Основы анализа текстовых данных

Кафедра управления и интеллектуальных технологий НИУ «МЭИ»

Весна 2022 г.

Что такое Data Mining?

Data Mining - совокупность методов обнаружения в данных ранее неизвестных, нетривиальных, практически полезных и доступных для интерпретации знаний, необходимых для принятия решений в различных сферах человеческой деятельности.

Термин *Data Mining* («*Добыча данных*») введен Григорием Пятецким-Шапиро в 1989г:
Имеется большая база данных, из которой хотим извлечь «Скрытые знания»:

- Ранее неизвестные
- Нетривиальные
- Полезные для практики
- Интерпретируемые

Основу методов Data Mining составляют всевозможные методы классификации, моделирования и прогнозирования, а также статистические методы, из которых большую часть составляют методы машинного обучения (Machine Learning).

Что такое Machine Learning?

ML - обширный подраздел искусственного интеллекта, изучающий методы построения алгоритмов, способных обучаться.

Постановка задачи ML:

X – Множество объектов; Y- Множество ответов

Имеется неизвестная целевая функция (target function) :

$$y : X \to Y$$

Дано:

$\{\vec{X}_1, \ldots, \vec{X}_l\} \in X$ - Выборка объектов (dataset)

$y_j = y(\vec{X}_j); j = 1 \ldots N$ - Известные ответы

Найти $a : X \to Y$ - алгоритм, решающая функция (decision function), приближающийся к y на всем множестве X

Способы построения алгоритма а:

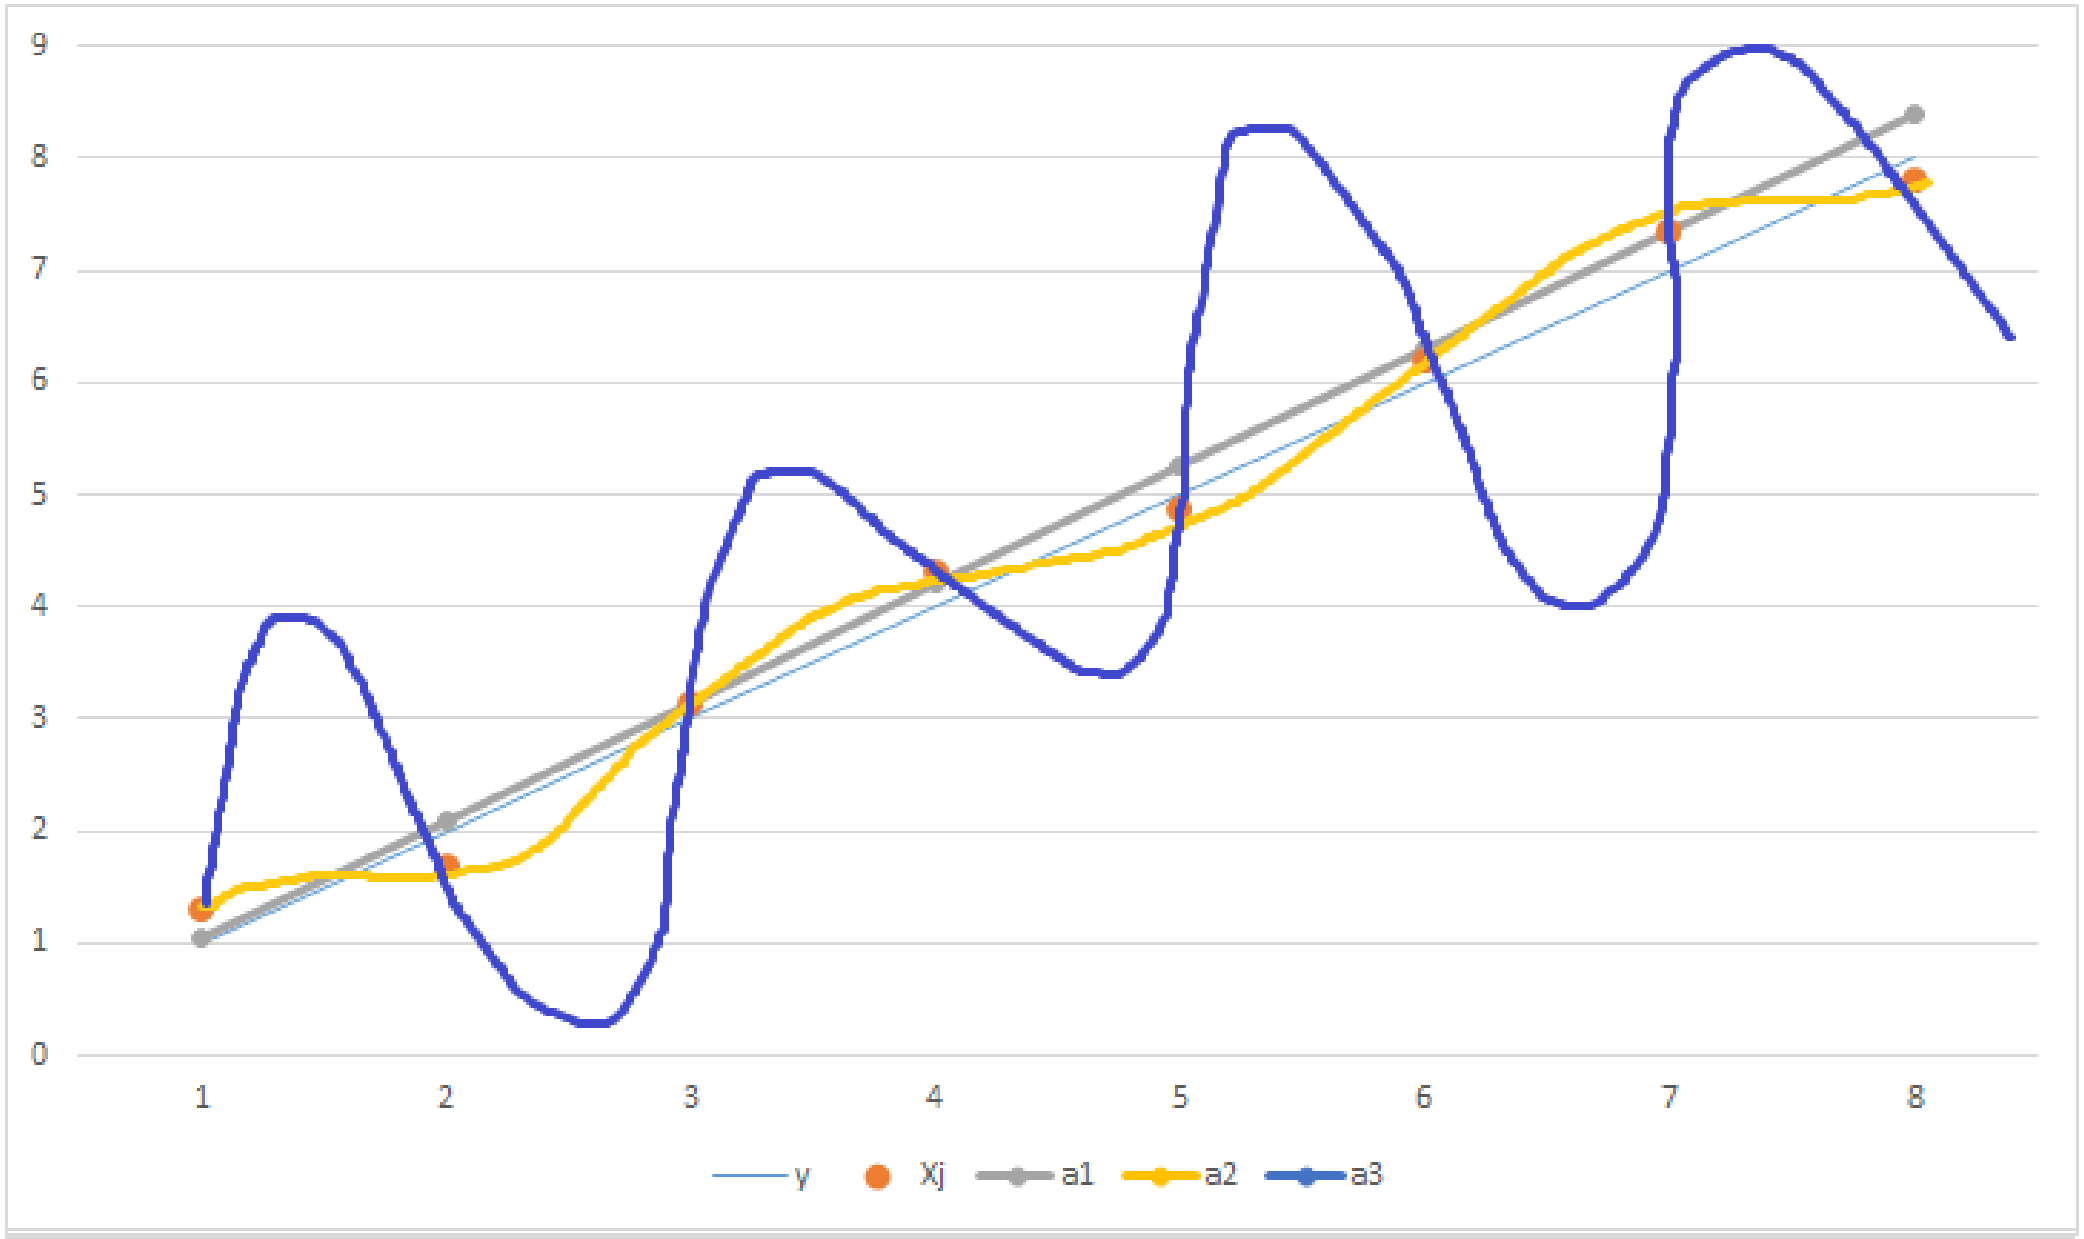

Объекты и признаки:

$x_j^{(i)}$ - Признаки/свойства (features)

i = 1…M

Выбор и построение (формирование) признаков – важный этап решения задачи ML

Виды признаков:

- Бинарный
- Номинальный
- Порядковый
- Количественный

Объект часто описывается в виде вектора:

$$\vec{X}_j = \begin{bmatrix} x_j^{(1)} \\ \vdots \\ x_j^{(i)} \\ \vdots \\ x_j^{(M)} \end{bmatrix}$$

Выборка – в виде матрицы «объект-признак»:

$$X = \begin{pmatrix} x_1^{(1)} & \dots & x_1^{(M)} \\ \vdots & \ddots & \vdots \\ x_N^{(1)} & \dots & x_N^{(M)} \end{pmatrix}$$

Типы задач. Классификация

1. **Задачи классификации** (Classification):

- Y= {-1;1} – бинарная классификация (классификация на 2 класса)
- Y= {1,…K} – На К непересекающихся классов
- $Y=\{0;1\}^K$ - На К классов, которые могут пересекаться

Пример: Задача классификации цветков ириса (Фишер, 1936г.)

