

Искусственный Интеллект

Лекция 7: Деревья решений. Ансамбли моделей

Мартынюк Полина Антоновна

telegram: @PAMartynyuk

email: pa-martynyuk@yandex.ru



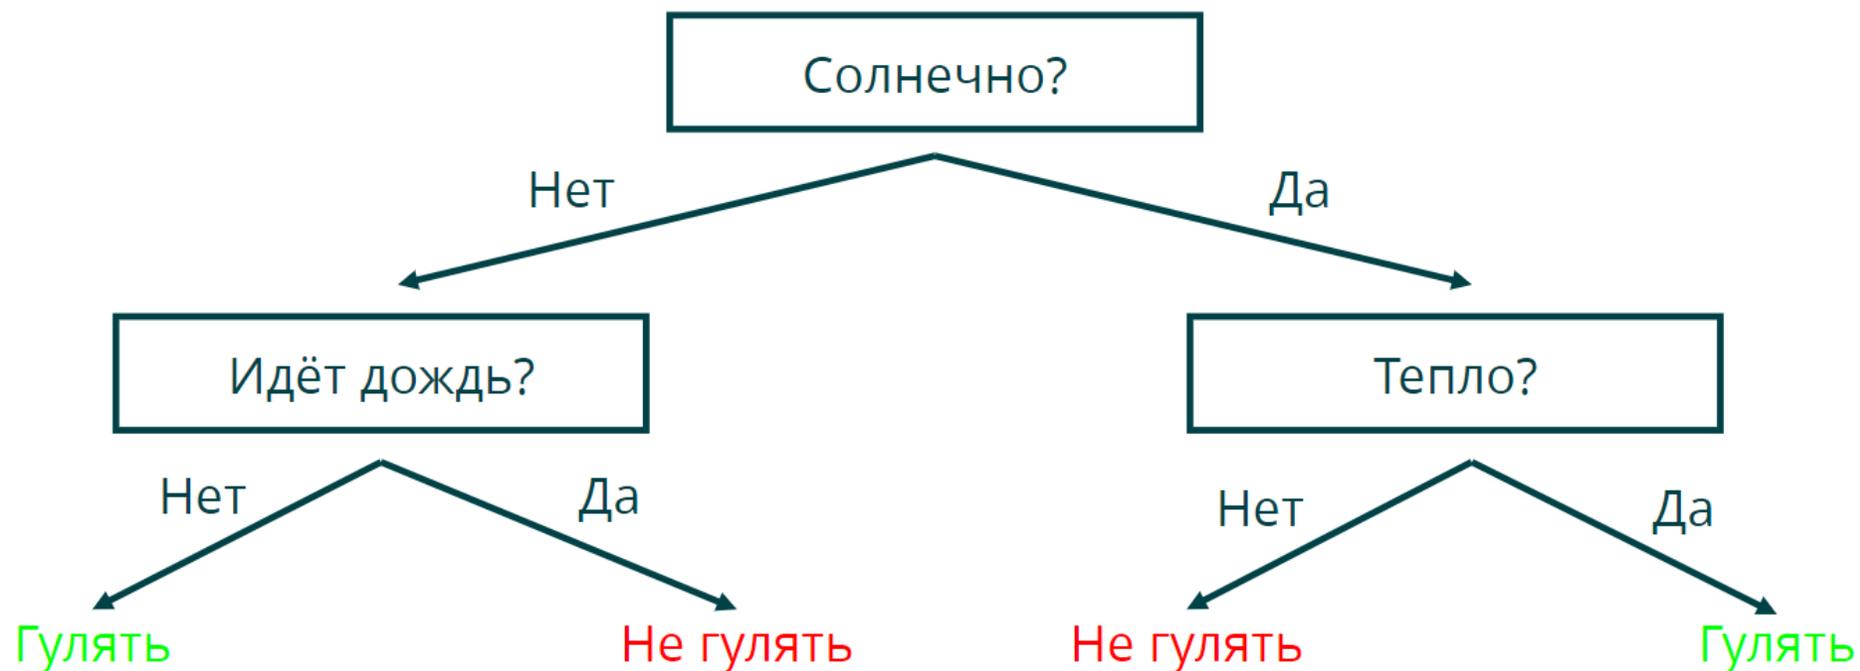
Проблема

- Умеем обучать модель для решения задачи классификации
- Умеем обучать модель для решения задачи регрессии

Проблемы внедрения в бизнес:

- А как работает модель?
- Модель предсказуема?
- Где гарантия того, что модель не наделает ошибок?

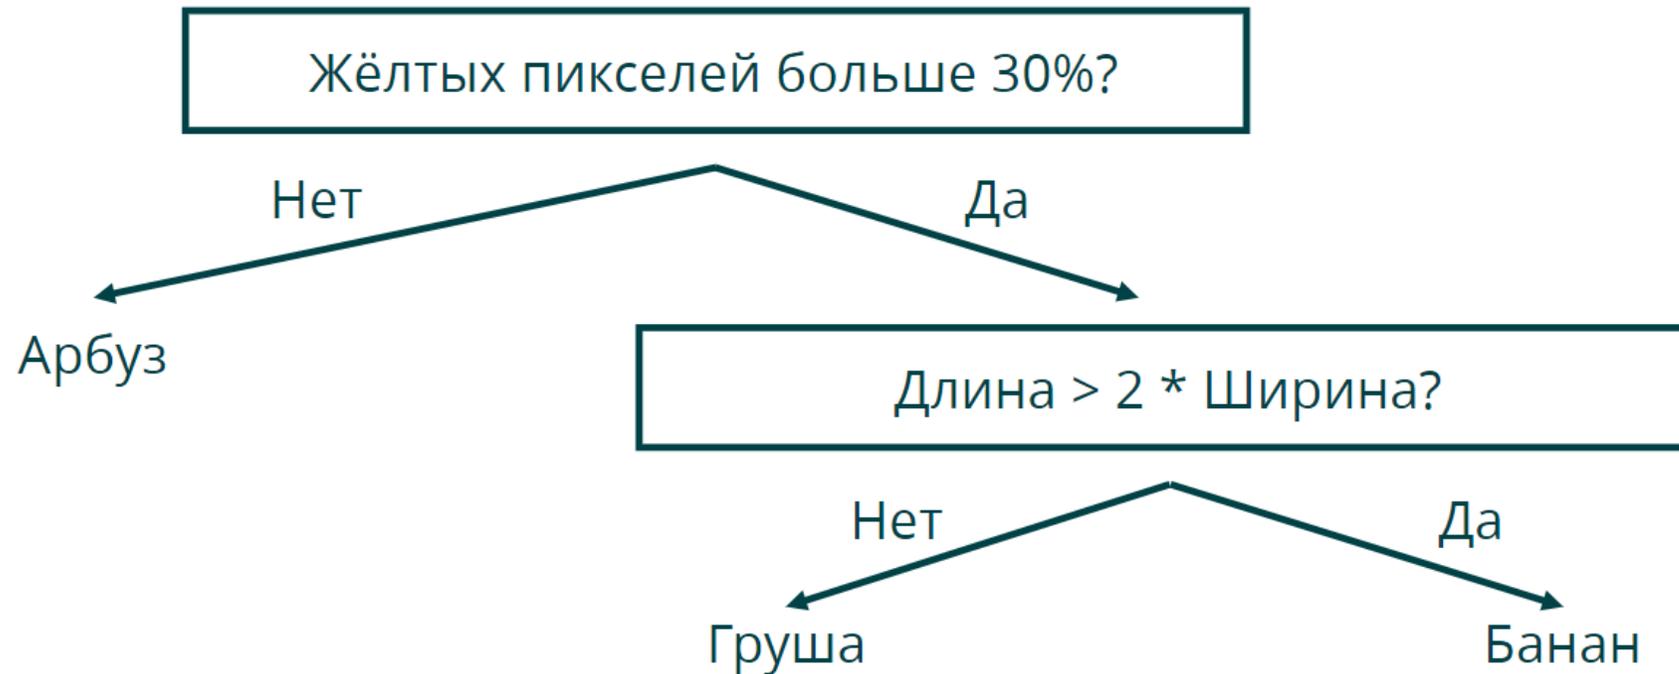
Деревья решений



В чем измерить «солнечность»? Что значит «тепло»?

