

# Разбор летучки

---

# Лекция 4

## Деревья принятия решений

---

Екатерина Тузова

## Мотивирующий пример

---


# Мотивирующий пример



```
In [10]: pokemons.head()
```

```
Out[10]:
```

	Type_1	Type_2	isLegendary	Color	hasGender	Egg_Group_1	Egg_Group_2	hasMegaEvolution	Body_Style
0	Grass	Poison	False	Green	True	Monster	Grass	False	quadruped
1	Grass	Poison	False	Green	True	Monster	Grass	False	quadruped
2	Grass	Poison	False	Green	True	Monster	Grass	True	quadruped
3	Fire	NaN	False	Red	True	Monster	Dragon	False	bipedal_tailed
4	Fire	NaN	False	Red	True	Monster	Dragon	False	bipedal_tailed



$X^l = (x_i, y_i)_{i=1}^l$  - обучающая выборка.

**Логическая закономерность** – предикат  $\beta : X \rightarrow \{0, 1\}$ , который удовлетворяет двум требованиям:

$X^l = (x_i, y_i)_{i=1}^l$  - обучающая выборка.

**Логическая закономерность** – предикат  $\beta : X \rightarrow \{0, 1\}$ , который удовлетворяет двум требованиям:

1. Интерпретируемость



$X^l = (x_i, y_i)_{i=1}^l$  - обучающая выборка.

**Логическая закономерность** – предикат  $\beta : X \rightarrow \{0, 1\}$ , который удовлетворяет двум требованиям:


1. Интерпретируемость
2. Информативность относительно одного из классов  $c \in Y$

$X^l = (x_i, y_i)_{i=1}^l$  – обучающая выборка.

Предикат  $\beta : X \rightarrow \{0, 1\}$

**Задача:** Найти множество логических закономерностей  $\mathcal{B}$  по  $X^l$ .  
Построить алгоритм  $a(X, \mathcal{B}) \rightarrow y$ , способный классифицировать произвольный объект  $x \in X$ .

1. Записывается на естественном языке
2. Зависит от небольшого числа признаков



**Идея:** Максимизировать количество правильно распознанных объектов класса  $c$  и при этом минимизировать количество объектов, ошибочно классифицированных как класс  $c$

**Идея:** Максимизировать количество правильно распознанных объектов класса  $c$  и при этом минимизировать количество объектов, ошибочно классифицированных как класс  $c$

$$tp(\beta) = \# \{x_i : \beta(x_i) = 1, y_i = c\} \rightarrow \max$$

**Идея:** Максимизировать количество правильно распознанных объектов класса  $c$  и при этом минимизировать количество объектов, ошибочно классифицированных как класс  $c$

$$tp(\beta) = \# \{x_i : \beta(x_i) = 1, y_i = c\} \rightarrow \max$$

$$fp(\beta) = \# \{x_i : \beta(x_i) = 1, y_i \neq c\} \rightarrow \min$$

1. Какого вида закономерности  $\beta(x)$  нужны?
2. Как определять информативность?
3. Как выбирать закономерности?
4. Как объединять закономерности в алгоритм?



# Виды правил

---

– Пороговое условие

$$\beta(x) = [x^j \leq a_j] \text{ или } [a_j \leq x^j \leq b_j]$$

- Пороговое условие

$$\beta(x) = [x^j \leq a_j] \text{ или } [a_j \leq x^j \leq b_j]$$

- Конъюнкция из  $J$  пороговых условий

$$\beta(x) = \bigwedge_{j \in J} [a_j \leq x^j \leq b_j]$$

- Пороговое условие

$$\beta(x) = [x^j \leq a_j] \text{ или } [a_j \leq x^j \leq b_j]$$

- Конъюнкция из  $J$  пороговых условий

$$\beta(x) = \bigwedge_{j \in J} [a_j \leq x^j \leq b_j]$$

- Синдром – выполнение не менее  $d$  условий из  $J$

$$\beta(x) = \left[ \sum_{j \in J} [a_j \leq x^j \leq b_j] \geq d \right]$$

Как собрать классификатор  
из закономерностей?

---

**Идея:**

Возьмем  $\beta_1(x), \beta_2(x), \dots, \beta_T(x)$  закономерностей и будем по порядку применять на объекте. Как только предикат  $\beta_i$  сработал – вернем соответствующий класс  $c_i$ .

