МИНИСТЕРСТВО НАУКИ И ВЫСШЕГО ОБРАЗОВАНИЯ РОССИЙСКОЙ ФЕДЕРАЦИИ
Федеральное государственное автономное образовательное учреждение высшего образования
«СЕВЕРО-КАВКАЗСКИЙ ФЕДЕРАЛЬНЫЙ УНИВЕРСИТЕТ»
Пятигорский институт (филиал)

МЕТОДИЧЕСКИЕ УКАЗАНИЯ К ВЫПОЛНЕНИЮ ЛАБОРАТОРНЫХ В РАБОТ ПО ДИСЦИПЛИНЕ СИСТЕМНЫЙ АНАЛИЗ ДАННЫХ И МОДЕЛИ ПРИНЯТИЯ РЕШЕНИЙ

Направление подготовки	**09.04.02 Информационные системы и технологии**
Направленность (профиль)	**Технологии работы с данными и знаниями, анализ информации**
Квалификация выпускника	Магистр

Пятигорск, 2024

СОДЕРЖАНИЕ

1. Цель и задачи освоения дисциплины

Целью освоения дисциплины является формирование набора профессиональных компетенций будущего магистра по направлению 09.04.02 Информационные системы и технологии для решения прикладных задач в рамках направленности (профиля) «Технологии работы с данными и знаниями, анализ информации».

Задачи освоения дисциплины: изучение основных понятий системного анализа данных и теории принятия решений, освоение методов и инструментов системного анализа данных и моделирования алгоритмов принятия решений.

2. Место дисциплины в структуре основной образовательной программы

Дисциплина «Системный анализ данных и модели принятия решений» относится к дисциплинам обязательной части.

3. Наименование лабораторных работ

Тема 2. Анализ данных и проектирование систем

Модели данных. Алгоритмы анализа данных. Методы Байеса. Вероятностный подход к построению графа принятия решения. Методы классификации и кластеризации. Методы DATA MINING

4. Содержэание лабораторных работ

Лабораторная работа № 1. Анализ данных и проектирование систем

Форма проведения: решение проблемных задач (2 часа)

Ход лабораторной работы:

1. Провести анализ данных поставленной задачи
2. Определить методы классификации и кодирования данных
3. Структурировать данные
4. Подвести итоги проведенного исследования

Вопросы для обсуждения:

Системное проектирование. Структурное проектирование. Логическое и физическое моделирование данных. Техническое и технологическое проектирование. Техничсекое задание. Технико-экономическое обоснование.

Теоретический материал

Диаграммы классов. Общие сведения

Диаграмма классов определяет типы классов системы и различного рода статические связи, которые существуют между ними. На диаграммах классов изображаются также атрибуты классов, операции классов и ограничения, которые накладываются на связи между классами.

Диаграмма классов UML - это граф, узлами которого являются элементы статической структуры проекта (классы, интерфейсы), а дугами - отношения между узлами (ассоциации, наследование, зависимости).

На диаграмме классов изображаются следующие элементы:

- Пакет (package) - набор элементов модели, логически связанных между собой;
- Класс (class) - описание общих свойств группы сходных объектов;
- Интерфейс (interface) - абстрактный класс, задающий набор операций, которые объект произвольного класса, связанного с данным интерфейсом, предоставляет другим объектам.

Класс

Класс - это группа сущностей (объектов), обладающих сходными свойствами, а именно, данными и поведением. Отдельный представитель некоторого класса называется объектом класса или просто объектом.

Под поведением объекта в UML понимаются любые правила взаимодействия объекта с внешним миром и с данными самого объекта.

На диаграммах класс изображается в виде прямоугольника со сплошной границей, разделенного горизонтальными линиями на 3 секции:

- Верхняя секция (секция имени) содержит имя класса и другие общие свойства (в частности, стереотип).
- В средней секции содержится список атрибутов
- В нижней - список операций класса, отражающих его поведение (действия, выполняемые классом).

Любая из секций атрибутов и операций может не изображаться (а также обе сразу). Для отсутствующей секции не нужно рисовать разделительную линию и как-либо указывать на наличие или отсутствие элементов в ней.

На усмотрение конкретной реализации могут быть введены дополнительные секции, например, исключения (Exceptions).

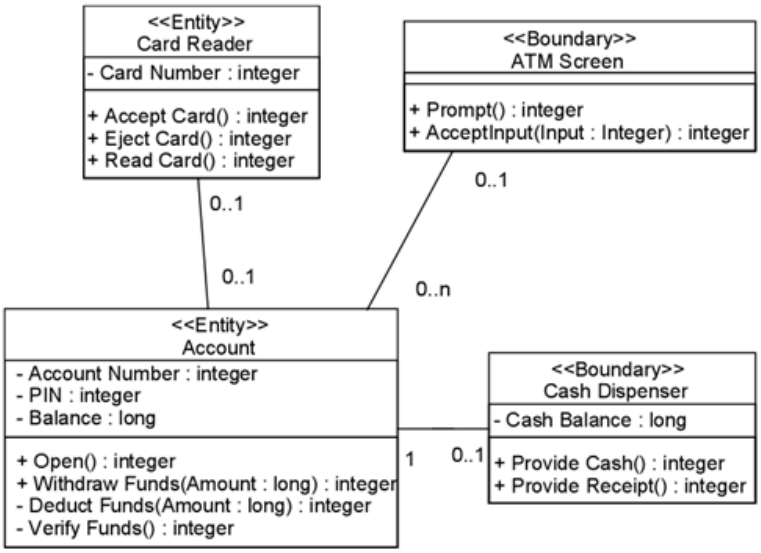

Рисунок 3.9 - Пример диаграммы классов

Стереотипы классов

Стереотипы классов – это механизм, позволяющий разделять классы на категории.

В языке UML определены три основных стереотипа классов:

- Boundary (граница);
- Entity (сущность);
- Control (управление).

Граничные классы

Граничными классами (boundary classes) называются такие классы, которые расположены на границе системы и всей окружающей среды. Это экранные формы, отчеты, интерфейсы с аппаратурой (такой как принтеры или сканеры) и интерфейсы с другими системами.

Чтобы найти граничные классы, надо исследовать диаграммы вариантов использования. Каждому взаимодействию между действующим лицом и вариантом использования должен соответствовать, по крайней мере, один граничный класс. Именно такой класс позволяет действующему лицу взаимодействовать с системой.

Классы-сущности

Классы-сущности (entity classes) содержат хранимую информацию. Они имеют наибольшее значение для пользователя, и потому в их названиях часто используют термины из предметной области. Обычно для каждого класса-сущности создают таблицу в базе данных.

Управляющие классы

Управляющие классы (control classes) отвечают за координацию действий других классов. Обычно у каждого варианта использования имеется один управляющий класс, контролирующий последовательность событий этого варианта использования. Управляющий класс отвечает за координацию, но сам не несет в себе никакой функциональности, так как остальные классы не посылают ему большого количества сообщений. Вместо этого он сам посылает множество сообщений. Управляющий класс просто делегирует ответственность другим классам, по этой причине его часто называют классом-менеджером.

В системе могут быть и другие управляющие классы, общие для нескольких вариантов использования. Например, может быть класс SecurityManager (менеджер безопасности), отвечающий за контроль событий, связанных с безопасностью. Класс TransactionManager (менеджер транзакций) занимается координацией сообщений, относящихся к транзакциям с базой данных. Могут быть и другие менеджеры для работы с другими элементами функционирования системы, такими как разделение ресурсов, распределенная обработка данных или обработка ошибок.

Помимо упомянутых выше стереотипов можно создавать и свои собственные.

Атрибуты

Атрибут – это элемент информации, связанный с классом. Атрибуты хранят инкапсулированные данные класса.

Так как атрибуты содержатся внутри класса, они скрыты от других классов. В связи с этим может понадобиться указать, какие классы имеют право читать и изменять атрибуты. Это свойство называется видимостью атрибута (attribute visibility).

У атрибута можно определить четыре возможных значения этого параметра:

- Public (общий, открытый). Это значение видимости предполагает, что атрибут будет виден всеми остальными классами. Любой класс может просмотреть или изменить значение атрибута. В соответствии с нотацией UML общему атрибуту предшествует знак « + ».

- Private (закрытый, секретный). Соответствующий атрибут не виден никаким другим классом. Закрытый атрибут обозначается знаком « – » в соответствии с нотацией UML.

- Protected (защищенный). Такой атрибут доступен только самому классу и его потомкам. Нотация UML для защищенного атрибута – это знак « # ».

- Package or Implementation (пакетный). Предполагает, что данный атрибут является общим, но только в пределах его пакета. Этот тип видимости не обозначается никаким специальным значком.

В общем случае, атрибуты рекомендуется делать закрытыми или защищенными. Это позволяет лучше контролировать сам атрибут и код.

С помощью закрытости или защищенности удается избежать ситуации, когда значение атрибута изменяется всеми классами системы. Вместо этого логика изменения атрибута будет заключена в том же классе, что и сам этот атрибут. Задаваемые параметры видимости повлияют на генерируемый код.

Операции

Операции реализуют связанное с классом поведение. Операция включает три части – имя, параметры и тип возвращаемого значения.

Параметры – это аргументы, получаемые операцией «на входе». Тип возвращаемого значения относится к результату действия операции.

На диаграмме классов можно показывать как имена операций, так и имена операций вместе с их параметрами и типом возвращаемого значения. Чтобы уменьшить загруженность диаграммы, полезно бывает на некоторых из них показывать только имена операций, а на других их полную сигнатуру.

В языке UML операции имеют следующую нотацию:

Имя Операции (аргумент: тип данных аргумента, аргумент2:тип данных аргумента2,...): тип возвращаемого значения

Следует рассмотреть четыре различных типа операций:

- Операции реализации;
- Операции управления;
- Операции доступа;
- Вспомогательные операции.

Операции реализации

Операции реализации (implementor operations) реализуют некоторые бизнес-функции. Такие операции можно найти, исследуя диаграммы взаимодействия. Диаграммы этого типа фокусируются на бизнес-функциях, и каждое сообщение диаграммы, скорее всего, можно соотнести с операцией реализации.

Каждая операция реализации должна быть легко прослеживаема до соответствующего требования. Это достигается на различных этапах моделирования. Операция выводится из сообщения на диаграмме взаимодействия, сообщения исходят из подробного описания потока событий, который создается на основе варианта использования, а последний – на основе требований. Возможность проследить всю эту цепочку позволяет гарантировать, что каждое требование будет реализовано в коде, а каждый фрагмент кода реализует какое-то требование.

Операции управления

Операции управления (manager operations) управляют созданием и уничтожением объектов. В эту категорию попадают конструкторы и деструкторы классов.

Операции доступа

Атрибуты обычно бывают закрытыми или защищенными. Тем не менее, другие классы иногда должны просматривать или изменять их значения. Для этого существуют операции доступа (access operations). Такой подход дает возможность безопасно инкапсулировать атрибуты внутри класса, защитив их от других классов, но все же позволяет осуществить к ним контролируемый доступ. Создание операций Get и Set (получения и изменения значения) для каждого атрибута класса является стандартом.

Вспомогательные операции

Вспомогательными (helper operations) называются такие операции класса, которые необходимы ему для выполнения его ответственностей, но о которых другие классы не должны ничего знать. Это закрытые и защищенные операции класса.

Чтобы идентифицировать операции, выполните следующие действия:

Изучите диаграммы последовательности и кооперативные диаграммы. Большая часть сообщений на этих диаграммах является операциями реализации. Рефлексивные сообщения будут вспомогательными операциями.

Рассмотрите управляющие операции. Может потребоваться добавить конструкторы и деструкторы.

Рассмотрите операции доступа. Для каждого атрибута класса, с которым должны будут работать другие классы, надо создать операции Get и Set.

Связи

Связь представляет собой семантическую взаимосвязь между классами. Она дает классу возможность узнавать об атрибутах, операциях и связях другого класса. Иными словами, чтобы один класс мог послать сообщение другому на диаграмме последовательности или кооперативной диаграмме, между ними должна существовать связь.

Существуют четыре типа связей, которые могут быть установлены между классами: ассоциации, зависимости, агрегации и обобщения.

Ассоциации

Ассоциация (association) – это семантическая связь между классами. Их рисуют на диаграмме классов в виде обыкновенной линии.

Рисунок 3.10 - Связь ассоциация

Ассоциации могут быть двунаправленными, как в примере, или однонаправленными. На языке UML двунаправленные ассоциации рисуют в виде простой линии без стрелок или со стрелками с обеих ее сторон. На однонаправленной ассоциации изображают только одну стрелку, показывающую ее направление.

Направление ассоциации можно определить, изучая диаграммы последовательности и кооперативные диаграммы. Если все сообщения на них отправляются только одним классом и принимаются только другим классом, но не наоборот, между этими классами имеет место однонаправленная связь. Если хотя бы одно сообщение отправляется в обратную сторону, ассоциация должна быть двунаправленной.

Ассоциации могут быть рефлексивными. Рефлексивная ассоциация предполагает, что один экземпляр класса взаимодействует с другими экземплярами этого же класса.

Зависимости

Связи зависимости (dependency) также отражают связь между классами, но они всегда однонаправлены и показывают, что один класс зависит от определений, сделанных в другом. Например, класс А использует методы класса В. Тогда при изменении класса В необходимо произвести соответствующие изменения в классе А.

Зависимость изображается пунктирной линией, проведенной между двумя элементами диаграммы, и считается, что элемент, привязанный к концу стрелки, зависит от элемента, привязанного к началу этой стрелки.

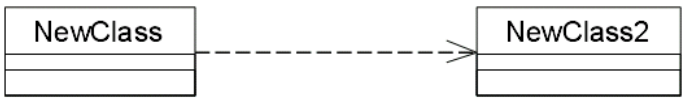

Рисунок 3.11 - Связь зависимость

При генерации кода для этих классов к ним не будут добавляться новые атрибуты. Однако, будут созданы специфические для языка операторы, необходимые для поддержки связи.

Агрегации

Агрегации (aggregations) представляют собой более тесную форму ассоциации. Агрегация – это связь между целым и его частью. Например, у вас может быть класс Автомобиль, а также классы Двигатель, Покрышки и классы для других частей автомобиля. В результате объект класса Автомобиль будет состоять из объекта класса Двигатель, четырех объектов Покрышек и т. д. Агрегации визуализируют в виде линии с ромбиком у класса, являющегося целым:

Рисунок 3.12 - Связь агрегация

В дополнение к простой агрегации UML вводит более сильную разновидность агрегации, называемую композицией. Согласно композиции, объект-часть может принадлежать только единственному целому, и, кроме того, как правило, жизненный цикл частей совпадает с циклом целого: они живут и умирают вместе с ним. Любое удаление целого распространяется на его части.

Такое каскадное удаление нередко рассматривается как часть определения агрегации, однако оно всегда подразумевается в том случае, когда множественность роли составляет 1..1; например, если необходимо удалить Клиента, то это удаление должно распространиться и на Заказы (и, в свою очередь, на Строки заказа).

Обобщения (Наследование)

Обобщение (наследование) - это отношение типа общее-частное между элементами модели. С помощью обобщений (generalization) показывают связи наследования между двумя классами.

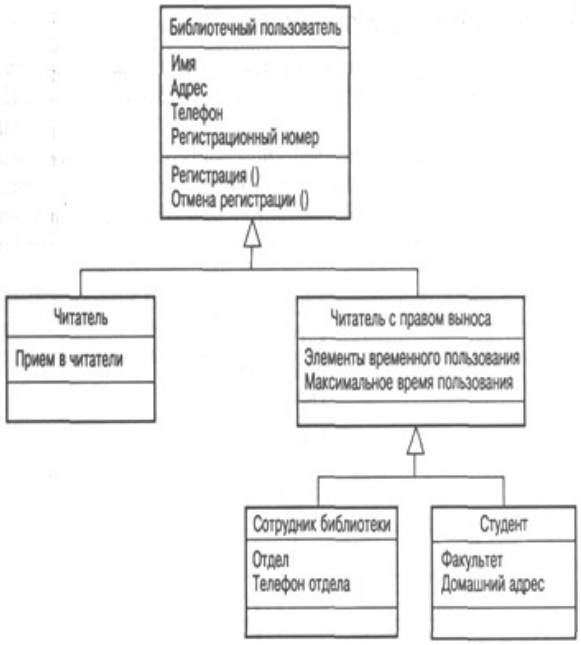

Рисунок 3.13 - Пример связи наследование

Большинство объектно-ориентированных языков непосредственно поддерживают концепцию наследования. Она позволяет одному классу наследовать все атрибуты, операции и связи другого. Наследование пакетов означает, что в пакете-наследнике все сущности пакета-предка будут видны под своими собственными именами (т.е. пространства имен объединяются). Наследование показывается сплошной линией, идущей от класса-потомка к классу-предку (в терминологии ООП - от потомка к предку, от сына к отцу, или от подкласса к суперклассу). Со стороны более общего элемента рисуется большой полый треугольник.

Помимо наследуемых, каждый подкласс имеет свои собственные уникальные атрибуты, операции и связи.

Множественность

Множественность (multiplicity) показывает, сколько экземпляров одного класса взаимодействуют с помощью этой связи с одним экземпляром другого класса в данный момент времени.

Например, при разработке системы регистрации курсов в университете можно определить классы Course (курс) и Student (студент). Между ними установлена связь: у курсов могут быть студенты, а у студентов – курсы. Вопросы, на который должен ответить параметр множественности: «Сколько курсов студент может посещать в данный момент? Сколько студентов может за раз посещать один курс?»

Так как множественность дает ответ на оба эти вопроса, её индикаторы устанавливаются на обоих концах линии связи. В примере регистрации курсов мы решили, что один студент может посещать от нуля до четырех курсов, а один курс могут слушать от 0 до 20 студентов.

В языке UML приняты определенные нотации для обозначения множественности.

Таблица 3.1 - Обозначения множественности связей в UML

Множественность	Значение
0..*	Ноль или больше
1..*	Один или больше
0..1	Ноль или один
1..1 (сокращенная запись: 1)	Ровно один

Имена связей

Связи можно уточнить с помощью имен связей или ролевых имен. Имя связи – это обычно глагол или глагольная фраза, описывающая, зачем она нужна. Например, между классом Person (человек) и классом Company (компания) может существовать ассоциация. Можно задать в связи с этим вопрос, является ли объект класса Person клиентом компании, её сотрудником или владельцем? Чтобы определить это, ассоциацию можно назвать «employs» (нанимает):

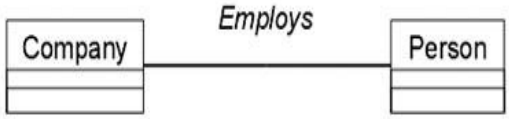

Рисунок 3.14 - Пример имен связей

Роли

Ролевые имена применяют в связях ассоциации или агрегации вместо имен для описания того, зачем эти связи нужны. Возвращаясь к примеру с классами Person и Company, можно сказать, что класс Person играет роль сотрудника класса Company. Ролевые имена – это обычно имена существительные или основанные на них фразы, их показывают на диаграмме рядом с классом, играющим соответствующую роль. Как правило, пользуются или ролевым именем, или именем связи, но не обоими сразу. Как и имена связей, ролевые имена не обязательны, их дают, только если цель связи не очевидна. Пример ролей приводится ниже:

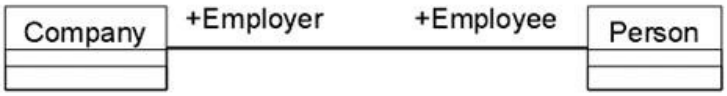

Рисунок 3.15 - Пример ролей связей

Пакет. Механизм пакетов

В контексте диаграмм классов, пакет - это вместилище для некоторого набора классов и других пакетов. Пакет является самостоятельным пространством имен.

