

# Статистические методы распознавания образов

Лекция N 7 курса  
“Современные задачи  
теоретической информатики”

Юрий Лифшиц  
yura@logic.pdmi.ras.ru

ИТМО

Осень'2005

Чем более подходящими шаблонами вы пользуетесь, тем более успешными будут ваши решения. Это обнадеживающее наблюдения для поборников искусственного интеллекта, так как, разумеется, компьютеры могут быть обучены распознаванию образов. Ясно, что успешные компьютерные программы, помогающие банкам — рассматривать заявки на кредиты, докторам — ставить диагнозы, а пилотам — приземлять самолеты, в каком-то смысле основаны на распознавании образов... Мы должны уделить намного больше внимания непосредственно распознаванию образов.

*Герберт Саймон, нобелевский лауреат*

- 1 **Общие принципы распознавания образов**
  - Постановка и применения
  - Методы распознавания
- 2 **Курс математической статистики в 5 слайдах**
- 3 **Статистические методы распознавания образов**
- 4 **Задача**

## 1 Общие принципы распознавания образов

Постановка и применения

Методы распознавания

2 Курс математической статистики в 5 слайдах

3 Статистические методы распознавания образов

4 Задача

Биоинформатика	Поиск шаблонов в ДНК
Базы данных	Поиск и классификация
Обработка текстов	Тематическая классификация
Анализ изображений	Распознавание букв
Производство	Контроль качества
Поиск по мультимедиа	Определение жанров, ...
Биометрия	Отпечатки пальцев,...
Прогнозирование	Погода, сейсмология, геология
Обработка речи	Перевод аудио в текст

# Распознавание образов по шагам

- ❶ Восприятие образа (измерения)
- ❷ Предварительная обработка
- ❸ Выделение характеристик (индексация)
- ❹ Классификация (принятие решения)

# Разработка системы распознавания

Что нужно сделать для построения системы  
распознавания образов?

# Разработка системы распознавания

Что нужно сделать для построения системы распознавания образов?

- 1 Достать тренировочную коллекцию
- 2 Выбрать модель представления объектов
- 3 Выбрать значимые характеристики
- 4 Разработать классифицирующее правило
- 5 Обучение алгоритма
- 6 Проверить качество. Вернуться к шагу 2 (3,4)...
- 7 Оптимизация алгоритма

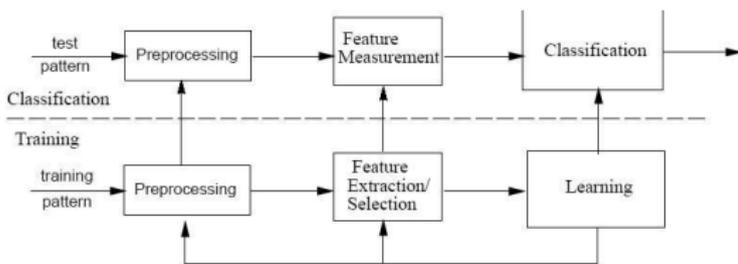


Figure 1: Model for statistical pattern recognition.

## Выделяют 4 группы методов:

- Сравнение с образцом
  - Применяем геометрическую нормализацию и считаем расстояние до прототипа

## Выделяют 4 группы методов:

- Сравнение с образцом
  - Применяем геометрическую нормализацию и считаем расстояние до прототипа
- Статистические методы
  - Строим распределение для каждого класса и классифицируем по правилу Байеса

## Выделяют 4 группы методов:

- Сравнение с образцом
  - Применяем геометрическую нормализацию и считаем расстояние до прототипа
- Статистические методы
  - Строим распределение для каждого класса и классифицируем по правилу Байеса
- Нейронные сети
  - Выбираем вид сети и настраиваем коэффициенты

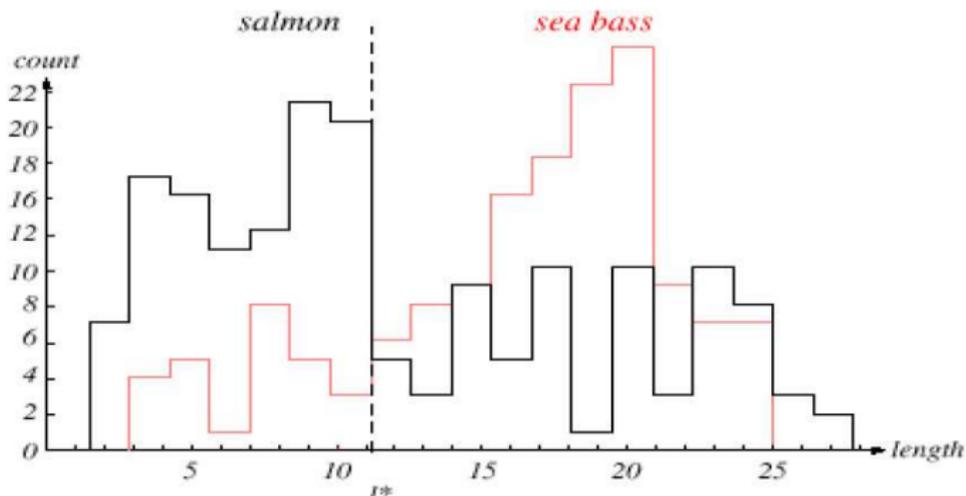
## Выделяют 4 группы методов:

- Сравнение с образцом
  - Применяем геометрическую нормализацию и считаем расстояние до прототипа
- Статистические методы
  - Строим распределение для каждого класса и классифицируем по правилу Байеса
- Нейронные сети
  - Выбираем вид сети и настраиваем коэффициенты
- Структурные и синтаксические методы
  - Разбираем объект на элементы. Строим правило, в зависимости от вхождения/невхождения отдельных элементов и их последовательностей

## Выделяют 4 группы методов:

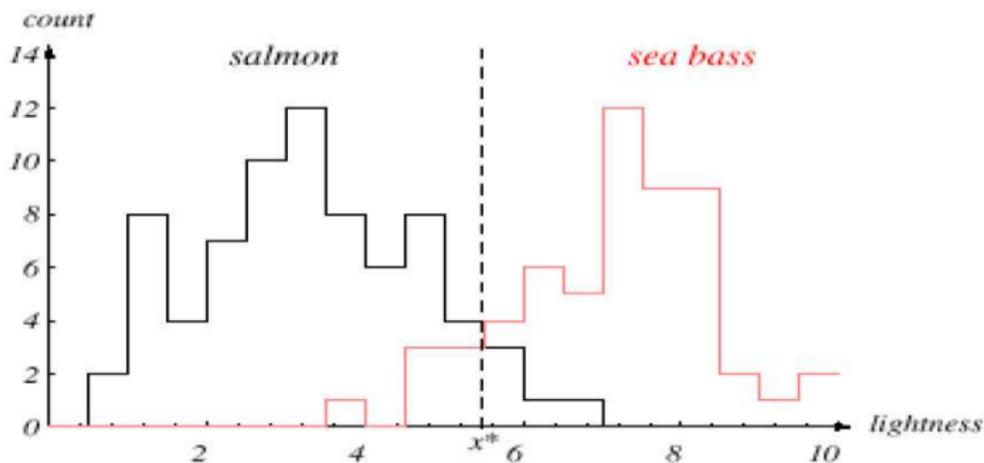
- Сравнение с образцом
  - Применяем геометрическую нормализацию и считаем расстояние до прототипа
- Статистические методы
  - Строим распределение для каждого класса и классифицируем по правилу Байеса
- Нейронные сети
  - Выбираем вид сети и настраиваем коэффициенты
- Структурные и синтаксические методы
  - Разбираем объект на элементы. Строим правило, в зависимости от вхождения/невхождения отдельных элементов и их последовательностей

В какие группы можно отнести методы из прошлой лекции?



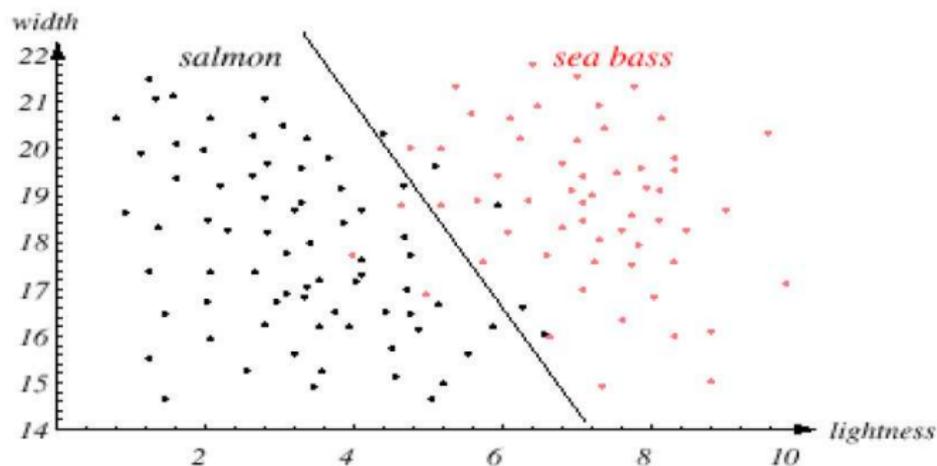
Пытаемся различить лосося и морского окуня. Длина — не идеальная характеристика.