Деревья решений

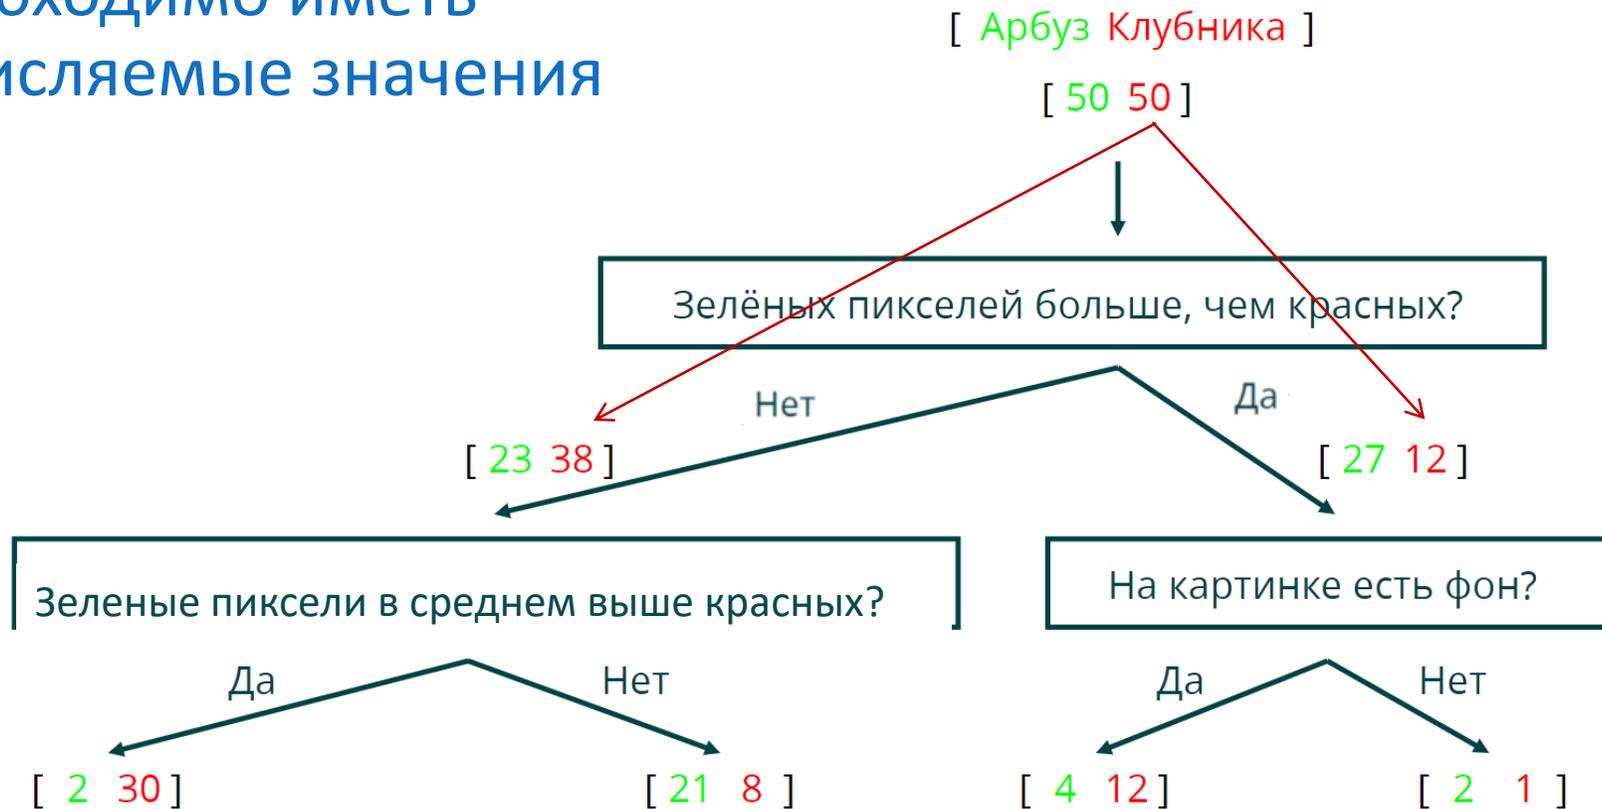
- Необходимо иметь исчисляемые значения



Условия представимы в виде математических формул → математическая модель
Глубина дерева = 2
Как еще можно оценить дерево?

Деревья решений

- Необходимо иметь исчисляемые значения



Проблема – в условиях должны быть задействованы фичи (условия по фичам – унифицированные условия)

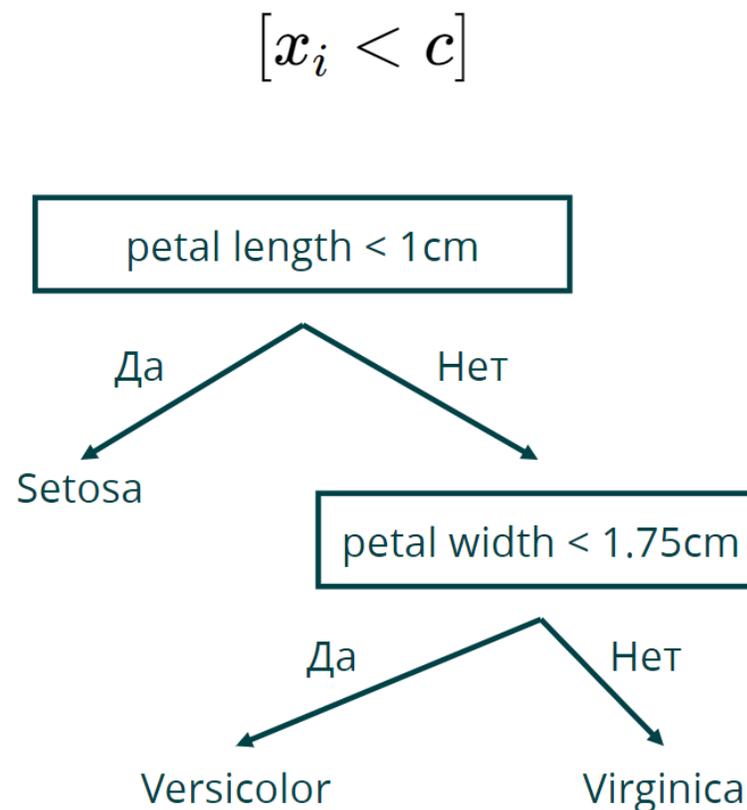
Деревья решений

Формат условий

- 1 условие – 1 фича (1 признак)

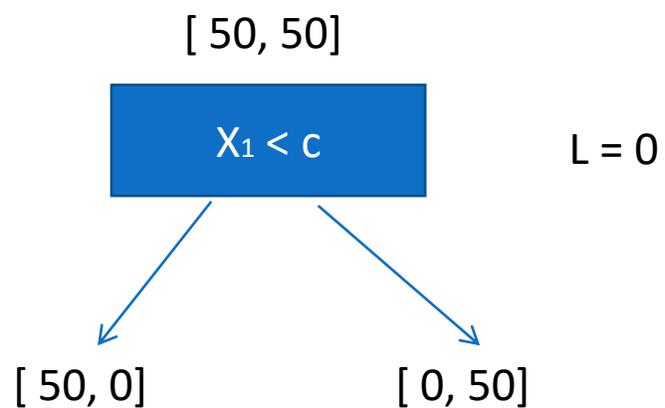
| petal length | petal width | sepal length | sepal width | target |
|--------------|-------------|--------------|-------------|------------|
| | | | | virginica |
| | | | | versicolor |
| | | | | setosa |
| | | | | virginica |
| | | | | virginica |
| | | | | setosa |
| | | | | versicolor |

Проблема – как подобрать фичи и условия?

