# Задача классификации данных

*Классификация – нить Ариадны в лабиринте природы.*

*Жорж Санд*

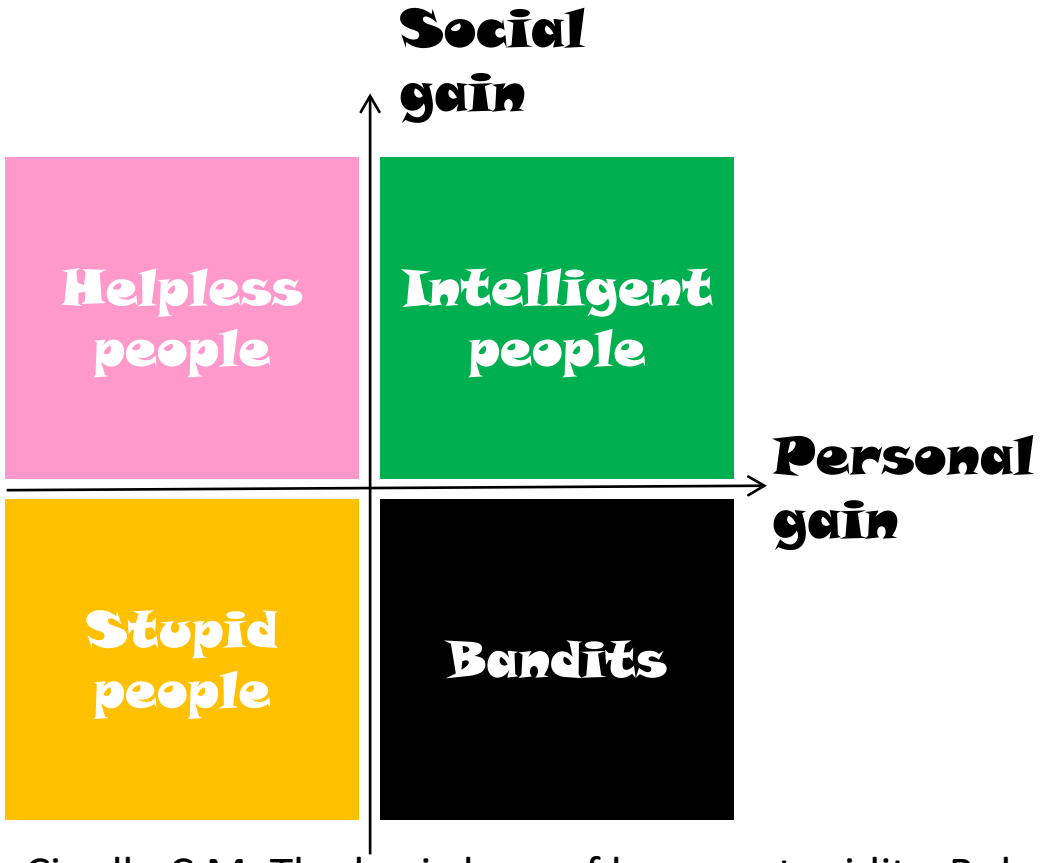


Cipolla C.M. The basic laws of human stupidity. Bologna: il Muli, 2011

# Содержание

- Основные понятия
- Деревья решений
- Байесовская классификация
- Классификация по ближайшим соседям
- Оценка качества классификации
- **Ансамблевая классификации**
  - **бэггинг**
  - **бустинг**
  - **случайный лес**