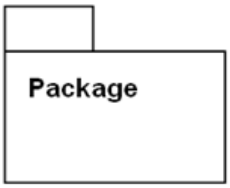

Рисунок 3.16 - Обозначение пакета в UML

В UML нет каких-либо ограничений на правила, по которым разработчики могут или должны группировать классы в пакеты. Но есть некоторые стандартные случаи, когда такая группировка уместна, например, тесно взаимодействующие классы, или более общий случай - разбиение системы на подсистемы.

Пакет физически содержит сущности, определенные в нем (говорят, что "сущности принадлежат пакету"). Это означает, что если будет уничтожен пакет, то будут уничтожено и все его содержимое.

Существует несколько наиболее распространенных подходов к группировке.

Во-первых, можно группировать их по стереотипу. В таком случае получается один пакет с классами-сущностями, один с граничными классами, один с управляющими классами и т.д. Этот подход может быть полезен с точки зрения размещения готовой системы, поскольку все находящиеся на клиентских машинах пограничные классы уже оказываются в одном пакете.

Другой подход заключается в объединении классов по их функциональности. Например, в пакете Security (безопасность) содержатся все классы, отвечающие за безопасность приложения. В таком случае другие пакеты могут называться Employee Maintenance (Работа с сотрудниками), Reporting (Подготовка отчетов) и Error Handling (Обработка ошибок). Преимущество этого подхода заключается в возможности повторного использования.

Механизм пакетов применим к любым элементам модели, а не только к классам. Если для группировки классов не использовать некоторые эвристики, то она становится произвольной. Одна из них, которая в основном используется в UML, – это зависимость. Зависимость между двумя пакетами существует в том случае, если между любыми двумя классами в пакетах существует любая зависимость.

Таким образом, диаграмма пакетов представляет собой диаграмму, содержащую пакеты классов и зависимости между ними. Строго говоря, пакеты и зависимости являются элементами диаграммы классов, то есть диаграмма пакетов – это форма диаграммы классов.

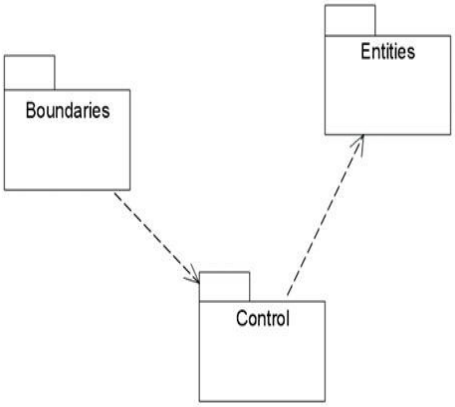

Рисунок 3.17 - Пример диаграммы пакетов

Зависимость между двумя элементами имеет место в том случае, если изменения в определении одного элемента могут повлечь за собой изменения в другом. Что касается классов, то причины для зависимостей могут быть самыми разными:

- один класс посылает сообщение другому;
- один класс включает часть данных другого класса; один класс использует другой в качестве параметра операции.

Если класс меняет свой интерфейс, то любое сообщение, которое он посылает, может утратить свою силу.

Пакеты не дают ответа на вопрос, каким образом можно уменьшить количество зависимостей в вашей системе, однако они помогают выделить эти зависимости, а после того, как они все окажутся на виду, остается только поработать над снижением их количества. Диаграммы пакетов можно считать основным средством управления общей структурой системы.

Пакеты являются жизненно необходимым средством для больших проектов. Их следует использовать в тех случаях, когда диаграмма классов, охватывающая всю систему в целом и размещенная на единственном листе бумаги формата А4, становится нечитаемой.

Диаграммы состояний

Диаграммы состояний определяют все возможные состояния, в которых может находиться конкретный объект, а также процесс смены состояний объекта в результате наступления некоторых событий.

Существует много форм диаграмм состояний, незначительно отличающихся друг от друга семантикой.

На диаграмме имеются два специальных состояния – начальное (start) и конечное (stop). Начальное состояние выделено черной точкой, оно соответствует состоянию объекта, когда он только что был создан. Конечное состояние обозначается черной точкой в белом кружке, оно соответствует состоянию объекта непосредственно перед его уничтожением. На диаграмме состояний может быть одно и только одно начальное состояние. В то же время, может быть столько конечных состояний, сколько вам нужно, или их может не быть вообще. Когда объект находится в каком-то конкретном состоянии, могут выполняться различные процессы. Процессы, происходящие, когда объект находится в определенном состоянии, называются действиями (actions).

С состоянием можно связывать данные пяти типов: деятельность, входное действие, выходное действие, событие и история состояния.

Деятельность

Деятельностью (activity) называется поведение, реализуемое объектом, пока он находится в данном состоянии. Деятельность – это прерываемое поведение. Оно

может выполняться до своего завершения, пока объект находится в данном состоянии, или может быть прервано переходом объекта в другое состояние. Деятельность изображают внутри самого состояния, ей должно предшествовать слово do (делать) и двоеточие.

Входное действие

Входным действием (entry action) называется поведение, которое выполняется, когда объект переходит в данное состояние. Данное действие осуществляется не после того, как объект перешел в это состояние, а, скорее, как часть этого перехода. В отличие от деятельности, входное действие рассматривается как непрерываемое. Входное действие также показывают внутри состояния, ему предшествует слово entry (вход) и двоеточие.

Выходное действие

Выходное действие (exit action) подобно входному. Однако, оно осуществляется как составная часть процесса выхода из данного состояния. Оно является частью процесса такого перехода. Как и входное, выходное действие является непрерываемым.

Выходное действие изображают внутри состояния, ему предшествует слово exit (выход) и двоеточие.

Поведение объекта во время деятельности, при входных и выходных действиях может включать отправку события другому объекту. В этом случае описанию деятельности, входного действия или выходного действия предшествует знак « ^ ».

Соответствующая строка на диаграмме выглядит как

Do: ^Цель.Событие (Аргументы)

Здесь Цель – это объект, получающий событие, Событие – это посылаемое сообщение, а Аргументы являются параметрами посылаемого сообщения.

Деятельность может также выполняться в результате получения объектом некоторого события. При получении некоторого события выполняется определенная деятельность.

Переходом (Transition) называется перемещение из одного состояния в другое. Совокупность переходов диаграммы показывает, как объект может перемещаться между своими состояниями. На диаграмме все переходы изображают в виде стрелки, начинающейся на первоначальном состоянии и заканчивающейся последующим.

Переходы могут быть рефлексивными. Объект может перейти в то же состояние, в котором он в настоящий момент находится. Рефлексивные переходы изображают в виде стрелки, начинающейся и завершающейся на одном и том же состоянии.

У перехода существует несколько спецификаций. Они включают события, аргументы, ограждающие условия, действия и посылаемые события.

События

Событие (event) – это то, что вызывает переход из одного состояния в другое. Событие размещают на диаграмме вдоль линии перехода.

На диаграмме для отображения события можно использовать как имя операции, так и обычную фразу.

Большинство переходов должны иметь события, так как именно они, прежде всего, заставляют переход осуществиться. Тем не менее, бывают и автоматические переходы, не имеющие событий. При этом объект сам перемещается из одного состояния в другое со скоростью, позволяющей осуществиться входным действиям, деятельности и выходным действиям.

Ограждающие условия

Ограждающие условия (guard conditions) определяют, когда переход может, а когда не может осуществиться. В противном случае переход не осуществится.

Ограждающие условия изображают на диаграмме вдоль линии перехода после имени события, заключая их в квадратные скобки.

Ограждающие условия задавать необязательно. Однако если существует несколько автоматических переходов из состояния, необходимо определить для них взаимно исключающие ограждающие условия. Это поможет читателю диаграммы понять, какой путь перехода будет автоматически выбран.

Действие

Действием (action), как уже говорилось, является непрерываемое поведение, осуществляющееся как часть перехода. Входные и выходные действия показывают внутри состояний, поскольку они определяют, что происходит, когда объект входит или выходит из него. Большую часть действий, однако, изображают вдоль линии перехода, так как они не должны осуществляться при входе или выходе из состояния.

Действие рисуют вдоль линии перехода после имени события, ему предшествует косая черта.

Событие или действие могут быть поведением внутри объекта, а могут представлять собой сообщение, посылаемое другому объекту. Если событие или действие посылается другому объекту, перед ним на диаграмме помещают знак « ^ ».

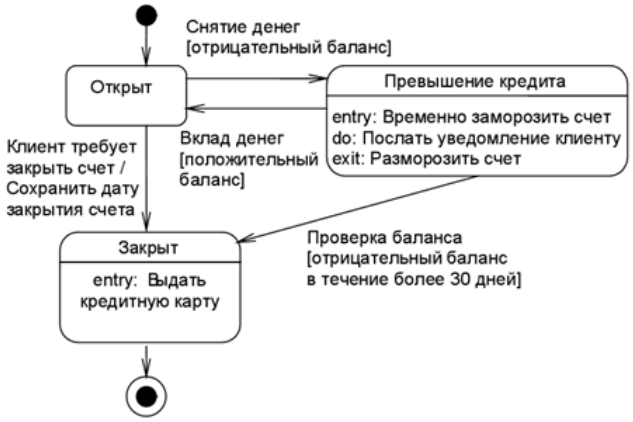

Рисунок 3.18 - Пример диаграммы состояний

Диаграммы состояний не надо создавать для каждого класса, они применяются только в сложных случаях. Если объект класса может существовать в нескольких состояниях и в каждом из них ведет себя по-разному, для него может потребоваться такая диаграмма.

Диаграммы размещения

Диаграмма размещения (deployment diagram) отражает физические взаимосвязи между программными и аппаратными компонентами системы. Она является хорошим средством для того, чтобы показать маршруты перемещения объектов и компонентов в распределенной системе.

Каждый узел на диаграмме размещения представляет собой некоторый тип вычислительного устройства – в большинстве случаев, часть аппаратуры. Эта аппаратура может быть простым устройством или датчиком, а может быть и мэйнфреймом.

Диаграмма размещения показывает физическое расположение сети и местонахождение в ней различных компонентов.

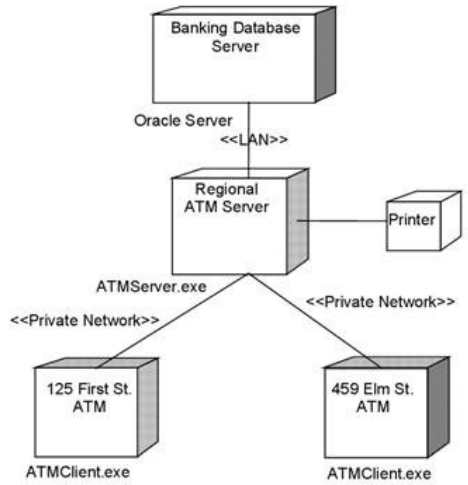

Рисунок 3.19 - Пример диаграммы размещения

Диаграмма размещения используется менеджером проекта, пользователями, архитектором системы и эксплуатационным персоналом, чтобы понять физическое размещение системы и расположение её отдельных подсистем.

Диаграммы компонентов

Диаграммы компонентов показывают, как выглядит модель на физическом уровне. На них изображены компоненты программного обеспечения и связи между ними. При этом на такой диаграмме выделяют два типа компонентов: исполняемые компоненты и библиотеки кода.

Каждый класс модели (или подсистема) преобразуется в компонент исходного кода. После создания они сразу добавляются к диаграмме компонентов. Между отдельными компонентами изображают зависимости, соответствующие зависимостям на этапе компиляции или выполнения программы.

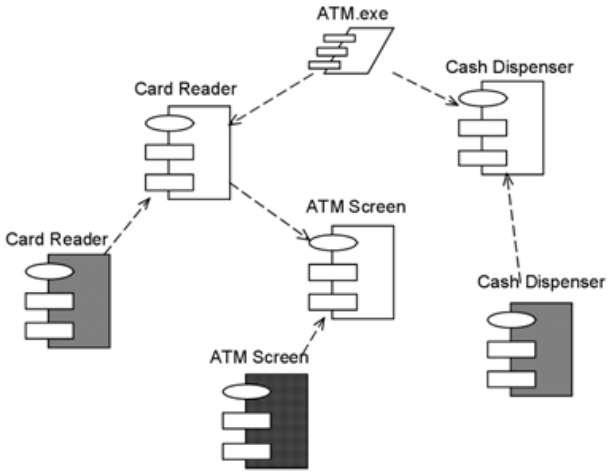

Рисунок 3.20 -. Пример диаграммы компонентов

Диаграммы компонентов применяются теми участниками проекта, кто отвечает за компиляцию системы. Из нее видно, в каком порядке надо компилировать компоненты, а также какие исполняемые компоненты будут созданы системой. На такой диаграмме показано соответствие классов реализованным компонентам. Она нужна там, где начинается генерация кода.

Объединение диаграмм компонентов и развертывания

В некоторых случаях допускается размещать диаграмму компонентов на диаграмме развертывания. Это позволяет показать какие компоненты выполняются и на каких узлах.

Работа с литературой:

Рекомендуемые источники информации (№ источника)			
Основная	Дополнительная	Методическая	Интернет-ресурсы
1-3	1-3	1-3	1-3

Оценочные средства: вопросы к собеседованию (См.: Фонд оценочных средств)

5. Типовые контрольные задания и иные материалы, характеризующие этапы формирования компетенций

5.1. Критерии оценивания компетенций

Оценка «отлично» выставляется студенту, если студент имеет глубокие знания, умения, навыки, демонстрирует полное понимание сущности рассматриваемых вопросов.

Оценка «хорошо» выставляется студенту, если студент имеет полные знания, умения, навыки, демонстрирует понимание сущности рассматриваемых вопросов в целом, но показывает недостаточно уверенное владение некоторыми теоретическими и практическими положениями дисциплины.

Оценка «удовлетворительно» выставляется студенту, если студент имеет низкий уровень знаний, умений, навыков, демонстрирует частичное понимание сущности рассматриваемых вопросов.

Оценка «неудовлетворительно» выставляется студенту, если студент имеет пробелы в знаниях, умениях, навыках, демонстрирует незнание сущности рассматриваемых вопросов.

5.2. Описание шкалы оценивания

Рейтинговая система оценки успеваемости студентов заочной формы не предусмотрена.

5.3. Методические материалы, определяющие процедуры оценивания знаний, умений, навыков и (или) опыта деятельности, характеризующих этапы формирования компетенций

Процедура проведения оценочных мероприятий включает в себя собеседование, подготовку к экзамену и выполнение индивидуальных заданий к лабораторным работам.

Предлагаемые студенту задания позволяют проверить компетенции ПК-6, ПК-13, ПК-14. Результаты экзамена и отчетов по индивидуальным заданиям оцениваются по:

- точности ответов на поставленные вопросы;
- последовательности и рациональности выполнения заданий;
- знанию технологий, использованных при выполнении задания.

6. Учебно-методическое и информационное обеспечение дисциплины

6.1 Перечень основной и дополнительной литературы, необходимой для освоения дисциплин

6.1.1. Перечень основной литературы

1. Основы компьютерного моделирование [Электронный ресурс] : учебно-методический комплекс / . — Электрон. текстовые данные. — Алматы: Нур-Принт, 2024.—175c. — 9965-756-09-0. — Режим доступа: http://www.iprbookshop.ru/67115.html.

2. Маглинец Ю.А. Анализ требований к автоматизированным информационным системам [Электронный ресурс]/ Маглинец Ю.А.—Электрон. текстовые данные.— М.: Интернет-Университет Информационных Технологий (ИНТУИТ), 2016.— 191 c.— Режим доступа: http://www.iprbookshop.ru/52184.— ЭБС «IPRbooks», по паролю.

6.1.2. Перечень дополнительной литературы

1. Шорников Ю.В. Инструментальное моделирование гибридных систем [Электронный ресурс]: учебное пособие/ Шорников Ю.В., Томилов И.Н., Достовалов Д.Н.— Электрон.текстовые данные.— Новосибирск: Новосибирский государственный технический университет, 2014.— 70с.—Режим доступа: http://www.iprbookshop.ru/44929.— ЭБС IPRbooks..

2. Клименко И.С. Теория систем и системный анализ [Электронный ресурс]: учебное пособие / И.С. Клименко. — Электрон. текстовые данные. — М.: Российский новый университет, 2014. — 264 c. —Режим доступа: http://www.iprbookshop.ru/21322.html.

6.2. Перечень учебно-методического обеспечения самостоятельной работы обучающихся по дисциплине

1. Методические указания по выполнению лабораторных работ по дисциплине «Системный анализ данных и модели принятия решений».

2. Методические рекомендации для студентов по организации самостоятельной работы по дисциплине «Системный анализ данных и модели принятия решений».

6.3. Перечень ресурсов информационно-телекоммуникационной сети «Интернет», необходимых для освоения дисциплины

1. Университетская библиотека online. http://www.biblioclub.ru.

2. ЭБС «IPRbooks». http://www.iprbookshop.ru.

3. Электронная библиотека СКФУ.. http://catalog.ncstu.ru.

4. Государственная публичная научно- техническая библиотека России. (ГПНТБ России). www.gpntb.ru.

МИНИСТЕРСТВО НАУКИ И ВЫСШЕГО ОБРАЗОВАНИЯ РОССИЙСКОЙ ФЕДЕРАЦИИ
Федеральное государственное автономное образовательное учреждение высшего образования
«СЕВЕРО-КАВКАЗСКИЙ ФЕДЕРАЛЬНЫЙ УНИВЕРСИТЕТ»
Пятигорский институт (филиал)

МЕТОДИЧЕСКИЕ УКАЗАНИЯ ДЛЯ СТУДЕНТОВ К ВЫПОЛНЕНИЮ САМОСТОЯТЕЛЬНОЙ РАБОТЫ ПО ДИСЦИПЛИНЕ СИСТЕМНЫЙ АНАЛИЗ ДАННЫХ И МОДЕЛИ ПРИНЯТИЯ РЕШЕНИЙ

Направление подготовки	**09.04.02 Информационные системы и технологии**
Направленность (профиль)	**Технологии работы с данными и знаниями, анализ информации**
Квалификация выпускника	Магистр

Пятигорск, 2024

СОДЕРЖАНИЕ

1. Цель и задачи освоения дисциплины

Целью освоения дисциплины является формирование набора профессиональных компетенций будущего магистра по направлению 09.04.02 Информационные системы и технологии для решения прикладных задач в рамках направленности (профиля) «Технологии работы с данными и знаниями, анализ информации».

Задачи освоения дисциплины: изучение основных понятий системного анализа данных и теории принятия решений, освоение методов и инструментов системного анализа данных и моделирования алгоритмов принятия решений.

2. Место дисциплины в структуре основной образовательной программы

Дисциплина «Системный анализ данных и модели принятия решений» относится к дисциплинам обязательной части. Ее освоение происходит в 4 семестре.