i = 4 признака

|Y| = 3 класса

Длина выборки N = 150

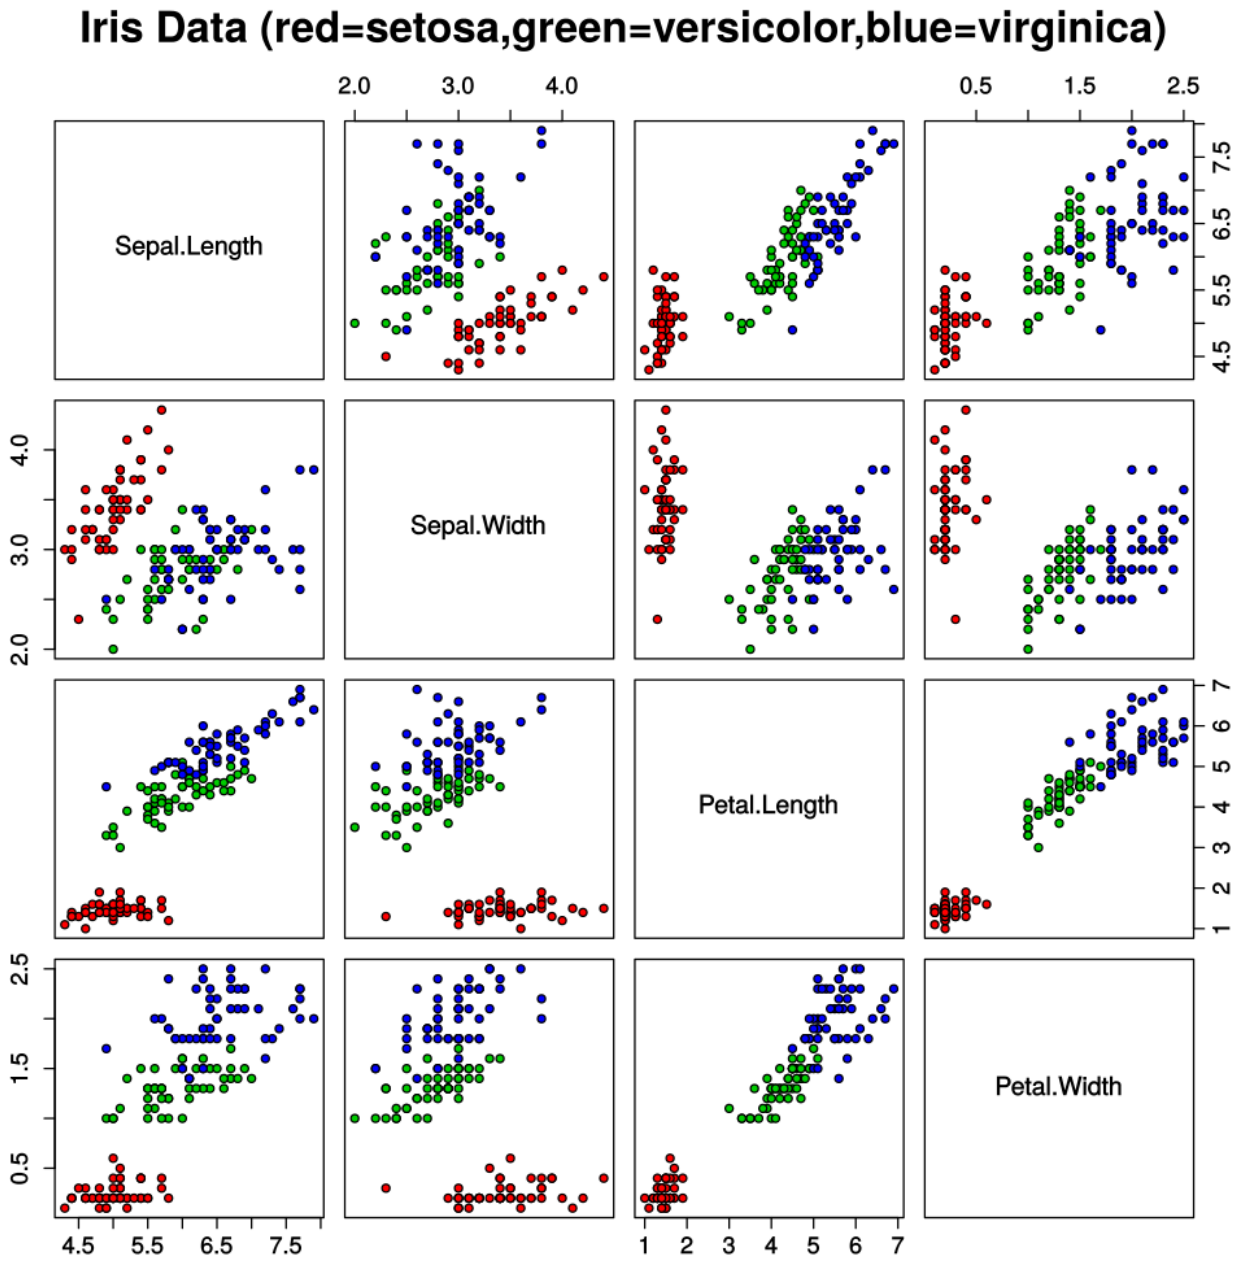

Этап обучения и применения

- Обучение. Строим алгоритм *a* по выборке:

$$\begin{pmatrix} x_1^{(1)} & \dots & x_1^{(M)} \\ \vdots & \ddots & \vdots \\ x_N^{(1)} & \dots & x_N^{(M)} \end{pmatrix} \to \begin{pmatrix} y_1 \\ \vdots \\ y_N \end{pmatrix} \Rightarrow a$$