## Пример II



Окраска также не позволяет разделить эти два вида

## Пример III



Комбинация двух характеристик дает лучший результат.

# План лекции

- 1 Общие принципы распознавания образов  
Постановка и применения  
Методы распознавания
- 2 Курс математической статистики в 5 слайдах**
- 3 Статистические методы распознавания образов
- 4 Задача

## Распределение (плотность распределения):

Каждому значению сопоставляет его вероятность

## Распределение (плотность распределения):

Каждому значению сопоставляет его вероятность

## Выборка

Набор значений случайной величины  $X_1, \dots, X_n$

## Распределение (плотность распределения):

Каждому значению сопоставляет его вероятность

## Выборка

Набор значений случайной величины  $X_1, \dots, X_n$

## (Статистическая) оценка

Любая функция от выборки  $T(X_1, \dots, X_n)$

# Две задачи мат. статистики

## Оценка параметров

Предполагаем, что случайная величина принадлежит

# Две задачи мат. статистики

## Оценка параметров

Предполагаем, что случайная величина принадлежит известному распределению с неизвестными параметрами

# Две задачи мат. статистики

## Оценка параметров

Предполагаем, что случайная величина принадлежит известному распределению с неизвестными параметрами  
Даем оценку параметрам

# Две задачи мат. статистики

## Оценка параметров

Предполагаем, что случайная величина принадлежит известному распределению с неизвестными параметрами

Даем оценку параметрам

Оценки: точечные и интервальные

# Две задачи мат. статистики

## Оценка параметров

Предполагаем, что случайная величина принадлежит известному распределению с неизвестными параметрами

Даем оценку параметрам

Оценки: точечные и интервальные

Требования к точечным: несмещенность и состоятельность

# Две задачи мат. статистики

## Оценка параметров

Предполагаем, что случайная величина принадлежит известному распределению с неизвестными параметрами

Даем оценку параметрам

Оценки: точечные и интервальные

Требования к точечным: несмещенность и состоятельность

## Проверка гипотез

Не знаем распределения

# Две задачи мат. статистики

## Оценка параметров

Предполагаем, что случайная величина принадлежит известному распределению с неизвестными параметрами

Даем оценку параметрам

Оценки: точечные и интервальные

Требования к точечным: несмещенность и состоятельность

## Проверка гипотез

Не знаем распределения

Делаем предположение о распределении ( $H_0$ )

# Две задачи мат. статистики

## Оценка параметров

Предполагаем, что случайная величина принадлежит известному распределению с неизвестными параметрами

Даем оценку параметрам

Оценки: точечные и интервальные

Требования к точечным: несмещенность и состоятельность

## Проверка гипотез

Не знаем распределения

Делаем предположение о распределении ( $H_0$ )

По выборке принимаем/отвергаем  $H_0$

# Две задачи мат. статистики

## Оценка параметров

Предполагаем, что случайная величина принадлежит известному распределению с неизвестными параметрами

Даем оценку параметрам

Оценки: точечные и интервальные

Требования к точечным: несмещенность и состоятельность

## Проверка гипотез

Не знаем распределения

Делаем предположение о распределении ( $H_0$ )

По выборке принимаем/отвергаем  $H_0$

Ошибка первого рода (отвергли правильное распределение) должна быть меньше  $\alpha$

# Правило Байеса I

**Данные:**

Два распределения  $A$  и  $B$

Значение  $X$ , порожденное одной из этих случайных величин

**Определить:** какой из них?

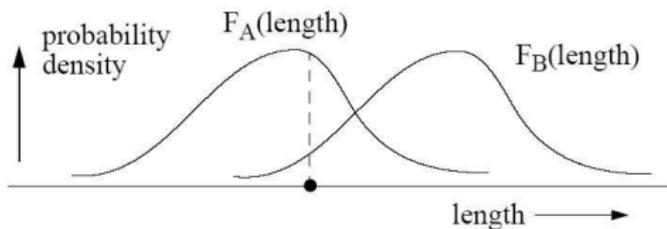
# Правило Байеса I

## Данные:

Два распределения  $A$  и  $B$

Значение  $X$ , порожденное одной из этих случайных величин

**Определить:** какой из них?



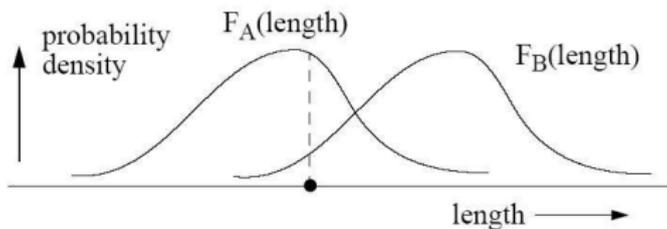
# Правило Байеса I

**Данные:**

Два распределения  $A$  и  $B$

Значение  $X$ , порожденное одной из этих случайных величин

**Определить:** какой из них?



**Интуиция:** Надо выбирать  $A$ , если

$$Prob(A|X) > Prob(B|X)$$

Немного преобразований:

$$Prob(A|X)Prob(X) = Prob(A, X) = Prob(A)Prob(X|A)$$

Немного преобразований:

$$Prob(A|X)Prob(X) = Prob(A, X) = Prob(A)Prob(X|A)$$

$$\begin{aligned} Prob(A|X) &= \frac{Prob(X|A)Prob(A)}{Prob(X)} \\ &= \frac{Prob(X|A)Prob(A)}{Prob(X|A)Prob(A) + Prob(X|B)Prob(B)} \end{aligned}$$

Немного преобразований:

$$Prob(A|X)Prob(X) = Prob(A, X) = Prob(A)Prob(X|A)$$

$$\begin{aligned} Prob(A|X) &= \frac{Prob(X|A)Prob(A)}{Prob(X)} \\ &= \frac{Prob(X|A)Prob(A)}{Prob(X|A)Prob(A) + Prob(X|B)Prob(B)} \end{aligned}$$

$$Prob(A|X) = \frac{F_A(X)P_A}{F_A(X)P_A + F_B(X)P_B}$$

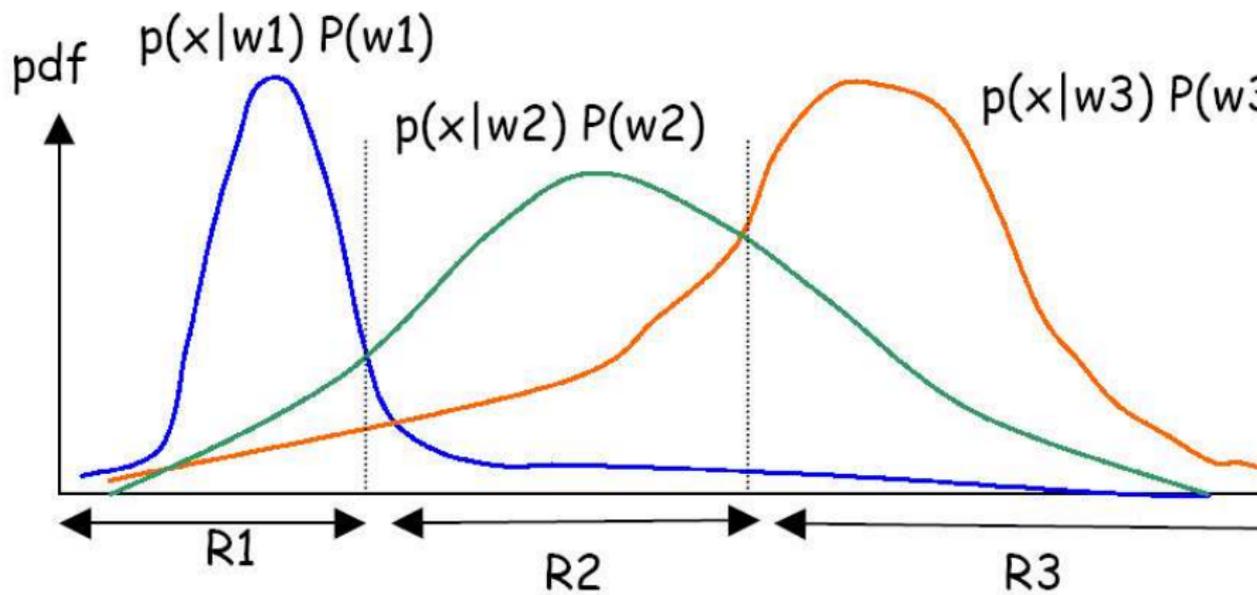
Немного преобразований:

$$Prob(A|X)Prob(X) = Prob(A, X) = Prob(A)Prob(X|A)$$

$$\begin{aligned} Prob(A|X) &= \frac{Prob(X|A)Prob(A)}{Prob(X)} \\ &= \frac{Prob(X|A)Prob(A)}{Prob(X|A)Prob(A) + Prob(X|B)Prob(B)} \end{aligned}$$