3 Технологическая карта самостоятельной работы обучающегося

Для студентов очной формы обучения:

Коды реализуемых компетенций, индикатора(ов)	Вид деятельности студентов	Средства и технологии оценки	Объем часов, в том числе		
			СРС	Контактная работа с преподавателем	Всего
2 семестр					
ПК-6, ПК-13, ПК-14	Подготовка к лекциям	Собеседование	1,08	0,12	1,2
ПК-6, ПК-13, ПК-14	Самостоятельное изучение литературы по темам 1, 2	Собеседование	71,28	7,92	79,2
ПК-6, ПК-13, ПК-14	Подготовка к лабораторным работам	Отчет письменный	3,24	0,36	3,6
			75,6	8,4	84

Для студентов заочной формы обучения:

Коды реализуемых компетенций, индикатора(ов)	Вид деятельности студентов	Средства и технологии оценки	Объем часов, в том числе		
			СРС	Контактная работа с преподавателем	Всего
2 семестр					
ПК-6, ПК-13, ПК-14	Подготовка к лекциям	Собеседование	0,36	0,04	0,4
ПК-6, ПК-13, ПК-14	Самостоятельное изучение литературы по темам 1, 2	Собеседование	88,56	9,84	98,4
ПК-6, ПК-13, ПК-14	Подготовка к лабораторным работам	Отчет письменный	1,08	0,12	1,2
			90	10	100

4. Содержание самостоятельной работы

Тема самостоятельного изучения № 1. Методы и средства системного анализа данных

Вид деятельности студентов: самостоятельное изучение литературы
Итоговый продукт самостоятельной работы: конспект
Средства и технологии оценки: собеседование
План конспекта:
Применение методов и средств анализа данных. Правила классификации. Деревья решений. Корреляционный и регрессионный анализ. Ассоциативные правила. Кластеризация. Типы алгоритмов.
Работа с литературой:

Рекомендуемые источники информации (№ источника)			
Основная	Дополнительная	Методическая	Интернет-ресурсы
1-3	1-3	1-3	1-3

Тема самостоятельного изучения № 2. Анализ данных и проектирование систем

Вид деятельности студентов: самостоятельное изучение литературы
Итоговый продукт самостоятельной работы: конспект
Средства и технологии оценки: собеседование
План конспекта:
Методы классификации. Методы Байеса. Наивный Байес. Вероятностный подход к наступлению состояния системы. Обучающая выборка. Оценочная функция Лапласа. Экспертная система. Система правил. Логический вывод. Семантическая модель. Продукционные, фреймовые и семантические сети. Интерпретатор. Применение баз знаний. Система авиалиний. ГИС-системы.
Работа с литературой:

Рекомендуемые источники информации (№ источника)			
Основная	Дополнительная	Методическая	Интернет-ресурсы
1-3	1-3	1-3	1-3

5. Теоретический материал

5.1 Математическое моделирование

Построение модели

Модель и моделирование - универсальные понятия, атрибуты одного из наиболее мощных методов познания в любой профессиональной области, познания системы, процесса, явления.

Вид модели и методы ее исследования больше зависят от информационно - логических связей элементов и подсистем моделируемой системы, ресурсов, связей с окружением, а не от конкретного наполнения системы.

Модельный стиль мышления позволяет вникать в структуру и внутреннюю логику моделируемой системы.

Построение модели - системная задача, требующая анализа и синтеза исходных данных, гипотез, теорий, знаний специалистов. Системный подход позволяет не только построить модель реальной системы, но и использовать эту модель для оценки (например, эффективности управления или функционирования) системы.

Модель - это объект или описание объекта, системы для замещения одной системы (оригинала) другой системой для лучшего изучения оригинала или воспроизведения каких-либо его свойств.

Например, отображая физическую систему на математическую систему, получим математическую модель физической системы. Любая модель строится и исследуется при определенных допущениях, гипотезах.

Пример. Рассмотрим физическую систему: тело массой m скатывается по наклонной плоскости с ускорением a, на которое воздействует сила F.

Исследуя такие системы, Ньютон получил математическое соотношение: F = m*a. Это физико-математическая модель системы или математическая модель физической системы скатывающегося тела.

При описании этой системы приняты следующие гипотезы:

- поверхность идеальна (коэффициент трения равен нулю);
- тело находится в вакууме (сопротивление воздуха равно нулю);
- масса тела неизменна;
- тело движется с одинаковым постоянным ускорением в любой точке.

Пример. Физиологическая система (система кровообращения человека) - подчиняется некоторым законам термодинамики. Описывая эту систему на физическом (термодинамическом) языке балансовых законов, получим физическую, термодинамическую модель физиологической системы. Если записать эти законы на математическом языке, т.е. соответствующие термодинамические уравнения, то уже получаем математическую модель системы кровообращения.

Пример. Совокупность предприятий функционирует на рынке, обмениваясь товарами, сырьем, услугами, информацией. Если описать экономические законы, правила их взаимодействия на рынке с помощью математических соотношений, например, системы алгебраических уравнений, где неизвестными будут величины прибыли, получаемые от взаимодействия предприятий, а коэффициентами уравнения будут значения интенсивностей таких взаимодействий, то получим экономико-математическую модель системы предприятий на рынке.

Слово "модель" (лат. modelium) означает "мера", "способ", "сходство с какой-то вещью".

Моделирование базируется на математической теории подобия, согласно которой абсолютное подобие может иметь место лишь при замене одного объекта другим точно таким же.

При моделировании большинства систем абсолютное подобие невозможно, и основная цель моделирования заключается в том, что модель достаточно хорошо должна отображать функционирование моделируемой системы.

Пример фрактальной модели - множество Кантора. Рассмотрим отрезок [0;1]. Разделим его на 3 части и выбросим средний отрезок. Оставшиеся 2 промежутка опять разделим на три части и выкинем средние промежутки и т.д. Получим множество, называемое множеством Кантора. В пределе получаем несчетное множество изолированных точек.

Рисунок 1.1 - Множество Кантора для 3-х делений

5.2 Основы компьютерного моделирования

Границы между моделями различного вида весьма условны. Можно говорить о различных режимах использования моделей - имитационном, стохастическом, динамическом, детерминированном и др.

Как правило, модель включает в себя: объект O, субъект A (не обязательно) , задачу Z, ресурсы B, среду моделирования C.

Модель можно представить формально в виде: M = < O, A, Z, B, C >.

Основные свойства любой модели:

1. Целенаправленность - модель всегда отображает некоторую систему, т.е. имеет цель такого отображения;
2. Конечность - модель отображает оригинал лишь в конечном числе его отношений и ресурсы моделирования конечны;
3. Упрощенность - модель отображает только существенные стороны объекта и она должна быть проста для исследования или воспроизведения;
4. Наглядность, обозримость основных ее свойств и отношений;
5. Доступность и технологичность для исследования или воспроизведения;
6. Информативность - модель должна содержать достаточную информацию о системе (в рамках гипотез, принятых при построении модели) и должна давать возможность получать новую информацию;
7. Полнота - в модели должны быть учтены все основные связи и отношения, необходимые для обеспечения цели моделирования;
8. Управляемость - модель должна иметь хотя бы один параметр, изменениями которого можно имитировать поведение моделируемой системы в различных условиях.

5.3 Жизненный цикл моделируемой системы

Жизненный цикл моделируемой системы состоит из следующих этапов:

1. Сбор информации об объекте, выдвижение гипотез, предварительный модельный анализ;
2. Проектирование структуры и состава моделей (подмоделей);
3. Построение спецификаций модели, разработка и отладка отдельных подмоделей, сборка модели в целом, идентификация (если это нужно) параметров моделей;
4. Исследование модели - выбор метода исследования и разработка алгоритма (программы) моделирования;
5. Исследование адекватности, устойчивости, чувствительности модели;
6. Оценка средств моделирования (затраченных ресурсов);
7. Интерпретация, анализ результатов моделирования и установление некоторых причинно-следственных связей в исследуемой системе;
8. Генерация отчетов и проектных (народно-хозяйственных) решений;
9. Уточнение, модификация модели, если это необходимо, и возврат к исследуемой системе с новыми знаниями, полученными с помощью модели и моделирования.

5.4 Моделирование как метод системного анализа

Часто в системном анализе при модельном подходе исследования может совершаться одна методическая ошибка, а именно, - построение корректных и адекватных моделей (подмоделей) подсистем системы и их логически корректная увязка не дает гарантий корректности построенной таким способом модели всей системы.

Модель, построенная без учета связей системы со средой, может служить подтверждением теоремы Геделя, а точнее, ее следствия, утверждающего, что в сложной изолированной системе могут существовать истины и выводы, корректные в этой системе и некорректные вне ее.

Наука моделирования состоит в разделении процесса моделирования (системы, модели) на этапы (подсистемы, подмодели), детальном изучении каждого этапа, взаимоотношений, связей, отношений между ними и затем эффективного описания их с максимально возможной степенью формализации и адекватности.

В случае нарушения этих правил получаем не модель системы, а модель "собственных и неполных знаний".

Моделирование рассматривается, как особая форма эксперимента, эксперимента не над самим оригиналом, т.е. простым или обычным экспериментом, а над копией оригинала. Здесь важен изоморфизм систем оригинальной и модельной.

Изоморфизм - равенство, одинаковость, подобие.

Модели и моделирование применяются по основным направлениям:

- в обучении, в познании и разработке теории исследуемых систем;
- в прогнозировании (выходных данных, ситуаций, состояний системы);
- в управлении (системой в целом, отдельными ее подсистемами);
- в автоматизации (системы или ее отдельных подсистем).

Классификация видов моделирования

Рисунок 3.1 - Классификация видов моделирования

При физическом моделировании используется сама система, либо подобная ей в виде макета, например, летательный аппарат в аэродинамической трубе.

Математическое моделирование есть процесс установления соответствия реальной системе S математической модели M и исследование этой модели, позволяющее получить характеристики реальной системы.

При аналитическом моделировании процессы функционирования элементов записываются в виде математических соотношений (алгебраических, интегральных, дифференциальных, логических и др.).

Аналитическая модель может быть исследована методами:

- аналитическими (устанавливаются явные зависимости, получаются, в основном, аналитические решения);
- численными (получаются приближенные решения);

Компьютерное математическое моделирование формулируется в виде алгоритма (программы для ЭВМ), что позволяет проводить над моделью вычислительные эксперименты.

Численное моделирование использует методы вычислительной математики.

Статистическое моделирование использует обработку данных о системе с целью получения статистических характеристик системы.

Имитационное моделирование воспроизводит на ЭВМ (имитирует) процесс функционирования исследуемой системы, соблюдая логическую и временную последовательность протекания процессов, что позволяет узнать данные о состоянии системы или отдельных ее элементов в определенные моменты времени.

Применение математического моделирования позволяет исследовать объекты, реальные эксперименты над которыми затруднены или невозможны.

Экономический эффект при математическом моделировании состоит в том, что затраты на проектирование систем в среднем сокращаются в 50 раз.

Mathcad — система компьютерной алгебры

Mathcad — система компьютерной алгебры из класса систем автоматизированного проектирования, ориентированная на подготовку интерактивных документов с вычислениями и визуальным сопровождением, отличается легкостью использования и применения для коллективной работы.

Широкий интерес к системе Mathcad привел к тому, что в России наконец-то появились книги по отдельным версиям. Система Mathcad была создана в 80-х годах в университете Станфорда (США).

Современные версии для ПК готовит фирма MathSoft Application. Достоинство – программирование на языке математики. Это универсальный математический интерфейс:

- Есть мощная поддержка графики.
- Возможен импорт графики из других программ.
- Большое количество встроенных математических функций (сотни).
- Встроенные справочники по предметным областям.
- Возможна анимация.
- Символьная математика.

Недостатки:

- Это интерпретатор.
- Возможности программирования ограничены.

Системы Mathcad пользуются огромной популярностью во всем мире благодаря удобным средствам подготовки документов, имеющих вид обычных статей или книг. В то же время оказывается, что эти средства вполне достаточны для решения подавляющего большинства задач по математике, физики и других направлений науки и техники.

Mathcad является математически ориентированными универсальными системами. Помимо собственно вычислений они позволяют решать оформительские задачи. Они позволяют готовить статьи, книги, диссертации, научные отчеты, дипломные и курсовые проекты с доступным набором самых сложных математических формул и изысканным графическим представлением результатов.

С самого первого своего появления системы класса Mathcad имели удобный пользовательский интерфейс – совокупность средств общения с пользователем в виде масштабируемых и перемещаемых окон, кнопок и иных элементов. У этой системы есть эффективные средства типовой научной графики, они просты в применении и интуитивно понятны. Словом, системы Mathcad ориентированы на массового пользователя – от ученика начальных классов до академика.

Несмотря на то, что эта программа в основном ориентирована на пользователей-непрограммистов, Mathcad также используется в сложных проектах, чтобы визуализировать результаты математического моделирования, путем использования распределённых вычислений и традиционных языков программирования. Также Mathcad часто используется в крупных инженерных проектах, где большое значение имеет трассируемость и соответствие стандартам.

Mathcad достаточно удобно использовать для обучения, вычислений и инженерных расчетов. Открытая архитектура приложения в сочетании с поддержкой технологий NET и XML позволяют легко интегрировать приложение.

Рассмотрим наиболее часто применяемые функции для статистических расчетов, которые встроены в программу.

5.5 Компьютерная реализация математических вычислений

Математическое моделирование сложных систем

Будем считать, что элемент s есть некоторый объект, обладающий определенными свойствами, внутреннее строение которого для целей исследования не играет роли, например, самолет для моделирования полета – не элемент, а для моделирования работы аэропорта – элемент.

Связь *l* между элементами есть процесс их взаимодействия, важный для целей исследования.

Система S – совокупность элементов со связями *l* и целью функционирования системы F.

Сложная система – это система, состоящая из разнотипных элементов с разнотипными связями.

Большая система – это система, состоящая из большого числа однотипных элементов с однотипными связями.

В общем виде систему математически можно представить в виде:

$$S = \{\{s\},\{l\},F\}$$

Автоматизированная система S_A есть сложная система с определяющей ролью элементов двух типов: технических средств $s_т$ и действий человека $s_Н$:

$$S_A = \{\{s_T\},\{s_H\},\{s_O\},\{l\},F\}$$

Здесь s_0 - остальные элементы системы.

Декомпозиция системы. Характеристики системы

Декомпозиция системы есть разбиение системы на элементы или группы элементов с указанием связей между ними, неизменными во время функционирования системы.

Практически все системы рассматриваются функционирующими во времени, поэтому определим их динамические характеристики.

Состояние – это множество характеристик элементов системы, изменяющихся во времени и важных для целей ее функционирования.

Процесс (динамика) – это множество значений состояний системы, изменяющихся во времени.

Цель функционирования есть задача получения желаемого состояния системы. Достижение цели обычно влечет целенаправленное вмешательство в процесс функционирования системы, которое называется управлением.

1. Расчет - определение значений параметров системы.
2. Анализ – изучение свойств функционирования системы.
3. Синтез – выбор структуры и параметров по заданным свойствам системы.

Параметры системы. Фазовая траектория. Фазовое пространство

Пусть $T = [t_0, t_1]$ есть временной интервал моделирования системы S (интервал модельного времени).

Построение модели начинается с определения параметров и переменных, определяющих процесс функционирования системы.

Параметры системы $\theta_1,\theta_2,\ldots,\theta_m$ - это характеристики системы, остающиеся постоянными на всем интервале T.

Переменные бывают зависимые и независимые.

Независимые переменные есть, как правило, входные воздействия (в том числе управляющие)

$$u = u(t) = (u_1(t),\ldots u_{n_1}(t)) \in U \subseteq R^{n_1}$$

ими могут быть также воздействия внешней среды.

Последовательность изменения x(t) при

$$t_1 < t_2 < \ldots < t_N$$

называется фазовой траекторией системы,

$x \in X$, где X – пространство состояний или фазовое пространство.

Последовательность изменения y(t) называется выходной траекторией системы.

Зависимые переменные есть выходные характеристики (сигналы)

$y = y(t) = (y_1(t),...,y_{n_4}(t)) \in Y \subseteq R^{n_4}$

Математическая модель системы

Общая схема математической модели (ММ) функционирования системы может быть представлена в виде, показанном на рисунке 4.1.

Множество переменных $\{u, v, \theta, x, y\}$ вместе с законами функционирования

$x(t) = ...,$

$y(t) = ...$

называется математической моделью системы.

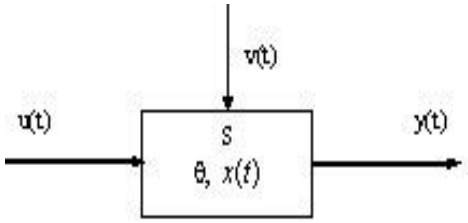

Рисунок 4.1 – Математическая модель системы

Если t непрерывно, то модель называется непрерывной, иначе – дискретной:

$(t = i \cdot \Delta,\ i = 1,2,...)$.

Если модель не содержит случайных элементов, то она называется детерминированной, в противном случае – вероятностной, стохастической.

Если математическое описание модели слишком сложное и частично или полностью неопределенно, то в этом случае используются агрегативные модели.

Сущность агрегативной модели заключается в разбиении системы на конечное число взаимосвязанных частей (подсистем), каждая из которых допускает стандартное математическое описание. Эти подсистемы называются агрегатами.

Моделирование случайных элементов в системах является одной из самых базовых задач математического моделирования.

Типы базовых датчиков:

- физические (любой физический шум), в последнее время практически не используются, т.к. характеристики нестабильны и реализацию повторить нельзя;
- псевдослучайные датчики.

Требования к базовым датчикам:

Отрезок апериодичности.

Равномерность.

Некоррелированность.

Функции регрессии.

Широко распространенной задачей обработки данных является представление их совокупности некоторой функцией y(x). Такое представление называется регрессией. Задача регрессии в том чтобы получить параметры функции такими, при которых функция приближает "облако" исходных точек с наименьшей квадратичной погрешностью.

Известны:

- Линейная регрессия (прямая линия);
- Полиномиальная регрессия (полином);
- Линейная регрессия общего вида (линейная сумма произвольных функций);
- Нелинейная регрессия общего вида (произвольная функция);
- Линейная регрессия.

При линейной регрессии функция y(x) имеет вид y(x)=ax+b и описывает отрезок прямой.

Функция предсказания

На практике нередко приходится сталкиваться с задачей расчёта последующих точек по ряду известных точек – задачей предсказания. Для предсказания поведения функциональной зависимости в Mathcad имеется функция: predict (data,k,N) – предсказание, где data – вектор данных, k – число точек предшествующих предсказанию, N - число предсказываемых точек данных.

Функция предсказания обеспечивает высокую точность при монотонных исходных функциях или функциях, представляемых полиномом невысокой степени.

Функция predict применима к предсказуемым событиям, поведение которых описывается реальной математической зависимостью. В странах со стабильной экономикой эта функция вполне применима для описания сезонных и стабильных колебаний курса валют, прибылей фирм, продажа товаров и.т.д.

Пример построения линейной регрессии:

$$VX := \begin{pmatrix} 1 \\ 2 \\ 3 \\ 4 \\ 5 \end{pmatrix} \qquad VY := \begin{pmatrix} 4 \\ 11 \\ 15 \\ 21 \\ 28 \end{pmatrix} \qquad \text{Исходные данные} ORIGN := 1$$

Вычислим коэффициенты a и b линейной регрессии:

$$a := intercept(VX, VY) \qquad b := slope(VX, VY) i := 1..6 \qquad f(x) := a + b \cdot x1 = -1.6 \qquad b = 5.8$$

$$corr(VX, VY) = 0,996 f(3) = 15,8 \qquad linterp(VX, VY, 3) = 15$$

По этим данным строим график линейной регрессии:

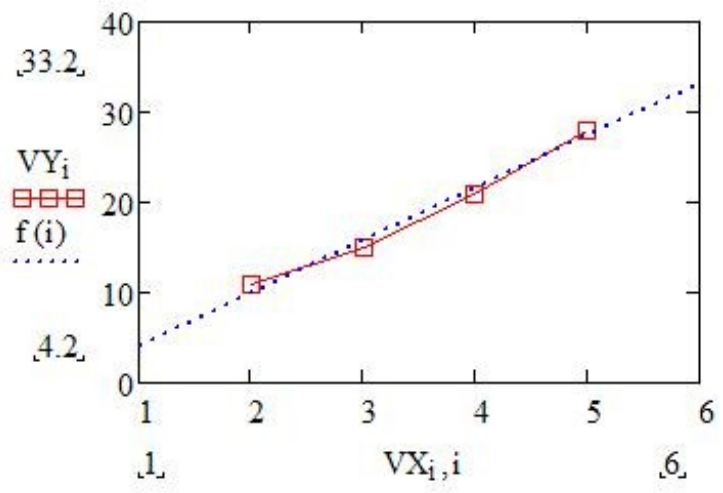

Рисунок 4.2 -Линейная регрессия

5.6 Построение диаграмм с применением вычислительной техники

Понятие о статических графиках. Основные элементы графика

Полученный в результате статистического исследования материал нередко изображается с помощью точек, геометрических линий и фигур или географических картосхем, т.е. графиков.

