




1

Алгоритмы машинного обучения

- Умеем обучать алгоритм ближайших соседей
- Умеем обучать линейные алгоритмы:
 - Умеем обучать модель для решения задачи классификации
 - Умеем обучать модель для решения задачи регрессии

Проблемы внедрения в бизнес:

1. Сложность в интерпретации работы модели, ее непредсказуемость
 - *А как работает модель?*
 - *Модель предсказуема?*
 - *Где гарантия того, что модель не наделает ошибок?*
2. В жизни мы принимаем решения не так, как это делают известные нам модели

Алгоритмы машинного обучения


Примеры решающих правил

- Если в анкете указан домашний телефон и зарплата клиента $> \$1000$ и размер кредита $< \$3000$, то кредит выдать
- Если возраст пациента > 60 и пациент ранее перенёс инфаркт, то операцию не делать

С подобными решающими правилами работают **логические алгоритмы**.


Логический алгоритм — алгоритм, использующий логические закономерности в данных.

Один из видов логических алгоритмов – **дерево решений**




Дерево решений

- В каждой вершине дерева находится вопрос
- В зависимости от ответа на вопрос, алгоритм направляется в нужную ветвь дерева
- Листы дерева соответствуют решению алгоритма




Дерево решений

- Ирис



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



Дерево решений


Как обучать?

Рассмотрим на примере:

- Пусть задача – бинарная классификация
- Находимся в красной вершине
- До красной вершины дошла часть объектов обучающей выборки



1. 100 объектов класса 1, 80 объектов класса 0
2. 70 объектов класса 1, 20 объектов класса 0
3. 9 объектов класса 1, 11 объектов класса 0

Задача: найти такое решающее правило, которое обеспечит наилучшее разделение объектов разных классов друг от друга



Дерево решений

Решающее правило строится по характеристикам – фичам:




- Одна из вершин стала терминальной
- Повторяем разбиения с другими нетерминальными вершинами

Дерево решений


Формализуем выбор критерия ветвления:

Идеальный вариант




$L = 0$

Наихудший вариант



$L = \max$

Специфический вариант



Очень специфичное условие –
разделение хорошее, но мала доля
отделенных элементов класса

→ надо следить, **какую долю
наблюдений отсекает условие**

Дерево решений

Формализуем выбор критерия ветвления:

$$L(X_m, i, c) = \underbrace{\frac{X_l}{X_m} I_{left}}_{\substack{\text{Ошибка слева} \\ \text{(критерий информативности)}}} + \underbrace{\frac{X_r}{X_m} I_{right}}_{\substack{\text{Ошибка справа} \\ \text{(критерий информативности)}}$$

X_m - количество экземпляров данных, дошедших до вершины m

i - i -тый признак (рассматриваем потенциальные разбиения по всем признакам)

c - константа, входящая в условие разбиения (граничное значение признака)


$\frac{X_l}{X_m}$ - доля экземпляров данных, отброшенных в левую ветку

$\frac{X_r}{X_m}$ - доля экземпляров данных, отброшенных в правую ветку

Дерево решений

Формализуем выбор критерия ветвления:

$$L(X_m, i, c) = \frac{X_l}{X_m} I_{left} + \frac{X_r}{X_m} I_{right} = \frac{13}{20} I_{left} + \frac{7}{20} I_{right}$$



$I_{left}, I_{right} = ?$


Дерево решений

Задача – бинарная кластеризация

Цель – выявить объекты класса 1

p_{left} - вероятность появления экземпляра класса 1 в левой ветке

p_{right} - вероятность появления экземпляра класса 1 в правой ветке




➤ Если p близко к 0 или 1 – вершина «чистая», это хорошо

➤ Если p близко к 0.5 – это плохо

Дерево решений

$$I_{left} = H(p_{left})$$

$$I_{right} = H(p_{right})$$



$$L(X_m, i, c) = \frac{X_l}{X_m} H(p_{left}) + \frac{X_r}{X_m} H(p_{right}) \rightarrow \min$$

$H(p)$: Значение меньше, если p ближе к 0 или 1; больше, если p ближе к 0.5

Дерево решений

$$\frac{X_l}{X_m} H(p_{left}) + \frac{X_r}{X_m} H(p_{right}) \rightarrow \min$$

Возможные функции $H(p)$:


➤ Энтропия

$$H(q) = -q \log q - (1 - q) \log(1 - q)$$

➤ Индекс Джини

$$H(q) = 4q(1 - q)$$

Затем решаем оптимизационную задачу
для поиска правила



Дерево решений

- В осях двух самых информативных признаков два класса разделились без ошибок, на третьем — три ошибки.

