

Компьютерная обработка результатов измерений

Лекция 2. Статистика и вероятность. Случайные величины и распределения

Емельянов Эдуард Владимирович

Специальная астрофизическая обсерватория РАН
Лаборатория физики оптических транзиентов



- 1 Случайные величины, вероятность
- 2 Комбинаторика
- 3 Характеристики случайных величин
- 4 Законы распределения
- 5 Корреляция и ковариация
- 6 Шум

Случайные величины, вероятность

Случайной величиной называется величина X , если все ее возможные значения образуют конечную или бесконечную последовательность чисел x_1, \dots, x_N , и если принятие ею каждого из этих значений есть случайное событие.

Вероятностью наступления события называют предел относительной частоты наступления данного события n_k/N :

$$P(x_k) = \lim_{N \rightarrow \infty} \frac{n_k}{N}.$$

Если событие **невозможно** (\emptyset), его вероятность равна нулю. Однако, обратное в общем случае неверно (например, вероятность попасть в конкретную точку мишени равна нулю, но это событие не является невозможным).

Вероятность **достоверного** события равна 1.



Условная вероятность

Условной вероятностью двух событий A и B (вероятность появления A при условии B) называют отношение числа опытов, в которых A и B появились вместе, к полному числу опытов, в которых появилось B :

$$P(A|B) = \frac{n_{AB}}{n_B} = \frac{n_{AB}/N}{n_B/N} = \frac{P(AB)}{P(B)}.$$

У **независимых** событий $P(A|B) = P(A)$, $P(B|A) = P(B)$. А т.к.
 $P(A|B) = \frac{P(AB)}{P(B)}$, получим для независимых событий:

$$P(AB) = P(A) \cdot P(B).$$

Умножение вероятностей

$$P(AB) = P(B) \cdot P(A|B) = P(A) \cdot P(B|A).$$

Сложение вероятностей

Несовместные события

$A_i A_j = \emptyset \quad \forall i \neq j, P(A_i + A_j) = P(A_i) + P(A_j).$

Совместные события

$P(A_i + A_j) = P(A_i) + P(A_j) - P(A_i A_j).$

Независимые совместные события

$P(\overline{A} \overline{B}) = P(\overline{A}) \cdot P(\overline{B}) = (1 - P(A)) \cdot (1 - P(B)) = 1 - P(A) - P(B) + P(A) \cdot P(B)$

$$P(A + B) = P(A) + P(B) - P(AB) \Rightarrow$$

$$1 - P(A + B) = P(\overline{A} \overline{B}) \quad \text{или} \quad P(A + B) = 1 - P(\overline{A} \overline{B}).$$



Полная вероятность

Полная вероятность (вероятность события, зависящего от условий опыта) является следствием правил сложения и умножения вероятностей.

N условий опыта должны быть взаимоисключающими, т.е. несовместными: $P(H_i H_j) = 0$ для $j \neq i$. И они должны формировать **полную группу**, т.е. $\sum P(H_i) = 1$. Тогда $P(A) = \sum P(AH_i)$. А т.к. $P(AH_i) = P(H_i) \cdot P(A|H_i)$, получим:

$$P(A) = \sum_{i=1}^N P(H_i) \cdot P(A|H_i).$$

Здесь $P(H_i)$ — **априорная вероятность** (известна до проведения опыта). Вероятность $P(A|H_i)$ мы узнаем из опыта, ее называют **апостериорной**.



Полная вероятность

Пример

Среди наблюдаемых спиральных галактик 23% имеют тип Sa, 31% – тип Sb и 45% – тип Sc. Вероятность вспышки сверхновой в течение года в галактике Sa составляет 0.20%, в Sb – 0.35%, в Sc – 0.55%. Найти вероятность вспышки сверхновой в спиральной галактике, тип которой не удается определить.