# Ансамблевая классификация с мажоритарным голосованием


Здоров


Болен


Болен

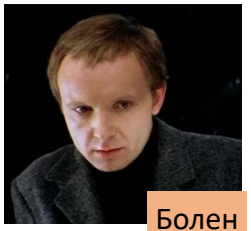
Болен


Здоров


Здоров


Здоров


Болен

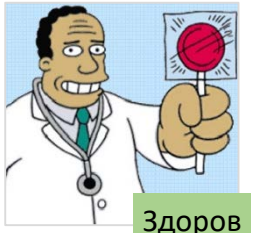
Здоров


Болен


Здоров

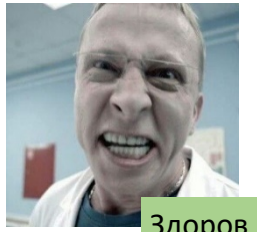
Здоров


Здоров

# Ансамблевая классификация со взвешенным голосованием

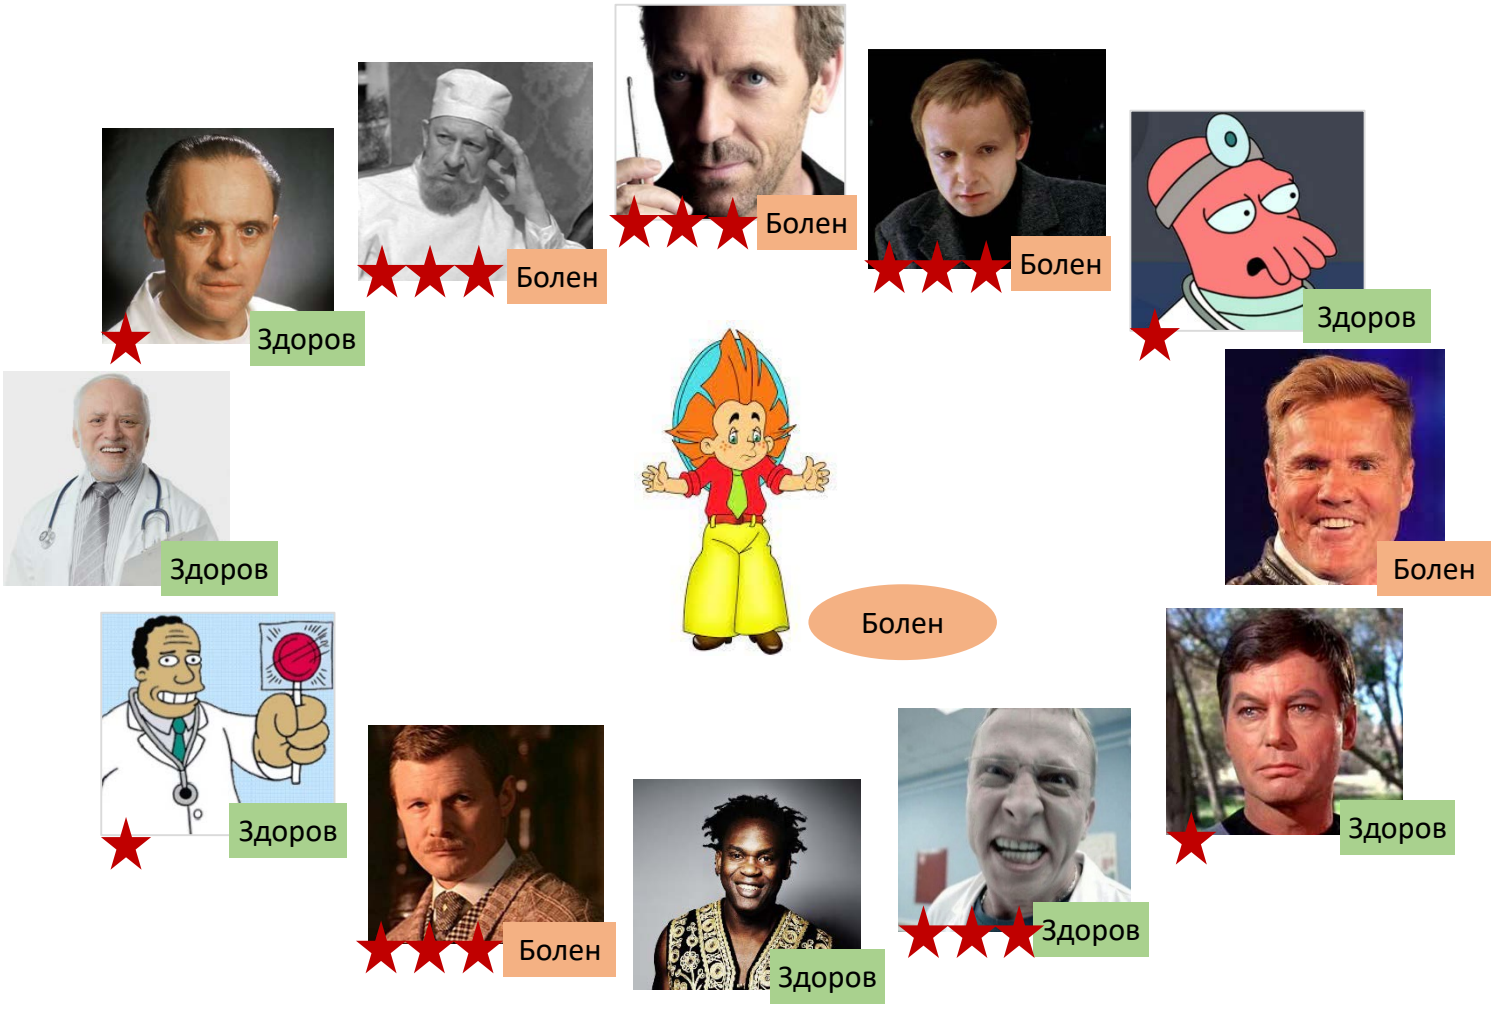

# Ансамблевая классификация

$$|D| = n = |D_i|,$$
$$\forall o \in D\colon P(o \in D_i) = 1 - (1 - 1/n)^n,$$
$$\lim_{n \to +\infty} P(o \in D_i) = 1 - 1/e \approx 0.632$$