В статистике графиком называют наглядное изображение статистических величин и их соотношений при помощи геометрических точек, линий, фигур или географических картосхем.

Представление данных в графическом виде позволяет решать самые разнообразные задачи. Основное достоинство такого представления — наглядность. На графиках легко просматривается тенденция к изменению. Можно даже определять скорость изменения тенденции. Различные соотношения, прирост, взаимосвязь различных процессов — все это легко можно увидеть на графиках.

Графики придают изложению статистических данных большую наглядность, чем таблицы, выразительность, облегчают их восприятие и анализ. Статистический график позволяет зрительно оценить характер изучаемого явления, присущие ему закономерности, тенденции развития, взаимосвязи с другими показателями, географическое разрешение изучаемых явлений. Еще в древности китайцы говорили, что одно изображение заменяет тысячу слов. Графики делают статистический материал более понятным, доступным и неспециалистам, привлекают внимание широкой аудитории к статистическим данным, популяризируют статистику и статистическую информацию.

При любой возможности анализ статистических данных рекомендуется всегда начинать с их графического изображения. График позволяет сразу получить общее представление обо всей совокупности статистических показателей. Графический метод анализа выступает как логическое продолжение табличного метода и служит целям получения обобщающих статистических характеристик процессов, свойственных массовым явлениям.

При помощи графического изображения статистических данных решаются многие задачи статистического исследования:

- наглядное представление величины показателей (явлений) в сравнении друг с другом;
- характеристика структуры какого-либо явления;
- изменение явления во времени;
- ход выполнения плана;
- зависимость изменения одного явления от изменения другого;
- распространенность или размещение каких-либо величин по территории.

Другими словами, в статистических исследованиях применяются самые разнообразные графики. В каждом графике выделяют (различают) следующие основные элементы:

- пространственные ориентиры (систему координат);
- графический образ;
- поле графика;
- масштабные ориентиры;
- экспликация графика;
- наименование графика

Иногда п.5 и п.6 объединяют в один элемент.

А) Пространственные ориентиры задаются в виде системы координатных сеток. В статистических графиках чаще всего применяется система прямоугольных координат. Иногда используется принцип полярных (угловых) координат (круговые графики). В картограммах средствами пространственной ориентации являются границы государств, границы административных его частей, географические ориентиры (контуры рек, береговых линий морей и океанов). На осях системы координат или на карте в определенном порядке располагаются характеристики статистических признаков изображаемых явлений или процессов. Признаки, располагаемые на осях координат, могут быть качественными или количественными.

Б) Графический образ статистических данных представляет собой совокупность линий, фигур, точек, образующих геометрические фигуры разной формы (окружность, квадраты, прямоугольники и т.п.) с различной штриховкой, окраской, густотой нанесения точек.

Любое явление, изучаемое статистикой, можно представить в графической форме. Для этого требуется найти правильное графическое решение, определить тот графический образ, который лучше всего соответствует данному явлению, нагляднее изображает статистические данные. Графический образ должен соответствовать цели графика. Поэтому перед построением графика необходимо уяснить сущность явления и цель, которая ставится перед графическим изображением. Выбранная форма графика должна соответствовать внутреннему содержанию и характеру статистического показателя. Например, сравнение на графике производится по таким измерениям, как площадь, длина одной из сторон фигур, местонахождением точек, их густотой и т.д.

Так, для изображения изменений явления во времени наиболее естественным типом графика является линия. Для рядов распределения – полигон или гистограмма.

Каждый из основных видов графических изображений в статистической практике строится с учетом определенных правил. В статистических исследованиях для выяснения характерных черт и особенностей массовых явлений, познания типичного в этих явлениях и решения других задач широко используется сравнение одних абсолютных, средних и относительных статистических величин с другими. Анализ – это, прежде всего сравнение и сопоставление статистических данных. Нередко возникает необходимость сопоставления результатов статистического исследования конкретного явления с величинами типичного (идеального) явления аналогичной природы. Поэтому наглядное представление (графическое изображение) сравнения статистических показателей относится к наиболее распространенным графикам в статистике. Для этих целей применяются диаграммы.

Диаграмма – это графическое изображение, наглядно показывающее соотношение между сравниваемыми величинами. Диаграмма представляет собой чертеж, на котором статистические данные условно изображаются геометрическими линиями, фигурами и телами различных размеров.

Различают следующие основные виды графиков (диаграмм) сравнения:

- столбиковые;
- полосовые;
- квадратные;
- круговые;
- фигурные.

Для построения диаграмм используются следующие компьютерные программы Excel, Mathcad, MATLAB и другие.

Для создания графиков в системе Mathcad имеется программный графический процессор. Основное внимание при его разработке было уделено обеспечению простаты задания графиков и их модификации с помощью соответствующих параметров. Процессор позволяет строить самые разные графики, например в декартовой и полярной системе координат, трехмерные поверхности, графики уровней.

Для построения графиков используются шаблоны. Их перечень содержит подменю Graph меню Insert. Большинство параметров графического процессора, необходимых для построения графиков, по умолчанию задается автоматически, поэтому для начального построения графика того или иного вида достаточно задать тип графика. В подменю Graph содержится список из семи основных типов графиков. Они позволяют выполнить следующие действия:

X – Y Plot (декартов график) – создать шаблон двухмерного графика в декартовой системе координат;

Polar Plot (полярный график) – создать шаблон графика в полярных координатах;

3D Plot Wizard (мастер трехмерных графиков) – вызов Мастера для построения трехмерных графиков с заданными свойствами;

Surface Plot (график поверхности) - создать шаблон для построения трехмерного графика;

Contour Plot (карта линий уровня) – создать шаблон для контурного графика трехмерной поверхности;

3D Scatter Plot (точечный график) – создать шаблон для графика в виде точек (фигур) в трехмерном пространстве;

3D Bar Plot (трехмерная столбиковая диаграмма) – создать шаблон для изображения в виде совокупности столбиков в трехмерном пространстве;

Vector Field Plot (векторное поле) – создать шаблон для графика векторного поля на плоскости.

С понятием графики связано представление о графических объектах, имеющих определенные свойства. В большинстве случаев об объектах можно забыть, если вы не занимаетесь объектно-ориентированным программированием. Большинство команд высокоуровневой графики ориентированы на конечного пользователя. Они автоматически устанавливают свойство графических объектов и обеспечивают воспроизведение графики в нужной системе координат, палитре цветов, масштабе и т.д.

5.7 Построение графика поверхности в системе Mathcad.

Построение поверхностей по матрице аппликат их точек. Поскольку элементы матрицы M – переменные с целочисленными индексами, то перед созданием матрицы требуется задать индексы в виде ранжированных переменных с целочисленными значениями, а затем уже из них формировать сетку значений x и y – координат для аппликат z(x,y). Значения x и y при этом обычно должны быть вещественными числами, нередко как положительными, так и отрицательными. После выполнения указанных выше определений вводится шаблон графика (команда Surface Plot).

Построение Графика Поверхности

$z(x,y) := \cos(x \cdot y)$ Функция двух переменных x,y

$i := 0..20$ $j := 0..20$ Целочисленные индексы

$$M_{i,j} := z\left[\frac{(i-10)}{5}, \frac{(j-10)}{5}\right]$$

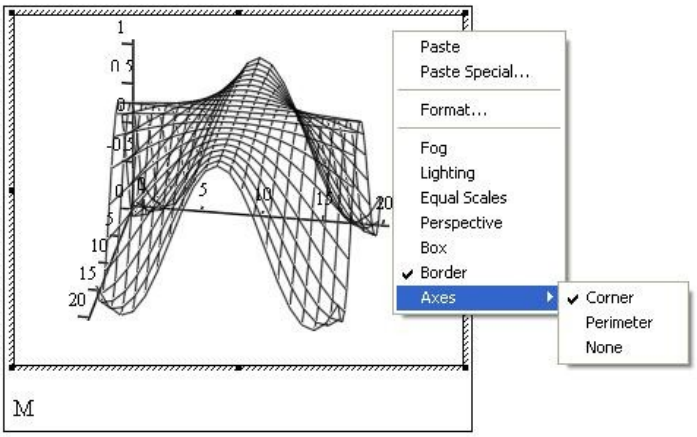

Рисунок 5.1 - Построение поверхности без удаления невидимых линий

Необходимо построить график поверхности в системе Mathcad, отформатировав его, применив алгоритм функциональной окраски и удаление невидимых линий. Показано, как отформатировать график, применение алгоритма функциональной окраски поверхности и удаление невидимых линий.

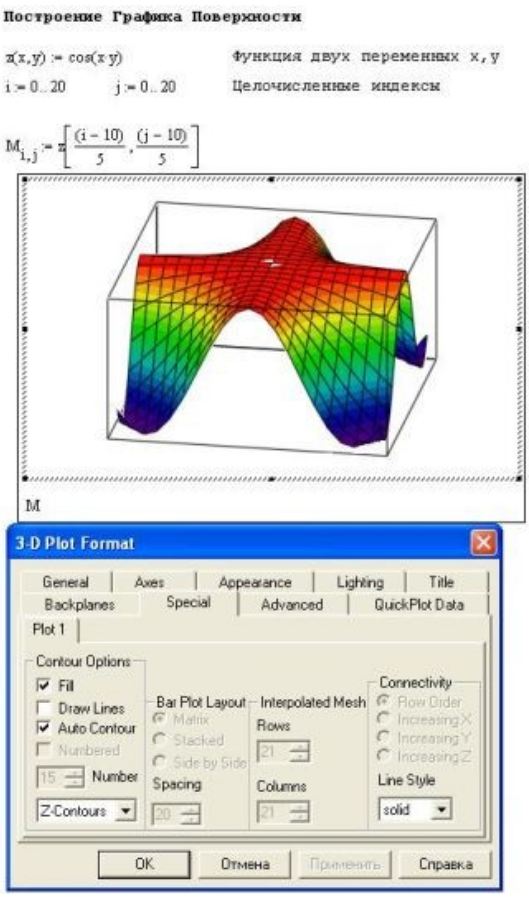

Рисунок 5.2 - Построение графика поверхности в системе Mathcad

Построение трехмерного графика в системе Mathcad

В программе Mathcad есть возможность построения трехмерных графиков – без задания матриц аппликат поверхностей. Единственным недостатком такого упрощенного метода построения поверхностей является неопределенность в масштабировании, поэтому графики требуют форматирования.

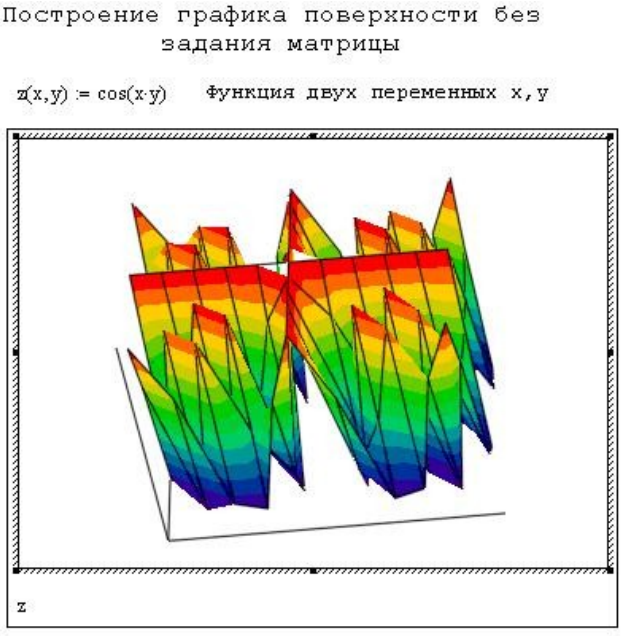

Рисунок 6.1 - Построение графика поверхности без задания матрицы

Применение графической функции CreateMesh

1. Зададим функцию двух переменных

$H(u,v) := \sin(u \cdot v)$

2. Зададим пределы изменения переменных

$u0 := -2 \quad u1 := 2$

$v0 := -2 \quad v1 := 2$

3. Используя функцию CreateMesh создадим матрицу поверхности

$C := \text{CreateMesh}(H,u0,u1,v0,v1)$

4. Задав построение графика типа Surface Plot, получим

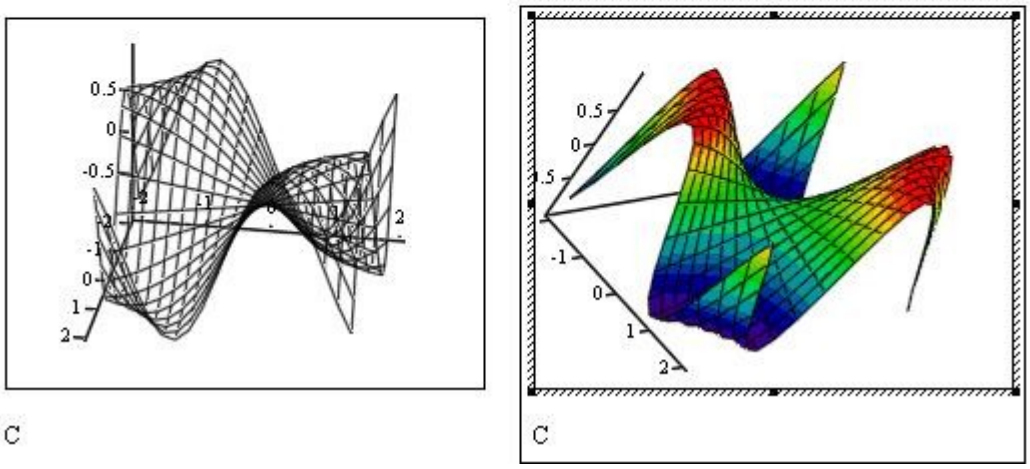

Рисунок 6.2 - Построение графика поверхности с применением функции CreateMesh

Еще один пример применения функции CreateMesh – построение объемной фигуры, которая получается вращением кривой, заданной функцией f(x), вокруг оси X или Y. На рисунке 6.3 показан пример решения данной задачи.

Построение фигуры, полученной вращением кривой вокруг оси X

$f(x) := x \cdot \cos(x^2) \quad a := -2 \quad b := 2 \quad mesh := 30$

$F(u,v) := u \quad G(u,v) := f(u) \cdot \cos(v) \quad H(u,v) := f(u) \cdot \sin(v)$

$S := \text{CreateMesh}(F,G,H,a,b,0,2\pi,mesh)$

График функции f(x)

$x := -2, -1.9 .. 2$

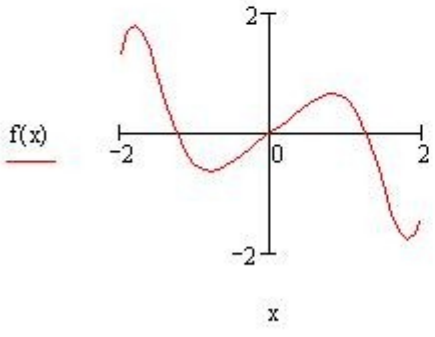

Поверхность вращения графика f(x)

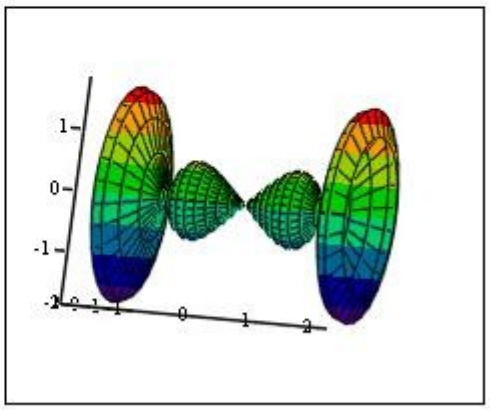

Рисунок 6.3 – Фигура, полученная вращением кривой.

5.8 Применение диаграмм Байеса. Задачи выбора и классификации

Байесовская классификация

Альтернативные названия: байесовское моделирование, байесовская статистика, метод байесовских сетей. Изначально байесовская классификация использовалась для формализации знаний экспертов в экспертных системах, сейчас байесовская классификация также применяется в качестве одного из методов Data Mining.

Так называемая наивная классификация или наивно-байесовский подход (naive-bayes approach) является наиболее простым вариантом метода, использующего байесовские сети. При этом подходе решаются задачи классификации, результатом работы метода являются так называемые "прозрачные" модели.

"Наивная" классификация - достаточно прозрачный и понятный метод классификации. "Наивной" она называется потому, что исходит из предположения о взаимной независимости признаков.

Свойства наивной классификации:

- Использование всех переменных и определение всех зависимостей между ними.
- Наличие двух предположений относительно переменных:
- все переменные являются одинаково важными;
- все переменные являются статистически независимыми, т.е. значение одной переменной ничего не говорит о значении другой.

Большинство других методов классификации предполагают, что перед началом классификации вероятность того, что объект принадлежит тому или иному классу, одинакова; но это не всегда верно.

Допустим, известно, что определенный процент данных принадлежит конкретному классу. Возникает вопрос, можем ли мы использовать эту информацию при построении модели классификации? Существует множество реальных примеров использования этих априорных знаний, помогающих классифицировать объекты. Типичный пример из медицинской практики. Если доктор отправляет результаты анализов пациента на дополнительное исследование, он относит пациента к какому-то определенному классу. Каким образом можно применить эту информацию? Мы можем использовать ее в качестве дополнительных данных при построении классификационной модели.

Отмечают такие достоинства байесовских сетей как метода Data Mining:

- в модели определяются зависимости между всеми переменными, это позволяет легко обрабатывать ситуации, в которых значения некоторых переменных неизвестны;
- байесовские сети достаточно просто интерпретируются и позволяют на этапе прогностического моделирования легко проводить анализ по сценарию "что, если";
- байесовский метод позволяет естественным образом совмещать закономерности, выведенные из данных, и, например, экспертные знания, полученные в явном виде;
- использование байесовских сетей позволяет избежать проблемы переучивания (overfitting), то есть избыточного усложнения модели, что является слабой стороной многих методов (например, деревьев решений и нейронных сетей).

Наивно-байесовский подход имеет следующие недостатки:

- перемножать условные вероятности корректно только тогда, когда все входные переменные действительно статистически независимы; хотя часто данный метод показывает достаточно хорошие результаты при несоблюдении условия статистической независимости, но теоретически такая ситуация должна обрабатываться более сложными методами, основанными на обучении байесовских сетей;
- невозможна непосредственная обработка непрерывных переменных - требуется их преобразование к интервальной шкале, чтобы атрибуты были дискретными; однако такие преобразования иногда могут приводить к потере значимых закономерностей;
- на результат классификации в наивно-байесовском подходе влияют только индивидуальные значения входных переменных, комбинированное влияние пар или троек значений разных атрибутов здесь не учитывается. Это могло бы улучшить качество

классификационной модели с точки зрения ее прогнозирующей точности, однако, увеличило бы количество проверяемых вариантов.

Байесовская классификация нашла широкое применение на практике.

Байесовская фильтрация по словам

Не так давно байесовская классификация была предложена для персональной фильтрации спама. Первый фильтр был разработан Полем Грахемом (Paul Graham). Для работы алгоритма требуется выполнение двух требований.

Первое требование - необходимо, чтобы у классифицируемого объекта присутствовало достаточное количество признаков. Этому идеально удовлетворяют все слова писем пользователя, за исключением совсем коротких и очень редко встречающихся.

