Санкт-Петербургский
государственный
университет
www.spbu.ru

# Анализ данных

Графеева Н.Г.

2018

Кафедра информационно-аналитических систем

# Анализ данных

## ПРОБЛЕМА

Современные информационные системы собирают гигантские объемы данных. Сбор данных без последующего глубокого анализа не позволяет использовать максимум имеющейся информации. В результате возникает парадоксальная ситуация – данных много, а пользы от них мало. Только применение полноценной аналитики позволяет трансформировать данные в реальные знания.

# Анализ данных

## Простые методы анализа

- Вычисление разнообразных статистических показателей
- создание специализированных аналитических отчетов
- построение разнообразных графиков и диаграмм
- использование OLAP-инструментов для оперативного вычисления статистики

## Глубокий анализ данных

Реальный бизнес характеризуется сложными зависимостями, большими объемами данных, быстрыми изменениями. Технологии глубокого анализа позволяют выявлять в огромных объемах данных нетривиальные закономерности и превращать знания в конкурентные преимущества.

## Понятие Data Mining

Data Mining – это процесс обнаружения в больших базах данных нетривиальных и практически полезных закономерностей.

## Сравнение формулировок задач OLAP и Data Mining

Какова средняя величина ежедневных покупок по украденной и не украденной кредитной карточке? (OLAP)

Существуют ли стереотипные схемы покупок для случаев мошенничества с кредитными карточками? (Data Mining)

## Классы задач Data Mining

- классификация
- кластеризация
- прогнозирование
- поиск ассоциаций
- поиск последовательностей

## Классификация (Classification)

Задача классификации сводится к определению класса объекта по его характеристикам.  В этой задаче множество классов, к которым может быть отнесен объект, известно заранее. Для решения задачи могут использоваться методы:

k-ближайшего соседа (k-Nearest Neighbor); байесовские сети (Bayesian Networks); деревья решений; нейронные сети (neural networks) и т.п.

# Анализ данных

## Пример классификации

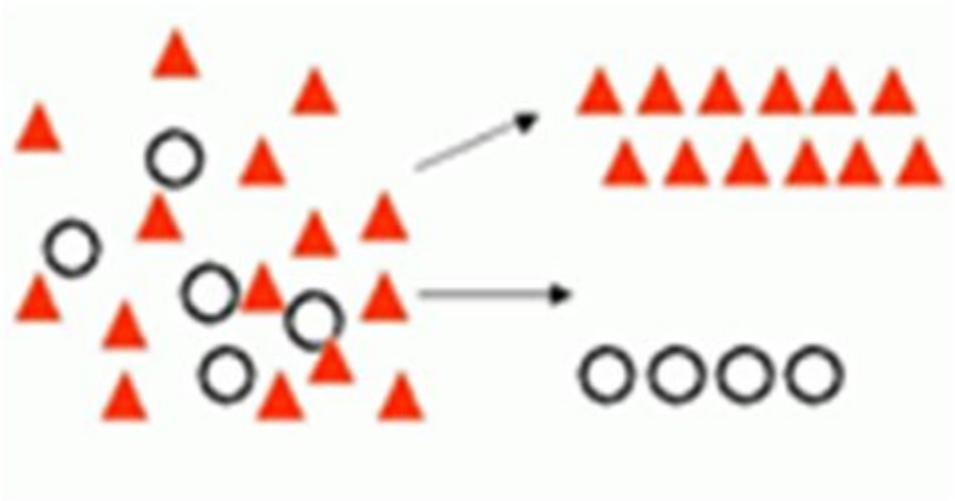

## Кластеризация (Clustering)

Задача кластеризации заключается в поиске независимых групп (кластеров) и их характеристик во всем множестве анализируемых данных. Решение этой задачи помогает лучше понять данные. Кроме того, группировка однородных объектов позволяет сократить их число, а следовательно, и облегчить дальнейший анализ.

# Анализ данных

## Пример кластеризации

# Живой пример работы алгоритма кластеризаци

http://www.naftaliharris.com/blog/visualizing-dbscan-clustering/

# Анализ данных

## Прогнозирование (Forecasting)

В результате решения задачи прогнозирования на основе особенностей исторических данных оцениваются пропущенные или же будущие значения целевых численных показателей. Для решения таких задач широко применяются методы математической статистики, нейронные сети и др.

