

## Тема 2. Однофакторная линейная регрессия

### Постановка задачи

В самых разных областях знания возникает *задача определения зависимости между случайными величинами*, являющимися признаками одних и тех же объектов.

Например, это может быть зависимость

- между ростом и весом человека;
- между силой сигнала на входе и выходе технического устройства;
- между затратами компании на рекламу и доходом от продаж;
- между уровнем инфляции и безработицей;
- между содержанием радиоактивного вещества в растениях-медоносах и в мёде, полученном от этих растений.

На практике на значение исследуемой величины влияет множество *факторов*, но для простоты мы будем считать, что основное влияние оказывает один из них, потому и анализ будем называть *однофакторным*.

Будем считать, что оба признака, зависимость между которыми мы стараемся выявить, представимы как значения вещественных переменных. Предположим, что нам известны результаты  $n$  измерений. Каждое измерение  $i (i=1, \dots, n)$  даёт пару чисел  $(x_i, y_i)$  – значения двух признаков измеряемого объекта, (например, рост – вес, затраты на рекламу – доход и т.д.), т.е. сырые данные представимы как таблица:


№ наблюдения, $i$	Значения фактора, $x_i$	Значения переменной отклика, $y_i$
1	$x_1$	$y_1$
...		
$i$	$x_i$	$y_i$
...		
$n$	$x_n$	$y_n$

Здесь каждая строка соответствует одному *объекту (наблюдению)*. Признак, который может быть непосредственно измерен ( $x$ ), является *фактором (предиктором)*, прогнозируемая переменная ( $y$ ) – *переменная отклика*.

*Цель исследования – построить (линейную) функцию (регрессионную модель), которая позволит прогнозировать значение переменной отклика ( $y$ ) по известному значению фактора ( $x$ )*

## Визуализация сырых данных

Построим систему координат, где по оси абсцисс будем откладывать значения фактора ( $x$ ), по оси ординат – значения переменной отклика ( $y$ ). Таким образом, каждому наблюдению (т.е. каждой паре)  $(x_i, y_i)$  ( $i = \overline{1, n}$ ) соответствует точка на координатной плоскости. Если зависимость между изучаемыми признаками была бы *линейной* и отсутствовала бы случайная компонента, то все эти точки лежали бы на одной прямой. Однако из-за наличия случайного «шума» точки оказываются разбросанными по координатной плоскости в виде так называемого «облака». Пример такого облака показан на приведённом ниже рисунке.



Здесь ось абсцисс соответствует затратам на рекламу, ось ординат – объёму продаж (зафиксированному через заданное время после проведения рекламной кампании).

Поставим задачу: *найти такую линейную функцию, которая наилучшим образом отражает зависимость переменной отклика  $y$  (объёма продаж) от фактора  $x$  (затрат на рекламу).*

Эта задача называется задачей **однофакторной линейной регрессии**.

Приведём математическую формулировку задачи.

### Математическая постановка задачи нахождения уравнения регрессии

Необходимо найти зависимость  $y = f(x)$ . Значения  $y$  и  $x$  измеряют в процессе эксперимента и при анализе они уже известны. Однако вид их функции связи (модель) до опыта не известен и должен быть найден по опытным данным. При этом имеется в виду, что на то, какое значение примет  $y$ , влияет не только значение  $x$ , но также ряд мешающих неуправляемых факторов, к которым относятся погрешности измерения, неконтролируемые изменения окружающей среды и другие. Поэтому даже при фиксированных значениях  $x$  функция  $y = f(x)$  ведет себя случайным образом, в связи


с чем ставится задача нахождения ее математического ожидания и дисперсии или доверительных интервалов. Каждому значению  $x$  соответствует некоторое вероятностное распределение случайной величины (СВ)  $Y$ . Предположим, что СВ  $Y$  «в среднем» линейно зависит от значений переменной  $x$ . Это означает, что условное математическое ожидание случайной величины  $Y$  при заданном значении переменной  $x$  имеет вид ( $Y$  среднее значение всех значений  $y$  для данного  $x$ )

$$M(Y|x) = \beta_0 + \beta_1 x \quad (1)$$

Функция переменной  $x$ , определяемая правой частью этой формулы, называется линейной регрессией  $Y$  на  $x$ , а параметры  $\beta_0, \beta_1$  - параметрами линейной регрессии.