iris setosa



petal sepal

iris versicolor





petal sepal

iris virginica




petal sepal




Дерево решений

- Недообучение и переобучение




Дерево решений


- Недообучение и переобучение



depth = 3




depth = 7




depth = 12

Дерево решений

- Параметры дерева



Глубина = 2



Глубина = 5

Дерево решений

- Параметры дерева


- Критерий ветвления ('gini', 'entropy')
- Максимальная глубина
- Минимальный размер листа
- Стратегия сплита



Дерево решений

- Решающее дерево для регрессии

- В листах дерева вместо классов объектов находятся действительные числа
- Количество ответов решающего дерева ограничено количеством листовых вершин



Дерево решений : резюме

Преимущества:

- простая идея и алгоритм обучения
- интерпретируемое
- возможна регуляризация
- обработка пропущенных значений

Недостатки:

- переобучается
- проблемы с регрессией
- сильно меняется в зависимости от параметров



Как улучшить?


Композиции алгоритмов

- Умеем обучать алгоритм **ближайших соседей**
- Умеем обучать **линейные алгоритмы**:
 - Умеем обучать модель для решения задачи классификации
 - Умеем обучать модель для решения задачи регрессии
- Умеем обучать **решающее дерево**
 - У всех – свои недостатки
 - Идея – построения композиции алгоритмов

Композиции алгоритмов

Принцип Кондорсе

- Если вероятность правильного решения члена жюри больше 0.5, то вероятность правильного решения присяжных в целом возрастает с увеличением количества членов жюри и стремится к единице.
- Если же вероятность быть правым меньше 0.5, то вероятность принятия правильного решения присяжными монотонно уменьшается и стремится к нулю с увеличением количества присяжных.



Принцип Кондорсе, 1784

Композиции алгоритмов

Эксперимент Френсиса Гальтона


Собралось около 800 человек, которые попытались угадать вес быка на ярмарке. Бык весил 1198 фунтов.

- Ни один крестьянин не угадал точный вес быка
- Среднее предсказание оказалось равным 1197 фунтов.



Композиции алгоритмов

1. Метод простого голосования (Max voting)



Минус – нет степени уверенности в ответе

Композиции алгоритмов


1. Метод простого голосования (Max voting)

Усреднение (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




Композиции алгоритмов

2. Бэггинг (Bagging)

Bootstrap AGGregation


Наиболее известная модель –
Случайный лес (Random Forest)




Композиции алгоритмов

Bootstrap

изначальная выборка



бутстрепные выборки



алгоритмы

a_1

a_2

a_3

Композиции алгоритмов

Bootstrap

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

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

Композиции алгоритмов

Случайный лес (Random forest)

- Много деревьев
- Бутстрепная выборка для каждого дерева
- Финальное решение принимается простым голосованием



Композиции алгоритмов

Случайный лес (Random forest)

- Всё, что относится к деревьям, можно сказать и про случайный лес
- **Позволяет преодолеть склонность деревьев переобучаться поодиночке**

Преимущества:


- Можно распараллелить
- Показывает важность каждой фичи



Композиции алгоритмов


3. Бустинг (Boosting)

Последовательный набор моделей, последующие работают с ошибками предыдущей модели



Композиции алгоритмов

3. Бустинг (Boosting)



height	color	gender	target
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




Композиции алгоритмов

3. Бустинг (Boosting) – последующие модели исправляют ошибки предыдущих

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




Композиции алгоритмов

3. Бустинг (Boosting)

height	color	gender	target 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


$$f_1(X)$$



$$f(x) = (((c1*f1) + c2*f2)+c3*f3)...$$


Композиции алгоритмов

3. Бустинг (Boosting)



Композиции алгоритмов


Адаптивный Бустинг (AdaBoost) – изменение весов ошибок



$$\alpha_1 \begin{array}{|c|} \hline \text{Red} \\ \hline \end{array} + \alpha_2 \begin{array}{|c|} \hline \text{Purple} \\ \hline \end{array} + \alpha_3 \begin{array}{|c|} \hline \text{Purple} \\ \hline \end{array} = \begin{array}{|c|} \hline \text{Complex Decision Boundary} \\ \hline \end{array}$$

Композиции алгоритмов

4. Стекинг (Stacking)



Мета-модель обучается на выходных данных предыдущих моделей

Выводы

- Дерево решений обучается последовательно (разветвление за разветвлением) 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 бутстрапа
- Бустинг объединяет модели в цепочку последовательных исправлений ошибок предыдущей моделей

Искусственный Интеллект

Спасибо за внимание!