$$

Представленные выше стационарные решения системы (1.25) дают основание утверждать, что применение определенных структурированных знаний $O = \varphi F_* / \lambda$ в устоявшихся информационных процессах приведет к появлению некоторого барьера $C(y_0) = C^* = \frac{\delta \varphi F_* - \lambda \gamma}{\gamma \psi \delta}$. Указанный барьер препятствует интеграции новых слабоструктурированных знаний в объеме $C(y) \leq C^*$. В этом случае, данные новые знания, даже при наличии определенной ценности, не попадут в рассматриваемый сектор глобальной сети и не будут влиять на характеристики протекания исследуемого информационного процесса. Описанная научная проблема имеет высокую значимость и отрицательно влияет на развитие технологий извлечения и управления знаниями в глобальной сети.

Для построения модели знаний в глобальной сети представим полный объем структурированных знаний переменной K , и напротив, полный объем неструктурированных или слабоструктурированных – переменной P , как это показано на рисунке 1.1, тогда необходимо максимизировать значение $G = K/P \rightarrow \max$. При экспоненциальном росте K значение G ежегодно уменьшается. Для решения данной проблемы выделим два базовых уровня приобретения и управления знаниями. На первом уровне источником знаний являются люди, а на втором - интеллектуальные системы, способные обрабатывать большие объемы информации, приобретать и генерировать новые знания, что позволяет рассчитывать на увеличение процента структурированных знаний в глобальной сети.

1.2. Эволюционная модель развития информационных технологий

Первый и наиболее значительный рост потенциальных возможностей и качественных новаций в применении информационных технологий был обусловлен созданием универсального многоцелевого процессора в 1969 году компанией *Intel Corporation* и технологии локальных компьютерных сетей *Ethernet* в 1973 году Б. Меткалфом. Сложно

переоценить стремительность и важность дальнейших открытий в области ИТ и их практических реализаций (рис. 1.2).

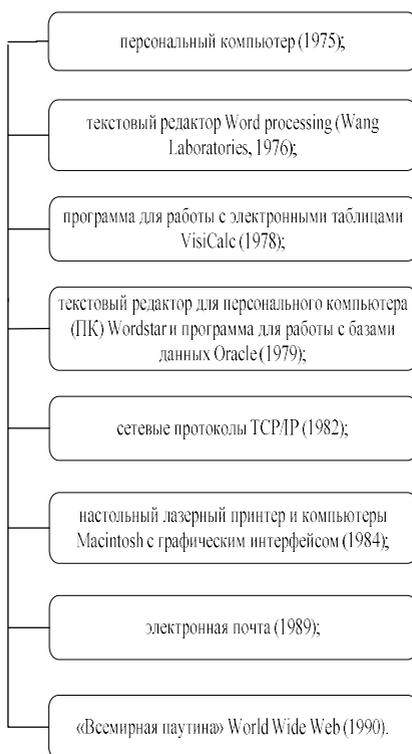


Рис. 1.2. Ретроспектива достижений в области информационных технологий

Такое стремительное распространение компьютеров и программного обеспечения радикально изменило структуру мирового экономического развития, вывело информатику в разряд самостоятельных наук и сделало информационные системы и технологии основой экономики развитых стран.

В связи с этим, необходимым условием для получения стратегического преимущества является разработка методов, обеспечивающих переход от хранения и обработки данных к извлечению и управлению знаниями. При этом эффективность процедур накоп-

ления и обработки знаний будет расти только в условиях интеллектуальности информационных систем, а также их самоорганизации [13, 14]. Описанные свойства информационных систем направлены на разработку средств и инструментов способных создать интеллектуальную глобальную сеть.

Для достижения этой цели необходимо провести структурирование информации и знаний, что сделает их восприятие доступным для технических средств, способных выполнять логический анализ и генерировать необходимые выводы [7, 11, 12, 15]. Для этого был создан ряд стандартов (рис. 1.3), содержащейся в сети Интернет в рамках проекта *Semantic Web (W3C)*.

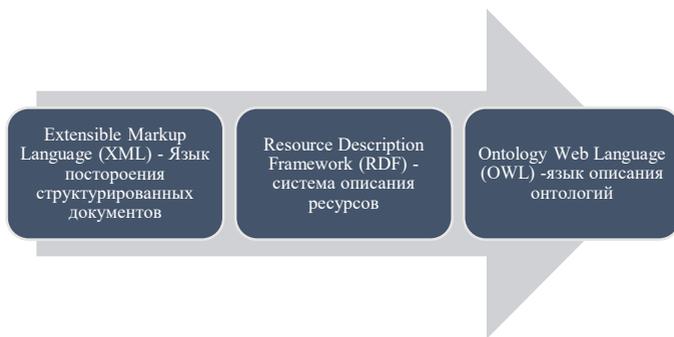


Рис. 1.3. Основные стандарты структурирования информации

Информационные системы (ИнфС), построенные для решения подобных задач, являются саморазвивающимися и интеллектуальными, а это, в свою очередь, требует использования методов искусственного интеллекта (ИИ), которые не имеют жестко заданной логики рассуждений и способны продуцировать нестандартные решения сложных оптимизационных задач. При этом необходимо учитывать не только структуру документов, но и обрабатывать его семантику. В связи с этим, активно развиваются технологии проектирования информационных систем на принципах адаптивного эволюционного моделирования, что позволяет создавать заданную ИнфС с помощью методов автоматического программирования.

Объединение информационных систем в сети создает связанное пространство, которое способно эволюционировать, и является абстрактным аналогом биосферы [16, 17], что позволяет выявить

определенное сходство между биологической эволюцией и эволюцией информационных систем.

Рассмотрим основные признаки эволюции с точки зрения техногенеза в сфере ИТ. Механизмы существования ИТ-рынков в полной мере реализуют «борьбу за существование». «Мутация» информационных систем происходит не случайно, но в совокупности учитываемых факторов вполне не предсказуемо. «Естественный отбор» проявляется в исчезновении с рынка бесперспективных разработок («видов») ИТ.

Единственным серьезным различием биологической и информационной эволюций является отсутствие во второй на данном моменте развития «механизмов самовоспроизводства». Информационным субъектам, как и биологическим, свойственна высокая «типизация» составляющих их элементов [11, 16, 17]. Это утверждение подтверждается тем, что информационные субъекты дискретны и детерминированы. Аналогией с «обменом веществом и энергией» для информационных систем стали, с одной стороны, данные, информация и знания, а с другой – программные и аппаратные ресурсы. «Раздражимость» информационных систем обусловлена реакцией на внешние запросы, обратную связь и поступающую априорную информацию. «Гомеостазом» будем считать центральную для информационных систем проблему целостности, т.к. на данный момент не создано автоматических средств поддержки и целостности, поэтому большинство систем крайне неустойчивы. Под «наследованием» понимается повторное использование удачных решений при обновлении версий программного обеспечения. Индивидуальное развитие («онтогенез») обусловлено использованием декомпозиции для разработки полноценной архитектуры информационной системы, усложняясь с уровня «черного ящика». «Филогенез» информационных технологий может быть рассмотрен на примере эволюционного развития программного обеспечения с формированием «базовых ветвей» семейств языков программирования и дальнейшим «взрывом видового разнообразия», когда практически одновременно были разработаны сотни языков программирования, например язык «perl» должен был называться «pearl» – *Practical Extraction and Report Language* (жемчужина), помешало наличие другого языка программирования с таким же названием. Впоследствии многие языки исчезли, не получив известности,

сокращение и вырождение в данном случае можно сравнить с «естественным отбором», а последнее появление новинок (*python, ruby, erlang, golang*) – с возникновением «новой базовой ветви эволюции».

Представим верхний уровень эволюции информационных технологий на примере развития *интеллектуальных информационных систем приобретения и управления знаниями (ИИСПУЗ)*. Участие ИИСПУЗ в управлении сложными процессами обеспечивает:

- параллельную оценку и анализ оперативной обстановки;
- своевременность и оптимальность принимаемых решений;
- координацию исполнения управляющих воздействий;
- контроль качества исполнения принимаемых решений;
- адаптацию жизненного цикла на основе обратной связи по управлению.

Управление.

Цикл управления знаниями представляется в следующем виде (рис. 1.4).

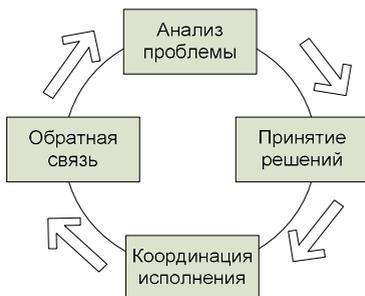


Рис. 1.4. Цикл управления знаниями

Таким образом, ИИСПУЗ, участвующая в управлении сложными процессами, является *активной* с точки зрения контроля отклонений от заданного диапазона или нештатного поведения пользователей [18]. Такая система формирует модель жизненного цикла и обрабатывает плановые и фактические аспекты исследуемых процессов, оперативно создавая альтернативные модели развития, что позволяет ИИСПУЗ реализовывать функции *обработки событий*. При этом, вся информация, получаемая, генерируемая и обрабатываемая системой имеет ярко выраженную временную составляющую. Логика подобной интеллектуальной информационной системы представлена прогнозной моделью структуры будущих событий с возможностью проработки альтернативных вариантов. Дальнейшее определение областей принятия решений

в такой модели позволяет достичь высокой скорости реакции системы на любые воздействия со стороны внешней и/или внутренней среды исследуемого процесса (объекта). Динамическая модификация жизненного цикла объекта за счет реализованных обратных связей наделяет информационную систему способностью к самообучению.

При чем степень устойчивости такой системы зависит от сложности ее организации, о чем говорит основной принцип синергетики – чем сложнее система, тем она устойчивей. Напротив, стагнация и последующее уничтожение интеллектуальной информационной системы начинается с упрощения ее состава.

1.3. Эволюция знаний

Понятие «знание» является общепринятым для неформализованного использования. Особого рассмотрения требует термин «управление знаниями» (*knowledge management*), так как в этом случае от смысла толкования понятия «знание» зависят цель, архитектура и характеристики интеллектуальных информационных систем, основанных на знаниях.

В искусственном интеллекте и системах, основанных на знаниях, знание представляет собой: (1) множество утверждений о свойствах объектов, (2) закономерности процессов и явлений, (3) правила логического вывода одних утверждений из других, (4) правила использования знаний для принятия решений. При этом отличие знаний от данных состоит в их структурированности и активности. Представим на рис. 1.5 одну из классификаций основных типов знаний [19].

Одной из основ построения информационных моделей интеллектуальных систем является логический вывод некоторого заключения φ , полученного по результатам обработки посылок $\varphi_1, \dots, \varphi_n$.

В общем случае логический вывод считается построенным, если в результате обработки по правилам дедуктивного вывода определенной упорядоченной последовательности математических выражений (аксиом, гипотез, заключений) получена необходимая итоговая формула [19].

Рассуждение – применение дедуктивных и иных эвристических правил логического вывода, а также некоторого числа управляющих воздействий для получения заключения из посылок. Искусственный интеллект с этой точки зрения будем считать совокупностью способностей.

Интеллектуальные системы: эволюция моделей и методов приобретения, управления и передачи знаний



Рис. 1.5. Классификация типов знаний

Согласно [19], под принципиальными особенностям ИИ будем понимать: выявление существенных закономерностей в знаниях; рефлексия; способность логично рассуждать; определение цели; выбор инструментов и средств для ее достижения; наличие позна-

вательной активности; элементы адаптации к внешним воздействиям; возможность самообучения и формирования обобщений; планирование и реализация познавательных процедур.

С учетом вышесказанного любая интеллектуальная система должна включать в себя гибкий интерфейс и решатель задач, который будет генерировать рассуждения и производить вычисления. Здесь функция самообучения необходима для расширения базы знаний (БЗ), а этапами, необходимыми для выполнения синтеза познавательных процедур, являются система связанных аналогий, индукция и абдукция.

Один из способов построения интеллектуальных систем подразумевает применение конструкций на основе квазиаксиоматических теорий (КТ) [19]. *Моделью КТ* является кортеж длины три $K = \langle M_p, M_h, O_c \rangle$, где M_p – частичная формализация исследуемой предметной области в виде множества принципов; M_h – динамичное множество гипотез с возможностью изменения и дополнения в процессе исследования; O_c – правила вывода; $O_c = O_{c1} \cup O_{c2}$, O_{c1} – дедуктивные правила; O_{c2} – правдоподобные правила.

Выполнение процесса преобразования идей в понятия является обязательным условием понятийного построения знаний при создании интеллектуальных систем. *Идея* – это мысленный прообраз (интуитивный терм) какого-либо действия, усиленный релевантным знанием [19]. Обозначим идею термом T , сформированным на множестве высказываний. Определим знания, входящие в данный терм как множество высказываний, связанных друг с другом отношением релевантности φ . Наличие «заданного нечеткого отношения» между элементами a и b идентифицирует отношение релевантности φ . Тогда, согласно [19], после описания содержания разрабатываемой интеллектуальной системы (ИС) и задания всех отображений описаний и структуры реализации ИС, произойдет упорядочивание значений идеи T и ее трансформация в понятие T' .

Обработка больших массивов нечеткой слабоструктурированной информации является основной проблемой, сопутствующей функционированию ИС. Упрощение данной проблемы основано на придании множеству информационных объектов упорядоченного вида с определенной структурой и иерархией.

Рассмотрим иерархию тесно связанных и общеизвестных понятий «данные», «информация» и «знание» (рис. 1.6).



Рис. 1.6. Иерархия понятий, предложенная Р. Акоффом

Один из классиков исследования операций Р. Аккофф [20] дал следующую обоснованную иерархию данных понятий (рис. 1.7).

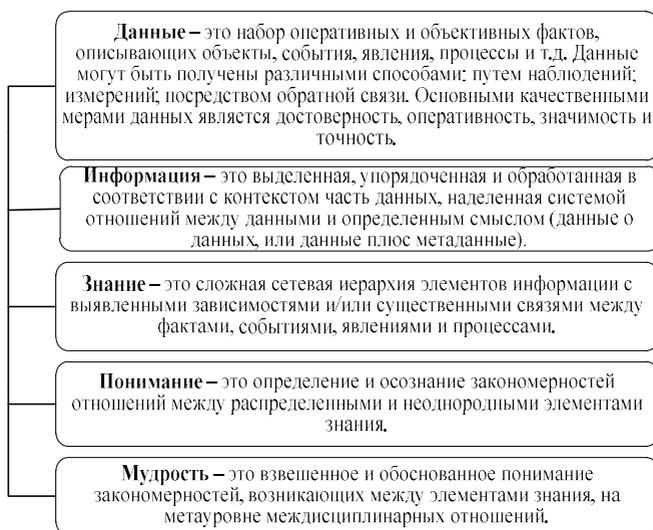


Рис.1.7. Основные информационные категории

Тогда иерархию понятий, предложенную Р. Акоффом, представим в виде «пирамиды» (рис. 1.8). Из анализа рисунка 1.8 следует, что прохождение по уровням (микро, макро и метауровню) иерархии данных определений происходит не с помощью суммирования, а на основе повышения качества знаний на каждом из этих уровней. При этом, процессы извлечения и управления знаниями требуют формализации процедур семантического поиска при обработке макро- и мета- уровней.



Рис. 1.8. «Пирамида познания» Р. Акоффа [20]

Описание найденных кластеров в контексте исследуемой модели представления знаний происходит на основе построения семантического вектора информационного ресурса. Скалярное произведение семантических векторов позволяет оценить релевантность исследуемых знаний. Релевантность тем значительнее, чем выше результат скалярного произведения. На рисунке 1.9 представлен пример сравнения элементов семантических векторов. Обучение нейронной сети с помощью накопленной поисковой статистики позволяет строить схожие вектора для близких по смыслу текстов, а также различные – для семантически разнородных знаний.

В частности, запросы к информационно-поисковым системам обрабатываются за счет сопоставления полученных для исследуемых ресурсов семантических векторов, которые строятся с применением векторных репрезентаций слов, где значение имеют лишь расстояния между конкретными векторами, а не сами вектора.

Семантический вектор 1	Y_{17}	Y_{18}	Y_{19}	Y_{20}	Y_{21}	Y_{22}	Y_{23}	Y_{24}	Y_{25}	Y_{26}	Y_{27}	Y_{28}	Y_{29}	Y_{30}	Y_{31}	Y_{32}	Y_{33}
Семантический вектор 2	X_{17}	X_{18}	X_{19}	X_{20}	X_{21}	X_{22}	X_{23}	X_{24}	X_{25}	X_{26}	X_{27}	X_{28}	X_{29}	X_{30}	X_{31}	X_{32}	X_{33}

Рис. 1.9. Пример сравнения элементов семантических векторов

Семантический вектор состоит из множества весовых коэффициентов понятий $\omega_{i,j}$, которые вычисляются методом *tf.idf* по следующей формуле [21]:

$$\omega_{i,j} = pf_{i,j} \times idf_i = pf_{i,j} \times \log \frac{N}{n_i}, \quad (1.26)$$

где N – число ресурсов; n_i – число ресурсов, включающих понятие p ; $pf_{i,j}$ – частота встречаемости понятия p в ресурсе d_j ; idf_i – значение обратное нормализованной частоте встречаемости ресурсов.

Ресурсы и запросы к ним представляются данными весовыми коэффициентами. Пусть d – это ресурс, а q – это запрос, которые состоят из последовательностей понятий. В векторном пространстве ресурс d и запрос q описаны в виде следующих векторов весовых коэффициентов [21]:

$$\vec{d} = (\omega_{1,d}, \omega_{2,d}, \dots, \omega_{n,d}) \text{ и } \vec{q} = (\omega_{1,q}, \omega_{2,q}, \dots, \omega_{n,q}). \quad (1.27)$$

Семантическая близость между ресурсом d и запросом q определяется величиной корреляции между заданными в (1.27) векторами [21]:

$$sim(q, d) = \cos(\vec{q}, \vec{d}) = \frac{\vec{d} \times \vec{q}}{|\vec{d}| \times |\vec{q}|} = \frac{\sum_{i=1}^n \omega_{i,d} \times \omega_{i,q}}{\sqrt{\sum_{i=1}^n \omega_{i,d}^2} \times \sqrt{\sum_{i=1}^n \omega_{i,q}^2}}, \quad (1.28)$$

$$sim(q, d) \in [0,1] \forall \omega_{i,d}, \omega_{i,q} \geq 0.$$

Каждый информационный ресурс в классических моделях описывается набором понятий. При ранжировании результатов поиска применяется оценка семантической близости данных наборов. Отсутствие учета особенностей естественных языков, таких как синонимия, омонимия и полисемия является ключевым недостатком подобных моделей.

Таким образом, расстояние от слова до центра определенного кластера в векторном пространстве вычисляется через семантический вектор данного слова. Сложение семантических векторов отдельных слов, входящих в исследуемый информационный ресурс, позволяет построить семантический вектор всего этого ресурса. Расстоянием между ресурсами в информационном пространстве считается косинусная мера сходства между их семантическими векторами.

Современный этап характеризуются полномасштабным развитием технологий управления знаниями. В науке и экономике именно сложные структуры знаний обеспечивают стратегическое преимущество, а важной проблемой становится не только создание, но и эффективное совершенствование и применение знаний [22].

Девенпорт и Прусак (одни из основоположников теории управления знаниями) считали, что «знания – это сочетание оформленного опыта, ценностей, контекстной информации и взглядов эксперта, которая дает схему для оценки и объединения нового опыта и информации. В организациях они зачастую попадают не только в документы или хранилища, но и в организационные процедуры, процессы, практику и нормы» [23]. Другой известный специалист в данной области И. Нонака предложил модель в виде спирали взаимодействия явных и неявных знаний [24], состоящей из последовательности процессов их преобразования: социализации (неявные в неявные); экстернализации (неявные в явные); комбинации (явные в явные); интернализации (явные в неявные).

Б.З. Мильнер, напротив, представил систему управления знаниями [25] в виде набора циклических управленческих процедур, повышающих эффективность поиска, извлечения и применения ценной информации.

С учетом данных определений представим обобщенную модель знания в виде графической диаграммы верхнего уровня декомпозиции (рис. 1.10).

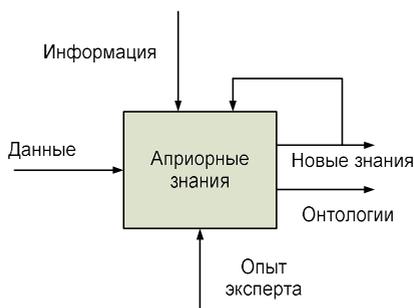


Рис. 1.10. Модель процесса получения нового знания

Таким образом, новое знание можно получить только в процессе обработки уже имеющегося, а процесс приобретения (прироста) нового знания имеет все признаки эволюции. В этом случае эффективность процессов получения нового знания напрямую зависит от скорости эволюции. При этом знания накапливаются и развиваются генетически. Этому способствуют процессы изменчивости, репликации, вариации и селекции идей.

Преподавательская деятельность и массовые научные мероприятия реплицируют идеи и дают возможность продуцировать новые, строя их на основе уже признанных. Обсуждение результатов экспериментальных исследований управляет процедурой отбора или отклонения идей. Причем, процедура выбора научных идей отличается крайне строгими механизмами, основанными на существующей реальности и особенностях критической дискуссии.

Таким образом, основой эволюционного развития знаний являются процессы, реализуемые на множестве распределенных разнородных информационных источников. Каждый такой процесс имеет характерные особенности:

- для запуска процесса *изменчивости* используется система связей на множестве элементов знания на междисциплинарном уровне;

- для развития *репликации* как способности автоматической генерации корректных ответов на нерегламентированные запросы используются адаптивные методы индексации исследуемой информации с сохранением полученных моделей распределения;

- для повышения эффективности процесса *селекции* применяются средства фильтрации знаний (knowledge sifters).

При этом бессистемный сбор знаний, не учитывающий специфику отношений между понятиями и индексирования по субъектам поиска, препятствует эволюции знаний и блокирует возможности для продуцирования новых идей.

1.4. Экосистема знаний

Системный анализ устанавливает структурные связи между элементами систем. Исследование *связей* и *отношений* между элементами необходимо проводить с учетом существующего *контекста*, потому что систему нельзя понять с помощью анализа, так как только свойство целого является основным свойством систем, которым не обладает ни одна из ее частей, в то же время, свойства частей могут быть выделены только из организации целого. Таким образом, системное мышление контекстуально и противоположно аналитическому мышлению [26]. Это утверждение всегда воспринималось как истина в биологии, но менее чем 100 лет было также подтверждено и квантовой теорией. Данный научный прорыв дал основание утверждать то, что невозможно разложить окружающий нас материальный мир на независимо суще-

ствующие элементарные единицы. Так и *логическая схема рассуждений* интеллектуальной информационной системы приобретения и управления знаниями должна строиться на основе нередуцируемого перцептуального паттерна (значимой организованной целостности), что позволит главной цели превысить сумму составляющих ее подзадач. Из этого можно предложить следующую *концепцию* эволюционного развития интеллектуальных информационных систем. *Эволюция информационных систем позволит им иметь целую интегрированную структуру подобную природным системам.* Наиболее ярким примером из природы, соответствующий предложенной концепции является роевой интеллект, представляющий собой многоагентную систему, обладающую коллективным интеллектом и способностями к адаптации и превышающими возможности отдельных индивидуумов [27].

Представим всю экосистему схематично в виде сети с несколькими узлами (рис. 1.11). Тогда, в целом, сетями внутри сетей будет показана взаимозависимость всех явлений. Причем, будем понимать только *сети, вложенные в сети*, при разработке моделей источников знаний, и примем метафору «сети», при которой новое качество и структуру всей «паутины» задает согласованность опосредованных отношений между элементами знания.

Среди множества задач приобретения и управления знаниями, особое место, занимают неструктурированные задачи обработки информации из распределенных неоднородных источников. В этих задачах цели, ограничения, условия представляются в неструктурированном виде и задаются неявно [19].

Из методологии системного анализа известно, что для автоматизированного решения неструктурированных задач необходимо использование знаний эксперта для приведения их к структурированному виду [19]. В этой связи, необходимо применение универсальных моделей интеллектуального приобретения и обработки знаний с формализацией семантики поиска и принятия решений из распределенных неоднородных источников на пересечении различных предметных областей. Тогда реальная среда для решения задач извлечения и управления знаниями представляет собой сложный для формализации комплекс предметных областей, в котором на первые позиции выходят неструктурированные задачи выявления и идентификации элементов знания.



Рис. 1.11. Экосистема знаний

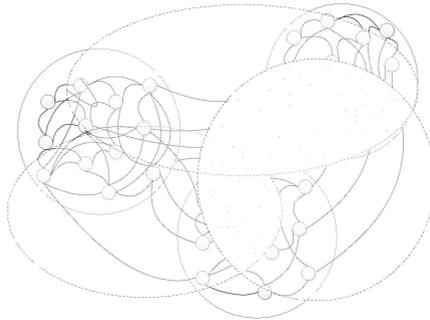
Построение модели подобного информационного пространства (рис. 1.12) основано на концепции агентности, предполагающей множественность и автономность, одновременно со связанностью [28]. При этом такое информационное пространство характеризуется свойствами *частичной наблюдаемости, динамики, непрерывности, эпизодичности, стохастичности*.

Частичная наблюдаемость среды решения проблем приобретения и управления знаниями (рис. 1.12) обусловлена работой агента в рамках ограниченных пространственных пределов, определенных глубиной поиска и мощностью окрестности рассматриваемых связей. В большинстве случаев это малая часть информационного пространства, с характерной неполнотой информации об отношениях между элементами знания.

Изменение с течением времени свойств и состава элементов, а также характеристик отношения в среде для решения задач приобретения и управления знаниями задает динамику среды с точки зрения автономных агентов. Непрерывность связана с субъективным восприятием агента, восстанавливающим непрерывную модель среды, характеризующейся неточностью, связанной с погрешностями восприятия агента. Эпизодичность пространства знаний связана с тем, что агент не обрабатывает определенные области среды.

Стохастичность реальной среды для решения задач извлечения и управления знаниями объясняется присутствием всех описанных ха-

рактических, влияющих на работу автономного агента. Эта особенность информационного пространства напрямую связана с недетерминированными нарушениями восприятия и не описывается априорными законами поведения агента [19]. При этом создание своей субъективной детерминированной картины мира – одна из основных задач функционирования агента для построения семантической сети на отношениях между элементами знания с целью решения задач выявления и идентификации неструктурированных междисциплинарных знаний.



1.12. Абстрактная модель иллюстрации пересечений областей знания реальной информационной среды

Задача построения семантической сети на множестве отношений между элементами знания обладает свойством *неопределенности*, т.к. заранее неизвестны результаты обработки междисциплинарных связей распределенных неоднородных источников. Любое информационное пространство для решения задач извлечения (приобретения) и управления знаниями обладает свойством неопределенности, что накладывает на процесс принятия решений дополнительные ограничения. Залогом эффективности приобретения и обработки знаний в такой среде является адекватность построенной агентом внутренней модели информационного пространства. Подобная модель сочетается с опытом и знаниями агента и является основой для определения последовательности этапов решения оптимизационных задач в условиях неопределенности. Задача создания внутренней модели реальной среды приобретения и управления знаниями представляется нетривиальной и связана с необходимостью структурирования процессов накопления и обработки элементов знания, как правило, характеризующихся существенной нелинейностью [19, 29]. Разработка таких ме-

ханизмов структуризации у систем приобретения и управления знаниями позволит решать задачи извлечения неявной структуры знаний из распределенных неоднородных источников реальной среды.

Другим подходом к решению проблемы структуризации знаний является построение онтологий. Решение проблемы поиска неявных (опосредованных) отношений между элементами знаний обеспечивает повышение интеллектуальности ИСПиУЗ. Онтология формализует неявные отношения, поэтому ее применение необходимо для эффективного решения описанной проблемы. Декларативное представление в онтологиях концептуализации на основе семантических отношений и аксиоматики делает интеллектуальными системы приобретения и управления знаниями.

В базах знаний систем извлечения и управления знаниями для интеллектуальных агентов создаются спецификации, построенные на определенных концептуализациях. Значимые отношения между элементами представляемых знаний описываются в специальном словаре. Множество терминов онтологии представляют ее ядро [30]. Отражение семантики понятий в онтологических структурах обеспечивает повышение уровня интеллектуальности информационных систем. Таким образом, онтология является наиболее формализованной моделью представления знаний.

Развитие социальной среды требует появления значительных возможностей для реализации мер по преодолению целого ряда экзистенциальных проблем на основе способов проведения коллективных рассуждений. С этой точки зрения общество представляет собой многоагентную систему, решающую неструктурированные задачи приобретения и управления знаниями, где сравнение мотивов и планов агентов на основе постановки друг другу встречных задач определяет коллективные цели и совместное целенаправленное поведение. Рассмотрим основные отличительные особенности неструктурированных задач. В первую очередь такие задачи представлены в виде эвристического описания на естественном языке. Цели и ограничения задачи в данном описании заданы неявно. Неизвестны, либо описаны неполно условия соглашений между субъектами отношений, а также роли и мотивы членов коллектива.

Интерпретация неструктурированных задач приобретения и управления знаниями осуществляется интеллектуальной информа-

ционной системой на основе применения актуальных подходов искусственного интеллекта. Машинный перевод, понимание речи, формализация мыслительных процессов, рассуждений, модели здравого смысла, распознавание образов, приобретение и управление знаниями – решение этих задачах искусственного интеллекта значительно усложняет отсутствие конструктивной модели семантики рассуждений человека [31, 32].

Прямое наблюдение или измерение не может объяснить феноменологию семантики. Это значительно усложняет решение задачи определения формальных признаков и разработки способов описания семантических отношений.

Учет мнения экспертов при постановке подобных задач является необходимым условием для получения адекватных моделей семантики системы обработки неструктурированных знаний. Методы искусственного интеллекта должны помочь эксперту привести среду распределенных неоднородных источников знаний к некоторому ожидаемому состоянию, связанному с приобретением знаний. Такое требование составляет основное содержание неструктурированной задачи, задаваемой экспертом автономному интеллектуальному агенту.

1.5. Самоорганизация информационных систем

В последнее время в организации информационных систем не появляется, пожалуй, ничего принципиально нового. За исключением самоорганизующихся информационных систем, способных взаимодействовать с системой иерархически организованных пользователей для запуска процесса коэволюции систем и создания системы более высокого уровня.

Известно, что «процесс самоорганизации приводит к значительному росту сложности внутренней организации системы» [13, 14, 26, 33]. Признаками самоорганизации обладают информационные системы, функциональность которых построена на основе методов эволюционных вычислений, искусственного интеллекта и биоинспирированного поиска.

Эффективность процесса самоорганизации способствует саморазвитию системы, разделенному на две фазы: *адаптацию* и *селекцию*. Для самоорганизующихся систем, в самом простом случае,

свойственна *алгоритмическая* адаптация, позволяющая непрерывно совершенствовать поведение системы с учетом прошлого опыта. В более сложной ситуации, система проводит *структурную* адаптацию. При этом приспособляемость к меняющимся условиям воздействия внешней среды обусловлена либо появлением новых элементов, обладающих необходимыми свойствами, либо возникновением новых признаков у «старых» элементов. Для создания предпосылок прогрессивного саморазвития системы, дифференциации и интеграции структур новые *элементы-признаки* [11] появляются в избыточном количестве, что увеличивает надежность воспроизведения и расширяет связи с внешней средой, а также, в последующем, способствует проведению процедуры селекции.

Основой успешной реализации процесса адаптации является *структурная устойчивость* системы. Тогда как эволюционные преобразования связаны лишь с количественными изменениями. Система является структурно устойчивой, если при появлении флуктуаций сеть элементов-признаков обеспечивает адаптивность и универсализм структуры, не меняется способ своего функционирования.

Важной проблемой является определение эволюционных преобразований систем в процессах приобретения и управления знаниями.

Под эволюцией *механизма управления знаниями* понимается множество информационных процессов, связанных с извлечением, приобретением, обработкой и передачей знаний о свойствах системы и отдельных ее элементов. Данный механизм определяет сложность иерархии элементов знаний с выявленными зависимостями и отношениями между фактами, событиями и явлениями.

Отметим, что любая саморазвивающаяся система связана с внешней средой двумя связями положительной и отрицательной:

- 1) положительная – передача управляющих воздействий от внешней среды к системе;
- 2) отрицательная – обратная связь с информацией о текущем состоянии системы.

На каждой итерации взаимодействия внешняя среда накапливает, обрабатывает и производит отбор знаний, полученных по обратной связи с системой. Отобранные знания накапливаются в информационном пространстве и передаются в интеллектуальную систему, обеспечивая возникновение новых свойств и характеристик

у ее элементов. Недостатком такого взаимодействия является вероятность выбросов со стороны системы и нежелательных случайных внешних воздействий, искажающих информационную картину и нарушающих нормальное течение преобразований. Для устранения этого недостатка предлагается использование следующих *принципов самоорганизации* информационных систем.

1. *Прогрессивная эволюция информационных систем* связана с постоянным ростом способностей к извлечению, накоплению, обработке, отбору, совершенствованию, распределению и сохранению знаний из внешней среды.

2. Процесс преобразования «внешнего» знания во «внутреннее» является автономным и происходит на основе *стабилизирующего отбора* – механизма осуществления обратной связи, усложнения и усовершенствования структуры системы, что в результате приводит к максимальной структурной устойчивости и эволюционной пластичности саморазвивающейся системы.

3. Для построения и развития *самоорганизующейся системы* недостаточно наделить ее закрепленными признаками, ставшими результатом адаптации к воздействию внешней среды, помимо этого система должна быть открытой и способной к обучению.

Таким образом, с точки зрения эволюции самоорганизация информационных систем определяется связью между понятиями изменчивости и управления знаниями, а понятие знание связывается с числом элементов-признаков, причем, на этапе адаптации системы важную роль играет избыточность накопленных знаний (элементов-признаков). Но необходимо отметить, что *«наличие у системы способностей обмена информацией с внешней средой, управления числом и функциями элементов-признаков, а также сохранения устойчивости еще не делает эту систему самоорганизующейся»* [33, 34]. Данное утверждение вытекает из существующей вероятности возникновения дополнительной неустойчивости системы, порождаемой неравновесными внешними условиями, что приводит к увеличению интенсивности диссипации и, как следствие, создает условия для новой неустойчивости. При этом интенсифицируются необратимые процессы, обеспечивающие еще большее отклонение системы от равновесного состояния, и возрастает вероятность существования класса флуктуаций, которые предопределяют неустойчивость вновь выстраиваемых информационных процессов.

Затухание подобных флуктуаций возможно только при снижении интенсивности диссипации, которая связана с ростом числа новых элементов-признаков и приводит к увеличению энтропии. Интенсивный рост числа новых элементов часто не обеспечен необходимой скоростью установления отношений (связей) между ними, это нарушает организацию системы, делая ее структурно неустойчивой. *Это соответствует холистическому подходу Аристотеля, указывающему на системный характер устойчивости системы, достигаемой за счет наличия связности и взаимодействия между частями целого, и определяющему целостность любой сложной системы, как нечто большее, чем простая сумма составляющих* [11–18].

Неустойчивости возникают в любой системе под воздействием подходящих возмущений. В то же время, нелинейность и удаленность от равновесия часто становятся причиной возникновения упорядоченности в системе. С точки зрения И.Р. Пригожина [26] одним из основных признаков процессов самоорганизации является потеря устойчивости с последующим переходом к устойчивым диссипативным структурам.

Таким образом, представим самоорганизацию информационных систем на примере модели из *адаптологии*, описывающей процесс адаптации живых систем к неблагоприятным факторам среды, как приобретение отсутствовавшей ранее устойчивости, уже после прохождения критической бифуркационной точки максимума своих возможностей, за счет формирования *доминант* – нервных центров, увеличивающих мощность системы и составляющих материальную основу долговременной адаптации. На основе рассмотренных принципов сформулируем *аксиому самоорганизации информационных систем*. Именно управление отношениями между элементами-признаками в информационных системах позволит создать междисциплинарные центры тяжести (центры силовой релаксации предметных областей), позволяющие осуществить переход к диссипативной структуре информационной системы после критической точки бифуркации за счет роста организованности и упорядоченности информационных потоков. Эволюционные (синергетические) преобразования системы в определяющей мере зависят не от наличия у системы способностей обмена информацией с внешней средой и управления числом и функциями элементов-признаков, а от изменений взаиморасположения и системы отношений на междисциплинарном множестве элементов-признаков (элементов

знаний), т.е. от изменений архитектур как отдельных предметных областей, так и всего единого информационного пространства в целом.

Согласно этой аксиоме, только выполнение определенных внешних и внутренних условий приводит к возникновению процессов самоорганизации. Данные условия связаны не с ростом количества информации, а с ее ценностью и целями ее использования. Заметим, что ценность информации будет различной для одной и той же системы в зависимости от разницы оперативных целей функционирования системы и условий внешней среды. При этом, важной мерой степени ценности информации является ее избыточность и незаменимость.

Ценная информация накапливается в системе постепенно без возникновения каких-либо явных преимуществ от ее применения. Значительные изменения в качестве функционирования системы возможны только при условии постоянного анализа и обработки полученной ценной информации для определения новых неявных зависимостей и закономерностей. Эти новые особенности позволяют выявить в информации новое знание, что обеспечивает системе переход на новый эволюционный уровень, в котором интегрируются элементы ценной информации.

Таким образом, в 1-ой главе монографии исследованы теоретические основы получения знаний на основе биологических принципов. В тексте представлены ключевые определения, а также представлено описание процессов приобретения и управления знаниями в глобальной информационной среде. Предложена математическая модель глобальной информационной среды для применения в контексте приобретения знаний. Также в 1-ой главе описана концепция приобретения знаний, представленная в виде стратегии и основных принципов для решения задач, поставленных в исследовании.

ГЛАВА 2. ИНФОРМАЦИОННЫЕ МОДЕЛИ И ЗАДАЧИ ПРИБРЕТЕНИЯ И УПРАВЛЕНИЯ ЗНАНИЯМИ

2.1. Эволюция процессов управления знаниями

Рассматривая эволюцию процессов управления знаниями, установим тождество понятий «информация» и «сообщение». Важно понимать, что не все сообщения несут информацию, связанную с исследуемыми процессами. Это является следствием формы представления и/или кодировки сообщения. В этом случае информация представляется либо как мера неопределенности, либо как мера сложности.

Дж. Миллер в своем междисциплинарном анализе и синтезе функций и поведения живых систем выделил 9 (девять) подсистем обработки информации (рис.2.1) [35].

На основе представленной таксономии подсистем обработки информации построим простейшую модель процесса рассуждений и принятия решений в живых системах. Процессы (стадии) модели обозначим как: поиск (сбор) – анализ (обработка) – решение (проверка) (рис. 2.2) [35].

Первый процесс связан с поиском имеющихся вариантов или сбором информации. Результатом процесса является концептуальная модель ситуации. Второй процесс подразумевает произведение выбора между несколькими вариантами поведения, которые впоследствии исследуются и оцениваются более строго. Третья стадия связана с проверкой принятого решения. Если предыдущие стадии были реализованы эффективно, процесс проверки должен подтвердить успешность выбранной модели поведения. Для реализации целевого управления в модели организованы обратные связи между процессами.

Темп реализации данной модели непостоянен. Время на реализацию различных процессов (стадий) распределяется не равномерно. Причем, модель используется не только линейным или циклическим образом. Например, во время игры в шахматы игрок, делающий ход, просматривает свои фигуры для поиска имеющихся вариантов, затем, после анализа, игрок останавливает внимание на одном из анализируемых вариантов и делает ход. В этом случае игрок не реализует модель линейным способом.

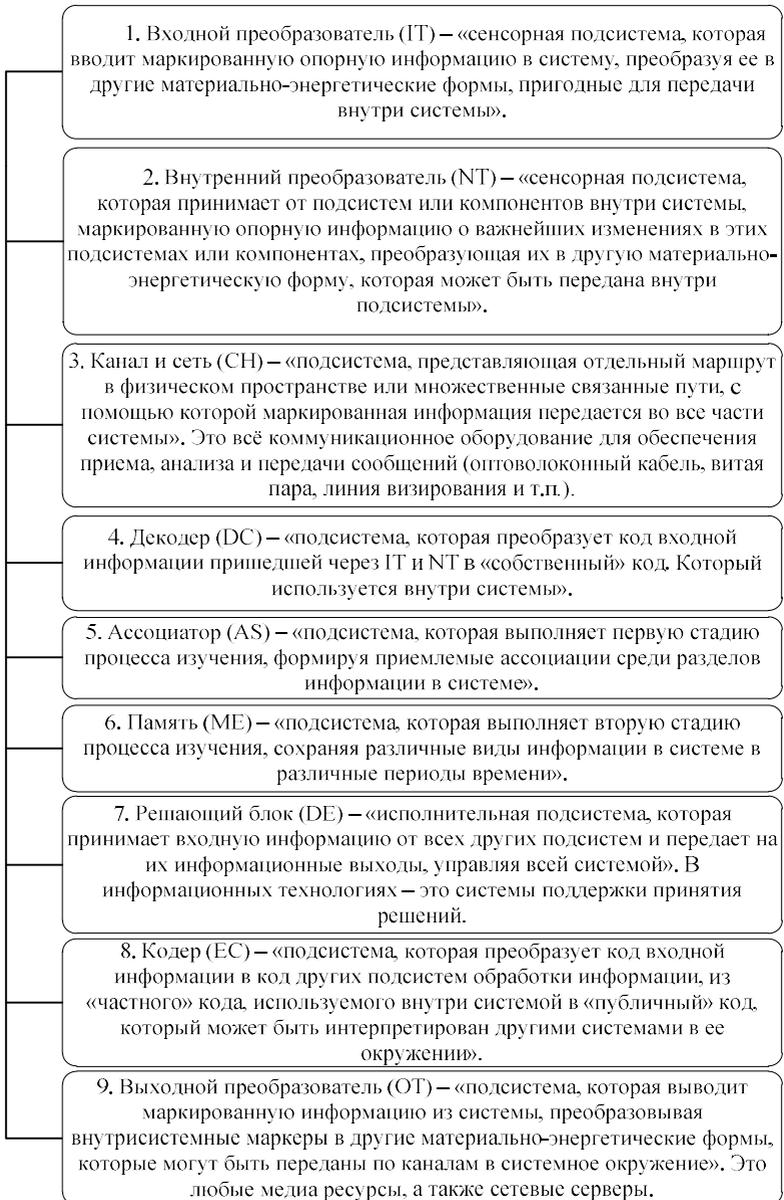


Рис. 2.1. Подсистемы обработки информации

При этом схема использования имеет следующую последовательность процессов: поиск – поиск – поиск... – анализ – обратная связь – поиск – анализ – решение.



Рис. 2.2. Модель процесса рассуждений и принятия решений
(поиск – анализ – решение)

Представленная модель творческого процесса является недостаточно эффективной для использования ее в чистом виде для решения задач управления знаниями. Основным недостатком отметим наличие своего рода неопределенности механизма движения от одной стадии к другой. В связи с этим, необходимым для упорядочивания функционирования является определение периода перехода между процессами модели.

Модифицируем представленную модель рассуждений и принятия решений путем включения стадий, непосредственно связанных с процессами управления знаниями. Рассматривая знания как сложную сетевую иерархию элементов информации, учтем, что полная обработка сообщения включает шифрование, трансдукцию, передачу, прием, расшифровку, ассоциации, анализ и решение [35].

Любая динамическая система для принятия решения в оперативной обстановке должна сравнивать характеристики внешнего воздействия с некоторой собственной моделью поведения, экстраполирующей вероятные реакции системы, на основе моделей прецедентов из прошлого опыта. Знания об этом опыте в живой природе могут быть унаследованы генетически или получены путем сохранения.

Множество этих прецедентов, сохраненных в системе, составляют ее парадигму.