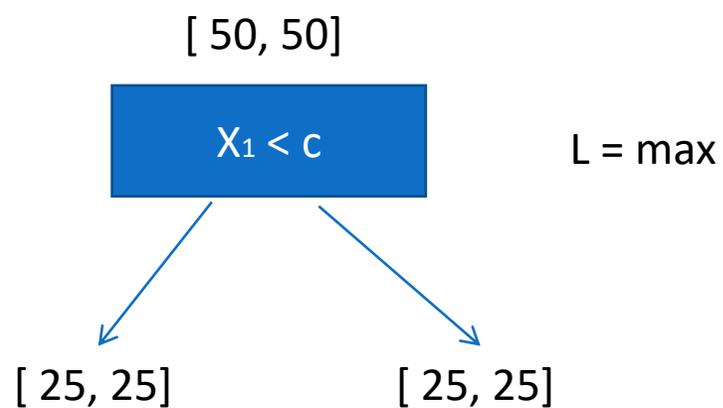


Деревья решений

Идеальный вариант

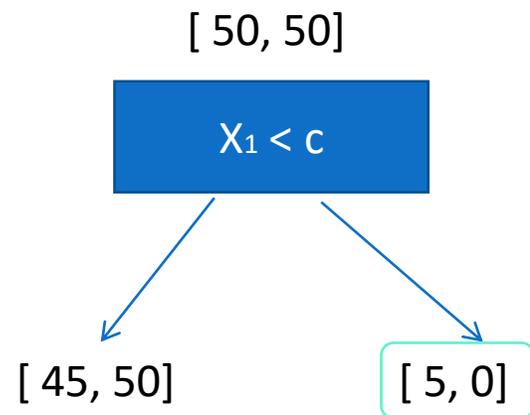


Наихудший вариант



Деревья решений

Очень специфичное условие – разделение хорошее, но мала доля отделенных элементов класса → надо следить, какую долю наблюдений отсекает условие



Деревья решений

Функция ошибки для дерева решений

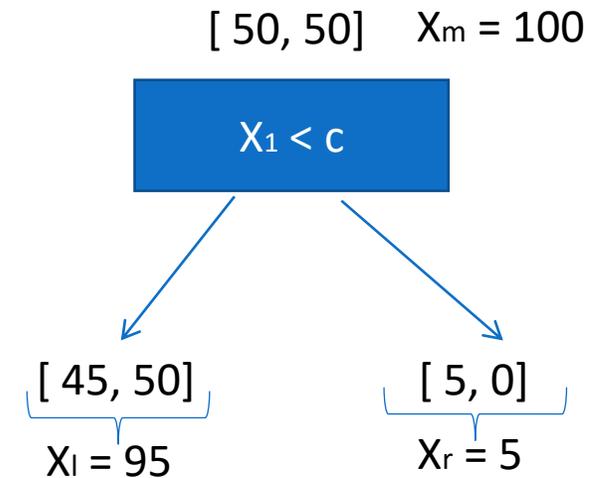
Ошибка слева
(критерий информативности)

