

Министерство образования и науки Российской Федерации
Южно-Уральский государственный университет
Кафедра «Информационно-аналитическое обеспечение управления
в социальных и экономических системах»

004.8(07)
К681

А.М. Коровин

ИНТЕЛЛЕКТУАЛЬНЫЕ СИСТЕМЫ

Текст лекций

Челябинск
Издательский центр ЮУрГУ
2015

УДК 004.89(075.8)
К681

*Одобрено
учебно-методической комиссией
факультета компьютерных технологий,
управления и радиоэлектроники*

*Рецензенты:
П.П. Переверзев, В.Г. Попов*

Коровин, А.М.

К681 Интеллектуальные системы: текст лекций / А.М. Коровин. – Челябинск: Издательский центр ЮУрГУ, 2015. – 60 с.

В тексте лекций в обзорной форме изложены основные понятия, методы и технологии, используемые в современных интеллектуальных системах управления социально-экономическими и сложными техническими объектами. Дана классификация основных способов представления знаний в интеллектуальных системах. Приведены характеристики методов интеллектуального анализа данных и программных средств их реализации в современной компании.

Текст лекций предназначен для магистрантов, обучающихся в рамках направления подготовки 09.04.01 «Информатика и вычислительная техника», а также будет полезен студентам других родственных кафедр и направлений подготовки. Рекомендуется для первоначального ознакомления с основами построения и применения интеллектуальных систем и технологий.

УДК 004.89(075.8)

© Издательский центр ЮУрГУ, 2015

ВВЕДЕНИЕ

Интеллектуальные информационные системы проникают во все сферы нашей жизни, поэтому становятся неотъемлемым элементом при решении задач автоматизации и управления сложными объектами и процессами.

Современное понятие интеллектуальных систем (ИС) сформировалось в процессе развития теоретических основ кибернетики, современной теории управления, теории алгоритмов, развития современных информационных технологий и обобщения накопленных научных знаний, методов и средств в области искусственного интеллекта (ИИ).

Целью текста лекций является обзорное ознакомление студентов, обучающихся по направлению «Информатика и вычислительная техника» и другим родственным направлениям, с проблематикой и областями использования искусственного интеллекта в автоматизированных системах обработки информации и управления, освещение теоретических и организационно-методических вопросов построения и функционирования систем, основанных на знаниях, привитие навыков практических работ по проектированию баз знаний. В результате изучения лекционного материала студенты получают знания по архитектуре и классификации ИС, методам представления знаний, областям применения, а также научатся выбирать адекватные проблемной области методы проектирования базы знаний.

Поэтому в соответствии с требованиями федерального государственного образовательного стандарта высшего профессионального образования для формирования у студентов общекультурных, общепрофессиональных и профессиональных компетенций в модуль «Профессиональные дисциплины» учебного плана подготовки магистров по направлению 09.04.01 «Информатика и вычислительная техника» введена учебная дисциплина «Интеллектуальные системы».

Изучение студентами дисциплины «Интеллектуальные системы» должно ознакомить с основными понятиями и концепциями теории интеллектуальных систем, а также осветить вопросы построения и функционирования ИС, основанных на знаниях, с целью вооружить будущих магистров теоретическими знаниями и практическими навыками, необходимыми для решения задач создания и использования современных интеллектуальных информационных технологий и систем в области информационно-аналитического обеспечения подготовки и принятия управленческих решений по всем аспектам экономических, социальных и технических проблем.

Предполагается, что студенты уже прослушали курсы по информатике, программированию и основам алгоритмизации, базам данных в информационно-управляющих системах, математическим основам кибернетики, теории систем и управления, моделированию систем, системам автоматизации и управления.

В связи с большим объемом информации при ограниченном количестве аудиторных часов в одном семестре (18 часов лекционных и 18 часов практических занятий) в определенной мере связаны ограниченный объем учебного по-

собия и краткость изложения материала, что во многом и предопределило его обзорный характер. Поэтому основная часть материала дана в виде краткой справочной информации со ссылками на более полные источники. В соответствии с этим в список рекомендуемой литературы включены источники, необходимые для углубленного изучения рассматриваемых вопросов. К настоящему времени издано множество научно-технической литературы по указанной проблематике, включая и учебно-методические издания из различных вузов. При формировании списка литературы учитывалась реальная возможность доступа студентов к рекомендуемым материалам, поэтому представленный список не претендует на полноту и не является исчерпывающим перечнем. В связи с этим ограничены ссылки на известные, но трудно доступные классические основополагающие работы, а в первую очередь указаны ссылки на более доступные современные книги, а также различные методические и справочные материалы в Интернете, отдельные фрагменты из которых частично использованы в данном пособии.

По причине ограниченности часов дисциплины внимание в тексте лекций уделено такому актуальному направлению ИИ как интеллектуальный анализ данных (ИАД). Приводится классификация методов и программных средств реализации ИАД, которые будут более подробно изучаться на практических занятиях.

Курс лекций включает 18 часов лекций, которые в соответствии с рабочей программой дисциплины сгруппированы в 3 раздела:

1. Введение в интеллектуальные системы.
2. Модели представления знаний. Способы формализации интеллектуальных задач с помощью методов искусственного интеллекта.
3. Интеллектуальный анализ данных. Методы ИАД и их программная реализация.

В конце каждого раздела помещены контрольные вопросы, которые служат для проверки качества усвоения и понимания материала и могут быть включены в экзаменационные билеты.

Фактическое содержание данного текста лекций является введением в научные и методические основы создания и применения современных интеллектуальных систем и технологий применительно к решению различных сложных задач управления в компаниях. Приведенный в тексте лекций материал интегрирует информацию из наиболее актуальных и значимых источников, что позволяет в лаконичной форме дать магистрантам результаты, достигнутые в теории и практике ИС.

Глава 1. ПОНЯТИЯ И ТЕРМИНОЛОГИЯ ИНТЕЛЛЕКТУАЛЬНЫХ СИСТЕМ

1.1. История исследований и основные понятия в области искусственного интеллекта

Возникновение понятия интеллектуальных систем тесно связано с понятием искусственного интеллекта (ИИ) и современной теории управления [1-14]. Исследования в области ИИ стали развиваться наиболее активно с 50-х годов прошлого века в связи с развитием средств вычислительной техники, информатики и кибернетики.

На разных этапах развития ИИ исследователями различных направлений ИИ предлагались свои определения ИИ. Так в математическом энциклопедическом словаре приводилось следующее определение: «Искусственный интеллект (от латинского *intellectus* – познание, понимание, рассудок) это раздел информатики, изучающий методы, способы и приемы моделирования и воспроизведения с помощью ЭВМ разумной деятельности человека, связанной с решением задач». Академик Г.С. Поспелов в книге «Искусственный интеллект – основа новой информационной технологии» писал: «под искусственным интеллектом понимается наука о том, как заставить машину делать то, что умеет делать умный человек». В зарубежной литературе применяют определение термина «искусственный интеллект» как «Artificial Intelligence» (AI). В отличие от философии и психологии, искусственный интеллект в области исследований и разработок технических систем ориентирован не столько на понимание, сколько на построение интеллектуальных систем.

На первоначальном этапе развития были выделены и на данный момент остались актуальными следующие **основные проблемы искусственного интеллекта и направления его развития**:

1. Представление знаний.
2. Решение неформализованных задач.
3. Создание комплексных экспертных систем.
4. Интеллектуальный анализ данных.
5. Общение с ЭВМ на естественном языке.
6. Обучение.
7. Когнитивное моделирование (*cognos* – знание) и моделирование разума.
8. Обработка визуальной информации и робототехника.

Исторически существует 2 направления исследований в области искусственного интеллекта:

1. Моделирование результатов интеллектуальной деятельности или так называемый машинный интеллект.
2. Моделирование биологических систем или так называемый искусственный разум.

Первое направление рассматривает продукт интеллектуальной деятельности человека, изучает его структуру и стремится воспроизвести этот продукт сред-

ствами компьютерной техники. Успехи этого направления тесно связаны с развитием вычислительной техники и программирования.

Второе направление ИИ рассматривает данные о нейрофизиологической деятельности человека. Разработчики стремятся воспроизвести структуры и процессы в нервной системе с помощью технических устройств так, чтобы их поведение хорошо совпадало с поведением человека в заданных ситуациях. Развитие этого направления тесно связано с успехами наук о человеке. В свою очередь работы по искусственному разуму ведутся по следующим направлениям:

1. Моделирование механизмов умственной деятельности, связанное с созданием нейроподобных сетей (нейрокибернетика). В первую очередь изучаются нервные клетки – нейроны и структуры из взаимосвязанных клеток – нейронные сети. Механизмы таких разработок воплощены в нейрокомпьютеры.

2. Моделирование информационных процессов или так называемое эвристическое программирование, при котором моделируется не нейронные клетки, а мыслительные операции, выполнение которых приводит к успешному решению задачи. Успехи теоретического и прикладного характера достигнуты за счет разработки общего решателя задач – GPS (General Problem Solver).

3. Комплексный подход или так называемое эвристическое моделирование.

Необходимо отметить, что современная теория ИИ и созданные на ее основе интеллектуальные системы (ИС) и технологии были подготовлены трудами многих исследователей на протяжении многих лет.

В 40-50-х годах прошлого века началось бурное развитие информационных технологий и автоматизации: были созданы первые ЭВМ, а Норберт Винер создал свои основополагающие работы по кибернетике, и произошло окончательное оформление искусственного интеллекта как научного направления.

В конце 50-х годов XX в. родилась модель лабиринтного поиска. В этом подходе задача представляется как некоторое пространство состояний в форме графа, и в этом графе проводится поиск оптимального пути от входных данных к результирующим.

Начало 60-х годов – это эпоха эвристического программирования. Эвристика – правило, теоретически не обоснованное, но позволяющее сократить количество переборов в пространстве поиска. Эвристическое программирование – разработка стратегии действий на основе известных, заранее заданных, эвристик.

В 1963-1970 гг. к решению задач ИИ стали подключать методы математической логики. На основе метода резолюций француз Альбер Кольмероз в 1973 г. создает язык логического программирования Пролог. Однако большинство реальных задач не сводится к набору аксиом. Человек, решая производственные задачи, не использует классическую логику, и поэтому применение логических моделей при всех своих преимуществах имеют существенные ограничения по классам решаемых задач.

В середине 1970-х годов в США вместо поисков универсальных алгоритма мышления стала развиваться идея моделирования конкретных знаний специа-

листов экспертов. В США появились первые коммерческие системы, основанные на знаниях, или экспертные системы (ЭС). Возник новый подход к решению задач искусственного интеллекта – представление знаний. В это время были созданы две первые классические экспертные системы для медицины (MYCIN) и для химии (DENDRAL).

В конце 70-х годов в Японии было объявлено о начале разработки проекта машин V поколения, основанных на знаниях.

В середине 1980-х годов был разработан в Центре космических исследований NASA язык CLIPS, обеспечивающий поддержку программирования на основе правил объектно-ориентированного и процедурного программирования. Название языка CLIPS – аббревиатура от C Language Integrated Production System.

Начиная с середины 80-х годов, повсеместно происходит коммерциализация искусственного интеллекта. Растут ежегодные капиталовложения, создаются промышленные экспертные системы. Растет интерес к самообучающимся системам, издаются десятки научных журналов, ежегодно собираются международные и национальные конференции по различным направлениям ИИ.

В Советском Союзе работы по искусственному интеллекту начались даже раньше, чем на западе [1-3, 5]. В 1954 г. в МГУ начал свою работу семинар «Автоматы и мышление» под руководством академика А.А. Ляпунова. В этом семинаре принимали участие физиологи, лингвисты, психологи, математики. Принято считать, что именно в это время родился искусственный интеллект в России.

Среди наиболее значимых результатов, полученных отечественными учеными в 60-е годы, отмечают алгоритм «Кора» М.М. Бонгарда, моделировавший деятельность человеческого мозга при распознавании образов.

В 1965-1980 гг. происходит рождение нового направления – ситуационного управления. Основателем этой научной школы стал проф. Д.А. Поспелов, разработавший специальные модели представления ситуаций.

В 1974 г. при Комитете по системному анализу при президиуме АН СССР начал работу Научный совет по проблеме «Искусственный интеллект». В 1988 г. создается Ассоциация Искусственного Интеллекта (АИИ). Ее членами стали более 300 исследователей, а президентом избирается Д. А. Поспелов.

В 1980-1990 гг. проводятся активные исследования в области представления знаний, разрабатываются языки представления знаний, экспертные системы (более 300). В МГУ им. М. В. Ломоносова создается язык РЕФАЛ.

В конце 90-х годов начинают более активно использоваться идеи и методы искусственного интеллекта в теории и практике управления, появляются отдельные разработки на базе ИИ, включаемые в состав систем управления (СУ). Такие разработки стали называть интеллектными компонентами (ИК) систем управления.

В качестве наиболее используемого типа ИК для СУ становятся искусственные нейронные сети. В системах управления применяется несколько типов ИНС: многослойный персептрон, сеть Кохонена (как однослойная самооргани-

зующаяся карта – Kohonen's Self-Organizing Map), сеть Хопфилда, машина Больцмана и другие [5-8].

В качестве второго типа интеллектуальных компонент систем управления рассматриваются эволюционные (генетические) алгоритмы, которые тоже являются инструментом поиска рациональных решений. Эволюционные алгоритмы (ЭА) понимаются как алгоритмы со специальными структурами данных, оперирующие с популяциями индивидов.

Для реализации высокоинтеллектуальных функций систем управления используются интеллектуальные компоненты третьего типа – системы, основанные на «знаниях» (СОЗ, Knowledge-Based Systems). Например, знания могут быть представлены в некотором логическом языке. Обработка знаний с помощью логических средств позволяет получать некоторые предпочтения на множестве допустимых управлений с целью выбора одного из них. В общем случае СОЗ оперируют с более широкой информацией логическими, объектно-ориентированными и другими моделями, основанными на знаниях экспертов. Вместе с тем СОЗ могут использовать и традиционные алгоритмы, базирующиеся на уравнениях динамики.

1.2. Основные направления исследований в области интеллектуальных систем

Рассмотрим краткие характеристики основных направлений исследований в области искусственного интеллекта, описанные в [1-3, 5-11].

Разработка интеллектуальных систем, основанных на знаниях. Это одно из главных направлений ИИ. Основной целью построения таких систем являются выявление, исследование и применение знаний высококвалифицированных экспертов для решения сложных задач, возникающих на практике. При построении систем, основанных на знаниях (СОЗ), используются знания, накопленные экспертами в виде конкретных правил решения тех или иных задач. Это направление преследует цель имитации человеческого искусства анализа неструктурированных и слабоструктурированных проблем. В данной области исследований осуществляется разработка моделей представления, извлечения и структурирования знаний, а также изучаются проблемы создания баз знаний (БЗ), образующих ядро СОЗ. Частным случаем СОЗ являются экспертные системы (ЭС), подробное описание которых можно найти в [1, 5, 9, 17].

Разработка естественно-языковых интерфейсов и машинный перевод. Проблемы компьютерной лингвистики и машинного перевода разрабатываются в ИИ с 1950-х гг. Системы машинного перевода с одного естественного языка на другой обеспечивают быстроту и систематичность доступа к информации, оперативность и единообразие перевода больших потоков. Системы машинного перевода строятся как интеллектуальные системы, поскольку в их основе лежат БЗ в определённой предметной области и сложные модели, обеспечивающие дополнительную трансляцию «исходный язык оригинала – язык смысла – язык перевода». Они базируются на структурно-логическом подходе, включающем последовательный анализ и синтез естественно-языковых сообщений. Кроме

того, в них осуществляется ассоциативный поиск аналогичных фрагментов текста и их переводов в специальных базах данных (БД). Данное направление охватывает также исследования методов и разработку систем, обеспечивающих реализацию процесса общения человека с компьютером на естественном языке (так называемые системы ЕЯ-общения). Кроме того, создаются системы речевого общения в целях повышения скорости ввода информации в ЭВМ, разгрузки зрения и рук, а также для реализации речевого общения на значительном расстоянии. В таких системах под текстом понимают фонемный текст (как слышится).

Обработка визуальной информации. В этом научном направлении решаются задачи обработки, анализа и синтеза изображений. Задача обработки изображений связана с трансформированием графических образов, результатом которого являются новые изображения. В задаче анализа исходные изображения преобразуются в данные другого типа, например в текстовые описания. При синтезе изображений на вход системы поступает алгоритм построения изображения, а выходными данными являются графические объекты (системы машинной графики).

Обучение и самообучение. Эта актуальная область ИИ включает модели, методы и алгоритмы, ориентированные на автоматическое накопление и формирование знаний с использованием процедур анализа и обобщения данных [19-21]. К данному направлению относятся появившиеся в 90-х годах системы добычи данных (Data Mining) и системы поиска закономерностей в компьютерных базах данных (Knowledge Discovery).

Игры и машинное творчество. Машинное творчество охватывает сочинение компьютерной музыки, стихов, интеллектуальные системы для изобретения новых объектов. Создание интеллектуальных компьютерных игр является одним из самых развитых коммерческих направлений в сфере разработки программного обеспечения. Кроме того, компьютерные игры предоставляют мощный арсенал разнообразных средств, используемых для обучения.

Программное обеспечение систем ИИ. Инструментальные средства для разработки интеллектуальных систем включают специальные языки программирования, ориентированные на обработку символьной информации (LISP, SMALLTALK, РЕФАЛ), языки логического программирования (PROLOG), языки представления знаний (OPS5, KRL, FRL), интегрированные программные среды, содержащие арсенал инструментальных средств для создания систем ИИ (KE, ARTS, GURU, G2), а также оболочки экспертных систем (BUILD, EMYCIN, EXSYS Professional, ЭКСПЕРТ), которые позволяют создавать прикладные ЭС, не прибегая к программированию [7, 15-17].