$\beta_1$  – тангенс угла наклона графика этой функции к оси  $OX$  (английский термин: «*slope*»),  $\beta_0$  – ордината точки пересечения этой прямой с осью  $OY$  (англ.: «*intercept*»). Задача состоит в том, чтобы *найти такие значения переменных  $\beta_0, \beta_1$ , при которых прямая (1) наилучшим образом проходит через облако точек  $(x_i, y_i), i = 1, \dots, n$ .*

Поясним смысл задачи геометрически. Зафиксируем произвольные значения  $\beta_0$  и  $\beta_1$  и построим соответствующую прямую:



Очевидно, построенная «наугад» прямая является не самой лучшей для данного облака точек. Формализуем понятие «качества» модели. При фиксированных  $\beta_0$  и  $\beta_1$  «ожидаемое» (согласно (1)) значение  $y$  при  $x = x_i$  составляет  $\beta_0 + \beta_1 \cdot x_i$ ,  $i = 1, \dots, n$  (т.е. точка  $(x_i, \beta_0 + \beta_1 \cdot x_i)$  лежит на построенной прямой). Но фактическое значение переменной  $y$  при  $x = x_i$  составляет  $y_i$ , т.е. «ошибка» составляет  $((\beta_0 + \beta_1 \cdot x_i) - y_i)$ .

На практике параметры линейной регрессии неизвестны и их оценки определяются по результатам наблюдений переменных  $y_i$  и  $x_i$ . Пусть проведено  $n$  независимых наблюдений случайной величины  $Y$  при значениях переменной  $X$ :  $x_1, x_2, \dots, x_n$ . При

этом измерения величины  $Y$  дали следующие результаты:  $y_1, y_2, \dots, y_n$ . Так как эти значения имеют разброс относительно линейной регрессии, то связь между переменными  $Y$  и  $X$  можно записать в виде линейной (по параметрам  $\beta_0, \beta_1$ ) регрессионной модели:

$$Y = \beta_0 + \beta_1 x + \varepsilon$$

где  $\varepsilon$  - случайная ошибка наблюдений, причем  $M(\varepsilon) = 0$ ,  $D(\varepsilon) = \sigma^2$ . Значение дисперсии ошибок  $\sigma^2$  неизвестно, и оценка ее определяется по результатам наблюдений.

Задача линейного регрессионного анализа состоит в том, чтобы по результатам наблюдений  $(x_i, y_i)$ ,  $i = \overline{1, n}$ :

1. Получить наилучшие точечные и интервальные оценки неизвестных параметров  $\beta_0, \beta_1$  и  $\sigma^2$  линейной регрессионной модели.
- 2) Проверить статистические гипотезы о параметрах модели.
- 3) Проверить, достаточно ли хорошо модель согласуется с результатами наблюдений (адекватность модели результатам наблюдений).

В соответствии с моделью результаты наблюдений зависимой переменной  $Y$ :  $y_1, y_2, \dots, y_n$  являются реализациями случайных величин  $\beta_0 + \beta_1 x_i + \varepsilon_i$ , обозначаемых  $y_i$ ,  $i = \overline{1, n}$ .

Задача линейного регрессионного анализа решается в предположении, что случайные ошибки наблюдений  $\varepsilon_i$  и  $\varepsilon_j$  не коррелированы, имеют математические ожидания

равные нулю, и одну и ту же дисперсию, равную  $\sigma^2$ , т.е.  $M(\varepsilon_i) = 0$ ,  $K_{\varepsilon_i \varepsilon_j} = \begin{cases} 0, & i \neq j \\ \sigma^2, & i = j \end{cases}$ ,

$i = \overline{1, n}$ . При статистическом анализе регрессионной модели предполагается также, что случайные ошибки наблюдений  $\varepsilon_i$ ,  $i = \overline{1, n}$  имеют нормальное распределение, т.е.  $\varepsilon_i \sim N(0, \sigma^2)$ ,  $i = \overline{1, n}$ . В этом случае ошибки наблюдений также являются независимыми случайными величинами. Можно определить величину ошибки для всех отмеченных точек. Линейная модель, которая наилучшим образом аппроксимирует данные – одна из тех, для которых общая ошибка выборки имеет наименьшее значение. Чтобы рассчитать ее нужно избежать позитивных и негативных значений. Это можно сделать, возведя все ошибки в квадрат и делая их положительными величинами. Линия наилучшего подбора – та, которая минимизирует квадраты разниц между рассматриваемыми значениями  $y$  и соответствующими значениями  $x$ , рассчитанными с помощью линии наилучшего подбора. Эта линия называется **линией регрессии, полученной методом наименьших квадратов**. Для нахождения оценок параметров