# Пример прогнозирования

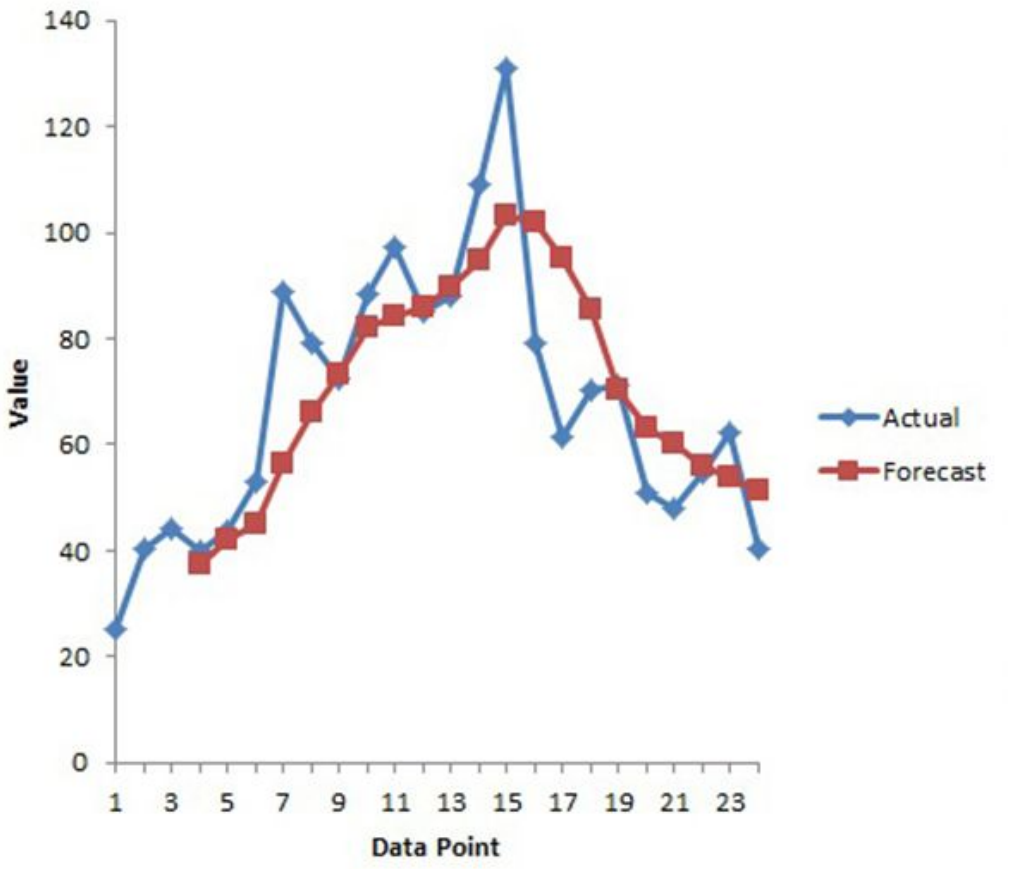

## Ассоциации (Associations)

При поиске ассоциативных правил целью является нахождение частых зависимостей между объектами. Найденные зависимости представляются в виде правил и могут быть использованы для лучшего понимания природы анализируемых данных. Наиболее известный алгоритм поиска ассоциативных правил – Apriori.