Новые архитектуры компьютеров. Это направление связано с созданием компьютеров не фон-неймановской архитектуры, ориентированных на обработку символьной информации. Известны удачные промышленные решения параллельных и векторных компьютеров, однако в настоящее время они имеют весьма высокую стоимость, а также недостаточную совместимость с существующими вычислительными средствами.

Интеллектуальные роботы. Создание интеллектуальных роботов составляет конечную цель робототехники. В настоящее время в основном используются программируемые манипуляторы с жёсткой схемой управления, названные роботами первого поколения. Несмотря на очевидные успехи отдельных разработок, эра интеллектуальных автономных роботов пока не наступила. Основными сдерживающими факторами в разработке автономных роботов являются нерешённые проблемы в области интерпретации знаний, машинного зрения, адекватного хранения и обработки трёхмерной визуальной информации.

1.3. Основные признаки и отличия интеллектуальных систем

Для интеллектуальных систем характерны следующие признаки [6-7, 10-11]:

1. Развитые коммуникативные способности: возможность обработки произвольных запросов в диалоге на языке максимально приближенном к естественному (система естественно-языкового интерфейса – СЕЯИ).
2. Направленность на решение слабоструктурированных, плохо формализуемых задач (реализация мягких моделей).
3. Способность работать с неопределёнными и динамичными данными.
4. Способность к развитию системы и извлечению знаний из накопленного опыта конкретных ситуаций.
5. Возможность получения и использования информации, которая явно не хранится, а выводится из имеющихся в базе данных.
6. Система имеет не только модель предметной области, но и модель самой себя, что позволяет ей определять границы своей компетентности.
7. Способность к выводам по аналогии.
8. Способность объяснять свои действия, неудачи пользователя, предупреждать пользователя о некоторых ситуациях, приводящих к нарушению целостности данных.

В отличие от обычных аналитических и статистических моделей, ИС позволяют получить решение трудно формализуемых слабо структурированных задач.

Возможность ИС работать со слабоструктурированными данными подразумевает наличие следующих качеств:

- решать задачи, описанные только в терминах «мягких» моделей, когда зависимости между основными показателями являются не вполне определёнными или даже неизвестными в пределах некоторого класса;
- способность к работе с неопределёнными или динамичными данными, изменяющимися в процессе обработки, позволяет использовать ИС в условиях, когда методы обработки данных могут изменяться и уточняться по мере поступления новых данных;
- способность к развитию системы и извлечению знаний из накопленного опыта конкретных ситуаций увеличивает мобильность и гибкость системы, позволяя ей быстро осваивать новые области применения.

Отличия программирования систем искусственного интеллекта от обычных программных систем представлены в таблице.

Отличия интеллектуальных систем от обычных программных систем

Характеристика	Программирование в интеллектуальных системах	Традиционное программирование
Тип обработки	Символьный	Числовой
Метод	Эвристический поиск	Точный алгоритм
Задание шагов решения	Неявное	Явное
Искомое решение	Удовлетворительное	Оптимальное
Управление и данные	Смешаны	Разделены
Знания	Неточные	Точные
Модификации	Частые	Редкие

Для интеллектуальных информационных систем, ориентированных на генерацию алгоритмов решения задач, характерны следующие признаки:

- развитые коммуникативные способности;
- умение решать сложные плохо формализуемые задачи;
- способность к самообучению.

Коммуникативные способности ИС характеризуют способ взаимодействия (интерфейса) конечного пользователя с системой, в частности, возможность формулирования произвольного запроса в диалоге с ИС на языке, максимально приближенном к естественному.

Сложные плохо формализуемые задачи – это задачи, которые требуют построения оригинального алгоритма решения в зависимости от конкретной ситуации, для которой могут быть характерны неопределенность и динамичность исходных данных и знаний.

Способность к самообучению – это возможность автоматического извлечения знаний для решения задач из накопленного опыта конкретных ситуаций.

В различных ИС перечисленные признаки интеллектуальности развиты в неодинаковой степени и редко, когда все четыре признака реализуются одновременно. Условно каждому из признаков интеллектуальности соответствует свой класс ИС:

- системы с интеллектуальным интерфейсом;
- экспертные системы;
- самообучающиеся системы.

Анализ интеллектуальности систем, разработанный профессором Логиновским О.В., основан на следующих базовых интеллектуальных структурах, которые приводятся ниже в соответствии с работой [10]. Такие структуры, как идентификаторы, исполнители, накопители, модификаторы являются базовыми элементами более сложных интеллектуальных систем (экспертных, систем автоматизации управления, в частности, автоматизированных систем проектирования и управления). При этом системы становятся многоуровневыми, иерархическими, на нижнем уровне которых обязательно присутствуют интеллектуальные идентификаторы, исполнители и накопители. В конкретной предметной

области управления (планирования, проектирования) объект управления выделяется в системе идентификаторами и накопителями по принципу обратной связи.

Перечисленные виды интеллектуальных систем:

1. Интеллектуальный идентификатор (ИДЕН)

$$\langle \text{ИДЕН} \rangle = \{ A, p, w, a, Ш \},$$

где A – множество объектов предметной области (опорное множество); p – подмножество A , являющееся классом эквивалентности по какому-либо признаку; w – семантическая достоверность сведения об объекте; a – семантический указатель объекта из опорного множества A ; $Ш$ – шкала понятий для множества A .

Интеллектуальный идентификатор выполняет в системе функции идентификации данных об объектах предметной области по существующим семантическим указателям, решая задачу интеллектуального распознавания объектов.

2. Интеллектуальный исполнитель (ИСП) представляет собой интеллектуальную структуру, позволяющую по данным об объекте a из опорного множества A отыскать конкретный объект и (при необходимости) осуществить операции по его воплощению в предметной области.

3. Интеллектуальный накопитель (НАК) также выполняет функции интеллектуальной системы, состоящие в пополнении данных об объекте от различных источников из множества A , формируя соответствующие базы и банки данных территориального и муниципального управления.

Формульные соотношения интеллектуальных накопителя и исполнителя аналогичны интеллектуальному идентификатору.

4. Интеллектуальный модификатор (МОД) осуществляет функции преобразования данных из одного множества A в данные об объектах другого множества A' со шкалой понятий (перечнем свойств) $Ш'$:

$$\{ A, p, w, a, Ш \} \Rightarrow \{ A', p, w, a', Ш' \}.$$

При совпадении опорных множеств A и A' , данные об объекте $a \in A$ преобразуются модификатором в данные о том же объекте (сингулярные модификаторы). Свойство сингулярности весьма характерно для автоматизированных систем проектирования и управления.

5. Интеллектуальный анализатор (АНАЛ), выполняющий функции анализа и оценки эффективности системы с учетом интеллектуальности и других основополагающих характеристик.

6. Интеллектуальный синтезатор (СИН), осуществляющий синтез новых характеристик, свойств и возможностей системы на основе сформированных баз знаний о предметной области в целом и самой системе в частности с помощью искусственного или естественного интеллекта.

На основе представленного набора интеллектуальных структур можно анализировать или формировать на множестве компонент предметной области топологию интеллектуальности посредством понятия интеллектуальной системы:

$$SI_i = \{ R_i, t_i \},$$

где R_i – множество компонент предметной области для i -той системы; t_i – топология i -той системы, включающую базу топологий в виде набора базовых интеллектуальных структур.

При $t_i = 0$, любая из рассматриваемых систем не является интеллектуальной.

Формализация процедур оценки интеллектуальности систем должна осуществляться совместно с оценкой их эффективности и конкурентоспособности:

$$SE_i = \{ R_i, F_i, C_i, P_i, I_i, E_i \},$$

где F_i – множество компонент функциональной модели i -той системы; C_i – множество компонент структурной модели i -той системы; P_i – множество компонент программного обеспечения i -той системы; I_i – множество компонент информационного обеспечения i -той системы; E_i – множество характеристик эффективности i -той системы.

Все указанные компоненты и характеристики для конкретных систем всегда больше нуля. Более сильная топология соответствует более высокому уровню эффективности и конкурентоспособности системы.

1.4. Основные типы интеллектуальных систем

В данном учебном пособии, как и в [11] мы будем рассматривать следующие классы систем искусственного интеллекта:

1. Системы с интеллектуальной обратной связью и интеллектуальными интерфейсами.
2. Автоматизированные системы распознавания образов.
3. Автоматизированные системы поддержки принятия решений.
4. Экспертные системы.
5. Нейронные сети.
6. Когнитивное моделирование.
7. Генетические алгоритмы и моделирование эволюции.
8. Выявление знаний из опыта (эмпирических фактов) и интеллектуальный анализ данных (Data Mining).

Этими классами системы ИС не исчерпываются, но мы вынуждены ограничиться ими, как основными, в связи с ограниченностью объема учебного пособия.

Системы с интеллектуальным интерфейсом. Применение ИИ для усиления коммуникативных способностей информационных систем привело к появлению систем с интеллектуальным интерфейсом, среди которых можно выделить следующие типы [6-7]:

1. Интеллектуальные базы данных. Они позволяют в отличие от традиционных БД обеспечивать выборку необходимой информации, не присутствующей в явном виде, а выводимой из совокупности хранимых данных.

2. Естественно-языковой интерфейс. Он применяется для доступа к интеллектуальным базам данных, контекстного поиска документальной текстовой информации, голосового ввода команд в системах управления, машинного перевода с иностранных языков. Для реализации ЕЯ-интерфейса необходимо решить проблемы морфологического, синтаксического и семантического анализа, а также задачу синтеза высказываний на естественном языке. При морфологическом анализе осуществляются распознавание и проверка правильности написания слов в словаре.

3. Гипертекстовые системы предназначены для реализации поиска по ключевым словам в базах текстовой информации. Интеллектуальные гипертекстовые системы отличаются возможностью более сложной семантической организации ключевых слов, которая отражает различные смысловые отношения терминов. Таким образом, механизм поиска работает прежде всего с базой знаний ключевых слов, а уже затем непосредственно с текстом. В более широком плане сказанное распространяется и на поиск мультимедийной информации, включающей помимо текстовой и цифровой информации графические, аудио и видео-образы.

4. Системы контекстной помощи можно рассматривать, как частный случай интеллектуальных гипертекстовых и естественно-языковых систем. В отличие от обычных систем помощи, навязывающих пользователю схему поиска требуемой информации, в системах контекстной помощи пользователь описывает проблему (ситуацию), а система с помощью дополнительного диалога ее конкретизирует и сама выполняет поиск относящихся к ситуации рекомендаций. Такие системы относятся к классу систем распространения знаний (Knowledge Publishing) и создаются как приложение к системам документации (например, технической документации по эксплуатации товаров).

5. Системы когнитивной графики позволяют осуществлять интерфейс пользователя с ИС с помощью графических образов, которые генерируются в соответствии с происходящими событиями. Такие системы используются в мониторинге и управлении оперативными процессами. Графические образы в наглядном и интегрированном виде описывают множество параметров изучаемой ситуации. Например, состояние сложного управляемого объекта отображается в виде человеческого лица, на котором каждая черта отвечает за какой-либо параметр, а общее выражение лица дает интегрированную характеристику ситуации.

Экспертные системы. Назначение экспертных систем (ЭС) заключается в решении достаточно трудных для экспертов задач на основе накапливаемой базы знаний, отражающей опыт работы экспертов в рассматриваемой проблемной области. Достоинство применения экспертных систем заключается в возможности принятия решений в уникальных ситуациях, для которых алгоритм заранее не известен и формируется по исходным данным в виде цепочки рассуждений

(правил принятия решений) из базы знаний. Причем решение задач предполагается осуществлять в условиях неполноты, недостоверности, многозначности исходной информации и качественных оценок процессов.

Экспертная система является инструментом, усиливающим интеллектуальные способности эксперта, и может выполнять следующие роли:

- консультанта для неопытных или непрофессиональных пользователей;
- ассистента в связи с необходимостью анализа экспертом различных вариантов принятия решений;
- партнера эксперта по вопросам, относящимся к источникам знаний из смежных областей деятельности.

Область исследования экспертных систем называют «инженерией знаний». ЭС применяются для решения неформализованных проблем, к которым относят задачи, обладающие одной (или несколькими) из следующих характеристик:

- задачи не могут быть представлены в числовой форме;
- неоднозначностью, неточностью, противоречивостью;
- цели нельзя выразить с помощью чётко определённой целевой функции;
- не существует однозначного алгоритмического решения задачи;
- алгоритмическое решение существует, но его нельзя использовать по причине большой размерности пространства решений и ограничений на ресурсы (времени, памяти).

Главное отличие ЭС на рис. 1 и систем искусственного интеллекта от систем обработки данных состоит в том, что в них используется символьный, а не числовой способ представления данных, а в качестве методов обработки информации применяются процедуры логического вывода и эвристического поиска решений.

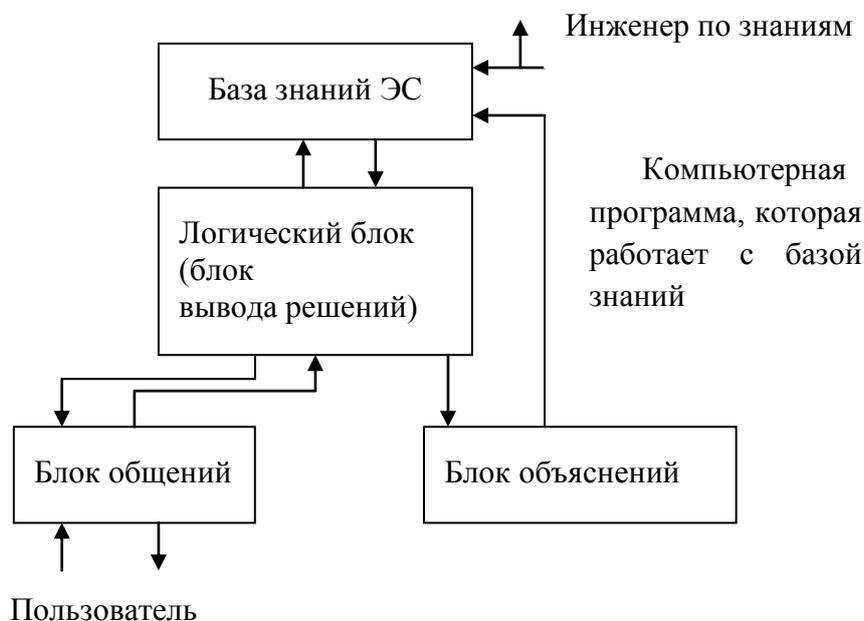


Рис. 1. Общая структура экспертной системы

Отличительным блоком структуры ЭС является логический блок (решатель), в котором вырабатывается экспертное заключение.

Структура классификации экспертных систем представлена на рис.2.

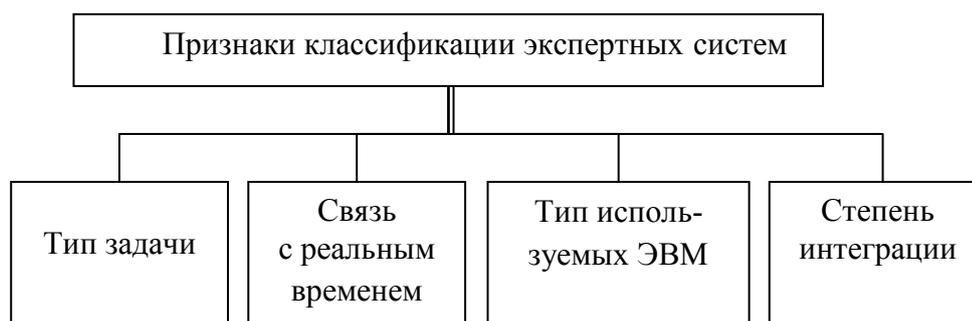


Рис. 2. Классификация экспертных систем

Классификация по решаемой задаче имеет вид:

1. Экспертные системы, обладающие средствами для интеллектуального анализа данных. Для интерпретации данных используются технологии Data Mining.

2. Диагностические экспертные системы. Они применяются при диагнозе технической системы, при диагностике в сфере медицины и в сфере финансов, банковского дела.

3. Экспертные системы мониторинга. Они способны дать объяснение данных в реальном масштабе времени, либо сигнализировать выход параметров за допустимые значения (границы) (например, в подразделениях министерства чрезвычайных ситуаций).

4. Экспертные системы прогнозирования. Системы, которые прогнозируют состояние финансового рынка, курс валют. ЭС прогнозирования являются первыми моделями аналитического плана, т. е. использующими элемент вероятности.

5. Экспертные системы планирования. С помощью таких систем составляется, например, бюджетное планирование, финансирование.

6. Экспертные системы для управления. Это системы, которые готовят варианты возможных решений для управления: например, системы-подсказчики для руководителей.

Классификация ЭС по связи с реальным временем:

1. Статические экспертные системы. К статическим относят такие системы, в которых базы данных и данные не меняются с течением времени (по меньшей мере, во время проведения экспертизы). Примером статической системы может служить ЭС диагностики технического состояния какого-либо устройства.

2. Динамические экспертные системы. Динамические системы применимы для задачи анализа, когда резко меняется ситуация или база знаний. Для работы такой системы должна существовать обратная связь и быстрые машины.

3. Квазидинамические экспертные системы. К квазидинамическим относятся ЭС, в которых если даже за время осуществления экспертизы параметры меняются, то при повторной экспертизе параметры остаются неизменными.

Классификация экспертных систем по типам применяемой архитектуры ЭВМ:

1. Экспертные системы с обычной архитектурой ЭВМ.
2. Экспертные системы со специальными нейрокомпьютерами – многопроцессорными вычислительными системами.