Внешнее воздействие на систему могут оказывать другие системы (субъекты) окружающей среды и сама окружающая среда в целом. Интерпретируем внешние воздействия на систему как со-

бытия различных видов. Сами по себе события нейтральны и содержат данные о воздействии. Информацией является результат обработки данных о событии системой, который она назначает сообщению на основе знаний о прошлом опыте. Значимость информации пропорциональна ее неопределенности. Большинство событий лишено информации, так как они либо не имеют значения для системы, либо являются явными и ожидаемыми.

Конфликт моделей (рис. 2.3) происходит, если на вход системы приходит высокоинформативное, а значит – неопределенное системной парадигмой событие. В этом случае возникает эффект новой информации, которая имеет высокую степень неопределенности по отношению к парадигме системы, как множество знаний об опыте, хранящемся в виде множества прецедентов.

Подобная ситуация имеет мощный информационный потенциал и требует выработки специальных решений для ее использования. Системе необходимо однозначно ответить на вопрос, представляет данное событие для нее угрозу или нет? В первом случае принятое решение должно реализовать новую стратегию для предотвращения или уменьшения нежелательных последствий, во втором – в случае наличия потенциальной выгоды, узнать, как использовать ее в своих интересах. Таким образом, системе необходимо ввести знание нового качества – *понимание* как определение и осознание закономерностей отношений между элементами знания, основанного на опыте.

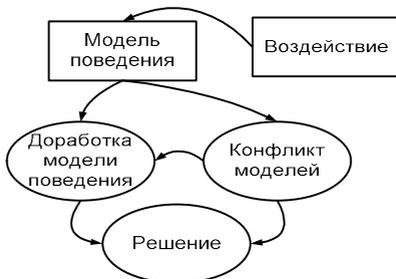


Рис. 2.3. Модель реакции системы на воздействие

Ввод знания нового качества в свою парадигму для системы является нежелательным. Процесс моделирования должен позволять системе исключить участие в потенциально опасных событиях. Если результаты моделирования будут благоприятными для системы, тогда

возможно включить новую информацию в парадигму, тем самым обеспечить новое качество знаний, основанных на опыте.

Рассмотрим модель реакции системы на воздействие в контексте процессов циклического сценария управления знаниями (рис. 2.4).

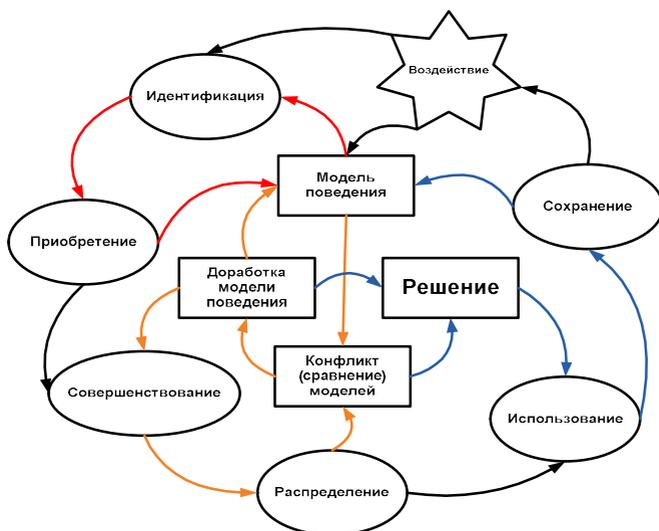


Рис. 2.4. Интегрированная модель управления знаниями на основе реакции системы на воздействие

Для идентификации функциональной зависимости между входным и выходным сигналами ($y = F(x)$), используют метод компараторной идентификации, который основан на использовании алгебры предикатов и предикатных операций. Решение систем предикатных уравнений осуществляется при помощи универсальных программ, написанных на языке высокого уровня, и представляется в виде переключательной цепи.

Под приобретением знаний понимается процесс переноса информации из различных источников в хранилище данных, который реализуется при помощи различных методов, алгоритмов и инструментальных средств (рис. 2.5).

Заметим, что интегрированная модель циклического управления знаниями, представленная на рисунке 2.4, становится более разнообразной, когда учитывается реакция системы на внешние воздействия, которое влияет на каждую стадию без исключения.

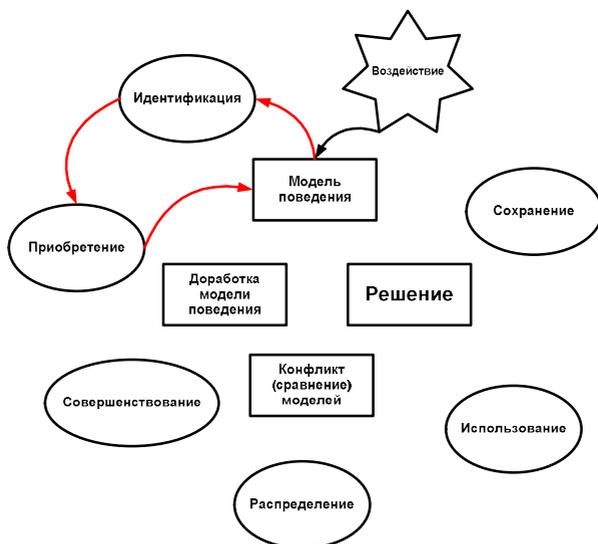


Рис. 2.5. Упрощенный цикл управления знаниями

Например, возможность обработки новой информации только на основе имеющейся модели поведения может запустить упрощенный цикл управления знаниями, содержащий в себе стадии идентификации и приобретения, с последующим учетом новых знаний в модели поведения, при необходимости (рис. 2.6).

Для любой интеллектуальной информационной системы крайне важно иметь возможность верификации и улучшения базы знаний (БЗ), поэтому необходимы инструменты анализа существующих формализованных знаний и их последующего использования. Задачей такого анализа является эволюция и совершенствование знаний.

С другой стороны, несовершенство модели поведения требует проведения стадий доработки и сравнения полученных моделей на предмет отсутствия конфликтов с возможным подключением этапов совершенствования и распределения знаний для использования в новых моделях поведения.

Завершение процесса формирования новой модели поведения запускает стадию принятия решения с последующим использованием и сохранением полученных новых знаний в новой модели поведения (рис. 2.7).

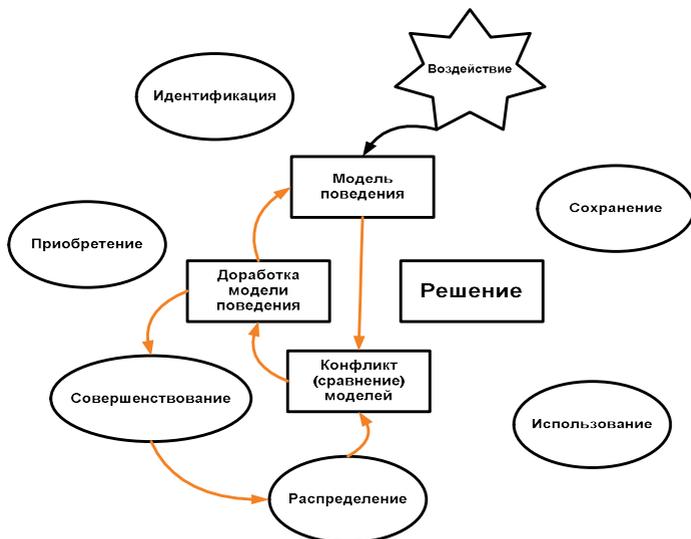


Рис. 2.6. Цикл доработки модели поведения

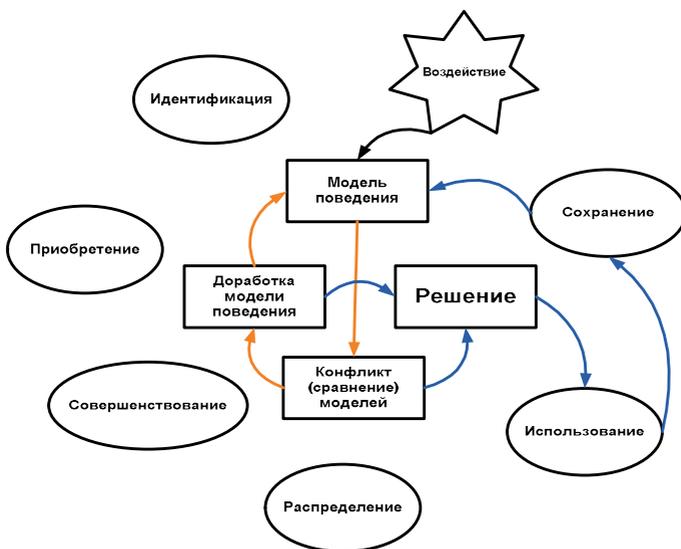


Рис. 2.7. Цикл принятия решений

При определенных условиях можно сделать вывод о интеллектуальном происхождении системы на основе распознавания программы

поведения объекта, даже если нет достоверных данных о происхождении самой системы. Эта аналогия с живыми системами поможет интеллектуальным информационным системам управления знаниями повысить эффективность путем итерационного изменения модели накопления и обработки знаний в циклическом сценарии управления.

2.2. Модифицированные модели представления и управления знаниями

Ранее использованные подходы к управлению знаниями обычно предполагали последовательное применение моделей представления, а затем управления знаниями. Однако современные информационные процессы инженерии знаний объединяют модели представления и управления знаниями в единый системный элемент, благодаря схожести процедур создания и обработки объектов знаний и классов, которые их образуют.

Эта согласованность между моделями позволила создать новый образ знаний, представленный на рисунке 2.8, который используется в интеллектуальных системах.

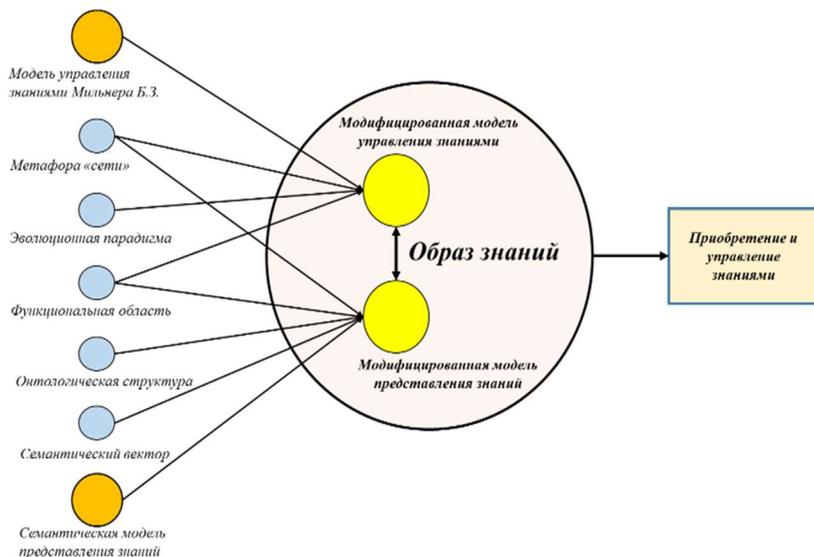


Рис. 2.8. Модель образа знаний в интеллектуальных системах

Он основан на объединении модифицированной семантической модели представления знаний с онтологическими структурами, а также с модифицированной моделью управления знаниями Мильнера Б.З. [25], которая была описана выше.

Отметим, что модифицированная модель Мильнера [25] содержит три значимых отличия от всех известных моделей управления знаниями, которые представлены на рисунке 2.9.

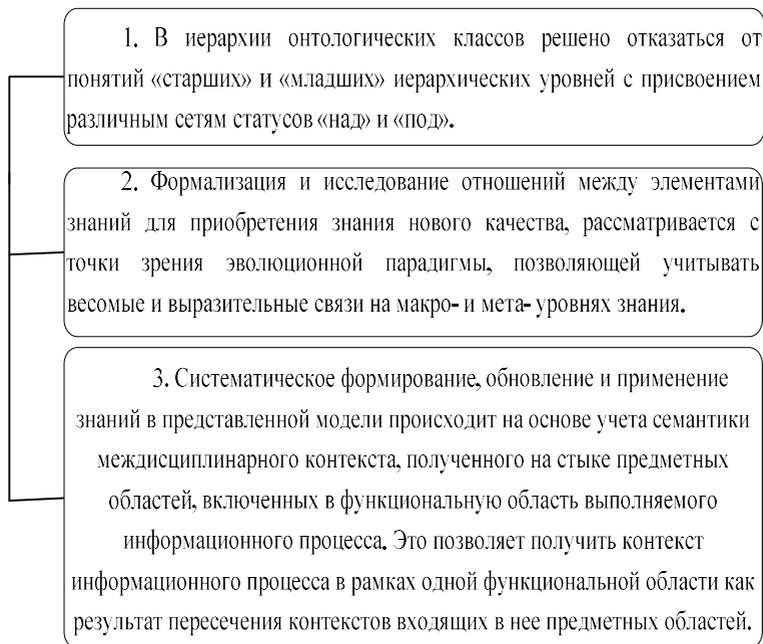


Рис. 2.9. Модифицированная модель Мильнера Б.З.

В соответствии с полученным выводом о целесообразности применения многоагентного подхода для создания модели глобального информационного пространства, построим математическую модель распределения интеллектуальных агентов обучения и комбинирования классификатора по классам. Данная модель демонстрирует отличный от представленного ранее подход к имитации процессов распространения знаний в глобальном информационном пространстве.

В данной математической модели популяция агентов обучения классификатора выполняет частные задачи приобретения и управления знаниями с помощью биоинспирированных алгоритмов. Популяция агентов комбинирования классификатора объединяет результаты решений и содержит важную и структурированную информацию. Для разработки этой модели необходима формализация динамики приобретения и управления знаниями в глобальном информационном пространстве. Одной из наиболее сложных задач является определение переменных, которые полностью описывают данный динамичный процесс.

Общее число интеллектуальных агентов равно N , и они могут быть распределены по четырем классам: α (агенты комбинирования), β (агенты обработки ценных и структурированных знаний), γ (агенты обработки неценных, но структурированных знаний) и δ (агенты обработки неценных и неструктурированных знаний).

Значения числа агентов каждого класса в момент времени y являются переменными модели. С использованием метода информационных балансов [36] и постановки нелинейных задач, мы можем построить *математическую модель распределения интеллектуальных агентов обучения и комбинирования классификатора по указанным классам*:

$$d\alpha/dy = -k_{\beta\alpha}\alpha + K_{\alpha} + K_{\alpha r}(y) + q_{\beta\gamma}\beta\gamma + q_{\beta\delta}\beta\delta + q_{\gamma\delta}\gamma\delta, \quad (2.1)$$

$$d\beta/dy = -k_{\beta\alpha}\beta + k_{\beta\alpha}(\beta_0 + \alpha_0) - (K_{\alpha} + K_{\alpha r}(y)) + k_{\beta\delta}(\beta - \delta) + q_{\gamma\alpha}\gamma\alpha + q_{\alpha\delta}\alpha\delta + q_{\gamma\delta}\gamma\delta, \quad (2.2)$$

$$d\gamma/dy = -k_{\gamma\delta}\gamma + k_{\gamma\delta}(\gamma_0 + \delta_0) - (K_{\gamma} + K_{\gamma r}(y)) + k_{\gamma\alpha}(\gamma - \alpha) + q_{\beta\alpha}\beta\alpha + q_{\beta\delta}\beta\delta + q_{\alpha\delta}\alpha\delta, \quad (2.3)$$

$$\delta = N + N_r(y) - \alpha - \beta - \gamma, \quad (2.4)$$

$$\alpha(y_0) = \alpha_0, \beta(y_0) = \beta_0, \gamma(y_0) = \gamma_0, \delta(y_0) = \delta_0. \quad (2.5)$$

В системе дифференциальных уравнений, полученной при рассмотрении процессов получения знаний интеллектуальными агентами в глобальном информационном пространстве, можно выделить ряд положительных коэффициентов – $\alpha_0, \beta_0, \gamma_0, \delta_0 \geq 0$; $k_{\beta\alpha}, k_{\beta\delta}, k_{\gamma\delta}, k_{\gamma\alpha}, q_{\beta\alpha}, q_{\beta\delta}, q_{\alpha\delta}, q_{\gamma\delta}, q_{\gamma\alpha}, q_{\beta\gamma}$, которые отражают изменения размеров классов агентов.; K_{α}, K_{γ} – математическое ожидание скорости роста и убывания числа агентов в классах α и β

и в классах γ и δ соответственно, в процессе приобретения знаний; $K_{ar}(y)$, $K_{\gamma r}(y)$, $N_r(y)$ – случайные составляющие соответствующих параметров [36].

Кроме того, присутствуют математические ожидания роста и убывания агентов в процессе обучения. С учетом того, что необходимо увеличить объем структурированных знаний и заданных зависимостей между переменными, основной задачей является максимизация количества агентов обучения, попавших в класс $\beta \rightarrow \beta_{max}$ при реализации информационных процессов приобретения и управления знаниями.

Чтобы достигнуть этой цели, все агенты должны взаимодействовать друг с другом, а общая численность агентов должна быть ограничена так, чтобы сохранить устойчивость системы.

Мы представляем математическую модель распределения ценных знаний в информационном пространстве с N интеллектуальными агентами. Наша модель представляет собой следующее уравнение [36]:

$$d\alpha/dy = (s + r\alpha)(N - \alpha), \alpha(0) = 0, \quad (2.6)$$

где $\alpha(y)$ – число агентов комбинирования классификатора в момент времени y ; s и r – положительные значения параметров интенсивности распространения ценных знаний через информационные каналы и путем взаимодействия агентов соответственно.

Согласно модели (2.6), скорость получения ценных знаний, структурированных в классификаторах, зависит от количества комбинировующих агентов и пропорциональна числу обучающих агентов $N - \alpha$. Модель предусматривает возможность перемещения агентов классификатора между классами, а также в группу комбинировующих агентов. Таким образом, можем записать следующее выражение для изменения числа комбинировующих агентов [36]:

$$d\alpha/dy = (s + r\alpha)(f(\alpha) - \alpha), \quad (2.7)$$

где $f(\alpha)$ – функция, описывающая количество агентов обучения классификатора, соответствующих требованиям для перехода в группу агентов комбинирования классификатора на момент времени y .

Допустим, что агенты всех классов разбиты на две группы N_1 и N_2 : одна получает знания из информационных каналов или от других агентов, а вторая только от других агентов. Исходя из этого, класс агентов комбинирования классификатора так же поделен

на две группы $\alpha_1(y)$ и $\alpha_2(y)$, и это влияет на базовую модель (2.6), которая становится следующей более сложной системой [36]:

$$\begin{aligned} d\alpha_1/dy &= (s + r(\alpha_1 + \alpha_2))(N_1 - \alpha_1), \\ d\alpha_2/dy &= r(\alpha_1 + \alpha_2)(N_2 - \alpha_2). \end{aligned}$$

Рассмотрим проблему потери ценности знаний в процессе их приобретения и учтем это в системе, введя коэффициент интенсивности, который отражает уменьшение ценности знаний при решении задач, что позволяет получить систему следующего вида [36]:

$$\begin{aligned} d\alpha_1/dy &= (s + r(\alpha_1 + \alpha_2))(N_1 - \alpha_1) - \vartheta\alpha_1, \\ d\alpha_2/dy &= r(\alpha_1 + \alpha_2)(N_2 - \alpha_2) - \vartheta\alpha_2, \end{aligned}$$

где $\vartheta > 0$ – интенсивность снижения ценности приобретаемых знаний в течение времени.

При переходе агента обучения классификатора в класс агента комбинирования классификатора происходит двухэтапный процесс с установлением корректного статуса. Первый этап исключает агента комбинирования классификатора, переклассифицированного в процессе, из передачи знаний для обеспечения правильной смены статуса. Второй этап снимает ограничения и позволяет новому агенту комбинирования классификатора работать в стандартном режиме. В уравнении (2.6) $\alpha'(y)$ обозначает агентов, находящихся в первом промежуточном этапе перехода в класс агентов комбинирования классификатора. Представим это в следующем виде [36]:

$$\begin{aligned} d\alpha/dy &= (s + r\alpha)\alpha', \\ d\alpha/dy &= (s + r\alpha)(N - \alpha - \alpha') - (s + r\alpha)\alpha' = \\ &= (s + r\alpha)(N - \alpha - 2\alpha'). \end{aligned}$$

Теперь на основе представленных выше факторов базовая модель (2.6) принимает следующий вид [36]:

$$\begin{aligned} d\alpha_1/dy &= (s + r(\alpha_1 + \alpha_2)) \left(f_1(\alpha_1 + \alpha_2) \frac{\alpha'_1 + \alpha_1}{N_1} - \alpha_1 \right) - \vartheta\alpha_1, \\ d\alpha_2/dy &= r(\alpha_1 + \alpha_2) \left(f_2(\alpha_1 + \alpha_2) \frac{\alpha'_2 + \alpha_2}{N_2} - \alpha_2 \right) - \vartheta\alpha_2, \end{aligned}$$

$$\begin{aligned}d\alpha'_1/dy &= (s + r(\alpha_1 + \alpha_2)) \left(N_1 - \alpha'_1 - f_1(\alpha_1 + \alpha_2) \frac{\alpha'_1 + \alpha_1}{N_1} \right) \\ &\quad - \vartheta\alpha'_1 + \vartheta\alpha_1, \\ d\alpha'_2/dy &= r(\alpha_1 + \alpha_2) \left(N_2 - \alpha'_2 - f_2(\alpha_1 + \alpha_2) \frac{\alpha'_2 + \alpha_2}{N_2} \right) - \vartheta\alpha'_2 \\ &\quad + \vartheta\alpha_2, \\ \alpha_1(0) &= \alpha_2(0) = \alpha'_1(0) = \alpha'_2(0) = 0.\end{aligned}$$

Построенная математическая модель имеет следующий стационарный режим [36]:

$$\alpha_1 = \alpha_2 = 0, \alpha'_1 = N_1 \frac{s}{s + \vartheta}, \alpha'_2 = 0.$$

Описанный стационарный режим математической модели учитывает высокую скорость потери ценности знаний со временем и медленный рост числа агентов в группе комбинирования классификатора. Это свидетельствует о необходимости увеличения количества структурированных знаний в глобальном информационном пространстве.

Базовые математические модели распределения интеллектуальных агентов обучения и комбинирования классификатора по классам в информационных процессах управления и приобретения знаний построены и исследованы в данном параграфе, а также проведено описание распределения ценных знаний в пространстве с несколькими агентами. В данных моделях использован отличный от представленного ранее подход к имитации процессов распространения знаний. Предложенные модели детально описывают ключевые особенности, присущие процессам управления и приобретения знаний.

2.3. Онтологическая модель представления знаний

Онтологическая структура является одним из основных компонентов модифицированной модели представления знаний как части системного элемента нового образа знаний, представленного в предыдущем пункте. В настоящее время *онтология* – это попытка всеобъемлющей и подробной формализации некоторой области знаний с помощью концептуальной схемы. В простом случае онтология описывает иерархию концептов (понятий) предметной области и построенную на их множестве систему значимых отношений категоризации [37]. Для интерпретации и выражения других

типов отношений между понятиями в онтологию включаются необходимые аксиомы.

Давайте рассмотрим более простое определение *онтологии*. Это формализованное описание области знаний, которое включает термины и правила их использования, необходимые для определения значений этих терминов. Таксономия терминов и правил вывода формально составляют онтологию, которая может быть представлена в виде формул логики первого порядка.

Онтология является системой, содержащей понятия и утверждения, необходимые для определения объектов, отношений, классов, функций и теорий. Она может быть реализована как база знаний с фактами, которые должны быть истинны в рамках определенного смысла, зафиксированного в словаре, используемом в предметной области [37].

Задачи исследования предметной области, при решении которых будет применяться спецификация концептуализации, определяют цель создания онтологии. Независимо от предназначения и вида, онтология должна содержать словарь терминов и необходимые спецификации их значений, что дает возможность ограничить число интерпретации терминов и отразить значимые отношения между понятиями данной предметной области знаний.

Сложность построения онтологии как центра представления знаний заключается в возможном различном понимании одинаковых терминов в разных предметных областях. Онтология используется в качестве посредника между естественным и машинным уровнями представления априорных знаний при решении задачи их структурирования. Такой подход идентифицирует онтологию как систему соглашений о некотором пространстве интересов при достижении поставленных целей. Что предполагает комплексное и масштабное представление о соответствующей предметной области знаний, включающее словарь терминов с указанием ограничений целостности, формальные и декларативные компоненты, а также логические правила и утверждения, задающие границы интерпретации терминов и значимых отношений между ними.

Сфера применения онтологий постоянно расширяется и задачи, решаемые с их помощью, можно условно разделить на три группы рис. 2.10. Кратко опишем перечисленные задачи, так как их решение необходимо при создании интеллектуальных систем обучения.

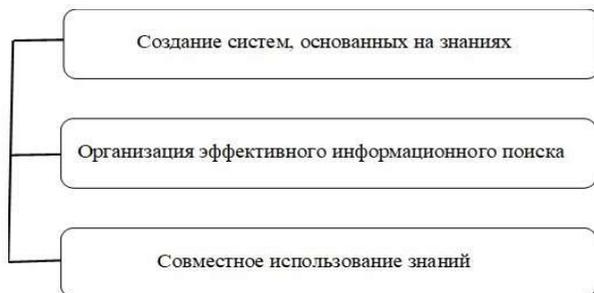


Рис. 2.10. Основные задачи, решаемые при помощи онтологий

К системам, *основанным на знаниях*, обязательной частью которых является база знаний, относятся следующие: экспертные системы (ЭС); системы автоматического реферирования; системы поддержки принятия решений (СППР); интеллектуальные роботы и другие.

Выделим основные задачи разработки данных систем:

- создание динамичных баз знаний (БЗ) с возможностью прототипирования и прогнозирования на основе прецедентов;
- создание коалиций интеллектуальных агентов и механизмов построения децентрализованной модели рассуждений.

В искусственном интеллекте задача построения баз знаний существует давно, однако наибольшей эффективности методы практической разработки БЗ достигли с появлением и развитием онтологических структур [37]. Алгоритмические и программные средства и инструменты создания и обработки онтологий стали ключевым аспектом технологий разработки БЗ. Один из вариантов использования онтологической структуры – моделирование предметной области. При этом, создаваемая база знаний должна быть релевантной данной модели и включать в себя декларативные знания и определения понятий и отношений предметной области.

Онтологический подход значительно снижает уровень ошибок, связанных с информационной неопределенностью, при реализации логических операций и процессов поддержки принятия решений на основе правдоподобных рассуждений. Повышение сложности разрабатываемых интеллектуальных информационных систем приобретения и управления знаниями приводит к росту востребованности применения онтологического подхода.

Опишем *основные задачи организации эффективного поиска* на основе применения онтологий:

- построение и обработка множеств метаданных об исследуемых источниках знаний;
- описание процедур совершенствования поисковых запросов;
- разработка методов контекстного поиска ценной информации;
- разработка моделей и методов семантического поиска на основе новых онтологических размерностей.

На языке разметки *XML* часто базируются современные популярные языки представления метаданных, в которых при построении множеств имен, словарей и классификаторов для достижения единства интерпретаций применяются онтологические структуры. Функционал онтологического подхода расширен методами управления знаниями, что позволяет эффективно решать задачи кластеризации и классификации слабоструктурированных информационных источников на основе создания и анализа метаданных. Структуры и определения метаданных соответствуют стандартным открытым интерфейсам.

Их развитием стали ЕЯ-интерфейсы, построенные по спецификациям структурированных информационных источников. Следующим шагом повышения эффективности поисковых механизмов стало применение онтологий приложений и предметной области при создании образа поискового запроса, что позволяет повысить соответствие интерпретации смысла основных терминов, присутствующих в запросах, а также расширить поиск включением в анализ понятий, не связанных напрямую с запросом, но имеющих определенную предметную связь в контексте рассматриваемых терминов в виде отношений тождества, ассоциации, противопоставления, отношений типа «часть–целое», «род–вид» и др.

На основе формального определения конкретизируем математическое описание онтологии. Определим множество отношений C следующим выражением [10]:

$$C = \{general, detail\}, \quad (2.8)$$

где *general* – отношение на уровне общего класса знаний; *detail* – отношение на уровне класса детализации знаний.

Добавим в выражение (2.8) отношение для экземпляра онтологии [10]:

$$C = \{general, detail, example\}, \quad (2.9)$$

где *example* – отношение для экземпляра онтологии. Тогда многоуровневая иерархия отношений между понятиями онтологии P^c примет вид следующего выражения [10]:

$$P^c = \{P, general, detail, example\}, \quad (2.10)$$

где P – является множеством понятий онтологии.

Опишем формальную структуру сущности понятия онтологии следующим выражением [10]:

$$\forall p \in P: p = \langle N, G, D, R^V, R^P, V \rangle, \quad (2.11)$$

где p – понятие онтологии; P – множество понятий онтологии; N – символьное имя понятия; $G = \{p' \in P: p' \text{ general } p\}$ – множество понятий на уровнях общих классов знаний; $D = \{p' \in P: p' \text{ detail } p\}$ – множество понятий на уровнях классов детализации знаний; $R^V = \{\langle k_0, v_0 \rangle, \dots, \langle k_i, v_i \rangle\}$ – множество атрибутов экземпляра онтологии; $R^V \subseteq R^{V^0}$; R^{V^0} – конечное множество всех атрибутов экземпляров онтологии; k_0, k_i – символьные имена атрибутов экземпляров онтологии; v_0, v_i – количественные значения атрибутов экземпляров онтологии; $R^P = \left\{ \langle f_0, w_0: p'' \in P, v_0: p^{example} \in V^{p''} \rangle, \dots, \langle f_j, w_j: p'' \in P, v_j: p^{example} \in V^{p''} \rangle \right\}$ – множество атрибутов понятия онтологии; $R^P \subseteq R^{P^0}$; R^{P^0} – конечное множество всех атрибутов понятий онтологии; $R^{V^0} \cup R^{P^0} = R$; R – согласно формальному определению конечное множество всех атрибутов онтологии; f_0, f_j – символьные имена атрибутов понятия онтологии; w_0, w_j – типы атрибутов понятия онтологии; v_0, v_j – значения атрибутов понятия онтологии; $p^{example}$ – экземпляр понятия онтологии; p'' – понятие-класс онтологии; $V = \{p' \in P: p' \text{ example } p\}$ – множество экземпляров понятия p ; $V \subseteq V^0$; V^0 – конечное множество экземпляров онтологии [10].

Эффективные процедуры семантического поиска в интернете являются важной технологией в области управления и приобретения знаний. Создание онтологических моделей, которые используют ин-

формационные профили знаний для оперативного выявления и исключения нерелевантных элементов поиска в информационном пространстве, является центральным элементом этой технологии [38].

К группе задач совместного использования знаний относят:

- построение и обработка баз основных знаний и модели информационного пространства;
- задание общей терминологии для сообщества экспертов и совместно используемых энциклопедических систем и приложений;
- применение онтологических структур в корпоративных информационных системах.

Множество информационных категорий (данные, информация, знания) требует применения различных технологий их анализа и обработки. Повышение эффективности и расширение спектра данных технологий связано с разработкой новых поколений интеллектуальных информационных систем приобретения и управления знаниями, созданных с применением комплекса информационных моделей междисциплинарного пространства знаний, в том числе, основанных на реализации онтологического подхода.

Известны две основные задачи, составляющие методику построения онтологических структур. Первая задача предусматривает выполнение анализа целей построения и области использования создаваемой онтологической структуры, а вторая связана непосредственно с ее построением, включая подзадачи поиска и извлечения знаний о предметной области, с дальнейшим проведением процесса кодирования.

Поиск и извлечение знаний о предметной области включают в себя: выполнение процедур определения базовых понятий в рамках исследуемой предметной области и построение на их множестве системы значимых отношений; определение точных непротиворечивых формулировок определений для каждого базового понятия и значимого отношения; задание основных терминов, связанных с базовыми понятиями и значимыми отношениями; изменение и согласование перечисленных элементов онтологической структуры.

Под кодированием будем понимать разбиение множества основных используемых в онтологической структуре терминов на классы, а также выбор или создание специального инструмента для представления и обработки знаний с последующим формированием спецификации концептуализаций.

Онтологические модели процессов обучения содержат описание базовых знаний по всему спектру компетенций специалиста и создаются с применением специальных конструкторов онтологий [38], функционирующих на основе многоагентного моделирования. Решение задачи интеграции знаний в подобных онтологических моделях позволяет обеспечить согласованность описаний профессиональных функций специалистов из разных сфер деятельности. Сложность решения задачи интеграции заключается в неполноте, разнородности, несогласованности, противоречивости и гетерогенности обрабатываемых знаний. В таких условиях создаваемые онтологии должны иметь в своем составе средства многоагентного поиска и обладать способностями самообучения с элементами эволюции.

2.4. Постановка и описание задач приобретения и управления знаниями

При решении задач приобретения и управления знаниями в условиях неопределенности и большой размерности анализируемых разнородных распределенных информационных ресурсов, множество которых определяет состав междисциплинарного пространства знаний, необходимо сформулировать постановку и условия задачи, так же, как и само понятие решения.

Допустим, что есть способ, назовем его «способом S », который позволяет нам из множества P разных доменов анализировать множество знаний K , представленных различными атрибутами X , и ставить им в соответствие определенные значения Y . Эти значения необходимы для эффективной обработки разнообразных информационных ресурсов R путем использования специальных методов M . Однако, для достижения оптимальности процесса получения и обработки знаний F , необходимо учитывать контекст H . Следовательно, значения Y являются надежным выводом, а «способ S » – решающим методом, основанным на логических правдоподобных рассуждениях. «Под рассуждением понимается построение последовательности аргументов, вынуждающих принятие некоторого утверждения, которое и является целью рассуждения» [39, 40]. Ясно, что в данном случае, способность точно делать выводы полностью зависит от умного способа анализа и обработки информации, которой мы располагаем. Получаемый вывод – это система

данных, которые мы проанализировали, и определенных соответствий, позволяющих нам обнаружить скрытые связи и закономерности между различными характеристиками X в совокупности знаний K . Новые связи и закономерности, которые мы обнаружим среди элементов знаний, будут основой для получения новых высококачественных знаний, и именно это является самой главной целью в управлении знаниями. Из [39] известно, что достоверное знание – это то, что мы получаем, когда логически рассуждаем и пытаемся понять, откуда начинаются, какие причины есть и какие элементы входят в процесс. В современном понимании процесса управления знаниями – система связей и отношений в информации на разных уровнях (на содержательном и метауровне). Тогда понятие рассуждение в данном контексте – процесс обнаружения и анализа неявных закономерностей на множестве гетерогенных и разнородных элементов знания, позволяющих получать непротиворечивые и корректные решения на основе информационных моделей междисциплинарного пространства знаний, моделей и методов приобретения и управления новыми знаниями и сценариев воздействий внешней среды [39].

Основной характеристикой задач построения рассуждений в данной работе является наличие информационной неопределенности и нечеткости, что требует получения и анализа определенного количества альтернативных вариантов упорядоченных множеств значимых неявных отношений между элементами знания исследуемых предметных областей [39]. Весомый практический эффект развития от использования данного альтернативного подхода, в первую очередь получают информационно-поисковые системы, в которых применение нерегламентированных и неформализованных пользовательских запросов делает использование системы более удобным и простым, в то же время, значительно усложняет процесс поиска составляющих знания для построения релевантного ответа. Когда мы имеем дело с большими доменами знаний, в этом случае, сложно формализовать и использовать алгоритмические методы для построения рассуждений. Для решения данных проблем предлагаются следующие принципы (рис.2.11) [4, 7, 11, 15, 41].

Эффективность производимых рассуждений при приобретении и управлении знаниями с учетом рассмотренных принципов напря-

мую зависит от результатов семантического поиска, классификации, структуризации и интеграции знаний. Сформулируем постановки и опишем данные задачи.

Для повышения эффективности реализации процедур приобретения и управления знаниями предлагаются следующие изменения в подходах к организации поиска рис.2.12. [19].

При этом основой представления структуры ИО будут являться классы соответствующей онтологии.

Зададим следующие обозначения компонентов онтологии: онтология O представляет собой знаковую систему $O = \langle P, V, R, C \rangle$, где P – множество понятий (концептов); V – множество экземпляров понятий; R – множество предикатов – атрибутов понятий; C – множество отношений, которые задают следующие виды связи между сущностями (рис. 2.13).

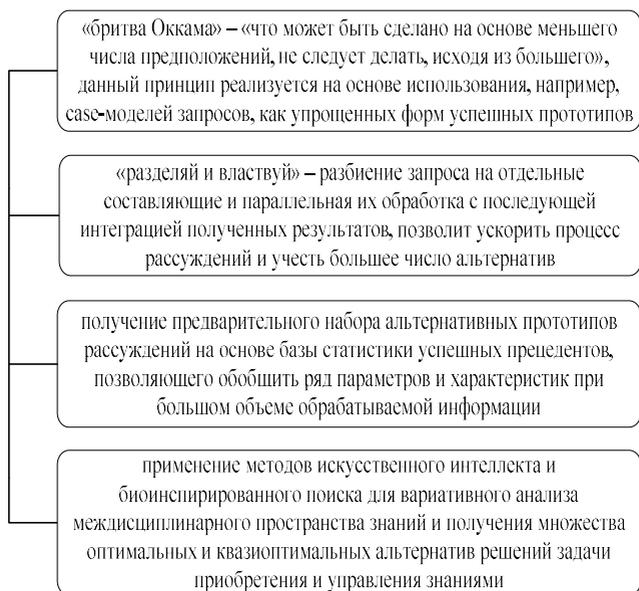


Рис. 2.11. Принципы

Тогда оценка близости между знанием и запросом – это численное значение, которое показывает степень их сходства и называется семантической оценкой, если она определяется на основе документов и запросов, имеющих семантическое значение [1, 42].

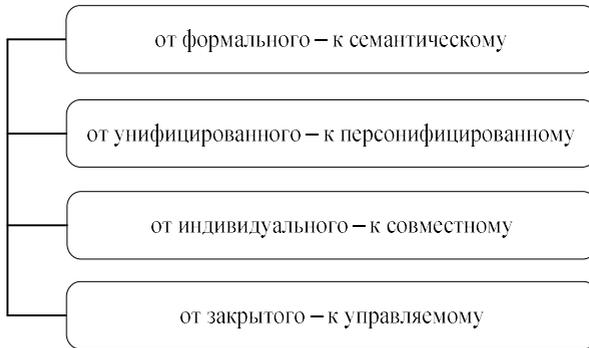


Рис. 2.12. Подходы к организации поиска

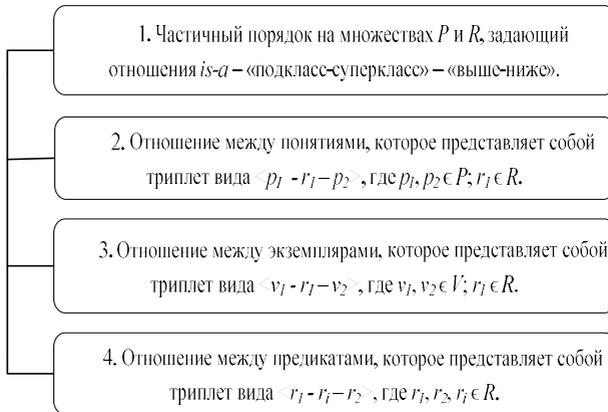


Рис. 2.13. Виды связей между сущностями

Сформулируем постановку задачи *семантического поиска*, которая 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 [42, 43]. Результаты поиска ранжируются по значениям их семантической близости к запросу.

Семантический поиск может помочь в выборе документов, которые имеют общий контекст, даже если они относятся к разным областям знаний. Это позволяет накапливать, извлекать и обновлять знания, которые находятся в разных областях, путем выявления и использования междисциплинарных связей.

Классификация знаний. Представим математическую постановку задачи классификации знаний. Пусть X – множество описаний элементов знаний, Y – множество наименований классов. Существует целевая зависимость – отображение $y^*: X \rightarrow Y$, значения которой известны только на объектах конечной обучающей выборки $X^m = \{(x_1, y_1), \dots, (x_m, y_m)\}$. Требуется построить алгоритм $a: X \rightarrow Y$, 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 $X^m = \{(x_1, y_1), \dots, (x_m, y_m)\}$ выборка наблюдений, сгенерированная согласно вероятностной мере P . Требуется построить алгоритм $a: X \rightarrow Y$, способный классифицировать произвольный объект $x \in X$.

Приведем основные виды классификации знаний (рис. 2.14–2.18).



Рис. 2.14. Классификация знаний по Ф. Махлуп

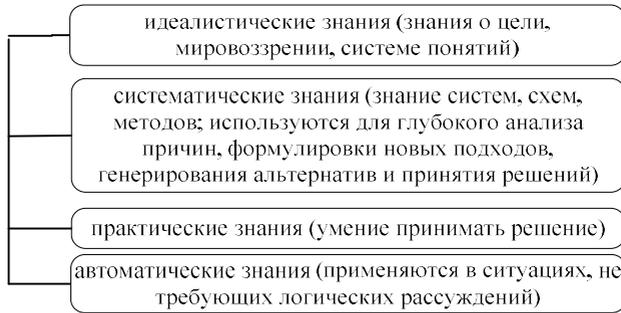


Рис. 2.15. Классификация знаний по К. Вииг

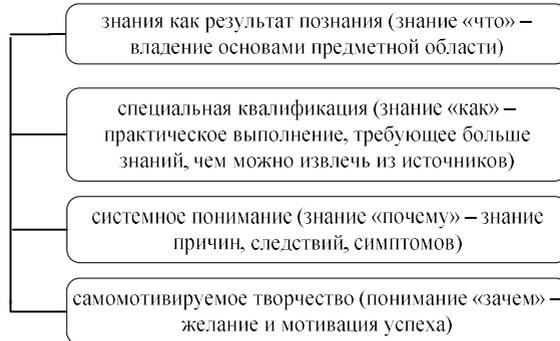


Рис.2.16. Классификация знаний на личностном уровне

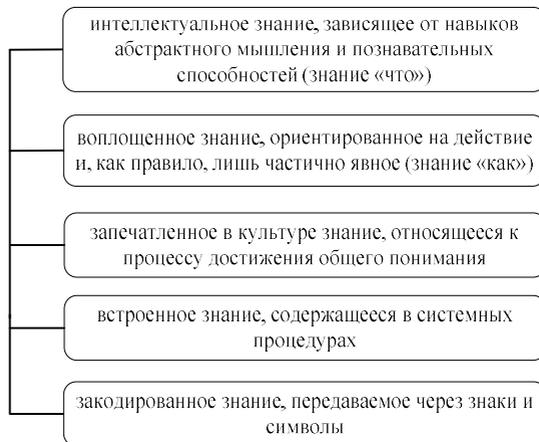
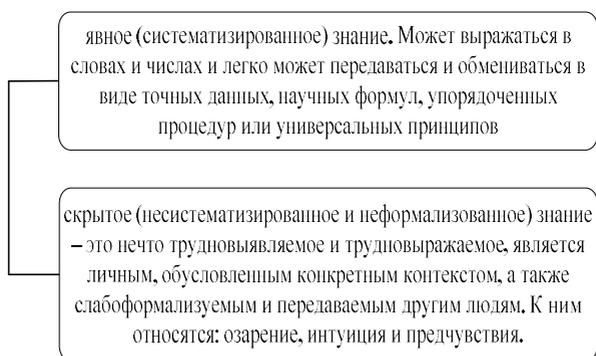


Рис.2.17. Классификация организационных знаний по Ф. Блеклеру



**Рис.2.18. Классификация организационного знания
Н. Тонака и Х. Такеучи**

Рассмотрев различные виды классификации знаний, отметим, что качество результатов решения задачи классификации зависит от эффективности выполнения других задач управления знаниями, таких как: идентификация; приобретение; совершенствование; распределение (рис. 2.19), а также использование и сохранение.