$$L(X_m, i, c) = I_{left} + I_{right}$$

$$L(X_m, i, c) = \frac{X_l}{X_m} I_{left} + \frac{X_r}{X_m} I_{right}$$

0.95 0.05

$$L(X_m, i, c) = \frac{X_l}{X_m} I(X_l) + \frac{X_r}{X_m} I(X_r)$$



Деревья решений

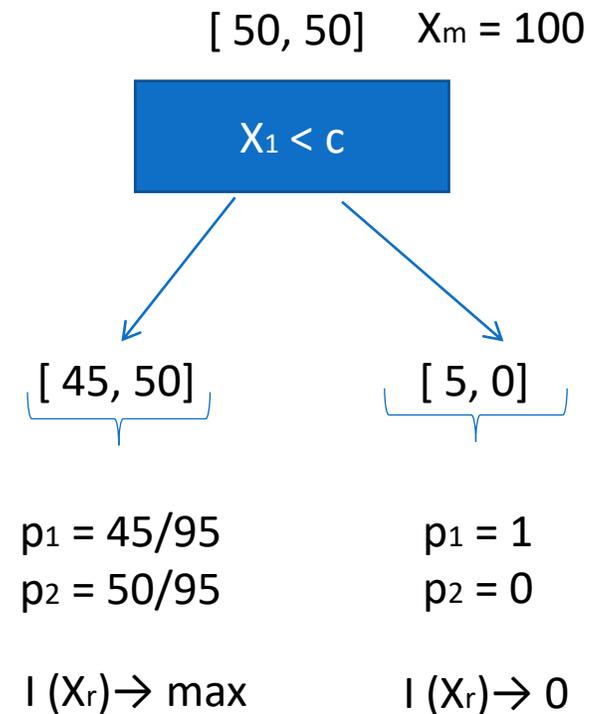
Критерий информативности Джини

$$I(X) = \sum_k p_k (1 - p_k)$$

$$p_k = \frac{1}{X} \sum_i [y_i = k]$$

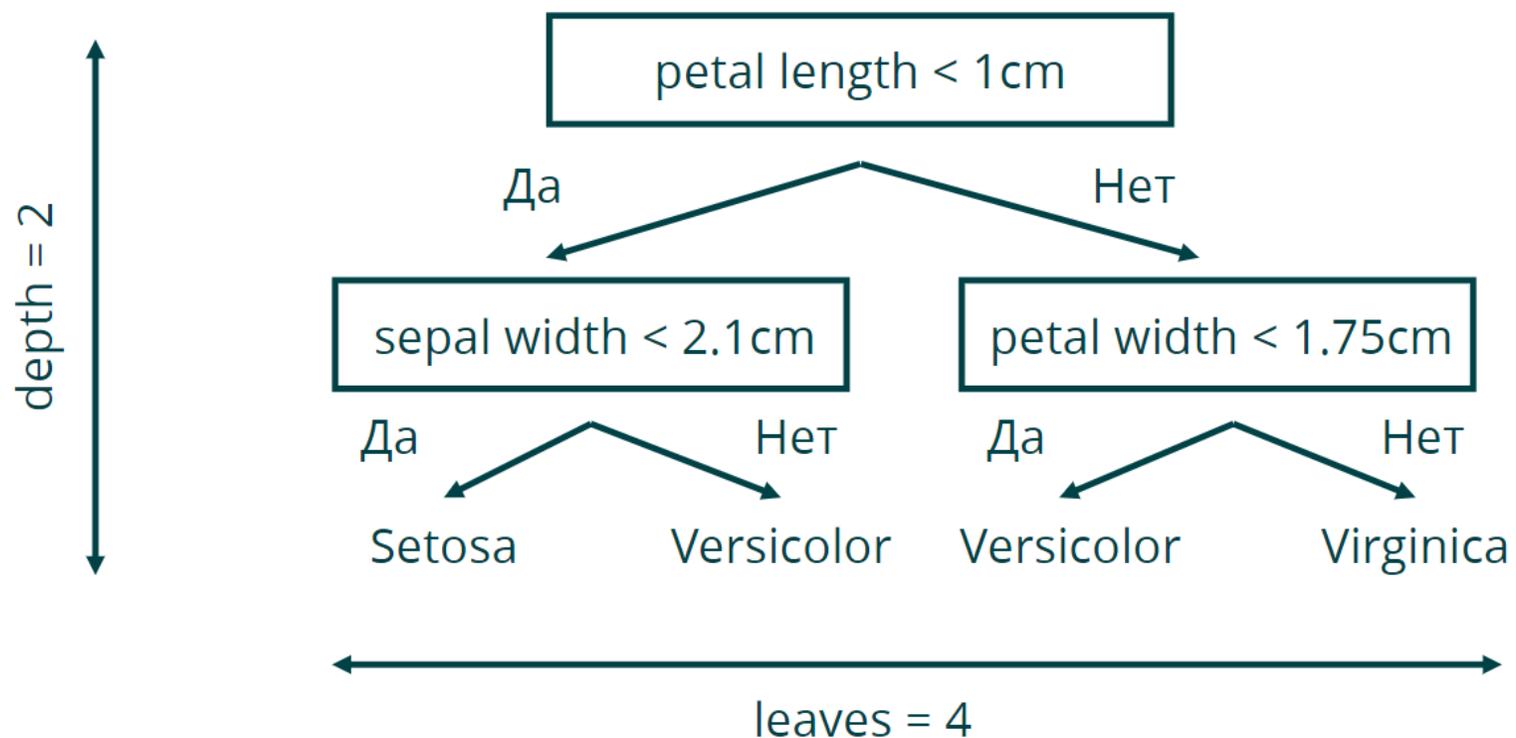
Другой критерий - энтропия

$$I(X) = - \sum_k p_k \ln(p_k)$$



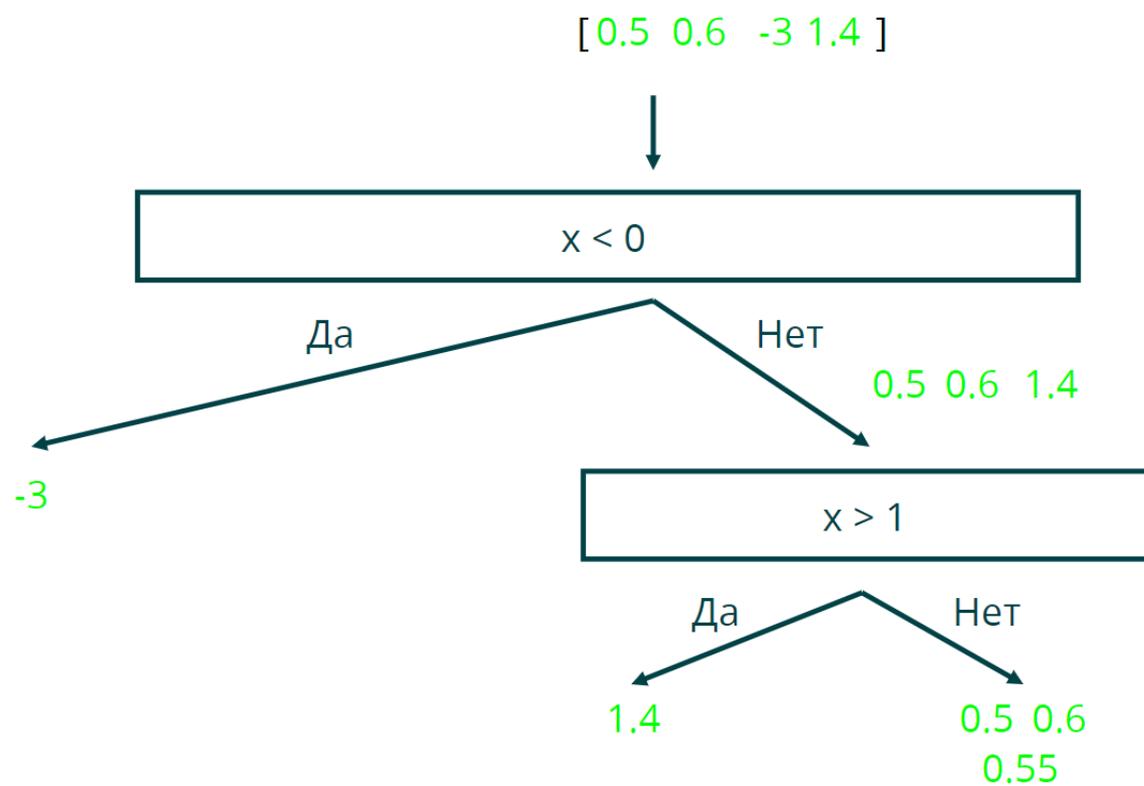
Деревья решений

Параметры дерева решений

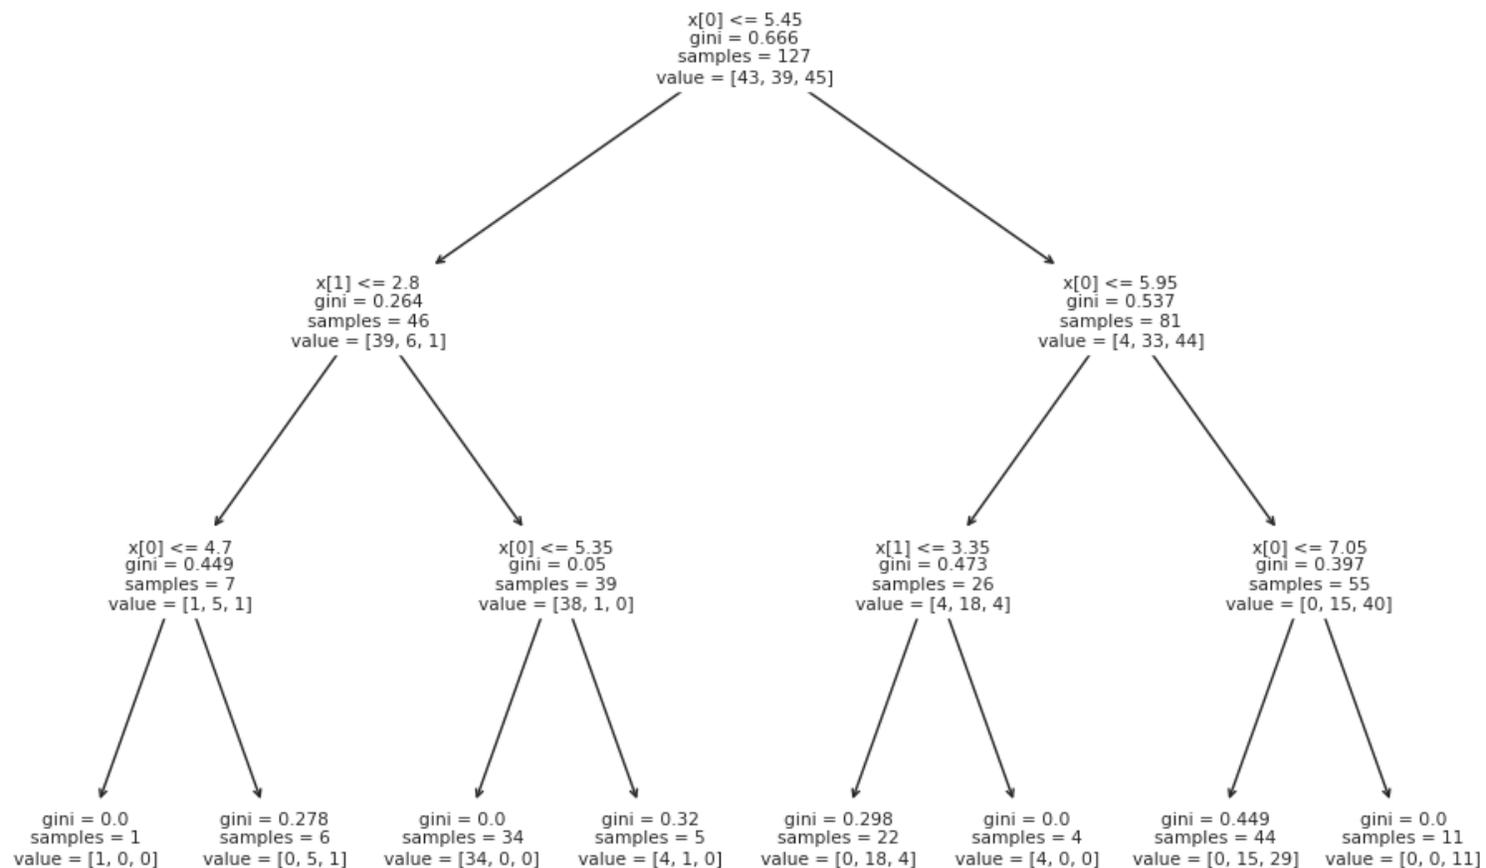


Деревья решений

Дерево решений для регрессии



Деревья решений



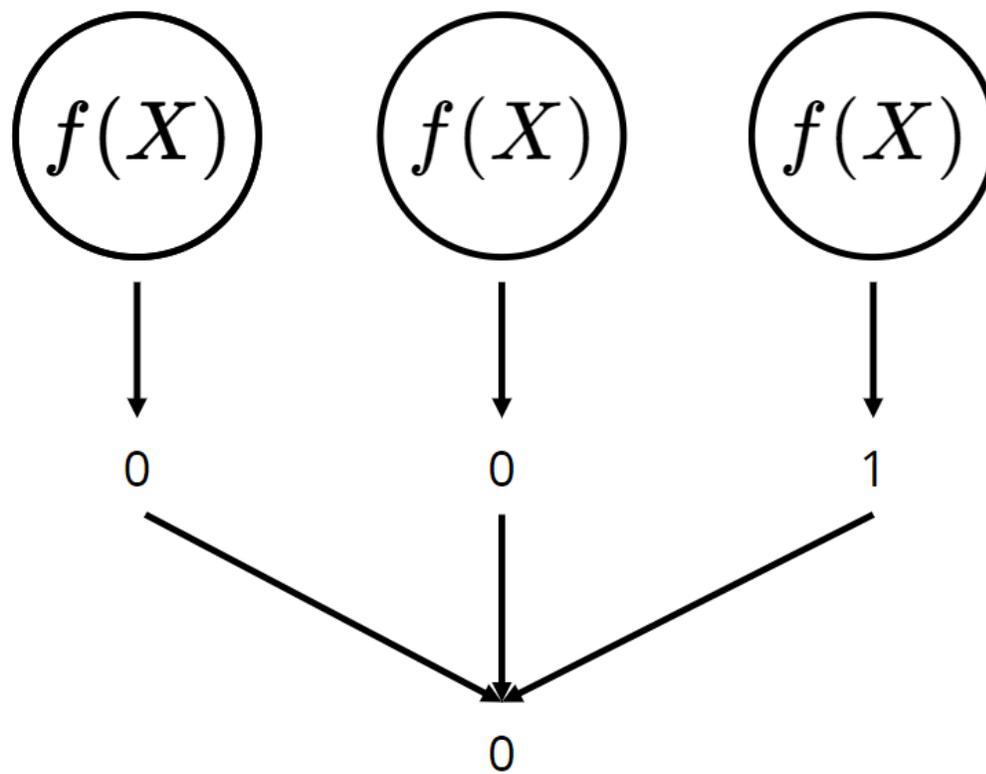
<https://scikit-learn.org/stable/modules/generated/sklearn.tree.DecisionTreeClassifier.html>