Второе требование - постоянное переобучение и пополнение набора "спам - не спам". Такие условия очень хорошо работают в локальных почтовых клиентах, так как поток "не спама" у конечного клиента достаточно постоянен, а если изменяется, то не быстро.

Однако для всех клиентов сервера точно определить поток "не спама" довольно сложно, поскольку одно и то же письмо, являющееся для одного клиента спамом, для другого спамом не является. Словарь получается слишком большим, не существует четкого разделения на спам и "не спам", в результате качество классификации, в данном случае решение задачи фильтрации писем, значительно снижается.

5.9 Методы классификации и прогнозирования. Деревья решений

Метод деревьев решений (decision trees) является одним из наиболее популярных методов решения задач классификации и прогнозирования. Иногда этот метод Data Mining также называют деревьями решающих правил, деревьями классификации и регрессии. Как видно из последнего названия, при помощи данного метода решаются задачи классификации и прогнозирования.

Если зависимая, т.е. целевая переменная принимает дискретные значения, при помощи метода дерева решений решается задача классификации.

Если же зависимая переменная принимает непрерывные значения, то дерево решений устанавливает зависимость этой переменной от независимых переменных, т.е. решает задачу численного прогнозирования.

Впервые деревья решений были предложены Ховилендом и Хантом (Hoveland, Hunt) в конце 50-х годов прошлого века. Самая ранняя и известная работа Ханта и др., в которой излагается суть деревьев решений - "Эксперименты в индукции" ("Experiments inInduction") - была опубликована в 1966 году.

В наиболее простом виде дерево решений - это способ представления правил в иерархической, последовательной структуре. Основа такой структуры - ответы "Да" или "Нет" на ряд вопросов.

На рисунке 8.1 приведен пример дерева решений, задача которого - ответить на вопрос: "Играть ли в гольф?" Чтобы решить задачу, т.е. принять решение, играть ли в гольф, следует отнести текущую ситуацию к одному из известных классов (в данном случае - "играть" или "не играть"). Для этого требуется ответить на ряд вопросов, которые находятся в узлах этого дерева, начиная с его корня.

Первый узел нашего дерева "Солнечно?" является узлом проверки, т.е. условием. При положительном ответе на вопрос осуществляется переход к левой части дерева, называемой левой ветвью, при отрицательном - к правой части дерева. Таким образом, внутренний узел дерева является узлом проверки определенного условия. Далее идет следующий вопрос и т.д., пока не будет достигнут конечный узел дерева, являющийся узлом решения. Для нашего дерева существует два типа конечного узла: "играть" и "не играть" в гольф.

В результате прохождения от корня дерева (иногда называемого корневой вершиной) до его вершины решается задача классификации, т.е. выбирается один из классов - "играть" и "не играть" в гольф.

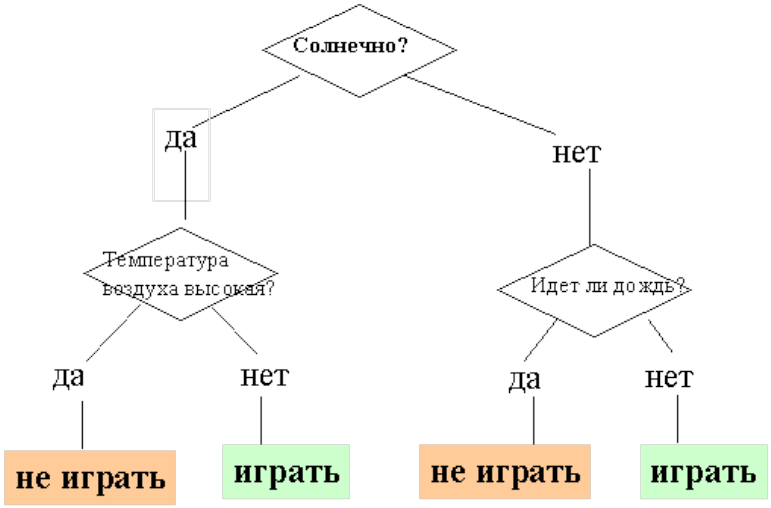

Рисунок 8.1 - Дерево решений "Играть ли в гольф?"

Целью построения дерева решения в нашем случае является определение значения категориальной зависимой переменной.

Итак, для нашей задачи основными элементами дерева решений являются:

- Корень дерева: "Солнечно?"
- Внутренний узел дерева или узел проверки: "Температура воздуха высокая?", "Идет ли дождь?"
- Лист, конечный узел дерева, узел решения или вершина: "Играть", "Не играть"
- Ветвь дерева (случаи ответа): "Да", "Нет".

В рассмотренном примере решается задача бинарной классификации, т.е. создается дихотомическая классификационная модель. Пример демонстрирует работу так называемых бинарных деревьев.

В узлах бинарных деревьев ветвление может вестись только в двух направлениях, т.е. существует возможность только двух ответов на поставленный вопрос ("да" и "нет").

5.10 Построение классификационной модели

Бинарные деревья являются самым простым, частным случаем деревьев решений. В остальных случаях, ответов и, соответственно, ветвей дерева, выходящих из его внутреннего узла, может быть больше двух.

Рассмотрим более сложный пример. База данных, на основе которой должно осуществляться прогнозирование, содержит следующие ретроспективные данные о клиентах банка, являющиеся ее атрибутами: возраст, наличие недвижимости, образование, среднемесячный доход, вернул ли клиент вовремя кредит. Задача состоит в том, чтобы на основании перечисленных выше данных (кроме последнего атрибута) определить, стоит ли выдавать кредит новому клиенту.

Такая задача решается в два этапа: построение классификационной модели и ее использование.

На этапе построения модели, собственно, и строится дерево классификации или создается набор неких правил. На этапе использования модели построенное дерево, или путь от его корня к одной из вершин, являющийся набором правил для конкретного клиента, используется для ответа на поставленный вопрос "Выдавать ли кредит?"

Правилом является логическая конструкция, представленная в виде "если…: то…:".

На рисунке 9.2 приведен пример дерева классификации, с помощью которого решается задача "Выдавать ли кредит клиенту?". Она является типичной задачей классификации, и при помощи деревьев решений получают достаточно хорошие варианты ее решения.

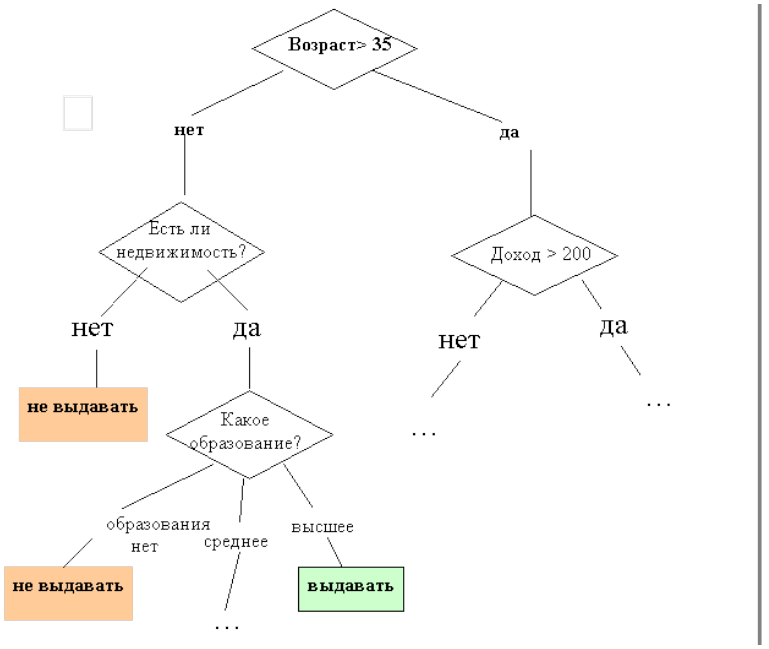

Рис. 9.2. Дерево решений "Выдавать ли кредит?"

Как мы видим, внутренние узлы дерева (возраст, наличие недвижимости, доход и образование) являются атрибутами описанной выше базы данных. Эти атрибуты называют прогнозирующими, или атрибутами расщепления (splitting attribute). Конечные узлы дерева, или листы, именуются метками класса, являющимися значениями зависимой категориальной переменной "выдавать" или "не выдавать" кредит.

Каждая ветвь дерева, идущая от внутреннего узла, отмечена предикатом расщепления. Последний может относиться лишь к одному атрибуту расщепления данного узла. Характерная особенность предикатов расщепления: каждая запись использует уникальный путьот корня дерева только к одному узлу-решению. Объединенная информация об атрибутах расщепления и предикатах расщепления в узле называется критерием расщепления (splitting criterion).

На рисунке 9.1 изображено одно из возможных деревьев решений для рассматриваемой базы данных. Например, критерий расщепления "Какое образование?", мог бы иметь два предиката расщепления и выглядеть иначе: образование "высшее" и "не высшее". Тогда дерево решений имело бы другой вид.

Таким образом, для данной задачи (как и для любой другой) может быть построено множество деревьев решений различного качества, с различной прогнозирующей точностью.

Качество построенного дерева решения весьма зависит от правильного выбора критерия расщепления. Над разработкой и усовершенствованием критериев работают многие исследователи.

Метод деревьев решений часто называют "наивным" подходом [34]. Но благодаря целому ряду преимуществ, данный метод является одним из наиболее популярных для решения задач классификации.

5.11 Преимущества деревьев решений

Интуитивность деревьев решений. Классификационная модель, представленная в виде дерева решений, является интуитивной и упрощает понимание решаемой задачи.

Результат работы алгоритмов конструирования деревьев решений, в отличие, например, от нейронных сетей, представляющих собой "черные ящики", легко интерпретируется пользователем. Это свойство деревьев решений не только важно при отнесении к определенному классу нового объекта, но и полезно при интерпретации модели классификации в целом. Дерево решений позволяет понять и объяснить, почему конкретный объект относится к тому или иному классу.

Деревья решений дают возможность извлекать правила из базы данных на естественном языке. Пример правила: Если Возраст > 35 и Доход > 200, то выдать кредит.

Деревья решений позволяют создавать классификационные модели в тех областях, где аналитику достаточно сложно формализовать знания.

Алгоритм конструирования дерева решений не требует от пользователя выбора входных атрибутов (независимых переменных). На вход алгоритма можно подавать все существующие атрибуты, алгоритм сам выберет наиболее значимые среди них, и только они будут использованы для построения дерева. В сравнении, например, с нейронными сетями, это значительно облегчает пользователю работу, поскольку в нейронных сетях выбор количества входных атрибутов существенно влияет на время обучения.

Точность моделей, созданных при помощи деревьев решений, сопоставима с другими методами построения классификационных моделей (статистические методы, нейронные сети).

Разработан ряд масштабируемых алгоритмов, которые могут быть использованы для построения деревьев решения на сверхбольших базах данных; масштабируемость здесь означает, что с ростом числа примеров или записей базы данных время, затрачиваемое на обучение, т.е. построение деревьев решений, растет линейно. Примеры таких алгоритмов: SLIQ, SPRINT.

Быстрый процесс обучения. На построение классификационных моделей при помощи алгоритмов конструирования деревьев решений требуется значительно меньше времени, чем, например, на обучение нейронных сетей.

Большинство алгоритмов конструирования деревьев решений имеют возможность специальной обработки пропущенных значений.

Многие классические статистические методы, при помощи которых решаются задачи классификации, могут работать только с числовыми данными, в то время как деревья решений работают и с числовыми, и с категориальными типами данных.

Многие статистические методы являются параметрическими, и пользователь должен заранее владеть определенной информацией, например, знать вид модели, иметь гипотезу о виде зависимости между переменными, предполагать, какой вид распределения имеют данные. Деревья решений, в отличие от таких методов, строят непараметрические модели. Таким образом, деревья решений способны решать такие задачи Data Mining, в которых отсутствует априорная информация о виде зависимости между исследуемыми данными.

Процесс конструирования дерева решений

Напомним, что рассматриваемая нами задача классификации относится к стратегии обучения с учителем, иногда называемого индуктивным обучением. В этих случаях все объекты тренировочного набора данных заранее отнесены к одному из предопределенных классов.

Алгоритмы конструирования деревьев решений состоят из этапов "построение" или " создание " дерева (tree building) и "сокращение " дерева (tree pruning). В ходе создания дерева решаются вопросы выбора критерия расщепления и остановки обучения (если это предусмотрено алгоритмом). В ходе этапа сокращения дерева решается вопрос отсечения некоторых его ветвей.

Критерий расщепления

Процесс создания дерева происходит сверху вниз, т.е. является нисходящим. В ходе процесса алгоритм должен найти такойкритерий расщепления, иногда также

называемый критерием разбиения, чтобы разбить множество на подмножества, которые бы ассоциировались с данным узлом проверки. Каждый узел проверки должен быть помечен определенным атрибутом. Существуетправило выбора атрибута: он должен разбивать исходное множество данных таким образом, чтобы объекты подмножеств, получаемых в результате этого разбиения, являлись представителями одного класса или же были максимально приближены к такому разбиению. Последняя фраза означает, что количество объектов из других классов, так называемых "примесей", в каждом классе должно стремиться к минимуму.

Существуют различные критерии расщепления. Наиболее известные - мера энтропии и индекс Gini.

В некоторых методах для выбора атрибута расщепления используется так называемая мера информативности подпространств атрибутов, которая основывается на энтропийном подходе и известна под названием "мера информационного выигрыша" (information gain measure) или мера энтропии.

6. Типовые контрольные задания и иные материалы, характеризующие этапы формирования компетенций

6.1. Критерии оценивания компетенций

Оценка «отлично» выставляется студенту, если студент имеет глубокие знания, умения, навыки, демонстрирует полное понимание сущности рассматриваемых вопросов.

Оценка «хорошо» выставляется студенту, если студент имеет полные знания, умения, навыки, демонстрирует понимание сущности рассматриваемых вопросов в целом, но показывает недостаточно уверенное владение некоторыми теоретическими и практическими положениями дисциплины.

Оценка «удовлетворительно» выставляется студенту, если студент имеет низкий уровень знаний, умений, навыков, демонстрирует частичное понимание сущности рассматриваемых вопросов.

Оценка «неудовлетворительно» выставляется студенту, если студент имеет пробелы в знаниях, умениях, навыках, демонстрирует незнание сущности рассматриваемых вопросов.

6.2. Описание шкалы оценивания

Рейтинговая система оценки успеваемости студентов заочной формы не предусмотрена.

6.3. Методические материалы, определяющие процедуры оценивания знаний, умений, навыков и (или) опыта деятельности, характеризующих этапы формирования компетенций

Процедура проведения оценочных мероприятий включает в себя собеседование, подготовку к экзамену и выполнение индивидуальных заданий к лабораторным работам.

Предлагаемые студенту задания позволяют проверить компетенции ПК-6, ПК-13, ПК-14. Результаты экзамена и отчетов по индивидуальным заданиям оцениваются по:

- точности ответов на поставленные вопросы;
- последовательности и рациональности выполнения заданий;
- знанию технологий, использованных при выполнении задания.

7. Учебно-методическое и информационное обеспечение дисциплины

7.1 Перечень основной и дополнительной литературы, необходимой для освоения дисциплин

7.1.1. Перечень основной литературы

1. Основы компьютерного моделирование [Электронный ресурс] : учебно-методический комплекс / . — Электрон. текстовые данные. — Алматы: Нур-Принт, 2024.—175c. — 9965-756-09-0. — Режим доступа: http://www.iprbookshop.ru/67115.html.

2. Маглинец Ю.А. Анализ требований к автоматизированным информационным системам [Электронный ресурс]/ Маглинец Ю.А.—Электрон. текстовые данные.—

М.: Интернет-Университет Информационных Технологий (ИНТУИТ), 2016.— 191 с.— Режим доступа: http://www.iprbookshop.ru/52184.— ЭБС «IPRbooks», по паролю.

7.1.2. Перечень дополнительной литературы

1. Шорников Ю.В. Инструментальное моделирование гибридных систем [Электронный ресурс]: учебное пособие/ Шорников Ю.В., Томилов И.Н., Достовалов Д.Н.— Электрон.текстовые данные.— Новосибирск: Новосибирский государственный технический университет, 2014.— 70с.—Режим доступа: http://www.iprbookshop.ru/44929.— ЭБС IPRbooks..

2. Клименко И.С. Теория систем и системный анализ [Электронный ресурс]: учебное пособие / И.С. Клименко. — Электрон. текстовые данные. — М.: Российский новый университет, 2014. — 264 c. —Режим доступа: http://www.iprbookshop.ru/21322.html.

7.2. Перечень учебно-методического обеспечения самостоятельной работы обучающихся по дисциплине

1. Методические указания по выполнению лабораторных работ по дисциплине «Системный анализ данных и модели принятия решений».

2. Методические рекомендации для студентов по организации самостоятельной работы по дисциплине «Системный анализ данных и модели принятия решений».

7.3. Перечень ресурсов информационно-телекоммуникационной сети «Интернет», необходимых для освоения дисциплины

1. Университетская библиотека online. http://www.biblioclub.ru.

2. ЭБС «IPRbooks». http://www.iprbookshop.ru.

3. Электронная библиотека СКФУ.. http://catalog.ncstu.ru.

4. Государственная публичная научно- техническая библиотека России. (ГПНТБ России). www.gpntb.ru.

МИНИСТЕРСТВО НАУКИ И ВЫСШЕГО ОБРАЗОВАНИЯ РОССИЙСКОЙ ФЕДЕРАЦИИ
Федеральное государственное автономное образовательное учреждение
высшего образования
«СЕВЕРО-КАВКАЗСКИЙ ФЕДЕРАЛЬНЫЙ УНИВЕРСИТЕТ»
Пятигорский институт (филиал)

МЕТОДИЧЕСКИЕ УКАЗАНИЯ ПО ВЫПОЛНЕНИЮ КОНТРОЛЬНОЙ РАБОТЫ ПО ДИСЦИПЛИНЕ СИСТЕМНЫЙ АНАЛИЗ ДАННЫХ И МОДЕЛИ ПРИНЯТИЯ РЕШЕНИЙ

Направление подготовки	**09.04.02 Информационные системы и технологии**
Направленность (профиль)	**«Технологии работы с данными и знаниями, анализ информации»**
Квалификация выпускника	Магистр

Пятигорск, 2024

СОДЕРЖАНИЕ

Введение

Методические указания содержат перечень вариантов заданий для контрольных работ, требования к оформлению контрольных работ и пример выполнения задания. Теоретической основой подготовки специалиста являются знания в области информатики, вычислительной систем.

1. Цель и задачи освоения дисциплины

Целью освоения дисциплины «Системный анализ данных и модели принятия решений» является формирование набора профессиональных компетенций будущего магистра по направлению подготовки 09.04.02 «Информационные системы и технологии» для решения прикладных задач в рамках направления (профиля) «Технологии работы с данными и знаниями, анализ информации».

Задачи освоения дисциплины: изучение основных понятий системного анализа данных, освоение методов системного анализа и инструментов разработки моделей принятия решений.

2. Формулировка задания и его объем

Контрольная работа включат в себе вопросы по темам, которые нужно изучить самостоятельно и по ним подготовить отчет и презентации. Результаты выполнения контрольной работы предоставляются в электронном виде. Объем контрольной работы составляет 10-15 печатных листов формата А4.

Варианты задании выбираются из таблицы по последним двум цифрам зачетной книжки.