Из анализа рис. 2.19 следует, что проблема классификации знаний лежит между обнаружением знаний и их представлением. Во время обнаружения знаний извлекаются неформализованные сведения из разнообразных источников информации. Во время представления знаний создаются онтологические, семантические, нечеткие, имитационные и другие модели.

Сформулируем задачу *структурирования знаний* – определение наличия или отсутствия признаков системности в структурах элементов знаний из различных предметных областей на основе разделения знаний на устойчивые группы и подгруппы. Этот процесс позволяет решить данную задачу. Основные принципы структурирования знаний включают в себя необходимость определения порядка деления знаний на группы с учетом их важности и наличия системных признаков, которые должны учитываться при делении.

В настоящее время с ростом объемов знаний происходит увеличение энтропии как меры информационного шума, что увеличивает сложность обработки информации и может привести к информационной перегрузке. Поэтому необходимо, в первую очередь,

решать следующие задачи, такие как противостояние манипуляциям и исключение информационного шума из анализируемых источников. Одним из подходов к эффективному решению данных задач является структурирование знаний [43–45].

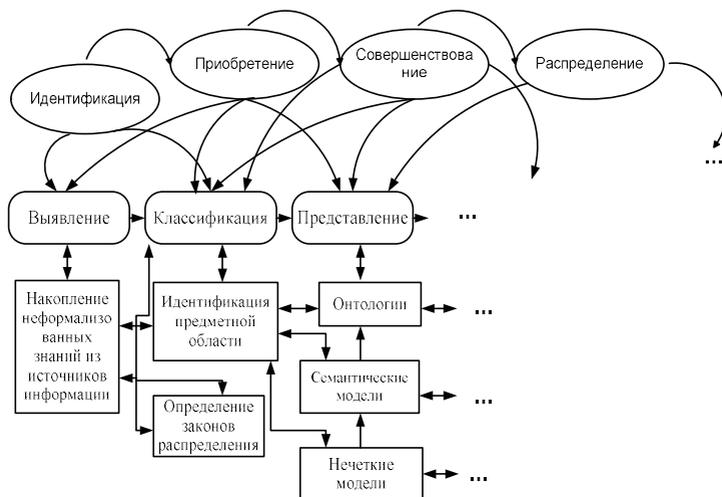


Рис 2.19. Связанные с классификацией этапы управления знаниями

Для описания указанного подхода введем ряд определений (рис. 2.20).

1. Мышление — это отображение в мозгу человека основных признаков объектов и событий;
2. Системно значимый признак — это наиболее важное свойство объекта или события (процесса);
3. Знания — это субъективное отражение реальности в форме понятий, определений и отношений между ними;
4. Понятие — это логическое действие, позволяющее раскрыть его содержание;
5. Определение понятия — это только существенные (системные) признаки, которые отделяют одно понятие от другого.

Рис. 2.20. Ряд определений

Отметим, что система знаний строится на основе задания отношений в совокупности элементов знаний одной предметной области, или на более высоком (междисциплинарном) уровне – между различными предметными областями.

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

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

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

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

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

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

где $f_{m1}, f_{m2}, \dots, f_{m(k-1)}, f_{mk}$ – элементы множества F_3 , задающие m класс системно значимых признаков для элементов знания некоторой предметной области.

Также зададим для каждого анализируемого элемента знания q_z ($z = 1 \dots n$) множество имеющихся у него системно значимых признаков $Q_z = \{Q_{z1} \cup Q_{z2} \cup \dots \cup Q_{znm}\}$, где $Q_{z1} \subset F_1, Q_{z2} \subset F_2, Q_{znm} \subset F_m$.

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

$$M_0 = Q_z \cap F \quad (2.12)$$

А целевая функция в таком случае примет вид:

$$M_0 = F \quad (2.13)$$

Отсутствие заданного тождества указывает на неполное соответствие элемента требованиям, выдвигаемым к системно значимым признакам [38].

Представим модель данной постановки задачи двудольным графом:

$$G = \langle P, F, I, L \rangle, \quad (2.14)$$

где P – множество элементов знания; F – множество необходимых признаков системной значимости; I – дуги, указывающие на харак-

теристики, присущие конкретному элементу знания; L – дуги, указывающие на желаемые характеристики системной значимости для соответствующей предметной области.

Рассмотрим пример структурирования знаний на примере (рис. 2.21).

Здесь:

1) элемент знания P_1 обладает признаками: $\{F_{11}, F_{1(i-y)}, F_{2j}, F_{m1}\}$, (дуги: $I_{11}, I_{12}, I_{13}, I_{14}$), из которых существенными являются $\{F_{11}, F_{1i}, F_{21}, F_{mk}\}$, (дуги: $L_{11}, L_{12}, L_{13}, L_{14}$). где y – неизвестное целочисленное значение. Тогда выражение определения соответствия элемента знания системно значимым требованиям предметной области примет вид: $M_1 = I_1 \cap L_1 = F_{11}$, а цель поиска или доработки – $S_1 = L_1 \setminus M_1 = \{F_{1i}, F_{21}, F_{mk}\}$;

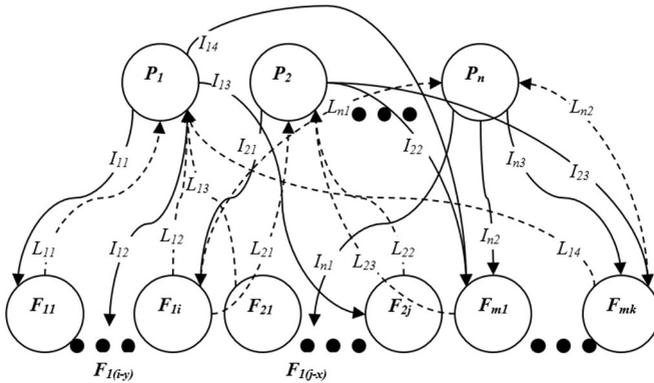


Рис. 2.21. Пример структурирования знаний

2) элемент знания P_2 обладает признаками: $\{F_{1i}, F_{m1}, F_{mk}\}$ (дуги: I_{21}, I_{22}, I_{23}), из которых, существенными являются: $\{F_{1i}, F_{2j}, F_{m1}\}$, (дуги: L_{21}, L_{22}, L_{23}). Тогда выражение определения примет вид: $M_2 = I_2 \cap L_2 = \{F_{1i}, F_{m1}\}$, а цель поиска или доработки – $S_2 = L_2 \setminus M_2 = F_{2j}$;

3) элемент знания P_n обладает признаками: $\{F_{1(i-x)}, F_{m1}, F_{mk}\}$ (дуги: I_{n1}, I_{n2}, I_{n3}), из которых существенными являются $\{F_{1i}, F_{mk}\}$, (дуги: L_{n1}, L_{n2}). Тогда выражение определения примет следующий вид: $M_n = I_n \cap L_n = F_{mk}$, а цель поиска или доработки – $S_n = L_n \setminus M_n = F_{1i}$.

Основная идея структурирования знаний заключается в оценке наличия существенных признаков для построения многоуровневой

связанной сети понятий на разных уровнях знаний. Однако, для создания междисциплинарных знаний необходимо использовать системную интеграцию онтологий из разных предметных областей. Рассмотрим постановку задачи системной интеграции множества онтологий:

$$O^U = \bigcup_i O_i, i = \overline{1, N}, \quad (2.15)$$

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

Объединение – это концептуальная системная интеграция исходных графов онтологии (онтографов, ОГ) и их отношений. Объем знаний в предметных областях выражается через параметры формально-онтологического представления. Например, при представлении в виде онтографа без учета типов отношений и сложности интерпретаций, объем знаний может быть оценен как число вершин онтографа. Если структура ОГ простая и древовидная, то определение объема знаний в области может быть записано следующим образом:

$$V = \sum_i \sum_p \sum_d O_i \cdot Z_{p,d}, \quad (2.16)$$

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:

$$V = \sum_i \sum_p O_i \cdot (\gamma_d + \sum_j \delta_{d,j}), \quad (2.17)$$

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

Интеграция знаний – это комплексная задача, которая включает в себя разработку баз знаний, множеств объектных, онтологических и семантических моделей для принятия решений, а также модулей выбора и формирования решений с использованием математического и имитационного моделирования.

Таким образом, во 2-ой главе исследованы основы приобретения и управления знаниями, предложен новый образ знаний, объединяющий в едином системном элементе модифицированные модели представления и управления знаниями. Также во 2-ой главе описана формализованная онтологическая модель представления знаний. Сформулированы основные постановки задач исследования.

ГЛАВА 3. ЭЛЕМЕНТЫ ТЕОРИИ ПРИОБРЕТЕНИЯ И УПРАВЛЕНИЯ ЗНАНИЯМИ

3.1. Элементы теории, концепция и стратегии интеллектуальной поддержки приобретения новых знаний

Процессы приобретения знаний и их обработки сложны и многоступенчаты. Для их корректной реализации необходимо соответствующее управление, которое обеспечит последовательность, согласованность и эффективность [3–7, 13–16]. Следует отметить, что *знания создаются в процессе обработки*, и поэтому необходимо управлять этим процессом.

Можно представить организацию информационных потоков и их взаимосвязь в виде модели модели циклического сценария, которая учитывает все аспекты управления знаниями (рис.3.1). В этой модели основными этапами являются показанные на рисунке 3.2.

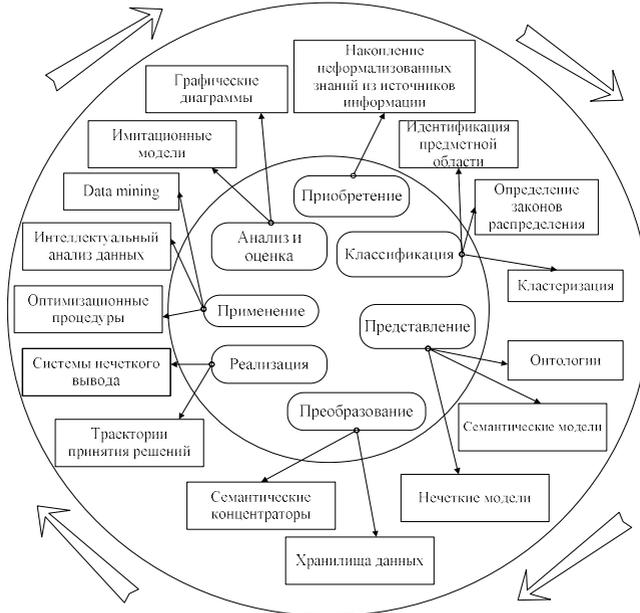


Рис. 3.1. Модель процессов циклического сценария управления знаниями



Рис. 3.2. Основные этапы управления знаниями

При управлении знаниями следует учитывать наличие метаданных и метаутверждений. В процессе обработки знаний важным элементом становится управление данными, которое обеспечивает эффективность обработки знаний.

На основе цикла управления знаниями, мы предлагаем *концепцию* интеллектуальной поддержки принятия решений, которая позволяет выявлять новые знания из разнородных источников информации. Междисциплинарный и мультидисциплинарный подход к накоплению знаний после обработки приводит к появлению новых знаний. Для решения основных задач управления знаниями мы предлагаем многоуровневую архитектуру приобретения знаний, включая уровень необходимых инструментов (рис. 3.3).

Эта архитектура позволяет поддерживать непрерывный контроль за процессами проверки знаний, чтобы выявлять новые закономерности и создавать новые знания, удовлетворяющие спрос на знания. Цель управления знаниями - *повысить прозрачность знаний*.

Для достижения данной цели рассмотрим систему взглядов, представленную в виде ряда утверждений и обобщающих их базовых принципов (рис. 3.4).

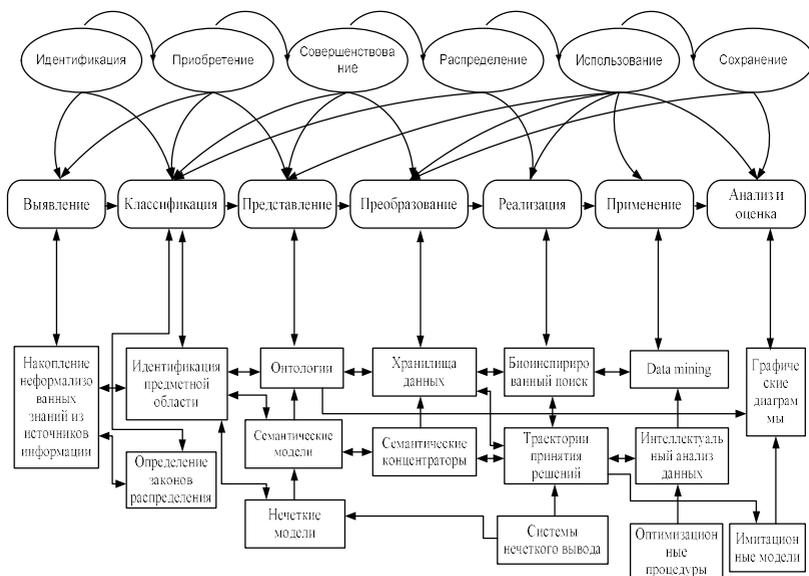


Рис. 3.3. Многоуровневая архитектура циклического сценария управления знаниями

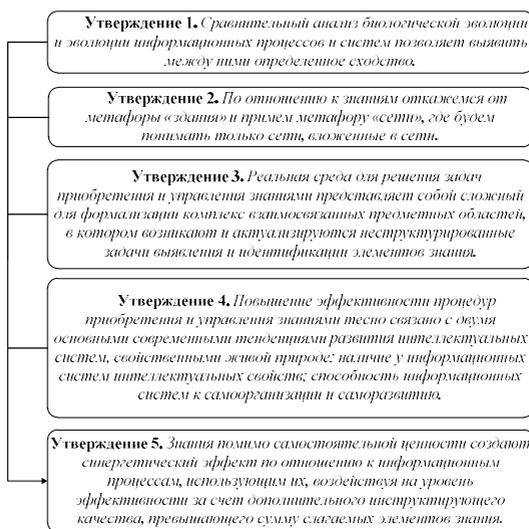


Рис. 3.4. Ряд утверждений

Одним из условий самоорганизации информационной системы является наличие механизмов поиска и отбора полезной информации. Этот подход является упрощённой моделью творческой деятельности людей [7, 39].

На основе этой концепции мы можем сформулировать *базовые принципы приобретения знаний и управления ими* (рис. 3.5).

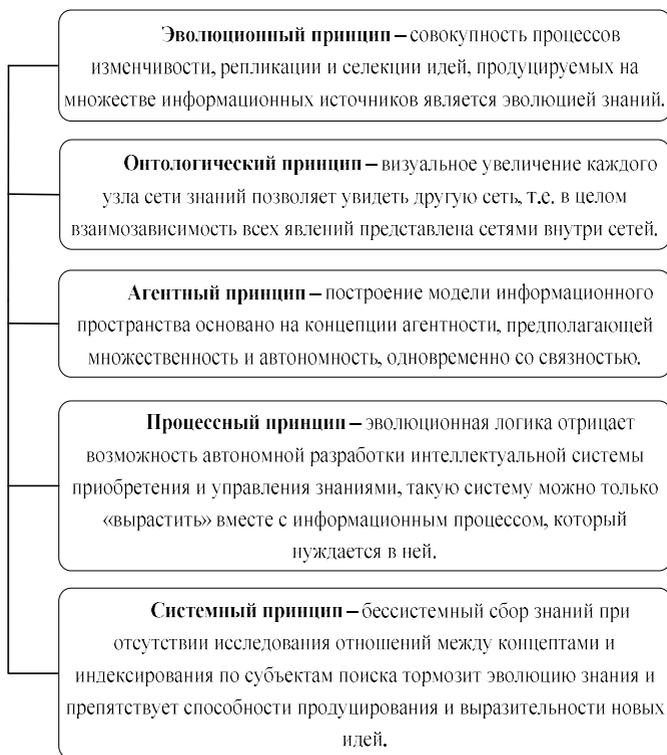


Рис. 3.5. Базовые принципы приобретения и управления знаниями

Так как процессы приобретения знаний и управление ими включают множество этапов с учетом возможных негативных воздействий внешней среды, таких как большая размерность, неопределенность информации, избыточность данных, недостоверность данных и т.д., а также вариантов реакции интеллектуальной системы на эти факторы, *стратегия* приобретения знаний и управления ими может быть представлена следующим образом. (рис. 3.6).

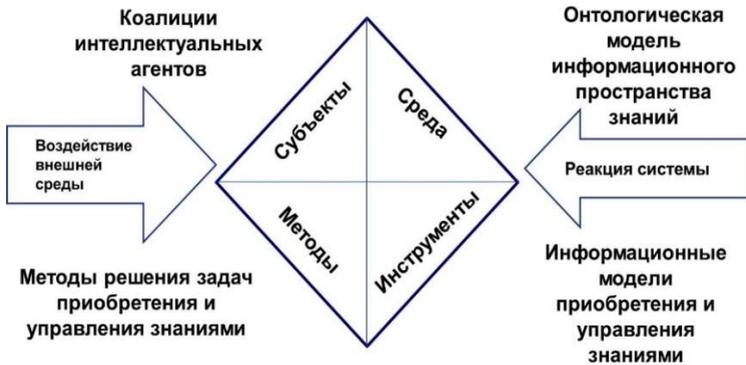


Рис. 3.6. Стратегия приобретения и управления знаниями

Эта стратегия направлена на получение точного знания, которое в современном контексте означает систему значимых отношений на множестве информации микро-, мета- и макро- содержательных уровней.

С учетом разработанной стратегии и принципа агентности, опишем базовую модель интеллектуального агента, способного совершенствоваться и верифицировать свою базу знаний.

Это одно из обязательных свойств каждой информационной системы. Для анализа приобретенных знаний и их формализации необходимо использовать инструменты анализа. Цель этого анализа – получение нового качества знаний путем построения правдоподобных рассуждений, сравнения полученных выводов с аналогичными событиями из базы прецедентов и доработки правил вывода. Новые знания о предметной области позволяют улучшить сценарии и модель поведения системы при обработке новых событий.

Мы будем использовать теорию многоагентных моделей для реализации этой функции. Моделирование сообществ агентов позволит представить набор сценариев приобретения знаний и управления. Опишем цикличность жизнедеятельности агента, а также его развитие и обучение. Зададим жизненный цикл агента в виде графа переходов $G = \langle B, E, P, U \rangle$ между множествами процессов и режимов функционирования. В графе представлены вершины B и E , которые не являются процессами в данной модели, а указывают на начало и конец работы интеллектуального агента. Информационным процессам соответствует множество вершин P , на котором за-

даны ребра переходов состояний интеллектуального агента. Построенные гиперребра моделируют режимы функционирования агента R , как это показано на рисунке 3.7.

Существует два типа моделей интеллектуальных агентов – глобальные и локальные. Глобальные модели включают множество субъектов, объединенных на основе сходства системно значимых признаков, тогда как локальные модели включают отдельный субъект.

Ниже перечислены основные подходы к моделированию интеллектуальных агентов:

- определение логики рассуждений коалиции агентов путем применения регрессионных зависимостей;
- построение модели поведения отдельного агента с использованием методов *data mining*;
- методы оптимизации для построения модели поведения агентов.

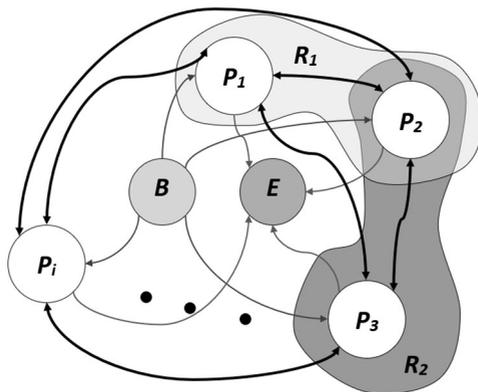


Рис. 3.7. Модель переходов интеллектуального агента

Создание локальных моделей на основе базы знаний подразумевает определение логики поведения конкретного агента. Аналогичный подход к определению поведения интеллектуальных агентов основывается на эквивалентности их свойств в одинаковых условиях. Изменения в наборах свойств могут привести к смене моделей поведения и рассуждений. Это может повлиять на вероятностную оценку возможностей продуцирования определенных выводов [46, 47].

Произведем учет особенностей всех рассматриваемых объектов при использовании данного подхода. Преимущества использования

такого подхода включают повышение качества прогнозов по сравнению с моделями регрессии, а также более точное прогнозирование на уровне групп субъектов. Также, использование данных за предыдущий период позволяет получить более оперативную информацию [3].

Для реализации данного подхода необходима более представительная выборка исходных данных для прогнозирования, которая может быть получена в процессе сбора априорной статистики. Построение моделей информационных процессов также требует большого количества данных и может быть реализовано с помощью имитационного моделирования.

Интегрированная информационная модель интеллектуального агента проиллюстрирована на рисунке 3.8 и задается следующим выражением [10]:

$$A_i = \langle L_i, B_i, C_i, T_i, P_i, D_i, S_i \rangle, \quad (3.1)$$

где L_i (level) – модель требуемого уровня знаний i -того интеллектуального агента; B_i (base) – модель стартового потенциала знаний i -того интеллектуального агента; C_i (conduct) – модель поведения i -того интеллектуального агента при определении намерений; T_i (type) – модель индивидуальных характеристик i -того интеллектуального агента; P_i (process) – модель организации процесса обучения i -того интеллектуального агента; D_i (distribution) – модель распределения имеющихся ресурсов i -того интеллектуального агента; S_i (storage) – доступные ресурсы и средства i -того интеллектуального агента.

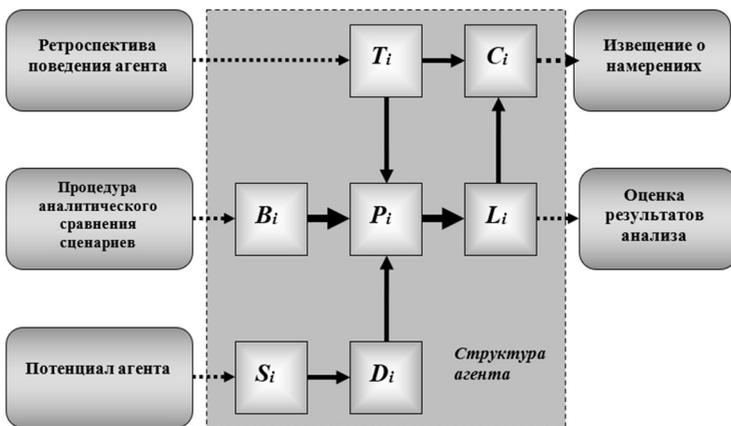


Рис. 3.8. Интегрированная модель интеллектуального агента

Исследуя альтернативные сценарии на первой стадии жизненного цикла, мы используем модель стартового потенциала интеллектуального агента для исследования альтернатив идентификации, приобретения и улучшения знаний. Модель организации процесса обучения агента, позволяющая перейти от начальной модели к модели требуемого уровня, зависит от моделей индивидуальных характеристик и распределенных ресурсов агента.

Поведение интеллектуального агента на всех стадиях его жизненного цикла оценивается экспертной системой, приведенной на рисунке 3.9.

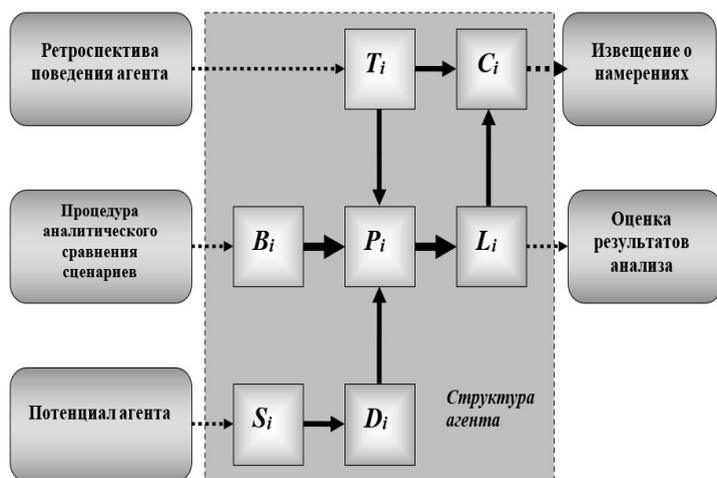


Рис. 3.9. Модель поведения интеллектуального агента

Здесь $ESA = \{\{c_{1i}, c_{2i}, \dots, c_{ni}\}, \{d_1, d_2, \dots, d_n\}, EM\}$, где $\{c_{1i}, c_{2i}, \dots, c_{ni}\}$ – вектор характеристик интеллектуального агента; $\{d_1, d_2, \dots, d_n\}$ – вектор правил преобразования характеристик интеллектуального агента; EM – экспертная система вывода.

Модель требуемого уровня знания используется для оценки результатов аналитического сопоставления сценариев с прототипами, хранящимися в базе ретроспективных примеров. Она влияет на модель поведения агента в определении его намерений и связана множеством значимых отношений с моделью его индивидуальных характеристик, созданной на основе ретроспективной информации

о поведении. Ресурсы и средства, доступные в модели распределения, составляют потенциал агента.

Построим простейшую *математическую модель поведения* для предложенного типа интеллектуального агента. Учтем возможность применения централизованных и децентрализованных схем управления популяцией подобных агентов, что подразумевает наличие определенной вероятности реализации различных режимов поведения при одинаковом наборе функций.

Предложенная ранее математическая модель описания процесса распределения ценных знаний в глобальной сети с общим числом интеллектуальных агентов равным N , указывает на возможность формирования информационной зависимости агентов обучения классификатора от агентов комбинирования классификатора. Это позволяет принять достаточно очевидную гипотезу о том, что поведение одного агента имеет определенное влияние на рассуждения другого агента в рамках информационного процесса приобретения и управления знаниями.

Введем количественные оценки различных режимов состояния модели поведения интеллектуального агента. Априорный (независимый) режим перехода агента в определенное состояние характеризуется вероятностью φ_i , тогда апостериорный (сформированный под воздействием) режим перехода в другое состояние характеризуется вероятностью ρ_i . Для обеспечения полноты предлагаемой модели учтем весь спектр вариантов зависимости интеллектуальных агентов, для этого введем функцию принадлежности μ_i . При абсолютной независимости агента $\mu_i = 1$, и наоборот, $\mu_i = 0$ – при абсолютной зависимости. Очевидно, что при $\mu_i = 1$, $\rho_i' = \varphi_i$.

Упростим постановку задачи введением условия о независимости от любого другого агента популяции влияния j -го агента на i -го [48]. Обозначим δ_{ij} – вероятность того, что i -ый агент примет модель поведения j -го и перейдет в новое состояние с вероятностью ρ_i . Тогда для зависимого агента полная вероятность ρ_i^0 перехода в новое состояние примет вид следующей формулы [48]:

$$\rho_i^0 = \sum_{j=1}^N \delta_{ij} \rho_j; \delta_{ii} = 0, \quad (3.2)$$

$$\sum_{j=1}^N \delta_{ij} = 1; \forall \delta_{ij} \neq \delta_{ii}, \delta_{ij} > 0, \quad (3.3)$$

Используя полученную формулу (3.2) полной вероятности, получим апостериорную вероятность ρ_i для i -го агента [48]:

$$\begin{aligned} \rho_i &= \rho'_i \mu_i + (1 - \mu_i) \rho_i^0, i = 1, 2, \dots, N, \\ \rho_i &= \varphi_i \mu_i + (1 - \mu_i) \sum_{j=1}^N \delta_{ij} \rho_j, i = 1, 2, \dots, N. \end{aligned} \quad (3.4)$$

Система (3.4) является искомой математической моделью общего вида, полученной с учетом принятых упрощений (φ , μ , δ). Для решения данной системы, представим ее в векторной форме [48]:

$$P = \Phi M + (E - M) \Delta P, \quad (3.5)$$

где Φ и P – векторы с компонентами φ_i и ρ_i , M – диагональная матрица (μ_i), E – единичная матрица, Δ – стохастичная матрица.

Завершим построение математической модели поведения агента доказательством существования решения системы (3.4) в интервале $0 \leq \rho_i \leq 1$.

Введем матрицу $\Omega = (E - M) \Delta$, тогда представим (3.5) в следующем виде [48]:

$$\begin{aligned} P &= \Phi M + \Omega P, \\ P - \Omega P &= \Phi M, \\ (E - \Omega) P &= \Phi M. \end{aligned} \quad (3.6)$$

Сначала предположим, что не все $\mu_i = 0$, при этом допустим, что все $\mu_i \neq 1$. Матрица Ω неотрицательна и (за исключением тривиального случая, т.е. при $N > 2$) неразложима. По теореме Фробениуса [48] данная матрица всегда имеет простой корень характеристического уравнения в виде положительного числа r с максимальным модулем, такого, что $s \leq r \leq S$, где s и S – соответственно минимальная и максимальная суммы элементов строк матрицы Ω . Отсюда следует, что $r < 1$, это является гарантией существования и неотрицательности матрицы, обратной к $(E - \Omega)$. Тогда решение системы (3.4) единственно и неотрицательно.

Докажем, что по норме $\rho_i^{max} \leq 1$. Разделим множество индексов i на два подмножества: Q и Z . Подмножество Q включает в себя индексы $i=q$, при которых $\mu_i = 0$, а множество Z – оставшиеся $i=z$. Тогда представим систему (3.4) в следующем виде [48]:

$$\rho_z = \varphi_z \mu_z + (1 - \mu_z) \sum_{j=1}^N \delta_{zj} \rho_j, z \in Z, \quad (3.7)$$

$$\rho_q = \sum_{j=1}^N \delta_{qj} \rho_j, q \in Q. \quad (3.8)$$

Введем подмножество W индексов $i=w$, для которых $\rho_i^{max} = \rho_w$. Докажем, что в определенной ранее группе индексов Z есть хотя бы один индекс из подмножества W , в противном случае для всех $w \in W$ имело бы место следующее равенство [48]:

$$\rho_w = \sum_{j=1}^N \delta_{wj} \rho_j, \quad (3.9)$$

Которое возможно только тогда, когда $\rho_j = \rho_w$, так как $\sum_{j=1}^N \delta_{wj}$, все $\delta_{wj} > 0$ и все $\rho_j > 0$. В этом случае, подмножество W совпадет со всем множеством $i = 1, 2, \dots, N$, что приведет к противоречию с допущением, что в Z нет ни одного индекса из подмножества W . Следовательно, в Z присутствует хотя бы один индекс из W , а значит имеет место следующее равенство [48]:

$$\rho_i^{max} = \mu_w \mu_w + (1 - \mu_w) \sum_{j=1}^N \delta_{wj} \rho_j, \quad (3.10)$$

тогда

$$\begin{aligned} \rho_i^{max} &\leq \mu_w + (1 - \mu_w) \sum_{j=1}^N \delta_{wj} \rho_i^{max}, \\ \rho_i^{max} &\leq \mu_w + (1 - \mu_w) \rho_i^{max}, \\ \rho_i^{max} &\leq \mu_w (1 - \rho_i^{max}) + \rho_i^{max}, \\ \mu_w (\rho_i^{max} - 1) &\leq 0. \end{aligned} \quad (3.11)$$

В данном случае, так как $\mu_w > 0$, то верным является $\rho_i^{max} \leq 1$, что и требовалось доказать.

В случае, когда часть популяции агентов является абсолютно независимой, тогда для них $\mu_s = 1, s \in S \subseteq i, i = 1, 2, \dots, N$. При этом, матрица Ω становится разложимой. Поведение независимой группы агентов определяется как априорное $\rho_s = \varphi_s$, порядок системы понижается. Новая матрица Ω' является неразложимым минором матрицы Ω и сохраняет все необходимые свойства [48], обеспечивая существование, неотрицательность и ограниченность решения.

Для повышения эффективности многоагентных систем на основе моделей интеллектуальных агентов необходимо унифицировать их внешнее представление знаний, чтобы упростить обмен информацией между агентами. Для этой цели используется потоковая схема круговорота ресурсов в качестве модели переходов интеллектуального агента. В отличие от предыдущих моделей, наша модель дифференцирует основные функции агента на реализованные процессы и режимы. Это позволяет использовать единый универсальный вид модели для решения различных задач, таких как классификация, структурирование, интеграция и семантический поиск знаний. Кроме того, модель учитывает возможность перехода в различные режимы поведения при сохранении набора функций

Для успешного решения задач сбора и управления знаниями, которые не имеют четкой структуры, и при этом важно учитывать содержание информационных источников, требуется разработать модели, которые имитируют то, как эксперт усваивает и использует знания. Такие модели должны описывать основные принципы и механизмы, определяющие действия и решения эксперта в процессе работы со знаниями.

Эти модели должны включать в себя основные принципы и правила, которые руководят действиями и решениями специалиста в контексте работы со знаниями. Они позволяют создать интеллектуальную систему, которая способна собирать и обрабатывать информацию аналогично эксперту, что обеспечивает ей схожие функциональные возможности с мышлением эксперта.

Чтобы построить модель, которая имитирует поведение эксперта, можно использовать уже существующие модели интеллектуальных систем и теории о том, как люди учатся и воспринимают информацию. В рамках такого подхода можно выделить различные стили обучения, основанные на индивидуальных особенностях каждого человека

Рассматривая междисциплинарный подход, выделим следующие стили учения на основе индивидуальных свойств.

1. Дивергентности – это получение знаний нового качества при синтезировании и интегрировании информации, в том числе в составе коалиций участников процесса приобретения знаний.

2. Ассимилятивности – это четкий детализированный план действий, анализ данных и исследование закономерностей на основе логичного и последовательного мышления.

3. Энвергентности – это субъекты, обладающие стратегическим мышлением и эффективно принимающие решения в условиях информационной неопределенности.

4. Аккомодативности — это практики, реализующие когнитивные процессы на основе использования уровня конкретного восприятия и предметных действий для получения необходимой ценной информации.

Из открытых источников известно несколько иных интерпретаций данной классификации. П. Хани и А. Мамфорд стили учения интерпретировали следующим образом: *дивергентный* как *деятельностный*, *ассимилятивный* как *рефлексивный*, *энвергентный*

как *теоретический* и *аккомодативный* как *готический* [49]. Для решения поставленной задачи зададим данные стили учения в виде множества $S_1 = \{s_{11}, s_{12}, s_{13}, s_{14}\}$.

Еще один подход к изучению стилей учения – это модель, предложенная А.Р. Грегорсом. В этой модели учитывается значимость конкретного профессионального опыта и абстрактных знаний для формирования последовательной или произвольной стратегии исследования [50]. Здесь: *конкретно-последовательный* стиль учения – это реализация последовательной траектории обучения и наглядного опыта; *конкретно-случайный* стиль учения подразумевает использование метода проб и ошибок; *абстрактно-последовательный* стиль учения, напротив, основан на использовании системных и словесных инструкций для применения аналитического подхода к получению знаний; *абстрактно-случайный* стиль учения рассматривается как комплексный подход к обучению на основе методов обработки неструктурированных данных и визуального восприятия [49]. Мы можем представить эти стили учения как множество $S_2 = \{s_{21}, s_{22}, s_{23}, s_{24}\}$.

Для более полного описания характеристик возможных стилей учения интеллектуальных агентов проведем их интеграцию с выявлением корреляции между ними. Для этого проведем анализ сходства основных характеристик, описанных в рассмотренных моделях стилей учения. Из проведенного анализа выявлены значимые сходства между *дивергентным* и *абстрактно-случайным*, *ассимилятивным* и *абстрактно-последовательным*, *энвергентным* и *конкретно-последовательным*, *аккомодативным* и *конкретно-случайным*, позволяющие представить модель их описания в виде двудольного графа $G = \langle S_1, S_2, L \rangle$ (рис. 3.10).

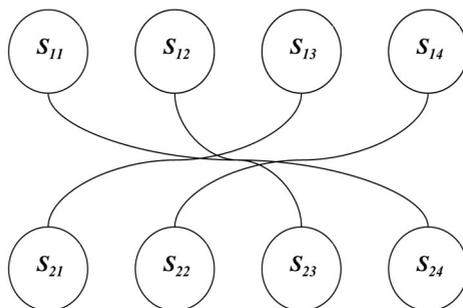


Рис. 3.10. Графовая модель сходств стилей учения

Здесь S_1 и S_2 – множества типов стилей учения, а L – множество ребер-сходств характеристик рассмотренных стилей учения. При этом, $l_1 = s_{11} \cup s_{24}$; $l_2 = s_{12} \cup s_{23}$; $l_3 = s_{13} \cup s_{21}$; $l_4 = s_{14} \cup s_{22}$. Тогда множество интегрированных стилей учения представляется следующим выражением:

$$IS = \{s_{11} \cup s_{24}, s_{12} \cup s_{23}, s_{13} \cup s_{21}, s_{14} \cup s_{22}\}. \quad (3.12)$$

Далее основе модели Дж. Ройса выделим три базовых категории для построения агентами разных «образов мира» (рис. 3.11).

Данные способы мышления зададим в виде множества $W = \{w_1, w_2, w_3\}$. Теперь давайте подробнее рассмотрим, как могут быть использованы разработанные модели стилей учения и способов мышления для определения индивидуальных особенностей интеллектуальных агентов.

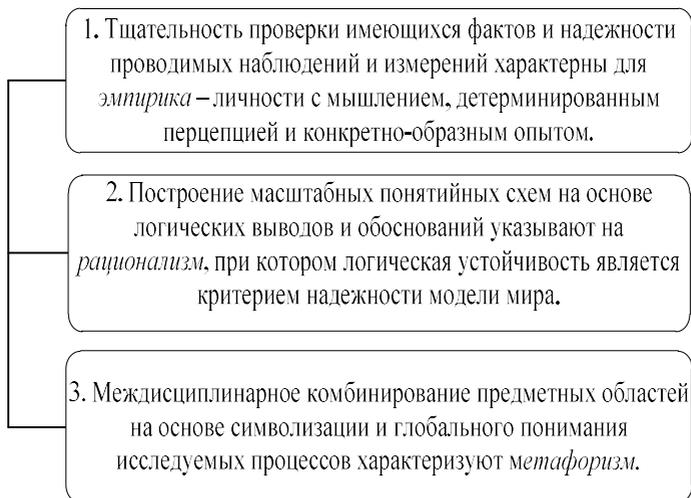


Рис. 3.11. Базовые категории

Под интеллектуальным агентом мы можем понимать некую сущность, которая находится в сообществе подобных ей субъектов, решает задачи по сбору и обработке информации в исследуемой неоднородной среде, влияет на эту среду и отражает события и процессы, которые в ней происходят. Однако сложность использования моделей интеллектуальных агентов для сбора и обработки информации заключается в наличии обширной классификации типов их индивидуальных свойств [46–50]. В связи с этим предлагается

использование комбинированных моделей индивидуальных характеристик интеллектуальных агентов на основе объединения с когнитивными характеристиками личности, представленными моделями стилей учения и способов мышления.

Комбинированные модели основаны на свойствах «слабых» и «сильных» интеллектуальных агентов. «Слабые» интеллектуальные агенты проявляют когнитивные способности, приближенные к естественным, однако они ограничены конкретными предметными областями и, следовательно, имеют ограниченное применение. «Сильные» же интеллектуальные агенты наделены всеобъемлющим интеллектом, который может генерировать новые идеи и решать задачи, которые раньше были им неизвестны или считались нерешаемыми.

Основные характеристики «слабых» ИА включают в себя:

– *автономность (autonomy)*: способность действовать без внешних вмешательств или контроля, которая достигается через самостоятельный контроль. Обучение такого типа агентов отличается высокой степенью активности и целостностью подхода, что соответствует таким стилям учения, как дивергентный, деятельностный и абстрактно-случайный;

– *социальное поведение (social ability)*: способность объединяться в коалиции и взаимодействовать друг с другом для обмена информацией, используя специальный язык коммуникации [50]. Этот тип поведения соответствует таким стилям учения, как ассимиляционный, рефлексивный и абстрактно-последовательный;

– *реактивность (reactivity)*: способность быстро реагировать на внешние воздействия, используя метод проб и ошибок, что соответствует аккомодативному, готическому и конкретно-случайному стилям учения;

– *активность (activity)*: способность генерировать цели и рационально действовать для их достижения, что соответствует энвергентному, теоретическому и конкретно-последовательному стилям учения.

Данные свойства «слабых» интеллектуальных агентов зададим в виде множества $A = \{a_1, a_2, a_3, a_4\}$, а сходство между стилями учения и их свойствами представим в виде гиперграфа $G_2 = (P, O)$ (рис. 3.12).

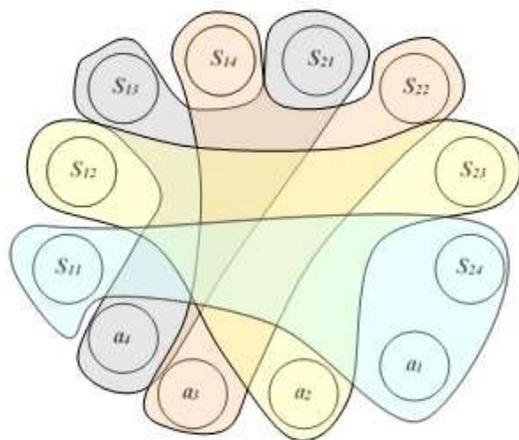


Рис. 3.12. Гиперграфовая модель сходства между стилями учения и свойствами «слабых» интеллектуальных агентов

Здесь P – множество вершин гиперграфа, а O – множество его гиперребер. При этом ($O_1 = s_{11} \cup s_{24} \cup a_1$; $O_2 = s_{12} \cup s_{23} \cup a_2$; $O_3 = s_{13} \cup s_{21} \cup a_4$; $O_4 = s_{14} \cup s_{22} \cup a_3$). При этом каждое ребро гиперграфа является точкой интеграции и соответствует одному стилю учения, полученному в результате объединения естественных и искусственных когнитивных свойств.

В результате далее для создания многоагентных ИИСПиУЗ будем использовать четыре стиля учения (автономный, коммуникативный, активный и реактивный). Далее при их укрупнении выделим два базовых стиля: *деятельностный* (постоянное применение полученных знаний и самообучение на основе проработки практических ситуаций) и *аналитический* (применение логического анализа и теоретического обоснования) [51]. В итоге получим *автономно-реактивный* и *коммуникативно-активный* стили учения слабых интеллектуальных агентов.

При рассмотрении характеристик «сильных» интеллектуальных агентов дополним их рядом «ментальных свойств», т. е. интенциональными понятиями, такими как [51]:

- *знание* (knowledge) – постоянные знания и представления агента о себе, окружающей среде и коалиции других агентах, которые являются начальным потенциалом и остаются неизменными в процессе жизнедеятельности агента;

- *убеждения* (beliefs) – приобретаемые, переменные знания и представления агента о себе, окружающей среде и коалиции других агентах, которые состоят из истинных и ошибочных убеждений;
- *желания* (desires) – целевые действия или показатели деятельности, определенные заданием и желаниями агента, возможно, в отдельных случаях, противоречивые;
- *намерения* (intentions) – деятельность агента, направленная на выполнение его обязательств перед другими субъектами, либо соответствующая его желаниям;
- *цели* (goals) – стратегическая цель жизнедеятельности интеллектуального агента, обусловленная множеством его состояний и характеристик;
- *обязательства* (commitments) – задачи, стоящие перед агентом и полученные по поручению других ИА, решение которых агент берет на себя в рамках коллективного сотрудничества для получения выводов в результате групповых рассуждений с другими конкретными агентами.

Свойства «сильных» интеллектуальных агентов зададим в виде множества $A_1 = \{a_{11}, a_{12}, a_{13}, a_{14}, a_{15}, a_{16}\}$ и сравним с моделью Дж. Ройса [51] На основе проведенного сравнения данные свойства соответствуют таким характеристикам «сильных» интеллектуальных агентов как *убеждения* (beliefs) и *цели* (goals). В основе критериев устойчивости, применяемых субъектом с *рациональным* способом мышления, находятся масштабные понятийные схемы и логические методы обоснования, что возможно только при наличии у такого субъекта постоянной составляющей *знаний* (knowledge).

