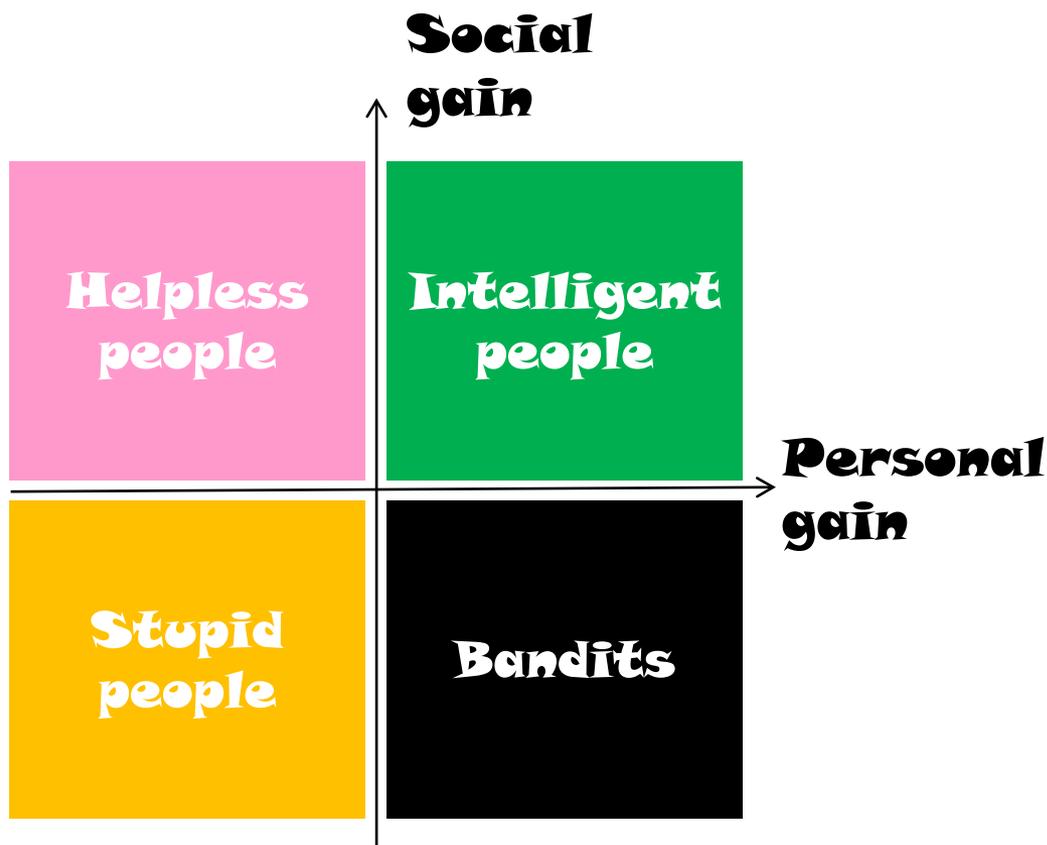


Задача классификации данных

*Классификация – нить Ариадны
в лабиринте природы.*

Жорж Санд



Cipolla C.M. The basic laws of human stupidity. Bologna: il Mulino, 2011

Содержание

- **Общий подход к классификации**
- **Деревья решений**
- Ансамблевая классификация
- Оценка качества классификации

Задача классификации

- Построение формальной модели, которая распределяет объекты, имеющие одинаковую структуру по заранее известным группам (классам) в зависимости от схожести атрибутов объектов
- Основные задачи классификации
 - **Предсказание:** назначить корректный класс объекту, который предварительно не был рассмотрен
 - **Описание:** указать способ, с помощью которого можно отличать объекты различных классов

Пример: анализ оттока клиентов



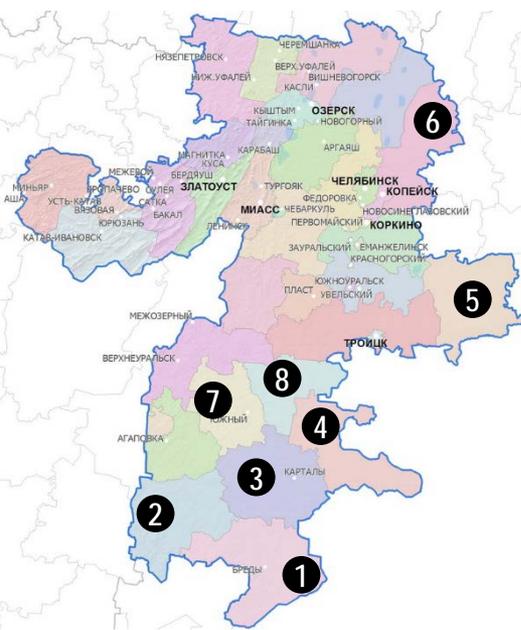
| # | Sex | Age | Day calls | Day charge | Eve calls | Eve charge | Night calls | Night charge | Intl calls | Intl charge | Plan | ... | CHURN |
|---|-----|-----|-----------|------------|-----------|------------|-------------|--------------|------------|-------------|------|-----|-------|
| 1 | M | 24 | 110 | 45.07 | 99 | 16.78 | 91 | 11.01 | 3 | 2.7 | A | | YES |
| 2 | M | 28 | 123 | 27.47 | 103 | 16.62 | 103 | 11.45 | 3 | 3.7 | B | | NO |
| 3 | F | 29 | 114 | 41.38 | 110 | 10.3 | 104 | 7.32 | 5 | 3.29 | C | | YES |
| 4 | M | 33 | 71 | 50.9 | 88 | 5.26 | 89 | 8.86 | 7 | 1.78 | A | | YES |
| 5 | M | 53 | 113 | 28.34 | 122 | 12.61 | 121 | 8.41 | 3 | 2.73 | C | | NO |
| 6 | M | 37 | 98 | 37.98 | 101 | 18.75 | 118 | 9.18 | 6 | 1.7 | A | | YES |
| 7 | F | 78 | 88 | 37.09 | 108 | 29.62 | 118 | 9.57 | 7 | 2.03 | B | | NO |
| 8 | M | 63 | 79 | 26.69 | 94 | 8.76 | 96 | 9.53 | 6 | 1.92 | B | | NO |
| 9 | F | 46 | 97 | 31.37 | 80 | 29.89 | 90 | 9.71 | 4 | 2.35 | A | | NO |
| | | | | | ... | | | | | | | | |

Определить, уйдет ли клиент к другому оператору

Пример: поиск полезных ископаемых



| # | $\text{FeSO}_4 \cdot 7\text{H}_2\text{O}$ | | $\text{NH}_4\text{H}_2\text{PO}_4$ | | $(\text{Na,Ca})(\text{Si,Al})_4\text{O}_8$ | | $\text{SiO}_2 \cdot n\text{H}_2\text{O}$ | | $\text{LiAlSi}_4\text{O}_{10}$ | | ... | Минерал |
|---|---|-----------|------------------------------------|-----------|--|-----------|--|-----------|--------------------------------|-----------|-----|---------|
| | Наличие | Плотность | Наличие | Плотность | Наличие | Плотность | Наличие | Плотность | Наличие | Плотность | | |
| 1 | Да | 3.40 | Нет | - | Да | 7.80 | Нет | - | Да | 23.92 | | Железо |
| 2 | Нет | - | Да | 7.22 | Да | 2.97 | Да | 5.97 | Да | 16.54 | | Медь |
| 3 | Да | 4.67 | Да | 5.45 | Да | 5.43 | Да | 8.95 | Да | 28.49 | | Серебро |
| 4 | Нет | - | Да | 3.12 | Нет | - | Да | 9.12 | Нет | - | | Цинк |
| 5 | Да | 2.78 | Да | 0.18 | Нет | - | Нет | - | Да | 25.02 | | Железо |
| 6 | Да | 1.02 | Нет | - | Нет | - | Да | 1.23 | Да | 2.12 | | НЕТ |
| 7 | Да | 0.75 | Нет | - | Нет | - | Да | 3.10 | Да | 2.99 | | НЕТ |
| 8 | Нет | - | Да | 0.36 | Да | 2.08 | Нет | - | Нет | - | | НЕТ |



Пример: классификация позвоночных

| Vertebrate Name | Body Temperature | Skin Cover | Gives Birth | Aquatic Creature | Aerial Creature | Has Legs | Hibernates | Class Label |
|-----------------|------------------|------------|-------------|------------------|-----------------|----------|------------|-------------|
| human | warm-blooded | hair | yes | no | no | yes | no | mammal |
| python | cold-blooded | scales | no | no | no | no | yes | reptile |
| salmon | cold-blooded | scales | no | yes | no | no | no | fish |
| whale | warm-blooded | hair | yes | yes | no | no | no | mammal |
| frog | cold-blooded | none | no | semi | no | yes | yes | amphibian |
| komodo dragon | cold-blooded | scales | no | no | no | yes | no | reptile |
| bat | warm-blooded | hair | yes | no | yes | yes | yes | mammal |
| pigeon | warm-blooded | feathers | no | no | yes | yes | no | bird |
| cat | warm-blooded | fur | yes | no | no | yes | no | mammal |
| leopard | cold-blooded | scales | yes | yes | no | no | no | fish |
| shark | | | | | | | | |
| turtle | cold-blooded | scales | no | semi | no | yes | no | reptile |
| penguin | warm-blooded | feathers | no | semi | no | yes | no | bird |
| porcupine | warm-blooded | quills | yes | no | no | yes | yes | mammal |
| eel | cold-blooded | scales | no | yes | no | no | no | fish |
| salamander | cold-blooded | none | no | semi | no | yes | yes | amphibian |


Атрибуты и метки класса

| Приложение | Набор атрибутов | Метка класса |
|-------------------------------------|---|--|
| Кредитный скоринг клиентов | Пол, возраст и доход клиента, величина, процент и срок кредита | Надежный / ненадежный |
| Предсказание успеваемости студентов | Пол, курс, местный/приезжий, количество посещений, количество сданных заданий | Отлично / хорошо / удовлетворительно / неудовлетворительно |
| Выявление спама | Характеристики, полученные из заголовка и тела сообщения | Спам / не спам |
| Идентификация опухолей | Характеристики, полученные из снимков МРТ | Злокачественная / доброкачественная |
| Классификация галактик | Характеристики, полученные из снимков с телескопа | Эллиптическая / спиральная / нерегулярной формы |

Процесс классификации: обучение (индукция)

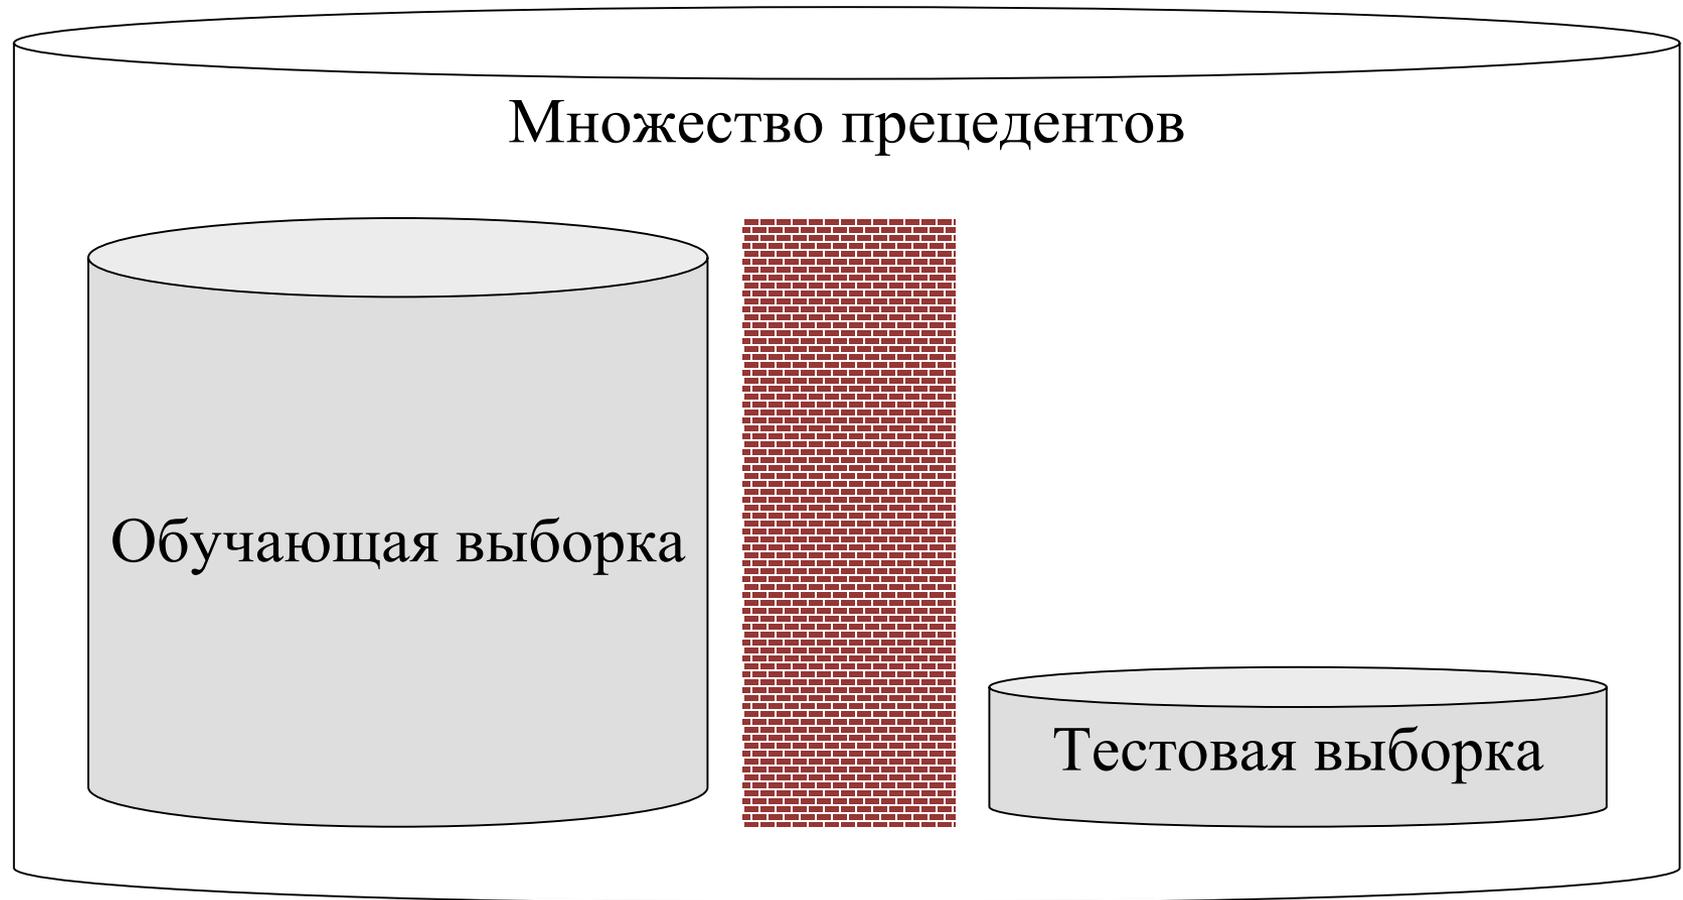
Обучающая выборка

| Name | Income | Age | Credit rating |
|------------------|--------|--------|---------------|
| Peter Parker | low | youth | risky |
| Anakin Skywalker | low | youth | risky |
| Tony Stark | high | middle | safe |
| Han Solo | low | middle | risky |
| Clark Kent | low | senior | risky |
| James Bond | medium | senior | risky |
| Harry Callahan | high | middle | safe |
| Bruce Banner | high | senior | safe |