## Идея:


Возьмем  $\beta_1(x), \beta_2(x), \dots, \beta_T(x)$  закономерностей и будем по порядку применять на объекте. Как только предикат  $\beta_i$  сработал – вернем соответствующий класс  $c_i$ .

Каждое правило принимает окончательное решение  $\Rightarrow$  ошибка правила равна ошибке всего алгоритма

# Бинарное решающее дерево

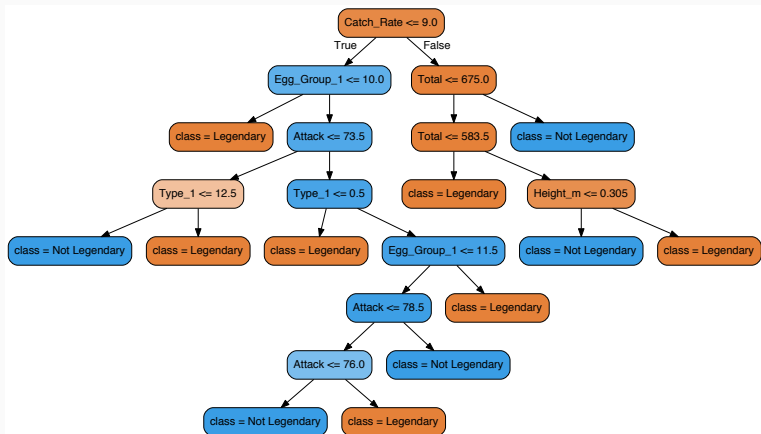
Бинарное решающее дерево – алгоритм классификации  $a(x, \beta)$ , задающийся бинарным деревом:

- $\forall v \in V_{inner} \rightarrow \beta_v : X \rightarrow \{0, 1\}, \beta \in \mathcal{B}$
- $\forall v \in V_{leaf} \rightarrow$  имя класса  $c_v \in Y$





# Пример решающего дерева



# Алгоритм построения ID3

```
1 function LEARNID3( $U, \mathcal{B}$ )
2   if все объекты из  $U$  лежат в одном классе  $c \in Y$  then
3     return новый лист  $v$ ,  $c_v = c$ 
4    $\beta^* = \max_{\beta \in \mathcal{B}} I(\beta, U)$ 
5    $U_{left} = \{x \in U : \beta^*(x) = 0\}$ 
6    $U_{right} = \{x \in U : \beta^*(x) = 1\}$ 
7   if  $U_{left} = \emptyset$  или  $U_{right} = \emptyset$  then
8     return  $v$ ,  $c_v = \text{Majority}(U)$ 
9   Создать новую внутреннюю вершину  $v$ :  $\beta_v = \beta^*$ 
10   $L_v = \text{LearnID3}(U_{left}, \mathcal{B})$ 
11   $R_v = \text{LearnID3}(U_{right}, \mathcal{B})$ 
12  return  $v$ 
```

# Критерии информативности

---

$$tp(\beta) = \# \{x_i : \beta(x_i) = 1, y_i = c\} \rightarrow \max$$

$$tn(\beta) = \# \{x_i : \beta(x_i) = 0, y_i \neq c\} \rightarrow \max$$

$$fp(\beta) = \# \{x_i : \beta(x_i) = 1, y_i \neq c\} \rightarrow \min$$

$$fn(\beta) = \# \{x_i : \beta(x_i) = 0, y_i = c\} \rightarrow \min$$

$$tp(\beta) = \# \{x_i : \beta(x_i) = 1, y_i = c\} \rightarrow \max$$

$$tn(\beta) = \# \{x_i : \beta(x_i) = 0, y_i \neq c\} \rightarrow \max$$

$$fp(\beta) = \# \{x_i : \beta(x_i) = 1, y_i \neq c\} \rightarrow \min$$


$$fn(\beta) = \# \{x_i : \beta(x_i) = 0, y_i = c\} \rightarrow \min$$


$$Precision = \frac{tp}{tp+fp}$$

$$Recall = TPR = \frac{tp}{tp+fn}$$

$$FPR = \frac{fp}{fp+tn}$$

# Precision-Recall





AUC – Area under the ROC curve

## Пример свертки двух критериев

Пусть число примеров искомого класса 200 и число остальных объектов 100

$tp$	$fp$	$tp - fp$	$tp - 5fp$	$Precision$
50	0	50	50	1
100	50	50	-150	0.6
50	9	41	5	0.84
5	0	5	5	1