Рассмотрим сходство между способами мышления, предложенными в модели Дж. Ройса, и характеристиками «сильных» интеллектуальных агентов. Представим характеристики «сильных» интеллектуальных агентов в виде двудольного графа $G_3 = \langle W, A_1, M \rangle$ (рис. 3.13). В данной графовой модели множество ребер M задает принадлежность определенных характеристик «сильных» интеллектуальных агентов описанным выше способам мышления. Для наглядности на рисунке 3.14 представим полученную закономерность в виде гиперграфа $G_4 = \langle K, N \rangle$, где K – множество вершин, $K = \{w_1, w_2, w_3, a_{11}, a_{12}, a_{13}, a_{14}, a_{15}, a_{16}\}$, N – множество ребер:
 $N_1 = w_1 \cup a_{12} \cup a_{15}$; $N_2 = w_2 \cup a_{11} \cup a_{16}$; $N_3 = w_3 \cup a_{13} \cup a_{14}$.

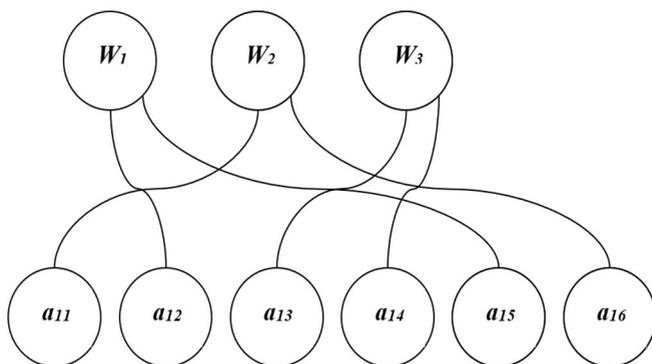


Рис. 3.13. Графовая модель соответствия характеристик «сильных» интеллектуальных агентов способам мышления

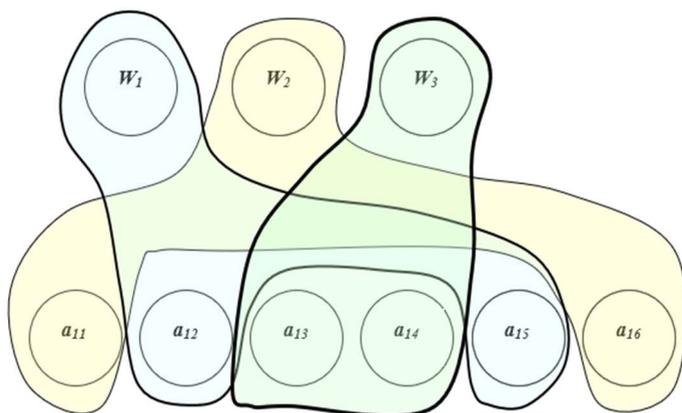


Рис. 3.14. Гиперграфовая модель соответствия характеристик «сильных» интеллектуальных агентов способам мышления

Из проведенного анализа вытекает новая классификация способов мышления «сильных» интеллектуальных агентов (рис. 3.15).

Данный подход повышает эффективность интеллектуальных информационных систем приобретения и управления знаниями за счет моделирования когнитивных процессов организации рассуждений эксперта.

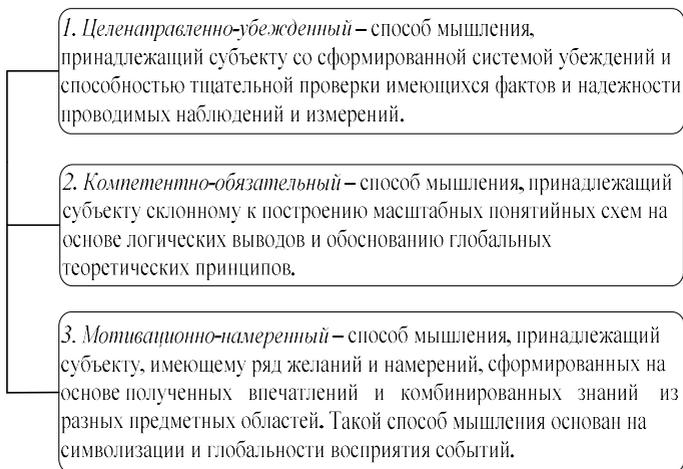


Рис. 3.15. Классификация способов мышления «сильных» интеллектуальных агентов

3.2. Онтологическая структура междисциплинарного пространства знаний

Рассмотрим принципы построения и использования онтологической структуры междисциплинарного пространства знаний (МПЗ) различных функциональных областей. Здесь онтологическая структура используется в качестве базиса при создании конкретных онтологий для решения задач интеграции и обработки знаний с учетом разных предметных (функциональных) областей. Данная структура реализована в виде системы онтологических паттернов содержания (*Ontology Content Design Patterns*), которые представляют собой небольшие целостные фрагменты онтологии, формализующие обобщенные сценарии обработки знаний функциональной области. Паттерны содержания используются в качестве строительных блоков при разработке онтологии. Данный подход при разработке онтологической структуры МПЗ, заключается в упрощении ее использования и обеспечении качества онтологического описания разнородных и распределенных знаний в разрабатываемых на ее основе онтологиях за счет повторного использования проверенных решений (прецедентов), представленных содержащимися в ней паттернами.

Усиление тенденции повсеместного использования территориально распределенных информационных систем требует разработки методов

приобретения и управления знаниями из разнородных неструктурированных источников. При этом возникает терминологическая несогласованность и понятийная противоречивость элементов формируемой модели информационной среды. Противоречивость представляемых знаний обусловлена наличием альтернативных взглядов на составные части проблемы у экспертов одной функциональной области. Для решения задач преодоления противоречивости в исследуемых элементах знаний, классификации и структуризации их представления с целью многократного и гибкого использования в интеллектуальных информационных системах приобретения и управления знаниями применяются онтологические структуры [52–54]. Такое решение предполагает создание отдельных онтологий функциональных областей знаний, каждая из которых поддерживается независимо, и их последующее объединение на основе поиска междисциплинарных отношений на множестве сущностей (элементов знаний) всех функциональных областей.

Представим онтологическую структуру МПЗ. Онтология МПЗ предназначена для интеграции и целостного представления знаний, накопленных в различных функциональных областях. МПЗ состоит из нескольких модулей, определённых в соответствии с уровнем абстракции их понятий и функционального назначения их содержимого. Каждый модуль – это отдельная онтология, описанная с помощью языка (*Ontology Web Language, OWL*). Таким образом, онтология МПЗ образуется путем импорта данных модулей (рис. 3.16).

Здесь основной является онтология информационных артефактов (*Information Artifact Ontology, IAO*), которая в свою очередь является расширением базовой формальной онтологии (*Basic Formal Ontology, BFO*) [55]. Модуль описания связей (отношений) на множестве сущностей всех функциональных областей (*Interdisciplinary objects' links ontology*) предназначен для представления некоторого описания междисциплинарных связей на естественном языке. В связи с этим предлагается ввести общие принципы представления знаний в онтологической структуре МПЗ:

- 1) создание системы отношений на множестве сущностей функциональных областей;
- 2) подбор подходящих онтологических паттернов содержания;
- 3) определение устойчивых отношений между паттернами;
- 4) формирование междисциплинарной функциональной области.

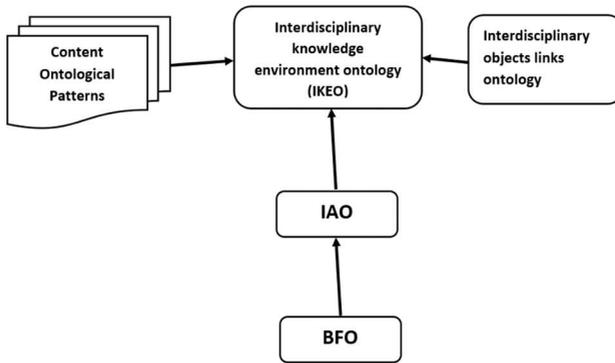


Рис. 3.16. Онтологическая структура МПЗ

Общая схема онтологических паттернов содержания имеет следующий вид (рис. 3.17):

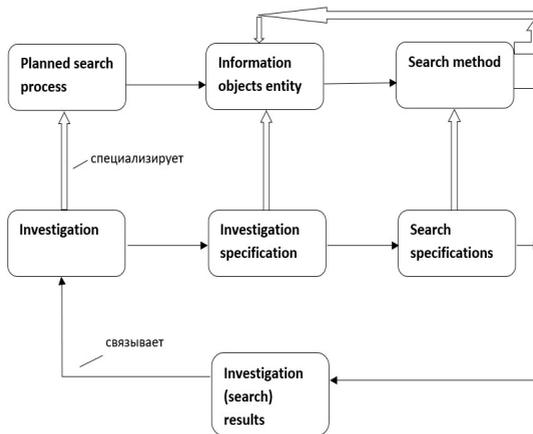


Рис. 3.17. Система онтологических паттернов содержания

К базовым онтологическим паттернам содержания относятся «Информационная сущность объектов» (*Information objects entity*) и «Запланированный процесс поиска» (*Planned search process*). Эти паттерны являются фрагментами IAO и основой для построения остальных.

Построение онтологической структуры МПЗ путем использования множества отдельных паттернов содержания позволяет упрощать

стить ее использование и обеспечить высокий уровень качества онтологического моделирования, за счет операций с ограниченной понятийной системой конкретной функциональной области, в рамках которой решается данная задача

3.3. Комплексный подход к решению задачи классификации знаний

Для решения задачи классификации знаний в глобальном информационном пространстве с применением семантических векторов используем метод комбинирования гиперповерхностных классификаторов (*Hyper Surface Classifier – HSC*) с помощью коалиции интеллектуальных агентов. Коалиция агентов имитируют процесс рассуждения, моделируя процедуру классификации информации, проводимую экспертами [56].

В процессе тренировки нейронной сети создается модель гиперповерхности, которая впоследствии используется для классификации информации, представленной в виде векторных признаков (семантический вектор), которые являются атрибутами объекта. При тренировке репрезентативная выборка и предварительные знания о предметной области используются для определения структуры классификатора и настройки его параметров. По окончании тренировки полученный классификатор проверяется на тестовых данных из следующего набора.

Теоретической основой служит теорема Жордана о замкнутой кривой, и результат классификации зависит от чётности или нечётности числа пересечений. Отметим, что использование топологической теоремы Жордана о замкнутой кривой в универсальном методе классификации HSC, позволяет решать нелинейную задачу классификации в распределенном информационном пространстве (онтологии) без необходимости проведения процедуры отображения семантических векторов в пространство (онтологию) большей размерности, и, как следствие, без использования функции ядра.

Рассмотрим теорему Жордана о кривой. Пусть X – ограниченное множество в n -мерном пространстве R_n . Если X гомеоморфно сфере в $n-1$ -мерном пространстве, тогда его дополнение $R_n \setminus X$ имеет две связанных компоненты, одна из которых называется внутренней, а другая – внешней [56]. Тогда теорема о классификации приобретает следующий вид. Для любой точки $x \in R_n \setminus X$, если x лежит внутри множества X , число кручения, то есть количество пересечений

между любым радиусом от x до X является нечетным (рис. 3.18). А если x не находится в X , тогда количество пересечений между любым радиусом от x до X является четным (рис 3.19) [56].

Поэтому одной из главных задач является построение разделительной гиперповерхности. Ключевой особенностью гиперповерхностных классификаторов является их способность создавать сложные области принятия решений на основе узлов, создающих гиперповерхностные границы во входном пространстве. С помощью координат узлов вычисляется нелинейная функция взвешенной суммы входных данных. Обычно используется сигмовидная функция и полиномы высоких степеней. Такие классификаторы обладают низкой вычислительной сложностью и потребляют мало памяти при классификации данных. Однако недостатком является сложность алгоритмов обучения (многослойный персептрон, сети высоких порядков, биоинспирированные подходы, бинарные древовидные классификаторы и т.д.) и время, необходимое для обучения.

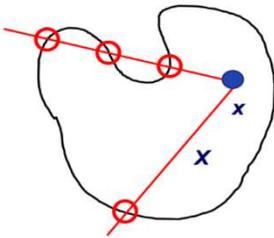


Рис. 3.18. Пример нечетного значения чисел кручения

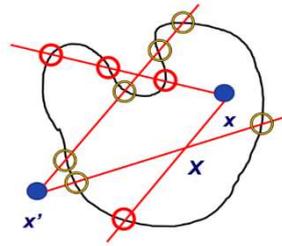


Рис. 3.19. Пример нечетного и четного значений чисел кручения

Основываясь на теореме Жордана о кривой [56], представим метод классификации знаний на основе гиперповерхностных классификаторов HSC и теоремы Жордана о замкнутой кривой в виде структурной схемы (рис. 3.20).

Для комбинирования и определения границ гиперповерхностных классификаторов применим коалиции интеллектуальных агентов, механизм поиска решений которых основан на методах биоинспирированного поиска. Использование многоагентных технологий обеспечивает непревзойденный уровень параллелизма при имитации процесса рассуждения экспертной группы.

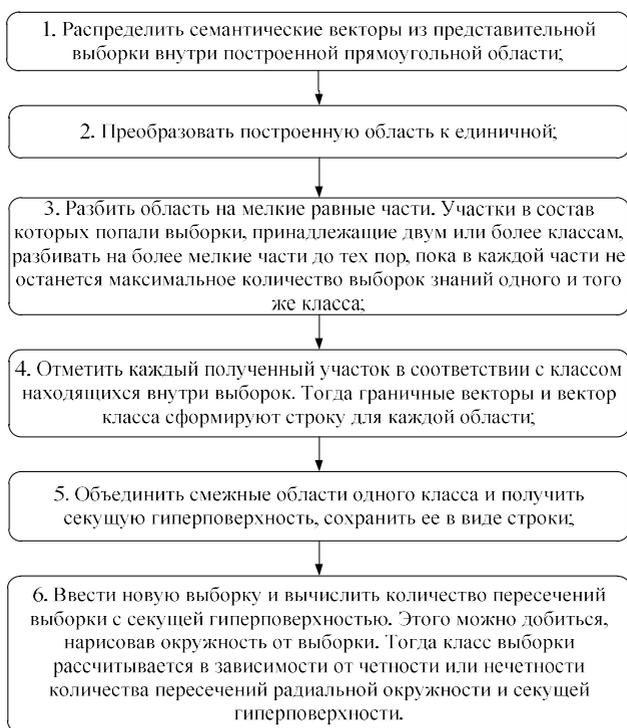


Рис. 3.20. Структурная схема метода классификации знаний

Каждый классификатор представлен множеством агентов с определенными абстрактными атрибутами. Предлагаемый метод классификации данных задействует два типа агентов: агентов обучения классификатора (АОК) и агентов комбинирования классификаторов (АКК). [56]. В качестве отдельного субъекта поиска соответствий между моделями пользователей, референтных групп и процессов обучения введен агент-координатор (АК), его основной функцией является последующее построение моделей обучения и классификации.

Агент обучения классификатора проверяет построенную модель классификации на основе встроенного биоинспирированного алгоритма и определяет наличие элементов, принадлежащих разным классам, но попавших в одну область, полученную гиперплоскостным делением пространства поиска.

Агент комбинирования классификатора объединяет результаты проверок, проведенных агентами обучения классификатора, вносит коррективы в анализируемые модели обучения и классификации путем дальнейшего деления гиперплоскостей и определяет возможность получения обобщенного вывода. Модель классификации знаний на основе построения оптимальных разделяющих гиперповерхностей представлена на рисунке 3.21.

Каждый агент обучения классификатора, работая в пределах назначенной части пространства решения, создает собственную модель классификации, учитывая заданные значимые для системы признаки, и предсказывает наличие проблемных областей. Это завершает этап предсказания классификации, после которого агент комбинирования классификатора производит разделение указанных областей, предсказанных агентами обучения классификатора.

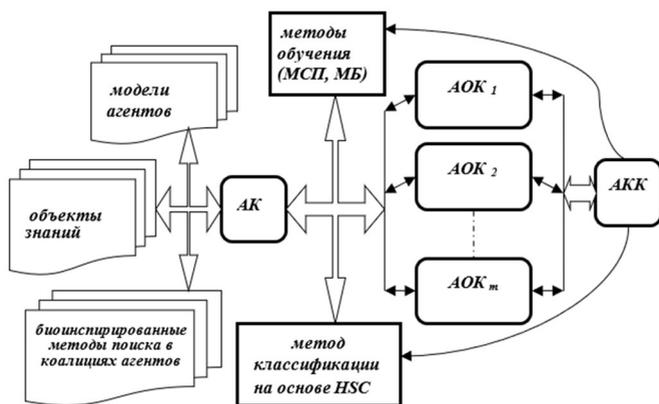


Рис. 3.21. Модель классификации знаний на основе построения оптимальных разделяющих гиперплоскостей

Агенты обучения классификатора анализируют особенности и присваивают определенный ярлык экземплярам, не соответствующим предварительной классификации, и отправляют полученные результаты с меткой агентам комбинирования классификатора. Агент комбинирования классификатора меняет статус класса и выполняет необходимые разделения проблемных областей.

Для обработки информационных ресурсов большой размерности используется комбинированное решение, которое заключается

в группировании множественных системно значимых признаков и формировании подмножеств элементов знания на основе заданных правил. Далее производится обработка классификатора для каждого сформированного подмножества. Общее решение представляется объединением результатов классификации. Представим описанные действия в виде структурных схем: алгоритма агента обучения классификатора (рис. 3.22) и алгоритма агента комбинирования классификатора (рис. 3.23).

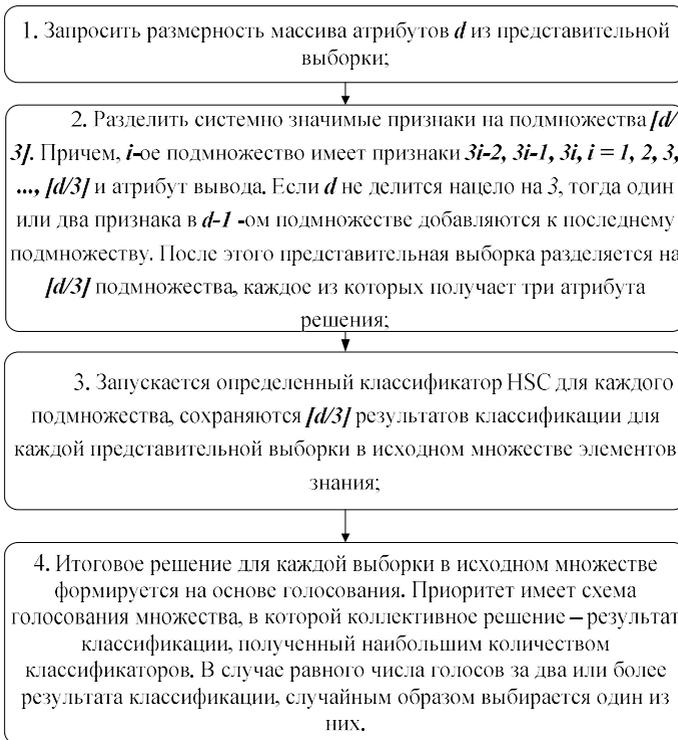


Рис. 3.22. Структурная схема алгоритма агента обучения классификатора

Эти процедуры повторяются итеративно, изменяя формы гиперповерхностей в информационном пространстве, пока не будут получены устойчивые классы. Агент объединения классификатора, таким образом, превосходит возможности отдельных классифика-

торов. Этот подход продемонстрировал высокую точность классификации без дополнительного обучения групп классификаторов за счет получения решений путем деления значимых для системы признаков, а не разделения исходного множества репрезентативных выборок. Предпочтение отдается вертикальным комбинациям, поскольку в этом случае можно избежать несовместимости размеров. Размер полученного подмножества совпадает с размером исходного множества репрезентативных выборок.

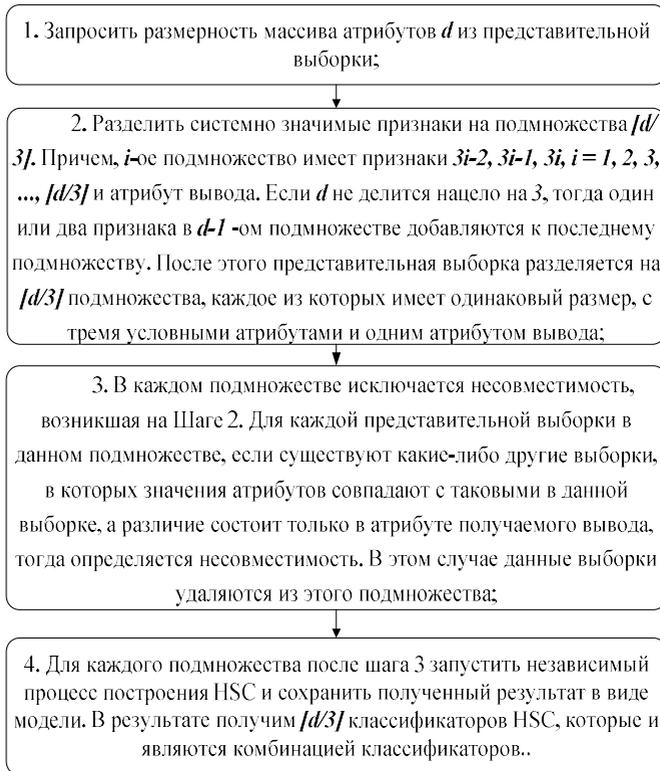


Рис. 3.23. Структурная схема алгоритма агента комбинирования классификатора

Комбинация *HSC* проводит классификацию знаний в условиях большой размерности, это стало возможным благодаря реализации процедур анализа множества сечений плоскостей представительных обучающих и шаблонных проверочных выборок. Необходимо

отметить, что комбинация классификаторов более устойчива к возникновению ошибок по сравнению с вариантом применения единичного классификатора [56].

Использование процедур голосования агентов в методах комбинирования *HSC* упрощает построение моделей рассуждений, так как не требует предварительного обучения [57]. Для улучшения работы агента комбинирования классификатора, на обучающем наборе каждому агенту обучения присваиваются индивидуальные веса. Значения этих весов определяются на основе применения генетического алгоритма в процессе предварительной обработки данных. Затем определяется квазиоптимальное значение целевой функции после обработки результатов голосований всех классификаторов. Эта функция помогает обнаруживать ошибки и рассчитывать частоту их возникновения. Агент комбинирования классификатора определяет принадлежность представительного тестового образца к определенному классу C_j , если число обучающих классификаторов, поддерживающих это решение, превышает число классификаторов обучающих, указывающих на другой класс.

Модели комбинирования гиперповерхностных классификаторов (*Combination Hyper Surface Classifiers Models – CHSCM*) на основе многоагентных структур демонстрируют высокую эффективность в решении задач получения и управления знаниями. Интеллектуальные системы, использующие эти модели, имеют открытую динамичную структуру, гетерогенные составляющие которой заранее не определены и могут изменяться. Работу этих систем обеспечивают коалиции интеллектуальных агентов, основная функция которых – разделение полученных областей классов. Для координации действий внутри коалиции используются популяционные биоинспирированные алгоритмы и общепринятые языки, содержащие протоколы взаимодействия между агентами.

Опишем способ построения объединенных рассуждений интеллектуальных агентов с использованием семантического вектора в качестве набора характеристик. Множество обрабатываемых компонентов представим, как коалицию АОК, а процесс создания рассуждений в интеллектуальной системе будет закреплен за АКК. Создадим двухуровневую структуру, верхний уровень которой будет представлять узел АКК, а нижний – коалицию АОК. Соответствие параметров

процесса получения и управления знаниями установленным характеристикам будет оказывать прямое влияние на разделение управляющих функций между интеллектуальными агентами. Все оперативные операции со знаниями в рамках указанного класса выполняются коалицией АОК. АКК выполняет объединяющую роль, учитывая и комбинируя данные каждого АОК и формируя в результате квазиоптимальный асинхронный путь получения знаний.

Введем основные элементы информационной модели: h_n – вектор признаков (семантический вектор) формируемых состояний множества АОК; m_n – вектор значений информационных сигналов, получаемых АКК от АОК; q_n – вектор обратной связи (координирующая информация) от АКК к АОК; b_p – вектор внешних воздействий; $n = \overline{1, N}$; $p = \overline{1, (N + 1)}$, где N – количество АОК в коалиции.

Зададим параметры всех АОК векторной функцией Ψ_n , состоящей из r частных характеристик состояния рассматриваемого агента. Опишем данную векторную функцию Ψ_n следующим выражением:

$$\Psi_n(b_n, q_n, m_n, h_n) = \langle \Psi_{n_1}, \dots, \Psi_{n_i} \rangle, i = \overline{1, 2^r}. \quad (3.13)$$

На основе предложенных ранее когнитивных моделей агентов, соответствующих свойствам стилей учения, примем $r = 4$. Целевой функцией данного векторного показателя станет достижение максимума:

$$\Psi_n(b_n, q_n, m_n, h_n) = \langle \Psi_{n_1}, \dots, \Psi_{n_i} \rangle \rightarrow \max, \quad (3.14)$$

что предполагает максимизацию 2^r частных характеристик $\Psi_{n_i}, i = \overline{1, 2^r}$.

Систему отношений агентов, представим в виде ориентированного графа G_{agents} , заданного кортежом $\langle \beta, W, b_p, q_n, m_n, h_n \rangle$ (рис. 3.24). Здесь вершины β и W моделируют абстрактные значения воздействия внешней среды и параметров внутреннего состояния АКК соответственно.

Итоговый вариант выражения описания системно важных отношений на группе интеллектуальных агентов будет представлен в виде функции. При этом цели АОК будут направлены на достижение максимального значения этого показателя:

$$\Phi_n(\Psi_n(b_n, q_n, m_n, h_n)) = \Phi_n(\Psi_{n_1}, \dots, \Psi_{n_i}) \rightarrow \max. \quad (3.15)$$

Выбор управляющего воздействия $q = \langle q_1, q_2, \dots, q_N \rangle \in Q$ – основная функция АКК, где Q – дискретное пространство. Координирующими воздействиями элемента верхнего уровня (АКК) на

элементы нижнего уровня (АОК) являются векторы q_n , $n = \overline{1, N}$. Вектор $h = \langle h_1, h_2, \dots, h_N \rangle$ отражает текущее состояние всей исследуемой интеллектуальной информационной системы. Зададим реакцию АОК на координирующее воздействие АКК в виде отображения $F_n(q_n)$ для каждого значения q_n . В построенной таким образом иерархической структуре передаваемая на верхний уровень информация агрегируется, то есть АКК учитывает не сами параметры h_n, f_n , а только некоторые функции от них.

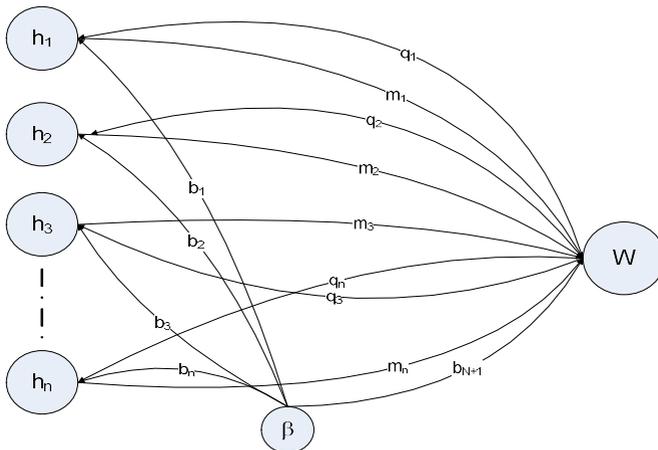


Рис. 3.24. Графовая модель отношений агентов обучения классификатора и агента комбинирования классификатора

Моделирование упорядоченного набора объединенных рассуждений нацелено на достижение подобия эффекта инсайт-озарения как важного компонента распространения знаний и усиления интеллекта в формируемой интеллектуальной многоагентной среде [58]. Полученные надежные выводы указывают на увеличение уровня компетентности коалиции интеллектуальных агентов и укрепление свойств самообучения системы приобретения и управления знаниями. На базе предложенной модели информации опишем процесс согласования выводов в дискретном наборе консолидированных рассуждений коалиции интеллектуальных агентов обучения и комбинирования классификатора.

Предварительная информация о комплекте системно значимых характеристик оцениваемого объекта передается каждому АОК после того, как объект проходит ряд специальных испытаний. Функция АОК

состоит в определении значений: верно - 1, неверно - 0, в соответствии с полученными репрезентативными выборками предварительной информации, определяющей уровень объекта по набору ключевых характеристик, связанных с стилями учения и способами мышления. Результат оценивания фиксируется в определенной ячейке. Промежуточное логическое заключение представлено набором нулей и единиц, итоговый вариант принимаемого решения формируется на основе выполнения мультипликативной сверки этого предварительного набора, где единица обозначает наличие признака, а ноль – как его отсутствие. Вариации комбинаций кодирования решений по определению откликов, полученных от коалиции АОК, сохраняются в памяти АКК, выполняющего роль оценщика. Поступление на вход неизвестного события представляет собой исключительный случай, требующий использования внешнего управляющего воздействия для получения заключения о соответствии или несоответствии имеющейся кодировки решения.

Определим эффективность рассуждений АКК как $P = S/C$, где C – полученные АКК репрезентативные выборки от АОК за некоторое определенное время, а S – среднее значение количества сгенерированных выводов по построению траекторий приобретения и управления знаниями. В случае возникновения неизвестного события и отсутствия у АКК готового экспертного решения на базе знаний по системно значимым признакам из репрезентативной выборки выбор пути получения и управления знаниями происходит на основе внешнего управляющего влияния. Уже на следующем этапе работы интеллектуальной системы полученная таким образом траектория попадает в банк прецедентов АКК.

Таким образом, разрешение описанных частных вопросов коалицией АОК и последующее классифицирование, проводимое АКК, на основании установленных информационных процессов составляет основу процесса конструирования рассуждений и формирования окончательного вывода о траектории получения и управления знаниями. Здесь работа коалиции АОК характеризуется параллелизмом исполняемых действий. Функция АКК заключается в осуществлении координационного управления.

Данная модель позволяет избежать увеличения размерности пространства при решении задачи классификации, как это происходит, например, в методе опорных векторов при введении нелинейной функции ядра.

Также в данном подходе предложенный метод построения консолидированных рассуждений интеллектуальных агентов на основе применения семантического вектора в качестве вектора признаков, позволяет распараллеливать решения сложных задач приобретения и управления знаниями.

3.4. Событийная имитационная модель рассуждений коалиций агентов при решении задачи классификации знаний

Рассмотрим внутреннюю значимую взаимосвязь между агентами в рамках процесса формирования рассуждений для решения задачи классификации знаний, используя имитационную модель, созданную с использованием аппарата сетей Петри. Эта модель будет отображать комбинации имеющихся значимых характеристик процесса классификации, которые представляют собой события. В результате интеллектуальная система будет реагировать, исходя из своих собственных параметров и управляемых входных данных.

Задача агентов-классификаторов заключается в том, чтобы опознать событие по представленной комбинации характеристик, что в дальнейшем позволит определить необходимые параметры системы и управляющие воздействия. Однако, экстраполяция набора параметров для эффективной работы интеллектуальных информационных систем остается одной из самых сложных задач, и определение достоверности такого решения также может быть проблематичным.

В связи с этим, предлагается использовать сети Петри для моделирования, где идентификация событий происходит в трех основных категориях: входные параметры реализуемого процесса классификации, соответствующие параметры системы и необходимые управляющие воздействия. Моделирование различных вариантов поведения интеллектуальной системы достигается путем выполнения цепочки связанных событий в виде потока запросов, проходящих через сеть. Анализ результатов моделирования позволит оценить эффективность различных моделей поведения системы и определить наиболее подходящую комбинацию входных параметров для достижения оптимального результата.

Сеть Петри представляет собой кортеж длины четыре $\langle P, T, I, O \rangle$, где P и T – два типа вершин, моделирующих множества позиций и переходов, I и O – два типа ребер, моделирующих множества входных и выходных функций. Позициям P соответствуют вершины, изображаемые окружностями, а переходам T – вершины,

графически представленные утолщенными линиями; функциям I соответствуют ребра, построенные от позиций к переходам, а функциям O – ребра, построенные от переходов к позициям [59].

Статические элементы сети представлены позициями, переходами и ребрами. Мы также вводим динамические маркеры, которые размещаются внутри позиций. Распределение и перемещение этих маркеров между позициями сети представляет собой процесс совершения событий. Условия, необходимые для осуществления каждого события, проверяются на уровне переходов, и при выполнении этих условий событие происходит мгновенно. Весь смоделированный процесс формируется из последовательности событий, происходящих в сети [59].

Рассмотрим пример, представленный на рисунке 3.25, который демонстрирует параллельные процессы формирования последовательности рассуждений в ходе решения задачи классификации с использованием имитационной модели и с учетом условий достижимости.

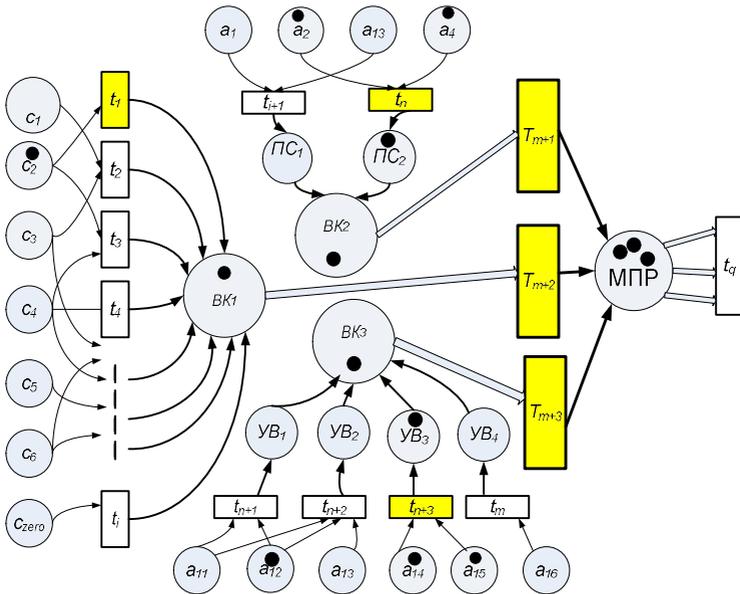


Рис. 3.25. Имитационная модель рассуждений с выполнением условия достижимости

Для начала смоделированного процесса мы используем следующие наборы условий:

- C – множество входных параметров задачи классификации знаний;
- A – множество параметров системы;
- A_1 – множество управляющих воздействий.

Выберем для анализа следующий случайный абстрактный вариант количественного состава параметров множеств начальных условий. $C = \{c_1, c_2, c_3, c_4, c_5, c_6, c_{zero}\}$, где c_1-c_6 – входные параметры задачи классификации знаний, c_{zero} – вершина, наличие маркера в которой указывает на ситуацию отсутствия анализируемых альтернатив комбинаций системно значимых признаков. Для полного изучения всех возможных сочетаний компонентов исследуемых параметров потребуются создать 2^6 различных переходов. Важно отметить, что порядок обработки переходов должен определяться в зависимости от числа входящих в переход дуг, и чем больше дуг входит в переход, тем выше его приоритет. Этот подход поможет разрешить возможные конфликты в пользу событий, которые включают в себя большее количество выделенных параметров рассматриваемого информационного процесса.

Тогда, например, если имеется комбинация характеристик, необходимых для открытия перехода t_i , $i = \overline{1, 2^6}$, агент классификации получит информацию о данных параметрах исследуемого процесса, а в вершине классификатора BK_1 будет размещен маркер, открывающий переход t_{m+2} для передачи информации об исследуемом процессе в модуль построения рассуждений (МПР).

В то же время, на результат построения рассуждений будут воздействовать комбинации маркеров в вершинах множества внутренних параметров системы $A = \{a_1, a_2, a_3, a_4\}$ и множества управляющих воздействий $A_1 = \{a_{11}, a_{12}, a_{13}, a_{14}, a_{15}, a_{16}\}$. В указанных множествах возможно появление недопустимых комбинаций. Допустимые наборы параметров системы (ПС) выражены наличием маркеров, обеспечивающих открытие переходов t_n , $n = \overline{i+1, i+2}$ к вершинам $ПС_1$ или $ПС_2$. Эта информация активизирует вершину классификатора BK_2 , открывающую переход t_{m+1} для доступа к модулю принятия решения.

Аналогичным образом комбинации маркеров в вершинах множества $A_1 = \{a_{11}, a_{12}, a_{13}, a_{14}, a_{15}, a_{16}\}$ задают допустимые наборы управляющих воздействий (УВ), что моделируется передачей маркеров через переходы t_m , $m = \overline{n+1, n+4}$ к вершинам $УВ_1$, $УВ_2$,

$УВ_3, УВ_4$. Эта информация активизирует вершину классификатора $ВК_3$, открывающую переход t_{m+3} для доступа к МПР.

Представим детализацию работы имитационной модели, проиллюстрированной на рисунке 3.25. Исходная маркировка необходима для определения следующих показателей классификации: множество активных собственных параметров интеллектуальной системы (переход t_n , вершина $ПС_2$); множество текущих управляющих воздействий (переход t_{n+3} , вершина $УВ_3$); характеристику исследуемого информационного процесса (переход t_1 вершина $ВК_1$). После открытия переходов $T_{m+1}, T_{m+2}, T_{m+3}$, в полученных условиях достижимости всех вершин классификаторов $ВК_1, ВК_2, ВК_3$, модель позволяет получить общий вывод проведенных рассуждений в модуле принятия решений.

Работа этой сети основана на перемещении трех маркеров к вершине, обозначенной как МПР. Возможность активации виртуального перехода t_q указывает на выполнение обязательного условия достижимости, которое должно выполняться для корректно построенной сети.

Рассмотрим, как нарушение этого условия может повлиять на работу сети, на примере маркировки начальных условий, представленных на рисунке 3.26.

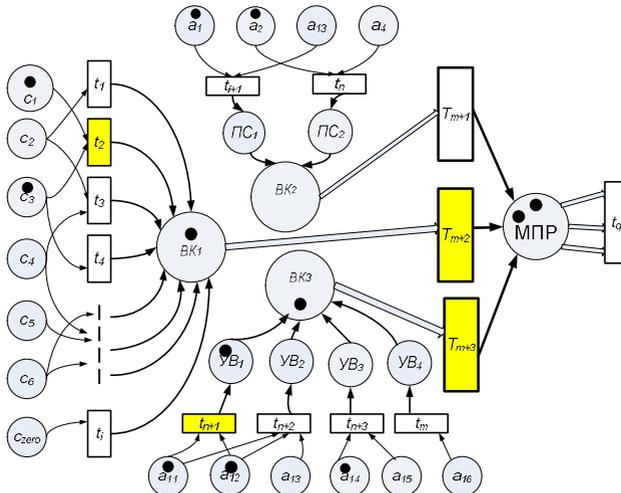


Рис. 3.26. Имитационная модель рассуждений с нарушением условия достижимости

Представленная исходная маркировка в ходе работы имитационной модели формирует: комбинацию управляющих воздействий

(переход t_{n+1} , вершина VB_1); комбинацию характеристик исследуемого процесса (переход t_2 , вершина BK_1). Недоступной в данном случае является вершина классификатора BK_2 , это происходит из-за отсутствия комбинации параметров системы, соответствующей любому из введенных шаблонов.

В результате работы этой сети в таких условиях только два маркера перемещаются к вершине МПР. Поэтому виртуальный переход t_q не активируется, и общий вывод (решение) получить невозможно. В этом случае корректировка начальных условий выполняется экспертом на основе анализа дополнительной информации, которая необходима для оценки текущей ситуации.

Изученная имитационная модель, использующая агентов-классификаторов, применяет интегрированный метод классификации знаний и может быть использована для решения других задач, связанных с приобретением и управлением знаниями, на стыке различных областей знаний. Комплексное исследование различных классов системно значимых признаков позволяет в режиме реального времени анализировать динамику изменений в системе с целью корректировки управляемых воздействий [59].

Рассмотрим, как работает предложенная модель, на примере решения задачи классификации (рис. 3.27).

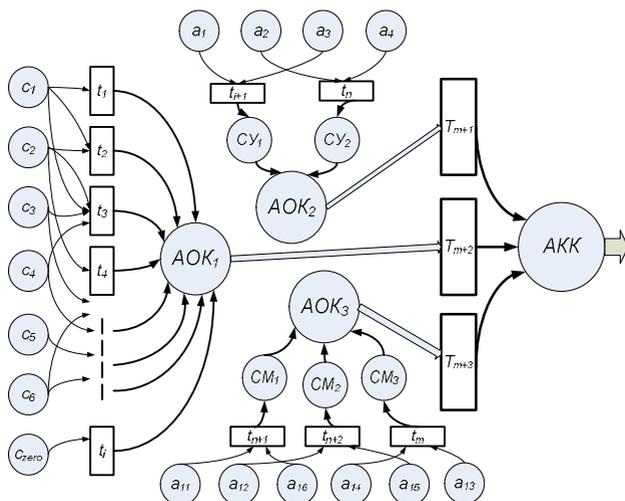


Рис. 3.27. Имитационная модель классификации составляющих компетентности и соответствующих когнитивных свойств

Иллюстрация позволяет учитывать составляющие компетентности и соответствующие характеристики личности, основанные на наборе требуемых компетенций эксперта в контексте задачи, а также когнитивные свойства агентов, основанные на стилях учения и способах мышления.

Анализируя компетентность с точки зрения задач приобретения и управления знаниями, разобьём ее на следующие составляющие, представленные на рисунке 3.28.

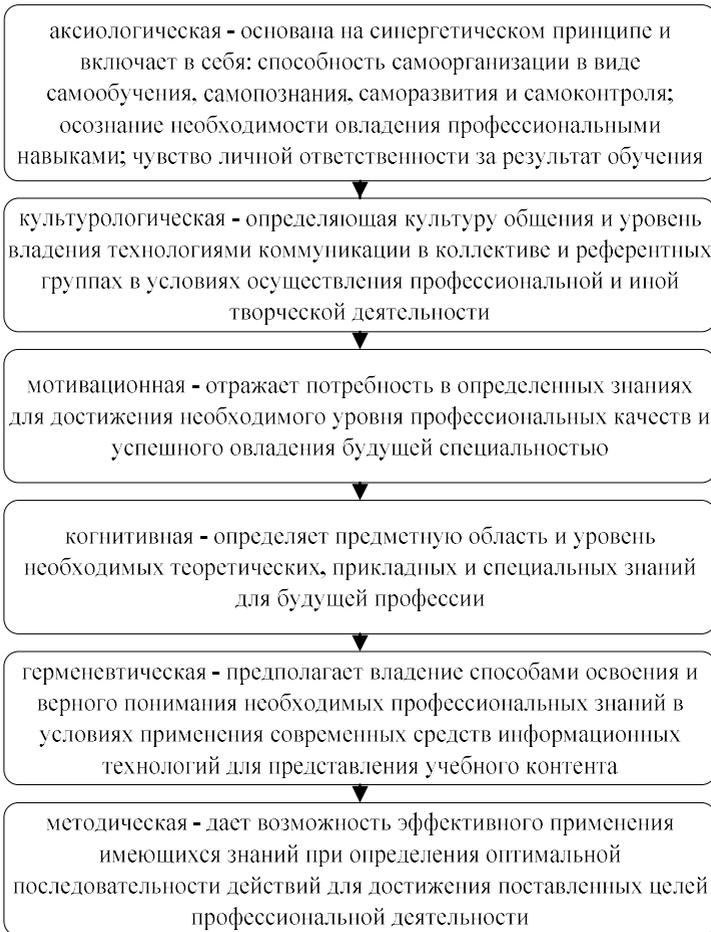


Рис. 3.28. Составляющие компетентности

Введем следующие три множества параметров:

- C – множество значимых признаков решаемой задачи;
- A – множество когнитивных свойств интеллектуальных агентов, задающих стиль учения эксперта, в соответствии с моделями Колба, Хани-Мамфорда и Грегорса;
- A_1 – множество когнитивных свойств интеллектуальных агентов, задающих способ мышления эксперта, в соответствии с моделью Ройса [60].

