

Классические методы распознавания образов. Теория вероятностей как модель регистрации данных

Зубюк Андрей Владимирович
zubjuk@physics.msu.ru

<http://NeuroFuzzy.Phys.MSU.ru>

Разделяющие гиперплоскости

Гиперплоскость в признаковом пространстве (в 2-мерном случае — прямая, в 3-мерном — плоскость) задаётся уравнением


$$(w, x) + b = 0 \quad \Leftrightarrow \quad w_1x_1 + w_2x_2 + \dots + b = 0.$$

Все векторы признаков x , лежащие в пространстве с одной стороны от этой гиперплоскости, удовлетворяют условию

$$(w, x) + b \leq 0,$$

с другой стороны — условию

$$(w, x) + b > 0.$$





$$w = \begin{pmatrix} 9 & 14 \end{pmatrix} \quad b = -2440$$

Разделение гиперплоскостью относится к **классическим** методам распознавания образов. Наряду с такими методами как деревья решений, леса решений, корреляционный анализ, математическая морфология Серра (анализ изображений) и др.



В настоящее время **классическими** принято называть все методы, которые не связаны с искусственными нейронными сетями.

Достоинства и недостатки классических и нейросетевых методов:

- ▶ Интерпретируемость (прозрачность) классических методов.
- ▶ Чёткая очерченность области применимости классических методов.
- ▶ Возможность внедрения в классические алгоритмы априорной информации о решении, предоставленной специалистом в предметной области,.
- ▶ Возможность «отладки» классических алгоритмов.
- ▶ Высокое качество нейросетевых методов в ряде задач при наличии большого объёма обучающих примеров.
- ▶ Высокая степень автоматизации построения нейросетевых алгоритмов по обучающим примерам.




Помимо числовых признаков **деревья решений** могут использовать **категориальные** признаки: цвет волос, профессию и др. Категориальный признак принимает конечное количество значений, каждое из которых означает принадлежность объекта к некоторой категории: блондин, брюнет (по цвету волос), учитель, инженер (по профессии) и т.п.




$$w = \begin{pmatrix} 9 & 14 \end{pmatrix} \quad b = -2440$$

Разделение гиперплоскостью — это дерево решений, в котором в качестве «нового» признака используется $y = (w, x) + b$. Обычно при построении деревьев решений используются исходные признаки, образующие матрицу (вектор признаков) x .

Для решения одной и той же задачи можно построить много разных деревьев решений.



Лес решений — принятие решения в пользу того класса, «за который проголосовало» больше всего деревьев.




Какой метод лучше?

Фундаментальный вопрос: **чем измерить качество алгоритма?**

Стандартный ответ «в духе» машинного обучения: сосчитать количество примеров, неверно распознанных алгоритмом, отнесённое к общему количеству примеров:

- 1 доля женщин, принятых за мужчин,
- 2 доля мужчин, принятых за женщин,
- 3 общая доля неверно распознанных мужчин и женщин.



Лучше тот метод, для которого доля ошибок меньше.

Применительно к тестам ошибки 1 и 2 часто называют ложно-положительными и ложно-отрицательными срабатываниями алгоритма. Обычно при уменьшении одного из этих показателей растёт другой.

Какой метод лучше? Проблема с подсчётом примеров



Фундаментальная проблема: при предложенном выше подходе к измерению качества алгоритма **качество будет разным для разных наборов обучающих примеров!**

Решение проблемы: **разные наборы примеров — это выборки из одного и того же (возможно, неизвестного) распределения вероятностей.** Тогда вероятности ошибок существуют «сами по себе» — без обучающих примеров — и неизменны. А доли ошибок, сосчитанные на основе обучающих примеров, — это случайные величины, примерно равные вероятностям при большом количестве примеров.

Аналогия с бросанием монеты. Вероятности выпадения орла и решки равны $1/2$ (50%). Но если 100 раз бросить монету, то орёл может выпасть 50 раз ($50/100 = 1/2$), а может 49, 51, 48 и т.д. (строго говоря — любое количество раз от 0 до 100 включительно).

Т.е. вероятность выпадения орла — «фундаментальная» константа, а доля случаев, когда выпал орёл, — случайная величина, примерно равная $1/2$ при большом количестве бросаний.

При прохождении теста укажите e-mail и фамилию, имя, отчество, которые вы указали при регистрации на курс. По этим данным будут суммироваться результаты всех ваших тестов в семестре. После ответа на тест вам на почту должно прийти письмо с вашими ответами.

https://docs.google.com/forms/d/e/1FAIpQLSeJwueu5HLvTrVhazuc8AEPJW7D4ZrVzjQhAZvXDZW_eji2EQ/viewform