модели по результатам наблюдений используется **метод наименьших квадратов**. По этому методу выбирают такие оценки  $\beta_0, \beta_1$ , которые минимизируют сумму квадратов отклонений наблюдаемых значений случайных величин  $y_i$  от их математических ожиданий, т.е.

$$\sum_{i=1}^n ((\beta_0 + \beta_1 \cdot x_i) - y_i)^2 \rightarrow \min \quad (2)$$

### Метод наименьших квадратов

Принцип поиска коэффициентов регрессии путём минимизации суммы квадратов отклонений между реальными значениями признака и прогнозируемыми согласно предполагаемой форме зависимости (в нашем случае – линейной) называется *методом наименьших квадратов* (англ.: Least Square Method, LSM).

Проиллюстрируем целевую функцию задачи (2) на следующем рисунке.



Значение целевой функции задачи (2) при фиксированных значениях  $\beta_0$  и  $\beta_1$  равно сумме квадратов длин построенных отрезков. Из рисунка видно, что построенная прямая – не лучшая, так как можно провести прямую, обеспечивающую меньшее значение целевой функции задачи (2).

Найдём решение задачи (2). Целевую функцию задачи (2) обозначим через  $\varphi(\beta_0, \beta_1)$ . Очевидно,  $\varphi(\beta_0, \beta_1)$  – дифференцируемая функция двух переменных. Найдём её частные производные:

$$\frac{\partial \varphi}{\partial \beta_0} = 2 \sum_{i=1}^n ((\beta_0 + \beta_1 \cdot x_i) - y_i) \quad (3)$$

$$\frac{\partial \varphi}{\partial \beta_1} = 2 \sum_{i=1}^n ((\beta_0 + \beta_1 \cdot x_i) - y_i) x_i$$

и запишем систему для поиска стационарной точки:

$$\begin{cases} \sum_{i=1}^n ((\beta_0 + \beta_1 \cdot x_i) - y_i) = 0 \\ \sum_{i=1}^n ((\beta_0 + \beta_1 \cdot x_i) - y_i) x_i = 0 \end{cases} \quad (4)$$

После несложных преобразований системы (4) получим

$$\begin{cases} n\beta_0 + \beta_1 \cdot \sum_{i=1}^n x_i - \sum_{i=1}^n y_i = 0 \\ \beta_0 \sum_{i=1}^n x_i + \beta_1 \cdot \sum_{i=1}^n x_i^2 - \sum_{i=1}^n x_i y_i = 0 \end{cases} \quad (5)$$

Введём обозначения:  $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$ ,  $\bar{y} = \frac{1}{n} \sum_{i=1}^n y_i$ ,  $\overline{x \cdot y} = \frac{1}{n} \sum_{i=1}^n x_i y_i$  и  $\overline{x^2} = \frac{1}{n} \sum_{i=1}^n x_i^2$ .

Поделив оба уравнения системы (5) на  $n$ , получим


$$\begin{cases} \beta_0 + \beta_1 \cdot \bar{x} - \bar{y} = 0 \\ \beta_0 \bar{x} + \beta_1 \cdot \overline{x^2} - \overline{x \cdot y} = 0 \end{cases} \quad (6)$$

Нетрудно показать, что система (5) имеет единственное решение  $(\beta_0^*, \beta_1^*)$ , где

$$\beta_1^* = \frac{\bar{x} \cdot \bar{y} - \overline{x \cdot y}}{\overline{x^2} - \bar{x}^2} \quad \beta_0^* = \bar{y} - \beta_1^* \cdot \bar{x} \quad (7)$$

Учитывая свойства функции  $\varphi(\beta_0, \beta_1)$ , нетрудно показать также, что это решение (т.е., стационарная точка функции  $\varphi(\beta_0, \beta_1)$ ) является *точкой минимума* функции  $\varphi(\beta_0, \beta_1)$ .

Иными словами, определяемые формулами (7) значения  $\beta_0^*$  и  $\beta_1^*$  обеспечивают получение наилучшей (в смысле задачи (2)) линейной функции, отражающей зависимость переменной отклика  $y$  от фактора  $x$ . График этой линейной зависимости называется *прямой регрессии* ( $y$  на  $x$ ). На приведённом ниже рисунке эта прямая имеет красный цвет.



Найденная линейная функция позволяет *прогнозировать* значение зависимого признака ( $y$ ) по заданным значениям независимого фактора ( $x$ ).