Множество $C = \{c_1, c_2, c_3, c_4, c_5, c_6, c_{zero}\}$, где c_1 – аксиологическая составляющая компетентности; c_2 – культурологическая составляющая компетентности; c_3 – мотивационная составляющая компетентности; c_4 – когнитивная составляющая компетентности; c_5 – герменевтическая составляющая компетентности; c_6 – методическая составляющая компетентности; c_{zero} – эта вершина необходима гипотетически для моделирования ситуации полного отсутствия выделенных составляющих компетентности.

Например, в случае недостаточности априорной информации, маркер в ней появится только в том случае, если будут отсутствовать маркеры во всех остальных вершинах множества C .

Для учета всех возможных сочетаний составляющих компетентности потребуется создать 2^6 различных переходов, плюс еще один переход для ситуации, когда все составляющие компетентности отсутствуют c_{zero} . Однако, при моделировании этот переход можно не учитывать, поскольку полное отсутствие составляющих компетентности является исключительным случаем. Обслуживание переходов происходит в порядке увеличения приоритета в зависимости от того, сколько дуг ведет к переходу. Это важно для разрешения возможных конфликтов в пользу событий, описывающих наличие большего количества выделенных составляющих компетентности.

Таким образом, открывшись, переход $t_i, i = \overline{1, 2^6}$ отправит информацию о наличии составляющих компетентности в вершину агента обучения классификатора AOK_i , наличие метки в которой позволит открыть переход t_{AOK_i} и передать полученные сведения в вершину агента комбинирования классификатора AKK .

С другой стороны, комбинация меток в вершинах множества $A = \{a_1, a_2, a_3, a_4\}$, описывающих свойства «слабых» интеллектуальных агентов, где a_1 – автономность (autonomy); a_2 – общественное поведение (social ability); a_3 – реактивность (reactivity); a_4 – активность (proactivity), позволяет определить стиль учения, посредством передачи

маркера через переходы t_n , $n = \overline{i+1, i+2}$ к вершинам CV_1 или CV_2 , моделирующих автономно-реактивный и коммуникативно-активный стили учения соответственно. В дальнейшем, эта информация попадет к агенту обучения классификатора AOK_2 и далее к агенту комбинирования классификатора AKK .

Подобным образом, комбинация меток в вершинах множества $A_I = \{a_{11}, a_{12}, a_{13}, a_{14}, a_{15}, a_{16}\}$, описывающих свойства «сильных» интеллектуальных агентов, где a_{11} – знание (knowledge); a_{12} – убеждения (beliefs); a_{13} – желания (desires); a_{14} – намерения (intentions); a_{15} – цели (goals); a_{16} – обязательства (commitments), позволяет определить способ мышления, посредством передачи маркера через переходы t_m , $m = \overline{n+1, n+3}$ к вершинам CM_1 , CM_2 или CM_3 моделирующих целенаправленно-убежденный, компетентно-обязательный и мотивационно-намеренный способы мышления соответственно. В дальнейшем эта информация попадет к агенту обучения классификатора AOK_3 и далее к агенту комбинирования классификатора AKK .

Предложенная и описанная имитационная модель для моделирования рассуждений коалиций агентов в процессе решения задачи классификации знаний отличается от других аналогов тем, что она позволяет анализировать различные комбинации наборов характеристик и признаков исследуемых процессов в уникальной форме. Основное преимущество этой модели заключается в ее комплексности и масштабности, позволяя учитывать множество параметров, включая условия задачи, свойства агентов, параметры системы и управляемые воздействия, включая воздействия внешней среды.

Таким образом, в 3-ей главе описана концепция, предложены базовые принципы и стратегия приобретения и управления знаниями, позволяющие увеличить объемную долю семантически обработанных знаний в глобальном информационном пространстве и интенсифицировать их совершенствование и применение. Построена комплексная модель интеллектуального агента, позволяющая учесть возможность реализации различных режимов поведения при одинаковом наборе функций агента. Предложен новый подход определения и усиления когнитивных свойств интеллектуальных агентов. На основе предложенных когнитивных свойств построена событийная имитационная модель рассуждений коалиций агентов при решении задачи классификации знаний. Разработан комплексный подход решения задачи классификации на основе применения оптимальных разделяющих гиперповерхностей.

ГЛАВА 4. МОДЕЛИ И МЕТОДЫ ПОСТРОЕНИЯ ИНФОРМАЦИОННЫХ ПРОЦЕССОВ ПРИБРЕТЕНИЯ ЗНАНИЙ

4.1. Метод построения траектории приобретения знаний на основе графовой модели онтологии

Основным требованием к интеллектуальным информационным системам приобретения и управления знаниями, используемым в междисциплинарном пространстве знаний, является способность адаптироваться к конкретным задачам поиска, рассматриваемому контексту и индивидуальным характеристикам пользователя и эксперта. Данная задача решается за счет организации поисковых процедур на основе междисциплинарной системы отношений между элементами знания, построенной на множестве функциональных областей. В этом случае межпонятийные отношения выражаются в графовых моделях дугами-ссылками вершин-понятий (концептов) онтологии [5, 6].

Семантическая сеть служит основой для определения необходимых компонентов знания в зависимости от условий поиска. Этот процесс включает в себя использование модели, которая начинает работу с метазнания - концепции, основанной на части междисциплинарных связей между различными функциональными областями, с определенным уровнем глубины и шириной охвата поиска. Затем мы анализируем связанные с этой концепцией понятия, чтобы определить список элементов знания. Таким образом, адаптация процесса поиска происходит через выбор пути в семантической сети и принятие решения о том, какую концепцию использовать в каждой точке сети [61]. *Формальный алгоритм* создания подобных траекторий приобретения знания представим в виде И/ИЛИ графовой модели.

Обсудим входные данные для алгоритма, который создает траекторию обретения знаний, используя графическую модель. Для задания исходного уровня обработки и накопления знаний по конкретному запросу используется множество K_{now} . Относительное целевое множество K_{goal} характеризует необходимый уровень. Траектория между K_{now} и K_{goal} имеет ряд промежуточных звеньев, которые характеризуются синтезируемым множеством D_{tr} , содержащим в себе описание обработанных элементов знания.

Предложим следующие основные правила формирования перечисленных множеств:

- *правило 1* – понятия, входящие в множество K_{goal} , являются выходными концептами определенных элементов знания, содержащих в себе инструктирующую (ценную) информацию в соответствии с имеющимся запросом;

- *правило 2* – любое входное понятие либо входит в число выходных концептов множества D_{tr} , либо относится к множеству K_{low} ;

- *правило 3* – выявление свойств и отношений между понятиями проводится таким образом, чтобы входные концепты формализуемых онтологий были упорядочены и однозначно определялись до их использования при построении траекторий извлечения знаний;

- *правило 4* – эффективность траектории извлечения знаний оценивается аддитивной целевой функцией на основе исследования имитационной модели процесса поиска.

Модель задачи формирования траектории приобретения знаний представим в виде И/ИЛИ-графа $G = \langle K, C, D, O \rangle$ (рис. 4.1).

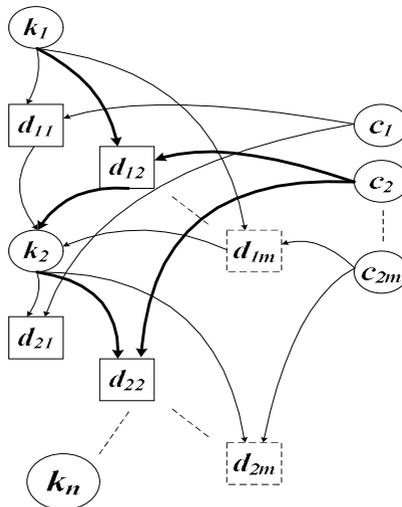


Рис. 4.1. Графовая модель задачи построения траектории приобретения знаний

В представленной модели: K – множество ИЛИ-вершин соответствующих одному из концептов онтологии, отражающих уровень

метазнания; C – множество ИЛИ-вершин соответствующих одному из концептов онтологии, отражающих особенности запроса и характеристики пользователя; D – множество И-вершин соответствующих одному из концептов онтологии, отражающих элементы знания, соответствующие полученной траектории; O – множество дуг, соответствующих отношениям $K_i \& C_j = D_{ij}$.

Представим подробную структурную схему алгоритма построения траектории приобретения знаний (рис. 4.2).

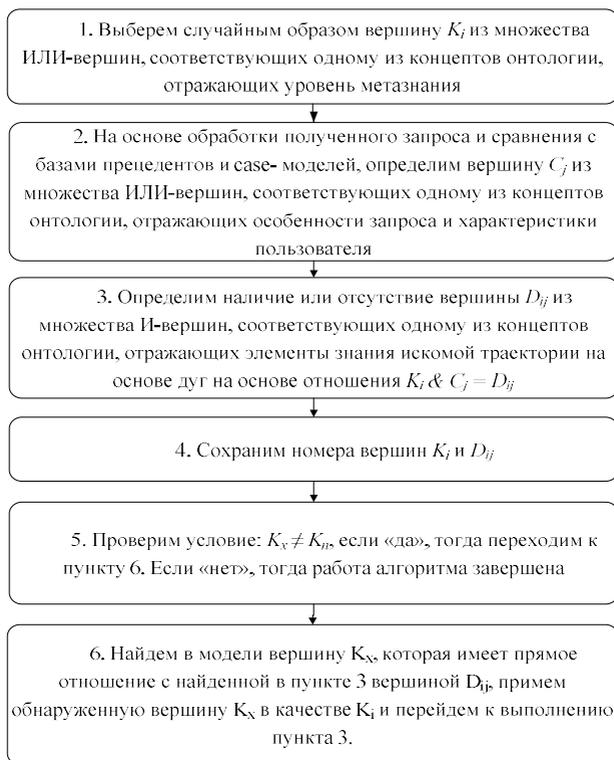


Рис. 4.2. Структурная схема алгоритма построения траектории приобретения знаний

Заметим, что сохраненное в процессе работы алгоритма множество номеров найденных вершин является искомой траекторией приобретения знаний.

4.2. Онтологическая модель и модифицированный метод силовой релаксации для решения задачи интеграции знаний

Рассмотрим построение онтологической модели интеграции знаний на основе принципа силовой релаксации, как одной из основ организации сообществ интеллектуальных агентов, функционирующих в междисциплинарном пространстве знаний (МПЗ). Модель среды интеграции основана на принципах агентности и информационного процесса как основы приобретения и управления знаниями. В основе предложенной модели находится разделение инвариантных аспектов оценки обстановки агентом, как многоуровневой архитектуры семантических связей фильтров знаний с функциональными областями и пассивными сущностями (объектами), и зависимых от предметной области знаний, описывающих среду функционирования и целевое назначение интеллектуального агента (ИА). Интеллектуальный агент – это субъект с самостоятельным, целенаправленным поведением, действующий в сложной, динамической, многоагентной среде, состоящей из распределенных и разнообразных знаний. Этот агент действует, опираясь на комплексную модель поведения.

Введем некоторые ключевые понятия, необходимые для создания такой всеобъемлющей, многоуровневой онтологической модели в междисциплинарном пространстве знаний: активными сущностями являются фильтры знаний (акторы), преобразующие информационные процессы; пассивные сущности (объекты), имеющие собственные характеристики (атрибуты).

Таким образом, на верхнем уровне описываемой архитектуры понятия разделяются на: *акторы* $[A_n]$ – фильтры знаний, которые представляют собой активный элемент, *функциональные области* $[F_m]$, представляющие определенный информационный процесс и *объекты* $[O_k]$, представляющие собой пассивные сущности и обладающие собственными атрибутами [62].

Опишем *модифицированный метод силовой релаксации для решения задачи интеграции знаний*. Построим информационную модель интеграции знаний в виде абстрактной многоуровневой онтологической архитектуры МПЗ (рис. 4.3).

Здесь мы используем принцип силовой релаксации для выявления стабильных междисциплинарных взаимосвязей. Для этого введем понятия *многоуровневой мощности окрестности* (это локальная степень связности одного объекта с другими на первом уровне

и одной функциональной области с другими – на втором) и *многоуровневой глубины поиска* (это допустимое количество объектов на первом уровне (макро- уровне знаний) и функциональных областей – на втором (мета- уровне знаний) в последовательной цепочке анализируемых семантических отношений).

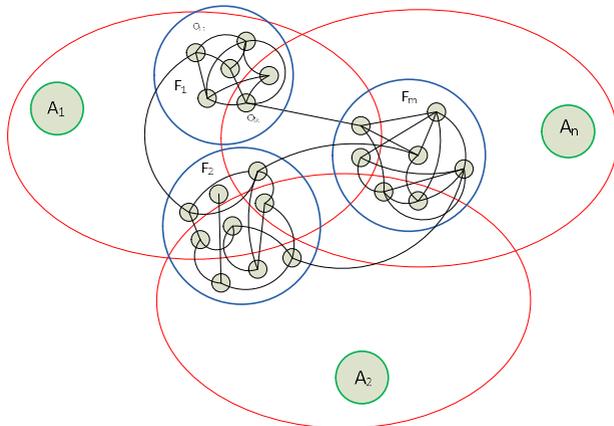


Рис. 4.3. Онтологическая модель междисциплинарного пространства знаний

При этом каждая связь на вторичном уровне в цепи является весомой и имеет значение, равное количеству обнаруженных взаимосвязей между предметными областями.

Опишем данный метод более подробно. Сначала определяется элемент структуры второго уровня (функциональная область), имеющий наибольшее значение параметра мощности окрестности, который назначается «центроидом» (рис. 4.4).

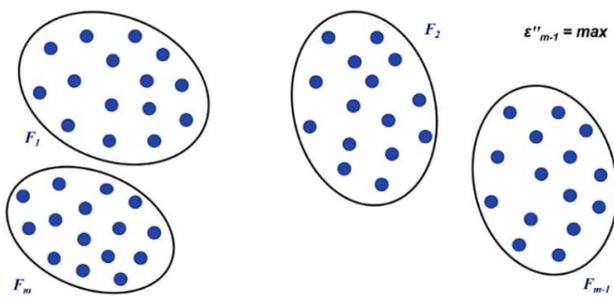


Рис. 4.4. Выбор центроида на метаяуровне знаний

При нахождении одинаковых элементов выбор производится случайным образом. Затем задается значение параметра глубины поиска второго уровня в зависимости от целей решаемой задачи.

Далее с учетом глубины поиска находятся все объекты в цепочке связанные с «центроидом» функциональных областей (ФО). Затем анализируются веса отношений (рис. 4.5), и максимальный вес принимается в виде значения целевой функции.

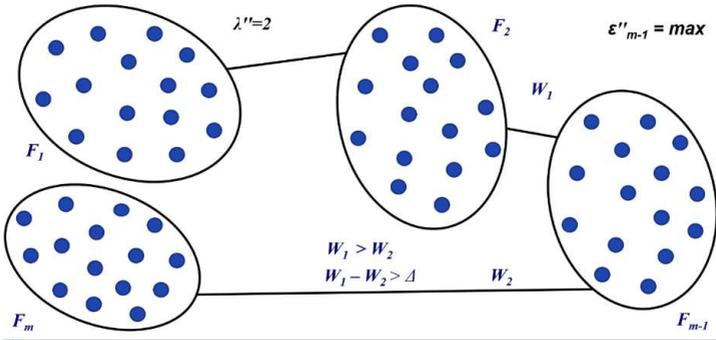


Рис. 4.5. Поиск значимых отношений на метауровне знаний

Далее производится сравнение полученного результата с пороговым значением, установленным экспертным путем и удовлетворяющие пороговому значению ФО попадают в репрезентативную выборку, границы которой задают область решений для поиска значимых междисциплинарных связей.

Затем процесс поиска переходит на макро уровень знаний внутри ФО, попавших в репрезентативную выборку (рис. 4.6).

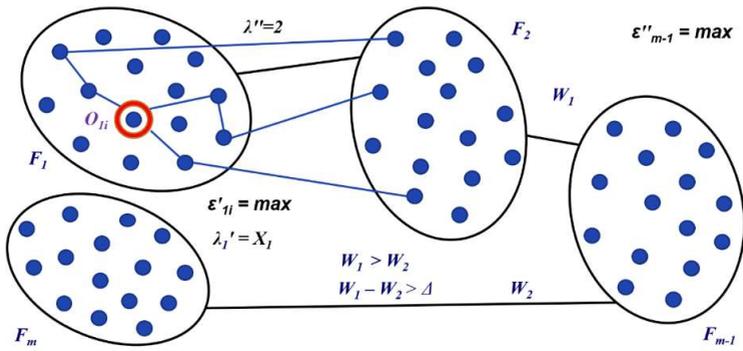


Рис. 4.6. Выбор центроида на макроуровне знаний

В каждой такой ФО, как это показано на рисунке 4.7, процесс поиска происходит аналогично мета- уровню.

Представим *формализованное описание пространства решений предложенного метода*. Зададим множество функциональных областей как $F = \{F_1, F_2, F_3 \dots F_z\}$, где $z = \overline{1, m}$, m – integer constant (количество функциональных областей), причем, $F_z = \{O_{z1}, O_{z2}, O_{z3}, \dots, O_{zk_z}\}$, где k_z – integer constant (количество объектов (сущностей) в F_z), причем, в случае задания отношений между объектами (сущностями) одной функциональной области получим, что $\forall i, j \rightarrow i = \overline{1, k_z}; j = \overline{1, k_z}; i \neq j \exists C_z[i][j] = n$, где n – количество связей между O_{zi} и O_{zj} , z – integer constant (номер исследуемой функциональной области).

В случае задания всех, в т.ч. междисциплинарных, отношений между объектами функциональных областей получим, что $\forall a, b \rightarrow a = \overline{1, \sum_{z=1}^m k_z}; b = \overline{1, \sum_{z=1}^m k_z}; a \neq b \exists C_{interdisc}[a][b] = p$, где p – количество всех, в т.ч. междисциплинарных, связей между объектами (сущностями) многоуровневой онтологической архитектуры.

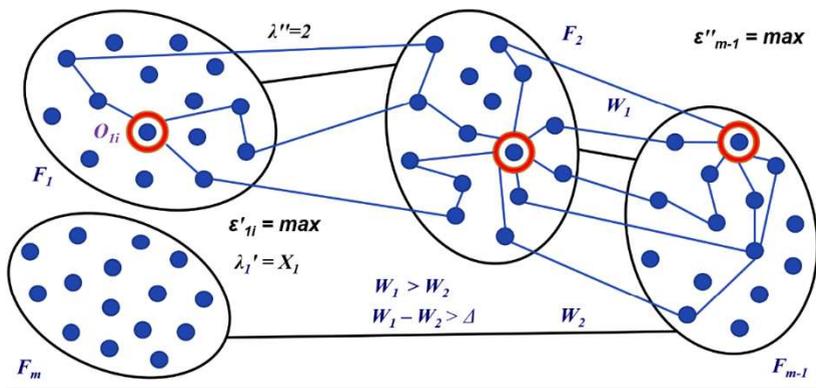


Рис. 4.7. Поиск значимых отношений на макроуровне знаний

Представим множество всех объектов (сущностей) данной архитектуры в виде следующего выражения:

$$O[d] = \left\{ O_{z1}, O_{z2}, O_{z3}, \dots, O_{zk_z}, O_{(z+1)1}, O_{(z+1)2}, \dots, O_{(z+1)k_{(z+1)}}, O_{(z+2)1}, O_{(z+2)2}, \dots, O_{(z+2)k_{(z+2)}}, \dots, O_{m1}, O_{m2}, \dots, O_{mk_m} \right\}, \quad (4.1)$$

где $d = \sum_{z=1}^m k_z$.

Результатом поиска является подмножество объектов из различных функциональных областей, связанных между собой значимыми междисциплинарными отношениями. В условиях информационной неопределенности представленный метод становится формализованной основой интеграции знаний.

На основе интегрированной информационной модели агента представим архитектуру автономного целенаправленного поведения агентов рассматриваемого класса (рис. 4.8), в которой важную роль играет модель оценки обстановки (МОО). Ее задача – формирование на высоком уровне семантически и прагматически значимых представлений для агента о состоянии мира, основанных на данных, полученных от подсистемы обработки данных низкого уровня и априорного знания о мире. Эта совокупность представлений в памяти агента образует модель мира (ММ), которая используется сообществом интеллектуальных агентов для решения задачи интеграции знаний в МПЗ.

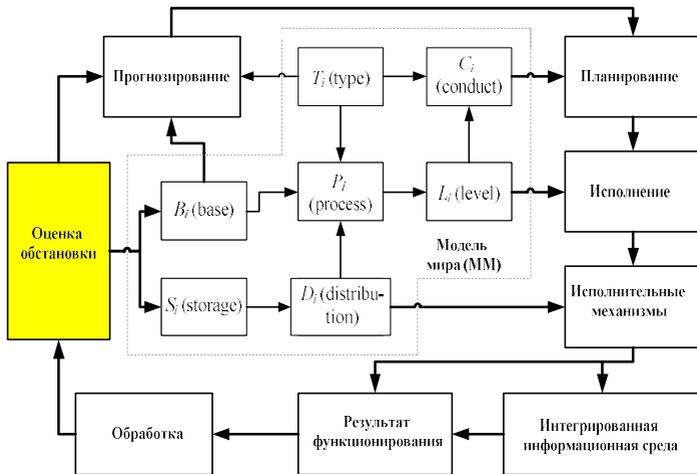


Рис. 4.8. Архитектура автономного целенаправленного поведения агента

При создании МОО следует учитывать следующие основные характеристики МПЗ: открытость – состав объектов, динамику и реализацию групповых действий.

Модель оценки обстановки (МОО) представлена на рис. 4.9 [63]:

- функции порождения f_c – создают и удаляют сущности модели в соответствии с текущими представлениями агента о структуре объектов внешней среды;
- функции связывания f_a – вычисляют новые отношения между сущностями в целях построения новых сущностей более высокого уровня иерархии.

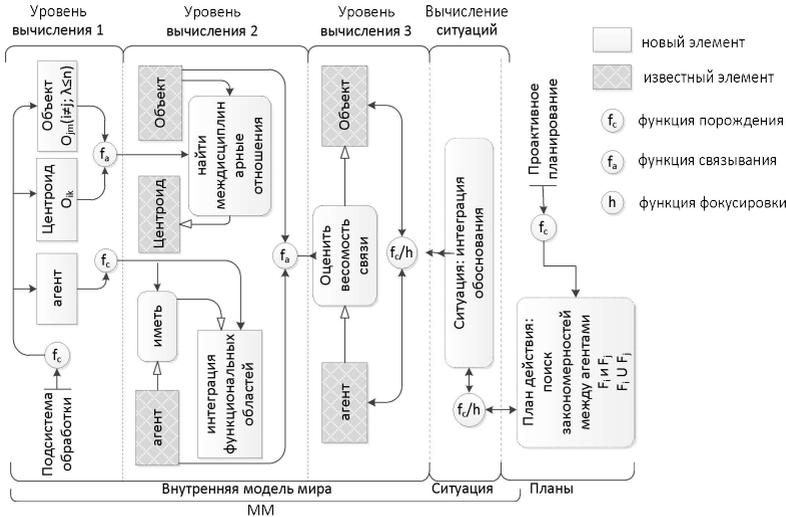


Рис. 4.9. Модель оценки обстановки интеллектуальными агентами

Предложенная модель позволяет обеспечить два уровня интеграции – в пределах одной предметной области (макроуровень данных) и между предметными областями (метауровень данных), что является ключевым отличием данной модели. Главное достоинство этой модели – возможность вертикальной (по уровню детализации) и горизонтальной (по числу предметных областей) масштабируемости.

4.3. Информационные модели фильтра знаний на основе подхода совместного семантического поиска

Использование различных интерпретаций метаданных, таких как профильные данные, в качестве предварительной информации для поиска, позволяет улучшить семантическую модель и упростить обнаружение ключевых признаков в системе анализируемых данных в онтологических структурах. Этот подход известен как совместный семантический поиск (collaborative semantic search) [64, 65].

Рассмотрим модель агента-фильтра знаний (актера), который решает задачи семантической идентификации ключевых данных и поиска системных признаков в массиве данных из различных информационных источников. Эффективному выполнению поисковых запросов мешает неоднородность и гетерогенность источников данных, а также семантическое несоответствие формы запроса и его содержания. Не стоит забывать и об особенностях интерфейса используемой интеллектуальной системы.

Рассмотрим понятие начального фильтра обработки поискового запроса, который используется для выполнения операций идентификации ключевых данных. Этот фильтр, также известный как агент-фильтр знаний, выполняет процесс построения семантического древа, описывающего таксономию понятий. Подобный актер, представленный на рисунке 4.10, осуществляет координирование процессов приобретения неструктурированных знаний в разнородных гетерогенных источниках.

Все действия и результаты работы агентов по обработке, улучшению и упорядочиванию запросов становятся паттернами, после чего они индексируются и сохраняются в базе прецедентов. Главное преимущество агента-фильтра данных заключается в реализации функционала интеллектуального агента с использованием свойств автономного и проактивного субъекта.

Выделим главные преимущества предлагаемой информационной модели: использование онтологических структур как информационного пространства для выполнения процедур семантического извлечения данных; возможность изменения формулировки запроса с применением разных энциклопедических справочников и использование базы прецедентов для определения наиболее эффективной смысловой формы поискового запроса.

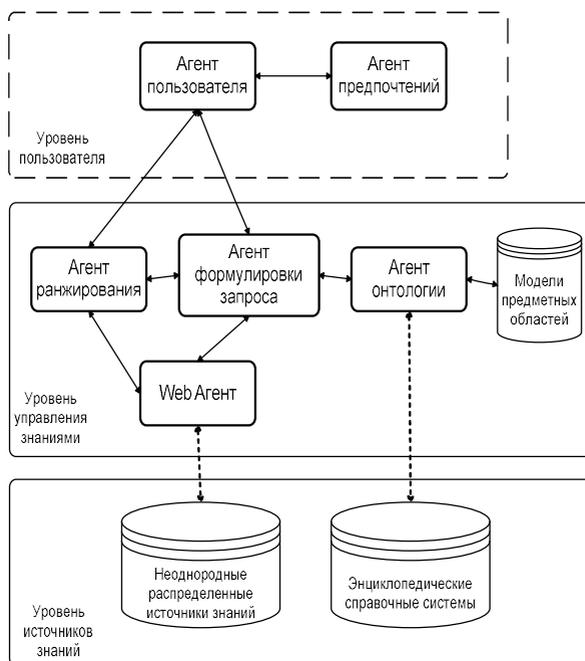


Рис. 4.10. Агентная информационная модель фильтра знаний

Важно отметить, что эта архитектура имеет модульное строение, что позволяет легко настраивать новые онтологии, информационные источники и справочные системы. Предложенная модель агента имеет трехуровневую систему. Это уровень пользователя, уровень управления данными и уровень информационных источников. Каждый специализированный агент находится на определенном уровне и выполняет конкретные функции, такие как формулирование, изменение, упорядочивание и представление результатов. Первый уровень включает агента предпочтений, который контролирует агента пользователя. На втором уровне расположены: агент онтологии, агент формулирования запроса, веб-агент и агент ранжирования, отвечающий за сбор результатов подзапросов из различных источников данных, оценивая их на основе семантических критериев в соответствии с требованиями агента предпочтений. При этом приоритеты определяются на основе степени авторитетности используемого источника (от 0 до 10) и важности термина, включенного в запрос.

Рассматривая тему шаблонов поведения агента-фильтра данных, мы также определяем семантику сквозного процесса операций, контролирующего весь процесс поиска. Основываясь на представленной модели агента-фильтра данных, абстрагируясь от классов агентов, их связей и характеристик, мы предлагаем статическую метамодель актора (фильтра знаний), представленную на рисунке 4.11.

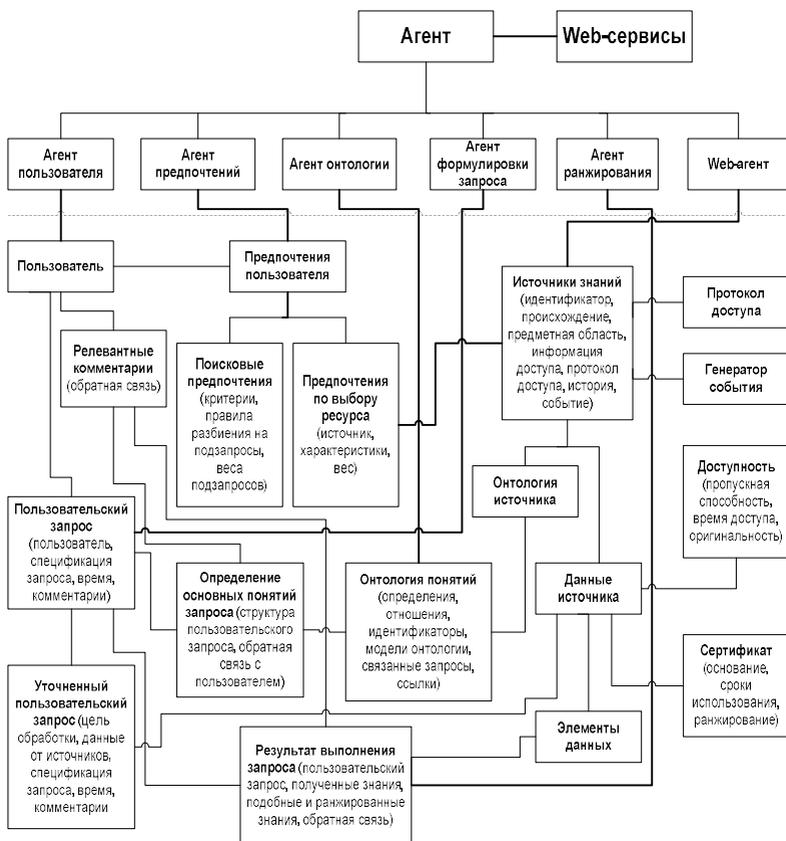


Рис. 4.11. Метамодель фильтра знаний

В этой метамодели в отличие от первой каждый агент управляет соответствующими классами объектов, обрабатывает спецификации и веб-сервисы. При этом результаты поиска влияют на разви-

тие метаданных, связанных с предпочтениями пользователя, формулировкой запроса, использованием источника данных и ранжированием результата.

Учет прецедентов (ранее сохраненных успешных пользовательских запросов) значительно ускоряет и повышает эффективность обработки поискового запроса. На рисунке 4.12 построена case-модель актора (фильтра знаний), позволяющая изменять спецификацию запроса и усовершенствовать его на основе ранее сохраненных в репозитории.

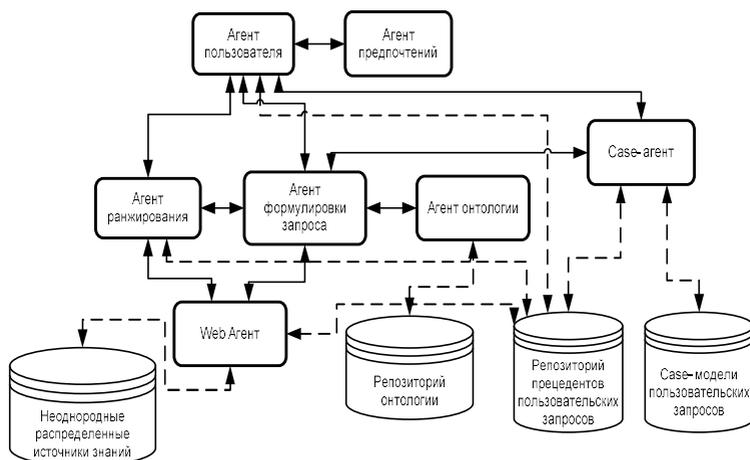


Рис. 4.12. Case-модель актора (фильтра знаний)

Изменение запроса будет успешным, только если пользователь высоко оценит степень соответствия результатов поиска изначальным целям. Здесь Case-агент управляет связью между Агентом пользователя и Агентом формулировки запроса с базой case-моделей запросов и хранилищем прецедентов успешных запросов пользователей. Такое совместное фильтрование позволяет агенту выбирать источники данных и динамически настраиваться под каждый из них.

Процесс семантической фильтрации, по мнению автора, необходимо рассматривать на основе математической модели диффузии знаний. Под *диффузией знаний* будем понимать – процессы приобретения ценных знаний в информационном пространстве функциональной области и обеспечения эффективного управления их обработкой, совершенствованием и распределением.

Запишем исходное уравнение *математической модели семантической фильтрации знаний S* на основе имитации их диффузии в глобальном информационном пространстве [8, 10, 36]:

$$\frac{dS}{dy} = Q(y) \sum_{i=1}^N \frac{V_i(y)C_i(y)}{M(y)}, \quad (4.2)$$

$$Q(y) = \frac{M(y)}{M_{max}(y)}, \quad (4.3)$$

где N – число каналов поступления знаний, $i=1, 2, \dots, N$; $Q(y)$ – коэффициент, указывающий на текущую загрузку каналов приобретения знаний в момент времени y по отношению к максимально возможному информационному объему пропускной способности ($0 \leq Q(y) \leq 1$); $V_i(y)$ – объем знаний по тематике рассматриваемой функциональной области, полученный из i -го канала в момент времени y ; $M(y)$ – суммарный объем знаний, приобретенный в момент времени y ($0 < M(y) \leq M_{max}(y)$); $M_{max}(y)$ – максимальный информационный объем знаний, который возможно получить по имеющимся каналам в момент времени y ; $C_i(y)$ – коэффициент ценности (наличия необходимых системно значимых признаков) приобретенных через i -ый канал знаний в момент времени y ($0 \leq C_i(y) \leq 1$).

Опишем условную ценность $C_i(y)$ системно значимых признаков элементов знания из i -го канала следующим выражением [8, 10, 36]:

$$C_i(y) = \frac{\sum_{j=1}^{Atr_i} \sigma_j(y)\tau_j(y)}{Atr_i(y)}, \quad (4.4)$$

где $Atr_i(y)$ – количество атрибутов классификации i -того канала приобретения знаний по системно значимым признакам в момент времени y ; $\sigma_j(y)$ – коэффициент достоверности j -того атрибута; $\tau_j(y)$ – коэффициент актуальности j -того атрибута ($0 \leq \tau_j(y) \leq 1$).

Очевидно, что информационные процессы приобретения и управления знаниями являются продолжительными по времени, поэтому в ряде случаев даже ценные, но уже неактуальные знания дают недостоверный результат их обработки и применения. В этом случае коэффициент актуальности $\tau(y)$ – скалярный показатель степени соответствия системно значимого признака семантической фильтрации в текущий момент времени [8, 10, 36]:

$$\tau(y) = 1 - \frac{int(y)}{int_{max}}, \quad (4.5)$$

где $int(y)$ – интервал неиспользования j -того атрибута классификации в момент времени y ($0 \leq int(y) \leq int_{max}$); int_{max} – допустимый интервал неиспользования атрибута классификации. Тогда при $int(y) = int_{max}$ атрибут классификации теряет актуальность.

Также основной характеристикой атрибутов классификации является достоверность элемента знаний. Коэффициент достоверности атрибута $\sigma(y)$ – скалярный показатель отношения правильно классифицированных по определенному системно значимому признаку элементов знаний к их общему числу [8, 10, 36]:

$$\sigma(y) = \frac{clas_{right}(y)}{clas_{gen}(y)}, \quad (4.6)$$

где $clas_{right}(y)$ – информационный объем правильно классифицированных знаний по определенному системно значимому признаку на данный момент времени; $clas_{gen}(y)$ – общий объем классифицированных знаний по определенному системно значимому признаку на данный момент времени.

Предложенная математическая модель семантической фильтрации знаний на основе имитации их диффузии в информационном пространстве функциональной области (4.2) – (4.6) описывает механизм приобретения ценных знаний в условиях эпистемологической неопределенности и значительного объема входной неструктурированной информации.

В данном пункте построен комплекс информационных моделей семантического фильтра знаний, повышающих эффективность решения задачи идентификации скрытых зависимостей и закономерностей при обработке разнородных распределенных ресурсов знаний, созданных на основе онтологических структур. Представлена математическая модель диффузии знаний как основы информационного процесса семантической фильтрации.

Таким образом, 4-ая глава посвящена вопросам построения информационных моделей, описывающих значимые для проводимого исследования параметры и переменные величины процессов решения основных задач приобретения и управления знаниями. Для определения устойчивых междисциплинарных связей использован принцип силовой релаксации. Построена математическая модель диффузии знаний как основы информационного процесса семантической фильтрации. Разработана интегрированная модель структурирования знаний, позволяющая реализовать настройку весовых коэффициентов при моделировании рассуждений на метауровне знаний.

ГЛАВА 5. БИОИНСПИРИРОВАННЫЕ МЕТОДЫ ОЦЕНКИ СЕМАНТИЧЕСКОЙ БЛИЗОСТИ

5.1. Онтологические размерности семантических зависимостей понятий

Рассмотрим способ определения размерностей исследуемых понятий как основы для обнаружения семантических зависимостей между схожими концептами. Применяемые уравнения для каждой размерности являются общими и используются для других онтологий, охватывающих любые из определенных размерностей. Главным достоинством является способность системы заменять одно понятие другим, исходя из определения их сходства и с учетом конкретных условий. Именно таким образом интеллектуальная информационная система осваивает новые концепции и непрерывно улучшает свою онтологию, чтобы оптимизировать будущие взаимодействия.

Главная задача онтологии в контексте интеллектуальных информационных систем, занимающихся приобретением знаний, заключается в стандартизации представления каждой концепции, связывая ее с соответствующим термином для определения семантического сходства между понятиями.

Существует множество методов определения семантического сходства, описанных в литературе. Они включают измерение степени сходства между концептами онтологии на основе теоретико-множественного подхода Тверски и сравнения характеристик концептов [66], определение длины кратчайшего пути между концептами в структуре связей как показателя сходства [66], где семантическое сходство концепта обратно пропорционально семантическому расстоянию или определяется на основе частотности концепта. Однако все эти методы имеют общий недостаток – симметричность, в то время как в реальной междисциплинарной области знаний симметричность важности связей между концептами встречается редко. Для решения этой проблемы используются два подхода. В первом подходе учитывается направление пути поиска взаимосвязей между концептами, при котором концепт-предшественник семантически дальше от концепта-преемника и наоборот [67]. Во втором подходе сходство концептов определяется наличием иерархических взаимосвязей, которые вычисляются рекурсивно.

В связи с этим, эффективными способами оценки семантического сходства являются комбинированные и гибридные методы, позволяющие решить проблему различий в названиях схожих концептов и связей, а также определить их в разных онтологиях. Кроме того, предлагается учесть решение проблемы определения меры семантического сходства на основе размерности исследуемых концептов [68–72] как набора условий, включающих основные признаки концептов, существенно влияющие друг на друга. Расчет размерности исследуемых концептов необходим для определения наличия семантической зависимости между схожими концептами одной онтологии или концептами онтологий разных функциональных областей. В тоже время, поиск семантической зависимости между концептами разных онтологий представляет собой более сложную задачу. Для решения этих проблем введем следующий базовый концептуальный уровень онтологической размерности концептов: эквивалентный; иерархический; метауровень; разделяющий; неопределенный.

Отметим, что применяемые выражения для каждой размерности являются общими и используются для любых онтологий, так как появляется возможность замены одного понятия на другое, основываясь на вычислении их подобия и учете определенных обстоятельств.

5.2. Модель интеграции знаний на основе оценок семантической близости концептов при отображении онтологий

Рассмотрим задачу отображения онтологии O_1 на онтологию O_2 , которая заключается в поиске для каждого концепта онтологии O_1 подобного ему концепта онтологии O_2 . Сходство и различие используемых в различных интеллектуальных информационных системах приобретения и управления знаниями онтологий определяется на основе анализа семантических зависимостей между существующими классами понятий. Семантические зависимости задают допустимые состояния интеллектуальных информационных систем и являются основой согласованного изменения элементов знаний. При решении задачи согласованного изменения элементов знания в контексте функциональной области выясняются сходства и различия используемых системами онтологий, согласуются онтологические спецификации. Основой для этих действий является вычисление семантической близости и установление семантических зависимостей

между концептами онтологий. При этом, проводимая интеграция знаний сохраняет соответствие множества онтологий интеллектуальных информационных систем приобретения и управления знаниями заданному набору семантических зависимостей.

Семантическая зависимость, которая задана на онтологии O , является s -предикатом, заданным на \bar{O} . Если существует семантическая зависимость, определенная одной из представленных выше размерностей S , в онтологии O , тогда примем обозначение $s(O)$. Множество таких зависимостей $S = \{s_1, s_2, s_3, s_4, s_5\}$ обладает свойством непротиворечивости, если $\exists s_i(O) \forall i (1 \leq i \leq 5)$. Рассмотрим две онтологии O_1 и O_2 . $O_1 = \langle P^1, V^1, R^1, C^1 \rangle$ и $O_2 = \langle P^2, V^2, R^2, C^2 \rangle$. Примем равным n количество концептов в онтологии O_1 , и равным m – в онтологии O_2 .

Сведем зависимость между онтологиями к семантическим зависимостям между концептами, определенным на множестве размерностей онтологических свойств понятий (рис. 5.1) [10].

Тогда онтологическая модель интеграции знаний на основе отображения онтологии O_1 на онтологию O_2 примет следующий вид:

$$Z = \langle O, H^O, S, U, mapping \rangle, \quad (5.1)$$

где $O = \langle P, V, R, C \rangle$ – онтология интегрированной информационной системы; H^O – интегрированная информационная система с онтологией O ; $S = \{s_1, s_2, s_3, s_4, s_5\}$ – множество семантических зависимостей; $U: F^O \rightarrow F^O$ – отображение, при котором $\forall H^O \in F^O, \forall s \in S$ выполняется $s(U(H^O))$; F^O – множество гетерогенных разнородных информационных систем с общей онтологией O в основе; U – изменение информационной системы в виде отображения [10].

Заметим, что процедура оценки эквивалентной семантической близости является NP- сложной задачей. В связи с этим необходимо для ее решения использовать эвристические методы.

Рассмотрим данную проблему на примере решения задачи отображения двух онтологий O_1 и O_2 .

Целевой функцией поставленной задачи является следующее выражение:

$$f(R^1, R^2) \rightarrow max, \quad (5.2)$$

где R^1, R^2 – множества предикатов концептов онтологий O_1 и O_2 .

Каждое множество предикатов состоит из подмножеств конкретных атрибутов, принадлежащих каждому из понятий двух онтологий.

$$R^1 = \{R_1^1; R_2^1; \dots; R_i^1; \dots; R_n^1\}, \quad (5.3)$$

где $i = \overline{1, n}$, n – количество понятий в O_1 .

$$R^2 = \{R_1^2; R_2^2; \dots; R_j^2; \dots; R_m^2\}, \quad (5.4)$$

где $j = \overline{1, m}$, m – количество понятий в O_2 .