# Пример нахождения ассоциативных правил

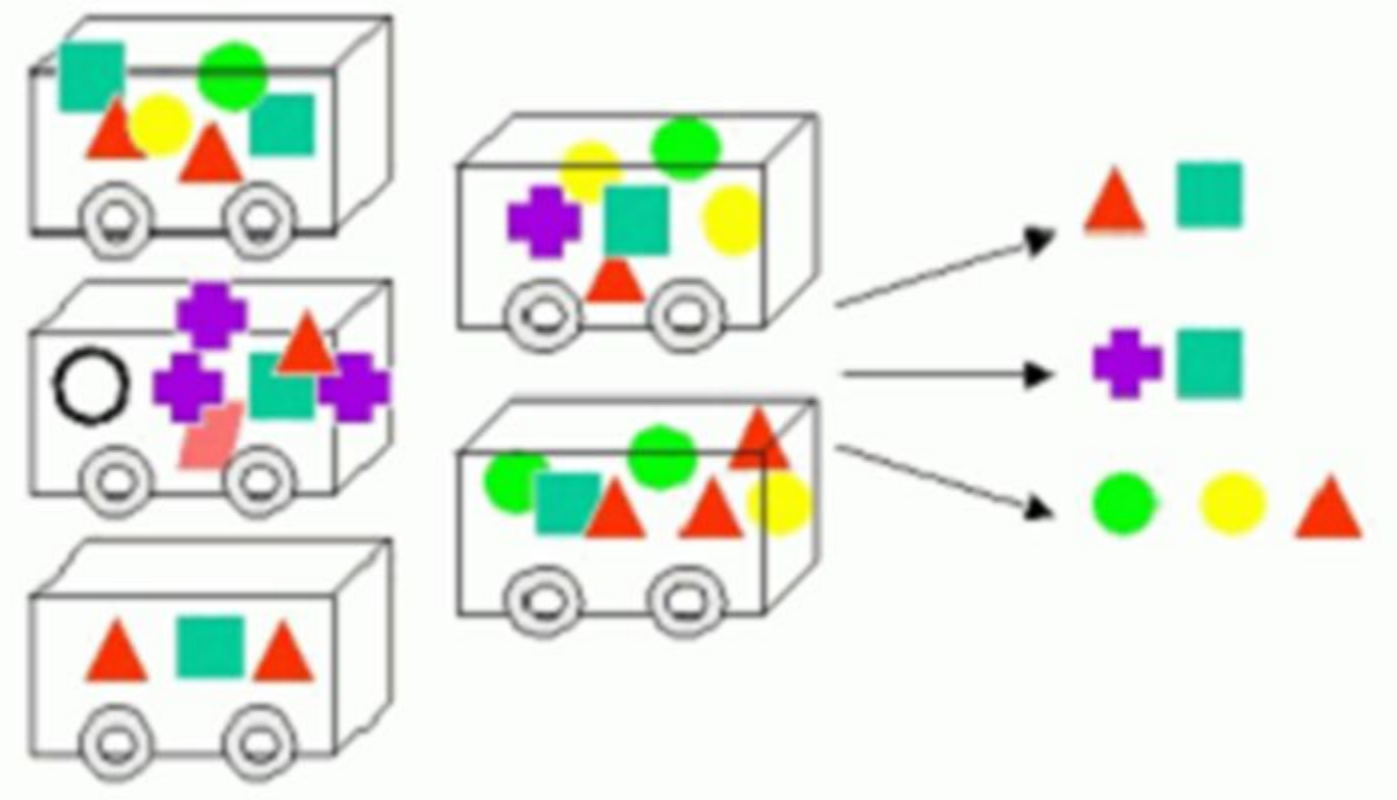

## Последовательность (Sequence)

Последовательность (sequential association) - временные закономерности между событиями. Последовательность определяется высокой вероятностью цепочки связанных во времени событий. Ассоциация является частным случаем последовательности с временным интервалом, равным нулю. Эту задачу также называют задачей нахождения последовательных шаблонов (sequential pattern).

## Сфера применения

Методы Data Mining сегодня интересуют коммерческие предприятия, обладающие большими информационными хранилищами данных. Data Mining представляет большую ценность для руководителей и аналитиков в их повседневной деятельности.

# Анализ данных

## Некоторые бизнес-приложения Data Mining

- розничная торговля
- банковское дело
- телекоммуникации
- страхование
- и другие приложения в бизнесе…

# Анализ данных

## Розничная торговля

- анализ покупательской корзины
- исследование временных шаблонов
- создание прогнозирующих моделей

# Анализ данных

## Банковское дело

- выявление мошенничества с кредитными карточками
- сегментация клиентов
- прогнозирование изменений клиентуры

# Анализ данных

## Телекоммуникации

- выявление категорий клиентов с похожими стереотипами поведения
- выявление лояльности клиентов

# Анализ данных

## Страхование

- выявление мошенничества
- анализ рисков по страховым выплатам

# Анализ данных

## Другие приложения в бизнесе

- поощрение любителей авиаперелетов
- прогнозирование гарантийных обращений к производителям продукции
- развитие автомобильной промышленности с учетом наиболее востребованных опций
- и т.п.

# Программные продукты Data Mining

- аналитические пакеты в некоторых СУБД (например, в ORACLE, DB2, Microsoft SQL Server)
- библиотеки алгоритмов Data Mining с соответствующей инфраструктурой
- узкоспециализированные решения

## Проблемы существующих решений

Data Mining – бурно развивающаяся мультидисциплинарная отрасль, в которой постоянно появляются новые методы извлечения знаний. Существующие программные продукты либо  не успевают, либо не очень следят за такими методами.

## Аналитический пакет ORACLE 12

Например, в СУБД ORACLE в 12 версии (выпущена в 2013 году) реализован единственный алгоритм для поиска ассоциативных правил – Apriori (дата публикации – 1994 год). Хотя с тех пор в авторитетных изданиях были опубликованы не менее 11 более совершенных алгоритмов…

## Наши работы в области Data Mining

- Выявление и классификация аномалий магнитного поля с помощью алгоритмов кластеризации (на примере археологических раскопок).
- Анализ лог-файлов для обнаружения разного рода сбоев в работе аппаратных комплексов.
- Анализ транспортных потоков Санкт-Петербурга.

## Наши работы в области Data Mining

- Прогнозирование потребления продуктов в сети ресторанов.
- Прогнозирование потребления электроэнергии.
- Поиск ассоциативных правил для профилирования ресторанов.
- И многие другие…

# Анализ данных