$$Prob(A|X) = \frac{F_A(X)P_A}{F_A(X)P_A + F_B(X)P_B}$$

**Правило Байеса:** Надо выбирать  $A$ , если  
 $F_A(X)P_A > F_B(X)P_B$



## Постановка задачи

Проверяемое распределение  $D$

Выборка  $X_1, \dots, X_n$

**Принять/отвергнуть:** “выборка принадлежит  $D$ ”

## Постановка задачи

Проверяемое распределение  $D$

Выборка  $X_1, \dots, X_n$

**Принять/отвергнуть:** “выборка принадлежит  $D$ ”

## Вычисления

Разбиваем область значений на  $m$  классов

Пусть  $n_j$  — кол-во элементов выборки в классе  $j$

Пусть  $p_j$  — вероятность попасть в класс  $j$

согласно  $D$ . Обозначим  $n'_j = np_j$

Вычисляем функцию:

$$T = \sum_{j=1}^m \frac{(n_j - n'_j)^2}{n'_j}$$

## Постановка задачи

Проверяемой распределение  $D$

Выборка  $X_1, \dots, X_n$

**Принять/отвергнуть:** “выборка принадлежит  $D$ ”

## Вычисления

Разбиваем область значений на  $m$  классов

Пусть  $n_j$  — кол-во элементов выборки в классе  $j$

Пусть  $p_j$  — вероятность попасть в класс  $j$

согласно  $D$ . Обозначим  $n'_j = np_j$

Вычисляем функцию:

$$T = \sum_{j=1}^m \frac{(n_j - n'_j)^2}{n'_j}$$

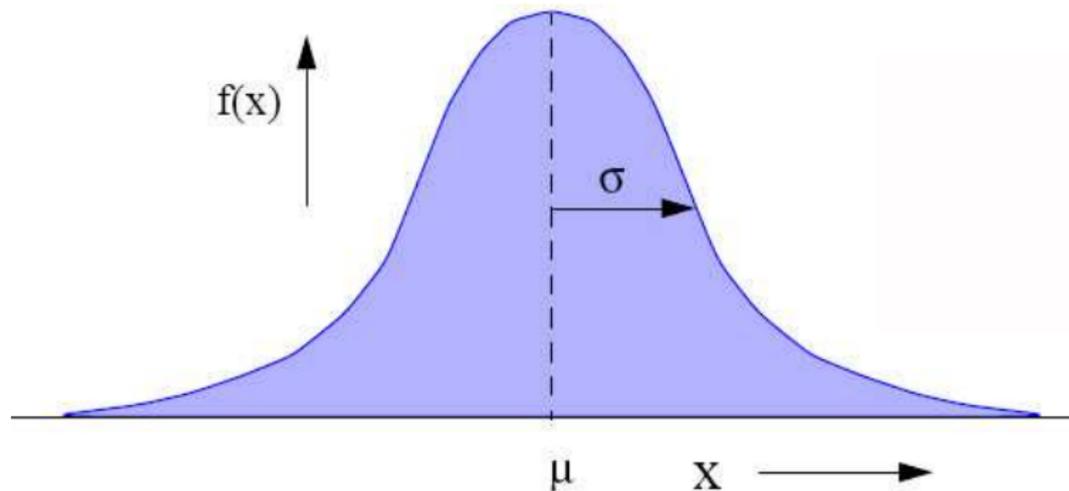
## Критический уровень

Если  $T < t$ , принимаем гипотезу,  $T \geq t$  — отвергаем

Значение  $t$  определяется как функция от  $\alpha$  и  $k$

**Пример:**  $\alpha = 0.05$ ,  $k = 5 \Rightarrow t = 11.1$

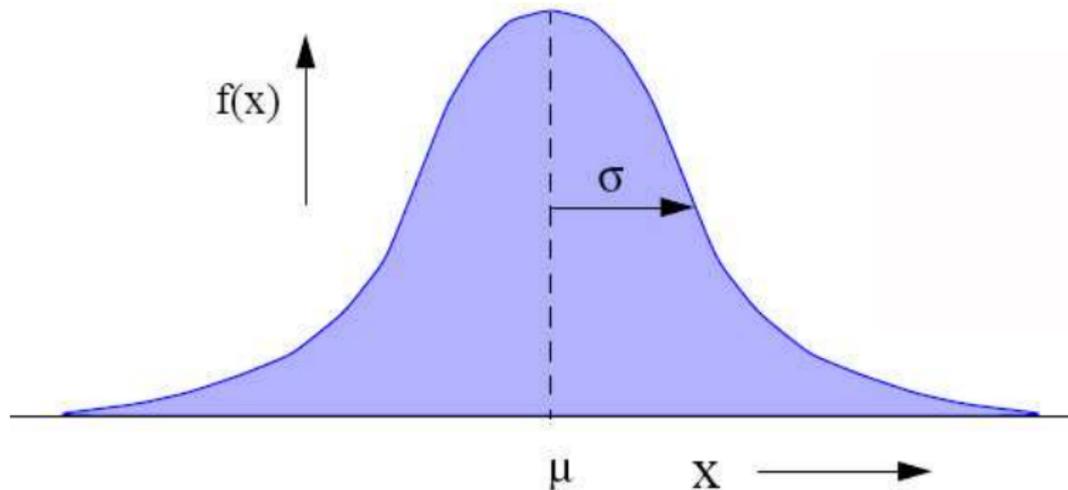
# Нормальное распределение



Функция плотности нормального распределения:

$$\frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2}$$

# Нормальное распределение



Функция плотности нормального распределения:

$$\frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2}$$

**Два параметра:**  $\mu$  — математическое ожидание и  $\sigma$  — дисперсия

# План лекции

- 1 Общие принципы распознавания образов  
Постановка и применения  
Методы распознавания
- 2 Курс математической статистики в 5 слайдах
- 3 Статистические методы распознавания образов**
- 4 Задача

## Задача

Дана тренировочная коллекция

Каждый объект = набор  $n$  характеристик =  $n$ -мерный вектор

Построить классифицирующее правило

## Задача

Дана тренировочная коллекция

Каждый объект = набор  $n$  характеристик =  $n$ -мерный вектор

Построить классифицирующее правило

## Предпосылки

Считаем, что элементы каждой категории имеют свое распределение в  $n$ -мерном пространстве

Будем принимать решение по правилу Байеса!

## Задача

Дана тренировочная коллекция

Каждый объект = набор  $n$  характеристик =  $n$ -мерный вектор

Построить классифицирующее правило

## Предпосылки

Считаем, что элементы каждой категории имеют свое распределение в  $n$ -мерном пространстве

Будем принимать решение по правилу Байеса!

Чего не хватает для полного счастья?

## Задача

Дана тренировочная коллекция

Каждый объект = набор  $n$  характеристик =  $n$ -мерный вектор

Построить классифицирующее правило

## Предпосылки

Считаем, что элементы каждой категории имеют свое распределение в  $n$ -мерном пространстве

Будем принимать решение по правилу Байеса!

Чего не хватает для полного счастья?

**Ответ:** функций распределения для каждой категории

# Строим функции распределения

**Нам известны функции распределения**

Просто используем правило Байеса

# Строим функции распределения

**Нам известны функции распределения**

Просто используем правило Байеса

**Известен тип, но не параметры**

**Пример:** нормальное распределение с неизвестными  $\mu, \sigma$

Используем точечные оценки:  $\hat{\mu} = \frac{X_1 + \dots + X_n}{n}$

$$\hat{\sigma} = \sqrt{\frac{1}{n-1} \sum (X_i - \hat{\mu})^2}$$

# Строим функции распределения

**Нам известны функции распределения**

Просто используем правило Байеса

**Известен тип, но не параметры**

**Пример:** нормальное распределение с неизвестными  $\mu, \sigma$

Используем точечные оценки:  $\hat{\mu} = \frac{X_1 + \dots + X_n}{n}$

$$\hat{\sigma} = \sqrt{\frac{1}{n-1} \sum (X_i - \hat{\mu})^2}$$

В чем разница с одномерным методом Rocchio?

# Строим функции распределения

## Нам известны функции распределения

Просто используем правило Байеса

## Известен тип, но не параметры

**Пример:** нормальное распределение с неизвестными  $\mu, \sigma$

Используем точечные оценки:  $\hat{\mu} = \frac{X_1 + \dots + X_n}{n}$

$$\hat{\sigma} = \sqrt{\frac{1}{n-1} \sum (X_i - \hat{\mu})^2}$$

В чем разница с одномерным методом Rocchio?

## Неизвестное распределение

Мы должны построить его по тренировочной коллекции!