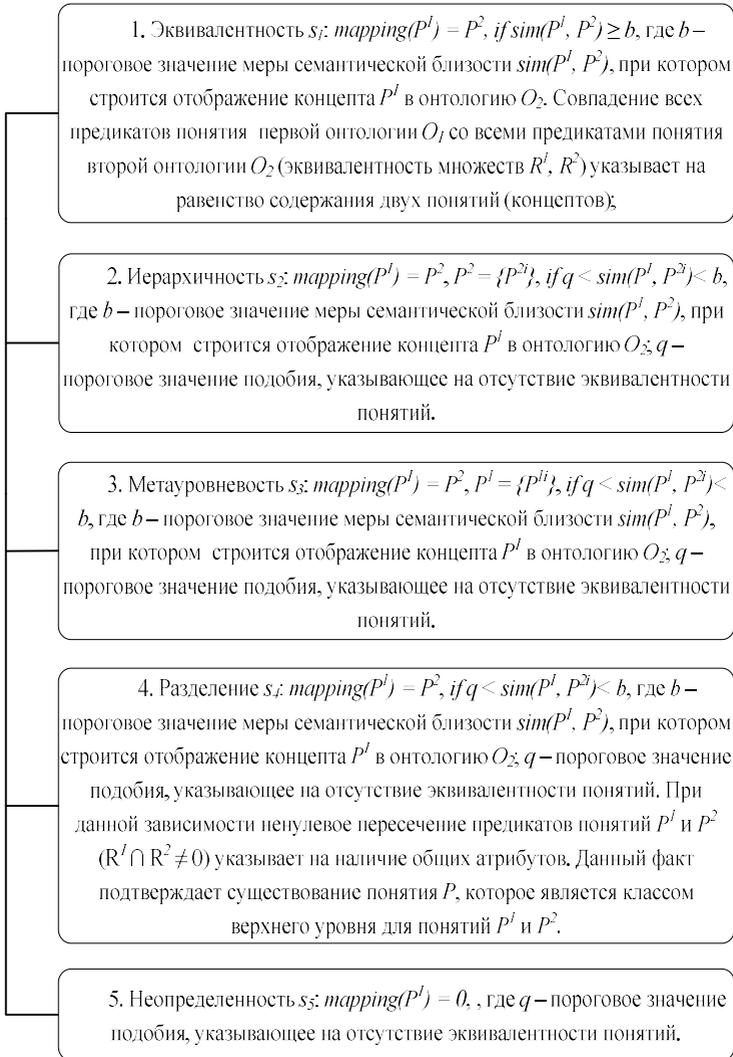


Рис. 5.1. Онтологические свойства

Решением задачи оценки эквивалентной семантической близости является следующее выражение:

$$f(R^1, R^2) = \sum_{i=1}^n \sum_{j=1}^m R_i^1 \cap R_j^2 \geq d, \quad (5.5)$$

где $d > 0$, d – пороговое значение, равенство или превышение которого означает присутствие эквивалентной семантической близости между подмножествами предикатов, принадлежащих концептам P_i^1 и P_j^2 . Чем выше показатель d , тем более значимой является эквивалентная семантическая близость между рассматриваемыми концептами [10].

Таким образом, при решении задачи отображения (интеграции) большего числа онтологий требуется найти такую пару онтологий O_a и O_b , для которых функция f примет наибольшее значение.

Как пример, при решении задачи интеграции знаний функциональных (предметных) областей из гетерогенных разнородных ресурсов возникает ситуация необходимости сравнения более чем 2-х онтологий. Тогда на первом этапе с применением комплекса методов роевого интеллекта сформируется начальная выборка из 2-х онтологий наиболее семантически близких по атрибутам для процедуры отображения. Далее на основе предложенных ранее многоагентных подходов решается задача интеграции знаний с учетом неявных зависимостей и закономерностей на множестве онтологических отношений между понятиями в контексте рассматриваемых проблем. В этом случае предварительная идентификация наиболее подобных онтологий значительно ускорит процесс отображения и повысит качество результата решения задачи интеграции знаний. Предложенный комбинированный подход позволяет повысить эффективность интеллектуальных информационных систем приобретения и управления знаниями.

Отметим, что вычисление оценки эквивалентной семантической близости требует применения эвристических методов с децентрализованным управлением. Это позволит обеспечить высокую параллельность вычислений для ускорения процесса решения задачи.

5.3. Модифицированный метод бактериальной оптимизации для решения задачи семантического поиска знаний

Одним из эвристических методов с децентрализованным управлением является метод бактериальной оптимизации (Bacterial Optimization, BO), который был впервые предложен в работах Пассино в 2002 году [73, 74].

Для решения задачи семантического поиска знаний рассмотрим абстрактную многоуровневую онтологическую архитектуру семантических связей в междисциплинарном пространстве знаний [10]. Связи между вершинами заданы множествами отношений C^1 и C^2 онтологий O_1 с подмножеством $R_1^1; R_2^1; \dots; R_i^1; \dots; R_N^1$ и O_2 с подмножеством $R_1^2; R_2^2; \dots; R_j^2; \dots; R_M^2$ соответственно. С целью упрощения вычислений будет исследоваться эквивалентность двух любых онтологий из пространства взаимосвязанных функциональных областей на метаровне знаний. При этом параллельность вычислений реализуется на основе кластерного подхода и метода бактериальной оптимизации. Здесь значение S – это размерность онтологий равная числу бактерий. Заметим, что для повышения эффективности поиска будут использованы эвристики на основе жадных процедур. На рисунке 5.2 представлены рассматриваемые онтологии, где вершины графов определяют значения атрибутов сравниваемых концептов.

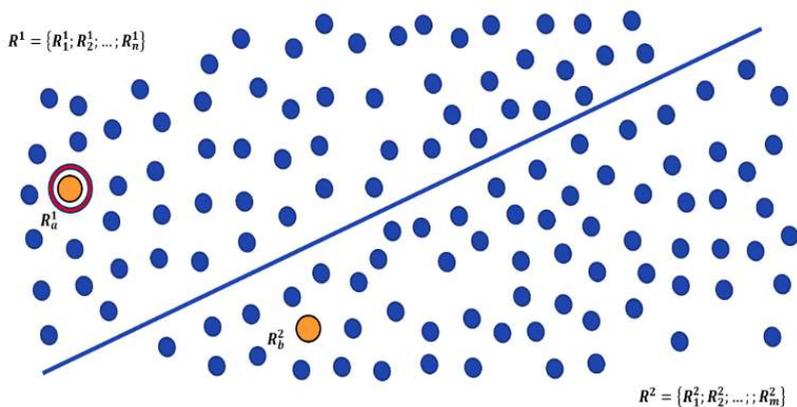


Рис. 5.2. Модель разделенного на подмножества пространства решений

Зададим пороговое значение d . Если данное значение больше или равно значению целевой функции $f(R^1, R^2)$, то существует эквивалентная семантическая близость между подмножествами предикатов, принадлежащих концептам P_i^1 и P_j^2 .

Рассмотрим работу предложенного подхода более подробно. Сначала случайным образом выбираются наборы, т.е. пары подмножеств атрибутов с номерами a и b , где $a \in [1: N]$, $b \in [1: M]$, для каждой бактерии колонии. Все выбранные пары будут составлять выборку. При этом одно подмножество назовем «верхним», а второе – «нижним».

На рисунке 5.3 рассмотрена процедура поиска.

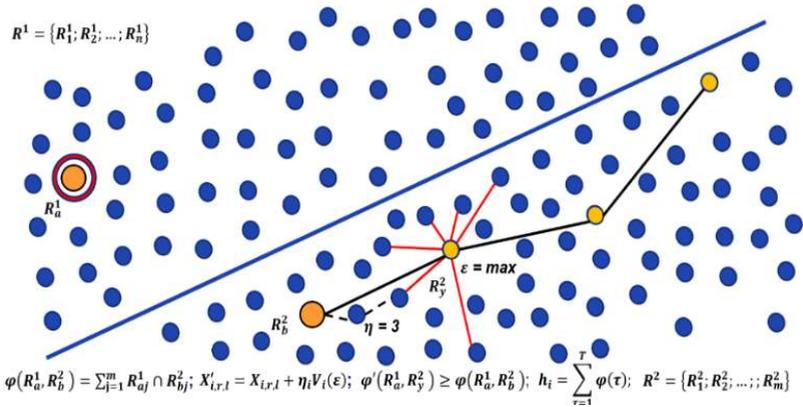


Рис. 5.3. Передвижение бактерии при росте ЦФ

Здесь «верхнее» подмножество набора является эталоном-константой, а «нижнее» – текущим положением $X_{i,r,l} = X_{i,r,l}(t)$ бактерии $s_i \in S$ на t -м шаге хемотаксиса, r -м шаге репродукции и l -м шаге ликвидации и рассеивания, при этом $i \in [1: |S|]$, $t \in [1: T]$, $r \in [1: T^r]$, $l \in [1: T^l]$, где T , T^r , T^l – общие числа шагов хемотаксиса, репродукции, ликвидации и рассеивания соответственно (свободные параметры алгоритма), а $|S|$ – четное число бактерии в колонии.

Если в процессе движения происходит уменьшения значения ЦФ, то бактерия производит кувырок и возвращается в предыдущую вершину для изменения дальнейшей траектории движения (рис. 5.4).

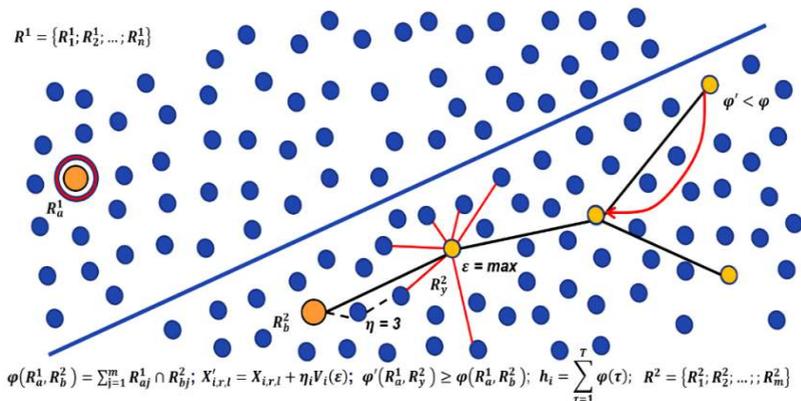


Рис. 5.4. Иллюстрация кувырка бактерии

При попадании бактерии в область локального оптимума во время реализации процедуры хемотаксиса производится изменение текущего положения бактерии и смена статуса подмножеств «верхнего» на «нижний» и наоборот (рис. 5.5).

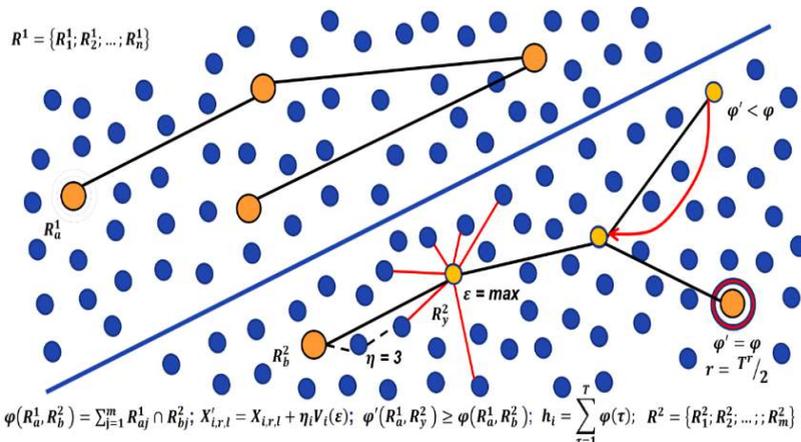


Рис. 5.5. Иллюстрация изменения статусов подмножеств

Для реализации этого механизма (рис. 5.6) в модифицированном алгоритме предусмотрена переменная α , имеющая значения «0» – означающее текущее положение бактерии или «1» - константу. Смена их

значений является шагом процедуры репродукции r и означает смену статуса подмножеств, а также текущего положения бактерии.

«upper» subset	R_{a1}^1	R_{a2}^1	...	R_{MAX}^1	$\alpha = 1$ (const)
«lower» subset	R_{b1}^2	R_{b2}^2	...	R_{MAX}^2	$\alpha = 0$ (search)

Рис. 5.6. Процедура репродукции

Таким образом, обнаружение максимального подобия (эквивалентности) между наборами подмножеств атрибутов позволяет сделать вывод о высокой эквивалентной семантической близости концептов, которым данные атрибуты принадлежат.

Далее для устранения несоответствия различной размерности подмножеств атрибутов разных концептов обеих онтологий выбирается максимальная размерность (MAX), а незанятые поля в конкретных подмножествах заполняются нулевыми значениями ($NULL$).

Для определения траектории направления вектора движения бактерии $V_i(\epsilon)$ по вершинам графа онтологии, соответствующей «нижнему» подмножеству, введем переменную ϵ_m , где $m \in [1: M]$ для онтологии O_2 . Данное значение определяет локальную степень вершин графа (мощность окрестности) онтологии. При изменении статуса онтологий, для O_1 мощность окрестности обозначим переменной ϵ_n , где $n \in [1: N]$. Тогда движение бактерии осуществляется к вершине, имеющую большую локальную степень. При этом скорость передвижения бактерии будет зависеть от величины шага хемотаксиса, которая задается переменной $\eta \geq 1$, указывающей количество вершин, которые бактерия проходит за один шаг.

Значение данной ЦФ принимает следующий вид [74]:

$$\varphi_{i,r,l} = \varphi_{i,r,l}(T). \quad (5.6)$$

А новое текущее положение $X'_{i,r,l}$ бактерии s_i на $t+1$ шаге хемотаксиса определяется следующим выражением:

$$X'_{i,r,l} = X_{i,r,l} + \eta_i V_i(\epsilon). \quad (5.7)$$

Заметим, что вектор $V_i(\epsilon)$ остается неизменным и $V'_i(\epsilon) = V_i(\epsilon)$, когда происходит увеличение значения ЦФ. Это демонстрирует, что находится эквивалентность в наборах анализируемых онтологий. В противном случае бактерия совершает «кувырок», возвращаясь в вершину с максимальной ϵ , для определения новой траектории движения. Данная процедура позволяет находить множество локально-оптимальных решений. На рисунке 5.7 представлена структурная схема

предложенного модифицированного метода бактериальной оптимизации (ММБО). Здесь механизм репродукции позволяет обеспечивать процесс поиска локальных оптимумов.

Для реализации данного механизма зададим текущий уровень здоровья (health status) бактерии как сумму значений ЦФ во всех точках пройденной траектории [74]:

$$h_i = \sum_{\tau=1}^T \varphi_{i,r,l}(\tau), i \in [1: |S|]. \quad (5.8)$$

Для проведения процедуры репродукции после вычисления значений всех h_i номера бактерий заносятся в список в порядке убывания значений их здоровья, чтобы на $r+1$ шаге исключить из рассмотрения половину наиболее слабых агентов, а каждого агента-бактерию из выживших дублировать копией с координатами, равными координатам дублируемого агента. Например, если выжившая бактерия $s_j, j \in [1: |S|]$ имеет положение $X_{j,r,l}$, тогда после репродукции появится бактерия s_k , причем, $k = \frac{|S|}{2} + j, X_{j,r+1,l} = X_{j,r,l}, X_{k,r+1,l} = X_{j,r,l}$. Таким образом, после процедуры репродукции общее количество бактерий в колонии остается неизменным.

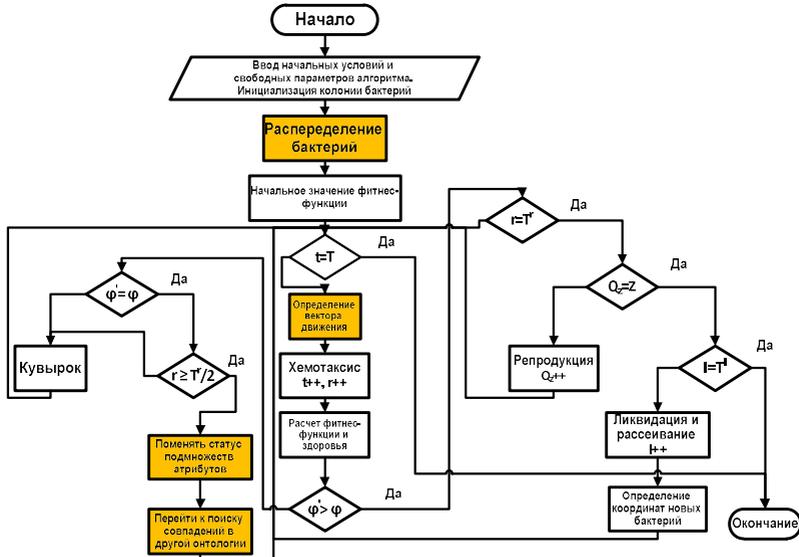


Рис. 5.7. Структурная схема модифицированного метода бактериальной оптимизации

Чтобы преодолеть локальные оптимумы и найти глобальный максимум целевой функции в алгоритме используются процедуры ликвидации и рассеивания. Для определения момента запуска этих процедур введем переменную θ_z , где $z \in [1: Z]$, Z – число процедур репродукции до начала ликвидации и рассеивания. При достижении максимального значения Z включаются процедуры ликвидации и рассеивания [74]. Сначала случайным образом производится уничтожение выбранного количества $w < |S|$ бактерий, а вместо них создается аналогичное число бактерий с начальными координатами в новых случайно выбранных парах подмножеств атрибутов концептов рассматриваемых онтологий. Далее процесс протекает итерационно.

Отметим, что колония бактерий значительной размерности формирует масштабные пространственно-временные структуры со сложной системой отношений, позволяющие повысить эффективность семантического поиска знаний.

Данный метод позволяет проводить детальный поиск в локальных областях. При этом эффективность поиска повышается за счет реализации процедуры репродукции, а преодоление локальных оптимумов производится за счет выполнения механизмов ликвидации-рассеивания.

5.4. Разработка модифицированного обезьяньего метода для решения задачи семантического поиска знаний

Другим эвристическим методом с децентрализованным управлением является метод обезьяньего поиска (*Monkey Search, MS*). Впервые данный метод предложен Чжао и Тангом в [74]. В нем используется модель передвижения обезьян по горам с целью нахождения пищи. Вершина горы, согласно данному методу, обладает наибольшим количеством пищи, следовательно решением задачи является пик самой высокой вершины. В данном методе при достижении одной из вершин обезьяны совершают локальные и глобальные прыжки, с целью обнаружения наиболее высоких из них. При этом локальные прыжки – это обследование окрестностей возле вершины, а глобальные – для организации новых пространств и выхода из локальных оптимумов [74–76]. Данный метод эффективен для решения задачи оценки эквивалентной семантической близости.

Укрупненная структурная схема модифицированного обезьяньего метода поиска (МОМП) представлена на рисунке 5.8.

Опишем предлагаемый модифицированный обезьяний метод оценки эквивалентной семантической близости более подробно. При этом кодировка решений остается постоянной, а координатами местоположения обезьян будут являться номера вершин графовых структур онтологий.

1. Примем за целевую функцию решаемой задачи максимизацию функции (5.2). Для вычисления значений функции $f(R^1, R^2)$ используется выражение (5.5).

2. Исходными данными для поиска примем подмножества атрибутов $R_1^1; R_2^1; \dots; R_i^1; \dots; R_N^1$ для онтологии O_1 , и $R_1^2; R_2^2; \dots; R_j^2; \dots; R_M^2$ для онтологии O_2 .

3. Для обеспечения единой размерности всех подмножеств анализируемых атрибутов концептов онтологий O_1 и O_2 вводиться единая максимальная размерность, а незанятые поля заполняются нулевым значением.

4. Зададим пороговое значение d . Если данное значение больше или равно значению целевой функции $f(R^1, R^2)$, то существует эквивалентная семантическая близость.

5. Зададим количество локальных R и глобальных прыжков L . При этом $r_{max} = R, r_i = 1$, а $l_{max} = L, l_i = 1$, где L и R – положительные целочисленные значения.

6. Также зададим начальные координаты X_i каждой обезьяны $s_i, i \in [1: S]$, где S – размер популяции (четное целое число) используется пара подмножеств атрибутов с номерами a и b , где $a \in [1: N], b \in [1: M]$. Процесс поиска происходит аналогично бактериальному методу, за одним исключением. Для реализации механизма локальных прыжков применяется «нижнее» подмножество ($\alpha = 0$). При этом процесс движения вверх продолжается до получения лучшего с точки зрения ЦФ решения. А для реализации механизма глобальных прыжков – «верхнее» ($\alpha = 1$). При этом если прыжок успешный, то статус подмножеств и значение переменной α меняются местами и процесс поиска продолжается в онтологии данного, вновь назначенного «нижнего» подмножества.

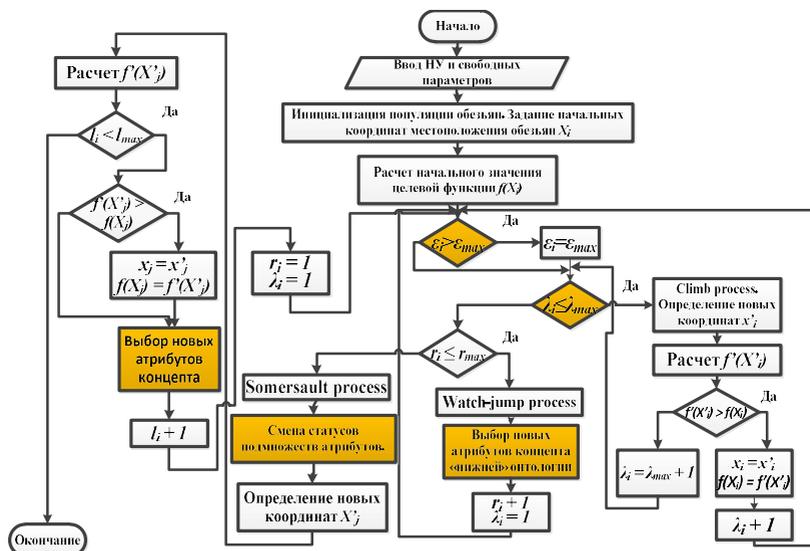


Рис. 5.8. Структурная схема модифицированного обезьяньего метода поиска

7. Далее генерируем популяцию обезьян S и равномерно случайно распределяем их в пространстве поиска. При этом каждой обезьяне s_i , $i \in [1: S]$ согласно статусу, ставится в соответствие пара подмножеств атрибутов концептов из рассматриваемых онтологий;

8. Затем происходит процесс движения вверх начиная с «нижнего» подмножества. В отличие от известных данный процесс будет реализовываться на основе принципа силовой релаксации. Для этого зададим целочисленные положительные значения максимально допустимых мощности окрестности ε_{max} и глубины поиска λ_{max} . При этом начальное значение глубины поиска $\lambda_i = 1$.

9. Далее определим результат пересечения «верхнего» и «нижнего» подмножества и сравним его со значением d . Затем рассматриваем соседние элементы «нижнего» подмножества. При этом если локальная степень рассматриваемого элемента превышает максимальное значение $\varepsilon_i > \varepsilon_{max}$, то присваиваем $\varepsilon_i' = \varepsilon_{max}$. Заметим, что каждый рассматриваемый элемент онтологии «нижнего» подмножества сравнивается с «верхним» (рис. 5.9). После этого определяется значения функции $f(R^1, R^2)$ и выбирается наилучшее с проверкой условия $f'(X_i^j) >$

$f(X_i)$. При соблюдении данного условия получаем новое текущее положение обезьяны, заменяя предыдущее $X_i = X'_i$. Далее увеличиваем значение глубины поиска $\lambda_i = \lambda_{max}$, далее $\lambda'_i = \lambda_i + 1$.

10. Проверка условия $\lambda'_i \leq \lambda_{max}$? Если «да», тогда $\lambda_i = \lambda'_i$. Переход к п.9. Если «нет», тогда переход к п.11;

11. Проверка условия $r_i \leq r_{max}$, если «да», тогда переход к п.12, если «нет» тогда переход к п.13;

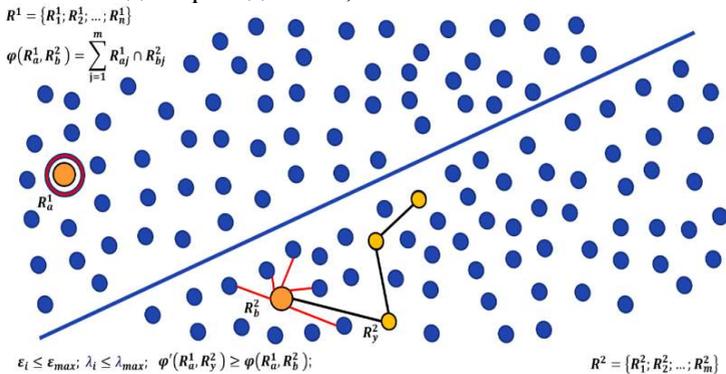


Рис. 5.9. Реализация процесса «движения вверх»

12. На рисунке 5.10 показан процесс реализации локального прыжка. Здесь длина прыжка должна быть не менее $\lambda_{max}/2$ и не более λ_{max} . При этом из онтологии «нижнего» подмножества выбирается новый набор атрибутов R^2_b , после чего возврат к п.9, а счетчик локальных прыжков увеличивается на единицу $r_i + 1$, глубина поиска принимает значение $\lambda_i = 1$;

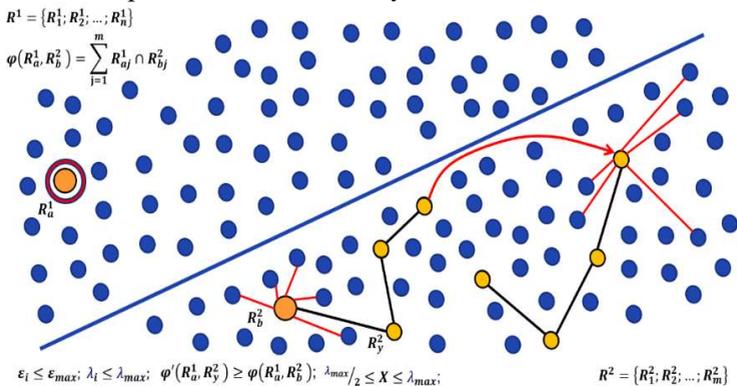


Рис. 5.10. Процесс реализации «локального прыжка»

13. На рисунке 5.11 показан процесс реализации глобального прыжка. При этом происходит смена статуса подмножеств и текущим положением обезьяны является X_j (рис. 5.12).

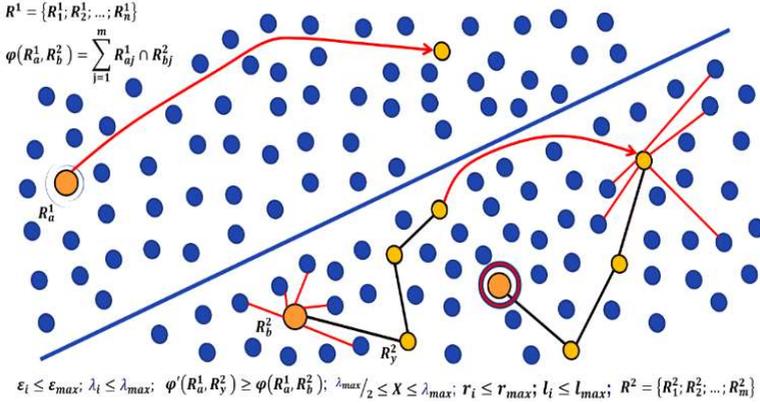


Рис. 5.11. Процесс реализации «глобального прыжка»

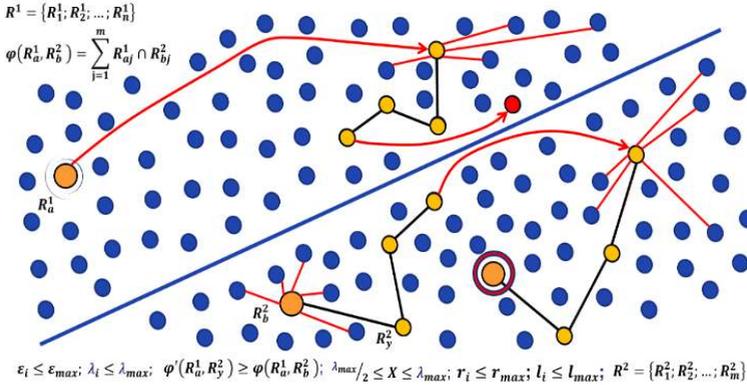


Рис.5.12. Иллюстрация механизмов поиска после смены статусов подмножеств

14. Проверка условия $l_i < l_{max}$, если «да», тогда переход к п.16, если «нет», то конец работы;

15. После смены статуса из нового «нижнего» подмножества выбирается новый набор атрибутов R_a^1 , и возврат к п.9, при этом счетчик глобальных прыжков увеличивается на единицу $l_i + 1, r_i + 1, \lambda_i = 1$.

16. Конец работы.

Данный метод позволяет реализовать более стохастичный процесс семантического поиска одним интеллектуальным агентом с большим охватом различных областей информационного пространства. При этом эффективность поиска реализуется за счет локальных прыжков, а преодоление локальных оптимумов – за счет глобальных. Отметим, что этот метод, как и бактериальный, имеет полиномиальную сложность, что позволяет масштабировать его для достаточно больших размерностей информационного пространства поиска.

5.5. Разработка модифицированного кукушкиного метода для решения задачи семантического поиска знаний

Еще одним методом биоинспирированной оптимизации является поиск кукушки (*Cuckoo Search, CS*). Он был разработан Янгом и Дебом в 2009 году [10, 74–78]. Одним из главных достоинств данного метода является малое число задаваемых параметров. За счет этого данный метод является более универсальным и эффективным в сравнении с другими биоинспирированными методами. На рисунке 5.13 представлена укрупненная структурная схема модифицированного метода поиска кукушки (ММПК) для решения задачи оценки эквивалентной семантической близости.

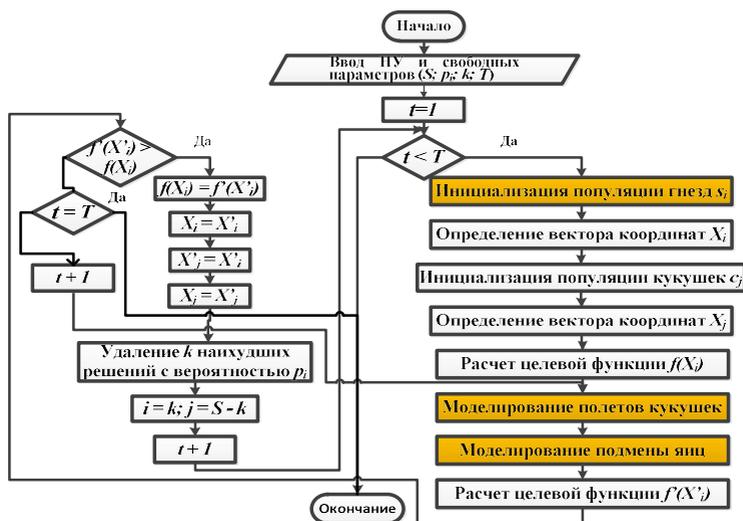


Рис. 5.13. Структурная схема модифицированного метода поиска кукушки

Здесь в каждом гнезде кроме настоящего находится чужое подложенное, которое имеет определенную степень сходства с оригинальным. Тогда оригинальному яйцу будет соответствовать элемент «верхнего» подмножества R_a^1 , $a \in [1: N]$, при ($\alpha = 1$), а чужое – «нижнему» подмножеству R_b^2 , $b \in [1: M]$ при ($\alpha = 0$). При этом ЦФ будет являться степенью сходства данных подмножеств. Ее необходимо максимизировать. Для этого необходимо подложить в гнездо такое «яйцо» R_y^2 , $y \in [1: M]$, $y \neq b$, где y – случайно выбранная вершина онтологии O_2 , у которого степень сходства больше с «яйцом» R_a^1 будет больше, чем у R_b^2 . Это позволяет повысить вероятность выживаемости за счет сходства [79]. Опишем работу метода более подробно.

1. Для реализации поиска используем шаги 1–4 из модифицированного метода обезьян.

2. Далее установим число итераций $t = 1, t \in [1: T]$, где T – максимум.

3. Сгенерируем из пар подмножества атрибутов рассматриваемых онтологий популяцию гнезд s_i , $i \in [1: S]$ из S хозяйских гнезд. Затем определим векторы координат гнезд X_i . При этом вероятность обнаружения в них чужих яиц будет задаваться случайно из множества $p_i \in (0:1)$.

4. Далее в онтологии O_2 , сгенерируем новую популяцию кукушек c_j , $j \in [1: S]$ с координатами X_j .

5. Затем для каждого нового гнезда вычисляем ЦФ $f(X_i) = f(R_a^1 \cap R_b^2)$, а при достижении максимального числа итераций конец работы.

6. Моделируем полет случайно выбранной кукушки c_j в случайно выбранное гнездо s_i , меняя при этом в имеющемся решении подмножество R_b^2 на подмножество R_y^2 , причем, $\forall y, b, y \neq b$.

7. После моделирования получаем новое значение ЦФ $f'(X'_i) = f(R_a^1 \cap R_y^2)$.

8. При чем если $f'(X'_i) > f(X_i)$, тогда $f(X_i) = f'(X'_i)$, а $X_i = X'_i, X'_j = X'_i, X_j = X'_j$, т.е. если условие выполняется, то происходит подмена яйца, а если нет то рассматривается другое гнездо.

9. Далее из популяции удаляется заданное число k , $k \in [1: S/2]$ наихудших решений-гнезд с вероятностью p_i , а на их место генерируются новые пары решений-гнезд $i = k$ и недостающее число новых кукушек $j = S - k$. Процесс продолжается итерационно.

Заметим, что начальные координаты гнезд и кукушек являются случайными, равномерно распределенными в пространстве вершин рассматриваемых онтологий. А траектория движения кукушки рассчитывается на основе полетов Леви [74,79]:

$$X'_j = X_j + V \otimes L_{|X|}(\lambda), \quad (5.9)$$

где $V = (v_z, z \in [1: |X|])$ – вектор размера шагов по соответствующим компонентам вектора X ; $L_{|X|}(\lambda) = (|X| \times 1)$ – случайный вектор независимых вещественных случайных чисел, распределенных по закону Леви [74, 79] (рис. 5.14).

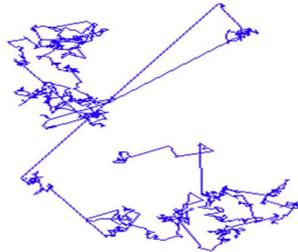


Рис. 5.14. Визуальная модель реализации полетов Леви

Здесь выражение (5.9) позволяет поддерживать траекторию агента, как совокупность малого числа больших (глобальных) перелетов и значительного числа – малых (локальных). В случае, если агент сразу не попадает в координаты свободного гнезда, тогда он перемещается в ближайшее из возможных (рис. 5.15).

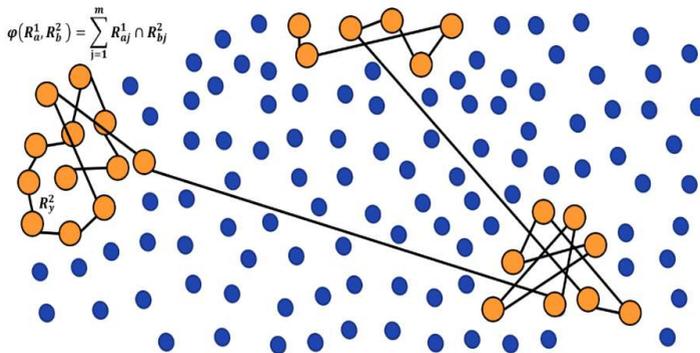


Рис. 5.15. Иллюстрация работы механизма поиска модифицированного кукушкиного метода

Отметим, что эффективность данного метода обеспечивается за счет улучшенного механизма отбора решений и аттрактивности применяемых процедур.

5.6. Программное приложение и вычислительный эксперимент

Для подтверждения эффективности предложенных методов и проведения вычислительного эксперимента создано программное приложение, архитектура которого представлена на рисунке 5.16.

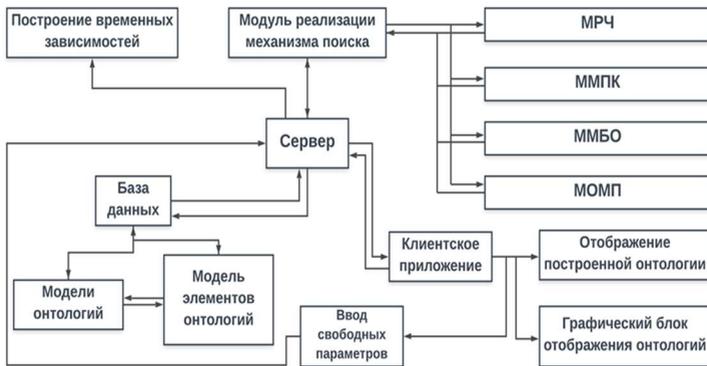


Рис. 5.16. Архитектура программного приложения

Архитектура данного приложения включает в себя блоки: построения онтологий, базы данных, введения свободных параметров методов, получения сравнительных оценок решений и реализации механизмов поиска на основе модифицированных биоинспирированных методов. В качестве значений атрибутов применялись усредненные абстрактные показатели, полученные случайным образом.

На основе созданного программного приложения был проведен вычислительный эксперимент, подтверждающий эффективность основных предложенных в работе моделей и методов.

В приложении генерировался ряд онтологий разных размерностей, затем создавались их полные копии, в которых случайным образом менялись атрибуты 5, 10, 15 и 20 процентов концептов. Затем, зная процент совпадения измененных копий с оригиналами проводился семантический поиск знаний в виде процедуры отображения полученных пар онтологий.

Для каждого из разработанных методов проводилось по три группы экспериментов исследования временных зависимостей. При применении модифицированного метода бактериальной оптимизации (ММБО) рассмотрены: зависимости времени работы метода от размера онтологий (табл. 5.1), от количества шагов хемотаксиса (табл. 5.2), и от размера популяции агентов (табл. 5.3).

Таблица 5.1

Зависимость времени работы ММБО от размера онтологий

№	Размер онтологий, ед	Длина хемотаксиса, шт	Размер популяции агентов, ед	Время работы, мс
1	10000	10	10	25.528
2	100000	10	10	52.562
3	500000	10	10	106.123
4	10000	100	100	109.269
5	100000	100	100	275.824
6	500000	100	100	512.364
7	10000	1000	1000	478.857
8	100000	1000	1000	1567.563
9	500000	1000	1000	4862.563

Таблица 5.2

Зависимость времени работы ММБО от длины хемотаксиса

№	Размер онтологий, ед	Длина хемотаксиса, шт	Размер популяции агентов, ед	Время работы, мс
1	100000	10	10	54.763
2	100000	100	10	206.388
3	100000	1000	10	397.234
4	100000	10000	10	920.465
5	100000	10	100	172.641
6	100000	100	100	377.356
7	100000	1000	100	668.671
8	100000	10000	100	1034.632
9	100000	10	1000	485.345
10	100000	100	1000	1021.563
11	100000	1000	1000	1734.583
12	100000	10000	1000	2618.148

Таблица 5.3

Зависимость времени работы ММБО от числа агентов

№	Размер онтологий, ед	Длина хемотаксиса, шт	Размер популяции агентов, ед	Время работы, мс
1	100000	10	10	35.546
2	100000	10	100	253.456
3	100000	10	1000	412.123
4	100000	10	10000	703.563
5	100000	100	10	231.388
6	100000	100	100	354.356
7	100000	100	1000	551.764
8	100000	100	10000	819.648
9	100000	1000	10	472.234
10	100000	1000	100	673.634
11	100000	1000	1000	1734.588
12	100000	1000	10000	3332.451

При применении модифицированного обезьяньего метода поиска (ММП) рассмотрены и проанализированы: зависимости времени работы метода от размера онтологий (табл. 5.4); зависимости времени работы метода от количества локальных прыжков (табл. 5.5); и зависимости времени работы метода от количества глобальных прыжков (табл. 5.6).

Таблица 5.4

Зависимость времени работы ММП от размера онтологий

№	Размер онтологий, ед	Локальные прыжки, шт	Глобальные прыжки, шт	Время работы, мс
1	10000	10	1	21.531
2	100000	10	1	39.785
3	500000	10	1	97.234
4	10000	100	10	43.234
5	100000	100	10	119.546
6	500000	100	10	267.685
7	10000	1000	100	238.336
8	100000	1000	100	1564.234
9	500000	1000	100	3703.594

Таблица 5.5

Зависимость времени работы МОМП от числа локальных прыжков

№	Размер онтологий, ед	Локальные прыжки, шт	Глобальные прыжки, шт	Время работы, мс
1	100000	100	10	119.546
2	100000	1000	10	323.456
3	100000	10000	10	651.409
4	100000	100	100	586.102
5	100000	1000	100	1577.108
6	100000	10000	100	2312.274
7	100000	100	1000	1421.563
8	100000	1000	1000	3564.223
9	100000	10000	1000	7618.546

Таблица 5.6

Зависимость времени работы МОМП от числа глобальных прыжков

№	Размер онтологий, ед	Локальные прыжки, шт	Глобальные прыжки, шт	Время работы, мс
1	100000	10	1	37.634
2	100000	10	10	41.176
3	100000	10	100	78.811
4	100000	100	1	41.546
5	100000	100	10	123.746
6	100000	100	100	178.469
7	100000	1000	1	203.634
8	100000	1000	10	782.502
9	100000	1000	100	1591.744

При применении модифицированного метода поиска кукушки (ММПК) исследованы: зависимости времени работы метода от размера онтологий (табл. 5.7); зависимости времени работы метода от количества итераций (табл. 5.8), и зависимости времени работы метода от количества k удаляемых худших вершин-гнезд (табл. 5.9).

Таблица 5.7

Зависимость времени работы ММПК от размера онтологий

№	Размер онтологий, ед	Счетчик итераций, шт	Фильтр k , шт	Время работы, мс
1	10000	10	10	12.157
2	100000	10	10	21.308
3	500000	10	10	78.217
4	10000	100	100	65.705
5	100000	100	100	126.399
6	500000	100	100	224.211
7	10000	1000	1000	189.557
8	100000	1000	1000	346.611
9	500000	1000	1000	589.112

Таблица 5.8

Зависимость времени работы ММПК от количества итераций

№	Размер онтологий, ед	Счетчик итераций, шт	Фильтр k , шт	Время работы, мс
1	100000	100	10	129.387
2	100000	1000	10	222.146
3	100000	10000	10	563.109
4	100000	100	100	128.308
5	100000	1000	100	234.713
6	100000	10000	100	652.775
7	100000	100	1000	178.377
8	100000	1000	1000	343.765
9	100000	10000	1000	965.489

Временная сложность всех предложенных модифицированных биоинспирированных методов является полиномиальной и в среднем составляет $O(n^2)$. Исследование скорости работы предложенных модифицированных биоинспирированных методов проводилось в сравнении с каноническим методом роя частиц (МРЧ). Диаграмма сравнения временных характеристик модифицированных биоинспирированных методов и метода роя частиц представлена на рисунке 5.17.

Таблица 5.9

Зависимость времени работы ММПК от количества k
удаляемых худших вершин-гнезд

№	Размер онтологий, ед	Счетчик итераций, шт	Фильтр k , шт	Время работы, мс
1	100000	10	10	25.101
2	100000	10	100	119.367
3	100000	10	1000	210.985
4	100000	100	10	27.844
5	100000	100	100	125.113
6	100000	100	1000	231.778
7	100000	100	10	86.677
8	100000	100	100	212.909
9	100000	100	1000	417.245

Из анализа проведенных экспериментальных исследований видно, что разработанные методы показали сопоставимые результаты по времени и скорости решения с известными алгоритмами. А полученный модифицированный алгоритм поиска кукушки при всей его стохастичности имеет очевидное преимущество, например, перед модифицированным алгоритмом обезьяньего поиска, основанное на применении логики передвижения полетов Леви в онтологической структуре, позволяющей найти большинство локальных решений при достаточном количестве глобальных изменений области поиска.

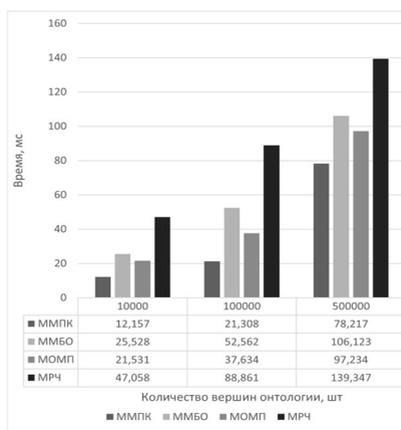


Рис. 5.17. Диаграмма сравнения временных характеристик

При этом качество решений данного алгоритма приближается к результатам, полученным при использовании модифицированного алгоритма бактериальной оптимизации, поиск в котором является процедурой более упорядоченной и эффективной.