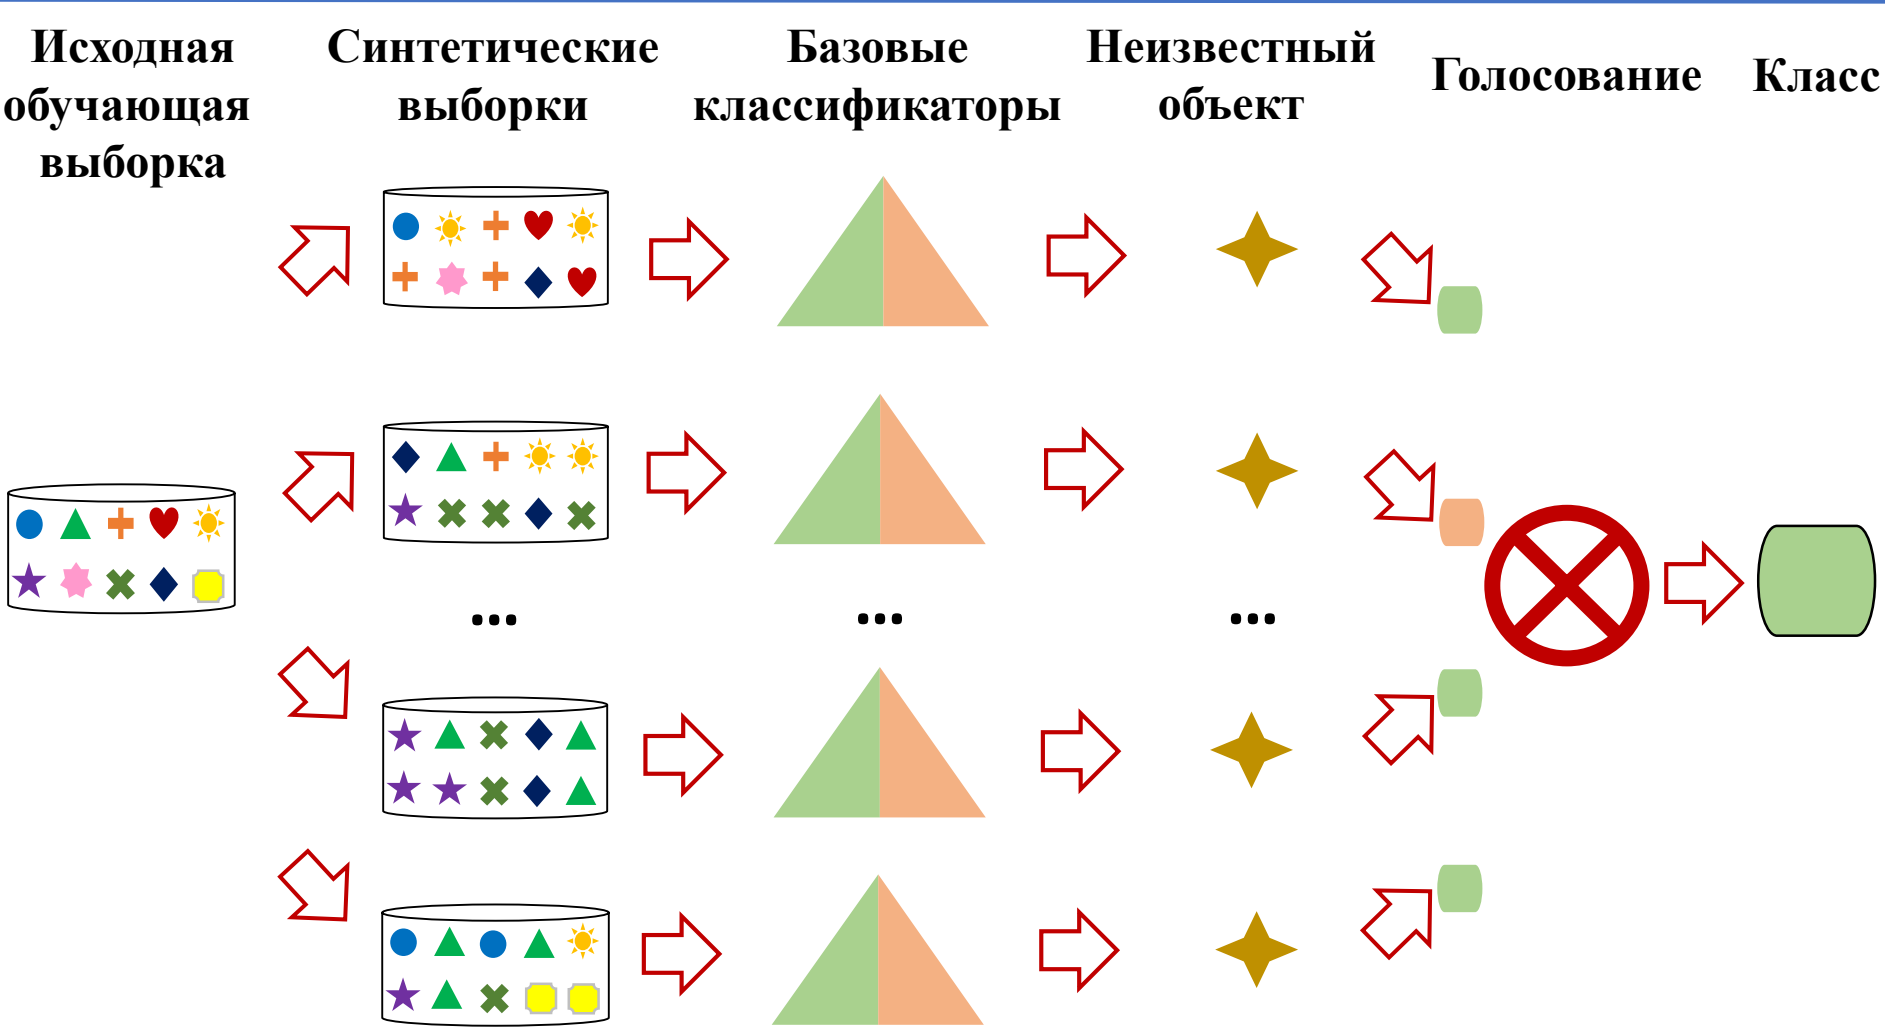

# Виды ансамблевых методов

- Манипуляции с распределением исходной обучающей выборки по выборкам участников
  - бэггинг (bagging), бустинг (boosting)
- Манипуляции со структурой объектов в выборках участников
  - случайный лес (random forest)
- Манипуляции с метками классов
  - кодирование вывода с исправлением ошибок (error-correcting output coding)