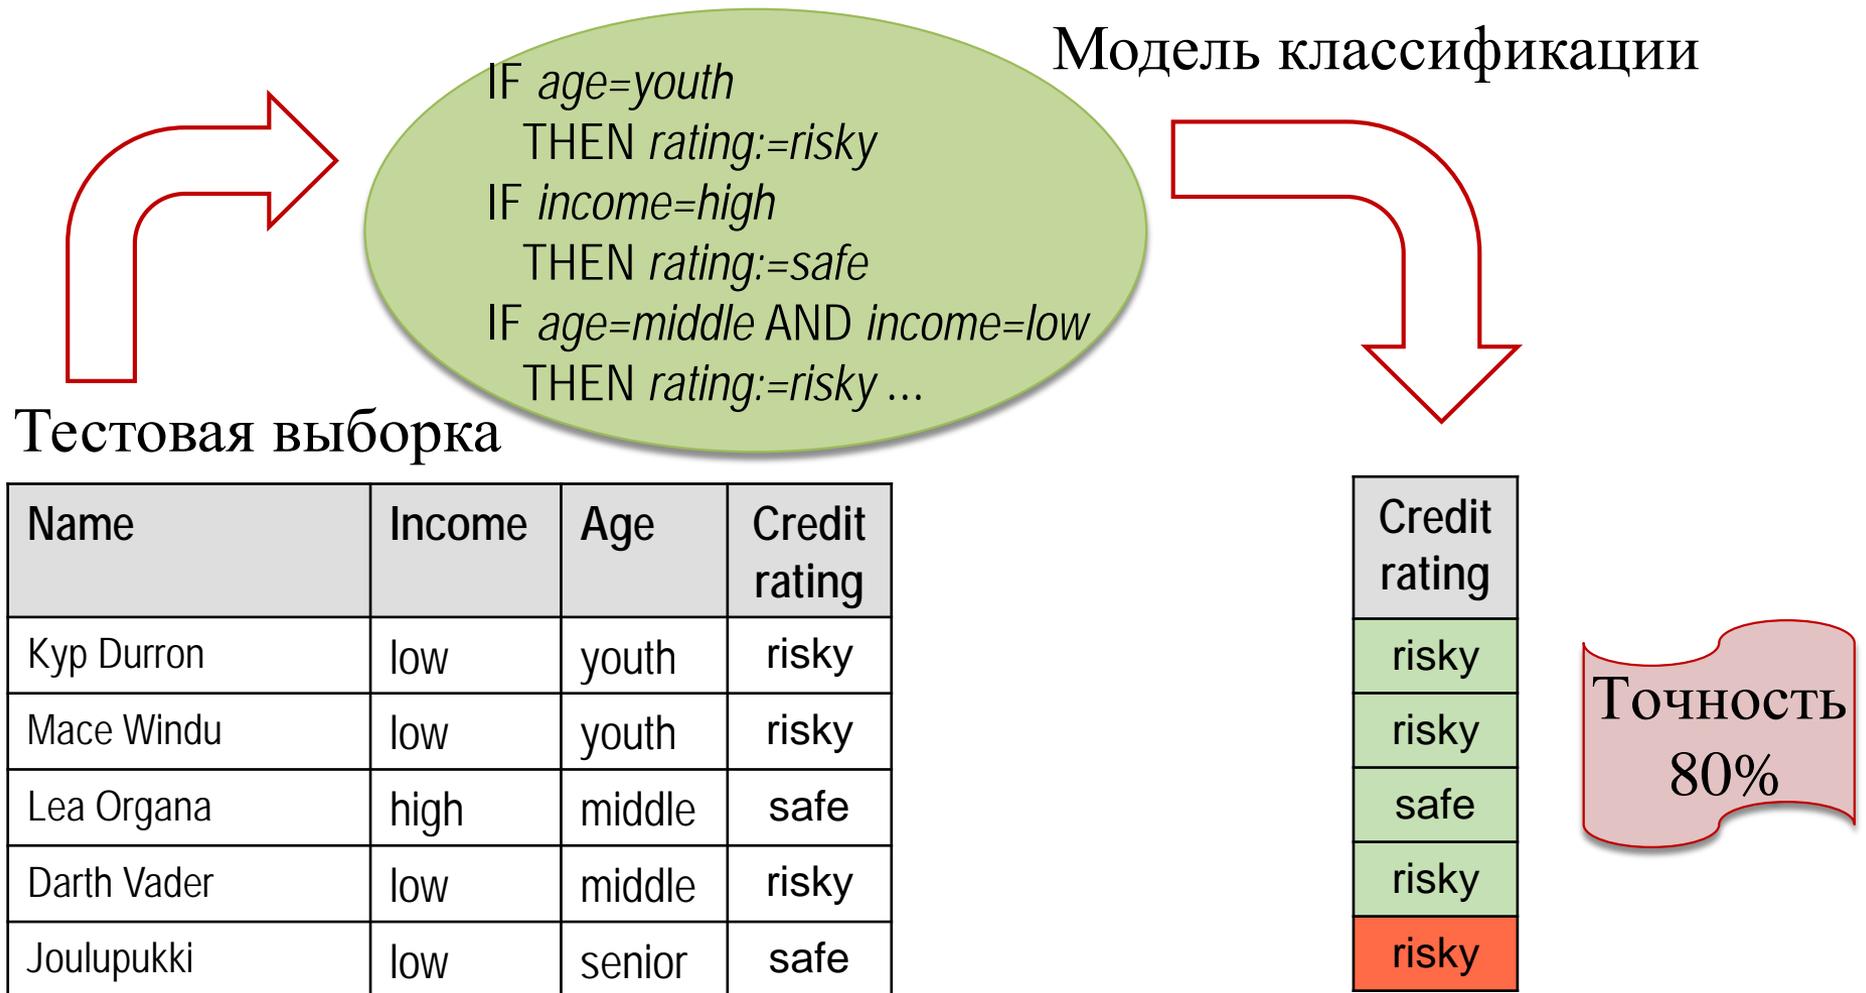


Модель классификации

Процесс классификации: обучающая vs. тестовая выборки



Процесс классификации: оценка модели

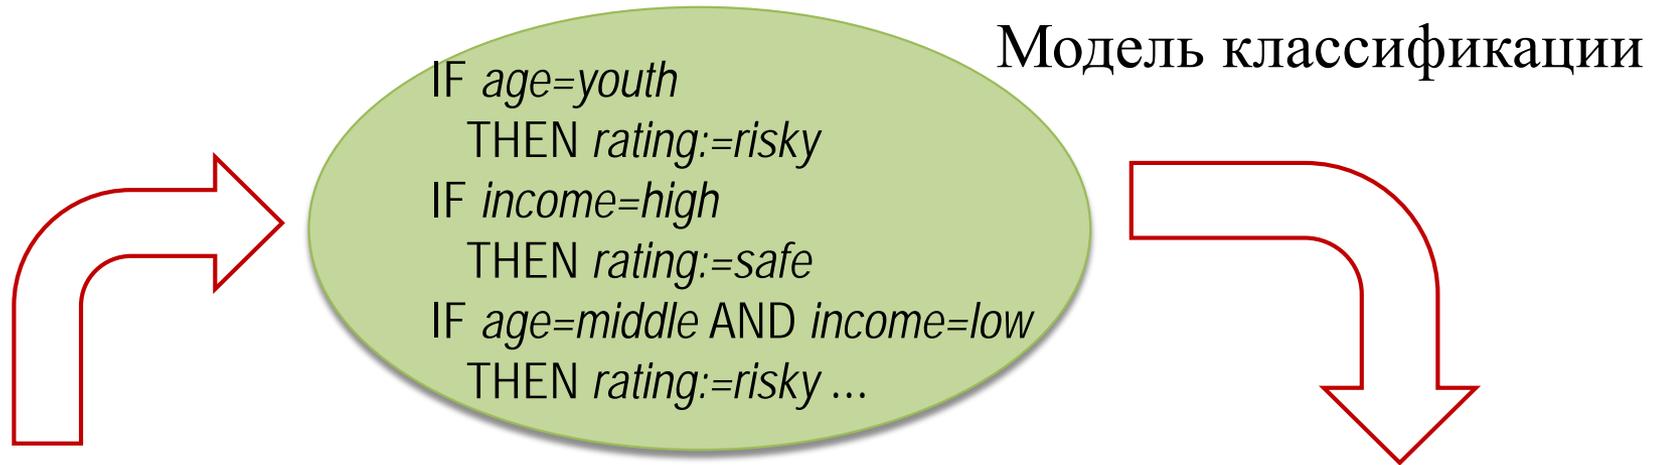


Оценка модели: матрица ошибок

| | | Реальный класс | |
|---------------------|----------|----------------|-----------|
| | | A | B |
| Предсказанный класс | A | <i>TP</i> | <i>FP</i> |
| | B | <i>FN</i> | <i>TN</i> |

- $Accuracy = \frac{TP+TN}{TP+FP+FN+TN}$
- $Error\ rate = \frac{FP+FN}{TP+FP+FN+TN}$

Процесс классификации: применение (дедукция)



Неизвестные данные

| Name | Income | Age |
|--------------------|--------|--------|
| John Doe | low | senior |
| Matti Meikäläinen | high | middle |
| Ivan Ivanov | high | youth |
| Pietro Sconosciuta | low | middle |
| ... | | |

| Credit rating |
|---------------|
| |
| |
| |
| |
| ... |

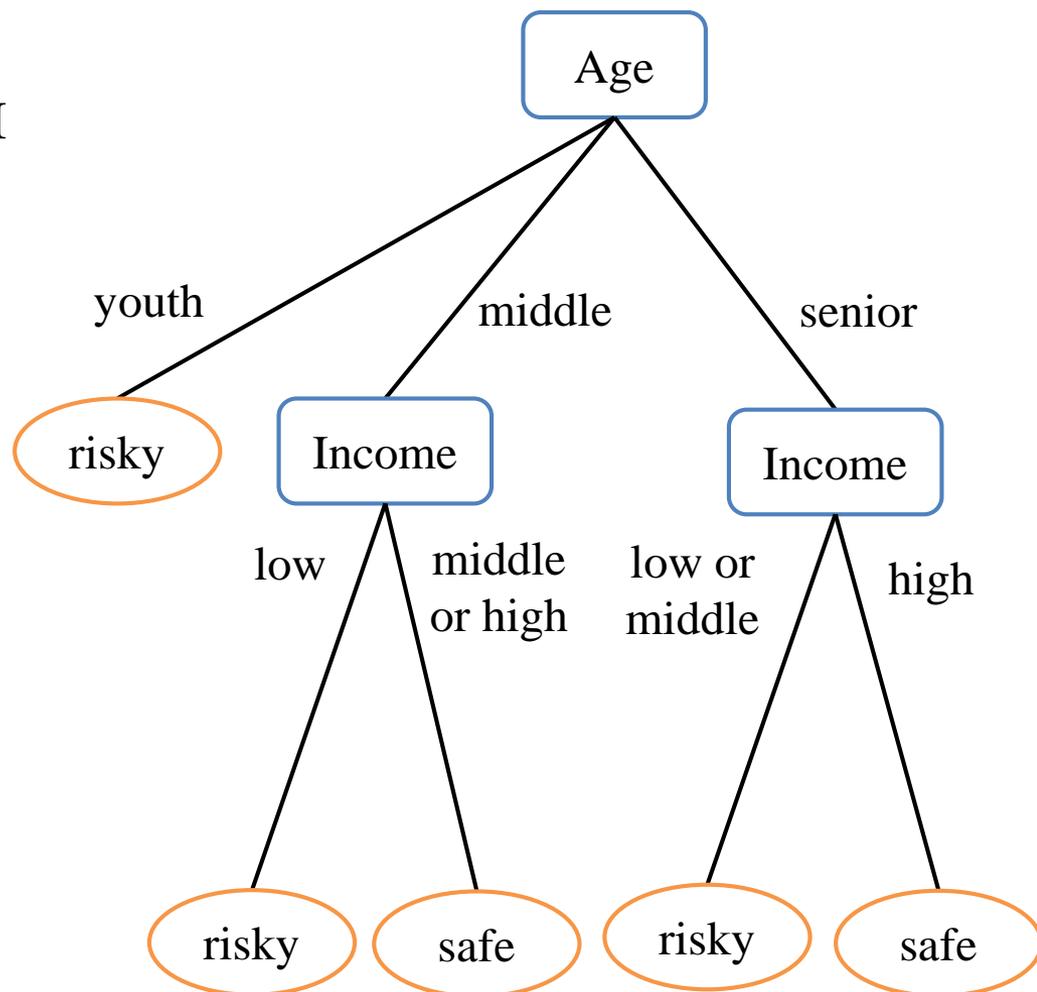
Содержание

- Общий подход к классификации
- **Деревья решений**
- Ансамблевая классификация
- Оценка качества классификации


Деревья решений

- Дерево решений – модель классификации в виде дерева, которое имеет

- корневой узел и внутренние узлы: проверка условия на атрибут объекта
- узлы-листья: метки классов
- ребра: переходы по результату проверки



Деревья решений



- Для применения не требуется компьютер
- Сферы применения: банковское дело, страхование, торговля, медицина, контроль качества продукции

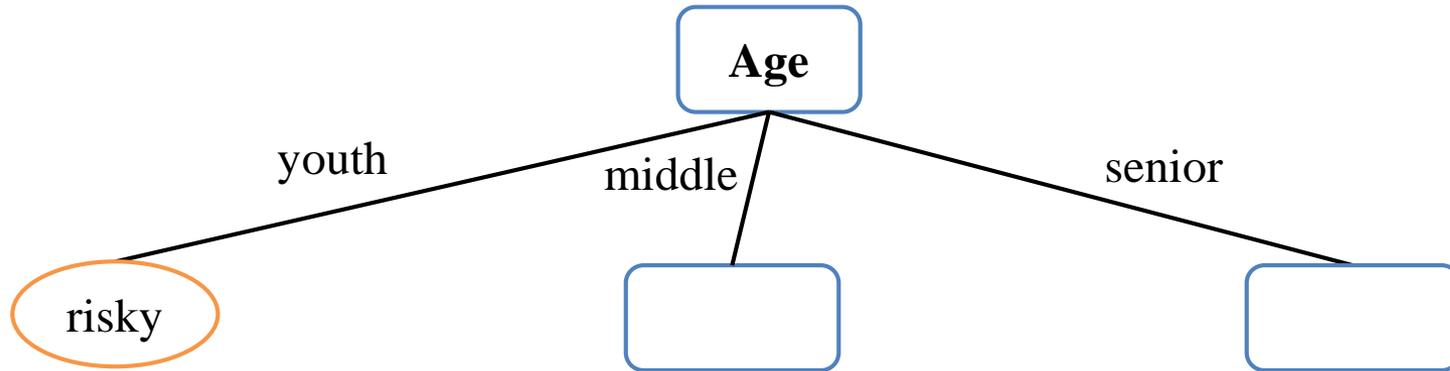
Построение дерева решений

NULL

| Name | Income | Age | Credit rating |
|------------------|--------|--------|---------------|
| Peter Parker | low | youth | risky |
| Anakin Skywalker | low | youth | risky |
| Tony Stark | high | middle | safe |
| Han Solo | low | middle | risky |
| Clark Kent | low | senior | risky |
| James Bond | medium | senior | risky |
| Harry Callahan | high | middle | safe |
| Bruce Banner | high | senior | safe |

- Если все объекты из одного класса, то создать лист с меткой этого класса, иначе выбрать атрибут для разбиения

Построение дерева решений



| Name | Income | Credit rating |
|------------------|--------|---------------|
| Peter Parker | low | risky |
| Anakin Skywalker | low | risky |