$P(S_a) = 0.23$, $P(S_b) = 0.31$, $P(S_c) = 0.46$. Вероятность вспышки в галактике типа X есть $P(F|X)$. Тогда полная вероятность вспышки равна $P(F) = \sum P(X)P(F|X)$. То есть:

$$P(F) = 0.23 \cdot 0.002 + 0.31 \cdot 0.0035 + 0.46 \cdot 0.0055 = 0.0041 = 41\%.$$



Формула (теорема) Байеса

Как и для полной вероятности, гипотезы H_i считаем несовместными, образующими полную группу. Событие A считаем уже произошедшим. В этом случае можно пересчитать априорные вероятности $P(H_i)$ с учетом этого. Найдем $P(H_i|A)$. Известно, что $P(H_i A) = P(H_i) \cdot P(A|H_i)$ или $P(H_i A) = P(A) \cdot P(H_i|A)$.

$$P(A) \cdot P(H_i|A) = P(H_i) \cdot P(A|H_i), \quad \Rightarrow$$

Формула Байеса

$$P(H_i|A) = \frac{P(H_i)P(A|H_i)}{P(A)},$$

где $P(A) = \sum P(H_i)P(A|H_i)$.



Формула (теорема) Байеса

Пример

В течение часа наблюдений была обнаружена вспышка сверхновой в спиральной галактике неизвестного типа. Определить вероятность того, что галактика принадлежит каждому из подтипов Sa, Sb или Sc.

По формуле Байеса, $P(X|F) = \frac{P(X)P(F|X)}{P(F)}$. В предыдущем примере мы уже нашли: $P(F) = 0.0041$, следовательно

$$P(S_a|F) = \frac{0.23 \cdot 0.0020}{0.0041} = 0.11,$$

$$P(S_b|F) = \frac{0.31 \cdot 0.0035}{0.0041} = 0.27,$$

$$P(S_c|F) = \frac{0.46 \cdot 0.0055}{0.0041} = 0.62.$$



Итог: свойства вероятности

$$P(\emptyset) = 0$$

$$\forall A \subset B \quad P(A) \leq P(B)$$

B включает в себя A

$$0 \leq P(A) \leq 1$$

$$\forall A \subset B \quad P(B \setminus A) = P(B) - P(A) \quad B \text{ наступит без } A$$

$$P(\overline{A}) = 1 - P(A)$$

$$P(A+B) = P(A) + P(B) - P(AB)$$

вероятность одного из событий

$$P(A|B) = P(AB)/P(B)$$

условная вероятность (*A при B*) \Rightarrow

$$P(AB) = P(B) \cdot P(A|B)$$

или $P(AB) = P(A) \cdot P(B|A) \Rightarrow$

$$P(A|B) = \frac{P(A) \cdot P(B|A)}{P(B)}$$

(теорема Байеса)

$$P(AB) = P(A) \cdot P(B)$$

для независимых событий

Комбинаторика

Размещение

Количество способов, которыми можно разместить n элементов по k ячейкам.

Без повторений: $A_n^k = n(n - 1) \cdots (n - k + 1) = \frac{n!}{(n - k)!} = \binom{n}{k} k!$.

С повторениями (каждый предмет можно взять до k раз): $\overline{A}_n^k = n^k$.

Размещение без повторений встречается в задачах на составление k -значных чисел из n цифр, причем, каждая цифра может использоваться лишь однократно. Размещение с повторениями показывает все возможные комбинации n цифр в k разрядах (например, количество чисел до k -го разряда по основанию n).



Комбинаторика

Перестановка

Без повторений: $P_n = A_n^n = n!$.

С повторениями (n элементов m типов). n_i – количество элементов каждого типа (т.е. $\sum n_i = n$). $P(n_1, \dots, n_m) = \frac{n!}{\prod n_i!}$.

Задача на перестановки без повторений является частным случаем задачи размещения без повторений, когда $k = n$.

Пример задачи на перестановки с повторениями — формирование разных слов (даже лишенных смысла) из букв заданного слова. Например, из слова «собака» можно составить $6!/(1!1!1!2!1!) = 720/2 = 36$.