# Насколько хорошо работают ансамбли?

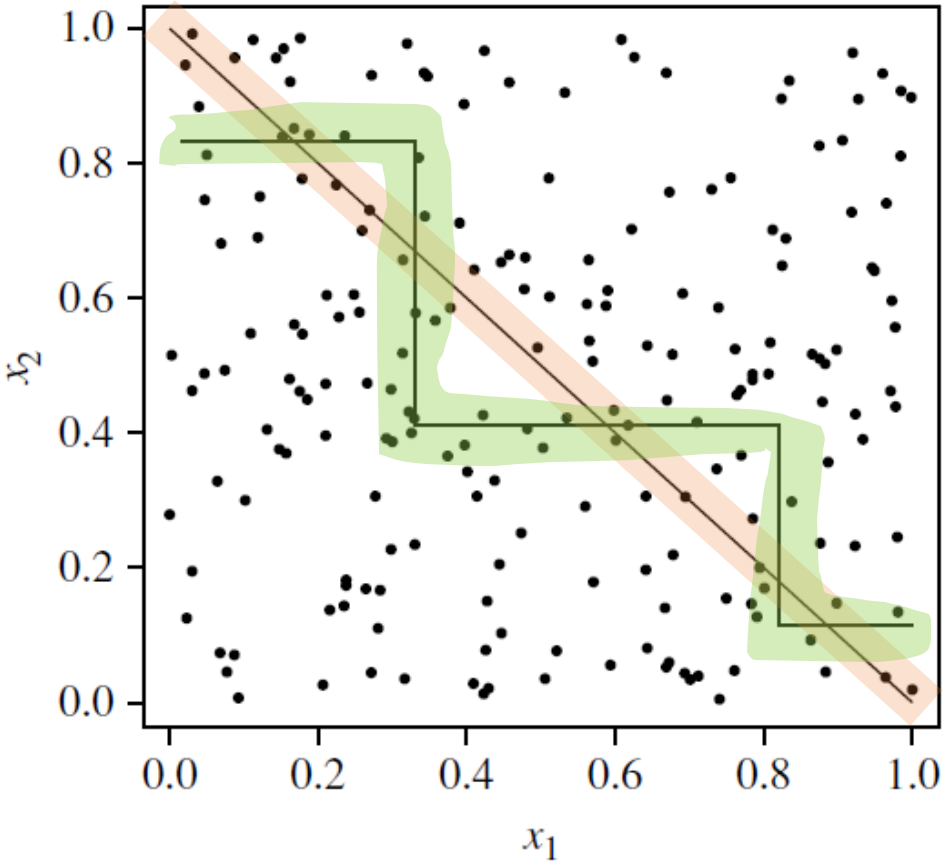


**Одно дерево решений**

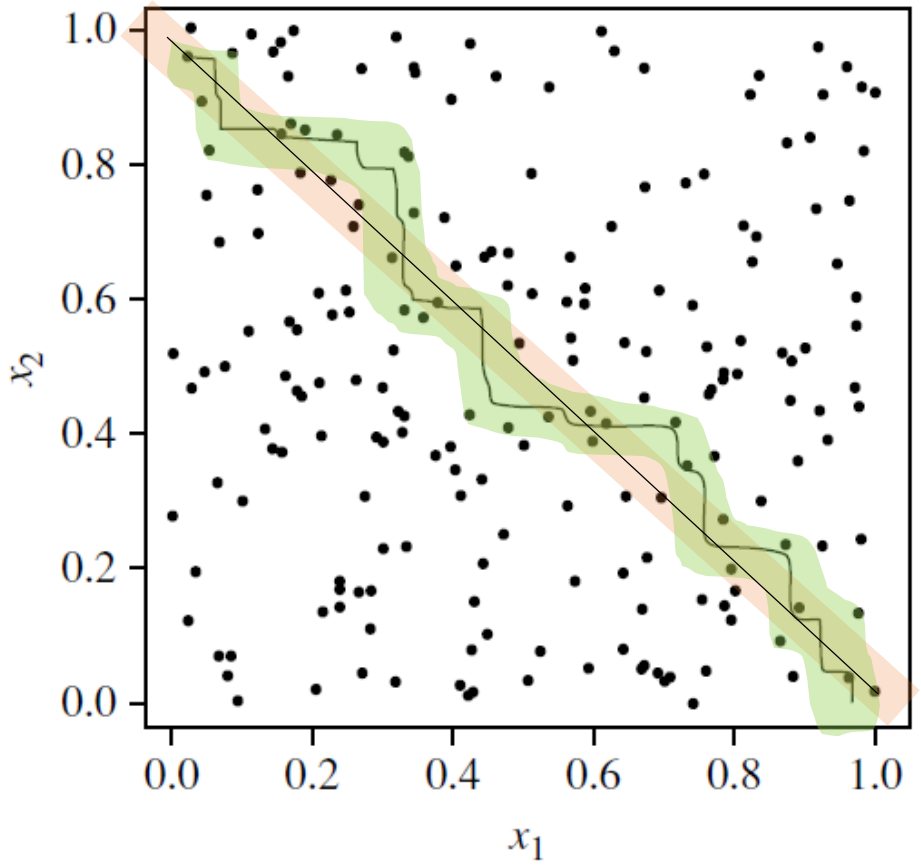


**Ансамбль деревьев решений**

# Насколько хорошо работают ансамбли?

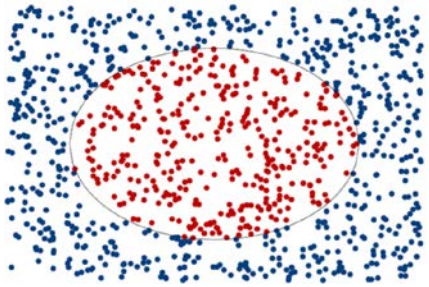

Исходное множество

