

Признаковое описание объектов реального мира. Задачи распознавания образов

Зубюк Андрей Владимирович
zubjuk@physics.msu.ru

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

Математика «умеет» работать с числами, но не с объектами реального мира.

Чтобы сделать возможным применение математических методов к объектам реального мира, их (объекты) необходимо описать числами.

В распознавании образов и машинном обучении числовые характеристики объектов принято называть **признаками**. Набор значений признаков объекта — это его **образ**.

Признаки человека: рост h , масса m , возраст a .

Обычно признаки объектов объединяются в таблицы (матрицы), например, в таблицы-строки или таблицы-столбцы:

$$(h \quad m \quad a) \qquad \begin{pmatrix} h \\ m \\ a \end{pmatrix}$$

Такие матрицы будем называть **векторами**.

Такое название может быть объяснено следующим образом. В «обычной» геометрии точка имеет 3 координаты, которые можно записать в матрицу-строку или матрицу-столбец, например, $(x \quad y \quad z)$ или $\begin{pmatrix} x_1 \\ x_2 \\ x_3 \end{pmatrix}$. Вектор — это направленный отрезок. Будем рассматривать только такие векторы, началом которых является точка с координатами $(0 \quad 0 \quad 0)$. Тогда координаты точки-конца вектора полностью определяют весь вектор.

Вообще, понятия «вектор» и «точка» в математике часто употребляются как синонимы.


Классификация. Заданы классы объектов. Пример: класс мужчин, класс женщин. Необходимо по значениям признаков объекта определить, к какому классу он относится.

Кластеризация. Необходимо разделить имеющиеся объекты на кластеры (группы, «облака») так, что в пределах одного кластера объекты «схожи» друг с другом, а между кластерами — «заметно различаются». Понятия схожести и различия могут быть определены разными способами, поэтому задача кластеризации имеет не единственное верное решение.

Регрессия. Оценивание значений ненаблюдаемых признаков объектов по значениям наблюдаемых признаков (возможно, других объектов). Пример — прогнозирование погоды.



Пример задачи классификации

Даны векторы признаков ряда **известных**
объектов из разных классов
(рост и масса мужчин и женщин)




Пример задачи классификации


Даны векторы признаков ряда **известных** **неизвестного** объекта отнести его к одному из классов
(рост и масса мужчин и женщин)



Способ разделения плоскости прямой




Пример задачи кластеризации



Явно выделяются 2 кластера (группы, «облака») точек. Задача их автоматического выделения — это и есть задача кластеризации.

Пример задачи кластеризации



Понятия «близость», «прямая» и др. должны быть формализованы на языке математики. Для этого необходимо на **множестве всех (гипотетических, не обязательно реальных) векторов признаков** ввести ряд операций, которые превращают это множество в **признаковое пространство**.

Пусть $x = (x_1 \ x_2 \ x_3)$ и $y = (y_1 \ y_2 \ y_3)$ — векторы признаков 2-ух разных гипотетических объектов.

Линейные операции: умножение на число α и сложение:

$$\begin{aligned}\alpha x &= (\alpha x_1 \ \alpha x_2 \ \alpha x_3), & \alpha y &= (\alpha y_1 \ \alpha y_2 \ \alpha y_3), \\ x + y &= (x_1 + y_1 \ x_2 + y_2 \ x_3 + y_3).\end{aligned}$$

Вычитание — это умножение одного вектора на число -1 с последующим сложением.

Признаковое пространство

Скалярное произведение:

$$(x, y) = x_1y_1 + x_2y_2 + x_3y_3 = \sum_{i=1}^3 x_iy_i.$$

Норма (длина, модуль) вектора признаков:

$$\|x\| = \sqrt{(x, x)} = \sqrt{\sum_{i=1}^3 x_i^2}, \quad \|y\| = \sqrt{(y, y)} = \sqrt{\sum_{i=1}^3 y_i^2}.$$

Расстояние между векторами (точками-концами векторов) x и y :

$$\rho(x, y) = \|x - y\| = \sqrt{\sum_{i=1}^3 (x_i - y_i)^2}.$$

Операции в признаковом пространстве и задача классификации

Прямая на плоскости « x_1, x_2 » задаётся уравнением


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

Все векторы $x = (x_1 \ x_2)$, лежащие на плоскости с одной стороны от этой прямой, удовлетворяют условию

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

с другой стороны — условию

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



$$w = (9 \ 14) \quad b = -2440$$

Схожесть объектов из одного кластера и различие объектов из разных кластеров могут быть определены с использованием расстояния (метрики) в признаковом пространстве

$$\rho(x, y) = \|x - y\|.$$

- ▶ Чем меньше $\rho(x, y)$, тем более схожи соответствующие объекты.
- ▶ Чем больше $\rho(x, y)$, тем сильнее они различаются.