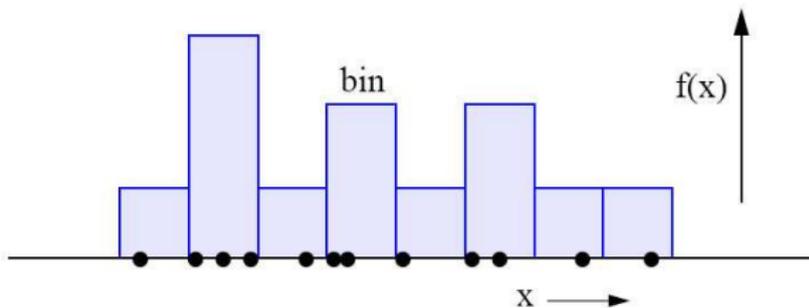
## Построим функцию распределения “в лоб”

Разобъем  $n$ -мерное пространство на клеточки  
для каждой клетки определим плотность распределения  
как долю всех документов, попавших в клетку

# Метод гистограмм

## Построим функцию распределения “в лоб”

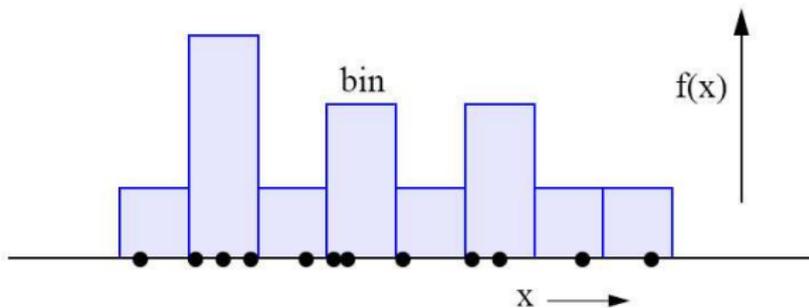
Разобьем  $n$ -мерное пространство на клеточки  
для каждой клетки определим плотность распределения  
как долю всех документов, попавших в клетку



# Метод гистограмм

## Построим функцию распределения “в лоб”

Разобьем  $n$ -мерное пространство на клетки  
для каждой клетки определим плотность распределения  
как долю всех документов, попавших в клетку



**Недостаток:** для большой размерности нужна огромная  
тренировочная коллекция

## Идея метода

Для каждой точки из класса построим функцию, достигающую максимума в этой точке и быстро убывающей при удалении от нее  
Сложим такие функции для всех точек

## Идея метода

Для каждой точки из класса построим функцию, достигающую максимума в этой точке и быстро убывающей при удалении от нее  
Сложим такие функции для всех точек

Что это вам напоминает?

## Идея метода

Для каждой точки из класса построим функцию, достигающую максимума в этой точке и быстро убывающей при удалении от нее  
Сложим такие функции для всех точек

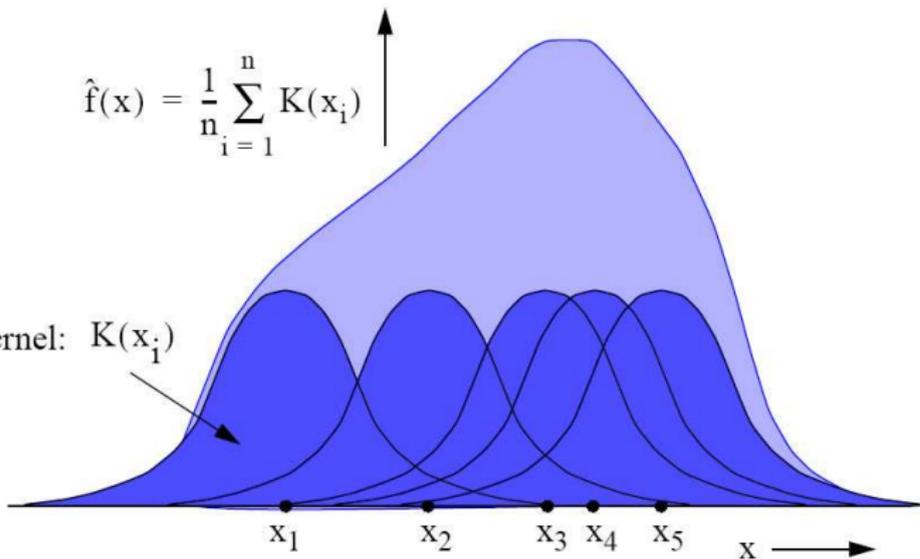
Что это вам напоминает? Сравните с kNN-методом.

$$\hat{f}(x) =$$

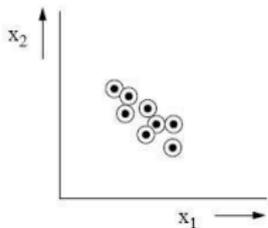


$$\hat{f}(x) = \frac{1}{n} \sum_{i=1}^n K(x_i)$$

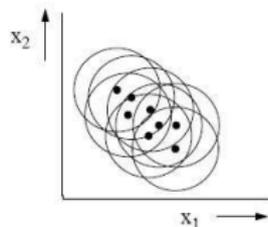
Kernel:  $K(x_i)$



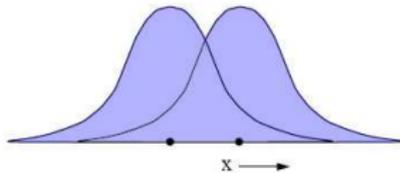
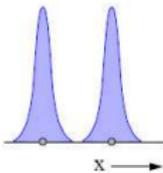
Как выбрать форму ядра? Слишком маленькая/большая форма может ухудшить качество распознавания:



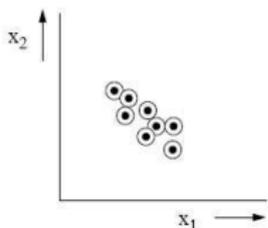
Too small: lot of empty space.



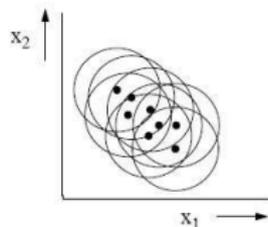
Too wide: estimated density is dominated by kernel shape.



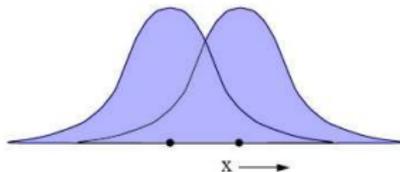
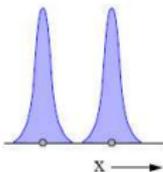
Как выбрать форму ядра? Слишком маленькая/большая форма может ухудшить качество распознавания:



Too small: lot of empty space.



Too wide: estimated density is dominated by kernel shape.



**Решение:** выбирать радиус ядра, чтобы в него попало 5 ближайших тренировочных документов

- 1 Общие принципы распознавания образов  
Постановка и применения  
Методы распознавания
- 2 Курс математической статистики в 5 слайдах
- 3 Статистические методы распознавания образов
- 4 Задача**

## Открытый вопрос от А.Куликова

Пусть есть граф из  $n$  вершин, степень каждой вершины не больше трех. Для какой наименьшей функции  $f(n)$  всегда можно разбить вершины на две группы по  $n/2$  так, чтобы между ними было не более  $f(n)$  ребер?

## Открытый вопрос от А.Куликова

Пусть есть граф из  $n$  вершин, степень каждой вершины не больше трех. Для какой наименьшей функции  $f(n)$  всегда можно разбить вершины на две группы по  $n/2$  так, чтобы между ними было не более  $f(n)$  ребер?

Гипотеза:  $f(n) = c \cdot n$  для некоторого  $c$

# Открытый вопрос от А.Куликова

Пусть есть граф из  $n$  вершин, степень каждой вершины не больше трех. Для какой наименьшей функции  $f(n)$  всегда можно разбить вершины на две группы по  $n/2$  так, чтобы между ними было не более  $f(n)$  ребер?

Гипотеза:  $f(n) = c \cdot n$  для некоторого  $c$

Нижние оценки. Можете ли придумать граф, в котором в любом разрезе будет хотя бы  $\log n$  ребер?

# Открытый вопрос от А.Куликова

Пусть есть граф из  $n$  вершин, степень каждой вершины не больше трех. Для какой наименьшей функции  $f(n)$  всегда можно разбить вершины на две группы по  $n/2$  так, чтобы между ними было не более  $f(n)$  ребер?

Гипотеза:  $f(n) = c \cdot n$  для некоторого  $c$

Нижние оценки. Можете ли придумать граф, в котором в любом разрезе будет хотя бы  $\log n$  ребер?

Задача имеет приложения в разработке эффективных алгоритмов

Если не запомните ничего другого:

- Распознавание образов: восприятие, характеристик, классификация

Если не запомните ничего другого:

- Распознавание образов: восприятие, характеристик, классификация
- Статистический метод: угадываем распределение и применяем правило Байеса

## Если не запомните ничего другого:

- Распознавание образов: восприятие, характеристик, классификация
- Статистический метод: угадываем распределение и применяем правило Байеса
- Метод Парзена: суммируем ядра вокруг всех тренировочных документов

## Если не запомните ничего другого:

- Распознавание образов: восприятие, характеристик, классификация
- Статистический метод: угадываем распределение и применяем правило Байеса
- Метод Парзена: суммируем ядра вокруг всех тренировочных документов

## Если не запомните ничего другого:

- Распознавание образов: восприятие, характеристик, классификация
- Статистический метод: угадываем распределение и применяем правило Байеса
- Метод Парзена: суммируем ядра вокруг всех тренировочных документов

Вопросы?