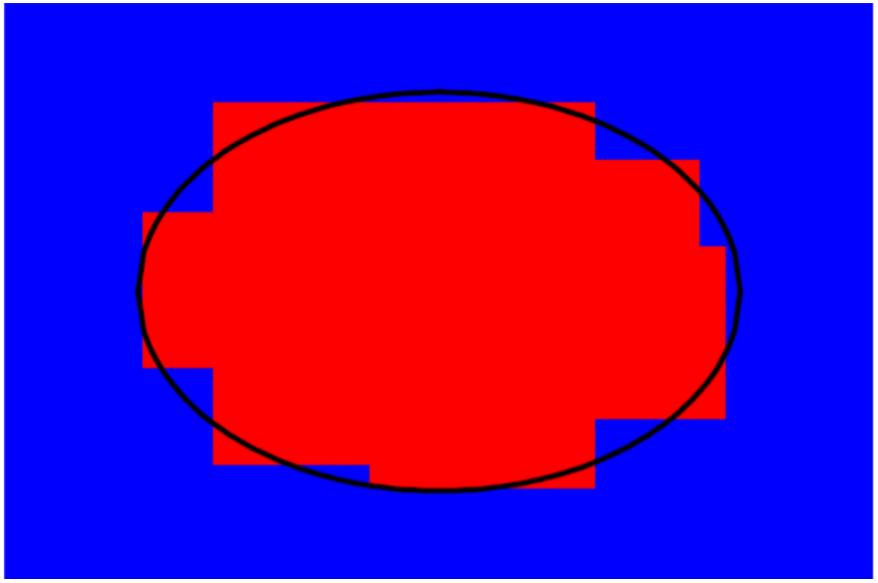

**Одно дерево решений**

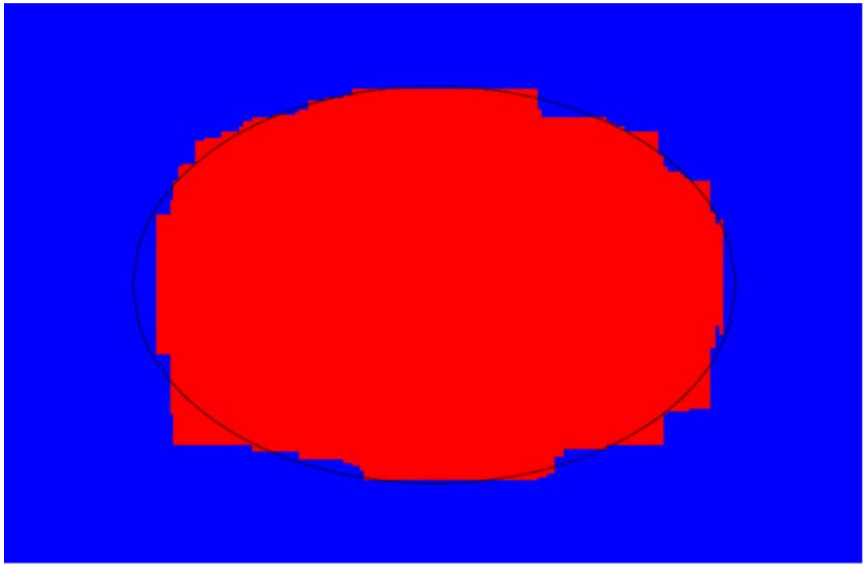

**Ансамбль деревьев решений**

# Почему ансамбли хорошо работают?

- Дано $n$ базовых классификаторов с вероятностью ошибки $\varepsilon$ 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