Послед цифра	Предпоследняя цифра									
	0	1	2	3	4	5	6	7	8	9
0	1,11	2,12	3,13	4,14	5,15	6,16	7,17	8,18	9,19	10,21
1	11,22	12,23	13,24	14,25	15,26	16,27	17,27	18,28	19,29	20,30
2	1,30	2,29	3,28	4,27	5,26	6,25	7,24	8,23	9,22	10,21
3	11,29	12,28	13,27	14,26	15,25	16,24	17,23	18,22	19, 21	20,10
4	19,31	18, 32	17, 33	16,34	15,35	14,18	13,19	12,20	11,21	10,22
5	9,35	8,34	7,33	6,32	5,31	4,30	3,29	2,28	1,27	30,26
6	30,11	29,10	28,9	27,8	26,7	25,6	24,5	23,4	22,3	21, 2
7	20,31	19, 30	18,29	17,28	16,27	15,26	14,25	13,24	12,23	11,22
8	10,29	9,31	8,33	7,35	6,25	5,23	4,21	3,19	2,17	1,15
9	1, 20	2,26	3,24	4,23	5,22	8,20	9,18	11,17	8,30	7, 31

Варианты заданий

1.Способы определения коэффициентов относительной значимости критериев (весов критериев).

2. Способы определения коэффициентов компетентности экспертов.

3. Способы определения вероятностей появления проблемных ситуаций.

4. Подходы к моделированию проблемных ситуаций.

5. Особенности использования количественных шкал для задания оценок предпочтения экспертов.

6. Особенности использования порядковых шкал для задания оценок предпочтения экспертов.

7. Отличительные черты систем поддержки принятия решений.

8. Влияние информационных технологий на развитие систем поддержки принятия решений.

9. Развитие экспертной оболочки ЭСППР.

10. Расширение числа вопросов, включаемых в ЭСППР.

11. Расширение числа ответов, включаемых в ЭСППР.

12. Расширение числа методов принятия решения, включаемых в ЭСППР.

13. Описание алгоритмов методов, которые предлагается включить в ЭСППР, на языке Системы.

14. Описание правил решения выбора новых методов.

15. Подходы к разработке альтернатив принятия решения.

16. Виды неопределенности в процессе принятия решения.

17. Моделирование последствий принятия решения.

18. Отличия сравнимых и несравнимых критериев.

19. Различные подходы к классификации методов принятия решения.

20. Экспертные оценки в процессе принятия решения.

21. Выбор шкалы задания оценок альтернатив в процессе принятия решения.

22. Принципы согласования оценок альтернатив в процессе принятия решения.

23. Аналитический обзор существующих систем поддержки принятия решения.

24. Аналитический обзор существующих экспертных систем.

25. Аналитический обзор используемых методов принятия решения.

26. Аксиомы рационального поведения. Парадокс Алле. Эвристики, используемые людьми при принятии решений.

27. Пространство Эджворта-Парето.

28. Классификация операций по степени сложности. Операции с критериями, с оценками альтернатив, с альтернативами.

29. Формирование набора критериев. Оценка важности критериев.

30. Многокритериальные задачи. Попытки снятия многокритериальности.

31. Методы векторной оптимизации. Метод STEM.

32. Методы векторной оптимизации. Методы, основанные на информации о мерах замещения.

33. Понятие нечеткого множества. Функция принадлежности. Нечеткие выводы.

34 Лингвистические переменные. Методы определения значений нечетких пременных.

35. Задача о назначениях. Постановка, принцип решения.

Методические рекомендации к выполнению контрольной работы

Алгоритмы анализа данных

Упрощенный алгоритм Байеса. Деревья решений. Линейная регрессия

Упрощенный алгоритм Байеса (NaiveBayes)

Упрощенный алгоритм Байеса - это алгоритм классификации, основанный на вычислении условной вероятности значений прогнозируемых атрибутов. При этом и предполагается, что входные атрибуты являются независимыми и определен хотя бы один выходной атрибут.

Алгоритм основан на использовании формулы Байеса. Пусть $A_1, A_2, \cdots$ - полная группа несовместных событий, а B - некоторое событие, вероятность которого положительна. Тогда условная вероятность события A_i, если в результате эксперимента наблюдалось событие B, может быть вычислена по формуле:

$$P(A_i|B) = \frac{P(B|A_i)P(A_i)}{\sum_j P(B|A_j)P(A_j)} \qquad (1.1)$$

Если говорить о СУБД MS SQLServer 2008, то там описание модели интеллектуального анализа хранится в виде иерархии узлов. Для упрощенного алгоритма Байеса иерархия имеет 4 уровня. Среда разработки BIDevStudio позволяет просмотреть содержимое модели (рисунок 3.1). На верхнем уровне иерархии находится узел самой модели. Самый нижний уровень содержит информацию о том, с какой частотой встречались в обучающей выборке различные значения выходного параметра в сочетании с указанным значением выбранного входного параметра (рисунок 1.1).

Для корректного использования упрощенного алгоритма Байеса необходимо учитывать что:

- входные атрибуты должны быть взаимно независимыми;
- атрибуты могут быть только дискретными или дискретизированными (в процессе дискретизации множество значений непрерывного числового атрибута разбивается на интервалы и дальше идет работа с номером интервала);
- алгоритм требует меньшего количества вычислений, чем другие алгоритмы интеллектуального анализа, представляемые Microsoft SQLServer 2008, поэтому он часто используется для первоначального исследования данных. По той же причине, данный алгоритм предпочтителен для анализа больших наборов данных с большим числом входных атрибутов.

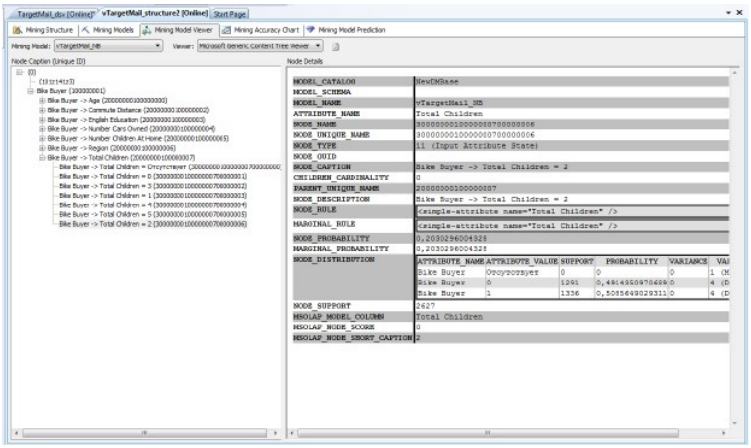

Рисунок 1.1. - Просмотр модели на базе упрощенного алгоритма Байеса средствами BIDevStudio

Для корректного использования упрощенного алгоритма Байеса необходимо учитывать что:

- входные атрибуты должны быть взаимно независимыми;
- атрибуты могут быть только дискретными или дискретизированными (в процессе дискретизации множество значений непрерывного числового атрибута разбивается на интервалы и дальше идет работа с номером интервала);

- алгоритм требует меньшего количества вычислений, чем другие алгоритмы интеллектуального анализа, представляемые Microsoft SQLServer 2008, поэтому он часто используется для первоначального исследования данных. По той же причине, данный алгоритм предпочтителен для анализа больших наборов данных с большим числом входных атрибутов.

Деревья решений (DecisionTrees)

Деревья решений (или деревья принятия решений, англ. "DecisionTrees") - семейство алгоритмов, позволяющих сформировать правила классификации в виде иерархической (древовидной структуры). В ряде случаев, деревья решений позволяют также решать задачи регрессии и поиска взаимосвязей.

Решение задачи классификации заключается в определении значения категориального (дискретного) выходного атрибута на основании входных данных. Для этого сначала производится оценка степени корреляции входных и выходных значений, после чего обнаруженные зависимости описываются в виде узлов дерева.

Рассмотрим следующий пример. Пусть в обучающей выборке имеется информация о том, купил клиент велосипед или нет (прогнозируемое значение), а также о возрасте клиентов. На рисунке 1.2a приведена гистограмма, показывающая зависимость прогнозируемого атрибута "Покупатель велосипеда" от входного "Возраст" (будем считать, что возраст имеет три значения "Младший", "Средний", "Старший"). Гистограмма 1.2b показывает, как эти данные могут использоваться при построении дерева решений.

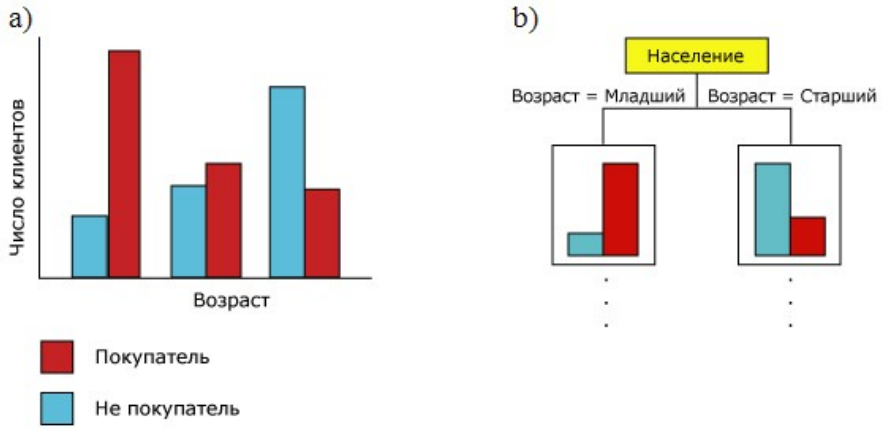

Рисунок 1.2 - Пример построения узла дерева решений для дискретного атрибута

По-другому алгоритм работает при построении дерева для прогнозирования непрерывного столбца. В этом случае, каждый узел содержит регрессионную формулу, а разбиение осуществляется в точке нелинейности в этой формуле. Данный подход показан на рисунке 1.3. Пусть наиболее точно имеющиеся данные можно моделировать двумя соединенными линиями (рисунок 1.3a). Дерево решений в этом случае строится так, как показано на рисунке 1.3b).

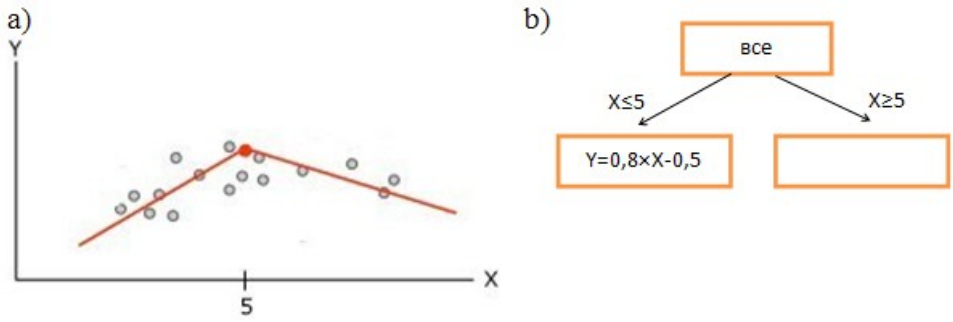

Рисунок 1.3. Построение дерева решений для непрерывного прогнозируемого атрибута

В случае Microsoft SQLServer, для того, чтобы можно было получить функцию линейной регрессии, в набор стандартных алгоритмов, начиная с версии SQLServer 2005, был включен алгоритм линейной регрессии (MicrosoftLinearRegression) о котором речь пойдет ниже.

При решении задачи классификации, пройдя от корневого узла до конечного ("листа"), мы получаем результат.

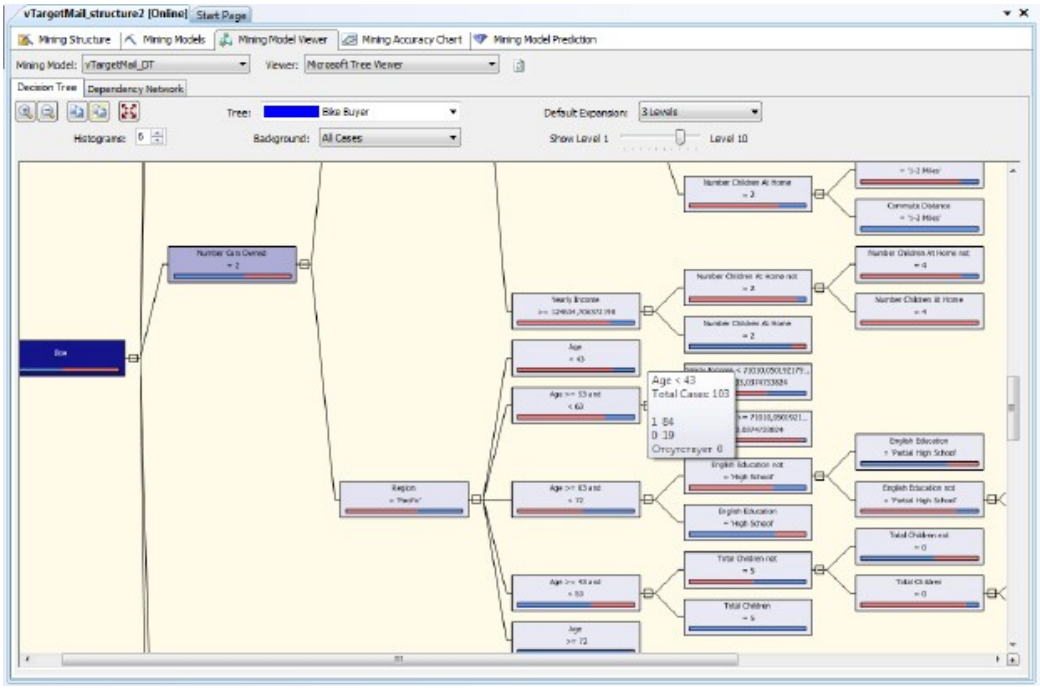

Рисунок 1.4 -Фрагмент диаграммы дерева решений

Несомненным достоинством деревьев решений является их интуитивная понятность. В частности, описанные деревом зависимости можно легко перевести в правила "если-то". Например, по представленному на рисунке 3.4 фрагменту диаграммы можно составить правила следующего вида: "Если клиент владеет двумя машинами, проживает в регионе "Pacific" (Тихоокеанский) и моложе 43 лет, то он с высокой вероятностью приобретет велосипед".

При построении дерева решений важно добиться того, чтобы модель корректно отображала особенности предметной области и в то же время не содержала неоправданно большого числа ветвей. Слишком "ветвистое" дерево может отлично классифицировать данные из обучающего набора, но иметь невысокую точность прогнозирования для новых данных. Это явление называется "переобучением". Для борьбы с ним используется остановка при достижении определенных пороговых показателей (например, по объему данных, поддерживающих разбиение) и процедура "обрезки" дерева, в результате которой некоторые ветви объединяются или удаляются.

Линейная регрессия

Алгоритм линейной регрессии позволяет представить зависимость между зависимой и независимой переменными как линейную, а затем использовать полученный результат при прогнозировании. Подобный пример представлен на рисунке 1.5. Линия на диаграмме является наилучшим линейным представлением данных.

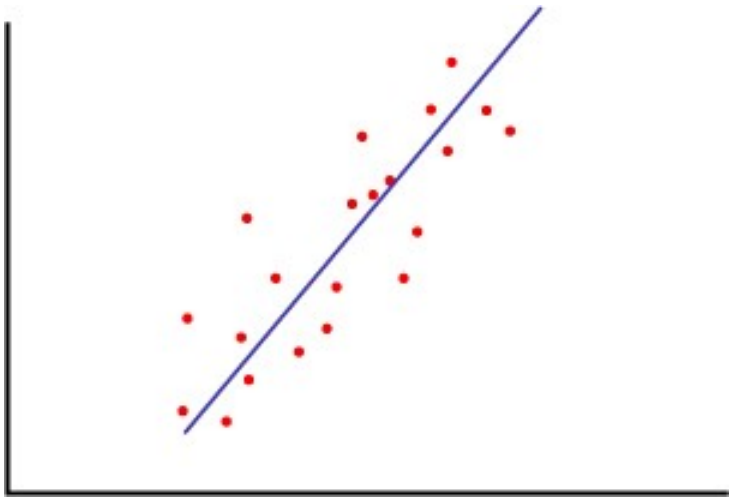

Рисунок 1.5. Пример использования линейной регрессии

В случае одной независимой переменной (одним регрессором) задача может быть сформулирована следующим образом. Уравнение описывающее линию: $y = a + bx$. Для i-й точки будет справедливо $Y_i = a + bx_i + e_i$, где e_i - разница между фактическим значением Y_i и вычисленным в соответствии уравнением линии. Иначе говоря, каждой точке соответствует ошибка, связанная с ее расстоянием от линии регрессии. Нужно с помощью подбора коэффициентов a и b получать такое уравнение, чтобы сумма ошибок, связанных со всеми точками, стала минимальной. Для решения этой задачи может использоваться, в частности, метод наименьших квадратов.

В SQLServer 2008 при выборе алгоритма линейной регрессии вызывается особый вариант алгоритма дерева решений с параметрами, которые ограничивают поведение алгоритма и требуют использования определенных типов данных на входе.

Линейная регрессия является полезным и широко известным методом моделирования, особенно для случаев, когда известен приводящий к изменениям базовый фактор и есть основания ожидать линейный характер зависимости. Существуют также и другие типы регрессии, в том числе - нелинейные.

Анализ временных рядов

В общем случае, временной ряд - это набор числовых значений, собранных в последовательные моменты времени (в большинстве случаев - через равные промежутки времени). В качестве примера можно назвать котировки иностранных валют или других биржевых товаров, результаты серии экспериментов и т.п. Целью анализа временного ряда может быть выявление имеющихся зависимостей текущих значений параметров от предшествующих и последующее их использование для прогнозирования новых значений.

Фактические значения элементов ряда используются для обучения модели, после чего делается попытка прогноза для указанного числа новых элементов. Пример подобного анализа представлен на рисунке 1.6, где пунктирной линией изображены предсказываемые значения.

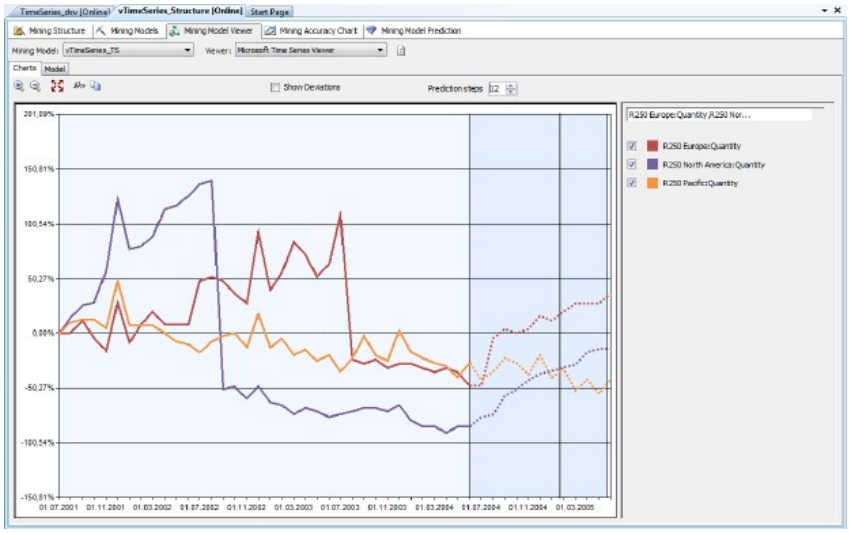

Рисунок 1.6 - Графики с историческими и прогнозируемыми значениями ряда

Рассмотрим теперь некоторые особенности реализации алгоритма в SQLServer. Алгоритм временных рядов Майкрософт (MicrosoftTimeSeries) предоставляет собой совокупность двух алгоритмов регрессии, оптимизированных для прогноза рядов непрерывных числовых значений. Этими алгоритмами являются:

- "дерево авторегрессии с перекрестным прогнозированием" (ARTxp), который оптимизирован для прогнозирования следующего значения в ряду, появился в SQL Server 2005;

- "интегрированные скользящие средние авторегрессии" (ARIMA), являющийся отраслевым стандартом в данной области; добавлен в SQL Server, чтобы повысить точность долгосрочного прогнозирования.