Комбинаторика

Сочетание

Неупорядоченный набор из k элементов n -элементного множества. Т.о. сочетание — это такое размещение n по k , где не учитывается порядок следования членов (напр., размещения 123, 213, 321 и т.д. считаются одним сочетанием).

Без повторений: $C_n^k = \binom{n}{k} = \frac{n!}{k!(n-k)!}$.

С повторениями: $\overline{C}_n^m = \binom{n+k-1}{n-1} = \binom{n+k-1}{k} = \frac{(n+k-1)!}{k!(n-1)!}$.

Схема испытаний Бернулли: $P_n^k = C_n^k p^k (1-p)^{n-k}$ (вероятность, что событие наступит k раз в n испытаниях).

$$1 = (p + [1 - p])^n = \sum C_n^k p^{n-k} (1-p)^k = \sum P_n^k.$$



Для непрерывных случайных величин, X , вводят понятия **Функции распределения**, $F(x)$ и **плотности вероятности**, $\rho(x)$: $F(x) = P(X < x)$.

$$\rho(x) = \lim_{\Delta x \rightarrow 0} \frac{P(x < X < x + \Delta x)}{\Delta x} = \frac{dF}{dx}.$$

$$P(x_1 < X < x_2) = \int_{x_1}^{x_2} \rho(x) dx = F(x_2) - F(x_1).$$

Генеральная совокупность — набор всех возможных значений случайной величины. **Выборка** — конечное число значений (подвыборка генеральной совокупности). **Энтропия** выборки:

$$E = - \sum_{k=1}^n p(x_k) \lg p(x_k).$$



Характеристики случайных величин

Среднее арифметическое и математическое ожидание

$$\langle X \rangle = 1/N \sum_{n=1}^N x_n,$$

$$M(X) \equiv \overline{X} = \lim_{N \rightarrow \infty} \frac{1}{N} \sum_{n=1}^N x_n \quad \text{и} \quad M(X) = \int_{-\infty}^{\infty} x \varphi(x) dx.$$

Свойства математического ожидания

- $\overline{\text{const}} = \text{const};$
- $\overline{\sum \mathfrak{C}_n \cdot X_n} = \sum \mathfrak{C}_n \cdot \overline{X_n}$, где \mathfrak{C}_n – постоянная величина;
- $\overline{\prod X_n} = \prod \overline{X_n}$ (для независимых случайных величин);
- $\overline{f(x)} = \int_{-\infty}^{\infty} f(x) \varphi(x) dx$ (для непрерывных случайных величин).



Моменты

Если $f(x) = (x - x_0)^n$, то $\overline{f(x)}$ — момент порядка n . Если $x_0 = 0$ — начальный момент, если $x_0 = \bar{X}$ — центральный момент.

Центральный момент второго порядка называют **дисперсией**:

$$D(X) = \overline{(x - \bar{x})^2} \equiv \overline{x^2} - \bar{x}^2. \text{ СКО: } \sigma = \sqrt{D}.$$

Свойства дисперсии:

- $D(\mathfrak{C}) = 0$;
- $D(\mathfrak{C}X) = \mathfrak{C}^2 D(X)$, где \mathfrak{C} — постоянная величина;
- $D(\sum X_n) = \sum D(X_n)$ (для независимых величин).

$\bar{X} \Leftrightarrow \langle X \rangle$? Закон больших чисел

Неравенство Чебышёва: $P(|X - \bar{X}| \geq \varepsilon) \leq D(X)/\varepsilon^2 \Rightarrow P(|X - \bar{X}| < \varepsilon) = 1 - P(|X - \bar{X}| \geq \varepsilon) \geq 1 - D(X)/\varepsilon^2$.

$$\lim_{n \rightarrow \infty} P\left(\left|\frac{\sum X_n}{n} - \frac{\sum \bar{X}_n}{n}\right| < \varepsilon\right) = 1, \quad \text{т.к. } D\left(\frac{\sum X_n}{n}\right) = D(X)/n$$

Теорема Бернулли: $\lim_{n \rightarrow \infty} P(|m/n - p| < \varepsilon) = 1$ (m событий в n испытаний).