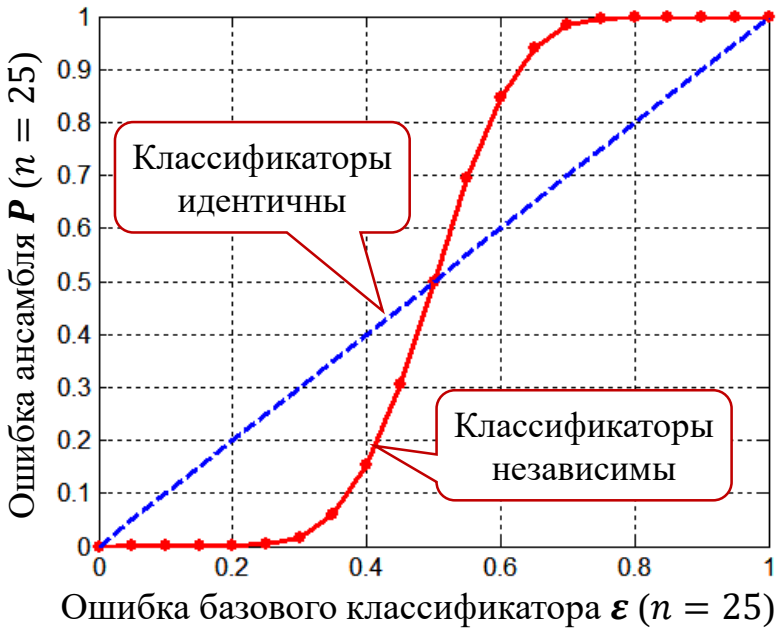

# Бэггинг (Bagging, Bootstrap Aggregating)

- Базовые идеи
  - Сэмплинг с повторением при формировании выборок
  - Мажоритарное голосование 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, чему у одного классификатора
  - Устойчивость к шумам в данных при несущественном снижении точности

# Алгоритм бэггинга

$$\delta(\cdot) = \begin{cases} 1, & \cdot - \text{Истина} \\ 0, & \cdot - \text{Ложь} \end{cases}$$

- Вход:
  - Обучающая выборка $D$
  - Базовые классификаторы: $C_1, \dots, C_k$
- Метод

  **for** $i := 1$ **to** $k$ **do**

  Создать случайную выборку с повторением $D_i, |D_i| = |D|$

  Обучить классификатор $C_i$ на выборке $D_i$
- Результат

  $C^*(x) = \arg\max_y \sum_{i=1}^{k} \delta(C_i(x) = y)$

# 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

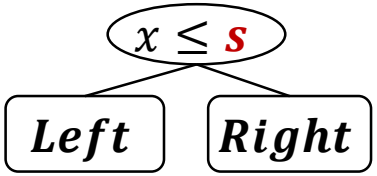


Ансамбль примитивных классификаторов

| 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 |

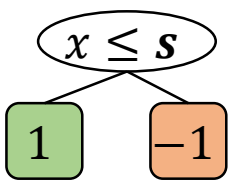


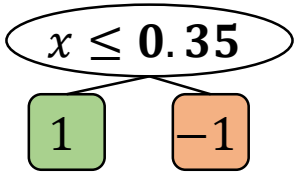

# Пример бэггинга: выборки и обучение 1-го – 5-го участников ансамбля

| 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 |

$x \le s$

1 −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 |

$x \le 0.35$

1 −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 |

$x \le 0.7$

1 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 |

$x \le 0.35$

1 −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 |

$x \le 0.3$

1 −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 |

$x \le 0.35$

1 −1

# Пример бэггинга: выборки и обучение 6-го – 10-го 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 |

$x \le s$

1 −1

**6**

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

$x \le 0.75$

−1 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 |

$x \le 0.75$

−1 1

**8**

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

$x \le 0.75$

−1 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 |

$x \le 0.75$

−1 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 |

$x \le 0.05$

1 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** |

# Достоинства и недостатки бэггинга

- Плюсы
  - Простота реализации
  - Возможность параллельного обучения
  - Увеличение точности по сравнению с одним классификатором, устойчивость к шумам
- Минусы
  - Недетерминированность результата (выборки формируются случайно)
  - Сложность интерпретации результатов по сравнению с одним классификатором
  - Отсутствие строгого математического обоснования условий улучшения прогноза ансамбля