Классификация ЭС по степени интеграции с другими программами:

1. Автономные экспертные системы. К автономным ЭС относят системы, которые не требуют дополнительных программ для обработки данных.
2. Гибридные экспертные системы. К гибридным ЭС относят системы, которые работают с привлечением дополнительных программных средств.

Экспертные системы охватывают самые разные предметные области, среди которых лидируют бизнес, производство, медицина, проектирование и системы управления [1, 5-7, 15, 17, 18].

Нейронные сети. Искусственная нейронная сеть (ИНС) – это кибернетическая модель нервной системы, которая представляет собой совокупность большого числа сравнительно простых элементов – нейронов, топология соединения которых зависит от типа сети. Чтобы создать нейронную сеть для решения какой-либо конкретной задачи, следует выбрать способ соединения нейронов друг с другом и подобрать значения параметров межнейронных соединений.

Нейронные сети – обобщённое название группы математических алгоритмов, обладающих способностью обучаться на примерах, «узнавая» впоследствии черты встреченных образцов и ситуаций. Благодаря этой способности нейронные сети используются при решении задач обработки сигналов и изображений, распознавания образов, а также для прогнозирования [7].

ИНС представляет собой совокупность простых вычислительных элементов – искусственных нейронов, каждый из которых обладает определённым количеством входов (дендритов) и единственным выходом (аксоном), разветвления которого подходят к синапсам, связывающим его с другими нейронами. На входы нейрона поступает информация извне или от других нейронов. Каждый нейрон характеризуется функцией преобразования входных сигналов в выходной (функция возбуждения нейрона). Нейроны в сети могут иметь одинаковые или разные функции возбуждения. Сигналы, поступающие на вход нейрона, неравнозначны в том смысле, что информация из одного источника может быть более важной, чем из другого. Приоритеты входов задаются с помощью вектора весовых коэффициентов, моделирующих синаптическую силу биологических нейронов.

Модель искусственного нейрона представляет собой дискретно-непрерывный преобразователь информации. Информация, поступающая на вход нейрона, суммируется с учётом весовых коэффициентов w_i , сигналов x_i , $i = 1, \dots, n$, где n – размерность пространства входных сигналов. Потенциал нейрона определяется по формуле:

$$P = \sum_{i=0}^n x_i w_i.$$

Взвешенная сумма поступивших сигналов (потенциал) преобразуется с помощью передаточной функции $f(P)$ в выходной сигнал нейрона Y , который передается другим нейронам сети, т. е. $Y = f(P)$. Вид передаточной (активационной) функции является важнейшей характеристикой нейрона. В общем случае эта функция может быть ступенчатой (пороговой), линейной или нелинейной). Тип функции переноса выбирается с учётом конкретной задачи, решаемой с применением нейронных сетей. Например, в задачах аппроксимации и классификации предпочтение отдают логистической (сигмоидальной) кривой.

Нейронная сеть представляет собой совокупность искусственных нейронов, организованных слоями. При этом выходы нейронов одного слоя соединяются с входами нейронов другого.

В зависимости от топологии соединений нейронов ИНС подразделяются на одноуровневые и многоуровневые, с обратными связями и без них. Связи между слоями могут иметь различную структуру.

В однолинейных сетях каждый нейрон (узел) нижнего слоя связан с одним нейроном верхнего слоя. Если каждый нейрон нижнего слоя соединён с несколькими нейронами следующего слоя, то получается пирамидальная сеть. Воронкообразная схема соединений предполагает связь каждого узла верхнего слоя со всеми узлами нижнего уровня. Существуют также древовидные и рекуррентные сети, содержащие обратные связи с произвольной структурой межнейронных соединений.

Чтобы построить ИНС для решения конкретной задачи, нужно выбрать тип соединения нейронов, определить вид передаточных функций элементов и подобрать весовые коэффициенты межнейронных связей.

При всём многообразии возможных конфигураций ИНС на практике получили распространение лишь некоторые из них. Классические модели нейронных сетей:

- многослойные сети;
- сети Хопфилда;
- сети Хемминга;
- сети обратного распространения;
- сети встречного распространения;
- РБФ-сети;
- сети Кохонена и др.

С помощью нейронных сетей, которые относят к методам эволюционного моделирования, решается широкий класс задач: классификация образов, кластеризация, аппроксимация, прогноз данных, оптимизация, ассоциативная память, управление динамическими объектами. Причем в силу всего вышесказанного, нейронные сети в сравнении с методами математической статистики справляются с перечисленными задачами тем успешнее, чем хуже формализуема задача.

Нейросетевые технологии нашли широкое применение в таких направлениях, как распознавание печатного текста, контроль качества продукции на производстве, идентификация событий в ускорителях частиц, разведка нефти,

борьба с наркотиками, медицинские и военные приложения, управление и оптимизация, финансовый анализ, прогнозирование и др.

В сфере экономики нейросетевые технологии могут использоваться для классификации и анализа временных рядов путём аппроксимации сложных нелинейных функций.

Экспериментально установлено, что модели нейронных сетей обеспечивают большую точность при выявлении нелинейных закономерностей на фондовом рынке по сравнению с регрессионными моделями [7].

Когнитивное моделирование – это способ анализа, обеспечивающий определение силы и направления влияния факторов на перевод объекта управления в целевое состояние с учетом сходства и различия в влиянии различных факторов на объект управления.

Ведущей научной организацией России, занимающейся разработкой и применением технологии когнитивного анализа, является Институт проблем управления РАН. На их научных трудах в области когнитивного анализа и основывается данная лекция [11].

В основе технологии когнитивного анализа и моделирования (рис. 3) лежит когнитивная (познавательная-целевая) структуризация знаний об объекте и внешней для него среды.

Когнитивная структуризация предметной области – это выявление будущих целевых и нежелательных состояний объекта управления и наиболее существенных (базисных) факторов управления и внешней среды, влияющих на переход объекта в эти состояния, а также установление на качественном уровне причинно-следственных связей между ними, с учетом взаимовлияния факторов друг на друга.

Результаты когнитивной структуризации отображаются с помощью когнитивной карты (модели).

Отбор базисных факторов проводится путем применения **PEST-анализа**, выделяющего четыре основные группы факторов (аспекта), определяющих поведение исследуемого объекта:

- **Policy** – политика;
- **Economy** – экономика;
- **Society** – общество (социокультурный аспект);
- **Technology** – технология.

PEST-анализ можно рассматривать как вариант системного анализа, так как факторы, относящиеся к перечисленным четырем аспектам, в общем случае тесно взаимосвязаны и характеризуют различные иерархические уровни общества, как системы.

В этой системе есть детерминирующие связи, направленные с нижних уровней иерархии системы к верхним (наука и технология влияет на экономику, экономика влияет на политику), а также обратные и межуровневые связи. Изменение любого из факторов через эту систему связей может влиять на все остальные.

Эти изменения могут представлять угрозу развитию объекта, или, наоборот, предоставлять новые возможности для его успешного развития.

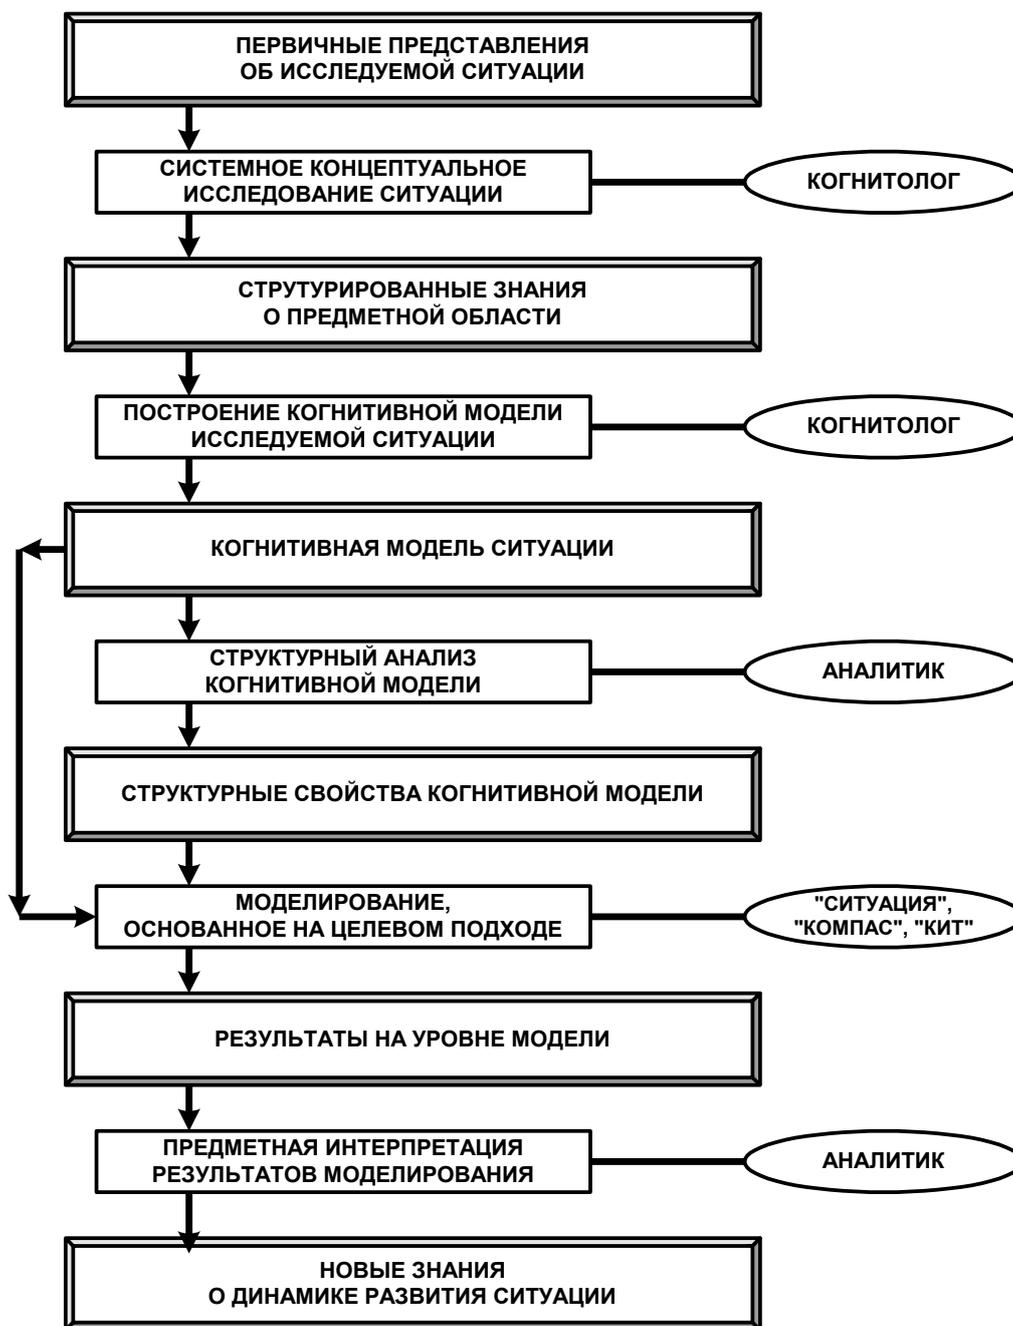


Рис. 3. Технология когнитивного анализа и моделирования

Следующий шаг – ситуационный анализ проблем, так называемый *SWOT-анализ*:

- Strengths – сильные стороны;
- Weaknesses – недостатки, слабые стороны;
- Opportunities – возможности;
- Threats – угрозы.

SWOT-анализ включает анализ сильных и слабых сторон развития исследуемого объекта в их взаимодействии с угрозами и возможностями и позволяет определить актуальные проблемные области, узкие места, шансы и опасности, с учетом факторов внешней среды.

Технология когнитивного анализа и моделирования поддерживается программными комплексами «Ситуация», «Компас», «КИТ» (см. рис. 3), созданными в ИПУ РАН, которые позволяют в сложных и неопределенных ситуациях быстро, комплексно и системно охарактеризовать и обосновать сложившуюся ситуацию и на качественном уровне предложить пути решения проблемы в этой ситуации с учетом факторов внешней среды.

Применение когнитивных технологий открывает новые возможности прогнозирования и управления в различных областях:

– в экономической сфере – позволяет в сжатые сроки разработать и обосновать стратегию экономического развития предприятия, банка, региона или даже целого государства с учетом влияния изменений во внешней среде;

– в сфере финансов и фондового рынка – учесть ожидания участников рынка;

– в военной области и области информационной безопасности – противостоять стратегическому информационному оружию, заблаговременно распознавая конфликтные структуры и вырабатывая адекватные меры реагирования на угрозы.

Когнитивные технологии автоматизируют часть функций процессов познания, поэтому они с успехом могут применяться во всех областях, в которых востребовано само познание. Вот лишь некоторые из этих областей:

1. Модели и методы интеллектуальных информационных технологий и систем для создания геополитических, национальных и региональных стратегий социально-экономического развития.

2. Модели выживания «мягких» систем в изменяющихся средах при дефиците ресурсов.

3. Ситуационный анализ и управление развитием событий в кризисных средах и ситуациях.

4. Информационный мониторинг социально-политических, социально-экономических и военно-политических ситуаций.

5. Разработка принципов и методологии проведения компьютерного анализа проблемных ситуаций.

6. Выработка аналитических сценариев развития проблемных ситуаций и управления ими.

7. Подготовка рекомендаций по решению первоочередных стратегических проблем на основе компьютерной системы анализа проблемных ситуаций.

8. Мониторинг проблем в социально-экономическом развитии корпорации, региона, города, государства.

9. Технология когнитивного моделирования целенаправленного развития региона РФ.

10. Анализ развития региона и мониторинг проблемных ситуаций при целенаправленном развитии региона.

Интеллектуальный анализ данных. Данная лекция основана на работах [8, 19-21]. К числу интеллектуальных технологий анализа данных относят технологии *Data Mining* (разведка, добыча данных), которые реализуют:

- поиск ранее неизвестных функциональных и логических закономерностей накопленной информации (интеллектуальная деятельность);
- построение моделей и правил с целью объяснения этих найденных закономерностей или найденных аномалий;
- прогнозирование развития изучаемых процессов.

Специфика современных требований к переработке данных:

- данные имеют практически неограниченный объем;
- данные являются разнородными (количественными, качественными, тестовыми и т.д.);
- результаты должны быть конкретны и понятны;
- инструменты для обработки «сырых», т. е. непроверенных, невалидированных данных должны быть просты в использовании.

Процесс обнаружения в «сырых» данных включает в себя поиск:

- ранее неизвестных знаний;
- нетривиальных выводов;
- практически полезных выводов;
- доступных для интерпретации знаний, необходимых для принятия решений в различных сферах человеческой деятельности.

Место технологий *Data Mining* среди других технологий обработки данных по уровню знаний, извлекаемых из данных, приведено на рис 4.



Рис. 4. Схема уровней знаний, извлекаемых из данных

Data Mining применяется в следующих отраслях:

- торговля, в том числе и розничная (анализ покупательской корзины, анализ временных шаблонов, создание прогнозируемых моделей);
- страхование;
- банковское дело (выявление мошенников с кредитными карточками, сегментация клиентов (разбиение на группы – каким клиентам какие услуги предлагать), прогнозирование изменения клиентуры);
- в сфере коммуникаций (здесь ставятся следующие задачи: анализ записей по характеристикам вызовов – какой круг клиентов, какими видами услуг пользуется; выявление лояльности клиентов);
- химия;
- промышленность;
- медицина и т. д.

Успех применения систем Data Mining основан на том, что эти технологии обеспечивают исследование эмпирических данных и выявление в них скрытых закономерностей различных видов, т. е. обеспечивают решение следующих задач:

1. Классификация – задача выявления признаков однотипных объектов для того, чтобы отнести новый объект к тому или иному классу.
2. Кластеризация – развитие идеи классификации на более сложный случай, когда сами классы объектов не predetermined, но стоит задача определить однородные группы данных.
3. Выявление ассоциаций – установление правил, указывающих на то, что при наступлении одного события с определенной вероятностью наступает другое.
4. Выявление последовательностей – установление связи между событиями, наступающими не одновременно, а с некоторым временным шагом.
5. Задача прогнозирования – оценка будущих значений, определяемых показателей на основе их текущих и ретроспективных данных. Это наиболее сложная из перечисленных задач.

Процесс информационной деятельности может быть представлен рядом временных стадий, которые изображены на рис.5.

Свободный поиск – это процесс исследования накопленных данных на предмет поиска скрытых закономерностей без предварительного выявления гипотез относительно этих закономерностей (если гипотеза скрытая, то поиск свободный).

В процессе свободного поиска используется математический аппарат условной логики, с помощью правил которой могут быть описаны группы примеров в задачах классификации и кластеризации.

На основе использования правил ассоциативной логики можно решать задачи выявления ассоциаций и последовательностей.

Выявление трендов (наличие какой-то устойчивой закономерности в том объеме данных, которые используются) и колебаний является первым этапом программирования.

Стадии					
Свободный поиск			Прогностическое моделирование		Анализ исключений
Выявление закономерностей условной логики	Выявление закономерностей ассоциативной логики	Выявление трендов и колебаний	Предсказание неизвестных значений	Предсказание развития процессов	Выявление и объяснение отклонений
Действия					

Рис. 5. Стадии информационной деятельности

Вторая стадия информационной деятельности – прогностическое моделирование. Осуществление действий на этой стадии становится возможным после выполнения действий на стадии свободного поиска.

Третья стадия – анализ исключения из правил. Данная стадия занимается тем, чем обусловлено выпадение какого-то параметра от ранее установленной закономерности, выявляются отклонения и даются им объяснения.