$$I(\beta, X^l) = \# \{(x_i, x_j) : \beta(x_i) = \beta(x_j), y_i \neq y_j\}$$


$$H(U) = - \sum_{i=1}^C p_i \log_2 p_i$$

$p_i$  – процентное соотношение объектов класса  $i$  в выборке  $U$

# Энтропия Шеннона

$$H(U) = - \sum_{i=1}^C p_i \log_2 p_i$$

$p_i$  – процентное соотношение объектов класса  $i$  в выборке  $U$



Прирост информации – уменьшение энтропии.

$$H = - \sum_{i=1}^C p_i \log_2 p_i$$

$$IGain(U, x^j) = H(U) - \sum_v \frac{|U_v|}{|U|} H(U_v)$$

$$v \in values(x^j) \quad U_v = \{x \in U | x^j = v\}$$

+ Интерпретируемость и простота классификации

- + Интерпретируемость и простота классификации
- + Допустимы разнотипные данные и данные с пропусками

- + Интерпретируемость и простота классификации
- + Допустимы разнотипные данные и данные с пропусками
- + Не бывает отказов от классификации

- + Интерпретируемость и простота классификации
- + Допустимы разнотипные данные и данные с пропусками
- + Не бывает отказов от классификации
- + Трудоёмкость линейна по длине выборки





- Жадный ID3 сильно переобучается


- Жадный ID3 сильно переобучается
- Высокая чувствительность к шуму, к составу выборки, к критерию информативности

- Жадный ID3 сильно переобучается
- Высокая чувствительность к шуму, к составу выборки, к критерию информативности
- Чем дальше  $v$  от корня, тем меньше надёжность выбора  $\beta_v$ ,  $c_v$

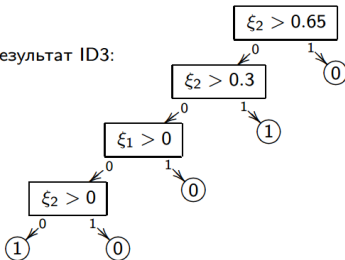
# Переобучение



Оптимальное дерево для задачи XOR:



Результат ID3:



## Подрезание дерева C4.5

$X^k$  – независимая контрольная выборка,  $k \approx 0.5l$

Для всех  $v \in V_{inner}$ :

$U_v$  = подмножество объектов  $X^k$ , дошедших до  $v$

Если  $U_v = \emptyset$ :

Вернуть новый лист  $v$ ,  $c_v = \text{Majority}(U)$

Вычислить число ошибок четырьмя способами:

$r(v)$  – поддеревом, растущим из вершины  $v$

$r_L(v)$  – левой дочерней вершины  $L_v$

$r_R(v)$  – правой дочерней вершины  $R_v$

$r_c(v)$  – к классу  $c \in Y$

В зависимости от того, какое из них минимально:

Сохранить поддерево  $v$

Заменить поддерево  $v$  поддеревом  $L_v$

Заменить поддерево  $v$  поддеревом  $R_v$


Заменить  $v$  листом  $c_v = \min_{c \in Y} r_c(v)$

# Небрежные решающие деревья

**Идея:** Сделаем дерево сбалансированным. Для этого нужно для всех узлов одного уровня использовать одинаковое условие ветвления.

# Небрежные решающие деревья

**Идея:** Сделаем дерево сбалансированным. Для этого нужно для всех узлов одного уровня использовать одинаковое условие ветвления.



**Идея:** Можно использовать результаты нескольких алгоритмов, а не одного.



Голосование деревьев классификации,  $Y = \{-1, +1\}$

$$a(t) = \text{Majority}(b_t(x))$$

- Каждое дерево  $b_t(x)$  обучается по случайной выборке с повторениями
- В каждой вершине предикат выбирается из случайного подмножества  $n$  предикатов

Вопросы?

## Что почитать по этой лекции

- G. James, D. Witten, T. Hastie, R. Tibshirani "An Introduction to Statistical Learning" Chapter 8
- Воронцов "Логические алгоритмы классификации"

## На следующей лекции

- Байесовские методы классификации
- Вероятностная постановка задачи
- Оптимальный Байесов классификатор
- Наивность
- Максимальное правдоподобие
- Разные распределения