По умолчанию службы AnalysisServices используют каждый алгоритм отдельно для обучения модели, а затем объединяют результаты, чтобы получить самый лучший прогноз. Также можно выбрать для использования только один алгоритм, в зависимости от имеющихся данных и требований к прогнозам.

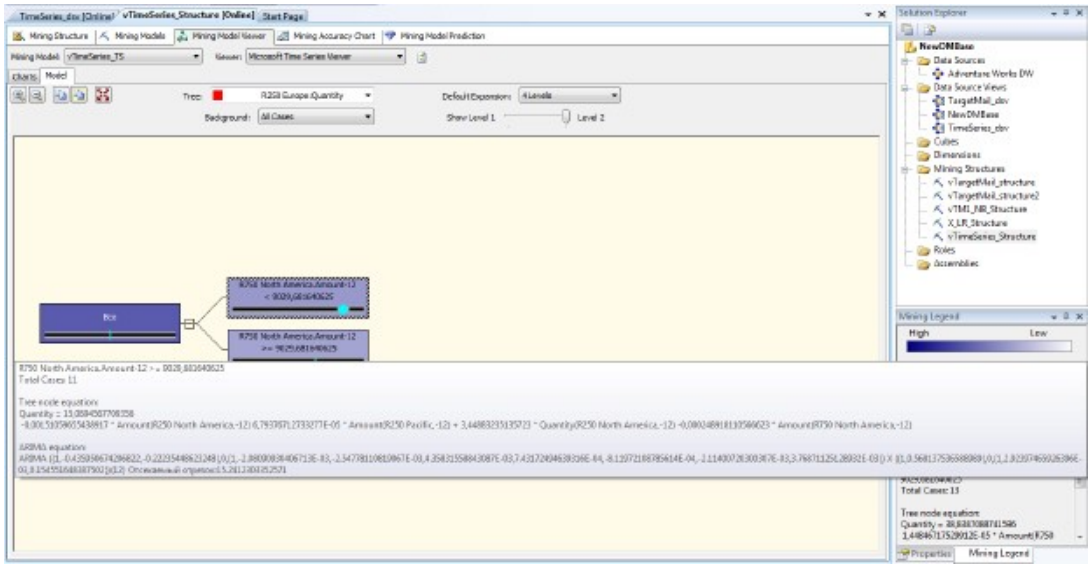

Рисунок 1.7. - Просмотр параметров модели

На рисунке 1.7 представлены параметры для одного из узлов прогнозирующей модели, основанной на алгоритме временных рядов. Из рисунка видно, что узел на самом деле содержит параметры для двух алгоритмов. Также у рассматриваемого временного

ряда 'R250 Europe: Quantity' (количество проданных в Европе велосипедов марки R250) обнаружена корреляция с другим рядом 'R750 NorthAmerica: Amount' (продажи в Северной Америке велосипедов марки R750).

Учет корреляций между рассматриваемыми рядами или, иначе говоря, перекрестного влияния, можно отметить в качестве особенности реализации алгоритма временных рядов в SQLServer. Это может быть важно, если одновременно анализируются связанные ряды, например, описывающие цены на нефть и котировки валют нефтедобывающих стран. Данную полезную возможность поддерживает только алгоритм ARTxp. Если для прогноза используется только алгоритм ARIMA, перекрестное влияние рядов не учитывается.

Точность прогноза для временного ряда может повысить указание известной периодичности. Например, в данных о продажах магазина спорттоваров по месяцам, скорее всего, будет присутствовать периодичность 12 (по числу месяцев в году).

Кластеризация

Как мы уже разбирали ранее, кластеризация позволяет снизить размерность задачи анализа предметной области, путем "естественной" группировки вариантов в кластеры. Таким образом, кластер будут объединять близкие по совокупности параметров элементы, и в некоторых случаях его можно рассматривать как единое целое. Например, описывая какой-то курортный регион можно сказать в нем 250 дней в году хорошая погода, не вдаваясь в подробности относительно температуры, атмосферного давления и т.д.

В случаях, когда для группировки используются значения 1-2 параметров, задача кластеризации может быть относительно быстро решена вручную или, например, обычными средствами работы с реляционными БД. Когда параметров много, возникает потребность в автоматизации процесса выявления кластеров.

Предоставляемый аналитическими службами SQL Server 2008 алгоритм кластеризации (MicrosoftClustering), использует итерационные методы для группировки вариантов со сходными характеристиками в кластеры. Алгоритм сначала определяет имеющиеся связи в наборе данных и на основе этой информации формирует кластеры.

Идею можно проиллюстрировать с помощью диаграмм на рисунке 1.8. На первом этапе (рисунок 1.8a) имеется множество вариантов, далее (рисунок 1.8b) идет итерационный процесс формирования кластеров, и в итоге относительно небольшой набор кластеров, которым можно задать идентификаторы и продолжить анализ.

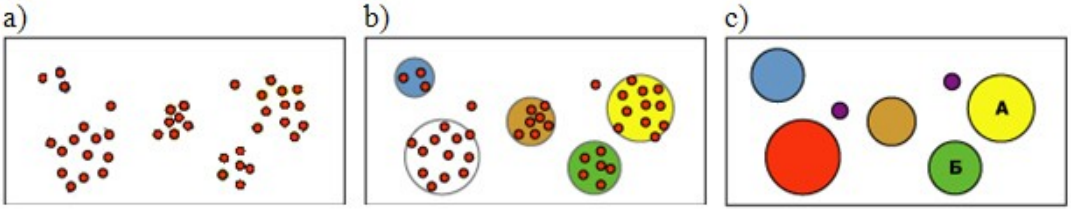

Рисунок 1.8. - Переход от отдельных вариантов к кластерам

Алгоритм взаимосвязей

Алгоритм взаимосвязей или ассоциативных правил (AssociationRules) позволяет выявить часто встречающиеся сочетания элементов данных и использовать обнаруженные закономерности для построения прогноза. Классический пример - это анализ покупательской корзины, когда проводится поиск товаров, наиболее часто встречающихся в одном заказе (чеке, транзакции), после чего, на основе выявленных закономерностей становится возможной выдача рекомендаций. Пример набора правил, формируемых подобным, алгоритмом приведен на рисунке 1.9. Предметная область - торговля велосипедами и связанными спортивными товарами. Для примера, первое

правило говорит о том, что если в заказе присутствует держатель для велосипедной фляги и кепка, с высокой вероятностью будет приобретена и сама фляга.

Правило
Road Bottle Cage = Existing, Cycling Cap = Existing -> Water Bottle = Existing
Mountain-200 = Existing, Mountain Tire Tube = Existing -> HL Mountain Tire = Existing
Mountain-200 = Existing, Water Bottle = Existing -> Mountain Bottle Cage = Existing
Touring-1000 = Existing, Water Bottle = Existing -> Road Bottle Cage = Existing
Road-750 = Existing, Water Bottle = Existing -> Road Bottle Cage = Existing
Touring Tire = Existing, Sport-100 = Existing -> Touring Tire Tube = Existing

Рисунок 1.9 -Пример набора правил, формируемых алгоритмом AssociationRules

Когда подобный набор правил сформирован, его можно использовать, например, для формирования рекомендаций. Скажем, покупателю держателя фляги и кепки, предложат обратить внимание и на имеющиеся фляги. Вопрос заключается в том, как сформировать подобные правила.

Для выявления часто встречающихся наборов объектов может использоваться алгоритм Apriori, реализация которого лежит в основе и Microsoft Association Rules, использующегося в SQLServer. Алгоритм Apriori последовательно выделяет часто встречающиеся одно-, двух- и т.д., n-элементные наборы. На i-м этапе выделяются i-элементные наборы. Причем сначала выполняется формирование наборов-кандидатов, после чего для них рассчитывается поддержка.

Алгоритмы нейронных сетей

Некоторые задачи интеллектуального анализа данных, в частности, задача классификации, могут решаться с помощью различных алгоритмов. В случае наличия в данных сложных зависимостей между атрибутами, "быстрые" алгоритмы интеллектуального анализа, такие как упрощённый алгоритм Байеса, могут давать недостаточно точный результат. Улучшить ситуацию может применение нейросетевых алгоритмов.

Нейронные сети - это класс моделей, построенных по аналогии с работой человеческого мозга. Существуют различные типы сетей, в частности, в SQLServer алгоритм нейронной сети использует сеть в виде многослойного перцептрона, в состав которой может входить до трех слоев нейронов, или перцептронов. Такими слоями являются входной слой, необязательный скрытый слой и выходной слой (рисунок 1.10).

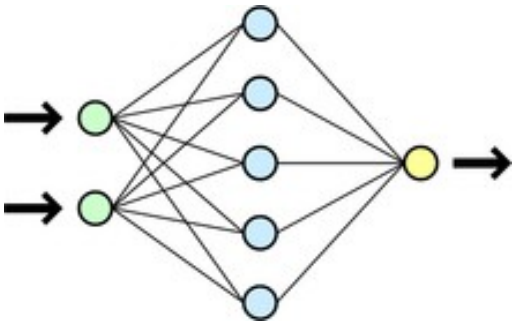

Рисунок 1.10 - Пример схемы нейронной сети: входной слой - зеленые узлы, скрытый слой - голубые, выходной – желтый

Каждый нейрон получает одно или несколько входных значений (входов)и создает выходное значение (один или несколько одинаковых выходов). Каждый выход является простой нелинейной функцией суммы входов, полученных нейроном. Входы передаются

в прямом направлении от узлов во входном слое к узлам в скрытом слое, а оттуда передаются на выходной слой. Нейроны в составе слоя не соединены друг с другом. Скрытый слой может отсутствовать (в частности, это используется алгоритмом логистической регрессии).

Имеющий более двух состояний дискретный входной атрибут модели интеллектуального анализа приводит к созданию одного входного нейрона для каждого состояния и одного входного нейрона для отсутствующего состояния (если обучающие данные содержат какие-либо значения NULL). Непрерывный входной атрибут "создает" два входных нейрона: один нейрон для отсутствующего состояния и один нейрон для значения самого непрерывного атрибута. Входные нейроны обеспечивают входы для одного или нескольких скрытых нейронов.

Выходные нейроны представляют значения прогнозируемых атрибутов для модели интеллектуального анализа данных. Дискретный прогнозируемый атрибут, имеющий более двух состояний, "создает" один выходной нейрон для каждого состояния и один выходной нейрон для отсутствующего или существующего состояния. Непрерывные прогнозируемые столбцы "создают" два выходных нейрона: один нейрон для отсутствующего или существующего состояния и один нейрон для значения самого непрерывного столбца.

Нейрон получает входы от других нейронов или из других данных, в зависимости от того, в каком слое сети он находится. Входной нейрон получает входы от исходных данных. Скрытые нейроны и выходные нейроны получают входы из выхода других нейронов нейронной сети. Входы устанавливают связи между нейронами, и эти связи являются путем, по которому производится анализ для конкретного набора вариантов.

Системы поддержки принятия решений

Понятие и архитектура системы поддержки принятия решений

К настоящему времени во многих организациях накоплены значительные объемы данных, на основе которых имеется возможность решения разнообразных аналитических и управленческих задач. Проблемы хранения и обработки аналитической информации становятся все более актуальными и привлекают внимание специалистов и фирм, работающих в области информационных технологий, что привело к формированию полноценного рынка технологий бизнес-анализа.

В идеале работа аналитиков и руководителей различных уровней должна быть организована так, чтобы они могли иметь доступ ко всей интересующей их информации и пользоваться удобными и простыми средствами представления и работы с этой информацией. Именно на достижение этих целей и направлены информационные технологии, объединяющиеся под общим названием хранилищ данных и бизнес-анализа.

В соответствии с определением Gartner, бизнес-анализ (BI, Business Intelligence) - это категория приложений и технологий для сбора, хранения, анализа и публикации данных, позволяющая корпоративным пользователям принимать лучшие решения. В русскоязычной терминологии подобные системы называются также системами поддержки принятия решений (СППР).

Сбор и хранение информации, а также решение задач информационно-поискового запроса эффективно реализуются средствами систем управления базами данных (СУБД). В OLTP (Online Transaction Processing)-подсистемах реализуется транзакционная обработка данных. Непосредственно OLTP-системы не подходят для полноценного анализа информации в силу противоречивости требований, предъявляемых к OLTP-системам и СППР.

Для предоставления необходимой для принятия решений информации обычно приходится собирать данные из нескольких транзакционных баз данных различной

структуры и содержания. Основная проблема при этом состоит в несогласованности и противоречивости этих баз-источников, отсутствии единого логического взгляда на корпоративные данные.

Поэтому для объединения в одной системе OLTP и СППР для реализации подсистемы хранения используются концепция хранилищ данных (ХД). В основе концепции ХД лежит идея разделения данных, используемых для оперативной обработки и для решения задач анализа, что позволяет оптимизировать структуры хранения. ХД позволяет интегрировать ранее разъединенные детализированные данные, содержащиеся в исторических архивах, накапливаемых в традиционных OLTP-системах, поступающих из внешних источников, в единую базу данных, осуществляя их предварительное согласование и, возможно, агрегацию.

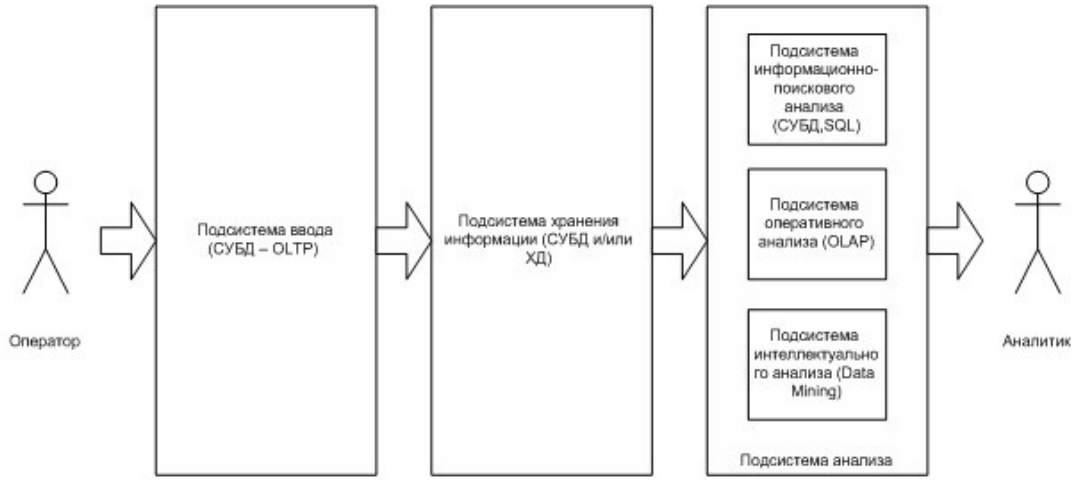

Рисунок 1.11 -Архитектура СППР

Подсистема анализа может быть построена на основе:

- подсистемы информационно-поискового анализа на базе реляционных СУБД и статических запросов с использованием языка SQL;
- подсистемы оперативного анализа. Для реализации таких подсистем применяется технология оперативной аналитической обработки данных OLAP, использующая концепцию многомерного представления данных;
- подсистемы интеллектуального анализа, реализующие методы и алгоритмы Data Mining.

Основные сведения о системах поддержки принятия решений

В 1980-е годы американские и японские компании начали развивать информационные системы, которые разительно отличались от MIS. Эти системы положили начало процессу "интеллектуализации" ИС. Новые системы были меньшими, интерактивными, и их целью было помочь конечным пользователям работать со всеми типами данных, проводить аналитические исследования, строить модели и разыгрывать сценарии для решения слабоструктурированных и вообще неструктурированных проблем в инновационных проектах. Системы, предоставляющие такие возможности, называются системами поддержки принятия решений - СППР (Decision Support System - DSS) [Turban E., http://www.abc.org.ru/smd.html].

В середине 1980-х такие системы стали использоваться в текущей деятельности крупных компаний и корпораций. В настоящее время DSS является обязательной частью корпоративных ИС (КИС) (рисунок 1.12).

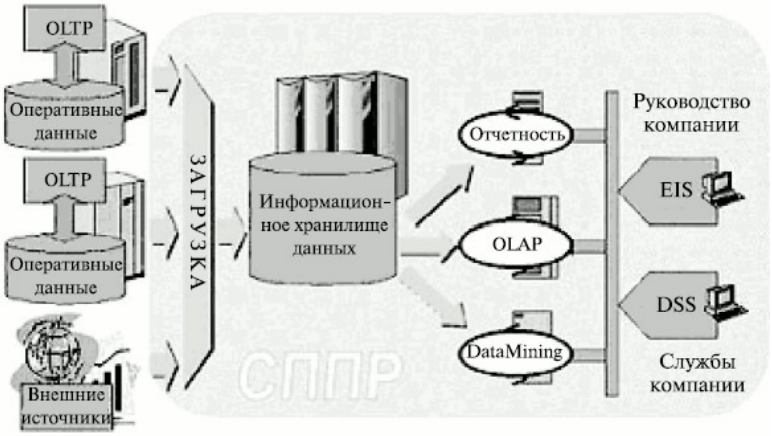

Рисунок 1.12 -Система поддержки принятия решения как составная часть КИС

Данные, приведенные в таблице 1.1, показывают различия между системами MIS и DSS.

Таблица 1.1 - Различия между системами MIS и DSS

Параметр	MIS	DSS
Концепция	Обеспечивает формализованные и частично формализованные данные для принятия структурированных решений	Обеспечивает интегрированные инструментальные средства, многомерные разнородные данные, динамические модели и язык интерпретации
Системный анализ	Выделяет информационные требования в соответствии с установленными правилами	Формирует порядок применения инструментальных средств и динамических правил в процессе работы
Проект	Поставляет информацию, основанную на утвержденных требованиях	Итеративный процесс добавления новых данных и информации, вытекающий из динамики среды
Источник данных	Внутренняя и частично внешняя среда	Внешняя и внутренняя среда
Пользователи	Менеджеры эксплуатационного и управленческого уровней	Высшее руководство, менеджеры департаментов, ИТ-служб, управленческого уровня, аналитики

Приведем основные характеристики систем поддержки принятия решения:

- предлагают гибкость использования, адаптируемость и быструю реакцию;
- допускают управление входом и выходом;
- работают практически без участия профессиональных программистов;
- обеспечивают информационную поддержку для решений проблем, которые не могут быть определены заранее;
- применяют сложный многомерный и многофакторный анализ и инструментальные средства моделирования.

Хорошо разработанные DSS применяются на многих уровнях предприятия. Руководители компании и ведущие менеджеры могут пользоваться финансовыми модулями DSS, чтобы предсказать эффективность использования активов компании при изменении деловой активности или экономической ситуации в стране. Менеджерам среднего звена та же система может быть полезной для оценки перспективности краткосрочных инвестиций по выполняемым проектам. Для руководителей проектов - это

инструмент для финансового планирования и распределения средств по планируемым закупкам.

DSS состоят из трех компонент: программного ядра и хранилища данных, аналитических средств обработки, анализа и представления информации, телекоммуникационных устройств.