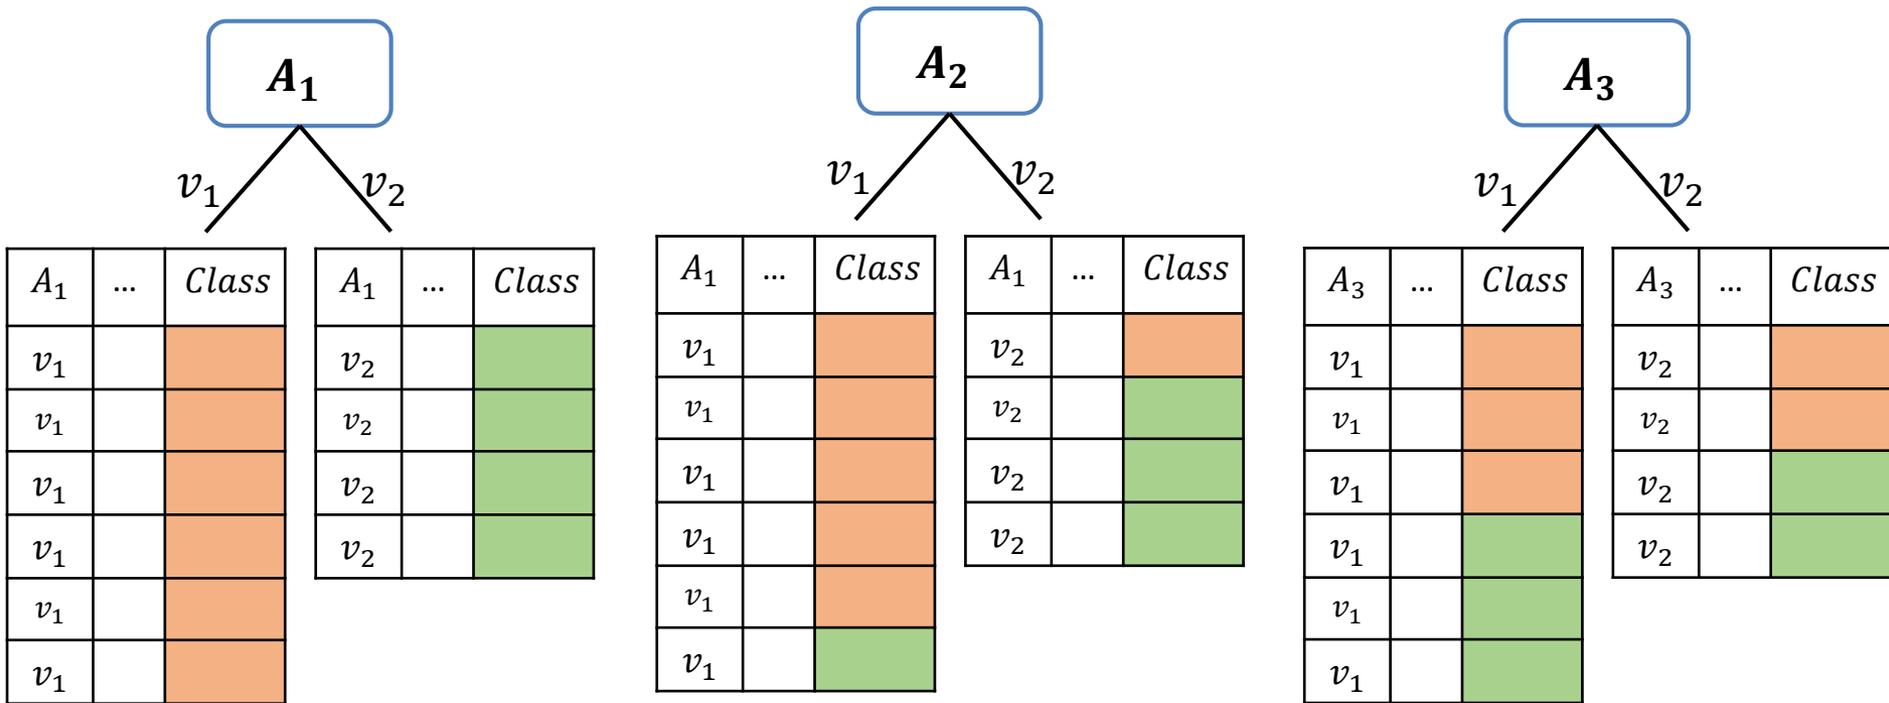
| Name | Income | Credit rating |
|----------------|--------|---------------|
| Tony Stark | high | safe |
| Han Solo | low | risky |
| Harry Callahan | high | safe |

| Name | Income | Credit rating |
|--------------|--------|---------------|
| Clark Kent | low | risky |
| James Bond | medium | risky |
| Bruce Banner | high | safe |

- Разбить выборку в соответствии со значениями выбранного атрибута
- Рекурсивно построить поддеревья

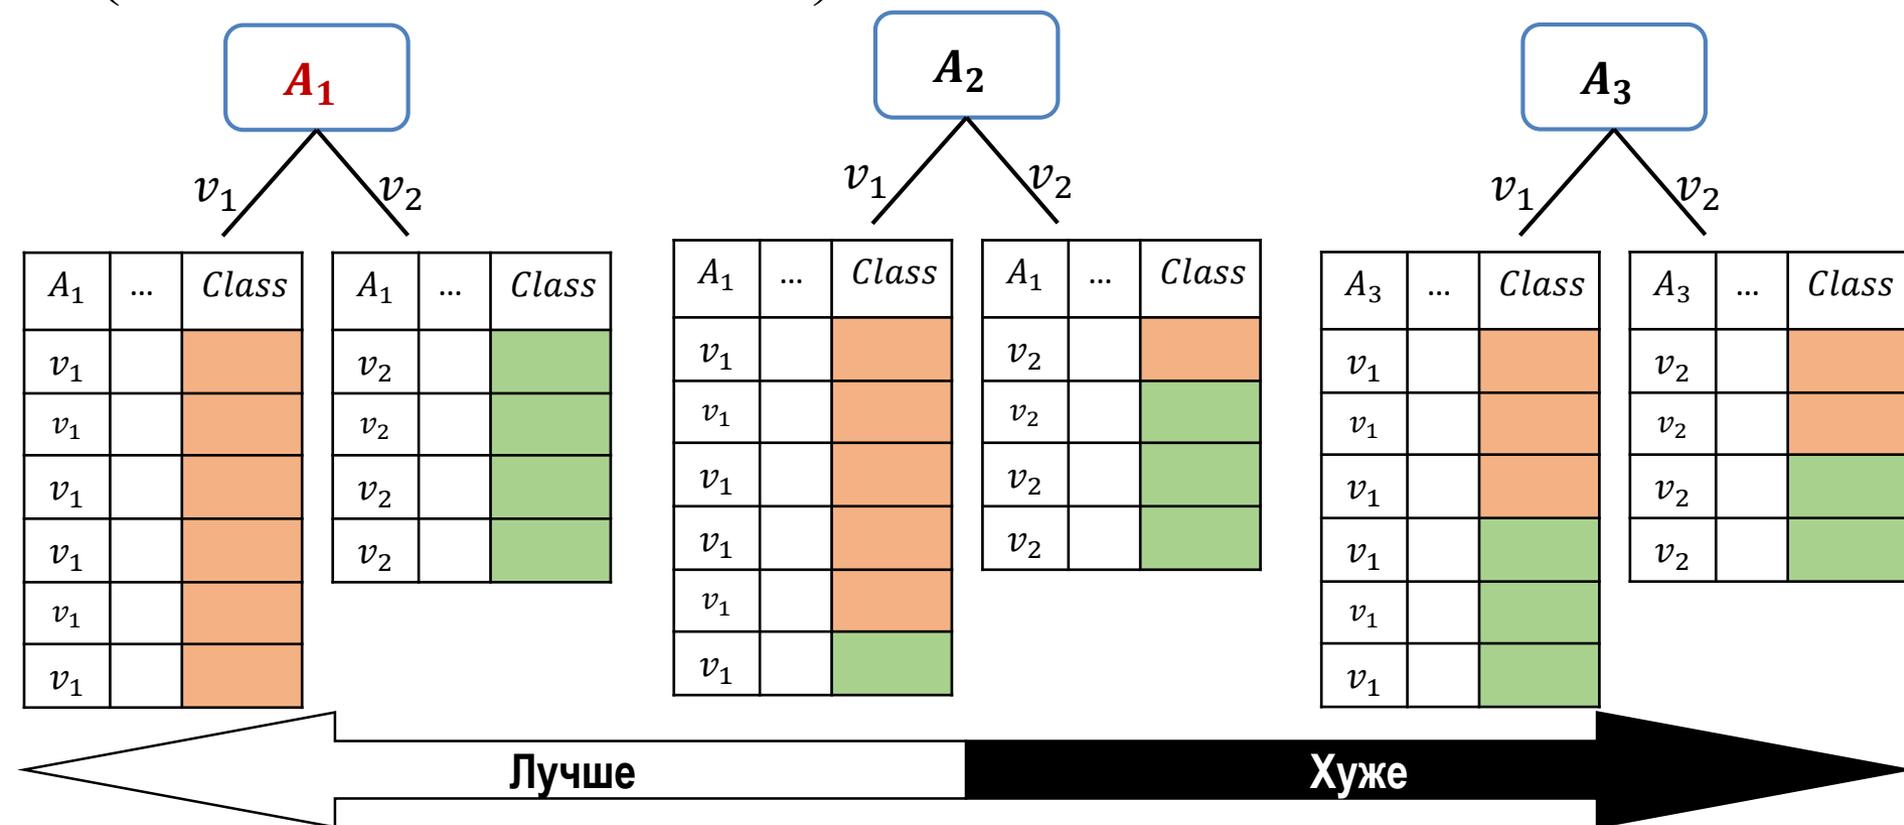
Выбор атрибута разбиения

- Какой атрибут выбрать для разбиения?

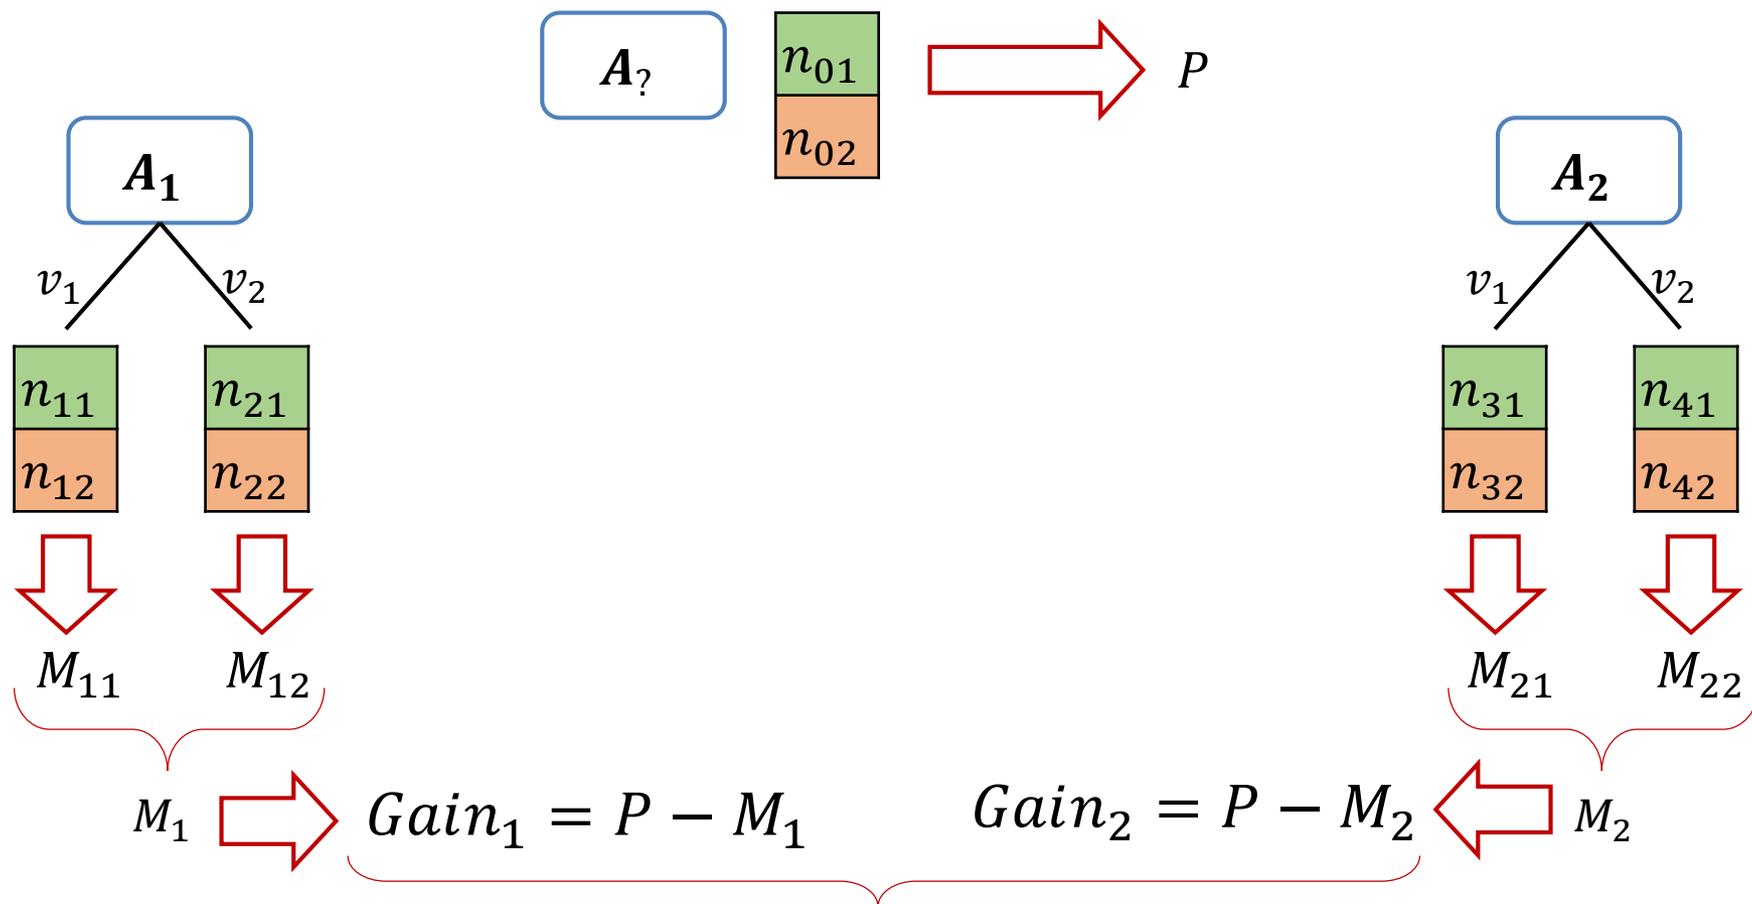


Выбор атрибута разбиения

- Жадный подход*: выбрать атрибут, разбивающий выборку на подмножества с минимальной долей «примесей» (объектов иного класса)



Критерий выбора атрибута – прирост информации



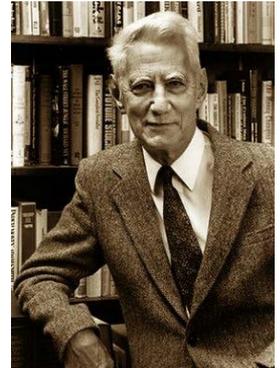
$$A_? = \arg \max\{Gain_1, Gain_2\}$$

Оценка доли примесей с помощью энтропии

$$Entropy = - \sum_{i=1}^n p_i \cdot \log_2 p_i$$

n – количество классов

p_i – вероятность объектов i -го класса в выборке узла



Клод Шеннон
1916-2001

to be, or not to be, that is the question

| i | Sym | num | p | -p*log2(p) |
|----|-------|-----|------|------------|
| 1 | space | 9 | 0.22 | 0.48 |
| 2 | comma | 2 | 0.05 | 0.21 |
| 3 | a | 1 | 0.02 | 0.13 |
| 4 | b | 2 | 0.05 | 0.21 |
| 5 | e | 4 | 0.10 | 0.33 |
| 6 | h | 2 | 0.05 | 0.21 |
| 7 | i | 2 | 0.05 | 0.21 |
| 8 | n | 2 | 0.05 | 0.21 |
| 9 | o | 5 | 0.12 | 0.37 |
| 10 | q | 1 | 0.02 | 0.13 |
| 11 | r | 1 | 0.02 | 0.13 |
| 12 | s | 2 | 0.05 | 0.21 |
| 13 | t | 7 | 0.17 | 0.44 |
| 14 | u | 1 | 0.02 | 0.13 |
| | | 41 | | 3.41 |