Математической основой систем Data Mining являются следующие методы поиска различных закономерностей в данных: деревья решений; алгоритмы кластеризации; регрессионный анализ; нейронные сети; временные ряды и др. Указанные методы и программные продукты Data Mining подробнее описаны в главе 3.

Генетические Алгоритмы (ГА) – это адаптивные методы функциональной оптимизации, основанные на компьютерном имитационном моделировании биологической эволюции. Основные принципы ГА были сформулированы Голландом в 1975 году и хорошо описаны во многих работах и на ряде сайтов в Internet [7-8].

В генетических алгоритмах используются специфические термины, взятые из генетики, которые трактуются следующим образом. Исходные логические закономерности в базе данных именуют хромосомами, а весь набор закономерностей называют популяцией хромосом. Популяция обрабатывается с помощью процедур репродукции, изменчивости (мутаций), генетической композиции. В ходе работы процедур на каждой стадии эволюции получают популяции со все более совершенными индивидуумами.

Генетические алгоритмы сконструированы таким образом, что при генерации каждой новой популяции используются фрагменты исходных решений, к которым добавляются новые элементы, обеспечивающие улучшение решений относительно сформулированного критерия отбора. Другими словами, генети-

ческие алгоритмы используют информацию, накопленную в процессе эволюции.

В генетических алгоритмах и эволюционном программировании используют два основных механизма воспроизводства хромосом:

- воспроизводство без мутаций, соответствующее митозу, результатом которого являются потомки – копии родителей;
- воспроизводство потомков, имеющих большие отличия от родителей. Этот механизм соответствует половому размножению.

В генетических алгоритмах в основном используется механизм родительского воспроизводства с рекомбинацией и мутацией, а в эволюционном программировании – механизм на основе мутации без рекомбинации.

Таким образом, по сути дела каждый конкретный генетический алгоритм представляют имитационную модель некоторой определенной теории биологической эволюции или ее варианта. Материальное воплощение сконструированных таким образом систем до сих пор была невозможна без участия человека. Однако интенсивно ведутся работы, результатом которых является уменьшение зависимости машинной эволюции от человека. Эти работы ведутся по двум основным направлениям:

1. Естественный отбор, моделируемый ГА, переносится из виртуального мира в реальный, например, проводятся эксперименты по реальным битвам роботов на выживание.

2. Интеллектуальные системы, основанные на ГА, конструируют роботов, которые в принципе могут быть изготовлены на автоматизированных заводах без участия человека.

Генетические алгоритмы используют в теории нечётких систем для настройки параметров функций принадлежности. Интеграция чётких и нечётких нейронных сетей и генетических алгоритмов обеспечивает реализацию оптимизационной задачи. Средства fuzzy–neuro–genetic используются в интеллектуальных системах и содержат следующие процедуры:

- преобразование входных примеров в нечёткое представление;
- извлечение знаний, представленных в виде продукций ЕСЛИ–ТО из нечёткой обучающей выборки с помощью нейронной сети;
- оптимизацию структуры продукционных правил с помощью генетического алгоритма.

Активно развивается направление, ориентированное на использование генетических алгоритмов для обучения нейронных сетей и корректировки структуры уже обученной сети. В отличие от метода обратного распространения ошибки генетические алгоритмы мало чувствительны к архитектуре сети. Генетические алгоритмы чаще всего применяются для улучшения характеристик ИНС, уже созданных и обученных с применением других методов

На основе генетических алгоритмов предложены классифицирующие системы, которые можно использовать для целей управления. Классифицирующая система состоит из трёх вложенных друг в друга подсистем: классификатора, системы обучения и генетического алгоритма. В классификатор поступают

внешние сообщения и положительные оценки (поощрения) его действий. Классификатор содержит правила вида «ЕСЛИ<условие>, ТО<сообщение>», с помощью которых формируются выходные сообщения. Обучающая система выполняет оценку используемых правил. Генетический алгоритм предназначен для случайно направленной модификации правил.

В настоящее время активно развиваются методы, основанные на объединении технологий инженерии знаний и генетических алгоритмов. В области ГА разрабатываются операторы, ориентированные на обработку знаний.

Генетические алгоритмы нашли широкое практическое применение в менеджменте и управлении для решения задач поиска оптимальных решений, формирования моделей и прогнозирования значений различных показателей. Они осуществляют поиск лучших решений на основе заданной целевой функции. Значение целевой функции для многих задач весьма непросто вычислить, поэтому в ряде случаев при исследовании плохо обусловленных проблем с этой целью применяются нейронные сети, позволяющие найти решение при отсутствии явной модели. Кроме того, для вычисления целевых функций в условиях неопределённости применяются статистические методы и методы логического вывода в чёткой или нечёткой среде.

Формирование системы прогнозирующих правил. Генетические алгоритмы могут использоваться для нахождения оптимального набора правил, позволяющих прогнозировать страховые риски с учётом ряда определяющих его факторов. Для решения этой задачи необходимо иметь базу данных, содержащую фактические значения переменных, влияющих на страховой риск.

Выводы

Современное состояние разработок в области интеллектуальных систем в России можно охарактеризовать как стадию все возрастающего интереса среди широких слоев специалистов – менеджеров, инженеров, программистов и других. Наибольшие трудности в разработке интеллектуальных систем, основанных на знаниях, вызывает не сколько процесс машинной реализации систем, а этап анализа знаний и проектирования базы знаний.

Создание интеллектуальных систем должно включать три этапа:

- создание материальной системы поддержки (эта проблема в основном решена, так как ИС могут создаваться даже на базе современных персональных компьютеров);
- создание системы потенциального искусственного интеллекта, то есть программной оболочки, инструментальной системы (таких систем в настоящее время существует пока еще очень мало);
- обучение и самообучение системы искусственного интеллекта и преобразование ее в реальную ИС.

Интеллектуальные системы применяются для решения сложных задач, связанных с использованием слабо формализованных знаний специалистов-практиков, а также с логической обработкой информации. Например, поддерж-

ка принятия решения в сложных ситуациях, анализ визуальной информации, управление в социально-экономической сфере.

Контрольные вопросы

1. Перечислите основные проблемы искусственного интеллекта и направления его развития.
2. Назовите основные направления исследований в области искусственного интеллекта.
3. Какова история исследований в области искусственного интеллекта в нашей стране и за рубежом?
4. Перечислите признаки интеллектуальных информационных систем.
5. Сформулируйте характеристики базовых интеллектуальных структур для анализа интеллектуальности систем.
6. Дайте определение понятия «интеллектуальная система», ее место в классификации информационных систем.
7. Сформулируйте основные отличия интеллектуальных систем от обычных программных систем.
8. Приведите классификацию интеллектуальных систем, цели и пути их создания.
9. Перечислите основные типы систем с интеллектуальным интерфейсом и дайте им краткую характеристику.
10. Перечислите основные типы экспертных систем и дайте им краткую характеристику.
11. Перечислите и охарактеризуйте основные компоненты экспертных систем.
12. Каков вид передаточной (активационной) функции нейрона?
13. Назовите классические модели нейронных сетей.
14. Назовите и дайте краткую характеристику базовым архитектурам нейронных сетей.
15. Охарактеризуйте место технологий интеллектуального анализа данных (Data Mining) среди других технологий обработки данных.
16. Сформулируйте задачи и стадии интеллектуального анализа данных и типы определяемых закономерностей.
17. Перечислите основные направления эволюционного моделирования и приведите основные факторы, определяющие неизбежность эволюции.
18. Какие алгоритмы называют генетическими? Сформулируйте основные особенности генетических алгоритмов.
19. Как проводится отбор базисных факторов управления и внешней среды, влияющих на переход объекта в будущие целевые и нежелательные состояния при когнитивной структуризации предметной области?
20. Назовите области применения когнитивных технологий для решения задач прогнозирования и управления.

Глава 2. МОДЕЛИ ПРЕДСТАВЛЕНИЯ ЗНАНИЙ В ИНТЕЛЛЕКТУАЛЬНЫХ СИСТЕМАХ

2.1. Представление знаний, рассуждений и задач

Систему знаний (СЗ) можно определить как некую математическую модель определенной области прикладного неформализованного знания. Система понятий и отношений этой математической модели должны отображать систему понятий и отношений прикладного знания, а зависимости, существующие в этой модели, аппроксимируют соответствующие зависимости прикладного знания [5, 8, 12, 25].

Разработанные модели должны быть зафиксированы в памяти ЭВМ и использоваться для решения с помощью прикладных программ.

Создание интеллектуальных систем, основанных на знаниях, связано с решением следующих взаимосвязанных проблем:

1. Проблема формализации знаний. Эта задача решается с помощью специалистов-прикладников и математиков. Результатом ее будет разработка концептуальной схемы модели.

2. Проблема представления знаний. Ее решение состоит в разработке формального аппарата для фиксации знаний в памяти ЭВМ.

3. Проблема использования знаний. Суть ее заключается в необходимости разработки теории вычислений и преобразований в построенных ранее моделях.

4. Проблема создания баз знаний и систем управления ими. Эта задача для системных программистов по разработке средств программной поддержки моделей знаний.

Знания о предметной области и способах решения в ней задач весьма разнообразны. Возможны различные классификации этих знаний, которые подробно описаны в литературе по управлению знаниями, в частности в [12, 25].

Требования к системам знаний. Выделяют следующие особенности, которыми должна обладать система знаний:

– Терпимость к противоречиям, которая вытекает из открытости внешнего мира и соответственно неполноты знаний о нем.

– Обеспечение вывода, т.е. система знаний должна быть способна к логическому выводу как из уже имеющейся информации, так и из вновь поступающих сведений. Различают два типа вывода:

– свободный (вывод осуществляется при поступлении новой информации в СЗ);

– направленный (вывод запускается при поступлении в СЗ конкретного запроса).

– Критичность к новой информации. Это способность проверить достоверность новой информации и согласовать её с имеющимися знаниями.

– Дробность системы знаний – знания в системе должны быть разбиты на фрагменты, каждый из которых может быть эффективно использован.

– Обучаемость и способность к переструктурированию знаний, т. е. в ходе функционирования должна обеспечиваться перестройка структуры СЗ, повышающая ее эффективность.

Особенности знаний для их представления в ЭВМ. Для представления СЗ в компьютере она должна обладать следующими особенностями:

1. Внутренняя интерпретируемость – каждая информационная единица должна иметь уникальное имя, по которой бы информационная система находила ее, а также отвечала бы на запросы, в которой это имя упомянуто.

2. Структурированность знаний, т. е. информационные единицы должны обладать определенной структурой, это означает, что должны быть возможности для установления отношений типа: часть – целое или род – вид, или элемент – класс.

3. Связность – в информационной базе между информационными единицами должна быть возможность установления связей различного типа, характеризующих отношения между ними. Семантика отношений может носить декларативный или процедурный характер.

Различают отношения структуризации, функциональные отношения типа аргумент – функция, казуальные отношения (причинно – следственные связи) и семантические отношения (объединяют и представляют все ранее перечисленные связи).

Перечисленные особенности позволяют создавать общую модель знаний, которую называют «семантическая сеть». Она представляет модель знаний, в вершинах которой находятся информационные единицы, а дуги характеризуют виды связей между информационными единицами. Если связи иерархичны, то они определяют отношения структуризации, а неиерархические связи будут определять отношения иных типов.

4. Семантическая метрика – отношение, которое характеризует ситуационную близость информационных единиц, т.е. силу ассоциативных связей между ними.

5. Активность. Появление новых данных должны стать источником активности интеллектуальной системы, т.е. выполнение программ в ИС должно инициироваться текущим состоянием информационной базы.

Перечисленные пять особенностей информационных единиц определяют ту грань, за которой данные превращаются в знания, базы данных перерастают в базы знаний (БЗ), а совокупность средств, обеспечивающих работу со знаниями, образуют систему управления базой знаний (СУБЗ).

Таким образом, база знаний (англ. Knowledge Base, KB) – это особого рода база данных, разработанная для управления знаниями (метаданными), то есть сбором, хранением, поиском и выдачей знаний. Раздел искусственного интеллекта, изучающий базы знаний и методы работы со знаниями, называется инженерией знаний. Под базами знаний понимают совокупность фактов и правил вывода, допускающих логический вывод и осмысленную обработку информации.

База знаний – важный компонент интеллектуальной системы. Наиболее известный класс таких программ – экспертные системы. Они предназначены для построения способа решения специализированных проблем, основываясь на записях БЗ и на пользовательском описании ситуации.

Создание и использование систем искусственного интеллекта потребует огромных баз знаний.

2.2. Модели представления знаний

В интеллектуальных системах в соответствии с [2, 5, 8] наиболее распространенными являются следующие способы представления знаний:

1. Логические модели.
2. Сетевые модели.
3. Фреймовые модели.
4. Продукционные модели.
5. Другие методы представления знаний.

Логические модели. В основе модели лежит формальная система, которая на языке теории множеств описывается следующей четверкой множеств:

$$M = \langle T, P, A, B \rangle,$$

где T – это множество базовых элементов различной природы, представляющих тезаурус, например: термины из какого либо словаря, набор деталей из конструкции; P – это множество синтаксических правил, с помощью которых из элементов множества T образуют синтаксически правильные совокупности; A – элементы этого множества образуют аксиомы, определенные на множестве P ; B – множество правил вывода, которые применяются к элементам множества A .

Для множества T существует некоторый способ $\Pi(T)$ определения принадлежности к этому множеству, а для определения принадлежности к множеству A вводится процедура $\Pi(A)$.

Во множество A входят информационные единицы, которые введены в базу извне, а с помощью правил вывода из них получают новые производные знания. Таким образом, описанная система представляет собой генератор порождения новых знаний в данной предметной области.

Логические модели представления знаний реализуются с помощью логики предикатов. Предикатом называют функцию, принимающую только два значения: истина и ложь и предназначенную для выражения свойств объектов или связей между ними. Кроме того, могут использоваться логические знаки конъюнкции (\vee), импликации (\wedge), логического следования (\Rightarrow), кванторы \forall, \exists и другие.

Рассмотрим в качестве примера знание: «Когда температура в печи достигает 120° и прошло менее 30 мин с момента включения печи, то давление не превосходить критического. Если с момента включения прошло более 30 мин, то необходимо включить вентиль N2».

В этой записи первая строка представляет собой описание декларативного знания, а вторая строка описывает процедурные знания.

С помощью логики предикатов, указанное утверждение выглядит следующим образом:

$$P(p = 120) T(t < 30) \rightarrow (D < D_{кр.}); \\ P(p = 120)T(t > 30) \Rightarrow F(N2),$$

где $P(p = 120)$ создает предикат, который становится истинным, когда температура достигается 120° ; $T(t < 30)$ – предикат, остающийся истинным в течение 30 мин с начала процесса; $T(t > 30)$ – предикат, становящийся истинным по истечении 30 мин; $(D < D_{кр.})$ – это утверждение о том, что давление ниже критического; $F(N2)$ – команда открыть вентиль $N2$.

Разработанные системы логического программирования Пролог, в ответах на простейшие запросы к базам знаний, выдают значения «истина» и «ложь» в зависимости от наличия соответствующих фактов [15, 16]. Преимущества логической модели представления знаний заключается в возможности непосредственно запрограммировать механизм вывода правильных высказываний.

Подобные языки логического типа использовались на ранних стадиях развития интеллектуальных систем, однако впоследствии большее внимание стали уделять другим моделям, что связано с такими недостатками логической модели, как отсутствие наглядности и удобочитаемости, а также громоздкость записи, которая приводит к трудности нахождения ошибок. Еще один недостаток состоит в том, что большинство интеллектуальных задач характеризуется недостаточной полнотой, неточностью и некорректностью. Это важно, например, в медицине и биологических науках, так как они слабо формализованные. Поэтому в данных областях науки чаще используют методы аналогий и ассоциаций.

Сетевые модели. В основе этой модели лежит конструкция, которая называется семантической сетью, которая может быть описана на языке теории множеств:

$$H = \langle I, C1, C2, \dots, Cn, G \rangle,$$

где I – множество информационных единиц; $C1, C2, \dots, Cn$ – множество типов связей между информационными единицами; G – множество отображений между информационными единицами.

В зависимости от типов связей между информационными единицами, которые используются в данной модели, различают следующие типы сетей:

- Классифицирующие сети – применяют отношение структуризации.
- Функциональные сети – функциональные отношения между информационными единицами. Примером могут выступать вычислительные модели.
- Сценарии.

В сценариях часто используются казуальные отношения (причинно-следственные отношения) между информационными единицами. Кроме того, могут встречаться отношения следующих типов «средство – результат», «орудие – действие» и т. п.

Так семантическая сеть, представляющая знания об автомобиле гр. Васильева, показана на рис. 6.

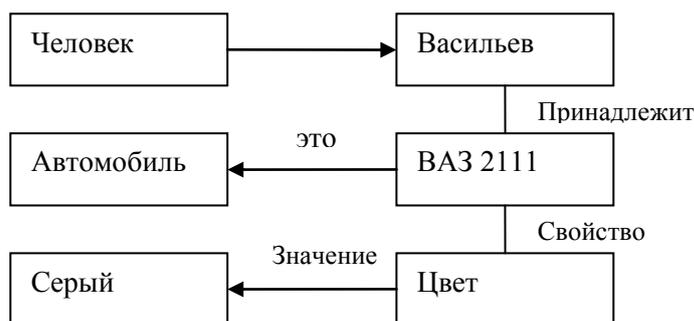


Рис. 6. Пример семантической сети

Преимущества модели представления знаний на основе семантических сетей: с помощью этой модели могут быть представлены родовидовые отношения; простота и наглядность описания предметной области.

Недостатки модели представления знаний на основе семантических сетей: снижение скорости работы механизма вывода, а также понижение быстродействия.