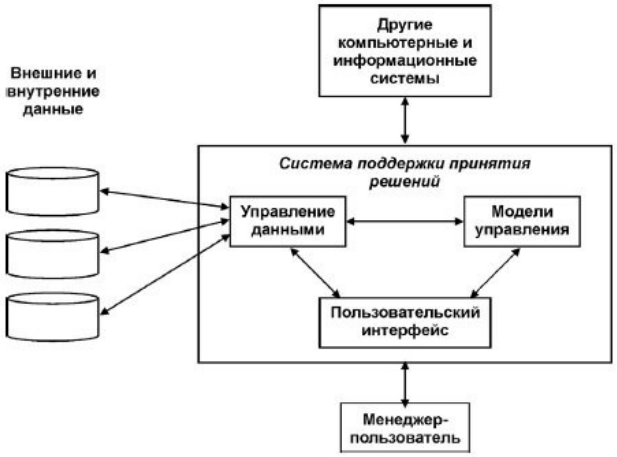

Рисунок 1.13 - Основные компоненты системы поддержки принятия решения

Хранилище данных предоставляет единую среду хранения корпоративных данных, организованных в структуры и оптимизированных для выполнения аналитических операций.

Аналитические средства позволяют конечному пользователю, не имеющему специальных знаний в области информационных технологий, осуществлять навигацию и представление данных в терминах предметной области. Для пользователей различной квалификации DSSрасполагают различными типами интерфейсов доступа к своим сервисам (рисунок 1.13).

Аналитические системы позволяют решать три основных задачи: анализ разнородной многомерной информации разной степени формализованности в реальном времени, последующий интеллектуальный анализ данных с построением моделей развития деловой ситуации и ведение отчетности.

Процесс принятия делового решения (рисунок 1.14) отличается от аналогичного процесса в научной или социальной сфере тем, что преобразование рабочей гипотезы в решение осложняется двумя объективно существующими проблемами.

Рисунок 1.14. -Итерационный процесс принятия решения

Первая из них состоит в том, что накопление личного опыта в ходе повседневной деятельности у бизнесменов отстает от динамичного изменения экономической ситуации - что особенно характерно для современной России. Вторая проблема заключается в том, что впредпринимательской деятельности - да еще в условиях свободного рынка - практически отсутствует возможность проведения целенаправленных экспериментов, которые позволяют проверять правильность гипотезы на практике.

Следовательно, применительно к бизнес-деятельности процесс принятия решения претерпевает разрыв как минимум в двух точках: на этапе выдвижения гипотез и на этапе экспериментальной верификации моделей. Ликвидировать эти разрывы призвано активно развивающееся направление информационных технологий - технология многомерного анализа данных (On-Line Analytical Processing - OLAP).

Коротко эту технологию можно охарактеризовать следующими словами: Быстрый Анализ Разделяемой Многомерной Информации (FastAnalysis of Shared Multidimensional Information - FASMI).

Ценность технологии многомерного анализа данных для бизнеса определяется тем, что она позволяет извлекать из "сырых" структурированных (как правило, в виде таблиц) данных информацию и знания, использование которых в принятии и реализации решений позволяет создавать дополнительную стоимость в компании по сравнению со стоимостью, создаваемой в отсутствие такой информации.

Интеллектуальные системы

Структура интеллектуальной системы

С развитием компьютерных технологий менялся смысл, вкладываемый в понятие информационной системы. Современная информационная система — это набор информационных технологий, направленных на поддержку жизненного цикла информации и включающего три основных процесса: обработку данных, управление информацией и управление знаниями. В условиях резкого увеличения объемов информации переход к работе со знаниями на основе искусственного интеллекта является, по всей вероятности, единственной альтернативой информационного общества.

Согласно определению Д.А. Поспелова, "Система называется интеллектуальной, если в ней реализованы следующие основные функции:

- накапливать знания об окружающем систему мире, классифицировать и оценивать их с точки зрения прагматической полезности и непротиворечивости, инициировать процессы получения новых знаний, осуществлять соотнесение новых знаний с ранее хранимыми;
- пополнять поступившие знания с помощью логического вывода, отражающего закономерности в окружающем систему мире в накопленных ею ранее знаниях, получать обобщенные знания на основе более частных знаний и логически планировать свою деятельность;
- общаться с человеком на языке, максимально приближенном к естественному человеческому языку;
- получать информацию от каналов, аналогичных тем, которые использует человек при восприятии окружающего мира;
- уметь формировать для себя или по просьбе человека (пользователя) объяснение собственной деятельности;
- оказывать пользователю помощь за счет тех знаний, которые хранятся в памяти, и тех логических средств рассуждений, которые присущи системе".

Перечисленные функции можно назвать функциями представления и обработки знаний, рассуждения и общения. Наряду с обязательными компонентами, в зависимости от решаемых задач и области применения в конкретной системе эти функции могут быть реализованы в различной степени, что определяет индивидуальность архитектуры.

13.3.2 База знаний и компоненты интеллектуальной системы

На рисунке 1.15 в наиболее общем виде представлена структура интеллектуальной системы в виде совокупности блоков и связей между ними.

База знаний представляет собой совокупность сред, хранящих знания различных типов. Рассмотрим кратко их назначение.

База фактов (данных) хранит конкретные данные, а база правил — элементарные выражения, называемые в теории искусственного интеллекта продукциями.

База процедур содержит прикладные программы, с помощью которых выполняются все необходимые преобразования и вычисления.

База закономерностей включает различные сведения, относящиеся к особенностям той среды, в которой действует система.

База метазнаний (база знаний о себе) содержит описание самой системы и способов ее функционирования: сведения о том, как внутри системы представляются единицы информации различного типа, как взаимодействуют различные компоненты системы, как было получено решение задачи.

База целей содержит целевые структуры, называемые сценариями, позволяющие организовать процессы движения от исходных фактов, правил, процедур к достижению той цели, которая поступила в систему от пользователя либо была сформулирована самой системой в процессе ее деятельности в проблемной среде.

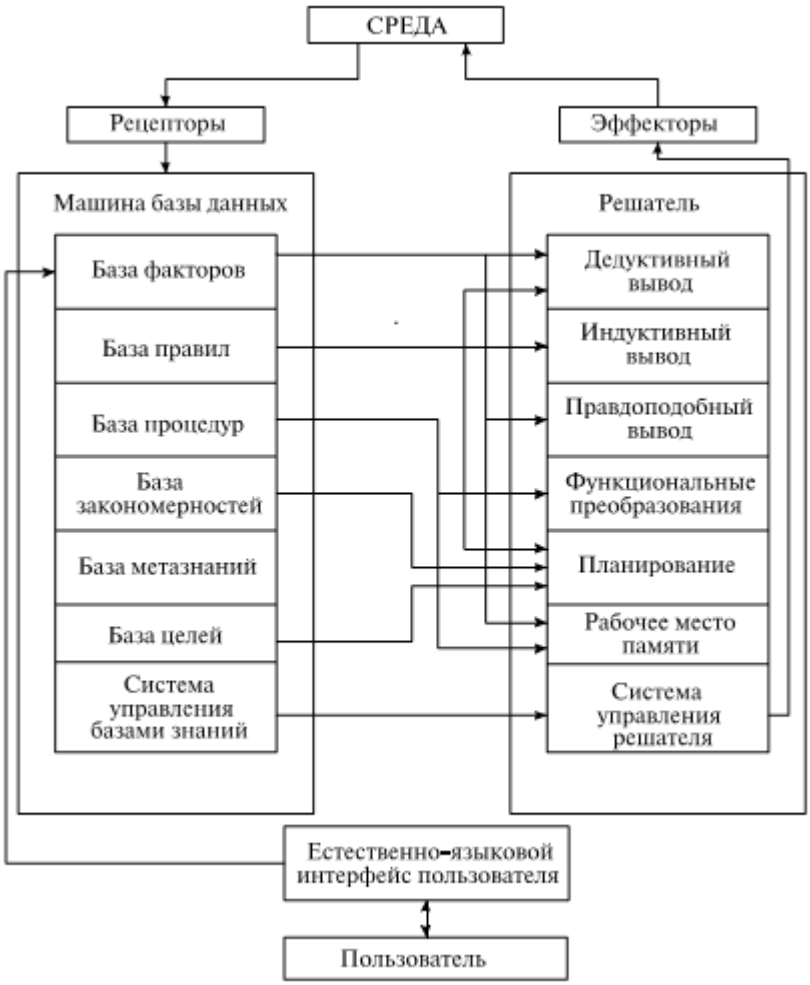

Рисунок 1.15. -Общая структура интеллектуальной системы

Управление всеми базами, входящими в базу знаний, и организацию их взаимодействия осуществляет система управления базами знаний. С ее же помощью

реализуются связи баз знаний с внешней средой. Таким образом, машина базы знаний осуществляет первую функцию интеллектуальной системы.

Выполнение второй функции обеспечивает часть интеллектуальной системы, называемая решателем и состоящая из ряда блоков, которые управляются системой управления решателя. Часть из блоков реализует логический вывод.

Блок дедуктивного вывода осуществляет в решателе дедуктивные рассуждения, с помощью которых из закономерностей из базы знаний, фактов из базы фактов и правил из базы правил выводятся новые факты. Кроме этого, данный блок реализует эвристические процедуры поиска решений задач как поиск путей решения задачи по сценариям при заданной конечной цели. Для реализации рассуждений, которые не носят дедуктивного характера, т. е. для поиска по аналогии, по прецеденту и т. д., используются блоки индуктивного и правдоподобного выводов.

Блок планирования применяется в задачах планирования решений совместно с блоком дедуктивного вывода.

Назначение блока функциональных преобразований состоит в решении задач расчетно-логического и алгоритмического типов.

Третья функция — функция общения — реализуется как с помощью компоненты естественно-языкового интерфейса, так и с помощью рецепторов и эффекторов, которые осуществляют так называемое невербальное общение и используются в интеллектуальных роботах.

Разновидности интеллектуальных систем

В зависимости от набора компонентов, реализующих рассмотренные функции, можно выделить следующие основные разновидности интеллектуальных систем:

- интеллектуальные информационно-поисковые системы;
- экспертные системы (ЭС);
- расчетно-логические системы;
- гибридные экспертные системы.

Интеллектуальные информационно-поисковые системы являются системами взаимодействия с проблемно-ориентированными (фактографическими) базами данных на естественном, точнее ограниченном как грамматически, так и лексически (профессиональной лексикой) естественном языке (языке деловой прозы). Для них характерно использование (помимо базы знаний, реализующей семантическую модель представления знаний о проблемной области) лингвистического процессора.

Экспертные системы являются одним из бурно развивающихся классов интеллектуальных систем. Данные системы в первую очередь стали создаваться в математически слабоформализованных областях науки и техники, таких как медицина, геология, биология и другие. Для них характерна аккумуляция в системе знаний и правил рассуждений опытных специалистов в данной предметной области, а также наличие специальной системы объяснений.

Расчетно-логические системы позволяют решать управленческие и проектные задачи по их постановкам (описаниям) и исходным данным вне зависимости от сложности математических моделей этих задач. При этом конечному пользователю предоставляется возможность контролировать в режиме диалога все стадии вычислительного процесса. В общем случае, по описанию проблемы на языке предметной области обеспечивается автоматическое построение математической модели и автоматический синтез рабочих программ при формулировке функциональных задач из данной предметной области. Эти свойства реализуются благодаря наличию базы знаний в виде функциональной семантической сети и компонентов дедуктивного вывода и планирования.

В последнее время в специальный класс выделяются гибридные экспертные системы. Указанные системы должны вобрать в себя лучшие черты как экспертных, так и

расчетно-логических и информационно-поисковых систем. Разработки в области гибридных экспертных систем находятся на начальном этапе.

Наиболее значительные успехи в настоящее время достигнуты в таком классе интеллектуальных систем, как экспертные системы.

Важное место в теории искусственного интеллекта (ИИ) занимает проблема представления знаний. В настоящее время выделяют следующие основные типы моделей представления знаний:

- семантические сети, в том числе функциональные;
- фреймы и сети фреймов;
- продукционные модели.

Семантические сети определяют как граф общего вида, в котором можно выделить множество вершин и ребер. Каждая вершина графа представляет некоторое понятие, а дуга — отношение между парой понятий. Метка и направление дуги конкретизируют семантику. Метки вершин семантической нагрузки не несут, а используются как справочная информация.

Различные разновидности семантических сетей обладают различной семантической мощностью, следовательно, можно описать одну и ту же предметную область более компактно или громоздко.

Фреймом называют структуру данных для представления и описания стереотипных объектов, событий или ситуаций. Фреймовая модель представления знаний состоит из двух частей:

- набора фреймов, составляющих библиотеку внутри представляемых знаний;
- механизмов их преобразования, связывания и т. д.

Существует два типа фреймов:

- образец (прототип) — интенсиональное описание некоторого множества экземпляров;
- экземпляр (пример) — экстенсиональное представление фрейм-образца.

В общем виде фрейм может быть представлен следующим кортежем:

<ИФ, (ИС, ЗС, ПП),..., (ИС, ЗС, ПП)>,

где ИФ — имя фрейма; ИС — имя слота; ЗС — значение слота; ПП — имя присоединенной процедуры (необязательный параметр).

Слоты — это некоторые незаполненные подструктуры фрейма, заполнение которых приводит к тому, что данный фрейм ставится в соответствие некоторой ситуации, явлению или объекту.

В качестве данных фрейм может содержать обращения к процедурам (так называемые присоединенные процедуры). Выделяют два вида процедур: процедуры-демоны и процедуры-слуги. Процедуры-демоны активизируются при каждой попытке добавления или удаления данных из слота. Процедуры-слуги активизируются только при выполнении условий, определенных пользователем при создании фрейма.

Продукционные модели — это набор правил вида "условия-действие", где условиями являются утверждения о содержимом базы данных, а действия представляют собой процедуры, которые могут изменять содержимое базы данных.

Формально продукция определяется следующим образом:

(i); Q;P;C; QA B; N,

где (i) — имя продукции (правила); Q — сфера применения правила; P — предусловие (например, приоритетность); C — предикат (отношение); A — > B — ядро; N — постусловия (изменения, вносимые в систему правил).

Практически продукции строятся по схеме "ЕСЛИ" (причина или, иначе, посылка), "ТО" (следствие или, иначе, цель правила).

Полученные в результате срабатывания продукций новые знания могут использоваться в следующих целях:

- понимание и интерпретация фактов и правил с применением продукций, фреймов, семантических цепей;

- решение задач с помощью моделирования;

- идентификация источника данных, причин несовпадений новых знаний со старыми, получение метазнаний;

- составление вопросов к системе;

- усвоение новых знаний, устранение противоречий, систематизация избыточных данных.

Процесс рассмотрения компьютером набора правил (выполнение программы) называют консультацией. Ее наиболее удобная для пользователя форма — дружественный диалог с компьютером. Интерфейс может быть в форме меню, на языке команд и на естественном языке.

Диалог может быть построен на системе вопросов, задаваемых пользователем, компьютером, или фактов — данных, хранящихся в базе данных. Возможен смешанный вариант, когда в базе данных недостаточно фактов.

При прямом поиске пользователь может задавать две группы вопросов, на которые компьютер дает объяснения:

- как получено решение. При этом компьютер должен выдать на экран трассу в виде ссылок на использованные правила;

- почему компьютер задал какой-то вопрос. При этом на экран выдается своеобразная трасса, которую компьютер хотел бы использовать для вывода после получения ответа на задаваемый вопрос. Вопрос почему может быть задан как в процессе консультации, так и после выполнения программы.

3. Общие требования к написанию и оформлению работы

Контрольная работа выполняется и сдается в электронном виде на CD/CDRW носителе. На конверте необходимо указать название дисциплины, ФИО студента, факультет, номер группы, шифр зачетной книжки, № варианта задания, и список всех созданных в ходе выполнения задания файлов.

Приведенный в конце методических указаний список литературы может использоваться студентами при выполнении контрольной работы.

4. План-график выполнения задания

Дата получения задания	Дата предоставления выполненного задания
3 семестр.	Летняя сессия за две недели до начала сессии.

5. Критерии оценивания работы

Оценка «отлично» выставляется студенту, если он продемонстрировал глубокие, исчерпывающие знания и творческие способности в понимании, изложении и использовании учебно-программного материала; логически последовательные, содержательные, полные, правильные и конкретные ответы на все поставленные вопросы и дополнительные вопросы преподавателя; свободное владение основной и дополнительной литературой, рекомендованной учебной программой.

Оценка «хорошо» выставляется студенту, если он продемонстрировал твердые и достаточно полные знания всего программного материала, правильное понимание сущности и взаимосвязи рассматриваемых процессов и явлений; последовательные,

правильные, конкретные ответы на поставленные вопросы при свободном устранении замечаний по отдельным вопросам; достаточное владение литературой, рекомендованной учебной программой.

Оценка «удовлетворительно» выставляется студенту, если он продемонстрировал твердые знания и понимание основного программного материала; правильные, без грубых ошибок ответы на поставленные вопросы при устранении неточностей и несущественных ошибок в освещении отдельных положений при наводящих вопросах преподавателя; недостаточное владение литературой, рекомендованной учебной программой.

Оценка «неудовлетворительно» выставляется студенту, если он продемонстрировал неправильные ответы на основные вопросы, допущены грубые ошибки в ответах, непонимание сущности излагаемых вопросов; неуверенные и неточные ответы на дополнительные вопросы.

6. Порядок защиты работы

Защита контрольной работы проводится в виде научной дискуссии с презентацией выполненных заданий в соответствии с графиком защиты. После доклада студенту задаются вопросы как преподавателем, так и студентами группы.

В процессе защиты своей работы студент делает доклад продолжительностью 7-10 минут. Доклад должен быть предварительно подготовлен студентом. Лучшее впечатление производит доклад в форме пересказа, без зачтения текста, которым следует пользоваться только для уточнения цифрового материала. Студент должен свободно ориентироваться в своей работе.

В выступлении необходимо корректно использовать демонстрационные материалы, которые усиливают доказательность выводов и облегчают восприятие доклада студента. Они оформляются в виде презентации в системе Power Point.

7. Учебно-методическое и информационное обеспечение дисциплины

Рекомендуемая литература

Основная литература

1. Советов, Б.Я. Теория информационных процессов и систем. Учебник/ Б.Я. Советов, В.А. Дубенецкий, В.В. Цехановский и др.; под ред. Б. Я. Советова. -М.: Академия, 2015. - 432с.

2. Тельнов, Ю. Ф. Проектирование систем управления знаниями. Учебное пособие./ Ю.Ф. Тельнов, В.А. Казаков. – М.: Евразийский открытый институт, 2016. – 207 с.

3. Блюмин, А. М. Проектирование систем информационного, консультационного и инновационного обслуживания. Учебное пособие./ А.М. Блюмин, Л.Т. Печеная, Н.А. Феоктистов. – М.: Дашков и Ко, 2014. – 352 с.

Дополнительная литература

1. Белов, В. С. Информационно-аналитические системы. Основы проектирования и применения: учебное пособие, руководство, практикум./ В. С. Белов, 2-е изд., перераб. и доп. – М.: Евразийский открытый институт, 2010. – 111 с.
2. Корпоративные информационные системы управления: учебник/ Н.М. Адбикеев и др.; ред.: Н.М. Адбикеев, О.В. Китова- М.: ИНФРА-М, 2011.
3.Мезенцева, О. С. Интеллектуальные системы и технологии / О. С. Мезенцева, М. В. Трофимова. – Ставрополь: СКФУ, 2013. – 240 с.
4. Федотова, Е.Л. Информационные технологии и системы: учеб.пособие. – М.: ИНФРА-М, 2011. – 352 с.

Методическая литература

1. Методические указания по выполнению лабораторных работ по дисциплине «Системный анализ данных и модели принятия решений».

2. Методические указания по выполнению контрольных работ по дисциплине «Системный анализ данных и модели принятия решений».

3. Методические рекомендации для студентов по организации самостоятельной работы

по дисциплине «Системный анализ данных и модели принятия решений».

Интернет-ресурсы

1. http://www.intuit.ru – сайт дистанционного образования в области информационных технологий.

2. http://window.edu.ru – образовательные ресурсы ведущих вузов.