

# Лекция 9, 10

## Интеллектуальный анализ данных Data Mining



Data Mining – это процесс обнаружения в сырых данных ранее неизвестных, нетривиальных, практически полезных и доступных интерпретации знаний, необходимых для принятия решений в различных сферах человеческой деятельности (Gregory Piatetsky-Shapiro)

Суть и цель технологии Data Mining можно охарактеризовать так: это технология, которая предназначена для поиска в больших объемах данных неочевидных, объективных и полезных на практике закономерностей.

Неочевидных – это значит, что найденные закономерности не обнаруживаются стандартными методами обработки информации или экспертным путем.

Объективных – это значит, что обнаруженные закономерности будут полностью соответствовать действительности, в отличие от экспертного мнения, которое всегда является субъективным.

Практически полезных – это значит, что выводы имеют конкретное значение, которому можно найти практическое применение.

Знания – совокупность сведений, которая образует целостное описание, соответствующее некоторому уровню осведомленности об описываемом вопросе, предмете, проблеме и т.д.

Использование знаний (knowledge deployment) означает действительное применение найденных знаний для достижения конкретных преимуществ (например, в конкурентной борьбе за рынок).

Интеллектуальный анализ данных - процесс обнаружения пригодных к использованию сведений в крупных наборах данных.

В интеллектуальном анализе данных применяется математический анализ для выявления закономерностей и тенденций, существующих в данных.

Обычно такие закономерности нельзя обнаружить при традиционном просмотре данных, поскольку связи слишком сложны, или из-за чрезмерного объема данных.

Эти закономерности и тренды можно собрать вместе и определить как модель интеллектуального анализа данных.

Модели интеллектуального анализа данных могут применяться к конкретным сценариям, а именно:

▣ Прогноз: оценка продаж, прогнозирование нагрузки сервера или времени простоя сервера



▣ Риски и вероятности: выбор наиболее подходящих заказчиков для целевой рассылки, определение точки равновесия для рискованных сценариев, назначение вероятностей диагнозам или другим результатам



□ **Рекомендации**: определение продуктов, которые с высокой долей вероятности могут быть проданы вместе, создание рекомендаций



□ **Определение последовательностей**: анализ выбора заказчиков во время совершения покупок, прогнозирование следующего возможного события



□ **Группирование**: разделение заказчиков или событий связанных элементов, анализ и прогнозирование общих черт

Модели интеллектуального анализа данных могут применяться к конкретным сценариям, а именно:

- ▣ Прогноз
- ▣ Риски и вероятности
- ▣ Рекомендации
- ▣ Определение последовательностей
- ▣ Группирование



К методам Data Mining иногда относят статистические методы (дескриптивный анализ, корреляционный и регрессионный анализ, факторный анализ, дисперсионный анализ, компонентный анализ, дискриминантный анализ, анализ временных рядов).

Такие методы, однако, предполагают некоторые априорные представления об анализируемых данных, что несколько расходится с целями Data Mining (обнаружение ранее неизвестных нетривиальных и практически полезных знаний).