# 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:**
  $(x_1, y_1), \ldots, (x_n, y_n)$, веса $w_1, \ldots, w_n$
- **Ансамбль:** $C_1, \ldots, C_k$
- **Ошибка участника ансамбля:**
  $\varepsilon_i = \frac{1}{n}\sum_{j=1}^{n} w_j \cdot \delta(C_i(x_j) \neq y_j)$
- **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 $(\sum_i w_i^{(j+1)} = 1)$

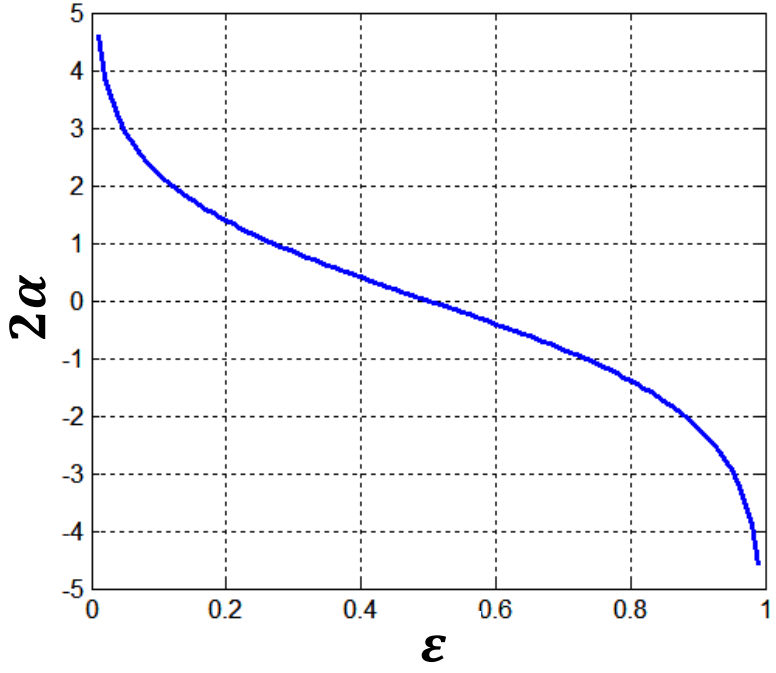

# Алгоритм AdaBoost

1: $\mathbf{w} = \{w_j = 1/N \mid j = 1, 2, \ldots, N\}$. {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: $\epsilon_i = \frac{1}{N}\left[\sum_j w_j \, \delta\big(C_i(x_j) \neq y_j\big)\right]$ {Calculate the weighted error.}
8: **if** $\epsilon_i > 0.5$ **then**
9: $\mathbf{w} = \{w_j = 1/N \mid j = 1, 2, \ldots, N\}$.
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: $C^*(\mathbf{x}) = \underset{y}{\operatorname{argmax}} \sum_{j=1}^{T} \alpha_j \delta(C_j(\mathbf{x}) = y)\big)$.

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

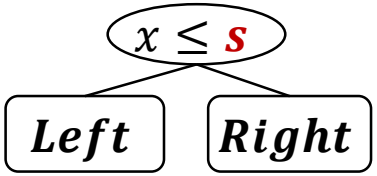


Ансамбль примитивных классификаторов

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

# Пример бустинга: выборки и обучение 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**

| $X$ | $Class$ | $weight$ |
|---|---|---|
| 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 |
| 0.8 | 1 | 0.1 |
| 1.0 | 1 | 0.1 |

**2**

| $X$ | $Class$ | $weight$ |
|---|---|---|
| 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**

| $X$ | $Class$ | $weight$ |
|---|---|---|
| 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 |

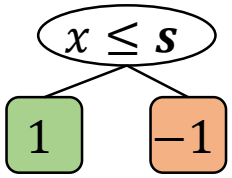


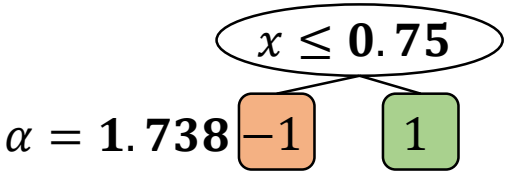


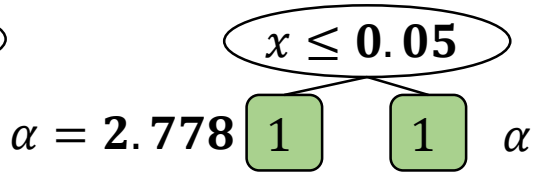


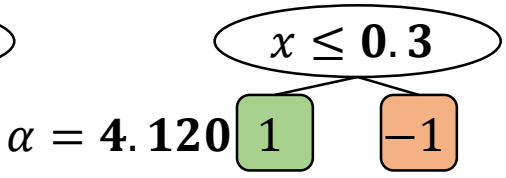

# Пример бустинга: проверка ансамбля

| Уч. | $s$ | $L$ | $R$ | $\alpha$ |
|---|---|---|---|---|
| 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** |