Фреймовые модели. Фреймы часто используют как структуру для представления стереотипных ситуаций. Фрейм – единица представления знаний, детали которой могут изменяться в соответствии с текущей ситуацией.

Структура фрейма такова, что он состоит из характеристик описанных ситуаций и их значений, которые называются соответственно слотом и заполнителем слота.

Имя фрейма:

Имя слота 1 (Значение слота 1);

Имя слота 2 (Значение слота 2);

.....

Имя слота k (Значение слота k).

Эта структура, пока она не заполнена какими-то значениями, называется протофреймом. Значением слота может быть число, математическое выражение, текст на естественном языке, программа для ЭВМ, правила вывода, ссылки на другие слоты данного фрейма или других фреймов.

При заполнении фрейма, имени слота и значения слотов из протофрейма получают фрейм-экземпляр (экзофрейм).

Пример:

Список работников: Фамилия (значение слота 1);

Год рождения (значение слота 2);

.....

Стаж работы (значение слота k).

Список работников: Фамилия (Попов – Сидоров – Иванов);

Год рождения (1965 – 1946 – 1925);

.....

Стаж работы (5 – 20 – 30).

Преимущество фреймовой модели заключается в том, что значения слотов представляются в такой системе в единственном экземпляре, поскольку включается только в один фрейм. Таким образом, обеспечивается экономное размещение баз знаний в памяти компьютера.

Недостатком фреймовой модели является снижение скорости работы механизма вывода, т. е. системы должны «просканировать» всю структуру на предмет ненужной информации.

Продукционные модели. Психологические исследования процессов принятия человеком решений показали, что, рассуждая и принимая решения человек, использует правила, аналогичные продукциям. Продукционная модель, основанная на правилах, позволяет представить знания в виде предложений типа «если (условие), то (действие)».

В общем случае продукцию можно представить в виде следующего выражения:

$$(i); Q; P; A \Rightarrow B; N,$$

где (i) – имя продукции, с помощью которой данная продукция выделяется из всего множества (порядковый номер, некоторая совокупность слов или цифр).

Элемент Q характеризует сферу применения продукции.

Основным элементом продукции является ее ядро $A \Rightarrow B$. Оно может быть прочитано: если выполняется A , то следует B . Ядро продукции описывает преобразования, которые представляют суть продукционного правила.

Элемент P есть условие применимости ядра продукции. Обычно P представляет собой логическое выражение типа предиката. Если P принимает значение «истина», то ядро продукции активируется, если P ложно, то ядро продукции не может быть использовано.

Элемент N описывает постусловие продукции. Оно активируется, когда ядро продукции реализовано. N – это действия и условия процедуры, которые могут быть выполнены после P .

Таким образом, продукционная модель хорошо применима для представления процедурных знаний.

Имя продукции i – интерпретация результатов психологического тестирования.

Предусловие Q – использовать в первую очередь.

Условие P – шкала лжи $L < 70$.

Ядро $A \Rightarrow B$ – если (шкала ошибок – шкала коррекции) $< - 11$, то сообщение: «Результаты недостоверны».

Постусловие N – закончить интерпретацию результатов.

Все ядра можно разделить на 2 большие группы:

1. Детерминированные ($A \Rightarrow B$ наступит с вероятностью 1).
2. Недетерминированные (если A выполняется, то возможно B).

Возможны различные оценки реализации ядра:

1. Вероятностная (если выполняется A , то с вероятностью P реализуется B).

2. Лингвистическая (малая, меньшая). Если выполняется A , то с большой долей уверенности наступит B .

Детерминированные продукции могут быть:

1. Однозначными (если выполняется A , то наступит B).

2. Альтернативные (если A выполняется, то чаще наступит $B1$, реже $B2$).

Продукции могут быть прогнозирующего типа (если наступит A , то с вероятностью P можно ожидать B).

Продукционной называется система знаний, которая использует понятие продукции в качестве основного элемента.

В общем случае продукционная система знаний (см. рис. 1) включает следующие компоненты:

1. Базу данных, содержащую множество фактов;

2. Базу правил, содержащую набор продукций;

3. Механизм логического вывода или решатель;

4. ЭВМ;

5. Система общения с внешней средой.

Продукционные системы делят на 2 типа:

1. С прямым выводом, т. е. рассуждения, идут от данных к гипотезе.

2. С обратным выводом, когда вначале выдвигается гипотеза, а потом для нее ищутся доказательства.

Достоинства продукционных систем:

– модульность;

– единообразие структуры (позволяет применять оболочку продукционных систем в различных проблемных областях);

– естественность вывода знаний;

– гибкость родовидовой иерархии понятий (изменение правил влечет изменения в иерархии).

Недостатки продукционных систем:

– процесс вывода может быть менее эффективен, чем в других системах.

– процесс вывода новых знаний трудно поддается управлению.

– линейный рост объема базы знаний по мере включения новых фрагментов знаний. Если используются деревья решений, то изменения происходят по логарифмическому закону.

Другие методы представления знаний. В качестве других методов представления знаний можно указать представление знаний по примерам. При использовании такого метода база знаний заполняется следующим образом: инженер по знаниям берет задачу и заполняет матрица из совокупности задач и правильных решений. Можно построить программу с поиском аналогичной задачи (метод на основе примеров).

Такой метод применяется, например, в области медицины и в юридической практике.

Достоинством метода представления знаний по примерам является простота данного способа, т. е. для данной задачи находится метод и вносится в память.

К недостатку можно отнести отсутствие интеллектуальной гибкости.

Выводы

Центральная парадигма интеллектуальных технологий – это обработка знаний. Системы, ядром которых является база знаний или модель предметной области, описанная на языке сверхвысокого уровня, приближенном к естественному языку, называют интеллектуальными.

В связи с организацией базы знаний в информационной системе, возникли задачи по поиску оптимального и верного решения на поставленную задачу перед информационной системой. Таким образом, неструктурированную массу знаний нужно было представить в такой форме, которая позволяла бы найти оптимальное решение с наименьшими затратами, например, временными. И начиная со второй половины 20-го века в области искусственного интеллекта стали появляться различные методы представления знаний.

Рассмотренные модели представления знаний широко используются в современных интеллектуальных системах и прежде всего в экспертных системах. Каждая из форм представлений знаний может служить основой для создания языка программирования, ориентированного на работу со знаниями. В конце 80-х годов наметилась тенденция создавать комбинированные языки представления знаний. Чаще всего комбинируются фреймовые и продукционные модели.

Контрольные вопросы

1. Определение системы знаний для задач создания интеллектуальных систем.
2. Требования к системам знаний в задачах создания интеллектуальных систем.
3. Особенности знаний для их представления в компьютере.
4. Понятие инженерии знаний и баз знаний.
5. Понятие и сравнительные характеристики основных моделей представления знаний.
6. Модели представления знаний, основанные на логике предикатов, их преимущества и недостатки, области применения.
7. Семантические сети: понятие и их роль для формализации знаний.
8. Фрейм как жесткая структура информационных единиц для представления стереотипных ситуаций, достоинства и недостатки фреймовых систем.
9. Сценарии – описание стандартной последовательности фактов, определяющих типичную ситуацию предметной области.
10. Определение продукции, классификация ядер продукции, типовая схема продукционной системы (база данных, база правил, интерпретатор). Преимущества и недостатки продукционной системы.

Глава. 3. ИЗВЛЕЧЕНИЕ ЗНАНИЙ ИЗ ДАННЫХ МЕТОДАМИ ИНТЕЛЛЕКТУАЛЬНОГО АНАЛИЗА ДАННЫХ

3.1. Особенности и классификация методов интеллектуального анализа данных

Потоки текстовой и числовой информации ежедневно порождаются и оседают в хранилищах данных. Закономерности, которые скрываются в этих массивах данных, могут представлять большую ценность.

С другой стороны в связи с высокой трудоемкостью извлечения знаний по обычной технологии инженерии знаний, в последнее время интенсивно разрабатывались методы автоматического извлечения знаний из накопленных фактов. В основе этих методов лежат известные из логики методы индуктивного вывода и ряд методов распознавания образов. В западной литературе эти методы получили название «*раскопка данных и открытие знаний*» – *Data Mining (DM)* и *Knowledge Discovery in Databases (KDD)*. В отечественной литературе привился термин «Интеллектуальный анализ данных» (ИАД) [8, 19-21].

Процесс Knowledge Discovery in Databases, состоит из следующих шагов:

1. **Подготовка исходного набора данных.** Этот этап заключается в создании набора данных, в том числе из различных источников, выбора обучающей выборки и т. д. Для этого должны существовать развитые инструменты доступа к различным источникам данных. Желательно иметь поддержку работы с хранилищами данных и наличие семантического слоя, позволяющего использовать для подготовки исходных данных не технические термины, а бизнес понятия.

2. **Предобработка данных.** Для того чтобы эффективно применять методы Data Mining, следует обратить внимание на вопросы предобработки данных. Данные могут содержать пропуски, шумы, аномальные значения и т. д. Кроме того, данные могут быть избыточны, недостаточны и т. д. В некоторых задачах требуется дополнить данные некоторой априорной информацией. Наивно предполагать, что если подать данные на вход системы в существующем виде, то на выходе получим полезные знания. Данные должны быть качественны и корректны с точки зрения используемого метода DM. Поэтому первый этап KDD заключается в предобработке данных. Более того, иногда размерность исходного пространства может быть очень большой, и тогда желательно применять специальные алгоритмы понижения размерности. Это как отбор значимых признаков, так и отображение данных в пространство меньшей размерности.

3. **Трансформация, нормализация данных.** Этот шаг необходим для приведения информации к пригодному для последующего анализа виду. Для чего нужно проделать такие операции, как приведение типов, квантование, приведение к «скользящему окну» и прочее. Кроме того, некоторые методы анализа, которые требуют, чтобы исходные данные были в каком-то определенном виде. Нейронные сети, скажем, работают только с числовыми данными, причем они должны быть нормализованы.

4. **Data Mining.** На этом шаге применяются различные алгоритмы для нахождения знаний. Это нейронные сети, деревья решений, алгоритмы кластеризации, установления ассоциаций и т. д.

5. **Постобработка данных.** Интерпретация результатов и применение полученных знаний в бизнес приложениях.

Безусловно, сердцем всего этого процесса KDD являются методы DM, позволяющие обнаруживать знания.

Классической основой извлечения знаний из накопленных данных является математическая статистика. Методы математической статистики оказались полезными, главным образом, для проверки заранее сформулированных гипотез и для «грубого» разведочного анализа, составляющего основу оперативной аналитической обработки данных.

***Интеллектуальный анализ данных** — это процесс поддержки принятия решений, основанный на поиске в данных скрытых закономерностей, то есть извлечения информации, которая может быть охарактеризована как знания.*

Интеллектуальный анализ данных является кратким обозначением довольно широкого спектра процедур автоматического анализа данных высокоинтеллектуальными технологиями. Эти методы позволяют извлекать из «сырых» данных ранее неизвестные зависимости между параметрами объектов и закономерности поведения классов объектов. Подобные программные продукты позволяют как бы «осмыслить» данные, оценивая их как с количественной, так и с качественной точки зрения.

Сферы применения систем Data Mining, задачи и стадии ИАД приведены в параграфе 1.4 данного пособия. Далее предлагается изложение основных методов ИАД, примеры их программной реализации для различных предметных областей в соответствии с [8, 19-21, 27].

В последнее время наряду с использованием арсенала классической статистики активно развиваются новые методы анализа данных и извлечения знаний, базирующиеся на иных, нежели традиционная интегро–дифференциальная парадигма, подходах и представленные на рис. 7:

- методы эволюционного моделирования,
- методы машинного обучения.

Термин «эволюционное моделирование» в настоящее время является достаточно устоявшимся, и общепринято под этим термином подразумевать генетические алгоритмы и искусственные нейронные сети.

Термин «машинное обучение» оставляет больше возможностей для дискуссий о том, какие методы имеются в виду, в частности, сюда относятся деревья решений.

Сформированы методологии анализа и основных принципов работы с данными в процессе анализа данных, поиска закономерностей и извлечения знаний не зависит от конкретной предметной области, поэтому может с успехом применяться для решения самого широкого спектра задач.

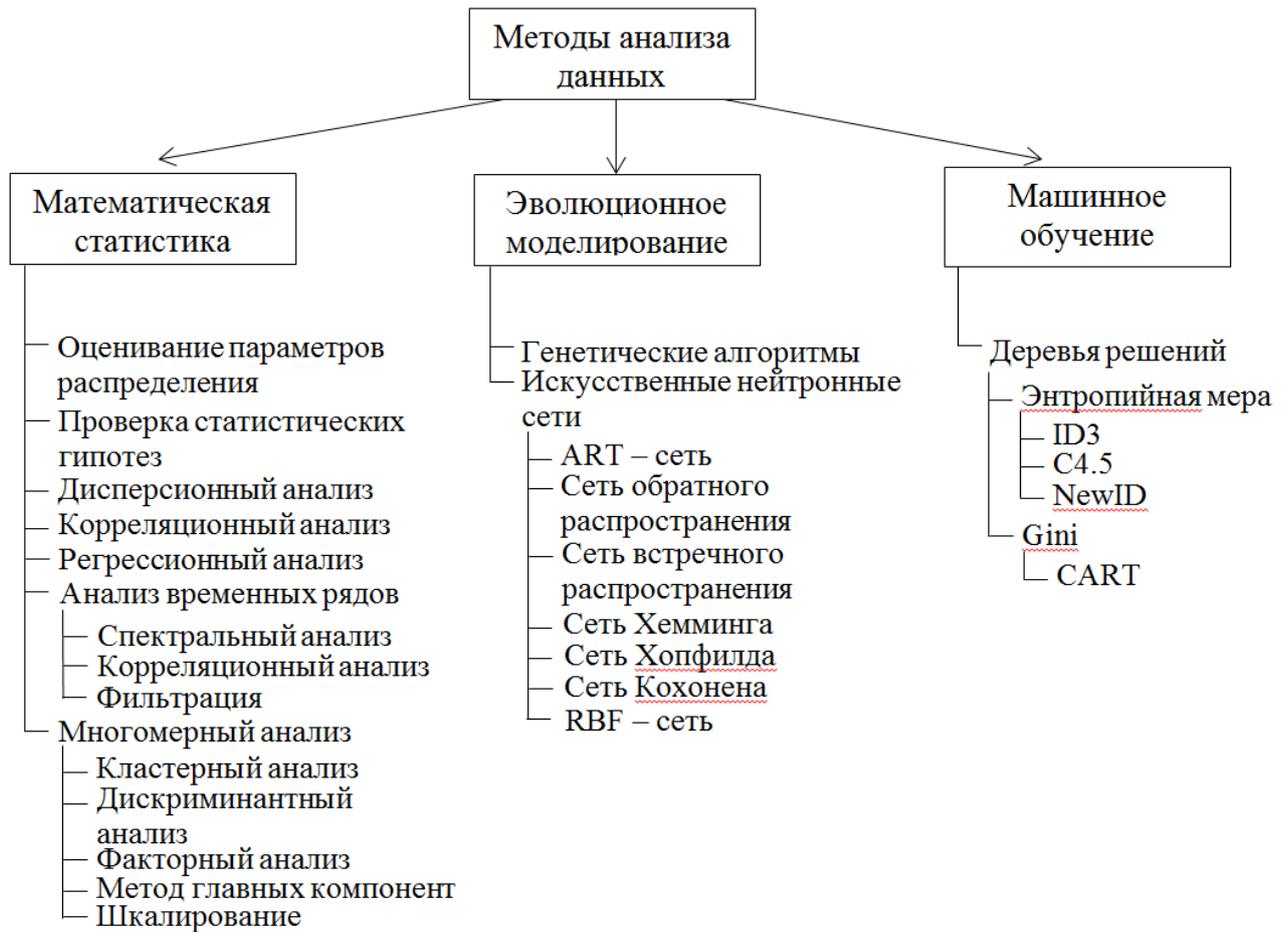


Рис.7. Классификация методов анализа данных

Алгоритмы, используемые в Data Mining, требуют большого количества вычислений. Раньше это являлось сдерживающим фактором широкого практического применения DM, однако сегодняшний рост производительности современных процессоров снял остроту этой проблемы. Теперь за приемлемое время можно провести качественный анализ сотен тысяч и миллионов записей.

Далее будут рассмотрены ряд методов интеллектуального анализа данных из числа приведенных на рис. 7. Приводится краткое изложение основных положений из статей Н.Б. Паклина и др., изложенных на сайте компании Base Group Labs – профессионального поставщика программных продуктов и решений в области анализа данных [27].

3.2. Логистическая регрессия и ROC-анализ данных

Логистическая регрессия – полезный классический инструмент для решения задачи регрессии и классификации. Без логистической регрессии и ROC-анализа, как аппарата для анализа качества моделей, немыслимо построение моделей в медицине и проведение клинических исследований. В последние годы логистическая регрессия получила распространение в скоринге для расчета рейтинга заемщиков и управления кредитными рисками. Поэтому, несмотря на

свое происхождение из статистики, логистическую регрессию и ROC-анализ почти всегда можно увидеть в наборе Data Mining алгоритмов.

Логистическая регрессия – это разновидность множественной регрессии, общее назначение которой состоит в анализе связи между несколькими независимыми переменными (называемыми также регрессорами или предикторами) и зависимой переменной. Бинарная логистическая регрессия, как следует из названия, применяется в случае, когда зависимая переменная является бинарной (т. е. может принимать только два значения). Иными словами, с помощью логистической регрессии можно оценивать вероятность того, что событие наступит для конкретного испытуемого (больной/здоровый, возврат кредита/дефолт и т. д.).

