

Data science

Лекция 3. Задачи классификации и регрессии

2024/2025 учебный год

Доцент кафедры ИВЭ, Махно В.В.

©Создано при помощи <https://sberuniversity.ru/>





Задача классификации.

Пример с вакансиями.

Необходимо построить алгоритм, который позволит системе определить, есть ли в резюме кандидата необходимые параметры. Если есть – отправить в папку «Собеседование», если нет – в папку «Отказать».

Ответы алгоритма и реальные данные

TRUE


FALSE

NEGATIVE-


POSITIVE +

Ответы алгоритма и реальные данные

True positive




False positive



False negative



True negative



Ответы алгоритма и реальные данные

Результат классификации


- TP — true positive, алгоритм верно пометил резюме как подходящее
- TN — true negative, алгоритм верно отнес резюме к неподходящим
- FP — false positive, алгоритм ошибочно считает подходящим резюме, в котором нет нужных качеств
- FN — false negative, алгоритм ошибочно отбраковал подходящее резюме



Метрики


- Самая простая метрика – **доля правильных предсказаний**: сколько раз прогноз машины и разметка программиста совпали между собой.
- Другая метрика – **точность**. Она показывает отношение количества верно угаданных подходящих резюме к количеству тех, кого машина вообще отнесла к группе «собеседование».
- Кроме точности есть еще метрика **полноты**. Она показывает отношение количества верно угаданных подходящих резюме, к другому значению: количеству кандидатов, которых следовало пригласить по мнению программиста.

Метрика точность




Точность показывает отношение количества верно угаданных подходящих резюме к количеству тех, кого машина вообще отнесла к группе «собеседование».

Метрика полнота



Полнота показывает отношение количества верно угаданных подходящих резюме, к другому значению: количеству кандидатов, которых следовало пригласить по мнению программиста.

F-метрика




Табличные данные

Зарботная плата	Возраст	Должность	Уровень образования	Город проживания	Стаж работы (годы)	Вернет ли клиент кредит
100000	26	Риэлтор	Высшее	Санкт-Петербург	5	Да
50000	20	Продавец-консультант	Высшее	Москва	1	Нет
35000	39	Автомеханик	Среднее специальное	Воронеж	8	Нет
25000	23	Программист	Высшее	Самара	2	Да
75000	41	Юрист	Среднее	Москва	14	Да

Создание алгоритма классификации

В этой задаче каждому объекту (строке в таблице данных) соответствует класс — значение из заданного набора классов.

Задача классификации состоит в том, чтобы разработать алгоритм, который по признакам объекта будет предсказывать класс




Кейсы классификации текстов

1. Классификация текстов (определение жанра, темы, тональности)
2. Выделение именованных сущностей (наименования, даты)
3. Генерация текстов (создание текстов на заданную тематику по картинке, по 2-3 предложениям)




Машинное обучение





Задача регрессии


Задача регрессии состоит в том, чтобы на основании различных признаков предсказать вещественный ответ, т.е. для каждого объекта нужно предсказать число.



Пример с монетой.



Пример с монетой.



Задача регрессии

Пример. Задача предсказания стоимости квартиры

Площадь (м ²)	Этаж	Число комнат	Число лет с последнего ремонта	Стоимость (млн)
115	3	4	2	46.0
55	5	2	5	10.3
72	6	3	12	17.7
55	20	1	0	32.0

Поиск значений весов



Линейные модели

Самый известный метод регрессии — это линейные модели.

Основной механизм предсказания с помощью линейной модели формулируется следующим образом: необходимо умножить значения всех признаков на веса и сложить.

Предположим, что мы хотим предсказать стоимость квартиры со следующими значениями признаков:

Площадь (м²)	Этаж	Число комнат	Число лет с последнего ремонта
70	2	3	5

Также предположим, что мы знаем веса признаков:

0,25 для площади,


1,8 для этажа,

0,5 для числа комнат и

(-0,2) для числа лет со дня ремонта.

Вес признака задает вклад признака в предсказание.

Тогда будет предсказана стоимость $0,25 \cdot 70 + 1,8 \cdot 2 + 0,5 \cdot 3 - 0,2 \cdot 5 = 21,6$ условных единиц




Преимущества линейных моделей

Линейные модели, как правило, решают задачу с приемлемым уровнем качества, однако уступают более мощным алгоритмам, ансамблям решающих деревьев и нейронным сетям, которые мы обсудим далее.

С другой стороны, качество линейных моделей можно значительно повысить, придумав новые признаки, вычисляемые на основе исходных признаков (например, добавив квадраты признаков), — при этом свойство интерпретируемости сохраняется. Благодаря своей интерпретируемости линейные модели очень популярны в бизнес-задачах, например в кредитном скоринге.

Переобучение

Может случиться, что алгоритм делает хорошие предсказания только для обучающих данных. Иными словами, алгоритм запомнил, зазубрил классы/числа для обучающих объектов, но не нашел никаких зависимостей между признаками и целевой переменной (классом/числом). Такой алгоритм будет плохо работать на шаге внедрения и называется переобученным.



Онлайн-курс СберУниверситета

Генеративное искусство

Подробнее о курсе

Бесплатный курс от Сбера
по генеративному
искусству

https://courses.sberuniversity.ru/generative-art?utm_source=telegram&utm_medium=organic&utm_campaign=courses&utm_content=gen_i&utm_term=01_09_2023