Деревья решений vs. нейронные сети

- Деревья можно (*очень осторожно*) назвать упрощённым вариантом нейронных сетей
- Обе модели способны выявлять **сложные нелинейные зависимости**
- Модели, основанные на **деревьях** - **детерминированные** (дают точный ответ), **нейронные сети** построены на **вероятностях** и дают вероятностный ответ
- Модели, основанные на деревьях, **объясняют** свой результат. Нейронные сети зачастую не дают понятной человеку информации о способе принятия решения

Ансамбли моделей

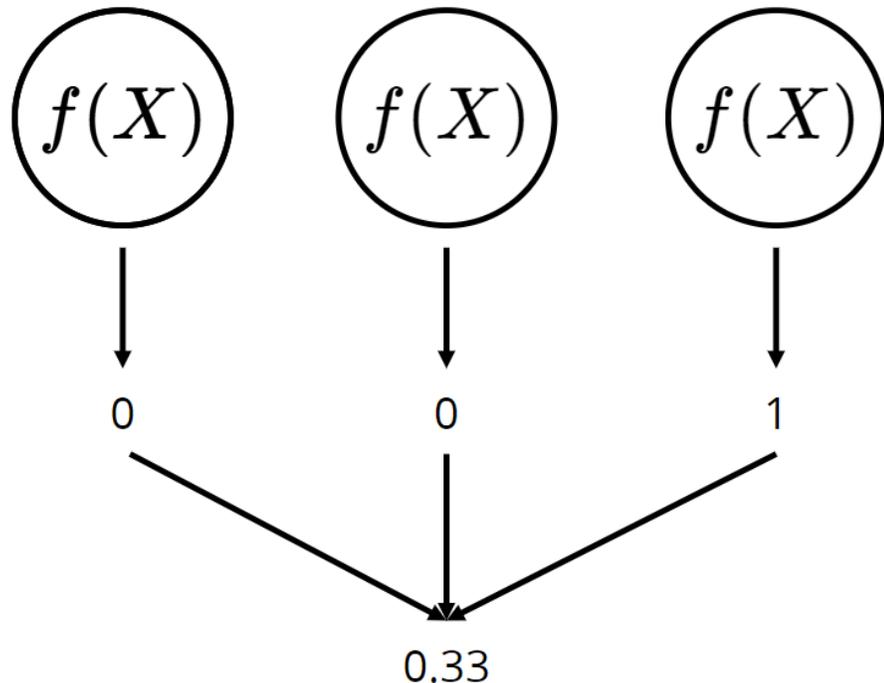
- Max Voting



Минус – нет степени уверенности в ответе

Ансамбли моделей

- Averaging



$$f_1(X), f_2(X), \dots, f_n(X)$$

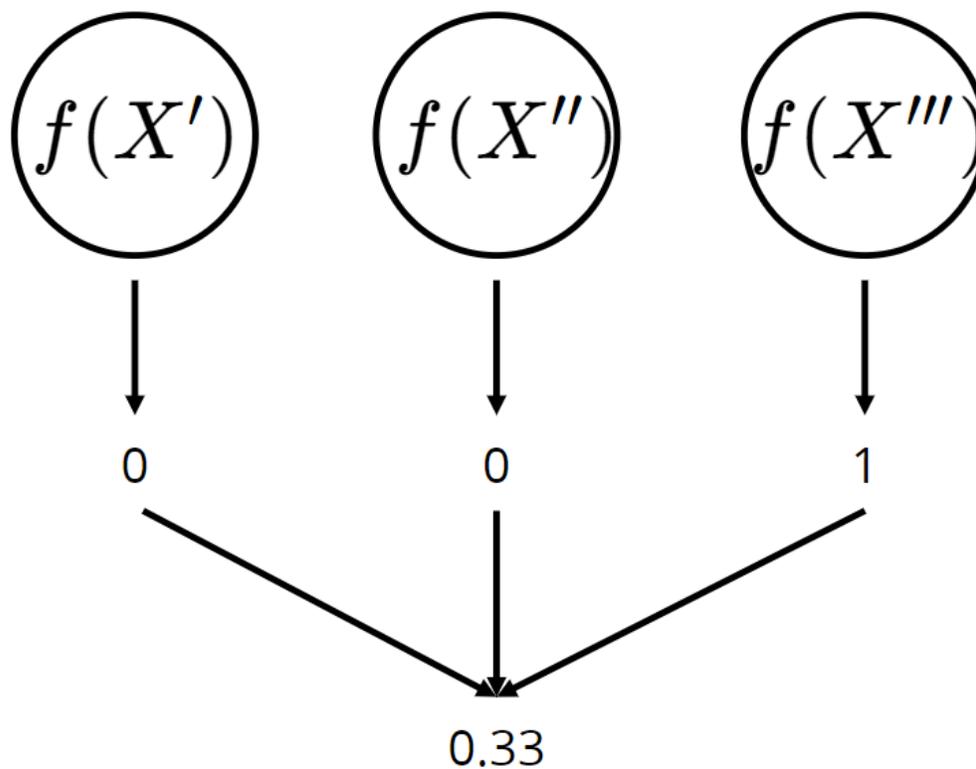
$$f(X) = \frac{\sum_i f_i(X)}{n}$$

Минус – если все модели обучены на одинаковом датасете, они дадут одинаковый результат

Ансамбли моделей

- **Bagging**

Bootstrap AGGregation

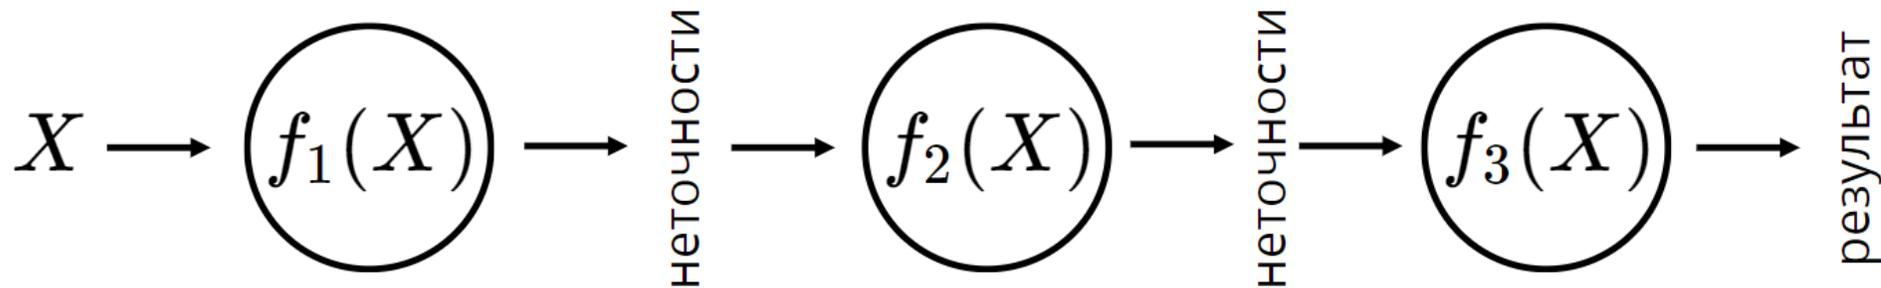


Наиболее известная модель – Случайный лес (Random Forest)