# Бустинг: ошибка обучения ансамбля

- $\varepsilon_{ensemble} \leq \prod_i \sqrt{\varepsilon_i(1-\varepsilon_i)}$
- Если ошибка участника ансамбля $\varepsilon_i < 0.5$, то мы можем ввести $\gamma_i$ – меру улучшения классификации участником по сравнению с угадыванием: $\varepsilon_i = 0.5 - \gamma_i$. Тогда

$$\varepsilon_{ensemble} \leq \prod_i \sqrt{1-4\gamma_i^2} \leq e^{-2\sum_i \gamma_i^2}$$

- Если $\exists \gamma^* \; \forall i \; \gamma_i < \gamma^*$, то ошибка обучения ансамбля убывает экспоненциально (быстрая сходимость алгоритма)

# Случайный лес (Random Forest)

- Вариация бэггинга
  - Участники ансамбля – деревья решений
  - Для обучения участника выбирается случайное подмножество атрибутов исходной выборки (обычно мощность одна для всех участников, может быть своя у каждого участника) и готовится соотв. обучающая выборка
    - Forest-RI: большое число атрибутов $p$, число выбираемых атрибутов $m = \lceil \log_2 p \rceil$ или $m = \lceil \sqrt{p} \rceil$
    - Forest-RC: малое число атрибутов; генерация $f$ искусственных атрибутов как линейных комбинаций случайных коэффициентов, равномерно распределенных в отрезке $[-1, 1]$ и выбор из них $m$ случайных атрибутов
  - Класс неизвестного объекта определяется мажоритарным голосованием участников
- Основная идея
  - Увеличение вариации деревьев в ансамбле и снижение корреляции между результатами их классификации;
  - Блокада потенциально доминирующих атрибутов (с вероятностью $\frac{p-m}{p}$), которые могут быть добавлены к каждому участнику
- Преимущества и недостатки
  - Высокая скорость обучения; распараллеливаемость
  - Устойчивость к выбросам и несбалансированным данным
  - Неинтерпретируемость, высокие требования к памяти

# Сравнение точности ансамблевых методов

| Data Set | Number of (Attributes, Classes, Records) | Decision Tree (%) | Bagging (%) № 3 | Boosting (%) № 2 | RF (%) № 1 |
|---|---|---|---|---|---|
| Anneal | (39, 6, 898) | 92.09 | 94.43 | 95.43 | 95.43 |
| Australia | (15, 2, 690) | 85.51 | 87.10 | 85.22 | 85.80 |
| Auto | (26, 7, 205) | 81.95 | 85.37 | 85.37 | 84.39 |
| Breast | (11, 2, 699) | 95.14 | 96.42 | 97.28 | 96.14 |
| Cleve | (14, 2, 303) | 76.24 | 81.52 | 82.18 | 82.18 |
| Credit | (16, 2, 690) | 85.8 | 86.23 | 86.09 | 85.8 |
| Diabetes | (9, 2, 768) | 72.40 | 76.30 | 73.18 | 75.13 |
| German | (21, 2, 1000) | 70.90 | 73.40 | 73.00 | 74.5 |
| Glass | (10, 7, 214) | 67.29 | 76.17 | 77.57 | 78.04 |
| Heart | (14, 2, 270) | 80.00 | 81.48 | 80.74 | 83.33 |
| Hepatitis | (20, 2, 155) | 81.94 | 81.29 | 83.87 | 83.23 |
| Horse | (23, 2, 368) | 85.33 | 85.87 | 81.25 | 85.33 |
| Ionosphere | (35, 2, 351) | 89.17 | 92.02 | 93.73 | 93.45 |
| Iris | (5, 3, 150) | 94.67 | 94.67 | 94.00 | 93.33 |
| Labor | (17, 2, 57) | 78.95 | 84.21 | 89.47 | 84.21 |
| Led7 | (8, 10, 3200) | 73.34 | 73.66 | 73.34 | 73.06 |
| Lymphography | (19, 4, 148) | 77.03 | 79.05 | 85.14 | 82.43 |
| Pima | (9, 2, 768) | 74.35 | 76.69 | 73.44 | 77.60 |
| Sonar | (61, 2, 208) | 78.85 | 78.85 | 84.62 | 85.58 |
| Tic-tac-toe | (10, 2, 958) | 83.72 | 93.84 | 98.54 | 95.82 |
| Vehicle | (19, 4, 846) | 71.04 | 74.11 | 78.25 | 74.94 |
| Waveform | (22, 3, 5000) | 76.44 | 83.30 | 83.90 | 84.04 |
| Wine | (14, 3, 178) | 94.38 | 96.07 | 97.75 | 97.75 |
| Zoo | (17, 7, 101) | 93.07 | 93.07 | 95.05 | 97.03 |

# Литература

- Han J., Kamber M., Pei J. Data Mining: Concepts and Techniques. 3rd Edition. Morgan Kaufmann, 2011. 740 p. ISBN: 978-0123814791
  - 8.6 Techniques to Improve Classification Accuracy, pp. 377-385
- 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
  - 4.10 Ensemble Methods, pp. 296-312