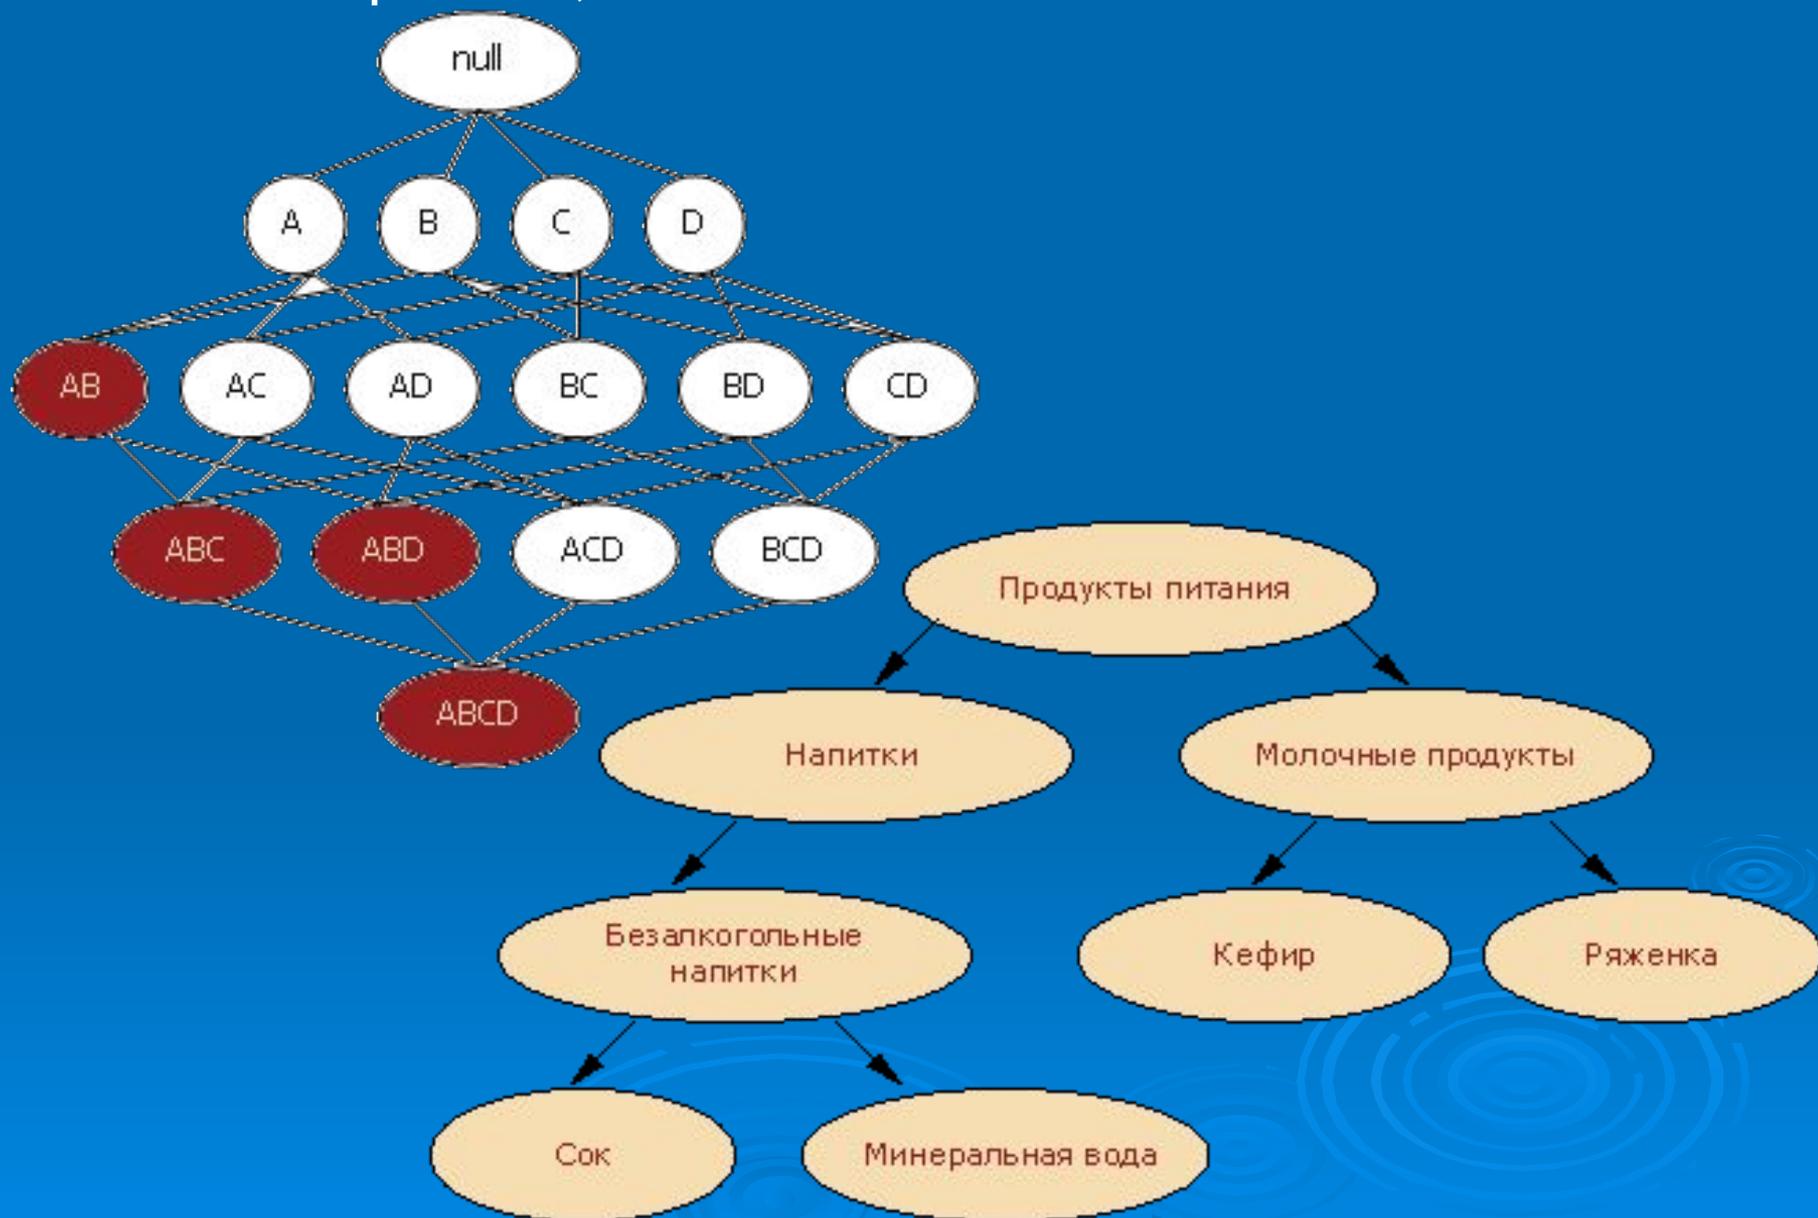
Одно из важнейших назначений методов Data Mining состоит в наглядном представлении результатов вычислений, что позволяет использовать инструментарий Data Mining людьми, не имеющими специальной математической подготовки. В то же время, применение статистических методов анализа данных требует хорошего владения теорией вероятностей и математической статистикой.