аааааааааааааааа...а

| i | Sym | num | p | -p*log2(p) |
|----|-----|-----|------|------------|
| 1 | a | 41 | 1.00 | 0.00 |
| 2 | | | | |
| 3 | | | | |
| 4 | | | | |
| 5 | | | | |
| 6 | | | | |
| 7 | | | | |
| 8 | | | | |
| 9 | | | | |
| 10 | | | | |
| 11 | | | | |
| 12 | | | | |
| 13 | | | | |
| 14 | | | | |
| | | 41 | | 0.00 |

Алгоритм ID3 (Iterative Dichotomiser 3)

- $Entropy = - \sum_{i=1}^n p_i \cdot \log_2 p_i$
- $\max Entropy = \log_2 n$, когда объекты равномерно распределены по классам (наименее желательная ситуация)
- $\min Entropy = 0$, когда объекты принадлежат одному классу (наиболее желательная ситуация)



John Ross
Quinlan

Вычисление энтропии узла дерева решений

- $Entropy = - \sum_{i=1}^n p_i \cdot \log_2 p_i$

$0 \cdot \log_2 0$ считается 0

- | |
|---|
| 0 |
| 6 |

 $Entropy = - \frac{0}{6} \cdot \log_2 0 - \frac{6}{6} \cdot \log_2 \frac{1}{1} = 0$

- | |
|---|
| 1 |
| 5 |

 $Entropy = - \frac{1}{6} \cdot \log_2 \frac{1}{6} - \frac{5}{6} \cdot \log_2 \frac{5}{6} = 0.65$

- | |
|---|
| 2 |
| 4 |

 $Entropy = - \frac{2}{6} \cdot \log_2 \frac{2}{6} - \frac{4}{6} \cdot \log_2 \frac{4}{6} = 0.92$

Вычисление прироста информации после разбиения узла по атрибуту

- $Gain(A) = Entropy(node) - Info(A)$

$$Entropy(node) = - \sum_{i=1}^n p_i \cdot \log_2 p_i$$

$$Info(A) = \sum_{i=1}^k \frac{n_i}{n} Entropy(child_i)$$

A – атрибут разбиения с k различных значений

n – количество объектов в выборке

разбиваемого узла-родителя $node$

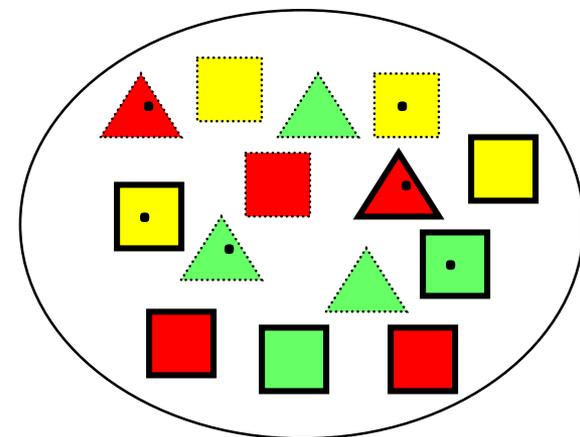
n_i – количество объектов в выборке узла-потомка $child_i$

- Для разбиения выбирается атрибут

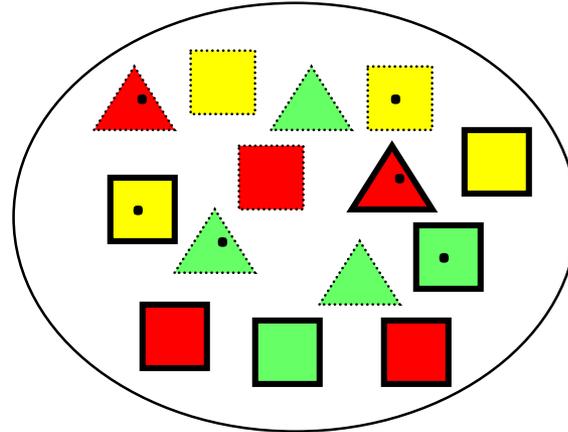
$$A_{split} = \arg \max_i Gain(A_i) = \arg \min_i Info(A_i)$$

Пример построения дерева решений по ID3

| # | Attribute | | | Shape |
|----|-----------|---------|-----|---------|
| | Color | Outline | Dot | |
| 1 | green | dashed | no | triange |
| 2 | green | dashed | yes | triange |
| 3 | yellow | dashed | no | square |
| 4 | red | dashed | no | square |
| 5 | red | solid | no | square |
| 6 | red | solid | yes | triange |
| 7 | green | solid | no | square |
| 8 | green | dashed | no | triange |
| 9 | yellow | solid | yes | square |
| 10 | red | solid | no | square |
| 11 | green | solid | yes | square |
| 12 | yellow | dashed | yes | square |
| 13 | yellow | solid | no | square |
| 14 | red | dashed | yes | triange |



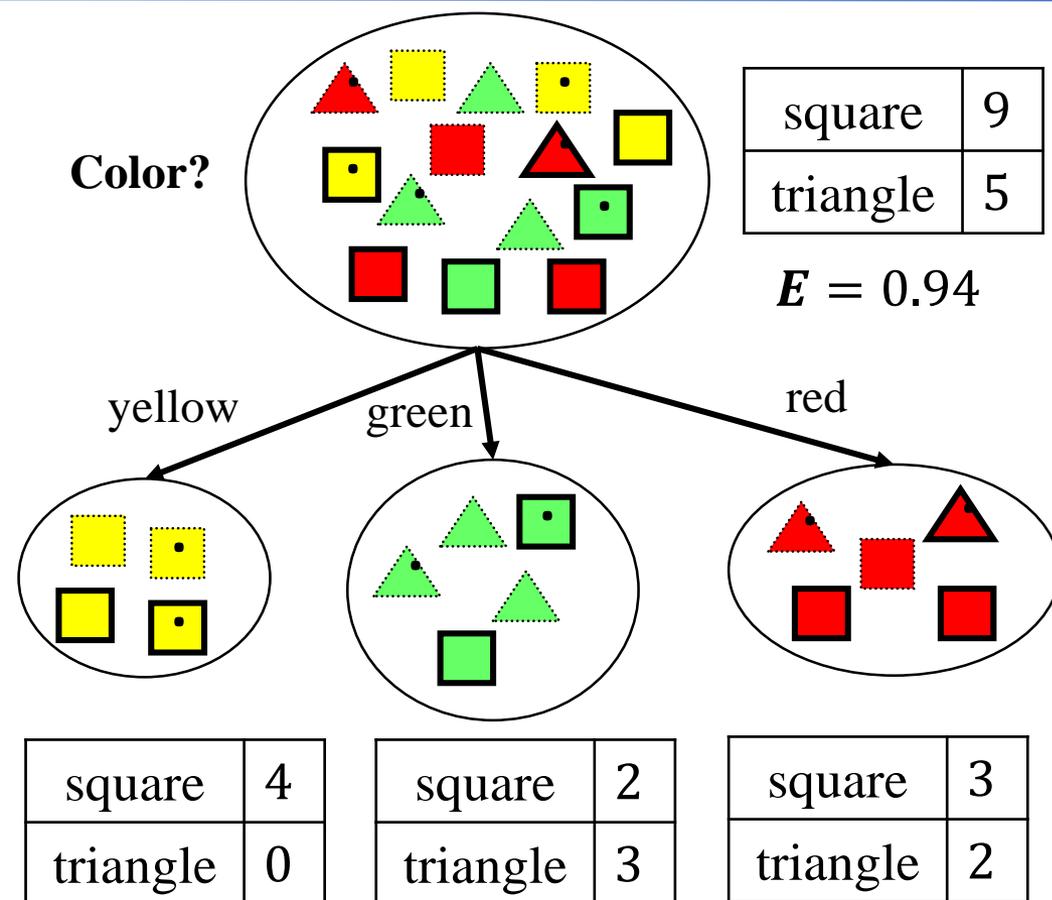
Пример: вычисление энтропии узла-родителя



| | |
|----------|---|
| square | 9 |
| triangle | 5 |

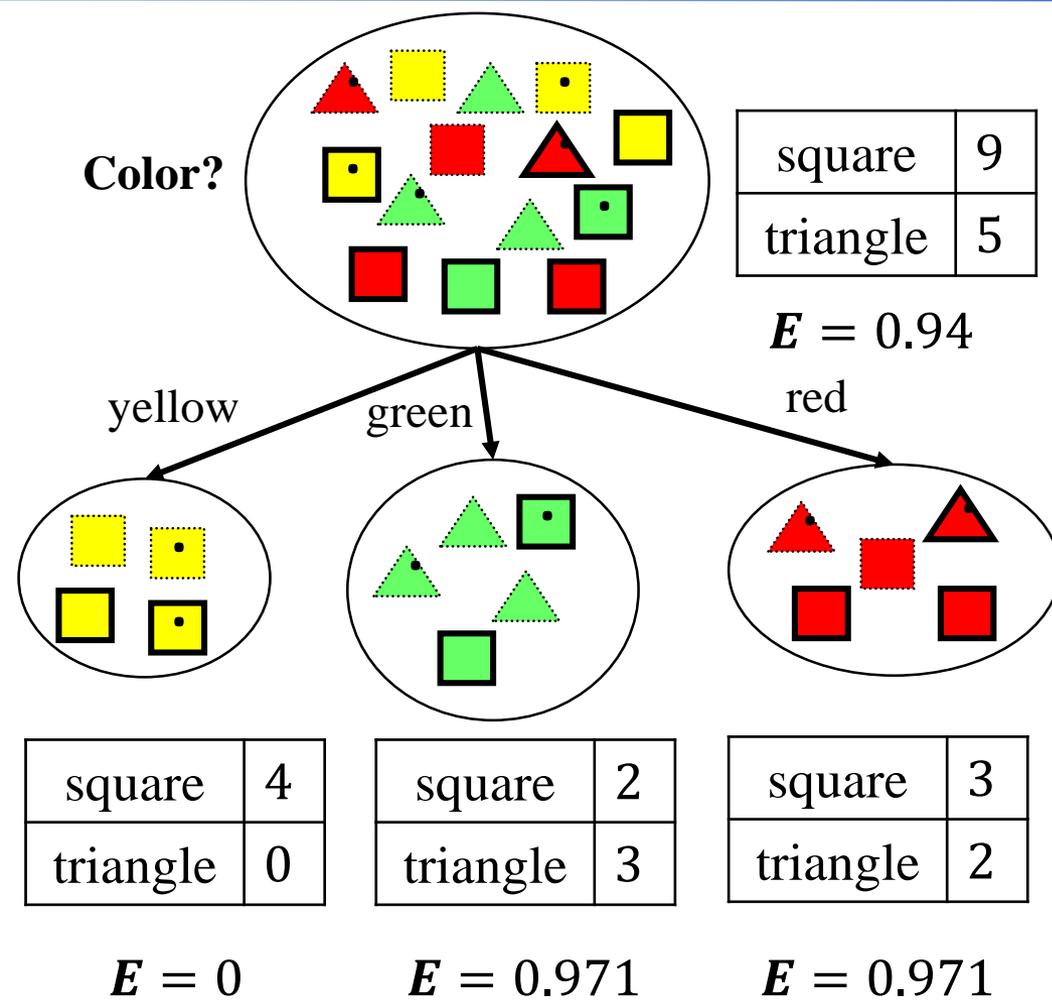
- ***Entropy*** = $-\frac{9}{14} \cdot \log_2 \frac{9}{14} - \frac{5}{14} \cdot \log_2 \frac{5}{14} = \mathbf{0.94}$

Пример: вычисление энтропии узлов-потомков



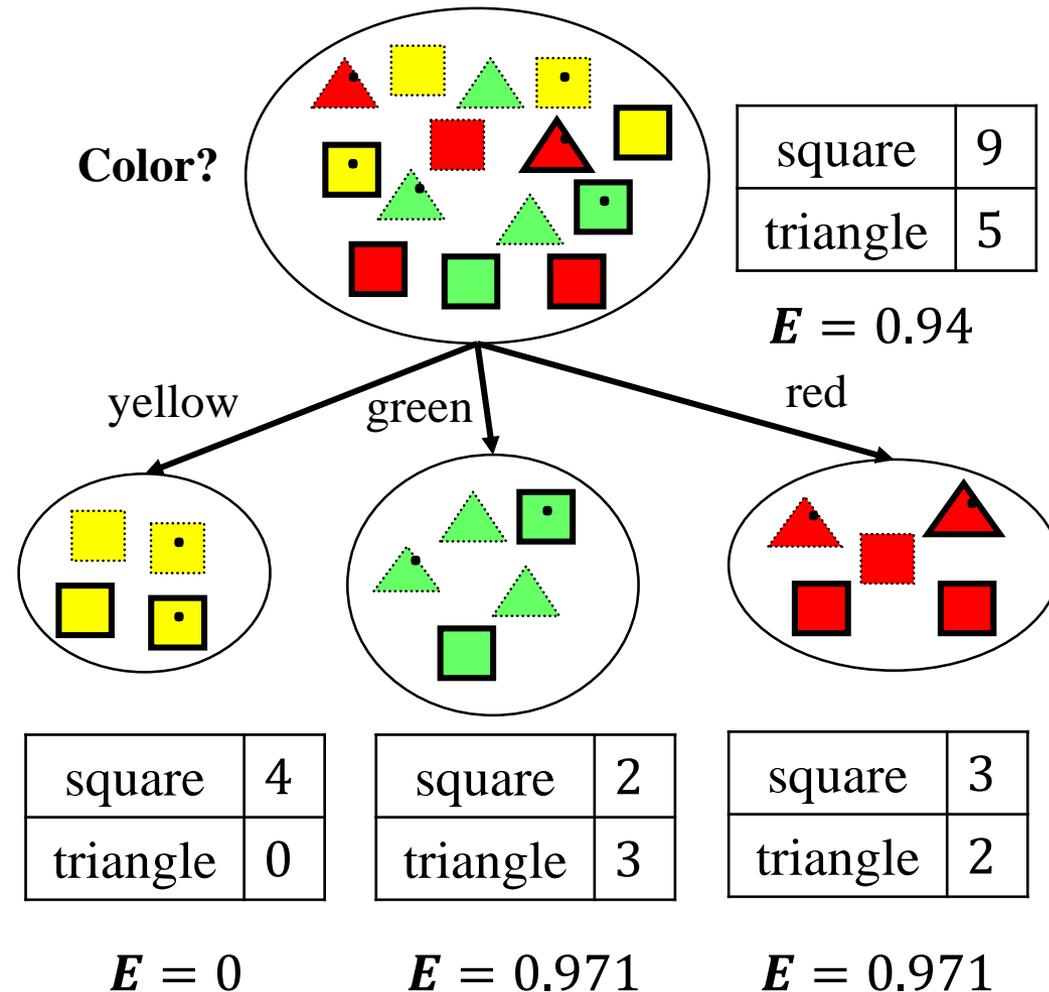
- $Entropy(yellow) = 0$
- $Entropy(green) = -\frac{2}{5} \cdot \log_2 \frac{2}{5} - \frac{3}{5} \cdot \log_2 \frac{3}{5} = 0.971$
- $Entropy(red) = -\frac{3}{5} \cdot \log_2 \frac{3}{5} - \frac{2}{5} \cdot \log_2 \frac{2}{5} = 0.971$