Ансамбли моделей

- **Boosting**

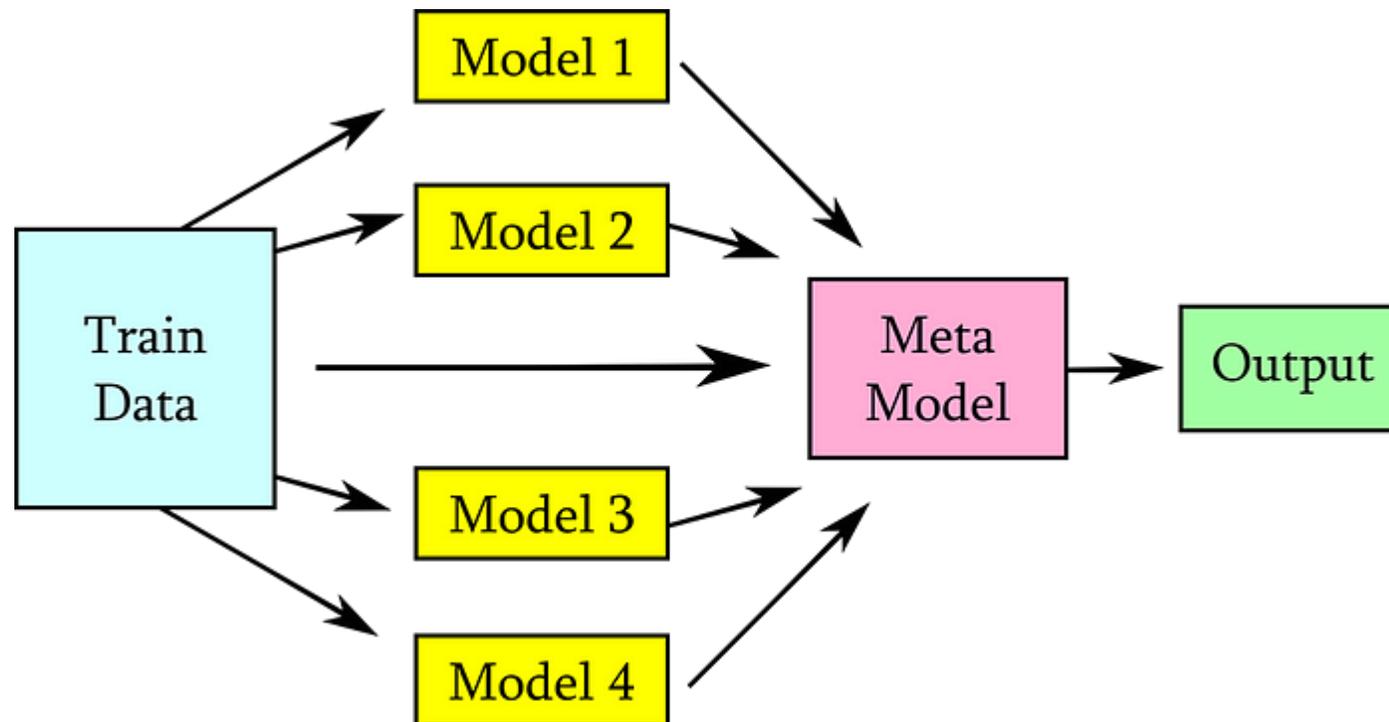
Последовательный набор моделей, последующие работают с ошибками предыдущей модели



Каждая следующая модель предсказывает то, как надо поправить предыдущую

Ансамбли моделей

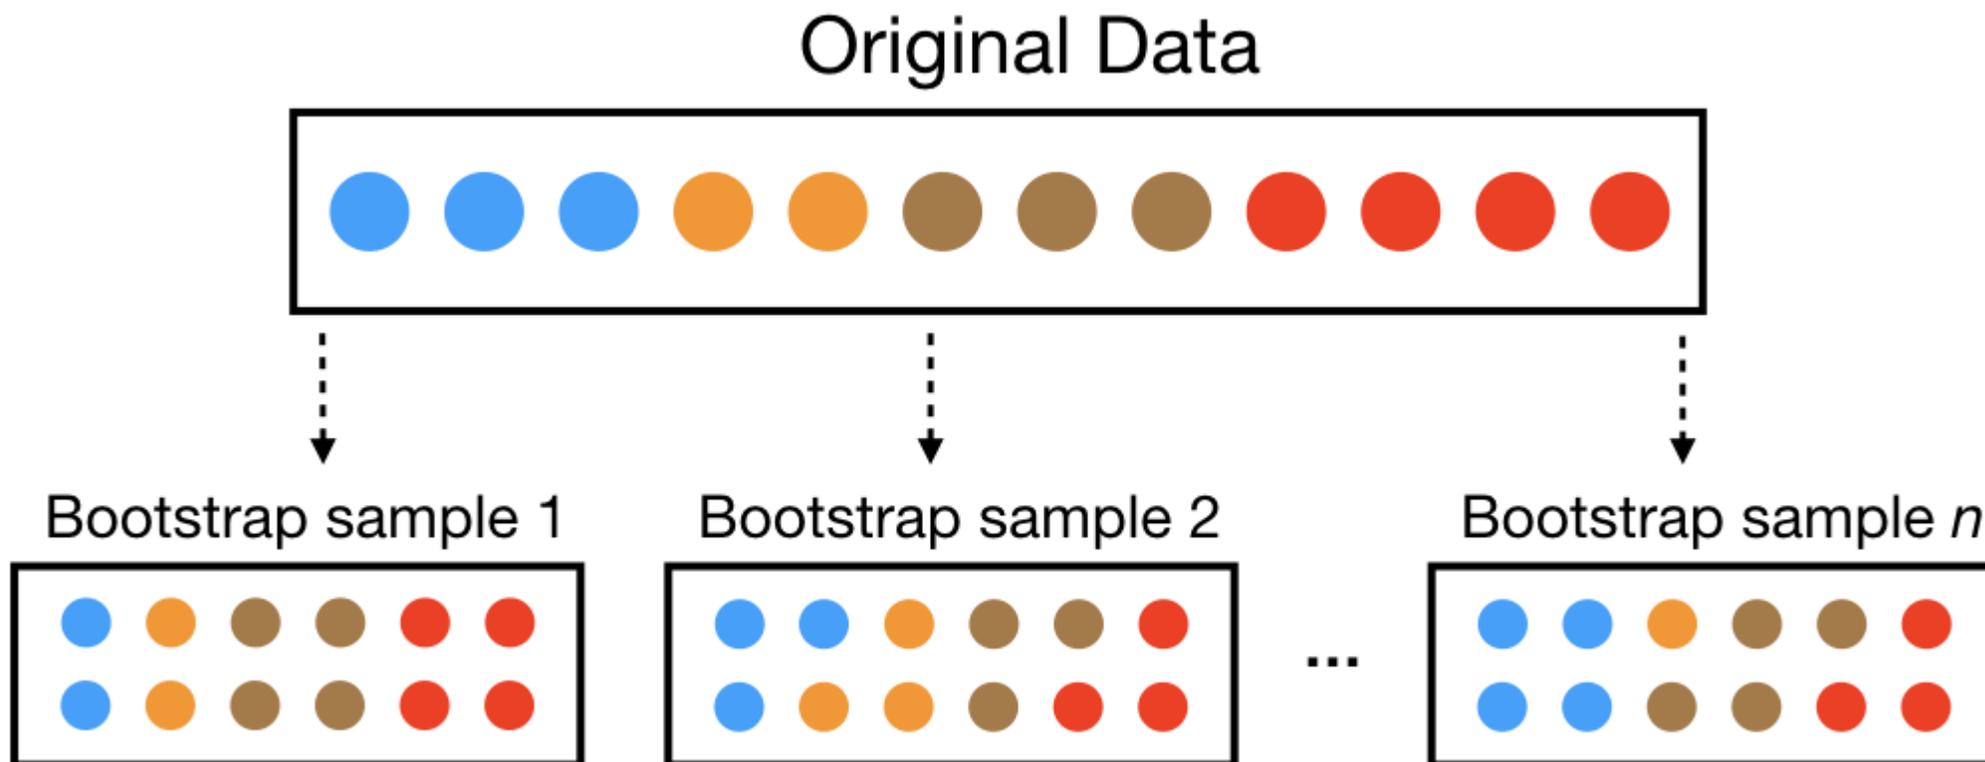
- **Stacking**



Мета-модель обучается на выходных данных предыдущих моделей

Случайный лес (Random Forest)

- Bootstrap



Bootstrap

Для каждого дерева выбираем экземпляры данных с возвращением

$$\{x^{(1)}, x^{(2)}, x^{(3)}, x^{(4)}, x^{(5)}\} \rightarrow \{x^{(1)}, x^{(3)}, x^{(4)}\}$$

плохой вариант - требуется дополнительный гиперпараметр

$$\{x^{(1)}, x^{(2)}, x^{(3)}, x^{(4)}, x^{(5)}\} \rightarrow \{x^{(1)}, x^{(3)}, x^{(4)}, x^{(1)}, x^{(4)}\}$$

Bootstrap

| height | color | gender | weight |
|--------|-------|--------|--------|
| 1.6 | blue | m | 88 |
| 1.6 | green | f | 76 |
| 1.5 | blue | f | 56 |
| 1.8 | red | m | 73 |
| 1.5 | green | m | 77 |
| 1.4 | blue | f | 57 |



| height | color | gender | weight |
|--------|-------|--------|--------|
| 1.6 | blue | m | 88 |
| 1.8 | red | m | 73 |
| 1.5 | blue | f | 56 |
| 1.8 | red | m | 73 |
| 1.5 | green | m | 77 |
| 1.5 | blue | f | 56 |