В множественной линейной регрессии предполагается, что зависимая переменная y является линейной функцией независимых переменных x_i , $i = 1, \dots, n$, т. е.:

$$y = a + b_1x_1 + b_2x_2 + \dots + b_nx_n.$$

Однако множественная регрессия просто игнорирует ограничения на диапазон значений для y . Поэтому для решения проблемы задача регрессии может быть сформулирована иначе: вместо предсказания бинарной переменной, мы предсказываем непрерывную переменную P со значениями на отрезке $[0,1]$ при любых значениях независимых переменных. Это достигается применением следующего регрессионного уравнения (логит-преобразование):

$$P = 1/(1 + e^{-y}),$$

где P – вероятность того, что произойдет интересующее событие.

Поскольку логистическое преобразование решает проблему об ограничении на 0-1 границы для первоначальной зависимой переменной (вероятности), то эти преобразованные значения можно использовать в обычном линейном регрессионном уравнении. А именно, если произвести логистическое преобразование обеих частей описанного выше уравнения, мы получим стандартную модель линейной регрессии.

Существует несколько способов нахождения коэффициентов логистической регрессии. На практике часто используют метод максимального правдоподобия. Он применяется в статистике для получения оценок параметров генеральной совокупности по данным выборки. Основу метода составляет функция правдоподобия (likelihood function), выражающая плотность вероятности (вероятность) совместного появления результатов выборки y .

Кроме того известно, что логистическую регрессию можно представить в виде однослойной нейронной сети с сигмоидальной функцией активации, веса которой есть коэффициенты логистической регрессии, а вес поляризации – константа регрессионного уравнения. Как известно, однослойная нейронная сеть может успешно решить лишь задачу линейной сепарации. Поэтому возможности по моделированию нелинейных зависимостей у логистической регрессии отсутствуют. Однако для оценки качества модели логистической регрессии су-

существует эффективный инструмент ROC-анализа, что является несомненным ее преимуществом.

Для расчета коэффициентов логистической регрессии можно применять любые градиентные методы: метод сопряженных градиентов, методы переменной метрики и другие.

ROC-кривая (Receiver Operator Characteristic) – кривая, которая наиболее часто используется для представления результатов бинарной классификации в машинном обучении. Название пришло из систем обработки сигналов. Поскольку классов два, один из них называется классом с положительными исходами, второй – с отрицательными исходами. ROC-кривая показывает зависимость количества верно классифицированных положительных примеров от количества неверно классифицированных отрицательных примеров. В терминологии ROC-анализа первые называются истинно положительным, вторые – ложно отрицательным множеством. При этом предполагается, что у классификатора имеется некоторый параметр, варьируя который, мы будем получать то или иное разбиение на два класса. Этот параметр часто называют порогом, или точкой отсечения (cut-off value). В зависимости от него будут получаться различные величины *ошибок I и II рода*.

В логистической регрессии порог отсечения изменяется от 0 до 1 – это и есть расчетное значение уравнения регрессии. Будем называть его рейтингом.

Для понимания сути ошибок I и II рода рассмотрим четырехпольную таблицу сопряженности (confusion matrix), которая строится на основе результатов классификации моделью и фактической (объективной) принадлежностью примеров к классам. Таблица содержит следующие данные:

- *TP (True Positives)* – верно классифицированные положительные примеры (так называемые истинно положительные случаи);

- *TN (True Negatives)* – верно классифицированные отрицательные примеры (истинно отрицательные случаи);

- *FN (False Negatives)* – положительные примеры, классифицированные как отрицательные (ошибка I рода). Это так называемый ложный пропуск – когда интересующее нас событие ошибочно не обнаруживается (ложно отрицательные примеры);

- *FP (False Positives)* – отрицательные примеры, классифицированные как положительные (ошибка II рода). Это ложное обнаружение, т. к. при отсутствии события ошибочно выносится решение о его присутствии (ложно положительные случаи).

Что является положительным событием, а что – отрицательным, зависит от конкретной задачи.

Вводят два определения: чувствительность и специфичность модели. Ими определяется объективная ценность любого бинарного классификатора.

Чувствительность *Se (Sensitivity)* – это и есть доля истинно положительных случаев:

$$Se = TP / (TP + FN).$$

Специфичность Sp (Specificity) – доля истинно отрицательных случаев, которые были правильно идентифицированы моделью:

$$Sp = TN / (TN + FP).$$

ROC-кривая получается следующим образом:

1. Для каждого значения порога отсечения, которое меняется от 0 до 1 с шагом dx (например, 0.01) рассчитываются значения чувствительности Se и специфичности Sp . В качестве альтернативы порогом может являться каждое последующее значение примера в выборке.

2. Строится график зависимости: по оси Y откладывается чувствительность Se в процентах, по оси X откладывают $(100\% - Sp)$ (сто процентов минус специфичность), или, что тоже самое, FPR – доля ложно положительных случаев. Пример графиков приведен на рис.8.

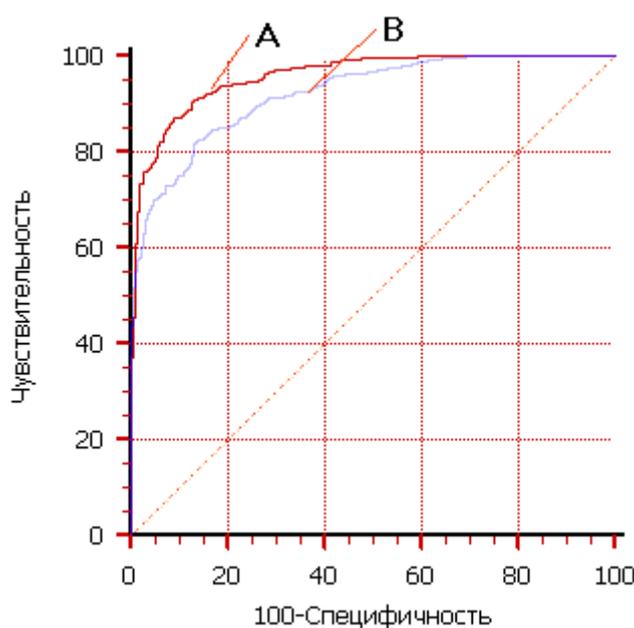


Рис. 8. – Сравнение ROC-кривых

Для идеального классификатора график ROC-кривой проходит через верхний левый угол, где доля истинно положительных случаев составляет 100% или 1.0 (идеальная чувствительность), а доля ложно положительных примеров равна нулю. Поэтому чем ближе кривая к верхнему левому углу, тем выше предсказательная способность модели. Наоборот, чем меньше изгиб кривой и чем ближе она расположена к диагональной прямой, тем менее эффективна модель. Диагональная линия соответствует бесполезному классификатору, т. е. полной неразличимости двух классов.

При визуальной оценке ROC-кривых расположение их относительно друг друга указывает на их сравнительную эффективность. Кривая, расположенная выше и левее, свидетельствует о большей предсказательной способности модели. Так, на рис. 8 две ROC-кривые совмещены на одном графике. Видно, что модель A лучше.

Идеальная модель обладает 100% чувствительностью и специфичностью. Однако на практике добиться этого невозможно, более того, невозможно одновременно повысить и чувствительность, и специфичность модели. Компромисс находится с помощью порога отсечения, так как пороговое значение влияет на соотношение Se и Sp . Можно говорить о задаче нахождения *оптимального порога отсечения* (optimal cut-off value).

Порог отсечения нужен для того, чтобы применять модель на практике: относить новые примеры к одному из двух классов. Для определения оптимального порога нужно задать критерий его определения, так как в разных задачах присутствует своя оптимальная стратегия.

3.3. Алгоритмы кластеризации на службе Data Mining

Кластеризация как объединение в группы схожих объектов является одной из фундаментальных задач в области анализа данных и Data Mining. Список прикладных областей, где она применяется, широк: сегментация изображений, маркетинг, борьба с мошенничеством, прогнозирование, анализ текстов и многие другие. Отсюда многообразие синонимов понятию кластер – класс, таксон, сгущение.

На современном этапе кластеризация часто выступает первым шагом при анализе данных.

Очень часто данные, с которыми сталкивается технология Data Mining, имеют следующие важные особенности:

- высокая размерность (тысячи полей) и большой объем (сотни тысяч и миллионы записей) таблиц баз данных и хранилищ данных (сверхбольшие базы данных);
- наборы данных содержат большое количество *числовых* и *категорийных* атрибутов.

Все атрибуты, или признаки объектов делятся на **числовые** (numerical) и **категорийные** (categorical).

Числовые атрибуты – это такие, которые могут быть упорядочены в пространстве, соответственно категориальные – которые не могут быть упорядочены. Например, атрибут «возраст» – числовой, а «цвет» – категориальный.

Большинство алгоритмов кластеризации предполагают сравнение объектов между собой на основе некоторой *меры близости* (сходства). В качестве меры близости для числовых атрибутов очень часто используется *евклидово расстояние*.

Для категориальных атрибутов распространена мера сходства Чекановского-Серенсена и Жаккара.

Можно классифицировать кластерные алгоритмы на **масштабируемые** и **немасштабируемые**.

Алгоритм называют масштабируемым (scalable), если при неизменной емкости оперативной памяти с увеличением числа записей в базе данных время его работы растет линейно.

По способу разбиения на кластеры алгоритмы бывают двух типов: *иерархические и неиерархические*.

Классические **иерархические** алгоритмы работают только с категориальными атрибутами, когда строится полное дерево вложенных кластеров. Здесь распространены агломеративные методы построения иерархий кластеров – в них производится последовательное объединение исходных объектов и соответствующее уменьшение числа кластеров. Иерархические алгоритмы обеспечивают сравнительно высокое качество кластеризации и не требуют предварительного задания количества кластеров.

Неиерархические алгоритмы основаны на оптимизации некоторой целевой функции, определяющей оптимальное в определенном смысле разбиение множества объектов на кластеры. В этой группе популярны алгоритмы семейства *k*-средних (*k*-means, fuzzy *c*-means, Густафсон-Кесселя), которые в качестве целевой функции используют сумму квадратов взвешенных отклонений координат объектов от центров искомым кластеров.

Одним из эффективных считается алгоритм обработки транзакционных данных CLOPE, который быстрее и проще в программной реализации.

Под термином *транзакция* здесь понимается некоторый произвольный набор объектов, будь это список ключевых слов статьи, товары, купленные в супермаркете, множество симптомов пациента, характерные фрагменты изображения и так далее.

Задача кластеризации транзакционных данных состоит в получении такого разбиения всего множества транзакций, чтобы похожие транзакции оказались в одном кластере, а отличающиеся друг от друга – в разных кластерах.

В основе **алгоритма кластеризации CLOPE** (англ.: Clustering with sLOPE) лежит идея максимизации глобальной функции стоимости, которая повышает близость транзакций в кластерах при помощи увеличения параметра *кластерной гистограммы*.

Пусть имеется база транзакций *D*, состоящая из множества транзакций $\{t_1, t_2, \dots, t_n\}$. Каждая транзакция есть набор объектов $\{i_1, \dots, i_m\}$. Множество кластеров $\{C_1, \dots, C_k\}$ есть разбиение множества $\{t_1, t_2, \dots, t_n\}$, такое, что $C_1 \dots C_k = \{t_1, t_2, \dots, t_n\}$ и $C_i \cap C_j = \emptyset, i, j = 1 \dots k$. Каждый элемент C_i называется *кластером*, n, m, k – количество транзакций, количество объектов в базе транзакций и число кластеров соответственно.

Каждый кластер *C* имеет следующие характеристики:

$D(C)$ – множество уникальных объектов; $Occ(i, C)$ – количество вхождений (частота) объекта *i* в кластер *C*; $W(C) = |D(C)|$ – ширина кластера; $H(C) = S(C)/W(C)$ – высота кластера, а площадь кластера определяется в виде $S(C) = \sum_{i \in D(C)} Occ(i, C) = \sum_{ti \in C} |ti|$.

Гистограммой кластера *C* называется графическое изображение его расчетных характеристик: по оси ОХ откладываются объекты кластера в порядке убывания величины $Occ(i, C)$, а сама величина $Occ(i, C)$ – по оси ОУ (рис. 9). На рис. 9 $S(C)$, равное 8, соответствует площади прямоугольника, ограниченного

осями координат и пунктирной линией. Очевидно, что чем больше значение H , тем более «похожи» две транзакции. Поэтому алгоритм должен выбирать такие разбиения, которые максимизируют H .

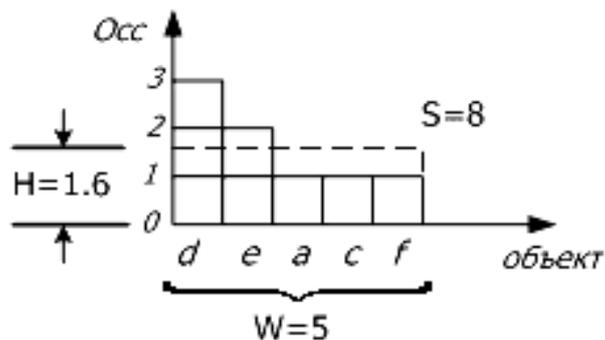


Рис.9. Пример гистограммы кластера

При совпадении значений высот применяют другие более сложные критерии: значение градиента, либо функцию стоимости.

Кластеризация транзакционных данных имеет много общего с анализом ассоциаций. Обе эти технологии Data Mining выявляют скрытые зависимости в наборах данных. Но есть и отличия.

С одной стороны, кластеризация дает общий взгляд на совокупность данных, тогда как ассоциативный анализ находит конкретные зависимости между атрибутами.

С другой стороны, ассоциативные правила сразу пригодны для использования, тогда как кластеризация чаще всего используется как первая стадия анализа.

Преимущества алгоритма CLOPE:

1. Высокие масштабируемость и скорость работы, а также качество кластеризации, что достигается использованием глобального критерия оптимизации на основе максимизации градиента высоты гистограммы кластера. Он легко рассчитывается и интерпретируется. Во время работы алгоритм хранит в RAM небольшое количество информации по каждому кластеру и требует минимальное число сканирований набора данных. Это позволяет применять его для кластеризации огромных объемов категориальных данных.

2. CLOPE автоматически подбирает количество кластеров, причем это регулируется одним единственным параметром – коэффициентом отталкивания в функции стоимости.

3.4. Деревья решений

Деревья решения являются одним из наиболее популярных подходов к решению задач Data Mining. Они создают иерархическую структуру классифицирующих правил типа «ЕСЛИ ..., ТО...», имеющую вид дерева.

Для того чтобы решить, к какому классу отнести некоторый объект или ситуацию, требуется ответить на вопросы, стоящие в узлах этого дерева, начиная с его корня, как показано на рис.10.

Вопросы имеют вид «значение параметра A больше x ». Если ответ положительный, осуществляется переход к правому узлу следующего уровня, если отрицательный – то к левому узлу; затем снова следует вопрос, связанный с соответствующим узлом.

Введем основные понятия из теории деревьев решений, которые будут употребляться далее:

- объект – пример, шаблон, наблюдение;
- атрибут – признак, независимая переменная, свойство;
- метка класса – зависимая переменная, целевая переменная, признак определяющий класс объекта;
- узел – внутренний узел дерева, узел проверки;
- лист – конечный узел дерева, узел решения;
- проверка (test) – условие в узле.

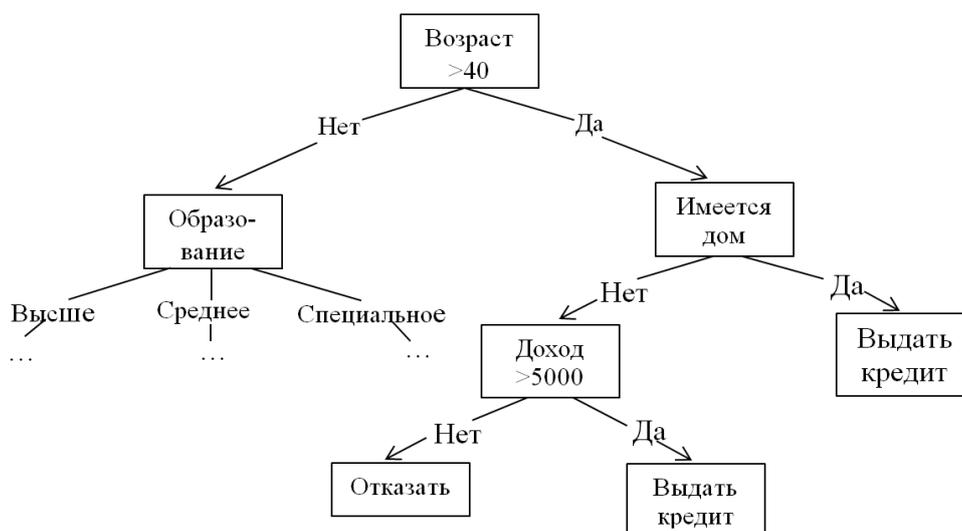


Рис.10. Пример дерева решений

Область применения дерева решений в настоящее время широка, но все задачи, решаемые этим аппаратом могут быть объединены в следующие три класса:

- **Описание данных:** Деревья решений позволяют хранить информацию о данных в компактной форме, вместо них мы можем хранить дерево решений, которое содержит точное описание объектов.
- **Классификация:** Деревья решений отлично справляются с задачами классификации, т. е. отнесения объектов к одному из заранее известных классов. Целевая переменная должна иметь дискретные значения.
- **Регрессия:** Если целевая переменная имеет непрерывные значения, деревья решений позволяют установить зависимость целевой переменной от независимых (входных) переменных. Например, к этому классу относятся задачи численного прогнозирования (предсказания значений целевой переменной).