Пример: вычисление прироста информации



- $$Info(Color) = \frac{4}{14} \cdot 0 + \frac{5}{14} \cdot 0.971 + \frac{5}{14} \cdot 0.971 = 0.694$$
- $$Gain(Color) = 0.94 - 0.694 = 0.246$$

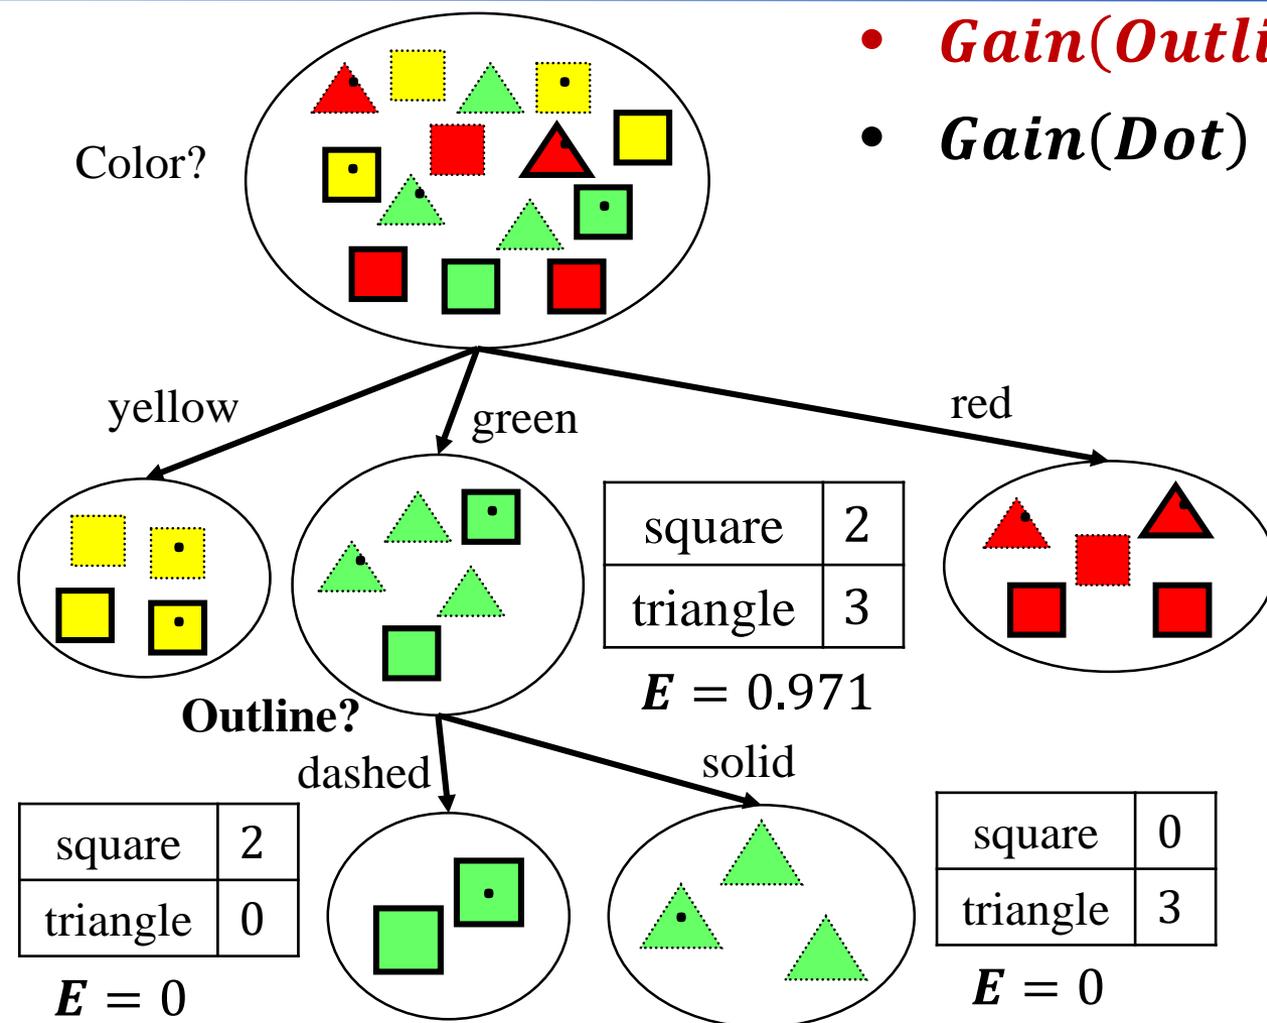
Пример: выбор атрибута разбиения



- $Gain(Color) = 0.246$
- $Gain(Outline) = 0.151$
- $Gain(Dot) = 0.048$

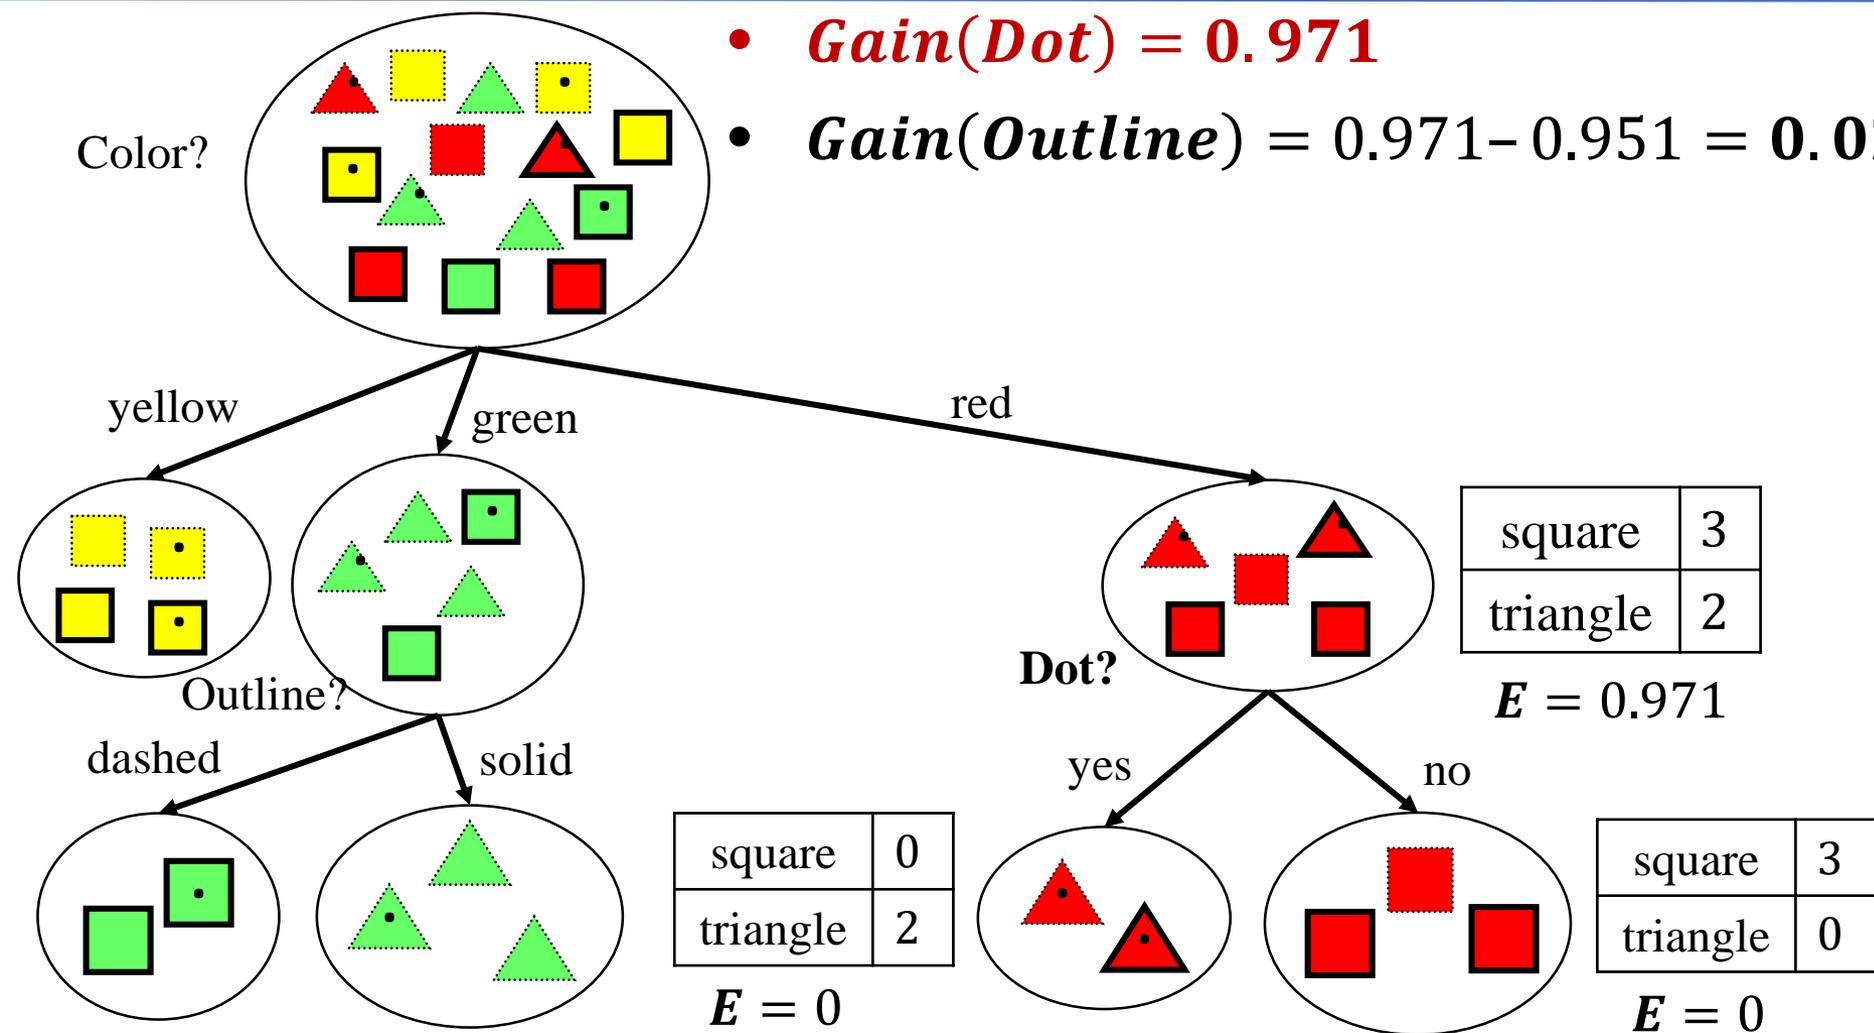
Пример: выбор атрибута разбиения

- $Gain(Outline) = 0.971$
- $Gain(Dot) = 0.971 - 0.951 = 0.02$

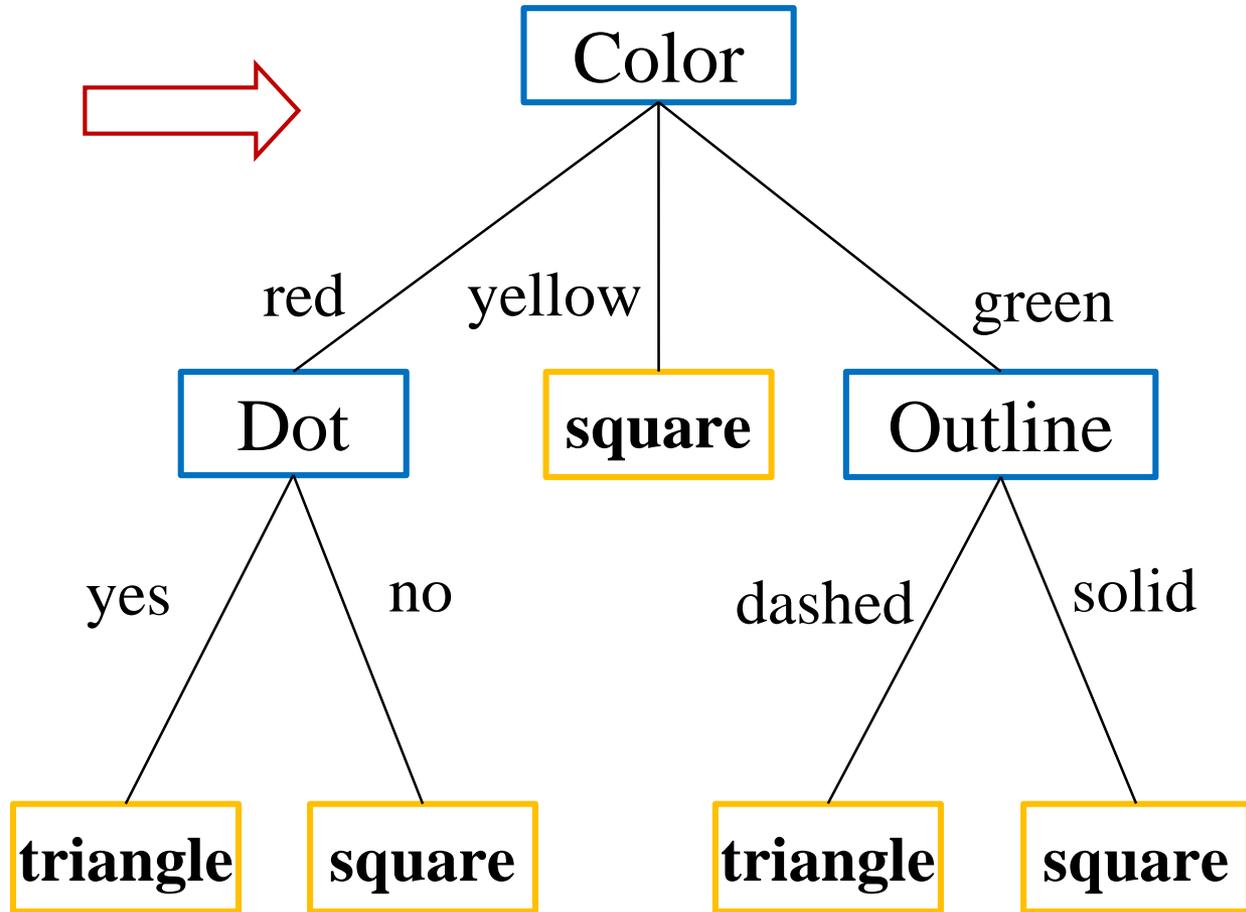
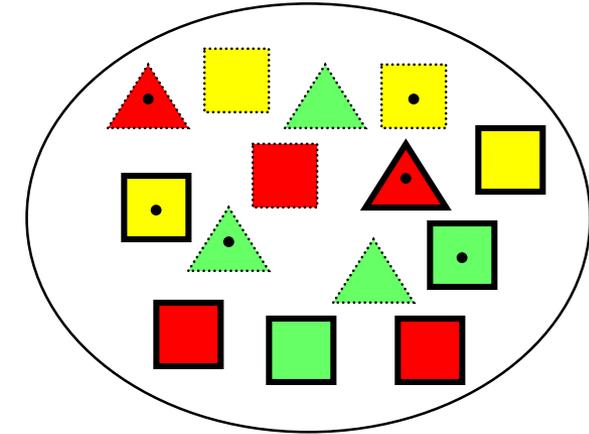