Случайный лес (Random Forest)

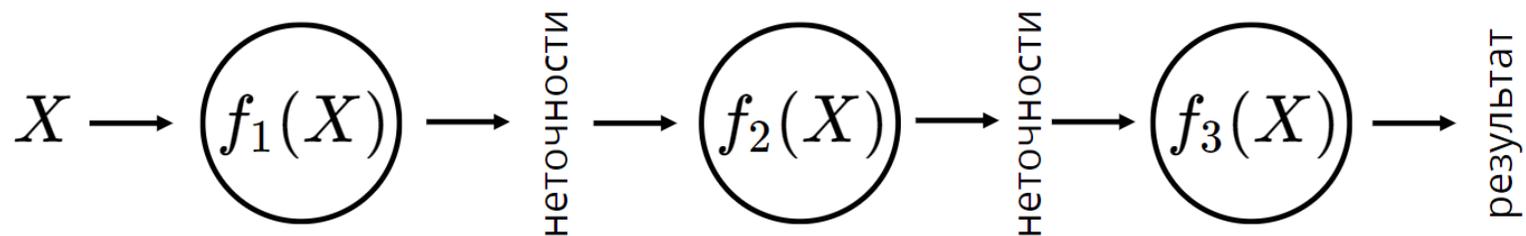
- Всё, что относится к деревьям, можно сказать и про случайный лес
- Случайный лес гораздо менее требователен к вычислительным ресурсам, чем нейронная сеть
- Случайный лес требует гораздо меньше данных для выхода на хорошие значения качества

Преимущества:

- Можно распараллелить
- Показывает важность каждой фичи

<https://scikit-learn.org/stable/modules/generated/sklearn.ensemble.RandomForestClassifier.html>

Boosting



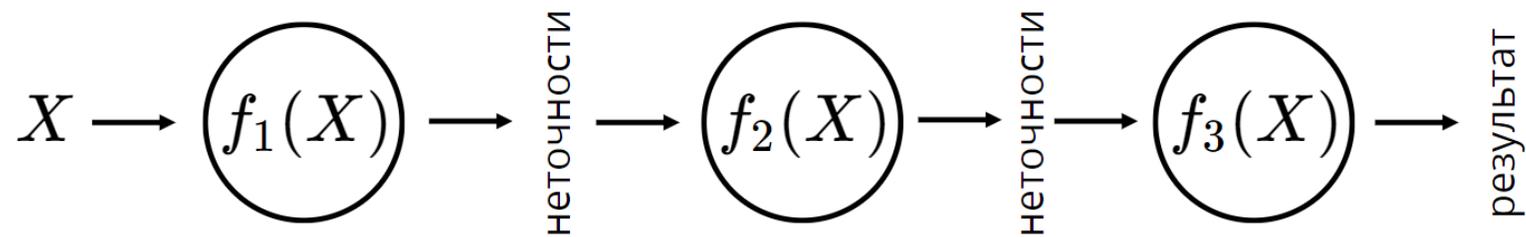
target

| height | color | gender | weight |
|--------|-------|--------|--------|
| 1.6 | blue | m | 88 |
| 1.6 | green | f | 76 |
| 1.5 | blue | f | 56 |
| 1.8 | red | m | 73 |
| 1.5 | green | m | 77 |
| 1.4 | blue | f | 57 |

Средний вес: 71.2

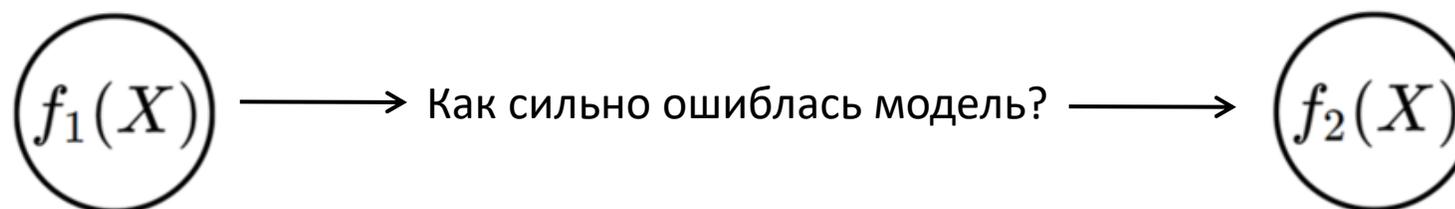


Boosting

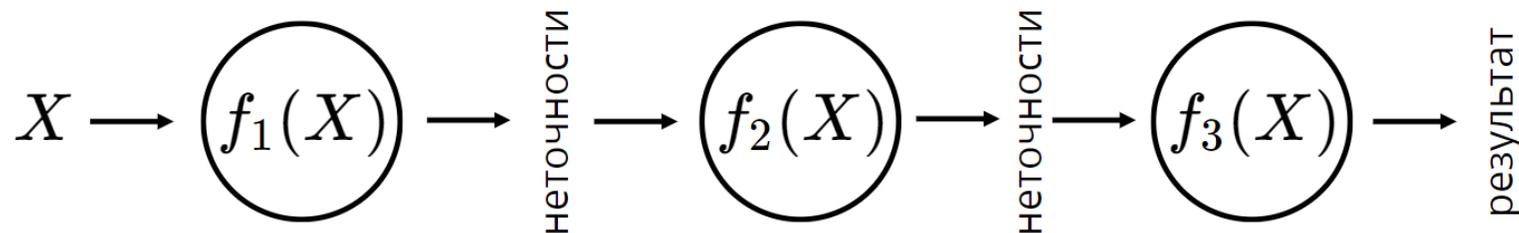


| height | color | gender | target | residuals |
|--------|-------|--------|--------|-----------|
| 1.6 | blue | m | 88 | 16.8 |
| 1.6 | green | f | 76 | 4.8 |
| 1.5 | blue | f | 56 | -15.2 |
| 1.8 | red | m | 73 | 1.8 |
| 1.5 | green | m | 77 | 5.8 |
| 1.4 | blue | f | 57 | -14.2 |

Средний вес: 71.2



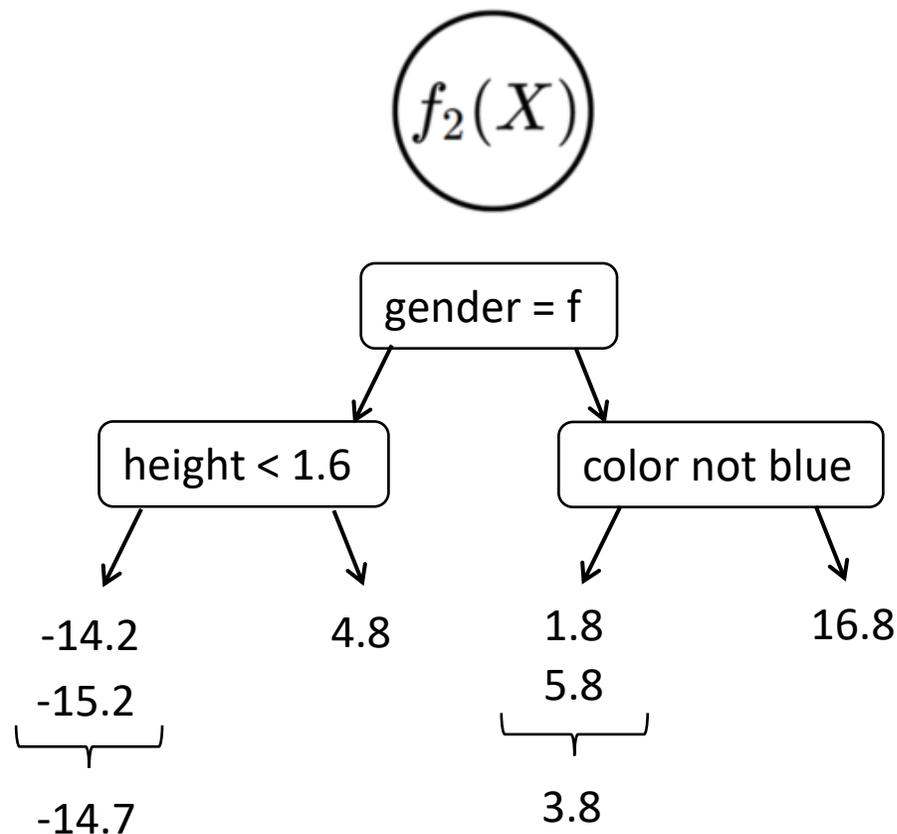
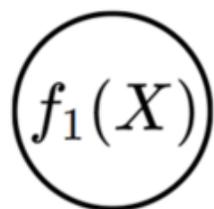
Boosting