Квантиль – значение, которое случайная величина не превышает с фиксированной вероятностью. α -квантиль, x_α : $P(X \leq x_\alpha) = \alpha$, $P(X \geq x_\alpha) = 1 - \alpha$.

$P(X \leq x_{\frac{1+\alpha}{2}}) = \frac{1+\alpha}{2}$, $P(X \leq x_{\frac{1-\alpha}{2}}) = \frac{1-\alpha}{2}$, следовательно, свойство:

$$P(x_{\frac{1-\alpha}{2}} \leq X \leq x_{\frac{1+\alpha}{2}}) = \frac{1+\alpha}{2} - \frac{1-\alpha}{2} = \alpha.$$

Процентиль (перцентиль) – квартиль, выраженная в процентах. Например, «70-й перцентиль» (величина с вероятностью 70% меньше этого значения).

Квартиль – деление на четыре (первый, второй и третий квартили).

Медиана – второй квартиль. $IQR = x_{0.75} - x_{0.25}$ – интерквартильный интервал.




Квантили нормального распределения

P – вероятность, x_P – квантиль (в RMS от мат. ожидания), $P_c = P(-x_P \leq X - \bar{X} \leq x_P)$.

P	99.99	99.90	99.00	97.72	97.50
x_P	3.719	3.090	2.326	1.999	1.960
P_c	99.98	99.80	98.00	95.44	95.00

P	95.00	90.00	84.13	50.00
x_P	1.645	1.282	1.000	0.000
P_c	90.00000	80.00	68.27	0.00



Octave: пакет statistics, функция norminv. Например:

```
norminv([0.9 0.95 0.99 0.999 0.9999])
ans =
1.2816    1.6449    2.3263    3.0902    3.7190
```

Можно также задать \bar{X} и σ_X (скажем, квантиль 90% при $\bar{X} = 25$ и $\sigma_X = 3$):

```
norminv(0.9, 25, 3)
ans = 28.845
```

Для расчета вероятности $P(X \leq x_0)$ функция normcdf (интегральное распределение). Например, посчитаем вероятности нахождения в интервале $\bar{X} \pm k\sigma$:


```
k=[1:0.5:5];
normcdf(k)-normcdf(-k)
ans =
0.68269    0.86639    0.95450    0.98758    0.99730    0.99953
0.99994    0.99999    1.00000
```



Характеристические значения распределений

Медиана и мода

Мода — наиболее часто встречающееся значение (но вполне могут быть мультиомодальные распределения). **Медиана** делит площадь распределения пополам.



Поиск медианы

Самый медленный — сортировкой ряда данных, $O(n \ln n)$. Quick Select, $O(n)$. Гистограмма (в т.ч. дерево гистограмм), $O(n)$. Для фиксированных n — `opt_med` („Numerical Recipes in C“), $O(n)$.

Законы распределения

Закон распределения дискретной случайной величины — соответствие между возможными значениями и их вероятностями.

Функция распределения

$$F(x) \equiv P(X \leq x) = \int_{-\infty}^x \varphi(x) dx, \quad \int_{-\infty}^{\infty} \varphi(x) dx = 1.$$


$$P(a \leq X \leq b) = F(b) - F(a).$$




Равномерное распределение

$$\varphi(x) = \begin{cases} \frac{1}{b-a}, & x \in [a, b] \\ 0, & x \notin [a, b] \end{cases}.$$

$$F(x) = \begin{cases} 0, & x < a \\ \frac{x-a}{b-a}, & a \leq x < b \\ 1, & x \geq b \end{cases}.$$



$$\begin{aligned}\bar{X} &= \text{med}(X) = (a + b)/2, \\ \text{Mo}(X) &= \forall x \in [a, b], \\ \sigma_X^2 &= \frac{(b - a)^2}{12}.\end{aligned}$$