Пример: выбор атрибута разбиения

- $Gain(Dot) = 0.971$
- $Gain(Outline) = 0.971 - 0.951 = 0.02$



Пример: итоговое дерево решений



Алгоритм построения дерева решений

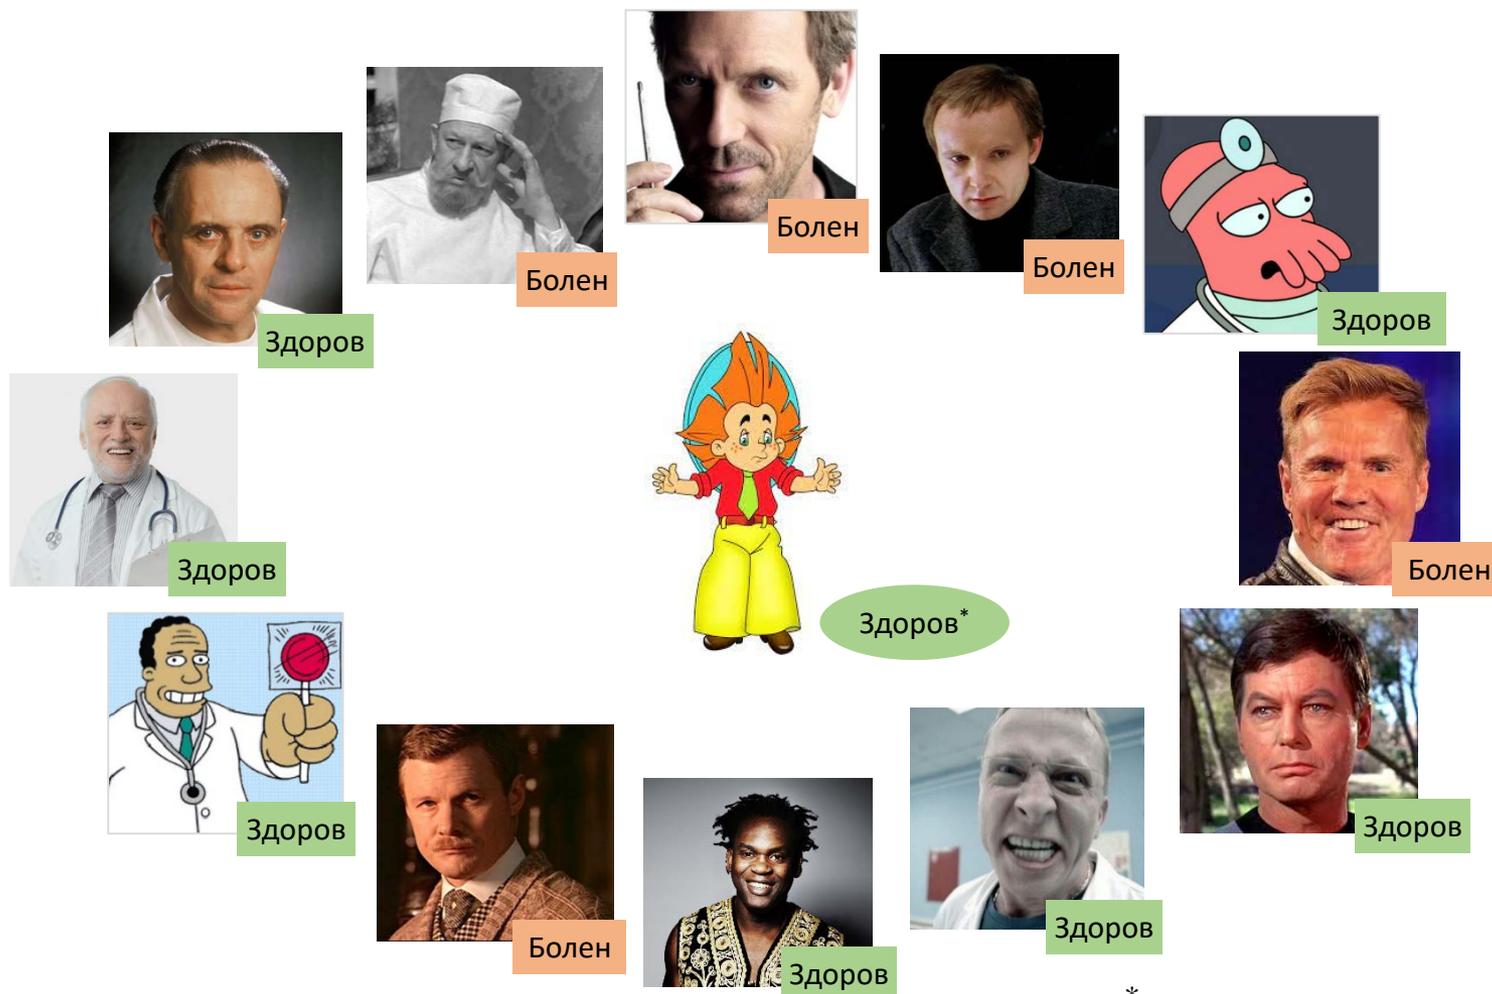
TreeGrowth (E, F)

```
1: if stopping_cond( $E, F$ ) = true then
2:   leaf = createNode().
3:   leaf.label = Classify( $E$ ).
4:   return leaf.
5: else
6:   root = createNode().
7:   root.test_cond = find_best_split( $E, F$ ).
8:   let  $V = \{v \mid v \text{ is a possible outcome of } root.test\_cond \}$ .
9:   for each  $v \in V$  do
10:     $E_v = \{e \mid root.test\_cond(e) = v \text{ and } e \in E\}$ .
11:    child = TreeGrowth( $E_v, F$ ).
12:    add child as descendent of root and label the edge ( $root \rightarrow child$ ) as  $v$ .
13:   end for
14: end if
15: return root.
```

Содержание

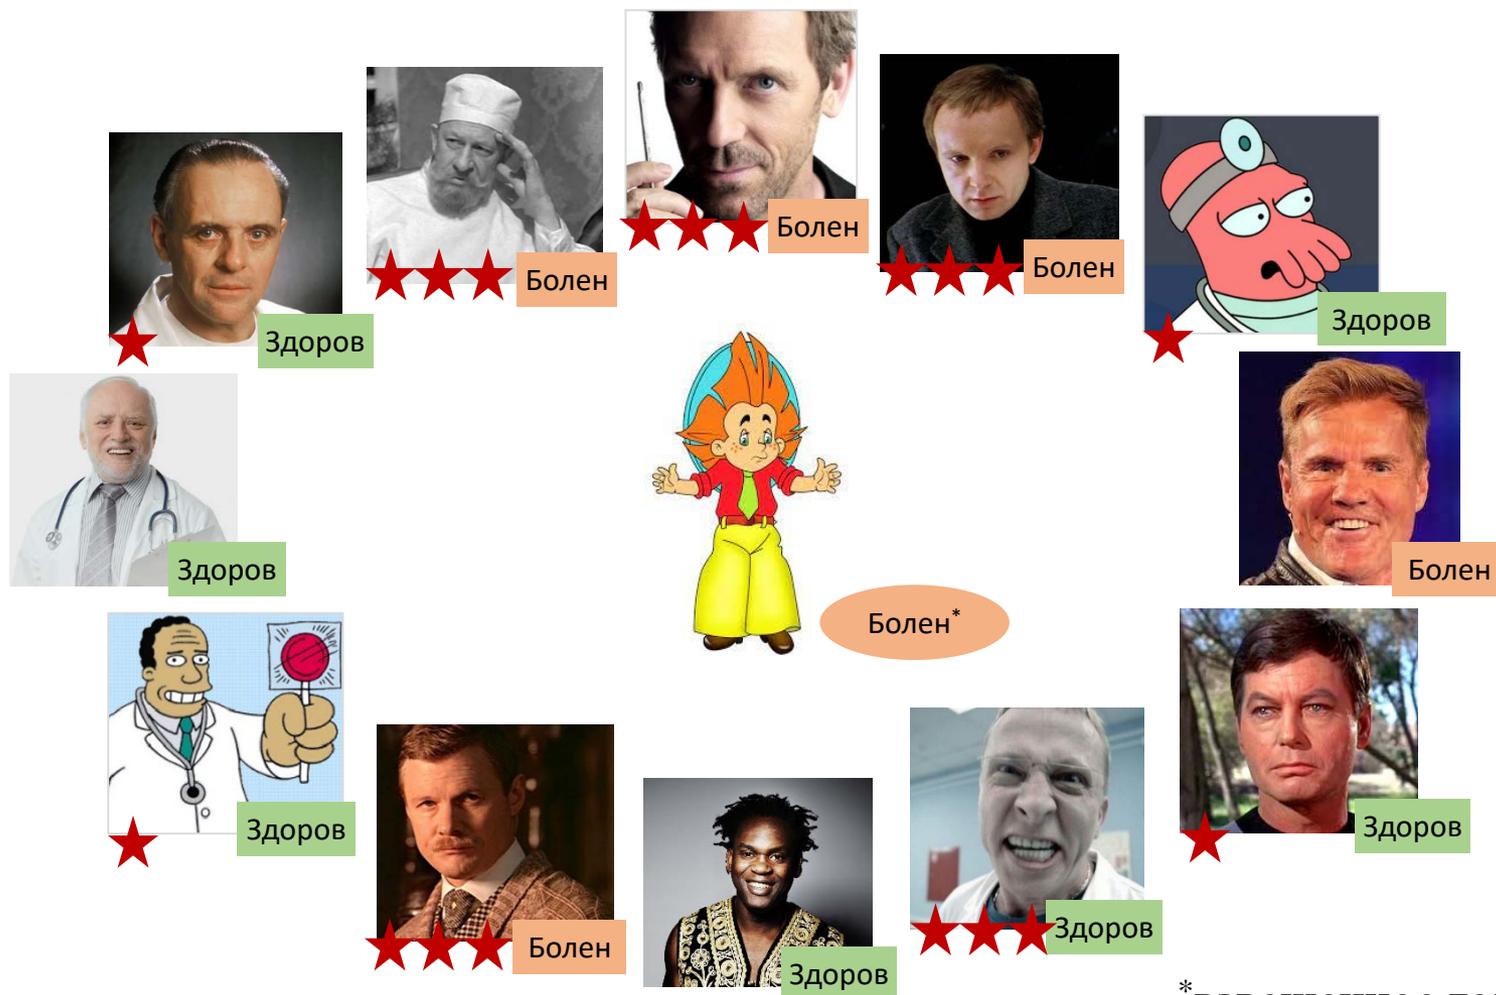
- Общий подход к классификации
- Деревья решений
- **Ансамблевая классификация**
- Оценка качества классификации

Ансамблевая классификация (идея)



* мажоритарное голосование

Ансамблевая классификация (идея)



* взвешенное голосование

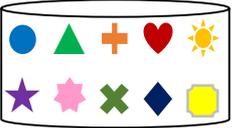
Ансамблевая классификация

$$|D| = n = |D_i|,$$

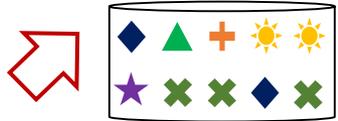
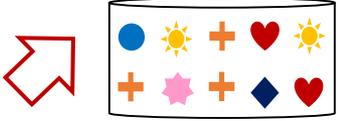
$$P(o \in D_i) = 1 - (1 - 1/n)^n,$$

$$\lim_{n \rightarrow +\infty} P(o \in D_i) = 1 - 1/e \approx 0.632$$

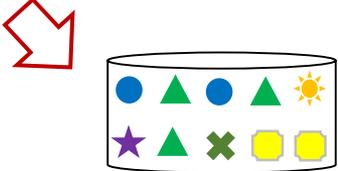
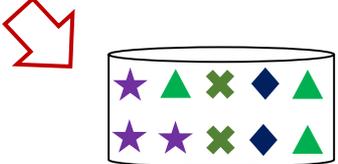
Исходная обучающая выборка



Синтетические выборки



...



Базовые классификаторы



...



Неизвестный объект



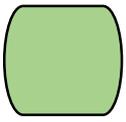
...



Голосование



Класс



Почему работают ансамбли?

- Дано n базовых классификаторов с вероятностью ошибки ε у каждого, *между их ошибками отсутствует корреляция*

- Тогда вероятность ошибки ансамбля

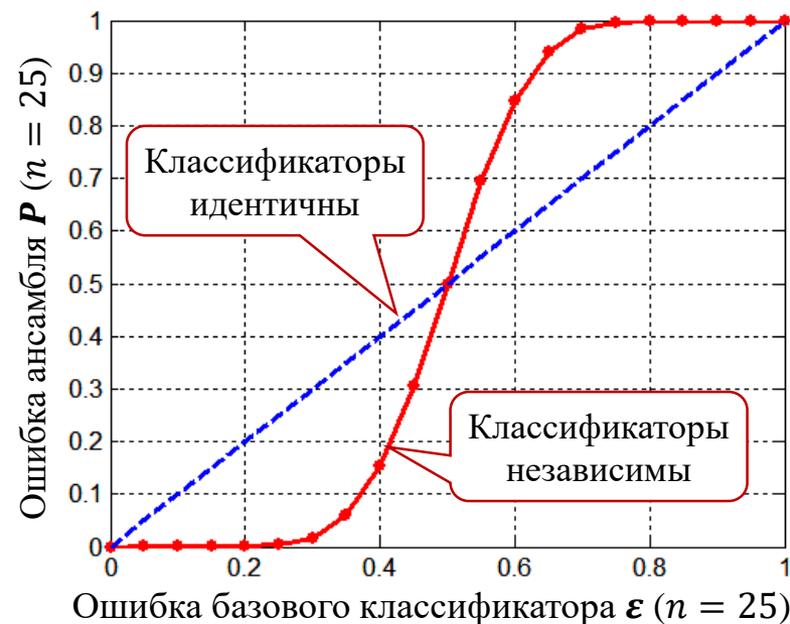
$$P(|wrong| > \lfloor n/2 \rfloor) = \sum_{i=\lfloor n/2 \rfloor+1}^n C_i^n \cdot \varepsilon^i \cdot (1 - \varepsilon)^{n-i}$$

$n = 25$ и $\varepsilon = 0.35$: $P = 0.06$ (!!)

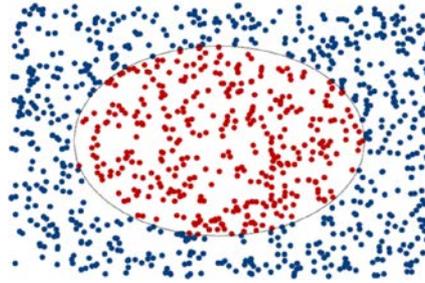
- Неравенство Хёфдинга**

$$P(|wrong| > \lfloor n/2 \rfloor) \leq e^{-0.5(2\varepsilon-1)^2}$$

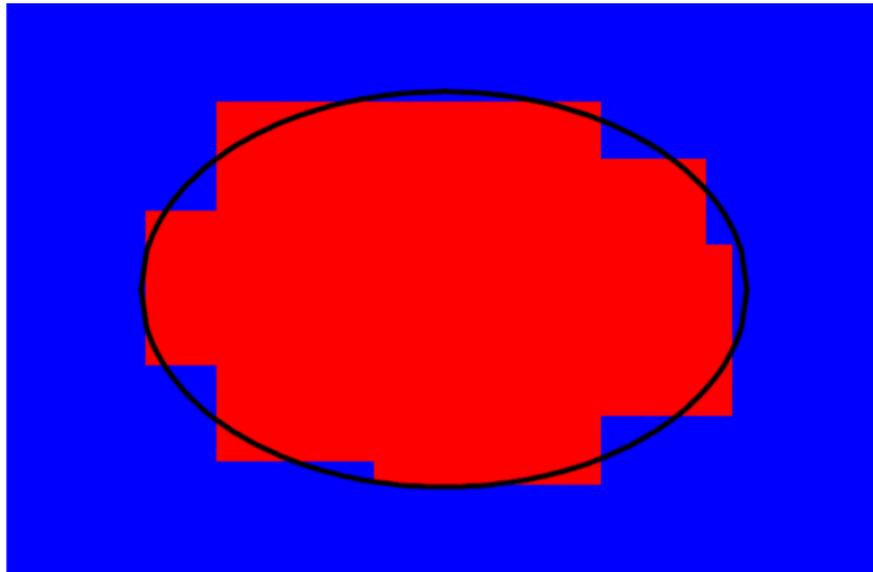
вероятность ошибки ансамбля убывает экспоненциально с ростом числа базовых классификаторов



Пример работы ансамбля классификаторов



Исходное множество



Одно дерево решений



Ансамбль деревьев решений

Бэггинг (Bagging, Bootstrap Aggregating)

- Базовые идеи
 - Сэмплинг с замещением при формировании подвыборок
 - Голосование по большинству при назначении метки класса
- Отличительные черты
 - Может использоваться для предсказания непрерывных значений (усреднение результатов, выданных участниками ансамбля)
 - Часто существенно более высокая точность, чем у одного классификатора. Лучшая точность при предсказании, чем у одного классификатора
 - Устойчивость к шумам в данных при несущественном снижении точности

Алгоритм бэггинга

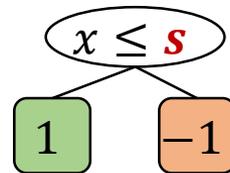
- 1: Let k be the number of bootstrap samples.
- 2: **for** $i = 1$ to k **do**
- 3: Create a bootstrap sample of size N , D_i .
- 4: Train a base classifier C_i on the bootstrap sample D_i .
- 5: **end for**
- 6: $C^*(x) = \operatorname{argmax}_y \sum_i \delta(C_i(x) = y)$.
 $\{\delta(\cdot) = 1$ if its argument is true and 0 otherwise $\}$.