Знания, добываемые методами Data mining, принято представлять в виде моделей:

- Ассоциативные правила – логические закономерности;
- Деревья решений – средства ППР для прогнозных моделей;
- Кластеры – объединение в группы схожих объектов;
- Математические функции.

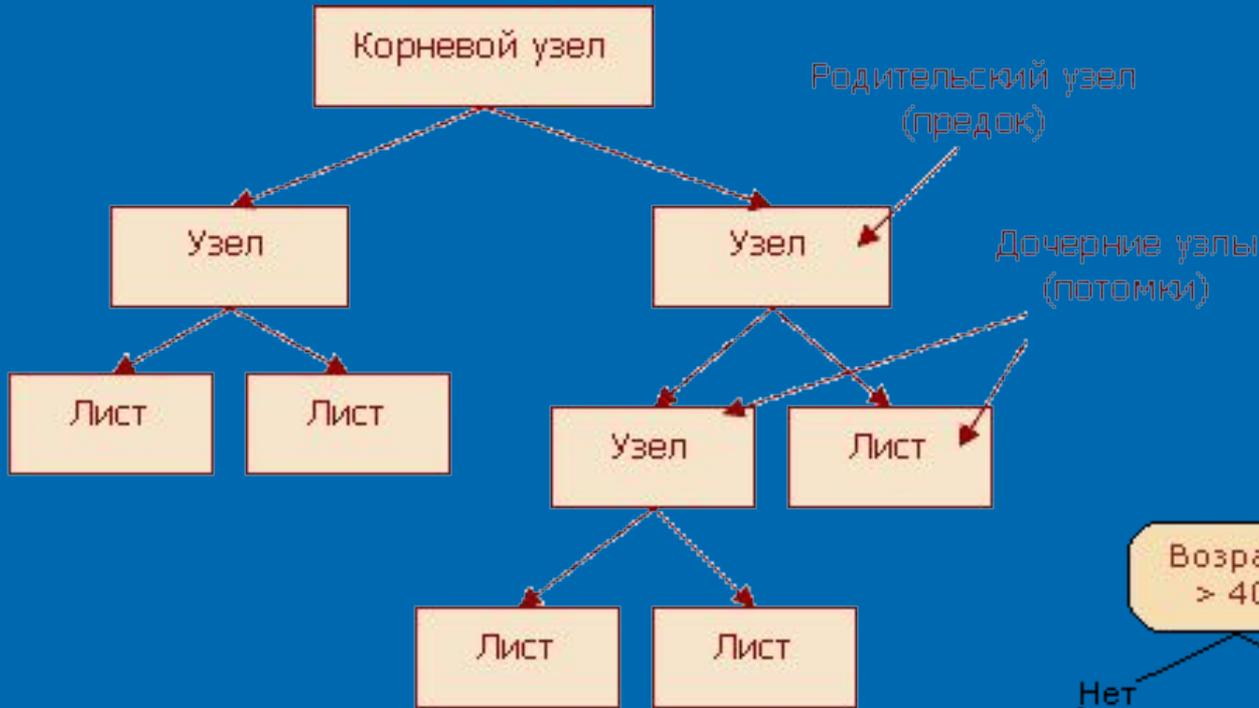


# Ассоциативные правила – логические закономерности;



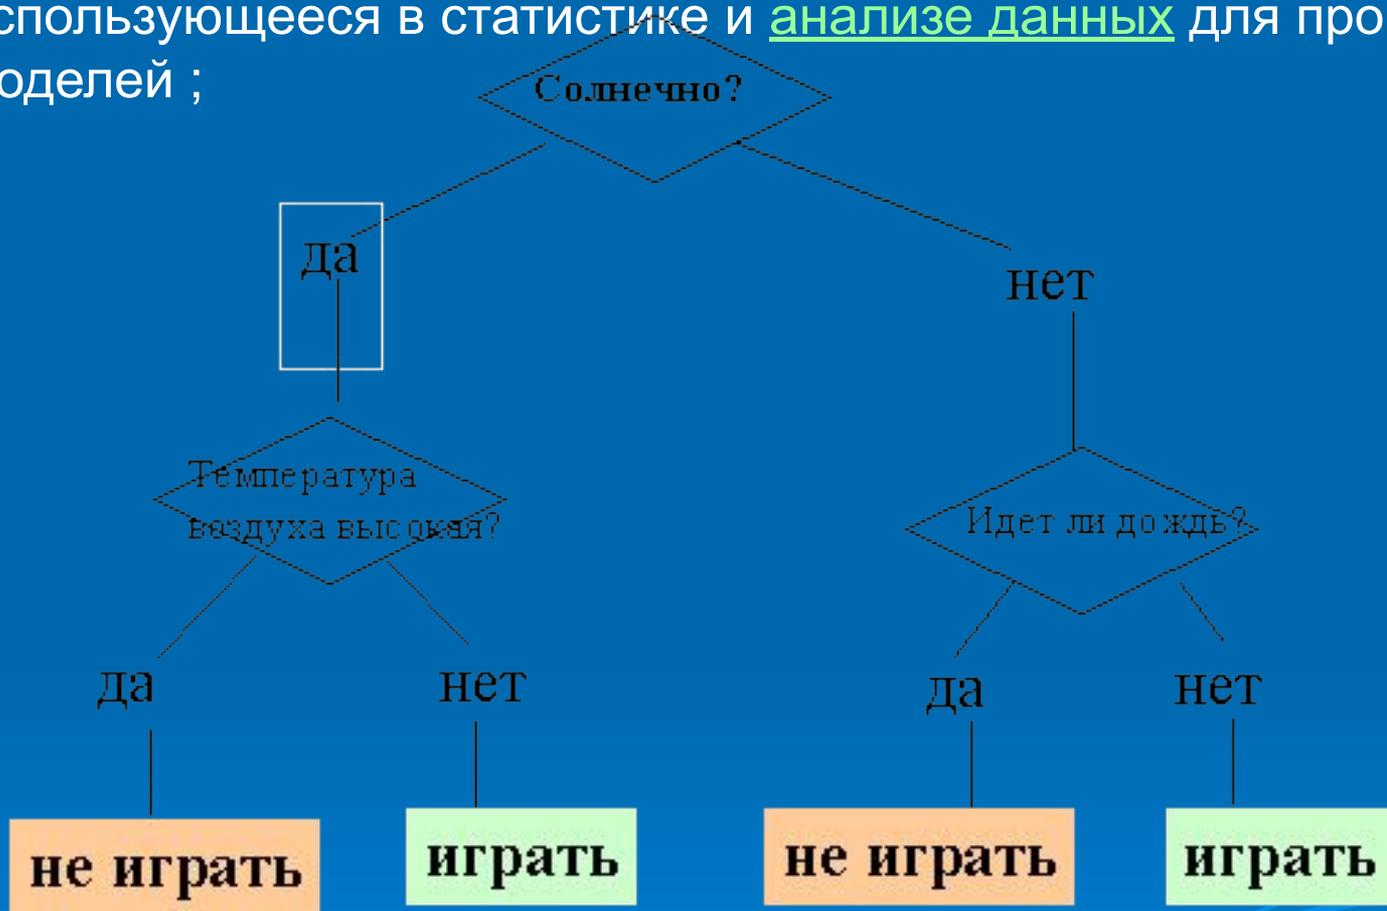


# Деревья решений;

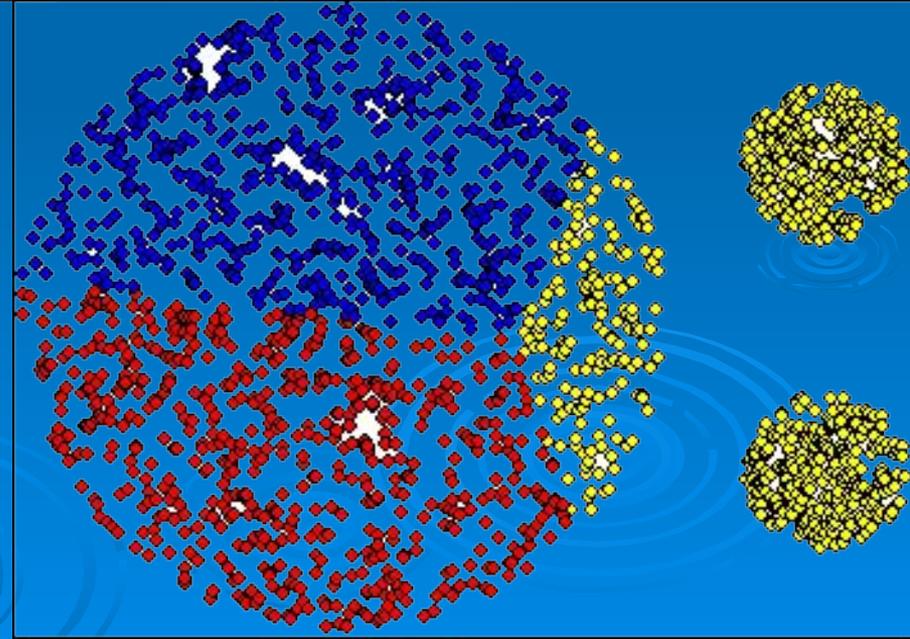
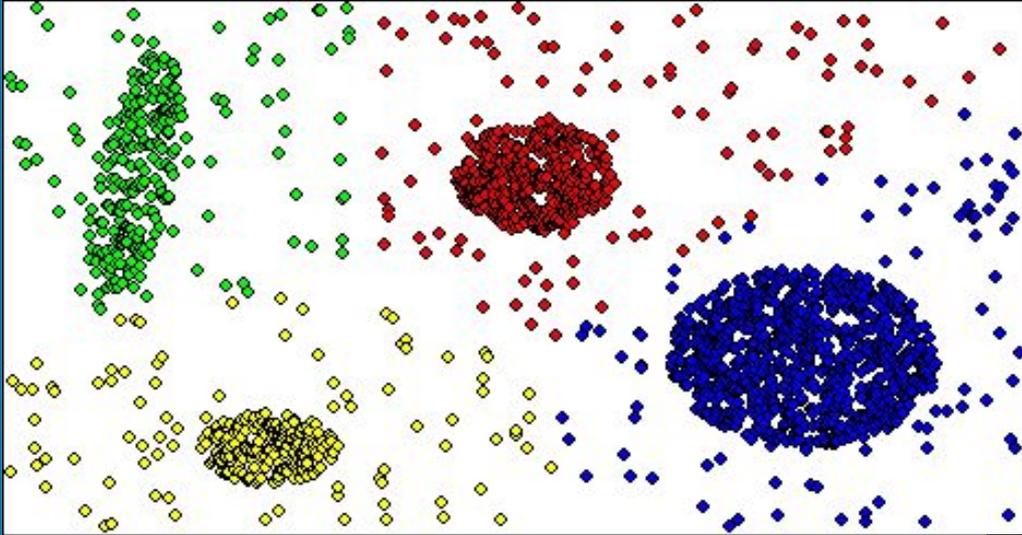




