

Лекция 3

Распределение Гаусса


Поскольку Гауссово распределение играет важную роль в технических измерениях, рассмотрим его более подробно.

Гауссова плотность распределение случайной величины x имеет вид


$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-x_M)^2}{2\sigma^2}}. \quad (1)$$

Здесь $\frac{1}{\sigma\sqrt{2\pi}}$ - нормирующий множитель такой, что интеграл от плотности вероятности равен единицы. В этой формуле для плотности вероятности имеются две важные величины: x_M - математическое ожидание (появление этой величины мы ожидаем чаще других значений), и дисперсия $\sigma^2 = D$, $\sigma = \sqrt{D}$ - среднеквадратическое отклонение.

Чем хороша эта функция? Она хороша тем, что она полностью определяется своими первыми двумя моментами. То есть для того чтобы восстановить эту функцию нужно только математическое ожидание и дисперсия.



На графике видно, что увеличению дисперсии σ плотность вероятности «размазывается». То есть разброс случайной величины увеличивается. Высота каждой кривой определяется соотношением $\sim 1/\sigma\sqrt{2\pi}$



На графике видно, что на диапазоне горизонтального интервала $x \in [-3\sigma, 3\sigma]$ практически полностью укладываются все возможные случайной величины с вероятностью 0,997. То же самое можно сказать и об интервале $x \in [-2\sigma, 2\sigma]$, с вероятностью 0,95. Эти интервалы называются доверительными.



Вероятность появления случайной величины в диапазоне от $-\infty$ до x равна


$$F(x) = \frac{1}{\sigma\sqrt{2\pi}} \int_{-\infty}^x e^{-\frac{(x-x_M)^2}{2\sigma^2}}$$

Зададим диапазон изменения величины в интервале значений $x \in [-3\sigma, 3\sigma]$, и в интервале значений $x \in [-2\sigma, 2\sigma]$, и получив вероятность этих событий:

$$F(x) = \frac{1}{\sigma\sqrt{2\pi}} \int_{-3\sigma}^{3\sigma} e^{-\frac{(x-x_M)^2}{2\sigma^2}} = 0,997, \quad F(x) = \frac{1}{\sigma\sqrt{2\pi}} \int_{-2\sigma}^{2\sigma} e^{-\frac{(x-x_M)^2}{2\sigma^2}} = 0,95$$

Приведем пример двух моделей с гауссовым шумом.





Под моментами случайной величины понимается выражение вида

$$M_n = \frac{1}{\sigma\sqrt{2\pi}} \int_{-\infty}^x x^n e^{-\frac{(x-x_M)^2}{2\sigma^2}}, \quad M_0 = 1, \quad M_1 = x_M, \quad M_2 = \sigma^2$$

Обычно начиная со второго момента моменты центрируют

$$M_n = \frac{1}{\sigma\sqrt{2\pi}} \int_{-\infty}^x (x-x_M)^n e^{-\frac{(x-x_M)^2}{2\sigma^2}},$$

Как определяются моменты экспериментально? Моменты определяются по выборкам. По совокупности измеренных данных. Сначала нужно использовать регрессионный анализ и МНК для определения трендовой составляющей. По теореме Вейерштрасса искомое решение представляется в $\tilde{y}_k = a_0 + a_1k + a_2k^2 + a_3k^3$

$$Q(a) = \sum_{i=0}^N (y_i - \tilde{y}(a_k, x_i))^2 = \sum_{i=0}^N (y_i - a_3x_i^3 - a_2x_i^2 - a_1x_i - a_0)^2 \rightarrow \min$$

Затем вычисляются частные производные по неизвестным коэффициентам

$$\frac{\partial Q}{\partial a_k} = 2 \sum_{i=0}^N (y_i - \tilde{y}(a_k, x_i)) \frac{\partial \tilde{y}(a_k, x_i)}{\partial a_k} = 0$$

И решается система алгебраических уравнений относительно a_k . Всё это можно сделать с быстрее с помощью псевдо обратной матрицы Мура-Пенроуза $\mathbf{A}^+ = (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T$. Матрица \mathbf{A} которая входит в псевдо обратную матрицу формируется по алгоритму.