Пример бэггинга: задача и обучающая выборка

Обучающая
выборка

| X | $Class$ |
|-----|---------|
| 0.1 | 1 |
| 0.2 | 1 |
| 0.3 | 1 |
| 0.4 | -1 |
| 0.5 | -1 |
| 0.6 | -1 |
| 0.7 | -1 |
| 0.8 | 1 |
| 0.9 | 1 |
| 1.0 | 1 |

Примитивная
классификация



Ансамбль примитивных
классификаторов

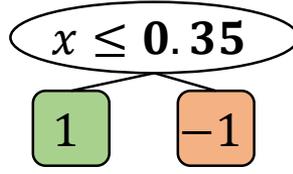
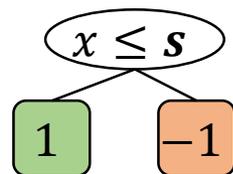
| Уч. | s | $Left$ | $Right$ |
|-----|------|--------|---------|
| 1 | 0.75 | -1 | 1 |
| 2 | ? | ? | ? |
| 3 | ? | ? | ? |
| 4 | ? | ? | ? |
| 5 | ? | ? | ? |
| 6 | ? | ? | ? |
| 7 | ? | ? | ? |
| 8 | ? | ? | ? |
| 9 | ? | ? | ? |
| 10 | ? | ? | ? |

Пример бэггинга: выборка и обучение 1-го участника ансамбля

| X | $Class$ |
|-----|---------|
| 0.1 | 1 |
| 0.2 | 1 |
| 0.3 | 1 |
| 0.4 | -1 |
| 0.5 | -1 |
| 0.6 | -1 |
| 0.7 | -1 |
| 0.8 | 1 |
| 0.9 | 1 |
| 1.0 | 1 |

1

| X | $Class$ |
|-----|---------|
| 0.1 | 1 |
| 0.2 | 1 |
| 0.2 | 1 |
| 0.3 | 1 |
| 0.4 | -1 |
| 0.4 | -1 |
| 0.5 | -1 |
| 0.6 | -1 |
| 0.9 | 1 |
| 0.9 | 1 |



Пример бэггинга: выборки и обучение 1-5 участников ансамбля

| X | $Class$ |
|-----|---------|
| 0.1 | 1 |
| 0.2 | 1 |
| 0.3 | 1 |
| 0.4 | -1 |
| 0.5 | -1 |
| 0.6 | -1 |
| 0.7 | -1 |
| 0.8 | 1 |
| 0.9 | 1 |
| 1.0 | 1 |

1

| X | $Class$ |
|-----|---------|
| 0.1 | 1 |
| 0.2 | 1 |
| 0.2 | 1 |
| 0.3 | 1 |
| 0.4 | -1 |
| 0.4 | -1 |
| 0.4 | -1 |
| 0.5 | -1 |
| 0.6 | -1 |
| 0.9 | 1 |
| 0.9 | 1 |

2

| X | $Class$ |
|-----|---------|
| 0.1 | 1 |
| 0.2 | 1 |
| 0.3 | 1 |
| 0.4 | -1 |
| 0.5 | -1 |
| 0.5 | -1 |
| 0.9 | 1 |
| 1.0 | 1 |
| 1.0 | 1 |
| 1.0 | 1 |

3

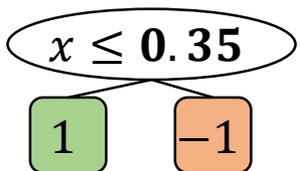
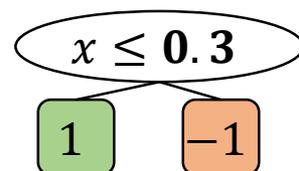
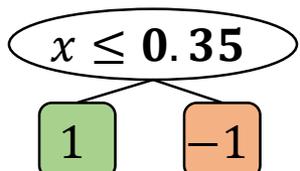
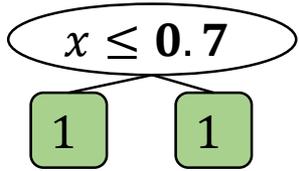
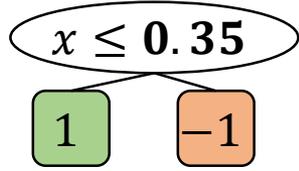
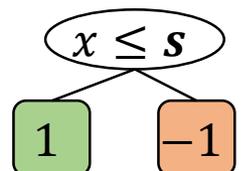
| X | $Class$ |
|-----|---------|
| 0.1 | 1 |
| 0.2 | 1 |
| 0.3 | 1 |
| 0.4 | -1 |
| 0.4 | -1 |
| 0.5 | -1 |
| 0.7 | -1 |
| 0.7 | -1 |
| 0.8 | 1 |
| 0.9 | 1 |

4

| X | $Class$ |
|-----|---------|
| 0.1 | 1 |
| 0.1 | 1 |
| 0.2 | 1 |
| 0.4 | -1 |
| 0.4 | -1 |
| 0.5 | -1 |
| 0.5 | -1 |
| 0.7 | -1 |
| 0.8 | 1 |
| 0.9 | 1 |

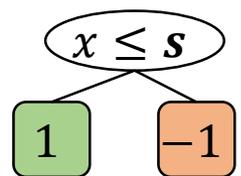
5

| X | $Class$ |
|-----|---------|
| 0.1 | 1 |
| 0.1 | 1 |
| 0.2 | 1 |
| 0.5 | -1 |
| 0.6 | -1 |
| 0.6 | -1 |
| 0.6 | -1 |
| 1.0 | 1 |
| 1.0 | 1 |
| 1.0 | 1 |



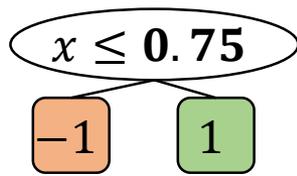
Пример бэггинга: выборки и обучение 6-10 участников ансамбля

| X | $Class$ |
|-----|---------|
| 0.1 | 1 |
| 0.2 | 1 |
| 0.3 | 1 |
| 0.4 | -1 |
| 0.5 | -1 |
| 0.6 | -1 |
| 0.7 | -1 |
| 0.8 | 1 |
| 0.9 | 1 |
| 1.0 | 1 |



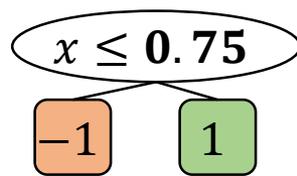
6

| X | $Class$ |
|-----|---------|
| 0.2 | 1 |
| 0.4 | -1 |
| 0.5 | -1 |
| 0.6 | -1 |
| 0.7 | -1 |
| 0.7 | -1 |
| 0.8 | 1 |
| 0.9 | 1 |
| 1.0 | 1 |



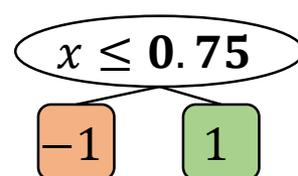
7

| X | $Class$ |
|-----|---------|
| 0.1 | 1 |
| 0.4 | -1 |
| 0.4 | -1 |
| 0.6 | -1 |
| 0.7 | -1 |
| 0.8 | 1 |
| 0.9 | 1 |
| 0.9 | 1 |
| 1.0 | 1 |



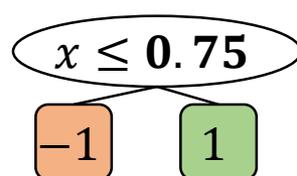
8

| X | $Class$ |
|-----|---------|
| 0.1 | 1 |
| 0.2 | 1 |
| 0.5 | -1 |
| 0.5 | -1 |
| 0.7 | -1 |
| 0.7 | -1 |
| 0.8 | 1 |
| 0.9 | 1 |
| 0.9 | 1 |
| 1.0 | 1 |



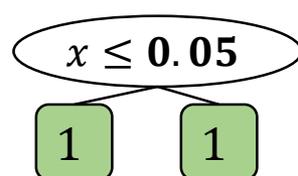
9

| X | $Class$ |
|-----|---------|
| 0.1 | 1 |
| 0.3 | 1 |
| 0.4 | -1 |
| 0.4 | -1 |
| 0.6 | -1 |
| 0.7 | -1 |
| 0.7 | -1 |
| 0.8 | 1 |
| 1.0 | 1 |
| 1.0 | 1 |



10

| X | $Class$ |
|-----|---------|
| 0.1 | 1 |
| 0.1 | 1 |
| 0.1 | 1 |
| 0.1 | 1 |
| 0.3 | 1 |
| 0.3 | 1 |
| 0.8 | 1 |
| 0.8 | 1 |
| 0.9 | 1 |
| 0.9 | 1 |



Пример бэггинга: итоговый ансамбль

| Участник | s | L | R |
|----------|------|-----|-----|
| 1 | 0.35 | 1 | -1 |
| 2 | 0.7 | 1 | 1 |
| 3 | 0.35 | 1 | -1 |
| 4 | 0.3 | 1 | -1 |
| 5 | 0.35 | 1 | -1 |
| 6 | 0.75 | -1 | 1 |
| 7 | 0.75 | -1 | 1 |
| 8 | 0.75 | -1 | 1 |
| 9 | 0.75 | -1 | 1 |
| 10 | 0.05 | 1 | 1 |

Пример бэггинга: проверка ансамбля

| Уч. | s | L | R |
|-----|------|-----|-----|
| 1 | 0.35 | 1 | -1 |
| 2 | 0.7 | 1 | 1 |
| 3 | 0.35 | 1 | -1 |
| 4 | 0.3 | 1 | -1 |
| 5 | 0.35 | 1 | -1 |
| 6 | 0.75 | -1 | 1 |
| 7 | 0.75 | -1 | 1 |
| 8 | 0.75 | -1 | 1 |
| 9 | 0.75 | -1 | 1 |
| 10 | 0.05 | 1 | 1 |

| Уч. | 0.1 | 0.2 | 0.3 | 0.4 | 0.5 | 0.6 | 0.7 | 0.8 | 0.9 | 1.0 |
|--------------|----------|----------|----------|-----------|-----------|-----------|-----------|----------|----------|----------|
| 1 | 1 | 1 | 1 | -1 | -1 | -1 | -1 | -1 | -1 | -1 |
| 2 | 1 | 1 | 1 | 1 | 1 | 1 | 1 | 1 | 1 | 1 |
| 3 | 1 | 1 | 1 | -1 | -1 | -1 | -1 | -1 | -1 | -1 |
| 4 | 1 | 1 | 1 | -1 | -1 | -1 | -1 | -1 | -1 | -1 |
| 5 | 1 | 1 | 1 | -1 | -1 | -1 | -1 | -1 | -1 | -1 |
| 6 | -1 | -1 | -1 | -1 | -1 | -1 | -1 | 1 | 1 | 1 |
| 7 | -1 | -1 | -1 | -1 | -1 | -1 | -1 | 1 | 1 | 1 |
| 8 | -1 | -1 | -1 | -1 | -1 | -1 | -1 | 1 | 1 | 1 |
| 9 | -1 | -1 | -1 | -1 | -1 | -1 | -1 | 1 | 1 | 1 |
| 10 | 1 | 1 | 1 | 1 | 1 | 1 | 1 | 1 | 1 | 1 |
| Vote | 2 | 2 | 2 | -6 | -6 | -6 | -6 | 2 | 2 | 2 |
| Class | 1 | 1 | 1 | -1 | -1 | -1 | -1 | 1 | 1 | 1 |

Boosting: основные идеи

- Веса объектов выборки
 - Вес объекта влияет на вероятность включения объекта в обучающую выборку участника ансамбля
 - Сначала объекты имеют одинаковые веса. Затем вес объекта, неверно классифицированного участником, увеличивается, иначе – уменьшается
- Обучение участников
 - Последовательно (один за другим)
 - Обучающая выборка участника формируется с помощью сэмплинга с замещением
 - Перед переходом к следующему участнику выполняется оценка точности текущего участника на всех объектах исходной выборки и затем пересчитываются их веса
- Классификация
 - Класс неизвестного объекта определяется взвешенным голосованием участников
 - Вес участника зависит от его точности классификации

Алгоритм AdaBoost

- **Обучающая выборка:**
 $(x_1, y_1), \dots, (x_n, y_n)$, веса w_1, \dots, w_n

- **Ансамбль:** C_1, \dots, C_k

- **Ошибка участника ансамбля:**

$$\varepsilon_i = \frac{1}{n} \sum_{j=1}^n w_j \cdot \delta(C_j(x_i) \neq y_i)$$

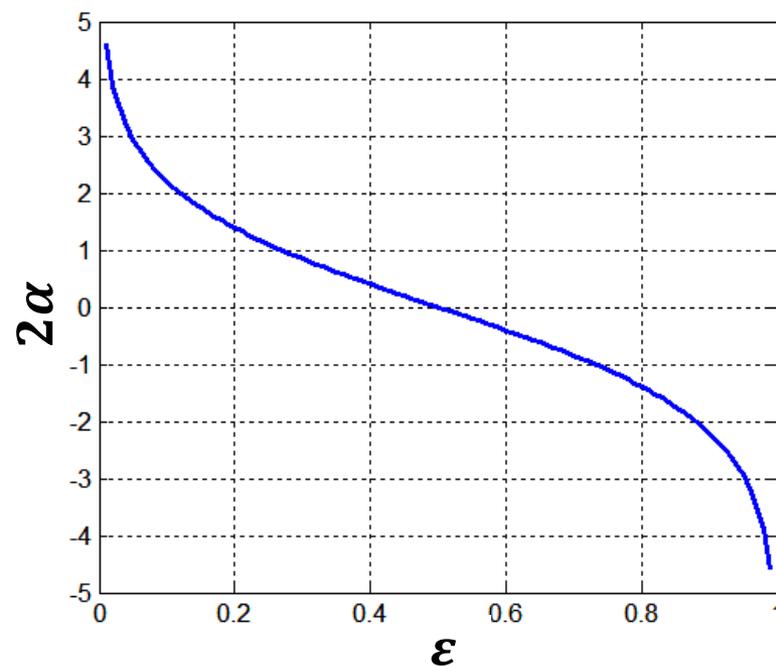
- **Вес участника:** $\alpha_i = \frac{1}{2} \ln \frac{1-\varepsilon_i}{\varepsilon_i}$

- **Обновление весов:**

$$w_i^{(0)} = 1/n$$

$$w_i^{(j+1)} = \frac{w_i^{(j)}}{Z_j} \cdot \begin{cases} e^{-\alpha_j}, & C_j(x_i) = y_i \\ e^{\alpha_j}, & C_j(x_i) \neq y_i \end{cases}$$

где Z_j – нормализующий множитель ($\sum_i w_i^{(j+1)} = 1$)



Алгоритм AdaBoost

- 1: $\mathbf{w} = \{w_j = 1/N \mid j = 1, 2, \dots, N\}$. {Initialize the weights for all N examples.}
- 2: Let k be the number of boosting rounds.
- 3: **for** $i = 1$ to k **do**
- 4: Create training set D_i by sampling (with replacement) from D according to \mathbf{w} .
- 5: Train a base classifier C_i on D_i .
- 6: Apply C_i to all examples in the original training set, D .
- 7: $\epsilon_i = \frac{1}{N} [\sum_j w_j \delta(C_i(x_j) \neq y_j)]$ {Calculate the weighted error.}
- 8: **if** $\epsilon_i > 0.5$ **then**
- 9: $\mathbf{w} = \{w_j = 1/N \mid j = 1, 2, \dots, N\}$.
- 10: Go back to Step 4.
- 11: **end if**
- 12: $\alpha_i = \frac{1}{2} \ln \frac{1-\epsilon_i}{\epsilon_i}$.
- 13: Update the weight of each example
- 14: **end for**
- 15: $C^*(\mathbf{x}) = \operatorname{argmax}_y \sum_{j=1}^T \alpha_j \delta(C_j(\mathbf{x}) = y)$.