Деревья решений - средство поддержки принятия решений - средство поддержки принятия решений, используемое в статистике - средство поддержки принятия решений, используемое в статистике и анализе данных для прогнозных моделей ;



 Кластеры - объединение в группы  
схожих объектов ;



## К методам и алгоритмам Data Mining относятся:

1. Искусственные нейронные сети
2. Деревья решений, символьные правила
3. Методы ближайшего соседа и k-ближайшего соседа
4. Метод опорных векторов
5. Байесовские сети
6. Линейная регрессия
7. Корреляционно-регрессионный анализ
8. Иерархические методы кластерного анализа
9. Неиерархические методы кластерного анализа, в том числе алгоритмы k-средних и k-медианы
10. Методы поиска ассоциативных правил, в том числе алгоритм Apriori
11. Метод ограниченного перебора
12. Эволюционное программирование и генетические алгоритмы

А также методы визуализации данных и др. методы.

Большинство аналитических методов, используемые в технологии Data Mining – это известные математические алгоритмы и методы.

Новым в их применении является возможность их использования при решении тех или иных конкретных проблем, обусловленная появившимися возможностями технических и программных средств.

Следует отметить, что большинство методов Data Mining были разработаны в рамках теории искусственного интеллекта.

Метод представляет собой норму или правило, определенный путь, способ, прием решений задачи теоретического, практического, познавательного, управленческого характера.

# Свойства методов Data Mining

Различные методы Data Mining характеризуются определенными свойствами, которые могут быть определяющими при выборе метода анализа данных.

Основные свойства и характеристики методов Data Mining:

- точность,
- масштабируемость,
- интерпретируемость,
- проверяемость,
- трудоемкость,
- гибкость,
- быстрота
- популярность.

# Свойства методов Data Mining

Масштабируемость – свойство вычислительной системы, которое обеспечивает предсказуемый рост системных характеристик, например, скорости реакции, общей производительности и пр., при добавлении к ней вычислительных ресурсов.

В таблице приведена сравнительная характеристика некоторых распространенных методов.

Оценка каждой из характеристик проведена следующими категориями, в порядке возрастания:

чрезвычайно низкая,  
очень низкая,  
низкая/нейтральная,  
нейтральная/низкая,  
нейтральная,  
нейтральная/высокая,  
высокая,  
очень высокая.

# Свойства методов Data Mining

АЛГОРИТМ	ТОЧНОСТЬ	МАСШТАБИРУЕМОСТЬ	ИНТЕРПРЕТИРУЕМОСТЬ	ПРИГОДНОСТЬ К ИСП.
<i>линейная регрессия</i>	нейтральная	высокая	высокая / нейтральная	высокая
<i>нейронные сети</i>	высокая	низкая	низкая	низкая
<i>методы визуализации</i>	высокая	очень низкая	высокая	высокая
<i>деревья решений</i>	низкая	высокая	высокая	высокая / нейтральная
<i>нейронные сети</i>	высокая	нейтральная	низкая	высокая / нейтральная
<i>k-ближайшего соседа</i>	низкая	очень низкая	высокая / нейтральная	нейтральная

АЛГОРИТМ	ТРУДОЕМКОСТЬ	РАЗНОСТОРОННОСТЬ	БЫСТРОТА	ПОПУЛЯРНОСТЬ
<i>линейная регрессия</i>	нейтральная	нейтральная	высокая	низкая
<i>нейронные сети</i>	нейтральная	низкая	очень низкая	низкая
<i>методы визуализации</i>	очень высокая	низкая	чрезвычайно низкая	высокая / нейтральная
<i>деревья решений</i>	высокая	высокая	высокая / нейтральная	высокая / нейтральная
<i>нейронные сети</i>	низкая / нейтральная	нейтральная	низкая / нейтральная	нейтральная
<i>k-ближайшего соседа</i>	нейтральная низкая	низкая	высокая	низкая

**Таблица 1 Сравнительная характеристика методов Data Mining**

# Свойства методов Data Mining

	Точность	Масштабируемость	Интерпретируемость	Трудоемкость	Быстрота	Популярность
Линейная регрессия	3	5	4	3	5	2
Нейронные сети	5	2	2	3	1	2
Деревья решений	2	5	5	5	4	4
Полином. нейронные сети	5	3	2	2	2	3
К-ый ближайший сосед	2	1	5	2	5	2

Как видно из рассмотренной таблицы, каждый из методов имеет свои сильные и слабые стороны. Но ни один метод, какой бы не была его оценка с точки зрения присущих ему характеристик, не может обеспечить решение всего спектра задач Data Mining.

# Методы Data Mining.

1. Технологические методы.
2. Статистические методы.
3. Кибернетические методы.