Пусть нам задано некоторое обучающее множество T , содержащее объекты (примеры), каждый из которых характеризуется m атрибутами (атрибутами), причем один из них указывает на принадлежность объекта к определенному классу.

Пусть через $\{C_1, C_2, \dots, C_k\}$ обозначены классы (значения метки класса), тогда существуют 3 ситуации:

1. Множество T содержит один или более примеров, относящихся к одному классу C_k . Тогда дерево решений для T – это лист, определяющий класс C_k .

2. Множество T не содержит ни одного примера, т. е. пустое множество. Тогда это снова лист, и класс, ассоциированный с листом, выбирается из другого множества отличного от T , скажем, из множества, ассоциированного с родителем.

3. Множество T содержит примеры, относящиеся к разным классам. В этом случае следует разбить множество T на некоторые подмножества. Для этого выбирается один из признаков, имеющий два и более отличных друг от друга значений O_1, O_2, \dots, O_n . Множество T разбивается на подмножества T_1, T_2, \dots, T_n , где каждое подмножество T_i содержит все примеры, имеющие значение O_i для выбранного признака. Это процедура будет рекурсивно продолжаться до тех пор, пока конечное множество не будет состоять из примеров, относящихся к одному и тому же классу.

Вышеописанная процедура лежит в основе многих современных алгоритмов построения деревьев решений, этот метод известен еще под названием разделения и захвата (divide and conquer). Очевидно, что при использовании данной методики, построение дерева решений будет происходить сверху вниз.

Поскольку все объекты были заранее отнесены к известным нам классам, такой процесс построения дерева решений называется обучением с учителем (supervised learning). Процесс обучения также называют индуктивным обучением или индукцией деревьев (tree induction).

На сегодняшний день существует значительное число алгоритмов, реализующих деревья решений CART, C4.5, NewId, ITrule, CHAID, CN2 и т. д. Но наибольшее распространение и популярность получили следующие два:

– **CART (Classification and Regression Tree)** – это алгоритм построения бинарного дерева решений – дихотомической классификационной модели. Каждый узел дерева при разбиении имеет только двух потомков. Как видно из названия алгоритма, решает задачи классификации и регрессии.

– **C4.5** – алгоритм построения дерева решений, количество потомков у узла не ограничено. Не умеет работать с непрерывным целевым полем, поэтому решает только задачи классификации.

Большинство из известных алгоритмов являются жадными алгоритмами. Если один раз был выбран атрибут, и по нему было произведено разбиение на подмножества, то алгоритм не может вернуться назад и выбрать другой атрибут, который дал бы лучшее разбиение. И поэтому на этапе построения нельзя сказать даст ли выбранный атрибут, в конечном итоге, оптимальное разбиение.

При построении деревьев решений особое внимание уделяется следующим вопросам: выбору критерия атрибута, по которому пойдет разбиение, остановки обучения и отсечения ветвей. Рассмотрим все эти вопросы по порядку.

Правило разбиения. Для построения дерева на каждом внутреннем узле необходимо найти такое условие (проверку), которое бы разбивало множество, ассоциированное с этим узлом на подмножества. В качестве такой проверки должен быть выбран один из атрибутов.

Общее правило для выбора атрибута можно сформулировать следующим образом: выбранный атрибут должен разбить множество так, чтобы получаемые в итоге подмножества состояли из объектов, принадлежащих к одному классу, или были максимально приближены к этому, т. е. количество объектов из других классов (примесей) в каждом из этих множеств было как можно меньше.

Алгоритм C4.5, усовершенствованная версия алгоритма ID3 (Iterative Dichotomizer), использует теоретико-информационный подход.

Алгоритм CART использует так называемый индекс Gini (в честь итальянского экономиста Corrado Gini), который оценивает «расстояние» между распределениями классов.

Правило остановки. В дополнение к основному методу построения деревьев решений были предложены следующие правила:

- Использование статистических методов для оценки целесообразности дальнейшего разбиения, так называемая ранняя остановка (prepruning). В конечном счете ранняя остановка процесса построения привлекательна в плане экономии времени обучения.

- Ограничить глубину дерева. Остановить дальнейшее построение, если разбиение ведет к дереву с глубиной превышающей заданное значение.

- Разбиение должно быть нетривиальным, т. е. получившиеся в результате узлы должны содержать не менее заданного количества примеров.

Правило отсечения. Очень часто алгоритмы построения деревьев решений дают сложные деревья, которые переполнены данными, имеют много узлов и ветвей. Такие ветвистые деревья очень трудно понять. К тому же ветвистое дерево, имеющее много узлов, разбивает обучающее множество на все большее количество подмножеств, состоящих из все меньшего количества объектов. Ценность правила, справедливого скажем для 2-3 объектов, крайне низка, и в целях анализа данных такое правило практически непригодно. Гораздо предпочтительнее иметь дерево, состоящее из малого количества узлов, которым бы соответствовало большое количество объектов из обучающей выборки.

Для решения вышеописанной проблемы часто применяется так называемое отсечение ветвей (prepruning).

Пусть под точностью (распознавания) дерева решений понимается отношение правильно классифицированных объектов при обучении к общему количеству объектов из обучающего множества, а под ошибкой – количество неправильно классифицированных. Предположим, что нам известен способ оценки

ошибки дерева, ветвей и листьев. Тогда, возможно использовать следующее простое правило:

- построить дерево;
- отсечь или заменить поддеревом те ветви, которые не приведут к возрастанию ошибки. Отсечение ветвей происходит снизу вверх, двигаясь с листьев дерева, отмечая узлы как листья, либо заменяя их поддеревом.

Преимущества использования деревьев решений:

- быстрый процесс обучения;
- извлечение правил на естественном языке;
- генерация правил в областях, где эксперту трудно формализовать свои знания;
- интуитивно понятная классификационная модель;
- высокая точность прогноза, сопоставимая с другими методами (статистика, нейронные сети);
- построение непараметрических моделей.

В силу этих и многих других причин, методология деревьев решений является важным инструментом в работе каждого специалиста, занимающегося анализом данных, вне зависимости от того практик он или теоретик.

Деревья решений являются прекрасным инструментом в системах поддержки принятия решений, интеллектуального анализа данных. В состав многих пакетов, предназначенных для интеллектуального анализа данных, уже включены методы построения деревьев решений. В областях, где высока цена ошибки, они послужат отличным подспорьем аналитика или руководителя

Деревья решений успешно применяются для решения практических задач в следующих областях:

- Банковское дело. Оценка кредитоспособности клиентов банка при выдаче кредитов.
- Промышленность. Контроль за качеством продукции (выявление дефектов), испытания без разрушений (например, проверка качества сварки) и т.д.
- Медицина. Диагностика различных заболеваний.
- Молекулярная биология. Анализ строения аминокислот.

Это далеко не полный список областей, где можно использовать деревья решений.

3.5. Классификация программных реализаций систем Data Mining

1. Предметно-ориентированные аналитические пакеты (например, в финансовой области предназначены для предсказания курса валют). Часто основой для таких технологий является несложный статистический аппарат (аппарат прикладной статистики), в наибольшей мере учитывающий специфику рассматриваемой области. Цена таких продуктов меньше \$1000, т. е. они недорогие и их много.

2. Статистические пакеты, включающие наряду с традиционными методами математической статистики также элементы Data Mining. Круг задач, ре-

шаемых с помощью статистических пакетов: создание корреляционных моделей; факторный анализ, регрессионный анализ и др.

Достоинства данных методов состоит в том, что они основываются на строгом математическом аппарате.

Недостатки: для их использования требуется специальная математическая подготовка пользователя, а также, принципиальный недостаток пакетов состоит в том, что они опираются на статистическую парадигму и поэтому дают математически усредненный вывод.

Наиболее распространены такие мощные статистические пакеты, как SAS (компания SAS Institute), SPSS (SPSS), Statistica и др. Эти системы достаточно дороги – от \$1000 до \$15000.

3. Нейросетевые системы. Принцип работы нейронных сетей заключается в следующем: имитируется работа нейронов в составе иерархической сети. При этом сигналы передаются от нижних слоев к верхним, а сила сигнала зависит от сложности связи.

Недостатки:

- необходимо иметь большой объем обучающей выборки;
- результаты работы такого пакета трудно объяснить.

Нейронные сети могут быть реализованы программным или аппаратным способом.

Вариантами аппаратной реализации являются нейрокомпьютеры, нейроплаты и нейроБИС (большие интегральные схемы). Одна из самых простых и дешёвых нейроБИС – модель MD 1220 фирмы Micro Devices, которая реализует сеть с 8 нейронами и 120 синапсами.

Большинство современных нейрокомпьютеров представляют собой персональный компьютер или рабочую станцию, в состав которых входит дополнительная нейроплата. К их числу относятся, например, компьютеры серии FMR фирмы Fujitsu.

К программам, реализующим технологии нейронных сетей относятся: пакет Brain Maker (CSS), NeuroShell (Ward Systems Group) и др. Стоимость таких систем очень высока (более \$1000). Пакет Brain Maker используется несколькими тысячами финансовых и промышленных компаний, а также оборонными ведомствами США для решения задач прогнозирования, оптимизации и моделирования ситуаций. К таким задачам относятся прогнозирование курсов валют и акций на биржах, моделирование кризисных ситуаций, распознавание образов и многие другие на основе использования сети Хопфилда с обучением по методу обратного распространения ошибки.

4. Системы рассуждений на основе аналогичных случаев (Case Based Reasoning – CBR) основаны на поиске аналога наличной ситуации. Назначение таких систем: среди БД множества случаев найти тот, который наиболее близок к рассматриваемому.

Недостатки:

- не создается никакой модели (ищем аналогию, но не ищем модель, правило);

– результат зависит от меры близости, которую можно выбрать и достаточно неправильной. Для эффективного решения задач классификации или прогноза необходимо, чтобы был накоплен большой объем данных.

Пример системы, использующей CBR, – Pattern Recognition Workbench (Unisca, США).

5. Деревья решений (Decision Tree). Указанная технология используется в том случае, если применимо правило типа «If ...,Then ...» и она представляет собой процесс мышления, при котором идет логический вывод от корня к ветвям и листьям. Такие переходы понятны и видны графически, т. е. пользователь получает модель, по которой он может сделать выводы о результатах.

Недостаток технологии деревьев решений заключается в том, что трудно найти оптимальное решение, такая система не дает ответа, какое решение следует считать оптимальным.

На использовании технологии деревьев решений работают продукты See5 / C5.0 (компания RuleQuest), KnowledgeSeeker (ANGOSS) и др. Стоимость таких пакетов от \$1000.

6. Пакеты на основе алгоритмов ограниченного перебора. Суть работы таких технологий заключается в следующем: алгоритм вычисляет частоты комбинаций простых логических событий в подгруппах данных и на основании вычисленных частот делается вывод о полезности той или иной комбинации. Они определяют логические «If ...,Then ...» правила и выдают результат. Технология ограниченного перебора используется там, где трудно найти функциональную связь.

Известным представителем этого подхода является продукт WizWhy (фирма WizSoft). Стоимость таких пакетов – около \$4000.

7. Генетические алгоритмы. Данная технология представляет собой попытку найти решение путем обращения к генетике. Генетический алгоритм (ГА) – это поисковый алгоритм, основанный на природных механизмах селекции и генетики. Эти алгоритмы обеспечивают выживание сильнейших решений из множества сгенерированных, формируя и изменяя процесс поиска на основе моделирования эволюции исходной популяции решений.

Коммерческое программное обеспечение, реализующее ГА, можно разделить на программные средства общего назначения, прикладные и алгоритмические программные продукты.

Программное обеспечение общего назначения включает разнообразные наборы инструментальных средств для построения конкретных программ, которые содержат библиотеки алгоритмов, программы моделирования, средства визуализации и другие инструменты. Пакеты подобного типа рассчитаны на опытных программистов, требуют знания основ теории эволюционных вычислений и характеризуются высокой трудоёмкостью освоения, которая в значительной мере зависит от квалификации пользователя.

Прикладные программные продукты ориентированы на решение проблем определённого класса в конкретных предметных областях (реинжиниринг, маркетинг, стратегическое планирование и др.). Такие средства не требуют от

пользователя теоретических знаний в области методологии создания интеллектуальных систем. Достаточно, чтобы он был специалистом в своей предметной области.

Алгоритмическое программное обеспечение поддерживает один (или несколько) генетический алгоритм. Преимущества таких программных продуктов – их гибкость и простота использования. При этом пользователям необходимо иметь представление об основах теории ГА.

Система PC/Beagle представляет собой программу поиска решающих правил, классифицирующих примеры из базы данных. Она превращает данные в знания за счёт использования машинного обучения. Один из модулей системы путём репродукции и селекции порождает правила, представленные в виде логических выражений.

Система Evolver реализует шесть методов генетической оптимизации и выполнена в виде расширения MS Excel. Основные области применения пакета – оптимизация доходности с учётом уровня риска и максимизация прибыли с учётом возможных издержек.

Genesis – известный алгоритмический программный продукт, который используется в качестве инструмента тестирования генетических алгоритмов. Он позволяет создать модифицированную программную среду и обеспечивает пользователя статистической информацией на выходе.

Программный продукт общего назначения EnGENEer помогает адаптировать генетические алгоритмы к новым проблемным областям.

Известен пакет GeneHunter фирмы Ward Systems Group, который может использоваться как приложение MS Excel и допускает составление собственных программ на языках C и Visual Basic. Его стоимость – около \$1000.

8. Эволюционное программирование. Процесс построения программ строится как эволюции в мире программ. Когда система находит программу, более или менее выражающую искомую зависимость, она начинает вносить в нее небольшие модификации и отбирает среди построенных дочерних программ те, которые повышают точность. Так работает отечественная программная система PolyAnalyst.

Другое направление эволюционного программирования связано с поиском зависимости целевых переменных от остальных в форме функций какого-то определенного вида, например, в форме полиномов. Указанное направление реализовано в системе NeuroShell компании Ward System Group. Стоимость систем до \$4000.

9. Аналитические платформы. Аналитические программные комплексы имеют тенденцию совершенствоваться в направлении увеличения количества параметров многомерного анализа и уровня адекватности математического аппарата реальным, многосторонним бизнес-процессам для повышения точности и долгосрочности прогнозирования развития процессов и ситуаций, и их оптимизации в интересах предприятий и организаций. Аналитические программные комплексы должны создаваться с расчетом на слияние с другими интеллектуальными средствами, имитационными математическими моделями, многокри-

териальными системами поддержки принятия решений, системами искусственного интеллекта и др. Только в этом случае возможно образование интегрированных комплексов поддержки принятия оптимальных решений, причем как в интересах достижения стратегических целей, так и в интересах своевременного, достаточно быстрого и адекватного реагирования на изменения внешних условий в процессе управления деятельностью предприятий и организаций.

Разработанный в России компанией BaseGroup Labs программный продукт Deductor является аналитической платформой, т. е. основой для создания законченных прикладных решений на основе решения задач анализа данных. Реализованные в Deductor технологии предоставляет полный набор инструментов и позволяют на базе единой архитектуры пройти все этапы построения аналитической системы: от создания хранилища данных до автоматического подбора моделей и визуализации полученных результатов [21, 27].

Deductor предоставляет аналитикам инструментальные средства, необходимые для решения самых разнообразных аналитических задач: корпоративная отчетность, прогнозирование, сегментация, поиск закономерностей – эти и другие задачи, где применяются такие методики анализа, как OLAP, Knowledge Discovery in Databases и Data Mining. Deductor является идеальной платформой для создания систем поддержки принятия решений.

3.6. Краткое описание применения аналитической платформы Deductor для решения задач интеллектуального анализа данных

Состав платформы Deductor. Система состоит из пяти частей:

– **Studio** – программа, реализующая функции импорта, обработки, визуализации и экспорта данных. Deductor Studio может функционировать и без хранилища данных, получая информацию из любых других источников, но наиболее оптимальным является их совместное использование. В Deductor Studio включен полный набор механизмов, позволяющий получить информацию из произвольного источника данных, провести весь цикл обработки (очистку, трансформацию данных, построение моделей), отобразить полученные результаты наиболее удобным образом (OLAP, диаграммы, деревья и др.) и экспортировать результаты на сторону.

– **Viewer** – рабочее место конечного пользователя. Позволяет отделить процесс построения сценариев от использования уже готовых моделей. Все сложные операции по подготовке сценариев обработки выполняются аналитиками-экспертами при помощи Deductor Studio, а Deductor Viewer обеспечивает пользователям простой способ работы с готовыми результатами, скрывает от них все сложности построения моделей и не предъявляет высоких требований к квалификации сотрудников.

– **Warehouse** – многомерное хранилище данных, аккумулирующее всю необходимую для анализа предметной области информацию. Использование единого хранилища позволяет обеспечить непротиворечивость данных, их централизованное хранение и автоматически обеспечивает всю необходимую поддержку процесса анализа данных.

– **Server** – служба, обеспечивающая удаленную аналитическую обработку данных. Позволяет автоматически обрабатывать данные и переобучать модели на сервере, оптимизирует выполнение сценариев за счет кэширования проектов и использования многопоточной обработки.

– **Client** – клиент доступа к Deductor Server. Обеспечивает доступ к серверу из сторонних приложений и управление его работой.

Реализованная в Deductor архитектура позволяет добиться максимальной гибкости при создании законченного решения. Благодаря данной архитектуре можно собрать в одном аналитическом приложении все необходимые инструменты анализа и реализовать автоматическое выполнение подготовленного сценария. Создание законченного решения занимает очень мало времени. Достаточно получить данные, определить сценарий обработки и задать место для экспорта полученных результатов. Наличие мощного набора механизмов обработки и визуализации позволяет двигаться по шагам, от наиболее простых способов анализа к более мощным. Таким образом, первые результаты пользователь получает практически сразу, но при этом можно легко наращивать мощность решения.