target

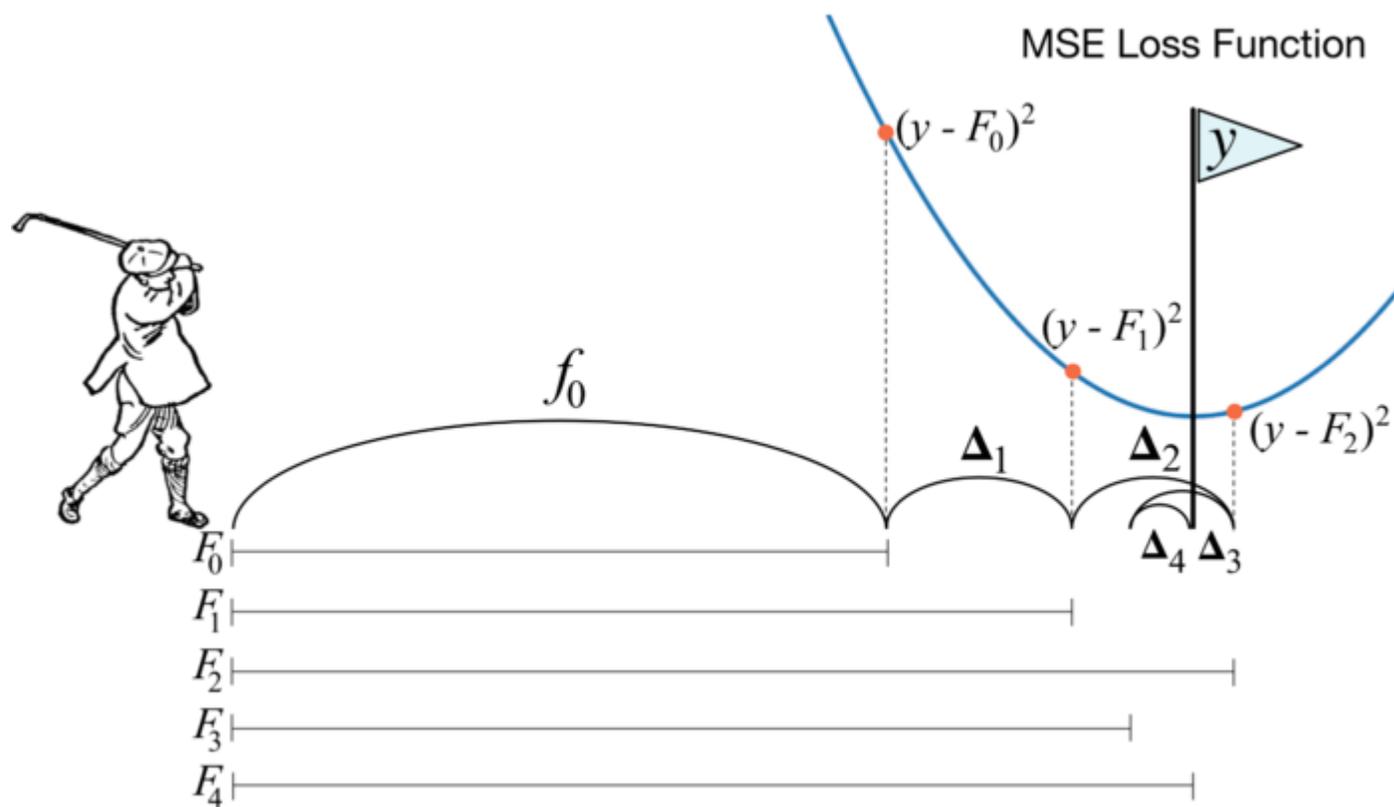
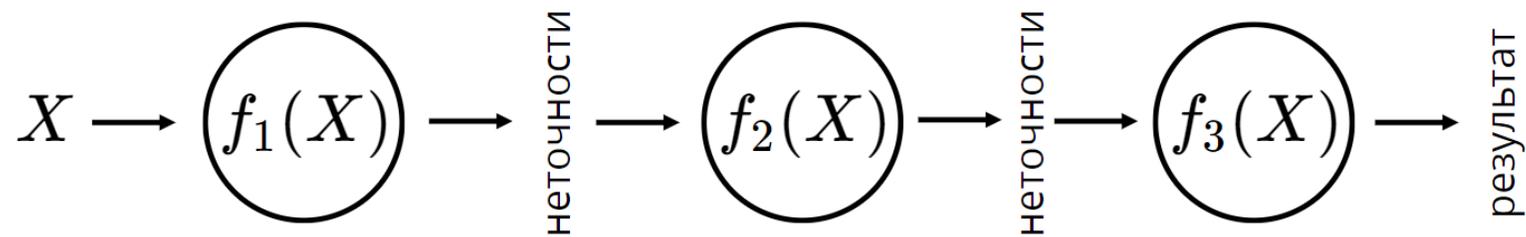
| height | color | gender | weight | residuals |
|--------|-------|--------|--------|-----------|
| 1.6 | blue | m | 88 | 16.8 |
| 1.6 | green | f | 76 | 4.8 |
| 1.5 | blue | f | 56 | -15.2 |
| 1.8 | red | m | 73 | 1.8 |
| 1.5 | green | m | 77 | 5.8 |
| 1.4 | blue | f | 57 | -14.2 |

Средний вес: 71.2



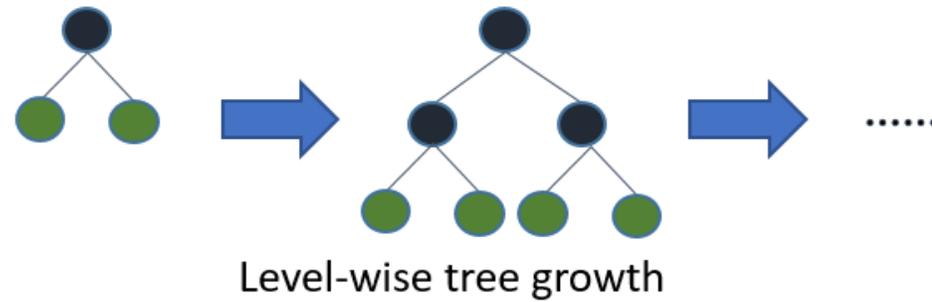
$$71.2 + 0.1 (f_2) + 0.1 (f_2) + \dots$$

Boosting

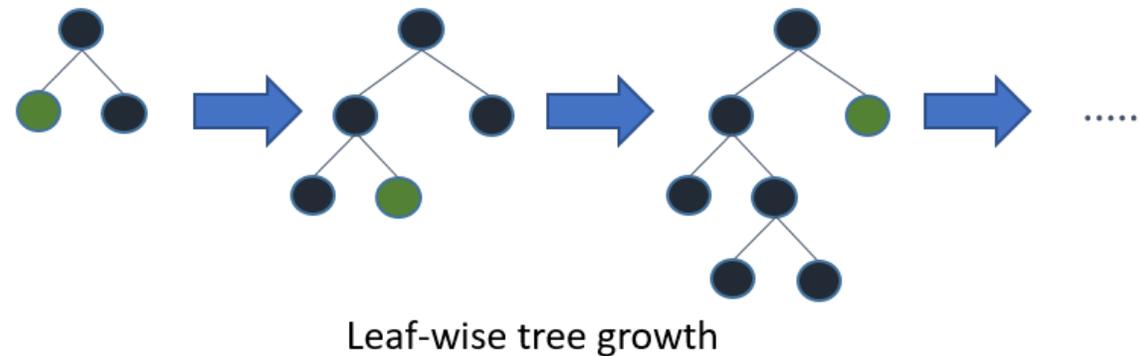


Boosting

XGBoost



LightGBM



Выводы

- Дерево решений обучается слой за слоем с помощью индекса Джини или энтропии и позволяет визуализировать данные
- Ансамбли моделей позволяют с помощью большого количества простых моделей находить сложные нелинейные зависимости
- Случайный лес параллельно объединяет деревья решений с помощью механизма бутстрапинг
- Бустинг объединяет модели в цепочку последовательных исправлений ошибок предыдущей моделей

Спасибо за внимание!

Конец Лекции 7