# Методы Data Mining.

## 1. Технологические методы.

- **Непосредственное использование данных, или сохранение данных:**  
кластерный анализ, метод ближайшего соседа, метод k-ближайшего соседа, рассуждение по аналогии
- **Выявление и использование формализованных закономерностей, или дистилляция шаблонов:**  
логические методы; методы визуализации; методы кросс-табуляции; методы, основанные на уравнениях

# Методы Data Mining.

## 2. Статистические методы.

- Дескриптивный анализ и описание исходных данных.
- Анализ связей (корреляционный и регрессионный анализ, факторный анализ, дисперсионный анализ).
- Многомерный статистический анализ (компонентный анализ, дискриминантный анализ, многомерный регрессионный анализ, канонические корреляции и др.).
- Анализ временных рядов (динамические модели и прогнозирование).

# Методы Data Mining.

## 3. Кибернетические методы.

- Искусственные нейронные сети (распознавание, кластеризация, прогноз);
- Эволюционное программирование (в т.ч. алгоритмы метода группового учета аргументов);
- Генетические алгоритмы (оптимизация);
- Ассоциативная память (поиск аналогов, прототипов);
- Нечеткая логика;
- Деревья решений;
- Системы обработки экспертных знаний.

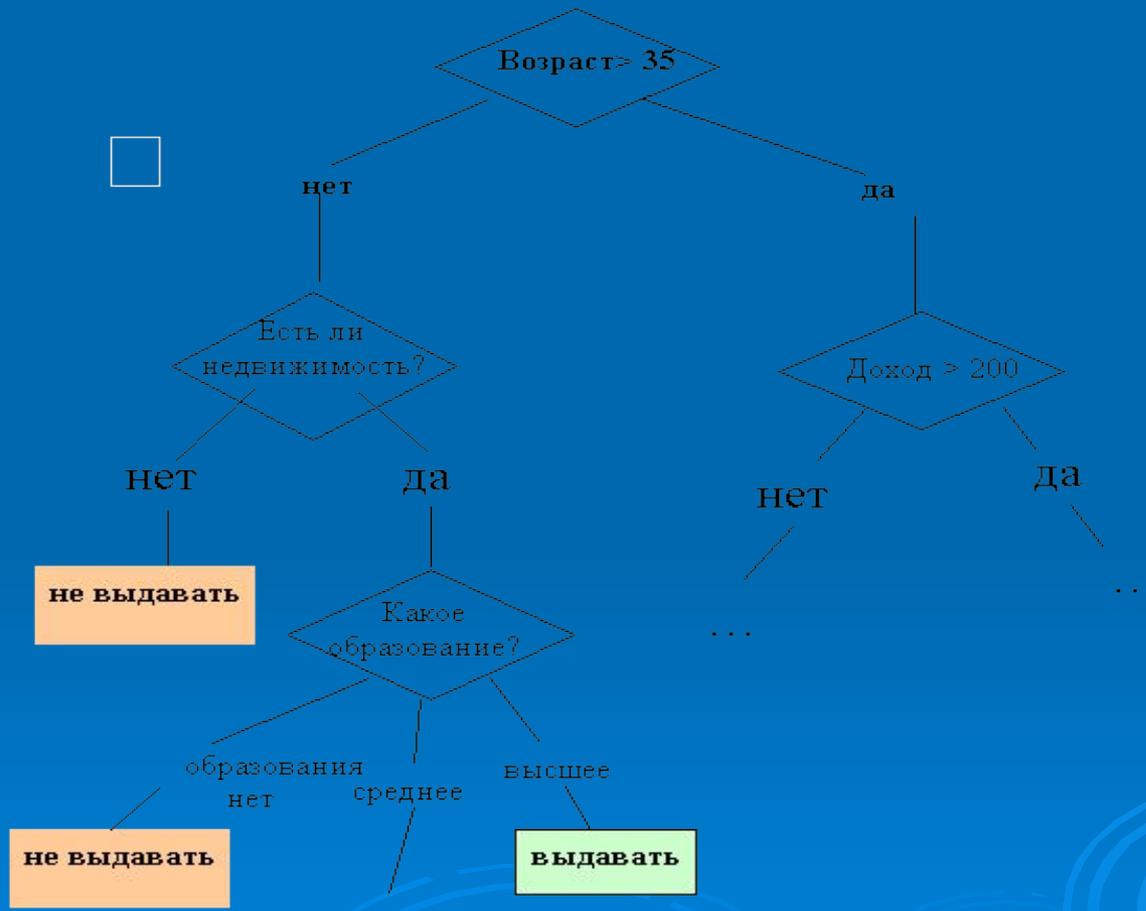
# Деревья решений

- Возникновение - 50-е годы (Ховиленд и Хант (Hoveland, Hunt) )
- Метод также называют деревьями решающих правил, деревьями классификации и регрессии
- *Это способ представления правил в иерархической, последовательной структуре*

# Деревья решений. Пример 1.



# Деревья решений. Пример 2.



# Деревья решений. Преимущества метода.

- **Интуитивность деревьев решений**
- **Возможность извлекать правила из базы данных на естественном языке**
- **Не требует от пользователя выбора входных атрибутов**
- **Точность моделей**
- **Разработан ряд масштабируемых алгоритмов**
- **Быстрый процесс обучения**
- **Обработка пропущенных значений**
- **Работа и с числовыми, и с категориальными типами данных**

# Деревья решений. Процесс конструирования.

Основные этапы алгоритмов  
конструирования деревьев:

- "построение" или "создание" дерева (tree building)
- "сокращение" дерева (tree pruning).