Отметим, что все разработанные модифицированные биоинспирированные методы в работе демонстрируют высокие и соразмерные друг другу результаты по качеству поиска весомых отношений между отображаемыми онтологиями.

Таким образом, в 5-ой главе построена информационная модель оценки эквивалентной семантической близости, которая позволяет определить степень сходства предикатов понятий разных онтологий на основе процедуры их отображения. Описана разработка комплекса модифицированных биоинспирированных методов (бактериального, обезьяньего и кукушкиного поиска) с децентрализованной схемой управления для решения задачи семантического поиска знаний при отображении онтологических структур. Предложенные методы имеют полиномиальную сложность, что позволяет масштабировать их для достаточно больших размерностей информационного пространства поиска решений. Эффективность разработанных модифицированных биоинспирированных методов обусловлена введением в механизмы поиска элементов диверсификации информационного пространства, что повысило привлекательность применяемых процедур.

ГЛАВА 6. МЕМЕТИЧЕСКАЯ ПЕРЕДАЧА МАШИННОГО ЗНАНИЯ ПРИ РЕШЕНИИ ЗАДАЧ ПОИСКОВОЙ ОПТИМИЗАЦИИ

6.1. Эволюция алгоритмов поисковой оптимизации, инспирированных мемами

Начиная с одноклеточных организмов, которые появились миллиарды лет назад, эволюция постепенно сформировала экосистемы, характеризующиеся удивительным биологическим разнообразием. Механизмы естественного отбора наделили живые организмы способностью выживать, адаптироваться к вызовам природы. Однако биологическая эволюция – чрезвычайно медленный процесс, особенно на фоне невероятной скорости технологической эволюции в настоящее время. Многоклеточным организмам потребовались миллионы лет, чтобы эволюционировать от одноклеточных бактерий. Человеческая цивилизация смогла продвинуться от первых в мире механических транспортных средств до сверхзвуковых реактивных самолетов, космических аппаратов и беспилотных дронов всего за три столетия. Такая радикальная трансформация технологического развития управляется процессами, аналогичными процессам эволюции. Однако эта трансформация происходит в совершенно другом пространстве, а именно в пространстве научных знаний, культуры и идей, которые появляются у нас и могут распространяться почти мгновенно, по сравнению со скоростью распространения генетических признаков в разных популяциях.

В книге Р. Докинза «Эгоистичный ген» [80] впервые был введен термин «меметика», где мем рассматривался как основная единица передаваемой информации, а меметические вычисления (МВ) предусматривали обработку мемов как строительных блоков знаний, закодированных в машинных представлениях для повышения производительности искусственных эволюционных систем в области поисковой оптимизации. Преимущества использования эвристической информации (знаний) для ускорения поиска решений были хорошо известны и раньше. Уникальность МВ заключается в том, что эвристику больше не нужно формировать вручную. Вместо этого, используя передачу знаний, можно выявлять и использовать знания, в том числе генерируемые в Интернете, для автоматического поиска наиболее эффективного оптимизатора.

Более того, мемы могут распространяться между различными оптимизаторами, решающими различные задачи. Это своего рода машинное обучение без необходимости разработки пользователем новых алгоритмов оптимизации, инспирированных природой. Это является отличительной чертой нашего подхода от существующей узкой интерпретации меметических алгоритмов как гибрида задаваемых вручную эвристик поиска для некоторого базового эволюционного оптимизатора. Цель авторов состоит в том, чтобы разработать обучаемые оптимизационные механизмы за счет адаптивной интеграции мемов, накопленных опытным путем и/или за счет взаимодействия с другими механизмами. Данный подход неплохо согласуется с современными вычислительными платформами, такими как облачные вычисления и Интернет вещей. С использованием этих технологий МВ в будущем могут занять центральное место в механизмах оптимизации.

Идеи биоэволюции проникли в область машинного обучения и дали толчок к развитию алгоритмов, инспирированных природой (биоэвристик), существующих уже несколько десятилетий [81, 82]. С помощью биоэвристик исследуется пространство поиска, синтезируются решения, являющиеся точками этого пространства, запрашивается оценка их качества или «приспособленности», которая затем используется для осуществления «естественного отбора». Тем самым биоэвристики обучаются тому, какие области пространства поиска содержат наилучшие решения [83]. Однако в отличие от биоэвристик возможности меметики используются не в полной мере, учитывая, что Интернет позволяет получить доступ к большим объемам информации, запросив через поисковую систему подходящее решение проблемы, или передать полученные знания коллегам, распространив мемы знаний.

В связи с этим интерес представляет разработка новых моделей поиска и оптимизации в интеллектуальных системах поддержки принятия решений. Традиционные методы оптимизации к решению конкретных задач основаны на подходе в стиле *tabula rasa* («чистого листа»). Поиск решений начинается с нуля, с использованием стандартных операторов поиска при условии нулевого уровня предварительных знаний о подходах к решению проблемы. Это мало согласуется с тем, как мы решаем проблемы, привлекая имеющийся опыт и знания.

Интеллектуальные системы будут недолговечны, если они не будут использовать огромный объем доступной информации. С алгоритмической точки зрения мемы можно рассматривать как строительные блоки знаний, выраженные в эвристических представлениях, которые могут быть извлечены из опыта и адаптивно переданы для повторного использования в различных задачах, благодаря современным вычислительным инфраструктурам, таким как облачные вычисления и Интернет вещей (*IoT*), предлагающим крупномасштабное хранение информации и бесперебойные средства связи.

Рассмотрим подробнее основные этапы эволюции МВ.

Простота и сравнительная эффективность процессов, происходящих в природе, зачастую создают иллюзию разумного замысла, наделяя живые организмы способностью решать многие проблемы. Это породило убеждение, что моделирование этих процессов может привести к успешному созданию машинного интеллекта [81, 82]. К тому же многочисленные практические приложения биоэвристик эволюционных вычислений (ЭВ) свидетельствуют об их эффективности по сравнению с классическими процедурами оптимизации [83]. ЭВ представляют собой математические преобразования, позволяющие трансформировать входной поток информации в выходной по правилам, основанным на имитации механизмов эволюции, а также на статистическом подходе к исследованию ситуаций и итерационном приближении к искомому решению. Характерной особенностью ЭВ является то, что их механизмы стохастического поиска требуют от пользователя небольшого опыта в предметной области [84]. В отличие от многих классических процедур, которые требуют тщательной настройки параметров в соответствии с областью применения алгоритма [85].

Однако темпы разработки ЭВ в последнее время несколько снизились в сравнении с другими технологиями искусственного интеллекта, которые в последнее время добились значительных успехов во многом благодаря *IoT* и облачным вычислениям, которые обеспечили расширение возможностей подключения физических устройств, а также распространение разнообразных информационных потоков во всех аспектах человеческой и производственной деятельности. ЭВ для поисковой оптимизации продолжают придерживаться традиционного подхода в стиле *tabula rasa* к решению задач. К тому же ЭВ требуют для получения значимых результатов

немалых вычислительных ресурсов, что не удивительно, поскольку процесс эволюции в природе характеризуется астрономическими масштабами времени. Моделирование биологической эволюции без учета каких-либо внешних знаний идет слишком медленно, чтобы поддерживать быстрые технологические циклы проектирования и производства. Меметический подход предполагает, что «обучение» занимает центральное место в качестве фундаментального аспекта поисковой оптимизации [86].

Идея МВ состоит в объединении ЭВ со всей доступной информацией о конкретной решаемой задаче [87]. Реальные задачи редко существуют изолированно. Многие из них либо повторяются, либо имеют особенности, зависящие от предметной области. Любая часть передаваемой информации, фиксирующая некоторую закономерность, специфичную для конкретной области, может представлять собой вычислительную реализацию мема. Способ передачи мемов и типы самих мемов могут быть различными [88]. Мемы знаний, полученные в результате конкретного опыта по решению проблем, могут передаваться от одного человека к другому, аналогично передаче мемов в их социальной коннотации. ЭВ поисковой оптимизации могут использовать ранее полученный опыт для решения новых задач. Например, алгоритм ЭВ выполняет исследование пространства возможных решений, а меметический модуль в это время запускается для активации наиболее важных строительных блоков знаний, т.е. мемов. Другими словами, происходит одновременное исследование задачи и цикл оптимизации.

Отличительной особенностью фреймворка является то, что мемы могут быть либо синтезированы «на лету» из информации, полученной в ходе поиска, и/или извлечены из прошлого опыта, из базы знаний в оптимизаторе. При этом требований к использованию какого-либо конкретного представления мемов не предъявляется. Иными словами, меметические вычисления обозначают любую вычислительную процедуру, которая отражает подобного рода фреймворк.

Первое поколение меметических алгоритмов (МА) [89] было шагом вперед в понимании мемов как строительных блоков знаний предметной области, способных повысить эффективность эволюционных алгоритмов для решения оптимизационных задач. Как

правило, это были гибридные алгоритмы, использующие несколько локальных схем поиска, представляемых экспертами предметной области. Например, в известной задаче о рюкзаке необходимо упаковать рюкзак предметами разной стоимости и веса, чтобы суммарная стоимость была максимальной при соблюдении ограничения на вместимость рюкзака [90]. Одна из эвристик (мем) упаковки – при переполнении рюкзака вначале удалять предметы с учетом соотношения стоимость/вес. Мем приводит к значительному ускорению производительности по сравнению с оптимизатором, основанным только на эволюционных механизмах.

Для данной задачи известно множество мемов. Согласно *NFL*-теореме Вольперта-Макрида (теорема об отсутствии бесплатного обеда в мышеловке) [91], подмножество мемов, которое в среднем хорошо справляется с одним классом задач, будет работать хуже при решении других задач. Поэтому для новой задачи необходимо использовать новую комбинацию мемов, причем искать эту комбинацию желательно автоматически, в режиме онлайн-адаптации локальных схем поиска, используя заранее заданный каталог эвристик (мультимемов) [92].

Второе поколение МВ также, в основном, ограничивалось разработкой гибридных МА и их применением к независимым задачам оптимизации, причем каталог используемых мемов указывался вручную заранее. Однако зависимость МВ от чисто случайных эволюционных процессов без экспертного руководства приводит к снижению характеристик производительности и точности для практических приложений, требующих решений в реальном времени. Это послужило толчком для концептуализации МВ, в которых механизмы эволюции дополняются знаниями о предметной области, выраженными в виде вычислительно закодированных мемов. Так возник канонический меметический алгоритм (КМА) [93].

В качестве примера для иллюстрации концепции КМА рассмотрим произвольную задачу оптимизации следующего вида:

$$\max_{X \in R^{|X|}} f(X) = f(X^*) = f^* \quad (6.1)$$

при условии $g_i(x) \leq 0, i = 1..|G|, h_j(x) = 0, j = 1..|H|$.

Здесь $f(X)$ – скалярная целевая функция, которая максимизируется в пространстве поиска $X, f(X^*) = f^*$ – искомое максимальное значение целевой функции, $X = (x_1, x_2, x_{|X|})$ – $|X|$ -мерный вектор варьируемых параметров $G = \{g_1, g_2, \dots\}$ и $H = \{h_1, h_2, \dots\}$ – множество

ограничений неравенств и равенств, выполнение которых необходимо для обеспечения выполнимости при заданном X (обозначение $||$ в (6.1) используется для указания мощности множеств), $R^{|X|} - |X|$ -мерное арифметическое пространство.

В КМА понятие мемов ограничивается математическими процедурами или эвристикой, которые служат локальными схемами поиска и гибридизируются с некоторым оптимизатором популяционного типа. КМА не накладывает никаких ограничений на X или $f(X)$. Если априори известно, что функция дифференцируема, а производные определены аналитически, то эти знания можно использовать при создании мема, специфичного для конкретной задачи. Однако произвольная комбинация эволюционных операторов и мемов может привести к снижению результирующей эффективности оптимизации.

Как известно, типичный популяционный алгоритм оптимизации содержит множество решений-кандидатов, которые итеративно обновляются (эволюционируют), следуя инспирированным природой операторам эволюции, которые направляют популяцию в области пространства поиска X с наилучшими значениями целевой функции $f(X)$ [81]. Операторы кроссингвера выполняют стохастическую рекомбинацию двух или более решений из популяции для создания новых решений-потомков. В ходе поиска предпочтения отдается решениям с наилучшими значениями целевой функции.

Однако на получение решений, близких к глобальному оптимуму влияет уровень разнообразия эволюционирующей популяции. Чем выше разнообразие, тем меньше вероятность преждевременной сходимости к локально оптимальному решению. Схемы локального поиска обрабатывают каждое решение в популяции изолированно и принимают вариант решения только в том случае, если это приводит к более высокому значению целевой функции.

Например, если в (6.1) функция является непрерывной и дифференцируемой в пространстве $X \in R^{|X|}$, широко используемой детерминированной схемой для уточнения локальных решений является метод градиента.

В частности, общая схема локального поиска на псевдокоде имеет вид алгоритма 6.1:

1. *Input*: начальное решение X
2. *repeat*

3. применяя метод локального поиска с начальным решением X , получаем решение X'
4. *if* $f(X') > f(X)$ *then*
5. $X \leftarrow X'$
6. *end if*
7. *until* (условие завершения локального метода поиска)
8. *return* $X, f(X)$

Тогда общая схема КМА имеет вид алгоритма 6.2:

1. Initialize: случайно создается популяция решений X_{pop}
2. *repeat*
3. *for* для каждого решения $X_i \in X_{pop}$
4. оценка $f_i(X_i)$
5. *if* X_i выбирается для локального поиска
6. $X', f(X') \leftarrow$ локальный поиск согласно алгоритму 6.1
7. $X, f(X) \leftarrow$ обновление по результатам локального поиска
8. *end if*
9. *end for*
10. Применение эволюционных операторов кроссинговера, мутации и селекции к текущей популяции для создания следующего поколения
11. *until* (условие останова)

Из алгоритма 6.2 видно, что не все особи в популяции выбираются для локальных улучшений. Другой интересный вопрос заключается в том, каким образом обновляются полученные в ходе локального поиска решения (шаг 7 алгоритма 6.2)? Ответ на этот вопрос приводит к классификации КМА на две разновидности: эволюция Ламарка [94] и эффект Болдуина [81] в зависимости от типа взаимодействия между модулем меметики и ЭА.

Согласно эволюции Ламарка, кодирование решения (генотип) и целевая функция одновременно изменяются в процессе эволюционного обучения (хотя такой эффект считается биологически неправдоподобным, однако обнаружено, что это ускоряет сходимость КМА [86]).

В отличие от эволюции Ламарка, эффект Болдуина не предполагает прямого изменения генотипа решения. В контексте алгоритма 6.2 это означает, что на шаге 7 обновляется только $f(X)$, в то время как X остается неизменным. В результате, даже если целевая функция некоторого решения не является максимальной, у него имеется шанс произвести потомство.

Стратегия поиска Болдуина иногда может быть более эффективной, нежели стратегия Ламарка, с точки зрения сходимости к глобальному оптимуму. Однако скорость сходимости в результате эффекта Болдуина медленнее. В [86] были представлены результаты эмпирического исследования КМА согласно эволюции Ламарка. В качестве примера была взята хорошо известная задача оптимизации сепарабельных булевых функций [95]. Показано, что сочетание эволюционных процессов со случайно подобранными мемами может привести к снижению производительности.

Для канонических форм меметических алгоритмов практический подход к решению проблемы заключается в том, чтобы либо тщательно протестировать производительность алгоритма на репрезентативных задачах из интересующей области, либо полагаться на экспертов предметной области при выборе локальной схемы поиска, которая оправдывала себя в прошлом при решении сходных проблем.

Совсем недавно, в связи с распространением технологий облачных вычислений, хранения данных, беспроводным коммуникационным средствам и технологии *IoT*, преимущества МВ начали выходить на первый план [96,97]. Доступность информации из разных источников, подразумевает возможность непосредственного извлечения мемов. Мемы, фиксирующие различные формы знаний о решении задач, становятся доступными для повторного использования. Оптимизаторы МВ могут автоматически использовать передаваемые мемы для организации поиска.

6.2. Проблема выбора мемов при решении задач поисковой оптимизации

Рассмотрим проблему, связанную с выбором конкретного мема из каталога мемов и оценкой вычислительных ресурсов, при решении задачи поисковой оптимизации.

Концепция мультимемов обеспечивает унифицированное изложение различных стратегий выбора и онлайн-адаптации для МВ. Самой простой стратегией, пожалуй, является случайный равновероятный выбор мема из каталога мемов [98]. Гарантии, что выбранный мем окажется подходящим для рассматриваемой задачи оптимизации, в этом случае нет. Другой стратегией к выбору мема является жадная стратегия, с которой связаны определенные вычислительные затраты [99].

Обе стратегии имеют одну общую черту – они не используют знания и данные, полученные в течение всего процесса оптимизации [10]. Существуют стратегии адаптации для МВ, использующие мемы, получаемые в процессе решения оптимизационной задачи. К ним относятся адаптивное металамаркистское обучение [101], мера эволюционности [92], множество мемов [102], мультисуррогаты [103].

Основная идея, лежащая в основе адаптивной металамаркистской стратегии обучения, состоит в том, чтобы оценить эффективность каждого мема из множества мемов, собранных для поисковой оптимизации. Согласно этой стратегии при выполнении мема он получает вознаграждение η в размере равном $\eta = \beta \cdot \Delta f / t_r^{LS}$, где $\Delta f = f(x_{mod}) - f(x)$; где $f(x)$ – начальная пригодность мема, $f(x_{mod})$ – пригодность мема после его применения, t_r^{LS} – общий премиальный бюджет, выделенный для мема, β – коэффициент масштабирования. В соответствии с адаптивной металамаркистской стратегией обучения, мем выбирается в зависимости от продемонстрированной эффективности поиска для решения поставленной задачи оптимизации.

Согласно стратегии меры эволюции, начальная стадия МВ, проводится аналогично адаптивной металамаркистской стратегии обучения со случайным выбором операторов вариации и мемов. Это позволяет собрать достаточно информативный набор данных D за определенное количество предварительных поколений МВ. Собранные данные разбиваются на несколько подмножеств вместе со значениями пригодности каждого мема, которые были достигнуты. Далее, определяются мемы с максимальной мерой эволюции.

В указанных выше стратегиях обучения решение-кандидат подвергается локальным доработкам под действием только одного мема, который адаптивно выбирается из множества вариантов. Более гибкое поведение в процессе обучения происходит с использо-

ванием комплекса мемов M [104]. В рамках комплекса мемов отдельные мемы взаимодействуют, усиливая друг друга, образуя структуру меметической стабильности. Другими словами, вместо того, чтобы выбирать один мем, акцент делается на создании сети мемов, которые участвуют в коллективном обучении. При этом каждый мем может выполнять определенную роль и дополнять другие мемы в ходе оптимизации. Мемы, составляющие комплекс мемов M , берутся из существующего каталога доступных мемов и образуются сеть мемов. В процессе обучения мемы из комплекса последовательно активируются. Все пары мемов (m_j, m_k) в сети соединены друг с другом ребром, имеющим вес w_{jk} , который указывает на силу связи между ними. Сильная связь означает, что активация одного мема приводит к активации другого мема. Матрица весов сети мемов имеет следующий вид:

$$W_M = \begin{bmatrix} w_{11} & \cdots & w_{1,|M|} \\ \vdots & \ddots & \vdots \\ w_{|M|,1} & \cdots & w_{|M|,|M|} \end{bmatrix}, \quad (6.2)$$

где w_{kk} обозначает уровень эффективности отдельного мема m_k . С учетом структуры сети мемов и матрицы весов W_M процедура локального поиска в МВ выглядит иначе, чем алгоритм 6.2. Сначала из комплекса мемов выбирается начальный мем $m_j \in M$ с вероятностью $p(m_j)$, которая задается как

$$p(m_j) = \frac{w_{jj}}{\sum_{i=1}^{|M|} w_{ii}}. \quad (6.3)$$

После выбора начального мема образуется цепочка мемов, которые последовательно применяются в ходе решения задачи. При этом выбор каждого последующего мема определяется вероятностно на основе распределения,

$$p(m_k) = \frac{[w_{kk}]^{\alpha_1} [w_{jk}]^{\alpha_2}}{\sum_{m_i \in M'} [w_{ii}]^{\alpha_1} [w_{ji}]^{\alpha_2}}, \quad (6.4)$$

где α_1 и α_2 – параметры, которые контролируют относительную эффективность отдельного мема и связи между мемами соответственно. При построении цепочки мемов, когда значение $|M|$ велико, ее длина ограничивается некоторой величиной L_M . В результате сложных взаимодействий мемов могут создаваться уникальные комбинированные эффекты МВ. На практике о весовой матрице W_M , бывает мало что известно априори. Поэтому оптимизация начинается с инициализации W_M , так чтобы обеспечить равные возможности для

активации каждого мема. После этого матрица весов обновляется в соответствии с накопленным вознаграждением, аналогично металамаркистской стратегии обучения. Таким образом выявляется потенциал отдельных мемов, а сетевые веса систематически согласуются с особенностями рассматриваемой задачи оптимизации.

Относительно узким, но трудоемким классом являются задачи оптимизации, в которых необходимо многократно вычислять достаточно сложные целевые функции, требующие для вычисления значительных ресурсов. Например, задачи в области инженерного проектирования, когда для оценки альтернативных проектов требуются часы численного моделирования или сложных физических экспериментов [105]. Популярным подходом для решения подобного рода проблем является мультисуррогатный подход к оптимизации [106]. Суррогат – это относительно простая с вычислительной точки зрения модель реальной целевой функции. Оптимизация с помощью суррогатов начинается с выборки небольшого числа n точек в пространстве поиска, в соответствии с которыми оцениваются значения реальной целевой функции для формирования набора данных

$$D = \{x_s, f(x_s)\}_{s=1}^n \quad (6.5)$$

После этого алгоритм строит на D суррогатную модель регрессионного типа. Разновидностью методов с суррогатной поддержкой является байесовская оптимизация, которая использует вероятностные оценки $f(x)$ [107]. Иными словами, разумно выбрать или найти некоторую комбинацию мемов, которые аппроксимируют целевую функцию с максимальной точностью.

Представленные стратегии выбора мемов при решении задач поисковой оптимизации определяют дальнейшие направления автоматизации интеграции мемов в процессе разработки алгоритмов гибридной оптимизации.

6.3. Меметический автомат для передачи машинного знания при поисковой оптимизации

Чтобы приблизить меметические вычисления к нашему умению решать задачи, предлагается концепция меметических автоматов [80–82].

Термин «автомат» обычно относится к самоуправляемой машине, реализующей определенный алгоритм. В контексте МВ меметический автомат рассматривается как программный агент (оп-

тимизатор), способный к обучению и автономному поведению. Понятие мема в этом случае не ограничивается сферой локального поиска, а расширяется до разнообразных форм знаний о решении той или иной задачи. Благодаря адаптивной управляемой данными интеграции мемов знаний, меметические автоматы могут восприниматься как своего рода машинное мышление, помогающее пользователям определить особенности задачи и действия, которые программный агент должен предпринять для ее решения.

С учетом современные возможности доступа к информации через Интернет, концепция меметических автоматов может оказать определенное влияние на будущее алгоритмов оптимизации. В рамках этой концепции попробуем интерпретировать мемы как вероятностные строительные блоки знаний, формализовать способы, которые могут быть использованы для повышения производительности оптимизации. Эффективность оптимизации должна расти по мере роста базы знаний мемов.

Любая практически полезная система в реальных условиях, как правило, решает большое количество задач, многие из которых являются либо повторяющимися, либо имеющими некоторые общие черты. Именно способность использовать знания предметной области отличает эксперта от обычного пользователя. В машинном обучении идея использования имеющейся информации из связанных источников для повышения точности решения целевой задачи получила название трансфертное обучение [105].

Что касается меметических автоматов, то возникает необходимость в разработке новых алгоритмов, способных собирать и использовать повторяющиеся закономерности между задачами в режиме онлайн на основе данных, полученных в ходе поиска. С аппаратной точки зрения передаче закодированных в компьютерной форме мемов должны способствовать облачные технологии и технологии *IoT*, способные поддерживать крупномасштабное хранение данных и бесперебойную связь между машинами [108].

Большинство реальных проблем имеют повторяющийся характер, поэтому нет смысла рассматривать их изолированно. Рассмотрим множество из K автономных задач оптимизации F_1, F_2, \dots, F_K , принадлежащих областям D_1, D_2, \dots, D_K соответственно. Здесь об-

ласть D_k будет представляться пространством поиска X_k ; и вспомогательным пространством Y_k , которое включает в себя все возможные условия оптимизации.

В качестве примера приведем задачу оптимизации конструкции крыла самолета. Целью задачи является минимизация общего сопротивления, действующего на крыло, при соблюдении заданной скорости полета (число махов) [109]. Различные самолеты предназначены для полетов на разных скоростях, поэтому конструкции крыла у них различаются. Иными словами, множество возможных конструкций крыла составляет пространство поиска, а число махов является вспомогательной переменной, определяющей условия эксплуатации самолета. Различные крейсерские скорости приводят к появлению альтернативных конструкций, которые могут иметь общие черты сходства.

С учетом вышесказанного, для данной задачи F_k в D_k элемент $y_k \in Y_k$ используется для обозначения условий эксплуатации. Кроме того, задача оптимизации F_k характеризуется функцией пригодности f_k , а также множеством ограничений-неравенств G_k и ограничительных равенств H_k . Тогда объединение различных сходных задач выражается в виде

$$F_k, \forall k \in \{1, 2, \dots, K\}: \max f_k(x, y_k) \text{ при условии } g_{ki}(x, y_k) \leq 0, \\ h_{ki}(x, y_k) = 0, \quad (6.6)$$

где $f_k: X_k \rightarrow \mathbb{R}$, причем y_k не является прямой частью поиска в уравнении (6.6), поскольку оптимизируются только решения $x \in X_k$.

Различие между (6.6) и стандартной формулировкой задачи оптимизации заключается в том, что здесь объединены K распределенных во времени задач. Оптимизаторы различных задач могут взаимодействовать друг с другом через Интернет, а результаты решения для одной задачи передаются для решения другой задачи. При поддержке облачной инфраструктуры знания, полученные в результате прошлого опыта решения проблем хранятся в онтологической базе знаний и доступны для повторного использования. Вычислительная сеть, в которой каждая автономная задача представляется отдельной вершиной, а ребро между вершинами указывает на передачу мемов между ними, моделирует распространение мемов знаний аналогично передаче сообщений в социальных сетях.

Возникает вопрос: приведет ли к повышению производительности подобного рода концепция передачи знаний? Понятно, что если пара

задач не имеет абсолютно ничего общего, то передача знаний от одной к другой, скорее всего, не даст преимущества. Случайная передача мемов вряд ли целесообразна. Необходимы методы оценки взаимозависимости и скрытой корреляции между задачами оптимизации с помощью онлайн-обучения, основанного на знаниях.

Рассмотрим некоторые качественные показатели взаимосвязи между задачами с точки зрения ожидаемой полезности передачи мемов.

Пусть $V_k = X_k \times Y_k$ представляет множество всех функций, охватываемых пространством поиска X_k ; и вспомогательным пространством Y_k в области D_k . Классифицируем пары задач оптимизации следующим образом: полное перекрытие областей, частичное перекрытие областей, полностью неперекрывающиеся области.

Тогда для любых двух задач оптимизации F_1 и F_2 соответствующие им области применения D_1 и D_2 считаются полностью перекрывающимися, если функции, охватываемые их соответствующими наборами функций, семантически идентичны, т.е. выполняется соотношение $V_1 = V_2$. Если обозначить пересечение множества функций как $V_{\cap} = V_1 \cap V_2$, то имеем

$$V_1 \setminus V_{\cap} = \emptyset \ \& \ V_2 \setminus V_{\cap} = \emptyset. \quad (6.7)$$

Поясним понятие полного перекрытия областей на ранее рассмотренном примере проектирования крыла самолета. Пусть задача F_1 включает в себя настройку геометрических параметров крыла для небольшого гражданского транспортного самолета малой и средней дальности, предназначенного для полетов со скоростью до 0,78 махов. Задача F_2 включает настройку тех же параметров, но для большого дальнемагистрального самолета, который предназначен для полета с крейсерской скоростью 0,86 махов. Эти две задачи различны, однако можно ожидать, что знания, полученные в результате решения одной задачи оптимизации, скорее всего, будут полезны для другой задачи.

Области D_1 и D_2 считаются частично перекрывающимися, если существует подмножество функций, которое уникально по крайней мере для одной задачи. Это условие может быть выражено как

$$V_{\cap} \neq \emptyset \ \& \ (V_1 \setminus V_{\cap} \neq \emptyset \vee V_2 \setminus V_{\cap} \neq \emptyset) \quad (6.8)$$

Примером частичного перекрытия областей является задача F_2 проектирования крыла самолета, в котором, в дополнение к настройке геометрических переменных, также оптимизируется

конфигурация материалов, из которых состоит крыло. По сравнению с предыдущим примером пространство функций дополняется переменными, представляющими материалы, из которых состоит крыло. Пространство поиска расширяется, однако некоторые передаваемые знания могут пригодиться в пределах перекрывающихся элементов, относящихся к геометрическим свойствам проектируемых крыльев. Таким образом, взаимосвязь, подразумеваемая непустым перекрытием, потенциально может быть использована меметическим автоматом.

Наконец, две области считаются полностью неперекрывающимися, если

$$V_{\cap} = \emptyset. \quad (6.9)$$

Другими словами, нет очевидных взаимосвязей между парой оптимизационных задач, например, одна задача имеет непрерывные функции, а другая задача дискретна, или наоборот. При этом между задачами не исключена возможность существования скрытых корреляций, которые могут быть выявлены при анализе данных, специфичных для конкретных задач.

В идеале, с увеличением значений отношения $|V_{\cap}| / |V_1 \cup V_2|$ можно ожидать, что эффективность передачи мемов будет расти.

Отметим важность унификации пространства поиска. Представим себе собрание людей разных национальностей, говорящих на разных языках. Они могут поделиться друг с другом полезной информацией только если владеют некоторым общим языком, или имеется переводчик, говорящий на нескольких языках. Аналогично, при инициализации передачи мемов в различных задачах с неполным перекрытием предметных областей, необходимость эквивалентного вычислительного транслятора для разнородных меметических автоматов приводит к понятию унификации пространства поиска для обеспечения общности постановки множества оптимизационных задач [86].

Унифицированное пространство поиска X должно охватывать пространства поиска всех задач. Решение $x \in X_k$ задачи F_k может быть декодировано в любом другом пространстве X_1 , или X_2 , ..., или X_k . Мемы, соответствующие одной задаче, могут быть переданы любой другой задаче через унифицированное пространство. Унифицированное пространство позволяет взаимодействовать меметическим автоматам, решающим различные задачи оптимизации. Для

кодирования дискретных решений можно использовать случайные векторы в многомерном пространстве. В частности, каждое случайное число, выбранное из непрерывного диапазона $[0, 1]$, служит ключом для декодирования.

Пусть размерности пространств поиска оптимизационных задач F_1, F_2, \dots, F_K в многозадачной постановке равны d_1, d_2, \dots, d_K соответственно. Тогда размерность X может быть определена как:

$$d_{un} = \max\{d_1, d_2, \dots, d_K\}. \quad (6.10)$$

При кодировании с использованием случайного ключа унифицированное пространство будет иметь размерность $[0, 1]^{d_{un}}$. Процедура унификации позволяет ускорить вычислительную процедуру обобщения предметной области и облегчает коммуникацию между разнородными меметическими автоматами.

Решение-кандидат x представляет точку, закодированную в унифицированном пространстве поиска X , из которого оно может быть декодировано в решение для других задач X_1 , или X_2 , ..., или X_K .

Рассмотрим любую задачу оптимизации f_k в унифицированном пространстве X :

$$F_k: \max_{p_k(x)} \int f_k(\psi_k^{-1}(x), y_k) \cdot p_k(x) \cdot dx. \quad (6.11)$$

Здесь ψ_k^{-1} указывает на декодирование (обратное отображение) решения x , а $p_k(x)$ представляет распределение вероятностей в пространстве X . В начале поиска известный набор ограничений генерирует распределение $p_k^0(x)$ на X :

$$p_k^0(x) > 0 \quad \forall x \in X_a, \quad (6.12)$$

где $X_a \subseteq X$ – множество всех допустимых решений F_k . В процессе поисковой оптимизации это распределение сходится к некоторому $p_k^i(x)$. Вероятностная модель представляет собой интерпретацию мема знаний $m_k \rightarrow p_k^i(x)$.

В аналогичных задачах оптимальные решения могут быть найдены при использовании мемов из накопленной базы знаний $M = \{m_1, m_2, \dots\}$, причем каждый раз при возникновении новой задачи база знаний пополняется:

$$M \leftarrow M \cup m_k.$$

Вероятностная интерпретация мемов знаний отличается от их обычной реализации в виде эвристики локального поиска, задаваемой вручную. Однако при наличии базы знаний мемов M возникает

необходимость в адаптивном отборе и интеграции мемов, содержащихся в M , всякий раз, когда возникает новая задача оптимизации. Проблема ассимиляции мемов осложняется тем, что M постоянно растет. Несмотря на это существует значительное преимущество в доступе к большой и разнообразной базе знаний. Чтобы быть точным, способность меметического автомата к решению оптимизационных задач должна монотонно расти с ростом M .

Вероятностное распределение $p_k^t(x)$ априори неизвестно. Тем не менее, наличие разнообразной базы знаний M позволяет меметическому автомату более эффективно определить целевое распределение, используя доступные мемы.

Множество из K задач оптимизации в многозадачной постановке может быть распределено по времени. Таким образом, для обучающихся меметических автоматов это распределение определяет направление передачи мемов. Представим математические формулировки постановок задач с точки зрения вероятностного моделирования.

В случае последовательной передаче знаний от задачи к задаче будем предполагать, что при решении задачи F_k база знаний M состоит из мемов задач, которые уже ранее решались. В результате, если мы рассматриваем F_k как цель, а F_1, F_2, \dots, F_{k-1} как набор ранее решенных задач, то поток мемов направлен от источников к цели. Тогда задача оптимизации F_k формулируется следующим образом:

$$\max_{\{w_1, \dots, w_{k-1}, w_k, p_k(x)\}} \int f_k(\psi_k^{-1}(x), y_k) \cdot \left[\sum_{k=1}^{k-1} w_k \cdot p_k^t(x) + w_k \cdot p_k(x) \right] \cdot dx, \text{ причем } \sum_{k=1}^k w_k = 1, w_k \geq 0. \quad (6.13)$$

При одновременной передаче знаний сразу многим задачам, в отличие от последовательной передачи мемов, где в данный момент оптимизируется одна целевая задача, сценарий многозадачности предполагает параллельное решение нескольких равноприоритетных задач. Математическая формулировка многозадачной оптимизации F_1, F_2, \dots, F_k записывается как

$$\max_{\{w_{jk}, p_j(x) \forall j, k\}} \sum_{k=1}^K \int f_k(\psi_k^{-1}(x), y_k) \cdot \left[\sum_{j=1}^K w_{jk} \cdot p_j(x) \right] \cdot dx,$$

причем

$$\sum_{k=1}^K w_{jk} = 1, \forall k, w_{jk} \geq 0, \forall j, k. \quad (6.14)$$

Здесь коэффициент смешивания w_{jk} означает влияние $p_j(x)$ из f_j на решение задачи f_k .

Рассмотрим процедуры последовательной и параллельной передачи мемов знаний подробнее.

6.4. Последовательный оптимизатор передачи мемов

Предположим, что множество задач, для решения которых привлекаются меметические автоматы, возникает одна за другой, так что передача мемов происходит последовательно от задачи к задаче. В связи с этим возникает проблема, заключающаяся в необходимости отбора и интеграции мемов, соответствующих текущей целевой задаче. Предлагается подход, основанный на смешанном моделировании и адаптивной онлайн-интеграции, управляемой данными, полученными в ходе поисковой оптимизации.

При последовательной передаче знаний оптимизация целевой задачи F_K формулируется согласно (6.13). Для всех K задач сформировано унифицированное пространство поиска X .

Предположим, что для уже встречавшихся задач F_1, F_2, \dots, F_{K-1} сформированы мемы с вероятностными распределениями $p_1^i(x), p_2^i(x), \dots, p_{K-1}^i(x)$. Суть МВ заключается в использовании всех доступных мемов для ускорения оптимизации целевой задачи. Соответственно, математическая формулировка цели выражается как смесь вероятностных моделей источника и цели:

$$\max_{\{w_1, \dots, w_{K-1}, w_K, p_K(x)\}} \int f_K(\psi_K^{-1}(x), y_K) \cdot \left[\sum_{k=1}^{K-1} w_k \cdot \frac{p_k^t(x)}{p_k(x)} + w_K \cdot \right] \cdot dx, \\ \text{причем } \sum_{k=1}^K w_k = 1, w_k \geq 0, \forall k. \quad (6.15)$$

В (6.15) f_K является целевой функцией (мерой пригодности) для задачи F_K , ψ_K^{-1} – обратное отображение для декодирования векторов решений из X в X_K , y_K – вспомогательная переменная, w_1, \dots, w_K – веса, определяющие степень влияния мемов на поиск оптимального решения целевой задачи. Проще говоря, целью является повышение эффективности оптимизации меметического автомата, решающего задачу F_K , используя базу накопленных знаний.

Отличием предлагаемого подхода является попытка применять мемы знаний, полученные из различных исходных задач.

Отметим, что было предложено несколько основанных на меметических моделях схем передачи знаний: для задач кластеризации и ранжирования на графе, моделирующем маршрутизацию транс-

портных средств, для задачи оптимизации шумоподавляющих автокодеров [86]. Однако необходимо найти универсальную формализацию мемов, чтобы она охватывала различные типы моделей.

В случае последовательной передачи знаний между задачами основным условием является то, что при решении задачи F_K множество мемов (вероятностных моделей) $p_1^i(x), p_2^i(x), \dots, p_{K-1}^i(x)$, полученных из прошлого опыта решения задач F_1, F_2, \dots, F_{K-1} , имеются в базе знаний. Для всех K задач сформировано унифицированное пространство поиска X .

Отметим, что на тип вероятностной модели не накладывается никаких ограничений. Вероятностная модель может быть либо простым одномерным предельным распределением, либо байесовской сетью, либо моделью конечной смеси. Понятно, что тип вероятностной модели влияет на затраты на обучение. Однако, несмотря на дополнительные затраты на построение более выразительных моделей, они имеют определенное преимущество в эффективности оптимизации. Обоснование этого утверждения представлено в [110] в виде теоремы о сходимости, которая применима к классу алгоритмов оптимизации на основе вероятностных моделей. Следовательно, предлагаемая вероятностная меметическая модель передачи знаний гарантирует глобальную сходимость результирующего меметического автомата.

Рассмотрим популяцию решений $X_{pop,K}^t: \{x_1, x_2, \dots, x_{n_{pop}}\}$ на X целевой задачи F_K в некотором поколении t базового эволюционного алгоритма. Тогда основные шаги процедуры для нахождения оптимальных значений весовых коэффициентов w_1, \dots, w_K , определяющих степень влияния мемов на поиск оптимального решения целевой задачи, перечислены ниже:

Шаг 1. Множество решений $X_{pop,K}^t$ случайным образом разбивается на S -подмножеств. После этого вероятность каждого решения оценивается с использованием уже имеющихся $(K-1)$ -моделей. Оценки записываются в матрицу L размера $(n_{pop} \times K)$.

Шаг 2. Используя матрицу L , весовые коэффициенты w_1, \dots, w_K можно вычислить согласно

$$\max_{\{w_1, \dots, w_K\}} \sum_{j=1}^{n_{pop}} \log(\sum_{k=1}^K w_k \cdot L_{jk}), \quad (6.16)$$

применяя известный статистический алгоритм максимизации математического ожидания [111].

Шаг 3. Для завершения процедуры линейного агрегирования промежуточная целевая модель перестраивается на основе множества решений $X_{pop,K}^t$. Результатом является множество $(K-1)$ -моделей $p_1^t(x)$, $p_2^t(x), \dots, p_{K-1}^t(x)$ и $p_K^t(x)$ с весами, полученными на *Шаге 2*.

Рассмотрим алгоритмическую реализацию последовательного оптимизатора передачи мемов (ПОПМ).

Обозначим через Δt интервал передачи данных, определяющий частоту, с которой меметический оптимизатор запускается для передачи знаний от исходных задач в текущую целевую задачу оптимизации. Слишком малое значение Δt увеличивает затраты на оптимизацию. С другой стороны, если Δt слишком велико, то передача мемов знаний происходит слишком редко. Необходим баланс между использованием передачи знаний и вычислительными затратами.

Псевдокод ПОПМ имеет следующий вид.

1. Input: $M = \{p_1^t(x), p_2^t(x), \dots, p_{K-1}^t(x)\}; f_K; \Delta t$
2. Инициализация: популяция $X_{pop,K}^t$ и оценки $f_K(X_{pop,K}^t)$
3. $t := 1$
4. repeat
5. if $\text{mod}(t, \Delta t) \neq 0$ then
6. Применить операторы кроссинговер и/или мутация к $X_{pop,K}^t$
для генерации потомков в популяции $X_{pop,K}^c$
7. else
8. Отобразить $X_{pop,K}^t$ в унифицированное пространство поиска
 X через $\psi_K^{-1}(X_{pop,K}^t)$
9. Выполнить шаги 1 – 3 процедуры поиска значений весовых коэффициентов w_1, \dots, w_K , построить $p_K^t(x)$ на X
 $X_{pop,K}^c = \psi_K^{-1}$ [например, из $p_K^t(x)$]
10. end if
11. Оценить $X_{pop,K}^c$ как $f_K(X_{pop,K}^c)$
12. Элитная селекция и формирование следующей популяции
13. Элитная селекция и формирование следующей популяции $X_{pop,K}^{t+1}$ из $(X_{pop,K}^c \cup X_{pop,K}^t)$
14. $t := t + 1$
15. until Проверка условия останова алгоритма

Продemonстрируем эффективность последовательного оптимизатора передачи мемов знаний на примере проектирования нейроэволюционного контроллера для робота-тележки (рис. 6.1).

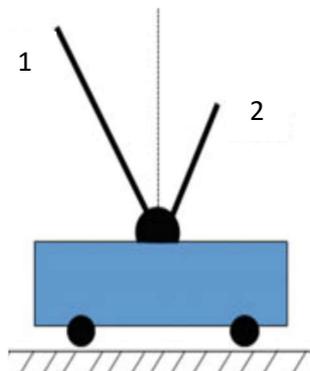


Рис. 6.1. Робот-тележка с двумя флагштоками

Задача состоит в том, чтобы создать для тележки с двумя флагштоками контроллер, способный удерживать баланс при условии, что флагштоки имеют разную длину, а тележка свободно перемещается по рельсовой колеи [112]. Тележка управляется путем приложения силы вдоль рельсового пути. Входным сигналом для контроллера является исходное состояние системы, включая положение и скорость тележки, а также угол наклона каждого флагштока относительно вертикали и угловые скорости двух флагштоков. Работа контроллера моделируется двухслойной нейронной сетью прямого распространения, состоящей из 10 скрытых нейронов скрытого слоя и одного выходного нейрона [113]. Функцией активации нейронов является гиперболический тангенс.

Задача считается невыполненной, если тележка выходит за пределы колеи длиной 4,8 м или если какой-либо из флагштоков отклоняется от вертикали более чем на 36 градусов. Наоборот, задача считается успешно решенной, если контроллер способен поддерживать баланс не менее, чем 30 минут. В задаче максимизируется функция пригодности, определяемая временем до сбоя системы. Цель оптимизатора состоит в том, чтобы настроить синаптические веса нейросетевого контроллера.