$\mathbf{A}_{i,k} = (x_i)^k$, здесь k - степень полинома, i - число выборок. Запишем формулу коэффициентов аппроксимирующего полинома.

$$\begin{pmatrix} a_0 \\ a_1 \\ a_2 \\ a_3 \end{pmatrix} = (X^T X)^{-1} X^T y,$$

Здесь $y = (y_0, y_1, y_2, \dots, y_N)^T$ совокупность табличных значений.

Затем составляется выражение для тренда

$$y(x) = a_0 + a_1 x + a_2 x^2 + a_3 x^3$$

Величины, которые дают нам приближенное значение моментов через табличные данные называются оценками или выборочные моменты. Приведём формулы для оценок моментов. Математическое ожидание

$$\delta_k = y_i - (a_0 + a_1 x_i + a_2 x_i^2 + a_3 x_i^3), \quad x_M = \frac{1}{N} \sum_{k=0}^{N-1} \delta_k$$

Оценка дисперсии определяется по формуле:

$$D = \frac{1}{N} \sum_{k=0}^{N-1} (\delta_k - x_M)^2$$


Рассмотрим **пример**. Получены табличные значения. По табличным значения необходимо определить закон распределения случайной величины.

$i := 0..N - 1$

$tl^T =$	0	1	2	3	4	5	6	7	8	9
	0	0.063	0.126	0.188	0.251	0.314	0.377	0.44	0.503	...

$Fs^T =$	0	1	2	3	4	5	
	0	-0.013	-0.028	0.08	0.346	0.041	...

По табличным данным строим графики.




Определяем тренд, используя метод наименьших квадратов (МНК)

$$k := 0..3 \quad X_{i,k} := (x1_i)^k \quad \begin{pmatrix} a_0 \\ a_1 \\ a_2 \\ a_3 \end{pmatrix} := (X^T \cdot X)^{-1} \cdot X^T \cdot F_s = \begin{pmatrix} -0.221 \\ 1.952 \\ -0.893 \\ 0.094 \end{pmatrix}$$


$$k := 0..3 \quad i := 0..N - 1 \quad X_{i,k} := (t1_i)^k \quad \begin{pmatrix} a_0 \\ a_1 \\ a_2 \\ a_3 \end{pmatrix} := (X^T \cdot X)^{-1} \cdot X^T \cdot F_s = \begin{pmatrix} -0.221 \\ 1.952 \\ -0.893 \\ 0.094 \end{pmatrix}$$

$$y_-(t) := a_0 + a_1 \cdot t + a_2 \cdot t^2 + a_3 \cdot t^3$$



Теперь можно определить случайную величину как отклонение от трендового значения

$$xs_i := (Fs_i - y_-(t1_i)) \text{ то есть величину ошибки}$$



Находим оценки случайной величины, первый (выборочное среднее) и второй моменты.


$$M_1 := \frac{1}{N} \cdot \sum_{i=0}^{N-1} xs_i = -0 \quad M_2 := \frac{1}{N-1} \cdot \sum_{i=0}^{N-1} (xs_i - M_1)^2 = 0.0134$$

Определяем среднеквадратическое отклонение

$$D := M_2 \quad \sigma := \sqrt{D} = 0.116$$

По графику видно, что выполняется закон 2-х и 3-х сигма.

$$s := \text{sort}(xs) \quad F(x, x_M, \sigma) := \int_{-100}^x f(x, \sigma, x_1) dx \quad x := -2 \cdot \sigma, -2 \cdot \sigma + 0.025 \dots 2.5 \cdot \sigma$$



$N = 100 \quad H := \text{histogram}(\text{trunc}(\sqrt{N}), s) \quad H^{(0)} =$


	0
0	-0.233
1	-0.182
2	-0.131
3	-0.08
4	-0.029
5	0.022
6	0.073
7	0.124
8	0.175
9	0.227

$H^{(1)} =$


	0
0	2
1	4
2	8
3	15
4	21
5	16
6	21
7	6
8	3
9	4

Построение Гистограммы

$$y(x) := \text{dnorm}(x, 0, \sigma) \cdot \sqrt{2 \cdot \pi} \cdot \sigma \cdot \max(H^{(1)})$$



Как проверить достоверность получаемых зависимостей



Расчет коэффициентов корреляции.

В качестве меры достоверности уравнения корреляционной зависимости используется процентное отношение средней квадратической ошибки уравнения Se к среднему уровню результативного признака y :