# Деревья решений. Критерии расщепления.

- "мера информационного выигрыша" (information gain measure)
- индекс Gini, т.е.  $gini(T)$ , определяется по формуле:

$$gini(T) = 1 - \sum_{j=1}^n p_j^2$$

- Большое дерево не означает, что оно "подходящее"

# Деревья решений. Остановка построения дерева.

*Остановка* - такой момент в процессе построения дерева, когда следует прекратить дальнейшие ветвления.

Варианты остановки:

- "ранняя остановка" (prepruning)
- ограничение глубины дерева
- задание минимального количества примеров

# Метод "ближайшего соседа" или системы рассуждений на основе аналогичных случаев.

*Прецедент* - это описание ситуации в сочетании с подробным указанием действий, предпринимаемых в данной ситуации.

Этапы:

- сбор подробной информации о поставленной задаче;
- сопоставление этой информации с деталями прецедентов, хранящихся в базе, для выявления аналогичных случаев;
- выбор прецедента, наиболее близкого к текущей проблеме, из базы прецедентов;
- адаптация выбранного решения к текущей проблеме, если это необходимо;
- проверка корректности каждого вновь полученного решения;
- занесение детальной информации о новом прецеденте в базу прецедентов.

# Метод "ближайшего соседа". Преимущества.

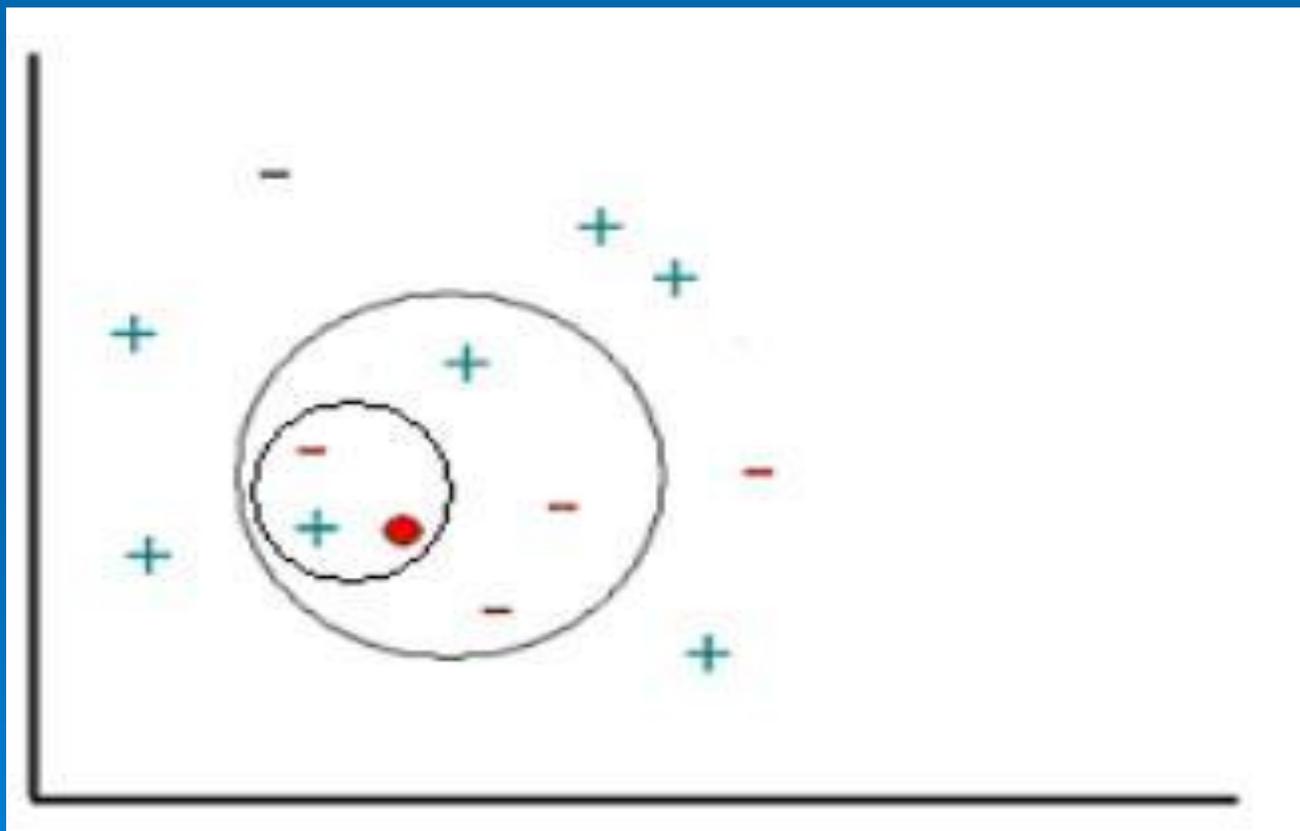
- Простота использования полученных результатов.
- Решения не уникальны для конкретной ситуации, возможно их использование для других случаев.
- Целью поиска является не гарантированно верное решение, а лучшее из возможных.