Длина флагштока 2 всегда короче, чем у флагштока 1, который имеет фиксированную длину $l_1 = 1$ м. Системе труднее поддерживать баланс, если длина флагштока 2 (l_2) приближается к 1 м. Численные эксперименты с простым эволюционным алгоритмом подтвердили, что балансировка системы оказывается относительно простой задачей при $l_2 \approx 0,1$ м. Если же длина l_2 превышала 0,7 м, то задача не решалась в рамках заданного времени. Возникает практический вопрос: возможно ли используя последовательный оптимизатор передачи мемов, полученных из предыдущего опыта решения более простых задач, решить похожую, но существенно более сложную задачу?

Было проведено сравнительное исследование между простым эволюционным алгоритмом [114] и ПОПМ. Целевая задача рассматривалась как вариант задачи балансировки тележки с двумя флагштоками с $l_1 = 1$ м, $l_2 = 0,8$ м. Оба алгоритма использовали идентичные операторы бинарного кроссинговера и полиномиальной мутации [115], элитарную селекцию и имели одинаковый вычислительный бюджет в размере 10000 оценок функций. ПОПМ имел доступ к мемам, взятым из предыдущих решений по проектированию контроллера для задач, где $l_2 = 0,6; 0,65; 0,7; 0,75$ и $0,775$ м соответственно. Интервал Δt передачи мемов в ПОПМ был установлен, равным 10 поколениям.

Эксперименты показали, что в ПОПМ вероятностным моделям, полученным из задач, в которых длина l_2 была значительно меньше 0,8 м, последовательно присваивается вес, близкий к нулю. Примечательно, что ПОПМ обучается в режиме онлайн, без вмешательства человека. Из множества доступных мемов алгоритм ПОПМ оказался способным автономно идентифицировать те мемы, которые являются наиболее полезными, он успешно присваивал таким мемам более высокую релевантность.

6.5. Параллельный оптимизатор передачи мемов

При последовательной передаче мемов решалась одна целевая оптимизационная задача, используя статическую базу знаний из мемов, извлеченных из прошлого опыта решения аналогичных задач. Передача мемов происходила в одном направлении. Рассмотрим случай одновременной многозадачной передачи знаний. Мо-

жет оказаться невозможным дожидаться завершения некоторых задач, чтобы сделать полученные мемы знаний доступными для других задач. Оптимизация должна выполняться параллельно, мемы, частично эволюционировавшие и обнаруженные в ходе поиска, передаются в динамическую базу знаний $M(t)$ для базового эволюционного алгоритма.

При параллельной передаче мемов задача формулируется согласно (6.14). Для всех K задач сформировано унифицированное пространство поиска X . В этом случае доступные мемы отражают распределение частично эволюционировавших популяций, а распределение характеризуется высокой дисперсией.

Предположим, что множество задач оптимизации тесно связано друг с другом, а решение, подходящее для одной из них, будет подходящим и для других задач. Рассмотрим популяцию решений $X_{pop,j}^t: \{x_1, x_2, \dots, x_{n_{pop,j}}\}$ в X в задачи F_j в некотором поколении t базового эволюционного алгоритма. Здесь n_{pop} представляет общее число решений в популяции. Поскольку в поколении t популяция эволюционировала лишь частично, то решения с более высоким значением целевой функции с большей вероятностью будут ближе к оптимальному. Для изучения мема, соответствующего F_j , имеет смысл сделать акцент на тех областях унифицированного пространства поиска X , которые связаны с решениями с высоким значением целевой функции. Для этого предлагается сгруппировать $X_{pop,j}^t$ в подмножества решений, близких с точки зрения их местоположения в пространстве X . После этого выбирается подмножество, содержащее решение с наибольшим значением целевой функции. Мем с вероятностным распределением $p_j^\mu(x|t)$ добавляется в общую базу знаний:

$$M(t) = \cup_{j \in \{1, \dots, K\}} p_j^\mu(x|t). \quad (6.17)$$

Поскольку вероятностная модель $p_j^\mu(x|t)$ представляет распределение локально сгруппированных решений, то распределение характеризуется меньшей дисперсией.

Таким образом, динамическая база мемов, созданная согласно (6.17), может быть применена для построения отдельной модели, соответствующей каждой задаче в рассматриваемом многозадачном режиме. Отметим, что в ходе рассмотрения задачи F_k

подмножество моделей, используемых для моделирования, составляет $M(t)P_k^u(x|t)$, поскольку мем, созданный самой задачей, естественно, избыточен.

Общая структура параллельного оптимизатора передачи мемов (ПаОПМ) имеет много общего с ранее описанным алгоритмом ПОПМ.

Псевдокод ПаОПМ имеет следующий вид.

1. Input: $f_k; \Delta t$
2. Инициализация: популяция $X_{pop,K}^1$ и оценки $f_k(X_{pop,k}^1)$
3. $t := 1$
4. repeat
5. $M(t) = \emptyset$
6. if $\text{mod}(t, \Delta t) \neq 0$ then
7. Применить операторы кроссинговер и/или мутация
к $X_{pop,k}^t$
для генерации потомков в популяции $X_{pop,k}^c$
8. else
9. Отобразить $X_{pop,k}^t$ в унифицированное пространство
поиска
 X через $\Psi_K(X_{pop,k}^t)$
10. $M(t) \leftarrow M(t) \cup P_k^u(x|t)$ # база мемов одновременно обновляется
для всех задач
11. $X_{pop,K}^c = \Psi_K^{-1}$ [например, из $P_k^u(x)$]
12. end if
13. Оценить $X_{pop,k}^c$ как $f_k(X_{pop,k}^c)$
14. Элитная селекция и формирование следующей популяции
 $X_{pop,k}^{t+1}$ из $(X_{pop,k}^c \cup X_{pop,k}^t)$
15. $t := t + 1$
16. until Проверка условия останова алгоритма ПаОПМ.

Тестирование алгоритма ПаОПМ проводилось на ранее рассмотренном примере проектирования нейроэволюционного контроллера для робота-тележки (рис. 6.1). Количество подмножеств, содержащих решение с наибольшим значением целевой функции, устанавливалось равным 5. Кластеризация выполняется с помощью алгоритма k -средних с евклидовой мерой расстояния. Экспе-

рименты показали, что параллельная передача мемов между простыми и более сложными задачами действительно приносит взаимную пользу друг другу.

В заключении отметим следующее. Дополняя базовый оптимизатор, например, эволюционный алгоритм, модулем меметики становится возможным реализовать поиск "на лету" при поддержке таких технологий как облачные вычисления и Интернет вещей, которые предлагают крупномасштабное хранение данных и бесперебойные средства связи. Объединенное пространство возможных конфигураций решений для взаимосвязанных задач естественным образом приводит к сценариям поисковой оптимизации, которые расширяют возможности существующих оптимизаторов. По существу, исчезает различие между модулем меметики и базовым оптимизатором, ускоряется производительность алгоритма по сравнению с традиционным подходом.

Перспективным направлением дальнейших исследований представляется обобщение идей меметического автомата для практического применения к решению масштабных задач поисковой оптимизации.

Таким образом, 6-ая глава посвящена разработке моделей обучения и передачи знаний за счет использования меметических вычислений, облачных технологий и Интернета вещей (*Internet of Things, IoT*) при решении задач поисковой оптимизации. Меметические вычисления являются новой парадигмой компьютеринга, в основе которой лежит понятие мема в качестве своеобразного строительного блока знаний. Анализируется эволюция алгоритмов поисковой оптимизации, инспирированных мемами, проблемы выбора мемов из базы знаний. Рассматривается модель меметического автомата для передачи машинного знания с целью повышения производительности интеллектуальных эволюционных систем при решении задач поисковой оптимизации. Предлагаются последовательный и параллельный оптимизатор передачи мемов.

ЗАКЛЮЧЕНИЕ

Основной целью описанных в данной монографии исследований является повышение эффективности интеллектуальных информационных систем на основе развития моделей, архитектур, алгоритмов и методов приобретения, управления и передачи знаний.

В начале работы проведен аналитический обзор эволюционного развития информационных технологий с точки зрения циклического сценария управления знаниями и иерархии развития технологий анализа данных, информации и знаний с перспективой перехода к процессам понимания в интеллектуальных системах. Основными классическими решаемыми задачами проводимого исследования являются: семантический поиск, структурирование, классификация и интеграция знаний. В работе представлены математические постановки данных задач. Разработан комплекс информационных моделей решения основных задач исследования на основе применения моделей рассуждений коалиций интеллектуальных агентов.

Представленные в работе модели интеллектуальных агентов отличаются от канонических введением новых когнитивных свойств, применяемых при описании известных психологических моделей характеристик личности эксперта. Усиление основных свойств используемых интеллектуальных агентов позволяет повысить эффективность процедур поиска.

Для создания поисковой среды предложена модель междисциплинарного пространства знаний, построенная на основе онтологических структур. Основное отличие данной модели заключается в использовании новых онтологических размерностей и семантических зависимостей, на основе которых создана классификация ряда типов оценок семантической близости, позволяющих определять сходство онтологий различных предметных областей при решении задач отображения и интеграции знаний.

На основе методов нечеткой логики, анализа иерархий и имитационного моделирования разработаны алгоритмы построения процессов приобретения и обработки знания в распределенных разнородных источниках. Применение данных алгоритмов позволяет обеспечить эффективное использование коалиций интеллектуальных агентов для решения задач совместного поиска (*collaborative search*) и фильтрации знаний (*knowledge sifter*).

Для определения моделей поведения интеллектуальных агентов (акторов) предложена подсистема оценка обстановки и разработан комплекс алгоритмов биоинспирированного поиска на основе модификации канонических алгоритмов бактериальной оптимизации, обезьяньего и кукушкиного поиска.

Основными результатами проведенных исследований являются следующие:

1. Проведен аналитический обзор современного состояния исследований в области задач приобретения и управления знаниями с точки зрения эволюции технологий проектирования интеллектуальных систем. Рассмотрены этапы качественного роста эффективности информационных технологий. Описаны процессы развития информационных технологий описаны по аналогии с процессами и системами живой природы. Проведен анализ основных моделей поведения и методов рассуждений в неструктурированных задачах реального мира. Исследованы возможности и перспективы развития методов управления знаниями на основе онтологий, когнитивных архитектур и моделирования рассуждений.

2. В результате проведенного аналитического обзора основных проблем и задач технологий управления знаниями построены и исследованы циклический сценарий и архитектура приобретения и управления знаниями в интеллектуальных системах, включающих уровни основных задач и инструментов для обработки ресурсов знаний предметных областей. Основной отличительной особенностью данных информационных моделей является комплексность и масштабность представления всех уровней и этапов процессов управления знаниями с учетом возможных пересечений и неявных отношений и связей между различными классами задач исследуемой проблемы.

3. Проведен анализ проблемы достоверного вывода при управлении знаниями в условиях большой размерности, распределенности и разнородности обрабатываемых источников. Сформулированы оригинальные постановки данных задач с учетом специфики процессов приобретения и управления знаниями.

4. Разработан комплекс моделей поведения интеллектуальных агентов, основной задачей которых является имитация системной организации и действий эксперта при решении задач управления знаниями. Данные модели отличаются от известных междисципли-

нарностью описания процессов рассуждений с применением известных из психологии характеристик стилей мышления человека. Предложена базовая модель легкого интеллектуального агента на основе потоковой модели круговорота ресурсов. Применение данных моделей в задачах приобретения и управления знаниями позволяет получить новое качество прогнозирования динамики развития на уровне отдельных групп субъектов, а не только на уровне всего массива агентов.

5. Впервые проведено теоретическое обоснование применения известных психологических теорий, описывающих стили мышления и способы учения человека, для создания комплексных междисциплинарных многоагентных моделей рассуждений. Полученные комплексные междисциплинарные модели позволяют воссоздать в упрощенном виде когнитивные процессы рассуждений человека на основе интеграции известных естественных и искусственных мыслительных процессов, что позволило развить методы приобретения знаний и повысить уровень компетенции интеллектуальных информационных систем.

6. Предложен метод анализа надежности моделей свойств интеллектуальных агентов, отличительной особенностью которого является использование в качестве исходных данных функций принадлежности и нечетких правил, характеризующих правильность выполнения операторных и логических элементов модели в зависимости от измеряемых параметров и влияющих факторов. Преимуществом данного метода является корреляция свойств интеллектуальных агентов и характеристик способов мышления и стилей учения, обеспечивающая выбор адекватной и полной модели прототипа системной организации эксперта для формирования модели поведения интеллектуального агента.

7. Созданы модель, метод и алгоритмы классификации знаний на основе коалиций интеллектуальных агентов. Отличительной особенностью проведенного моделирования процессов поиска и приобретения знаний в междисциплинарном пространстве знаний является использование технологии комбинирования гиперплоскостных классификаторов, что позволило эффективно и точно классифицировать массивы данных большого объема в двухмерном и трехмерном пространстве.

8. Построена событийная имитационная модель рассуждений с учетом условий достижимости на основе многоагентного подхода и сети Петри. В данной модели впервые использован интегрированный метод представления знаний. Эффективность предложенной модели продемонстрирована на примере решения задачи структуризации знаний.

9. Проведено моделирование информационных процессов в задачах управления знаниями. Для этого решены следующие подзадачи: – введены основные концептуальные понятия онтологической структуры семантических связей в междисциплинарном пространстве знаний, предложена ее абстрактная многоуровневая архитектура; – разработан метод интеграции знаний на основе принципа силовой релаксации. Отличительной особенностью метода является применение интеллектуальных акторов (агентов) для поиска неявных зависимостей и закономерностей между элементами знания различных предметных областей.

10. Создан комплекс информационных моделей для решения задач семантического поиска, классификации, структуризации и интеграции знаний. Построены информационные модели фильтра знаний на основе подхода совместного семантического поиска. Основным преимуществом данной фильтрации знаний является комбинирование совокупности действий по использованию новых агентной, мета- и case-моделей фильтра знаний для получения лучших решений. Также предложена формальная информационная модель классификации междисциплинарного пространства знаний. Оригинальность построенных моделей заключается в создании на первом этапе моделей структуризации содержательной и метасодержательной частей разнородных знаний предметной области, ставших в дальнейшем основой для построения интегрированной модели;

11. Разработан комплекс алгоритмов построения информационных процессов приобретения и управления знаниями. Созданные алгоритмы направлены на получение достоверных выводов при решении задачи структурирования.

12. Предложены новые онтологические размерности для оценки семантической близости концептов. Разработаны модификации алгоритмов, инспирированных бактериальным, обезьяньим и кукушкиным поиском, для решения задачи оценки семантической близости

сти. Проведены вычислительные эксперименты на тестовых примерах (бенчмарках). Модифицированные биоинспирированные алгоритмы показали лучшие результаты по времени и качеству решений по сравнению с аналогичными каноническими алгоритмами.

13. Для проведения экспериментальных исследований разработан программный модуль, включающий в себя функции построения онтологии, генерации набора атрибутов исследуемых событий и проведения оценки семантической близости на основе модифицированных биоинспирированных алгоритмов бактериальной оптимизации, обезьяньего поиска и поиска кукушек. В качестве значений атрибутов применены усредненные абстрактные показатели, полученные случайным образом с заданной вероятностью.

14. Рассмотрены аспекты разработки моделей обучения и передачи знаний за счет использования меметических вычислений, облачных технологий и Интернета вещей для задач поисковой оптимизации. Меметические вычисления являются новой парадигмой компьютерного инжиниринга, в основе которой лежит понятие мема в качестве своеобразного строительного блока знаний. Анализируется эволюция алгоритмов поисковой оптимизации, инспирированных мемами, проблемы выбора мемов из базы знаний. Рассматривается модель меметического автомата для передачи машинного знания с целью повышения производительности интеллектуальных эволюционных систем при решении задач поисковой оптимизации. Предлагаются последовательный и параллельный оптимизатор передачи мемов.

СПИСОК ИСПОЛЬЗУЕМЫХ СОКРАЩЕНИЙ

- АК – агент координатор;
АКК – агент комбинирования классификатора;
АОК – агент обучения классификатора;
БЗ – база знаний;
ВК – вершина классификатора;
ГИП – глобальное информационное пространство;
ДЕ – дидактические единицы;
ИА – интеллектуальный агент;
ИИ – искусственный интеллект;
ИИС – интеллектуальные информационные системы;
ИИСПЗ – интеллектуальные информационные системы приобретения знаний;
ИнфС – информационные системы;
ИО – информационный объект;
ИР – информационный ресурс;
ИС – интеллектуальные системы;
ИТ – информационные технологии;
МАИ – метод анализа иерархий;
МАИС – многоагентные интеллектуальные системы;
МВ – меметические вычисления;
ММ – модель мира;
ММБО – модифицированный метод бактериальной оптимизации;
ММПК – модифицированный метод поиска кукушки;
МОМП – модифицированный обезьяний метод поиска;
МПР – модуль построения рассуждений;
МРЧ – метод роя частиц;
ПК – персональный компьютер;
ПО – программное обеспечение;
МОО – модель оценки обстановки;
ПС – параметры системы;
СМ – способ мышления;
СС – самоорганизующиеся структуры;
СУ – стиль учения;

УВ – управляющие воздействия;
ФО – функциональная область;
ЭА – эволюционный алгоритм;
ЭС – экспертные системы;
ВО – Bacterial Optimization;
CHSCM – Combination Hyper Surface Classifiers Models;
CS – Cuckoo Search;
DDM – Distributed Data Mining;
HSC – Hyper Surface Classifier;
IoT – Internet of Things;
IT – Information Technologies;
MS – Monkey Search;
OWL – Ontology Web Language;
RDF – Resource Description Framework.

СПИСОК ИСПОЛЬЗУЕМОЙ ЛИТЕРАТУРЫ

1. Хорошевский В. Ф. Семантические технологии: ожидания и тренды / В. Ф. Хорошевский // Открытые семантические технологии проектирования интеллектуальных систем. 2012. №2. С. 143–158.
2. Достоверный и правдоподобный вывод в интеллектуальных системах / под ред. В. Н. Вагина, Д. А. Поспелова. – 2-е изд., испр. и доп. – М.: Физматлит, 2008. 712 с.
3. Казаков В. А. Технология организации и доступа к знаниям в интегрированном информационно-образовательном пространстве / В. А. Казаков, Ю. Ф. Тельнов // Труды 13-й национальной конф. по искусственному интеллекту «КИИ 2012». 2012. Т. 2. С. 193–204.
4. Кравченко Ю. А. Способы интеллектуального анализа данных в сложных системах / Ю. А. Кравченко, Д. Ю. Запорожец, А. А. Лежебоков // Известия КБНЦ РАН. 2012. №3 (47). С.52–57.
5. Gruber T. A Translation Approach to Portable Ontology Specification / T. Gruber // Knowledge Acquisition Journal. 1993. vol. 5. P. 199–220.
6. Кравченко Ю. А. Синтез разнородных знаний на основе онтологий / Ю. А. Кравченко // Известия ЮФУ. Технические науки. 2012. №11 (136). С. 216–221.
7. Емельянов С. В. Информационные технологии и вычислительные системы / С. В. Емельянов. – М.: Ленанд, 2011. 84 с.
8. Тимофеев С. В. Математическая модель распространения новой информации в обществе / С. В. Тимофеев // Вопросы теории и практики журналистики. 2020. Т. 9. №1. С. 5–17.
9. Корогодина В. И. Информация как основа жизни / В. И. Корогодина, В. Л. Корогодина. – Дубна: Феникс, 2000. 208 с.
10. Кравченко Ю. А. Информационные модели приобретения знаний и методы их классификации, структурирования, интеграции и семантического поиска: дис. ... д-ра техн. наук: 05.13.17 / Ю. А. Кравченко. – Таганрог: 2021. 314 с.
11. Бородакий Ю. В. Эволюция информационных систем (современное состояние и перспективы) / Ю. В. Бородакий, Ю. Г. Лободинский. – М.: Горячая линия – Телеком, 2011. 369 с.
12. Миков А. И. Информационные процессы и нормативные системы в IT: Математические модели. Проблемы проектирования. Новые подходы / А. И. Миков. – М.: КД Либроком, 2013. 256 с.

13. Капра Ф. Паутина жизни. Новое научное понимание живых систем / Ф. Капра; пер. с англ., под ред. В. Г. Трилиса. – М.: София, 2003. 336 с.
14. Курейчик В. В. Технологии интеллектуального анализа и извлечения данных на основе принципов эволюционного моделирования: коллективная монография / В. В. Курейчик, Ю. А. Кравченко, В. В. Бова [и др.] – Таганрог: Изд-во Технологического института ЮФУ, 2009. 124 с.
15. Гвоздева В. А. Информатика, автоматизированные информационные технологии и системы: учебник / В. А. Гвоздева. – М.: ИД ФОРУМ, НИЦ ИНФРА-М, 2013. 544 с.
16. Вернадский В. И. Химическое строение биосферы Земли и ее окружение / В. И. Вернадский. – М.: Наука, 2001. 376 с.
17. Вернадский В. И. Биосфера и ноосфера / В. И. Вернадский. – М.: Айрис-Пресс, 2004. 576 с.
18. Кравченко Ю. А. Многоуровневая архитектура сценария управления знаниями на основе онтологического анализа / Ю. А. Кравченко // Известия ЮФУ. Технические науки. 2015. №2 (163). С.186–195.
19. Рассел С. Искусственный интеллект. Современный подход / С. Рассел, П. Норвиг. – М.: Вильямс, 2019.
20. Акофф Р. Искусство решения проблем / Р. Акофф. – М.: Книга по требованию, 2012. 221 с.
21. Нгуен Б. Н. Классификация текстов на основе оценки семантической близости терминов / Б. Н. Нгуен, А. Ф. Тузовский // Известия Томского политехнического университета. 2012. Т. 320. № 5. С. 43–48.
22. Тоффлер Э. Третья волна / Э. Тоффлер. – М.: АСТ, 2010. 784 с.
23. Давенпорт Д. Как организации управляют тем, что они знают / Д. Давенпорт, Ф. Прусак. – 1998. 560 с.
24. Нонака Х. Компания – создатель знания. Зарождение и развитие инноваций в японских фирмах / Х. Нонака, И. Takeuchi. – М.: Олимп-Бизнес, 2003. 320 с.
25. Мильнер Б. З. Управление знаниями: эволюция и революция в организации / Б. З. Мильнер. – М.: 2003. 176 с.
26. Пригожин И. Самоорганизация в неравновесных системах / И. Пригожин, Г. Николис. – М.: Мир, 1979. 512 с.
27. Dorigo M. Ant Colony System: a cooperative learning approach / M. Dorigo, G. Maria // IEEE Trans. Evol. Comput. 1997. vol. 1. P. 53–66.

28. Кравченко Ю. А. Многоагентное моделирование в задачах управления знаниями / Ю. А. Кравченко // Сборник научных трудов по материалам VII межд. научно-практической конференции «Теоретические и прикладные аспекты современной науки»: в 10 ч. / под общ. ред. М. Г. Петровой. – Белгород: 2015. Ч. III. С. 61–65.

29. Жданов А. А. Автономный искусственный интеллект / А. А. Жданов // Издательство: Бином. Лаборатория знаний, Серия: Адаптивные и интеллектуальные системы, 2009. 359 с.

30. Тузовский А. Ф. Онтолого-семантические модели в корпоративных системах управления знаниями: дис. докт. техн. наук / А. Ф. Тузовский. – Томск, 2007. 342 с.

31. Осуга С. Обработка знаний / С. Осуга– М.: Мир, 1989.

32. Попов Э. В. Статические и динамические экспертные системы. – М.: Финансы и статистика, 1996.

33. Дульнев Г. Н. Введение в синергетику / Г. Н. Дульнев– СПб.: Проспект, 1998.

34. Курейчик В. В. Модели и методы представления знаний в интеллектуальных системах поддержки принятия решений: коллективная монография / В. В. Курейчик, Ю. А. Кравченко, В. В. Бова [и др.]. – Таганрог: Изд-во ТТИ ЮФУ, 2010. 114 с.

35. Miller J. G. Living systems / J. G. Miller. – New York: McGraw-Hill, 1978.

36. Тимофеев С. В. Анализ подходов в моделировании средств массовой информации / С. В. Тимофеев, А. П. Суходолов, И. А. Кузнецова // Вопросы теории и практики журналистики. 2017. Т. 6. №3. С. 287–305.

37. Кравченко Ю. А. Управление знаниями как одно из направлений развития технологий открытого образования / Ю. А. Кравченко // Открытое образование. 2015. №3 (104). С. 71–76.

38. Норенков И. П. Онтологические методы синтеза электронных учебных пособий / И. П. Норенков // Открытое образование. 2010. №6. С. 39–44.

39. Родзин С. И. Искусственный интеллект: учебное пособие / С. И. Родзин. – Таганрог: Изд-во ТТИ ЮФУ, 2009. 200 с.

40. Курейчик В. В. Эволюционные, синергетические и гомеостатические методы принятия решений: монография / В. В. Курейчик. – Таганрог: Изд-во ТРТУ, 2001.

41. Курейчик В. В. Архитектуры и стратегии принятия решений / В. В. Курейчик, П. В. Сороколетов // Сборник трудов межд. научно-

практической конференции «Интегрированные модели и мягкие вычисления в искусственном интеллекте». 2007. Т. 2. С. 397–406.

42. Kravchenko Y. A. Models for Supporting of Problem-Oriented Knowledge Search and Processing / Y. A. Kravchenko, V. V. Bova, I. O. Kursitys // Proc. of the First Int. Scientific Conf. “Intelligent Information Technologies for Industry” (ИТИ’16). 2016. vol. 1. P.287–295.

43. Курейчик В. В. Комбинированный поиск при проектировании / В. В. Курейчик, В. В. Бова, Вл. Вл. Курейчик // Образовательные ресурсы и технологии. 2014. №2 (5). С. 90–94.

44. Kravchenko Y. A. Information’s Semantic Search, Classification, Structuring and Integration Objectives in the Knowledge Management Context Problems / Y. A. Kravchenko, E. V. Kuliev, I. O. Kursitys // Proc. 10th Int. Conf. on Application of Information and Communication Technologies. 2016. P. 136–141.

45. Kravchenko Y. A. Decision Support Systems for Knowledge Management / Y. A. Kravchenko, V. V. Bova, V. V. Kureichik // Software Engineering in Intelligent Systems. 2015. vol. 3. P. 123–130.

46. Kravchenko Y. A. Knowledge Management Based on Multi-Agent Simulation in Informational Systems / Y. A. Kravchenko, V. V. Kureichik // 8th IEEE Int. Conf. on Application of Information and Communication Technologies. 2014. P. 264–267.

47. Городецкий В. И. Многоагентные системы / В. И. Городецкий, М. С. Грушинский, А. В. Хабалов // Новости искусственного интеллекта. 1998. №2. 196 с.

48. Краснощеков П. С. Простейшая математическая модель поведения. Психология конформизма / П. С. Краснощеков // Математическое моделирование. 1998. Т. 10. №7. С. 76–92.

49. Кравченко Ю. А. Метод определения познавательных стилей на основе теории агентов / Ю. А. Кравченко // Известия ЮФУ. Технические науки. 2009. № 12 (101). С. 120–128.

50. Кравченко Ю. А. Интеграция свойств когнитивных стилей и интеллектуальных агентов как основа создания адаптивных информационных обучающих систем / Ю. А. Кравченко // Открытое образование. 2010. № 4 (81). С. 20–28.

51. Кравченко Ю. А. Принципы создания моделей диагностики личности на основе теории агентов / Ю. А. Кравченко // Российская академия наук. Научный журнал. Известия КБНЦ РАН. 2011. №1 (39). С. 148–153.

52. Кравченко Ю. А. Онтологический подход формирования информационных ресурсов на основе разнородных источников знаний / Ю. А. Кравченко, В. В. Марков // Известия ЮФУ. Технические науки. 2013. №7 (144). С. 116–120.

53. Hernich A. Dichotomies in ontology-mediated querying with the guarded fragment / A. Hernich, C. Lutz, F. Papacchini, F. Wolter // Proc. of the 36th Symp. on Principles of Database Systems (PODS). 2017. P. 185–199.

54. Lutz C. Ontology-mediated queries with closed predicates / C. Lutz, I. Seylan, F. Wolter // Proc. of the 24th Int. Joint Conf. on Artificial Intelligence (IJCAI). 2015. P. 3120–3126.

55. Палагин А. В. Системно-онтологический анализ предметной области / А. В. Палагин, Н. Г. Петренко // УСиМ. 2009. №4. С. 3–14.

56. He Q. Combination methodologies of multi-agent hyper surface classifiers: design and implementation issues / Q. He // Proc. second international workshop, AIS-ADM. 2007. – Springer Berlin Heidelberg, 2007. P. 100–113.

57. Протасов В. И. Математическая модель мультиагентной системы принятия консолидированных решений / В. И. Протасов // Материалы 1-й межд. конф. «Автоматизация управления и интеллектуальные системы и среды». Научный сборник. – Нальчик: Изд-во КБНЦ РАН. 2010. Т. 2. С. 84–87.

58. Кравченко Ю. А. Метод построения имитационных моделей принятия решений на основе многоагентных технологий / Ю. А. Кравченко // Известия ЮФУ. Технические науки. 2010. №7 (108). С.119–125.

59. Kravchenko Y. A. Information and knowledge integration based on simulation modeling / Y. A. Kravchenko, Vl. Vl. Kureichik, D. Yu. Zaporozhets, D. V. Zaruba // Proc. 9th IEEE Int. Conf. “Application of Information and Communication Technologies – AICT 2015”. 2015. P. 22–24.

60. Кравченко Ю. А. Метод оценки эффективности многоагентных систем, требующих большого объема знаний / Ю. А. Кравченко // Труды Конгресса по интеллектуальным системам и информационным технологиям “AIS-IT”. Научное издание в 4-х томах. – М.: Физматлит. 2010. Т. 1. С. 160–165.

61. Kravchenko Y. A. Architecture and Method of Integrating Information and Knowledge on the Basis of the Ontological Structure /

Y. A. Kravchenko, D. Y. Kravchenko, I. O. Kursitys // *Advances in Intelligent Systems and Computing*. 2018. vol. 658. P. 93–103.

62. Bienvenu M. The complexity of ontology-based data access with OWL 2 QL and bounded treewidth queries / M. Bienvenu // *In Proc. of the 36th Symp. on Principles of Database Systems*. 2017. P. 201–216.

63. Lutz C. Ontology-mediated queries with closed predicates / C. Lutz, I. Seylan, F. Wolter // *In Proc. of the 24th Int. Joint Conf. on Artificial Intelligence*. 2015. P. 3120–3126.

64. Кравченко Ю. А. Семантически-ориентированный доступ к ресурсам знаний на основе технологий биоинспирированного поиска и дополненной реальности: коллективная монография / Ю. А. Кравченко, В. В. Бова, В. В. Курейчик [и др.] – Таганрог: Изд-во Южного федерального университета, 2016. 148 с.

65. Кравченко Ю. А., Марков В. В., Новиков А. А. Семантический поиск в Semantic Web / Ю. А. Кравченко, В. В. Марков, А. А. Новиков // *Известия ЮФУ. Технические науки*. 2016. №6 (179). С. 65–75.

66. Кузнецов О. П. Онтология как систематизация научных знаний: структура, семантика, задачи / О. П. Кузнецов, В. С. Суховеров, Л. Б. Шипилина [Электронный ресурс]. – Режим доступа: <http://cmm.ipu.ru/proc> (дата обращения: 20.05.2023).

67. Alviano M. Stable model semantics for tuple-generating dependencies revisited / M. Alviano, M. Morak, A. Pieris // *Proc. of the 36th ACM SIGMOD-SIGACT-SIGAI Symp. on Principles of Database Systems*. 2017. P. 377–388.

68. Moussallem D. Machine translation using semantic web technologies: A survey / D. Moussallem, M. Wauer, A.-C. Ngomo // *Journal of Web Semantics*. 2018. vol. 51. P. 1–19.

69. Slota M. The rise and fall of semantic rule updates based on semodels / M. Slota, J. Leite // *TPLP*. 2014. vol. 14 (6). P. 869–907.

70. Volkanov D. A combined toolset for the verification of real-time distributed systems / D. Volkanov // *Programming and Computer Software*. 2015. vol. 41 (6). P. 325–335.

71. Нгуен Б. Н. Оптимизация хранения словаря триплетов с использованием числовых идентификаторов / Б. Н. Нгуен, А. Ф. Тузовский // *Научно-технический вестник Поволжья*. 2012. №2. С. 235–245.

72. Кравченко Ю. А. Разработка генетического алгоритма расчета семантической близости в задачах управления знаниями /

Ю. А. Кравченко, И. О. Курситыс, Э. В. Кулиев // Известия ЮФУ. Технические науки. 2016. №6 (179). С. 75–87.

73. Кравченко Ю. А. Метод интеллектуального принятия эффективных решений на основе биоинспирированного подхода / Ю. А. Кравченко, Э. В. Кулиев, О. А. Логинов [и др.] // Известия КБНЦ РАН. №6 (80). 2017. Ч. 2. С. 162–169.

74. Карпенко А. П. Современные алгоритмы поисковой оптимизации: учебное пособие / А. П. Карпенко. – М.: Издательство МГТУ им. Н. Э. Баумана, 2014. 446 с.

75. Kuliev E. Monkey Search Algorithm for ECE Components Partitioning / E. Kuliev, V. Kureichik, Vl. Kureichik // Journal of Physics: Conference Series. 2018. vol. 1015. no. paper 042026.

76. Кулиев Э. В. Модель адаптивного поведения «обезьян» для решения задачи компоновки блоков ЭВА / Э. В. Кулиев, В. В. Курейчик, Вл. Вл. Курейчик // Информатизация и связь. 2018. №4. С. 31–37.

77. Кравченко Ю. А. Гибридный биоинспирированный алгоритм отображения онтологий в задачах извлечения и управления знаниями / Ю. А. Кравченко, Д. Ю. Кравченко, В. В. Марков // Известия ЮФУ. Технические науки. 2020. №2 (212). С. 16–28.

78. Kravchenko Y. Assessment of Ontological Structures Semantic Similarity Based on a Modified Cuckoo Search Algorithm / Y. Kravchenko, V.V. Bova // IOP Conference Series: Materials Science and Engineering. 2020. vol. 734. no. paper 012018.

79. Liao Q. Parameter Estimation of Nonlinear Systems by Dynamic Cuckoo Search / Q. Liao // Neural Computation. 2017. vol. 29. no. 4. P. 1103–1123.

80. Докинз Р. Эгоистичный ген / Р. Докинз. – М.: АСТ: CORPUS, 2013. 512 с.

81. Курейчик В. В. Теория эволюционных вычислений / В. В. Курейчик, В. М. Курейчик, С. И. Родзин. – М.: Физматлит, 2012. 260 с.

82. Рутковская Д. Нейронные сети, генетические алгоритмы и нечеткие системы / Д. Рутковская, М. Пилиньский, Л. Рутковский. – М.: Горячая линия – Телеком, 2013. 384 с.

83. Родзин С. И. Биоэвристики: теория, алгоритмы и приложения / С. И. Родзин, Ю. А. Скобцов, С. А. Эль-Хатиб. – Чебоксары: Среда, 2019. 224 с.

84. Курейчик В. В. Вычислительные модели эволюционных и роевых биоэвристик (обзор) / В. В. Курейчик, С. И. Родзин // Информационные технологии. 2021. Т. 27. №10. С. 507–520.

85. Курейчик В. В. Вычислительные модели биоэвристик, основанных на физических и когнитивных процессах (обзор) / В. В. Курейчик, С. И. Родзин // Информационные технологии. 2021. Т. 27. №11. С. 563–574.

86. Gupta A. Memetic Computation, Adaptation, Learning, and Optimization / A. Gupta, Y.-S. Ong. – Springer Nature Switzerland AG, 2019. 109 p.

87. Moscato P. A modern introduction to memetic algorithms / P. Moscato, C. Cotta // Handbook of metaheuristics. Springer US. 2010. P. 141–183.

88. Rodzin S. Metaheuristics memes and biogeography for trans computational combinatorial optimization problems / S. Rodzin, O. Rodzina // Proc. of the 6th Int. Conf. on Cloud System and Big Data Engineering (Confluence'2016). AI and Soft Computing. 2016. P. 1–5.

89. Moscato P. On evolution, search, optimization, genetic algorithms and martial arts: Towards memetic algorithms / P. Moscato // Caltech concurrent computation program, C3P Report, 1989. 826 p.

90. Гладков Л. А. Биоинспирированные методы в оптимизации / Л. А. Гладков, В. В. Курейчик, В. М. Курейчик [и др.]. – М.: Физматлит, 2009. 384 с.

91. Wolpert D. H. No free lunch theorems for optimization / D. H. Wolpert, W. G. Macready // IEEE Transactions on Evolutionary Computation 1997. vol. 1 (1). P. 67–82.

92. Le M. N. A unified framework for symbiosis of evolutionary mechanisms with application to water clusters potential model design / M. N. Le, Y. S. Ong, Y. Jin, B. Sendhoff // IEEE Computational Intelligence Magazine. 2012. 7 (1). P. 20–35.

93. Rodzin S. Integration and Transfer of Information: Search Engine Optimizer Inspired by Memes / S. Rodzin, L. Rodzina // Proc. Int. Russian Automation Conf. (RusAutoCon). Publ. IEEE. 2023. DOI: 10.1109/RusAutoCon58002.2023.10272935.

94. Ku K. W. A study of the Lamarckian evolution of recurrent neural networks / K. W. Ku, M. W. Mak, W. C. Siu // IEEE Trans. on Evolutionary Computation. 2000. 4 (1). P. 31–42.

95. Pelikan M. Escaping hierarchical traps with competent genetic algorithms / M. Pelikan, D. Goldberg // Proc. of the 3rd Annual Conf. on Genetic and Evolutionary Computation. 2001. P. 511–518.

96. Ковалев С. М. Аналитический обзор современных интеллектуальных информационных технологий в технике и на производстве / С. М. Ковалев, В. Снашел, А. Н. Гуда [и др.] // Вестник Ростовского государственного университета путей сообщения. 2019. №1. С. 60–75.

97. Тарасов В. Б. Технологии индустрии 4.0: от цифрового производства и интернета вещей до интеллектуального имитационного моделирования и коллаборативных роботов / В. Б. Тарасов // Мягкие измерения и вычисления. 2018. №12. С. 3–15.

98. Rodzin S. Effectiveness evaluation of memetics and biogeography algorithms using benchmark and trans computational tasks of combinatorial optimization / S. Rodzin, O. Rodzina // Proc. of the First Int. Scientific Conf. “Intelligent Information Technologies for Industry” (ИТИ’16). 2016. vol. 1. P. 463–475.

99. Ковалев С. М. Информационные технологии: интеллектуализация обучения, моделирование эволюции, распознавание речи / С. М. Ковалев, С. И. Родзин. – Ростов н/Д: СКНЦ ВШ, 2002. 224 с.

100. Neri F. Memetic algorithms and memetic computing optimization: A literature review / F. Neri, C. Cotta // Swarm and Evolutionary Computation. 2012. no. 2. P. 1–14.

101. Ong Y. S. Meta-Lamarckian learning in memetic algorithms / Y. S. Ong, A. J. Keane // IEEE Trans. on Evolutionary Computation. 2004. no. 8 (2). P. 99–110.

102. Rodzin S. Effectiveness evaluation of memetic and biogeography algorithms using benchmark and trans computational tasks of combinatorial optimization / S. Rodzin, O. Rodzina // Proc. of the First Int. Scientific Conf. «Intelligent Information Technologies for Industry» (ИТИ’16). 2016. vol. 1. P. 463–475.

103. Zhou Z. Memetic algorithm using multi-surrogates for computationally expensive optimization problems / Z. Zhou, Y. Ong, M. Lim, B. Lee // Soft Computing. 2007. no. 11 (10). P. 957–971.

104. Родзин С.И. Алгоритмы биомеметики / С.И. Родзин, О.Н. Родзина // Образовательные ресурсы и технологии. 2014. №2 (5). С. 129–132.

105. Кравченко Ю. А. Интеллектуальный меметический автомат для интеграции и передачи знаний / Ю. А. Кравченко, С. И. Родзин, Л. С. Родзина // Труды межд. научно-технического конгресса

«Интеллектуальные системы и информационные технологии – 2023» («ИС & ИТ-2023», «IS&IT'23»). Таганрог: Изд-во Ступина С. А. 2023. Т. 1. С. 93–108.

106. Jin Y. Surrogate-assisted evolutionary computation: Recent advances and future challenges / Y. Jin // *Swarm and Evolutionary Computation*. 2011. no. 1. P. 61–70.

107. Shahriari B. Taking the human out of the loop: A review of Bayesian optimization / B. Shahriari // *Proc. of the IEEE*. 2016. no. 104 (1). P. 148–175.

108. Родзин С. И. Построение прогнозов в рекомендательных системах с помощью машинного обучения на основе популяционного алгоритма / С. И. Родзин, О. Н. Родзина // *Вестник компьютерных и информационных технологий*. 2020. №1. С. 48–56.

109. Ong Y. S. Evolutionary optimization of computationally expensive problems via surrogate modeling / Y. S. Ong, P. B. Nair, A. J. Keane // *AIAA Journal*. 2003. no. 41 (4). P. 687–696.

110. Joyce J. M. Kullback-leibler divergence / J. M. Joyce // *International encyclopedia of statistical science*. – Berlin Heidelberg: Springer, 2011. P. 720–722.

111. Воронцов К. В. Математические методы обучения по прецедентам (теория обучения машин) / К. В. Воронцов // *Информационный бюллетень ассоциации История и компьютер*. 2011. С. 4.

112. Родзина О. Н. Задача балансирования тележки с двумя флажками разной длины: нейроэволюционный алгоритм / О. Н. Родзина, Л. С. Родзина // *Вестник РГУПС*. 2017. №3. С. 90–95.

113. Rodzin S. Neuroevolution: problems, algorithms, and experiments / S. Rodzin, O. Rodzina, L. Rodzina // *Proc. of the 10th IEEE Int. Conf. Application of Information and Communication Technologies (AICT'2016)*. P. 469–472.

114. Карпенко А. П. Популяционные алгоритмы глобальной поисковой оптимизации. Обзор новых и малоизвестных алгоритмов / А. П. Карпенко // *Приложение к журналу «Информационные технологии»*. 2012. №7. С. 1–31.

115. Родзина О. Н. Бенчмаркинг нейроэволюционного подхода для задачи управления балансом тележки / О. Н. Родзина, Л. С. Родзина // *Труды Конгресса по интеллектуальным системам и информационным технологиям (IS&IT'17)*. – Таганрог: Изд-во Ступина С.А. 2017. Т. 1. С. 61–70.

Научное издание

Кравченко Юрий Алексеевич
Курейчик Владимир Викторович
Родзин Сергей Иванович

**ИНТЕЛЛЕКТУАЛЬНЫЕ СИСТЕМЫ:
ЭВОЛЮЦИЯ МОДЕЛЕЙ И МЕТОДОВ ПРИОБРЕТЕНИЯ,
УПРАВЛЕНИЯ И ПЕРЕДАЧИ ЗНАНИЙ**

Монография

Чебоксары, 2023 г.

Компьютерная верстка *Е. О. Тевянова*
Дизайн обложки *Н. В. Фирсова*

Подписано в печать 16.11.2023 г.

Дата выхода издания в свет 27.11.2023 г.

Формат 60×84/16. Бумага офсетная. Печать офсетная.
Гарнитура Times. Усл. печ. л. 11,16. Заказ 2908. Тираж 500 экз.

Издательский дом «Среда»
428005, Чебоксары, Гражданская, 75, офис 12
+7 (8352) 655-731
info@phsreda.com
https://phsreda.com

Отпечатано в ООО «Типография «Перфектум»
428000, Чебоксары, ул. К. Маркса, 52