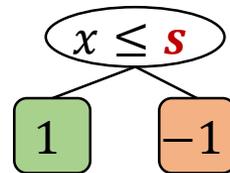
Если ошибка классификации более 50%,
то повторить сэмплинг

Пример бустинга

Обучающая
выборка

| X | $Class$ |
|-----|---------|
| 0.1 | 1 |
| 0.2 | 1 |
| 0.3 | 1 |
| 0.4 | -1 |
| 0.5 | -1 |
| 0.6 | -1 |
| 0.7 | -1 |
| 0.8 | 1 |
| 0.9 | 1 |
| 1.0 | 1 |

Примитивная
классификация



Ансамбль примитивных
классификаторов

| Уч. | s | $Left$ | $Right$ | α |
|-----|------|--------|---------|----------|
| 1 | 0.75 | -1 | 1 | ? |
| 2 | ? | ? | ? | ? |
| 3 | ? | ? | ? | ? |

Пример бустинга: выборки и обучение участников ансамбля

| <i>X</i> | <i>Class</i> |
|----------|--------------|
| 0.1 | 1 |
| 0.2 | 1 |
| 0.3 | 1 |
| 0.4 | -1 |
| 0.5 | -1 |
| 0.6 | -1 |
| 0.7 | -1 |
| 0.8 | 1 |
| 0.9 | 1 |
| 1.0 | 1 |

1

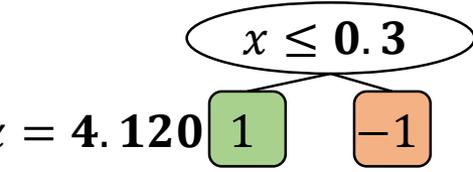
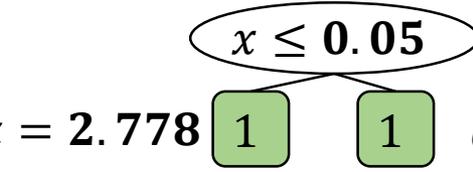
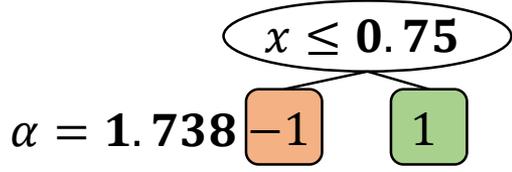
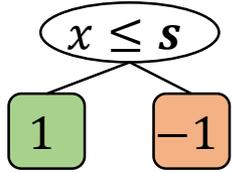
| <i>X</i> | <i>Class</i> | <i>weight</i> |
|----------|--------------|---------------|
| 0.1 | 1 | 0.1 |
| 0.4 | -1 | 0.1 |
| 0.5 | -1 | 0.1 |
| 0.6 | -1 | 0.1 |
| 0.6 | -1 | 0.1 |
| 0.6 | -1 | 0.1 |
| 0.7 | -1 | 0.1 |
| 0.7 | -1 | 0.1 |
| 0.7 | -1 | 0.1 |
| 0.8 | 1 | 0.1 |
| 1.0 | 1 | 0.1 |

2

| <i>X</i> | <i>Class</i> | <i>weight</i> |
|----------|--------------|---------------|
| 0.1 | 1 | 0.311 |
| 0.1 | 1 | 0.311 |
| 0.2 | 1 | 0.311 |
| 0.2 | 1 | 0.01 |
| 0.2 | 1 | 0.01 |
| 0.2 | 1 | 0.01 |
| 0.3 | 1 | 0.01 |
| 0.3 | 1 | 0.01 |
| 0.3 | 1 | 0.01 |
| 0.3 | 1 | 0.01 |

3

| <i>X</i> | <i>Class</i> | <i>weight</i> |
|----------|--------------|---------------|
| 0.2 | 1 | 0.029 |
| 0.2 | 1 | 0.029 |
| 0.4 | -1 | 0.029 |
| 0.4 | -1 | 0.228 |
| 0.4 | -1 | 0.228 |
| 0.4 | -1 | 0.228 |
| 0.5 | -1 | 0.228 |
| 0.6 | -1 | 0.009 |
| 0.6 | -1 | 0.009 |
| 0.7 | -1 | 0.009 |



Пример бустинга: проверка ансамбля

| Уч. | s | L | R | α |
|-----|------|-----|-----|----------|
| 1 | 0.75 | -1 | 1 | 1.738 |
| 2 | 0.05 | 1 | 1 | 2.778 |
| 3 | 0.3 | 1 | -1 | 4.120 |

| Уч. | 0.1 | 0.2 | 0.3 | 0.4 | 0.5 | 0.6 | 0.7 | 0.8 | 0.9 | 1.0 |
|--------------|------|------|------|-------|-------|-------|-------|-------|-------|-------|
| 1 | -1 | -1 | -1 | -1 | -1 | -1 | -1 | 1 | 1 | 1 |
| 2 | 1 | 1 | 1 | 1 | 1 | 1 | 1 | 1 | 1 | 1 |
| 3 | 1 | 1 | 1 | -1 | -1 | -1 | -1 | -1 | -1 | -1 |
| SUM | 5.16 | 5.16 | 5.16 | -3.08 | -3.08 | -3.08 | -3.08 | 0.397 | 0.397 | 0.397 |
| Class | 1 | 1 | 1 | -1 | -1 | -1 | -1 | 1 | 1 | 1 |

Содержание

- Общий подход к классификации
- Деревья решений
- Ансамблевая классификация
- **Оценка качества классификации**

Матрица ошибок (Confusion matrix)

| Прогноз \ Класс | C | $\neg C$ |
|-----------------|--|--|
| C | <p><i>True Positives (TP)</i></p>  | <p><i>False Positives (FP)</i></p>  |
| $\neg C$ | <p><i>False Negatives (FN)</i></p>  | <p><i>True Negatives (TN)</i></p>  |

Матрица ошибок (Confusion matrix)

| Прогноз \ Класс | C | $\neg C$ |
|-----------------|-----------------------------|-----------------------------|
| C | <i>True Positives (TP)</i> | <i>False Positives (FP)</i> |
| $\neg C$ | <i>False Negatives (FN)</i> | <i>True Negatives (TN)</i> |

- TP – верно распознанные объекты класса C
- TN – верно распознанные объекты класса $\neg C$
- FN – объекты класса C , неверно распознанные как объекты класса $\neg C$
- FP – объекты класса $\neg C$, неверно распознанные как объекты класса C
- $P = TP + FN$ – объекты класса C
- $N = FP + TN$ – объекты класса $\neg C$

Accuracy, recognition rate (Аккуратность)

Error/misclassification rate (Доля ошибок)

- $Accuracy = \frac{TP+TN}{P+N} = \frac{TP+TN}{TP+FN+FP+TN}$
- $Error = 1 - Accuracy = \frac{FP+FN}{P+N} = \frac{FP+FN}{TP+FN+FP+TN}$
- Наиболее простой способ оценки качества:
доля верных/неверных ответов
- Неадекватен при дисбалансе классов

| П\К | C | $\neg C$ |
|----------|------|----------|
| C | TP | FP |
| $\neg C$ | FN | TN |

Неадекватность Accuracy и Error при дисбалансе классов в обучающей выборке

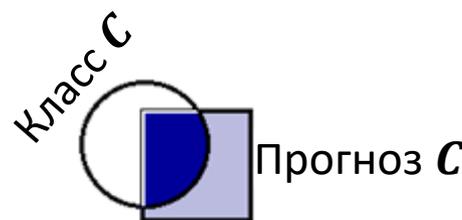
| П\К | Рак = да | Рак = нет |
|-----------|----------|------------|
| Рак = да | $TP = 0$ | $FP = 10$ |
| Рак = нет | $FN = 0$ | $TN = 990$ |

- $Accuracy = \frac{0+990}{0+0+10+990} = 99\%$, $Error = 1\%$
- Классификатор идеально распознает отсутствие рака и плохо распознает рак
- При дисбалансе классов в обучающей выборке нужны отдельные меры качества распознавания объектов из классов C и $\neg C$

Precision (точность), Recall (полнота)

- Точность* показывает долю объектов, распознанных как объекты класса C , действительно являющихся объектами класса C

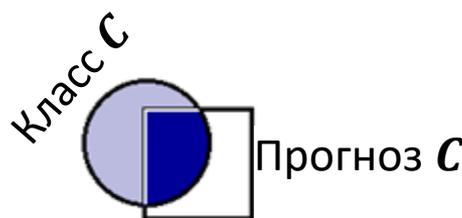
$$Precision = \frac{TP}{TP+FP}$$



| П\К | C | $\neg C$ |
|----------|------|----------|
| C | TP | FP |
| $\neg C$ | FN | TN |

- Полнота* показывает долю объектов класса C , которые действительно распознаны как объекты класса C

$$Recall = \frac{TP}{TP+FN}$$



| П\К | C | $\neg C$ |
|----------|------|----------|
| C | TP | FP |
| $\neg C$ | FN | TN |

- Точность и полнота имеют обратную зависимость

Пример

| Прогноз\Класс | Рак = Да | Рак = Нет |
|---------------|-------------------------|--------------------------|
| Рак = Да | 90 <i>TP</i> | 140 <i>FP</i> |
| Рак = Нет | 210 <i>FN</i> | 9560 <i>TN</i> |
| Всего | 300 <i>P</i> | 9700 <i>N</i> |

$$Precision = \frac{TP}{TP + FP}$$

$$Recall = \frac{TP}{TP + FN}$$

- $Accuracy = \frac{90+9560}{300+9700} = 97.7\%$, $Error = 2.3\%$
- $Precision = \frac{90}{90+140} = 39.13\%$
- $Recall = \frac{90}{90+210} = 30\%$

Меры F и F_β

- Мера F (F_1 или F -score) – гармоническое среднее точности (*precision*) и полноты (*recall*)

$$F = \frac{2 \cdot \textit{Precision} \cdot \textit{Recall}}{\textit{Precision} + \textit{Recall}}$$

- F_β – взвешенная мера точности (*precision*) и полноты (*recall*)

$$F_\beta = \frac{(1 + \beta^2) \cdot \textit{Precision} \cdot \textit{Recall}}{\beta^2 \cdot \textit{Precision} + \textit{Recall}}$$

- $\beta > 0$ показывает важность точности (*precision*) по отношению к полноте (*recall*)
- типичные значения $\beta = 2$ и $\beta = 0.5$

Пример

| Прогноз\Класс | Рак = Да | Рак = Нет |
|---------------|-------------------------|--------------------------|
| Рак = Да | 90 <i>TP</i> | 140 <i>FP</i> |
| Рак = Нет | 210 <i>FN</i> | 9560 <i>TN</i> |
| Всего | 300 <i>P</i> | 9700 <i>N</i> |

$$Precision = \frac{TP}{TP + FP}$$

$$Recall = \frac{TP}{TP + FN}$$

$$F = \frac{2 \cdot Precision \cdot Recall}{Precision + Recall}$$

- $Accuracy = \frac{90+9560}{300+9700} = 97.7\%$, $Error = 2.3\%$
- $Precision = \frac{90}{90+140} = 39.13\%$, $Recall = \frac{90}{90+210} = 30\%$
- $F = \frac{2 \cdot 0.3913 \cdot 0.3}{0.3913 + 0.3} = 0.34$

Меры качества классификации

- $Accuracy = \frac{TP+TN}{P+N}$, $Error = 1 - Accuracy$
- $Precision = \frac{TP}{TP+FP}$
- $Sensitivity = Recall = TPrate = \frac{TP}{TP+FN}$
- $Specificity = TNrate = \frac{TN}{TN+FP}$
- $FPrate = 1 - Specificity$
- $FNrate = 1 - Sensitivity$
- $F = \frac{2 \cdot Precision \cdot Recall}{Precision + Recall}$, $F_{\beta} = \frac{(1 + \beta^2) \cdot Precision \cdot Recall}{\beta^2 \cdot Precision + Recall}$

| $\Pi \backslash K$ | C | $\neg C$ |
|--------------------|------|----------|
| C | TP | FP |
| $\neg C$ | FN | TN |

Основные методы подготовки тестовой выборки

- Откладывание (*hold-out*)
 - Множество размеченных данных единожды разбивается на непересекающиеся подмножества: обучающая выборка и тестовая выборка. Типичные соотношения – 70:30, 80:20
- Случайный отбор (*random sampling*)
 - Повторить откладывание k раз, итоговая точность – среднее
- Перекрестная проверка из k итераций (*k-fold cross-validation*), обычно $k = 10$
 - Обучающая выборка разбивается на k непересекающихся частей
 - Выполняется k итераций: обучение проводится на $k - 1$ частях, тестирование проводится на части, не участвовавшей в обучении
 - Итоговая точность – отношение общих кол-в верных ответов и попыток
 - Вариация для маломощных множеств: k равно мощности выборки
- Самонастройка (*0.632 bootstrapping*)
 - По выборке из d объектов d раз строятся случайные выборки с повторением из d объектов – обучающие выборки; не отобранные объекты формируют тестовые выборки
 - $Accuracy(M) = \frac{1}{d} \sum_{i=1}^d (0.632 \cdot Accuracy(M_i)_{test_{set}} + 0.368 \cdot Accuracy(M_i)_{train_{set}})$

Литература

- Han J., Kamber M., Pei J. Data Mining: Concepts and Techniques. 3rd Edition. Morgan Kaufmann, 2011. 740 p. ISBN: 978-0123814791
 - 8. Classification: Basic Concepts. 8.1. Basic Concepts, 8.2. Decision Tree Induction, 8.5 Model Evaluation and Selection, 8.6 Techniques to Improve Classification Accuracy
- Tan P.-N., Steinbach M., Karpatne A., Kumar V. Introduction to Data Mining. 2nd Edition. Pearson, 2019. 839 p. ISBN: 978-0-13-312890-1
 - 3. Decision Tree Induction. 3.1 Basic Concepts, 3.2 General Framework for Classification, Decision Tree Classifier, 3.5 Model Selection, 3.6 Model Evaluation, 4.10 Ensemble Methods