# Метод "ближайшего соседа".

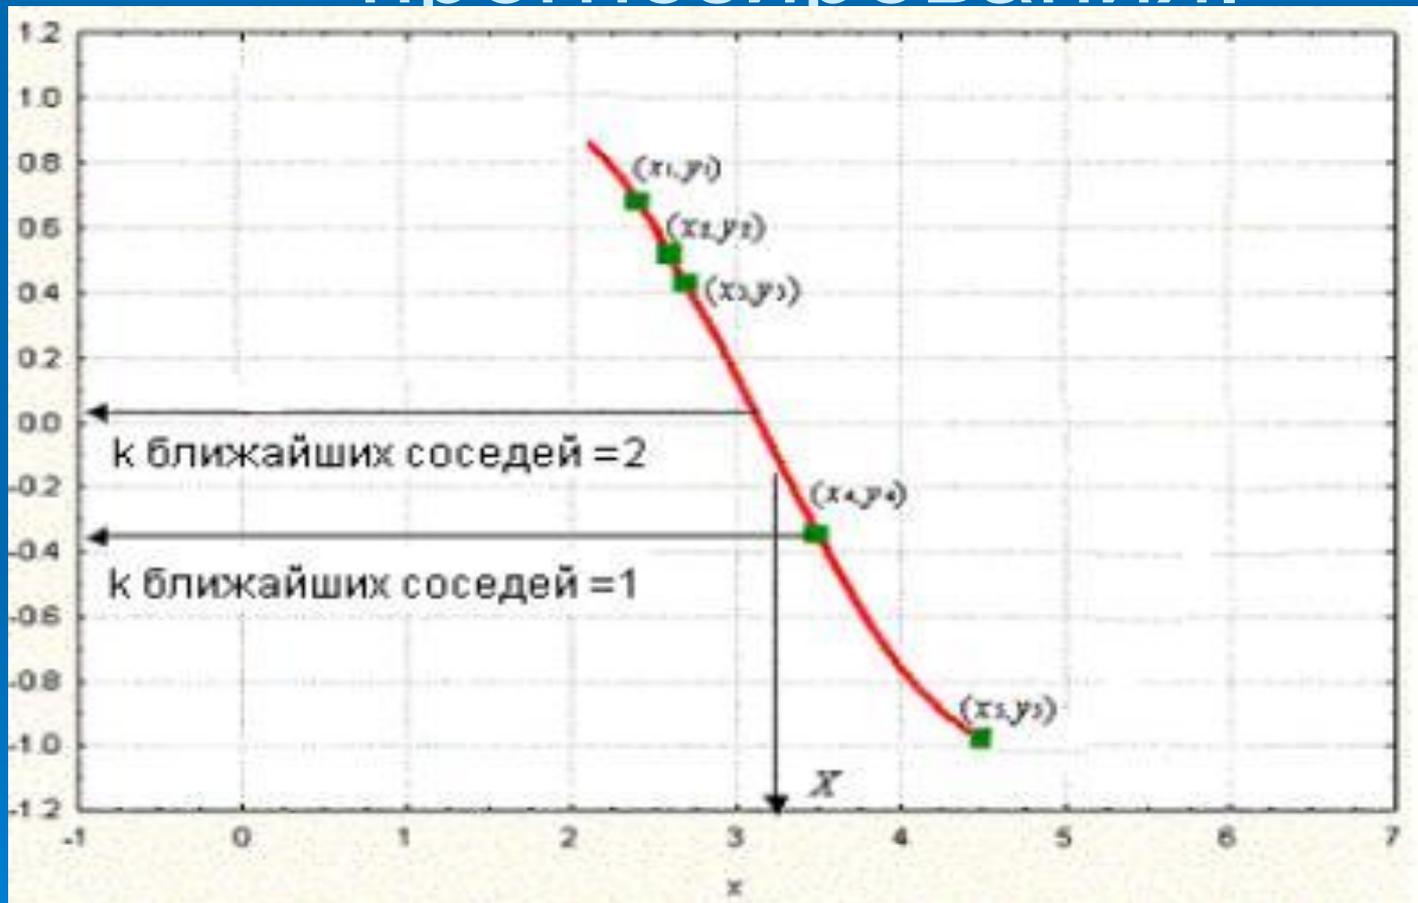
## Недостатки.

- Данный метод не создает каких-либо моделей или правил, обобщающих предыдущий опыт
- Сложность выбора меры "близости" (метрики).
- Высокая зависимость результатов классификации от выбранной метрики.
- Необходимость полного перебора обучающей выборки при распознавании, следствие этого - вычислительная трудоемкость.
- Типичные задачи данного метода - это задачи небольшой размерности по количеству классов и переменных.

# Метод "ближайшего соседа". Решение задачи классификации НОВЫХ объектов.



# Метод "ближайшего соседа". Решение задачи прогнозирования.



# Метод "ближайшего соседа". Оценка параметра $k$ методом кросс-проверки.

- *Кросс-проверка* - известный метод получения оценок неизвестных параметров модели.
- Основная идея - разделение выборки данных на  $v$  "складок". В "складки" здесь суть случайным образом выделенные изолированные подвыборки.