Хранилище данных. Deductor включает в себя кросс-платформенное хранилище Deductor Warehouse – специализированную базу, в которую загружается информация из существующих учетных систем. Оно спроектировано специально для обработки аналитических запросов и включает удобный семантический слой, благодаря которому пользователи в состоянии извлечь любые интересующие их сведения без написания сложных запросов, только оперируя понятными бизнес-терминами.

Deductor поддерживает работу практически с любыми источниками данных: офисные приложения, 1С:Предприятие, популярные СУБД, ERP-, CRM-, BI-системы, текстовые файлы, XML-источники и десятки других. Где бы ни хранилась информация, ее можно будет извлечь, трансформировать к нужному виду и загрузить в хранилище данных.

Интеграция. Для получения аналитической отчетности при помощи Deductor может использоваться информация из десятков источников: хранилища данных, учетные системы, СУБД, файлы и многое другое. Полученные результаты можно просмотреть на экране, передать в офисные приложения (MS Excel, Word, Access), разместить на веб-сайте, загрузить в базу данных.

Простота применения. Для построения аналитического решения на базе платформы Deductor не требуется написания сложного кода. Практически все операции производятся в режиме визуального проектирования, при помощи специальных мастеров, облегчающих работу аналитика, которая отделена от работы конечного пользователя. Аналитик строит при помощи мастеров сценарии, в которых реализована произвольная логика обработки, а конечный пользователь просто выбирает нужный отчет и автоматически получает интересующие данные.

Прогнозирование – одна из самых востребованных, но при этом и самых сложных задач анализа. Качественный прогноз является ключом к решению та-

ких актуальных бизнес-задач, как оптимизация складских запасов и финансовых потоков, бюджетирование, оценка инвестиционной привлекательности и многие другие. Обработчики в Deductor обеспечивают возможность построения прогностических моделей с использованием как простых моделей (по среднему, на основе предыдущих периодов, по жестким правилам), так и мощных самообучающихся алгоритмов (регрессионные модели, нейронные сети, анализ временных рядов).

OLAP-визуализатор. Результаты планирования, моделирования, различные варианты сценарных прогнозов можно просмотреть при помощи множества удобных визуализаторов, в частности с использованием встроенного OLAP-модуля. Он поддерживает весь необходимый для бюджетирования функционал: просмотр в любых срезах, детализация (drill down), сортировки, группировки, множество способов фильтрации.

Анализ отклонений. Одним из важнейших этапов работы системы бюджетирования является выявление отклонений и анализ причин их возникновения. Deductor включает мощные Data Mining алгоритмы, позволяющие не только найти аномалии, отклонения, противоречия, но и проанализировать что привело к такому результату, выявить влияние на аномалии множества факторов, найти причинно-следственные связи.

Версии платформы. Существует три версии этой платформы. Версия *Enterprise* предназначена для корпоративного использования. В ней присутствуют:

- серверные компоненты Deductor Server и Deductor Client;
- интерфейс доступа к Deductor через механизм OLE Automation;
- традиционное хранилище данных Deductor Warehouse на трех СУБД: Firebird, MS SQL, Oracle;
- виртуальное хранилище данных Deductor Virtual Warehouse.

Версия *Professional* предназначена для небольших компаний и однопользовательской работы. В ней отсутствуют серверные компоненты, поддержка OLE, виртуальное хранилище, а традиционное хранилище данных можно создавать только на СУБД Firebird.

Версия *Academic* предназначена для образовательных и обучающих целей. Ее функционал аналогичен версии Professional за исключением того, что отсутствуют пакетный запуск сценариев, т. е. работа в программе может вестись только в интерактивном режиме, а также нет импорта из промышленных источников данных: 1С, СУБД, файлы MS Excel, Deductor Data File.

Реализованные технологии Data Mining:

- задача ассоциации на основе алгоритма Apriori;
- задача кластеризации на основе сетей и карт Кохонена, а также алгоритмов k-means и G-means;
- задача классификации и регрессии на основе линейной и логистической регрессии, деревьев решений (алгоритм C 4.5), многослойного персептрона (алгоритмы BProp, RProp);

- анализ и прогнозирование временных рядов на основе регрессионных и нейросетевых моделей;
- сравнение моделей на основе ROC-анализа.

В Deductor Studio вся работа ведется с использованием пяти мастеров.

Для создания сценариев обработки данных используются *мастера импорта, обработки и экспорта*. Для настройки подключений к источникам данных используется *мастер подключений*. *Мастер визуализации* настраивает визуализаторы для конкретного узла.

Подробное изложение системы Deductor изложено в работах Н.Б. Паклина и других разработчиков и исследователей в [21, 27]. Учебные примеры применения платформы содержатся также в пособиях [22, 23].

Сопоставление Deductor со известными специализированными продуктами других производителей. По производительности работа Warehouse на Oracle, SQL и Firebird при более-менее активном лазании в Хранилище (закачка транзакций и какой-то дополнительной информации, а также постоянное ее использование для прогнозирования порядка 30000-40000 временных рядов в месяц и сохранение прогнозов) отличается существенно, при больших объемах раз в 10-20. При грамотной оптимизации можно добиться еще большей разницы в скорости. Это связано с тем, что тяжелые базы сами по себе работают быстрее (точнее могут больше выжать из оборудования), но не только. Дело в том, что у Oracle и MS SQL есть нестандартные опции, позволяющие загружать данные пачками, извлекать большими кусками и прочее. Кроме того, поддерживается размещение в различные табличные пространства и прочее. При небольших объемах (база до гигабайта) разницы в производительности у указанных баз данных и Deductor 5 почти нет [27]. В Deductor 5 есть алгоритмы для построения прогнозных моделей. Так что теоретических проблем нет, а вот на счет качества – это уже вопрос обучения, данных и прочее. Для работы нужен Deductor Studio. Даже бесплатная версия Deductor Academic может обрабатывать выборки объемом в несколько миллионов записей без особых проблем.

Выводы

Технологии извлечения знаний из хранилищ данных основаны на методах статистического анализа и моделирования, ориентированных на поиск моделей и отношений, скрытых в совокупности данных. Эти модели могут в дальнейшем использоваться для оптимизации деятельности предприятия или фирмы.

Для извлечения значимой информации из хранилищ данных имеются специальные методы (OLAP-анализа, Data Mining или Knowledge Discovery), основанные на применении методов математической статистики, нейронных сетей, индуктивных методов построения деревьев решений и др.

Контрольные вопросы

1. Каковы основные шаги процедур Knowledge Discovery in Databases при работе с данными в процессе анализа данных?
2. Перечислите основные методы из арсенала математической статистики, применяемые при анализе данных.

3. Перечислите и кратко охарактеризуйте основные методы из арсенала эволюционного моделирования, применяемые для интеллектуального анализе данных.

4. Перечислите и кратко охарактеризуйте основные методы из арсенала машинного обучения, применяемые для интеллектуального анализе данных.

5. Дайте определение бинарной логистической регрессии, логит-преобразования, определение ROC-кривой для представления результатов бинарной классификации в машинном обучении.

6. Какова процедура построения и визуальной оценки ROC-кривых для представления результатов бинарной классификации и прогноза?

7. Каковы особенности алгоритмов кластеризации наборов данных, содержащих большое количество числовых и категориальных атрибутов?

8. В чем смысл задачи кластеризации транзакционных данных?

9. Какие процедуры содержит алгоритм кластеризации транзакционных данных CLOPE?

10. Каковы преимущества алгоритма кластеризации транзакционных данных CLOPE?

11. Каковы основные понятия из теории деревьев решений используются при решении задач Data Mining?

12. Каковы области применения дерева решений при решении задач Data Mining?

13. Какие процедуры лежат в основе многих современных алгоритмов построения деревьев решений?

14. Каковы особенности алгоритмов CART и C4.5, реализующих деревья решений?

15. Выбор критерия атрибута, по которому пойдет разбиение, остановка обучения и отсечение ветвей деревьев решений.

16. Перечислите и кратко охарактеризуйте виды программных реализаций систем Data Mining.

17. Каковы параметры алгоритма конструирования классификатора в программе See5?

18. Как преобразовать полученное дерево решений в набор правил If...Then?

19. Как можно уменьшить ошибки классификации в программе See5?

20. Какой алгоритм положен в основу работы программы WizWhy для поиска логических правил в данных?

21. Какие параметры следует задать для работы процедуры поиска правил и какие отчеты готовит система WizWhy?

22. Каков перечень решаемых задач и состав аналитической платформы Deductor 5?

23. В чем заключена новизна взгляда на данные при применении аналитической платформы Deductor?

24. Какой объем выборки данных может обрабатывать и какие задачи может решать демоверсия Deductor 5?

ЗАКЛЮЧЕНИЕ

В сферу приложений искусственного интеллекта в настоящее время вошли практически все направления современной информатики. Многие из этих направлений, таких как вопросы создания экспертных систем, искусственных нейросетей и др., в достаточной мере освещены в учебной и методической литературе. Поэтому я не ставил перед собой цель «объять необъятное», а включил в текст лекций как разделы, содержащие описание традиционных моделей знаний, понятий, определений и типов интеллектуальных систем, так и новый перспективный подход к решению проблем интеллектуальной обработки накопленных массивов данных.

При написании пособия автор видел свою цель в том, чтобы познакомить студентов с принципами создания и функционирования интеллектуальных информационных систем. Практический опыт показывает, что люди, не знакомые с этими принципами, испытывают большие трудности, выступая в роли пользователей интеллектуального программного обеспечения.

С учетом динамичного развития современной области ИИ текст лекций является лишь введением в огромную и интересную область знаний. Слушатели, заинтересовавшиеся работами в этом перспективном научном направлении и вопросами практического применения методов ИИ в решении сложных задач управления, имеют прекрасную возможность самостоятельно продолжить изучение этой тематики. Огромный мир Интернета позволяет получить быстрый доступ к самой различной информации по тематике создания и применения интеллектуальных систем и технологий, к имеющейся обширной библиографии, углубленным теоретическим и практическим курсам по систематическому освещению многих вопросов, относящихся к области ИИ и ИС. Многие перспективные направления ИИ, ИС в работе лишь упомянуты, или приведены в качестве примеров развития возможных теоретических направлений и практических применений.

Автор надеется, что знания, полученные при изучении данной книги, помогут читателю решать практические примеры при самостоятельном освоении технологии и продуктов Data Mining, а также позволят расширить кругозор в области интеллектуальных информационных систем и технологий.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Искусственный интеллект: справочник. В 3 кн. Кн. 1: Системы общения и экспертные системы / под ред. Э.В. Попова. – М.: Радио и связь, 1990. – 461 с.
2. Искусственный интеллект: справочник. В 3 кн. Кн. 2: Модели и методы / под ред. Д.А. Поспелова. – М.: Радио и связь, 1990. – 304 с.
3. Искусственный интеллект: справочник. В 3 кн. Кн. 3: Программные и аппаратные средства / под ред. В.Н. Захарова и В.Ф. Хорошевского. – М.: Радио и связь, 1990. – 320 с.
4. Коршунов, Ю.М. Математические основы кибернетики: учебное пособие для вузов / Ю.М. Коршунов. – М.: Энергоатомиздат, 1987. – 496 с.
5. Острейковский, В.А. Информатика: учебник для вузов / В.А. Острейковский. – М.: Высшая школа, 2009. – 510 с.
6. Тельнов, Ю.Ф. Интеллектуальные информационные системы: учебное пособие / Ю.Ф. Тельнов. – М.: Московский международный институт экономики, информатики, финансов и права, 2002. – 118 с.
7. Интеллектуальные информационные системы и технологии: учебное пособие / Ю.Ю. Громов, О.Г. Иванова, В.В. Алексеев и др. – Тамбов: Изд-во ТГТУ, 2013. – 244 с.
8. Дюк, В. Data Mining: учебный курс / В. Дюк, А. Самойленко. – СПб.: Питер, 2001. – 366 с.
9. Попов, Э.В. Статические и динамические экспертные системы / Э.В. Попов, И.Б. Фоминых, Е.Б. Кисель и др. – М.: Финансы и статистика, 1997. – 310 с.
10. Логиновский, О.В. Управление и стратегии: учебное пособие / О.В. Логиновский. – Оренбург: Изд-во ОГУ; Челябинск: Изд-во ЮУрГУ, 2001. – 704 с.
11. Луценко, Е.В. Интеллектуальные информационные системы: учебное пособие для студентов специальности 230400 «Информационные системы и технологии» / Е.В. Луценко. – Краснодар: КубГАУ, 2013. – 645 с.
12. Гаврилова, Т.А. Базы знаний интеллектуальных систем: учебное пособие для вузов / Т.А. Гаврилова, В.Ф. Хорошевский. – СПб.: Питер, 2000. – 382 с.
13. Романов, В.П. Интеллектуальные информационные системы в экономике: учебное пособие для вузов по специальности «Прикладная информатика» и другим междисциплинарным специальностям / под общ. ред. Н.П. Тихомирова. – М.: Экзамен, 2003. – 494 с.
14. Макаренко, С.И. Интеллектуальные информационные системы: учебное пособие / С.И. Макаренко. – Ставрополь: СФ МГГУ, 2009. – 206 с.
15. Таунсенд, К. Проектирование и программная реализация экспертных систем на персональных ЭВМ / К. Таунсенд, Д. Фохт; пер. с англ. – М.: Финансы и статистика, 1990. – 356 с.
16. Программные средства интеллектуальных систем / А.Е. Городецкий. – СПб.: Изд. СПбГТУ, 2000. – 316 с.

17. Бессмертный, И.А. Искусственный интеллект: учебное пособие / И.А. Бессмертный. – СПб: СПбГУ ИТМО, 2010. – 132 с.
18. Барыкин, С.Г. Системы искусственного интеллекта: учебное пособие / С.Г. Барыкин, Н.В. Плотникова. – Челябинск: Изд-во ЮУрГУ, 2004 – 85 с.
19. Барсегян, А.А. Технологии анализа данных: Data Mining, Visual Mining, Text Mining, OLAP: учебное пособие для специальности «Информационные системы» / А.А. Барсегян. – СПб.: БХВ Петербург, 2007. – 376 с.
20. Кацко, И.А. Практикум по анализу данных на компьютере: учебное пособие / И.А. Кацко, Н.Б. Паклин. – М.: КолосС, 2009.– 278 с.
21. Паклин, Н.Б. Бизнес-аналитика: от данных к знаниям: учебное пособие / Н.Б. Паклин, В.И. Орешков. – СПб.: Питер, 2013. – 704 с.
22. Поллак, Г.А. Современные технологии анализа информации: учебное пособие / Г.А. Поллак. – Челябинск: Издательский центр ЮУрГУ, 2013 – 115 с.
23. Поллак, Г.А. Современные технологии анализа информации: учебное пособие к практическим работам / Г.А. Поллак. – Челябинск: Издательский центр ЮУрГУ, 2013 – 99 с.
24. Чинакал, В.О. Интеллектуальные системы и технологии: учебное пособие / В.О. Чинакал. – М.: РУДН, 2008. – 303 с.
25. Коровин, А.М. Управление знаниями на основе ИТ-технологий: текст лекций / А.М. Коровин. – Челябинск: Издательский центр ЮУрГУ, 2013. – 48 с.
26. <http://www.ipu.ru/labs/lab51/projects.html>.
27. <http://www.basegroup.ru/deductor/>
28. <http://www.rulequest.com/>
29. <http://www.interface.ru/sysmod/>
30. <http://www.bipartner.ru/services/dm.html>.

ОГЛАВЛЕНИЕ

ВВЕДЕНИЕ.....	3
Глава 1. ПОНЯТИЯ И ТЕРМИНОЛОГИЯ ИНТЕЛЛЕКТУАЛЬНЫХ СИСТЕМ	
1.1. История исследований и основные понятия в области искусственного интеллекта.....	5
1.2. Основные направления исследований в области интеллектуальных систем	8
1.3. Основные признаки и отличия интеллектуальных систем.....	10
1.4. Основные типы интеллектуальных систем.....	13
Глава 2. МОДЕЛИ ПРЕДСТАВЛЕНИЯ ЗНАНИЙ В ИНТЕЛЛЕКТУАЛЬНЫХ СИСТЕМАХ	
2.1. Представление знаний, рассуждений и задач.....	28
2.2. Модели представления знаний.....	30
Глава 3. ИЗВЛЕЧЕНИЕ ЗНАНИЙ ИЗ ДАННЫХ МЕТОДАМИ ИНТЕЛЛЕКТУАЛЬНОГО АНАЛИЗА ДАННЫХ	
3.1. Особенности и классификация методов интеллектуального анализа данных	36
3.2. Логистическая регрессия и ROC-анализ данных.....	38
3.3. Алгоритмы кластеризации на службе Data Mining	42
3.4. Деревья решений.....	44
3.5. Классификация программных реализаций систем Data Mining.....	48
3.6. Краткое описание применения аналитической платформы Deductor для решения задач интеллектуального анализа данных.....	52
ЗАКЛЮЧЕНИЕ.....	57
БИБЛИОГРАФИЧЕСКИЙ СПИСОК.....	58

Учебное пособие

Коровин Александр Михайлович

ИНТЕЛЛЕКТУАЛЬНЫЕ СИСТЕМЫ

Текст лекций

Техн. редактор *А.В. Миних*

Издательский центр Южно-Уральского государственного университета

Подписано в печать 01.12.2015. Формат 60×84 1/16. Печать цифровая.
Усл. печ. л. 3,75. Тираж 15 экз. Заказ 653.

Отпечатано в типографии издательского центра ЮУрГУ.
454080, г. Челябинск, пр. им. В.И. Ленина. 76.