- Применение. Алгоритм *a* для новых объектов выдает ответы:

$$\begin{pmatrix} \tilde{x}_1^{(1)} & \dots & \tilde{x}_1^{(M)} \\ \vdots & \ddots & \vdots \\ \tilde{x}_T^{(1)} & \dots & \tilde{x}_T^{(M)} \end{pmatrix} \xrightarrow{a} \begin{pmatrix} \tilde{a}_1 \\ \vdots \\ \tilde{a}_T \end{pmatrix}$$

Типы задач. Регрессия и ранжирование

2. Задачи восстановления регрессии (Regression)

- Y = **R**

3. Задачи ранжирования (ranking):

- Y- конечное упорядоченное множество

Типы задач. Кластеризация

4. Кластеризация (clustering) – обучение без учителя (unsupervised learning)

- Y – не задается. В этом случае требуется искать зависимости между объектами

Кредитный скоринг

- **Объект** – заявка на получение кредита
- **Классы**: good, bad
- **Примеры признаков**:
  - Бинарные: пол, наличие телефона,…
  - Номинальные: место работы, профессия, место жительства,…
  - Порядковые: должность, образование,…
  - Количественные: возраст, зарплата, стаж работы, сумма кредита,…
- **Особенности задачи**:
  - Вероятны пропуски данных
  - Возможна недостоверность данных
  - Нужно оценить вероятность дефолта *P(bad)*

Предсказание оттока клиентов

- **Объект** – абонент в определенный момент времени
- **Классы**: уйдет или не уйдет в следующем месяце
- **Примеры признаков**:
  - Бинарные: включенные услуги, корпоративный клиент…
  - Номинальные: тарифный план, регион проживания,…
  - Количественные: длительность разговоров (входящих, исходящих, СМС, трафик), сумма оплаты, частота оплаты,…
- **Особенности задачи**:
  - Сверхбольшие выборки
  - Непонятно, какие признаки вычислять по «сырым данным»
  - Нужно оценить вероятность ухода

Задача ранжирования поисковой выдачи

- **Объект** – пара <запрос, документ>
- **Классы**: релевантен или не релевантен
- **Примеры признаков**:
  - Количественные: частота слов запроса в документе, число ссылок на документ, число кликов на документ,…
- **Особенности задачи**:
  - Оптимизируется не число ошибок, а качество ранжирования
  - Сверхбольшие выборки

Категоризация текстовых документов

- **Объект** – текстовый документ
- **Классы**: Рубрики тематического каталога
- **Примеры признаков**:
  - Номинальные: автор, год, издание,…
  - Количественные: Частота появления терминов в документе, в названии, в в ключевых словах,…
- **Особенности задачи**:
  - Очень большое количество признаков (слов, словоформ)
  - Документ написан на естественном языке (ЕЯ)
  - Документ может относиться к нескольким рубрикам

Text Mining – интеллектуальный анализ текстов

- **Категоризация текстов** (*classification*) –
  - отнесении документов из коллекции к одной или нескольким группам (классам, кластерам) схожих между собой текстов
- **Извлечение информации** (*information extraction*) –
  - это задача автоматического извлечения (построения) структурированных данных из неструктурированных или слабоструктурированных машиночитаемых документов (распознавание имен людей, названий организаций, поиск ключевых слов для текста, автореферирование)
- **Информационный поиск** (*information retrieval*) –
  - процесс поиска *неструктурированной* документальной информации, удовлетворяющей информационные потребности (процесс выявления в некотором множестве документов всех тех, которые посвящены указанной теме)