Биномиальное распределение

Формула Бернули: $P_n(k) = C_n^k p^k q^{n-k}$, $C_n^k = \frac{n!}{k!(n-k)!}$, $q = 1 - p$.

$$(p+q)^n = C_n^n p^n + \cdots + C_n^k p^k q^{n-k} + \cdots + C_n^0 q^n.$$

Описывает вероятность наступления события k раз в n независимых испытаниях



$$F(k; n, p) = P(X \leq k) = \sum_{i=0}^{\lfloor k \rfloor} C_n^i p^i (1-p)^{n-i}.$$

$$\bar{X} = np, \text{Mo}(X) = \lfloor (n+1)p \rfloor, \\ \lfloor np \rfloor \leq \text{med}(X) \leq \lceil np \rceil, \sigma_X^2 = npq.$$



Распределение Пуассона

Распределение вероятности *редких событий*. При $n \rightarrow \infty$ распределение Бернулли преобразуется в распределение Пуассона ($\lambda = np$):

$$P_n(k) = \frac{\lambda^k}{k!} \exp(-\lambda).$$


$$F(k, \lambda) = \frac{\Gamma(k+1, \lambda)}{k!}, \quad \bar{X} = \lambda,$$

$$\text{Mo}(X) = \lfloor \lambda \rfloor,$$

$$\text{med } X \approx [\lambda + 1/3 - 0.02/\lambda],$$

$$\sigma_X^2 = \lambda.$$

С ростом λ распределение Пуассона стремится к распределению Гаусса.




Распределение Гаусса

$$\varphi(x) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left(-\frac{(x-\bar{x})^2}{2\sigma^2}\right), \quad F(x) = \frac{1}{\sigma\sqrt{2\pi}} \int_{-\infty}^x \exp\left(-\frac{(t-\bar{x})^2}{2\sigma^2}\right) dt,$$

$$\text{Mo}(X) = \text{med } X = \bar{X}. \quad P(\alpha < X < \beta) = \Phi\left(\frac{\beta-\bar{x}}{\sigma}\right) - \Phi\left(\frac{\alpha-\bar{x}}{\sigma}\right),$$

$$\text{функция Лапласа } \Phi(x) = \frac{1}{\sqrt{2\pi}} \int_0^x \exp\left(-t^2/2\right).$$




Показательное (экспоненциальное) распределение

Время между двумя последовательными свершениями события

$$f(x) = \begin{cases} 0, & x < 0, \\ \lambda \exp(-\lambda x), & x \geq 0; \end{cases} \quad F(x) = \begin{cases} 0, & x < 0, \\ 1 - \exp(-\lambda x), & x \geq 0, \end{cases}$$

$$\bar{X} = \lambda^{-1}, \text{Mo}(X) = 0, \text{med } X = \ln(2)/\lambda, \sigma_X^2 = \lambda^{-2}.$$



Корреляция и ковариация

Ковариация является мерой линейной зависимости случайных величин и определяется формулой: $\text{cov}(X, Y) = \overline{(X - \bar{X})(Y - \bar{Y})} \Rightarrow \text{cov}(X, X) = \sigma_X^2$.
Ковариация независимых случайных величин равна нулю, обратное неверно.

Если ковариация положительна, то с ростом значений одной случайной величины, значения второй имеют тенденцию возрастать, а если знак отрицательный — убывать.

Масштаб зависимости величин пропорционален их дисперсиям \Rightarrow масштаб можно отнормировать (**коэффициент корреляции Пирсона**):

$$\rho_{X,Y} = \frac{\text{cov}(X, Y)}{\sigma_X \sigma_Y}, \quad r \in [-1, 1].$$



Коэффициент корреляции равен ± 1 тогда и только тогда, когда X и Y линейно зависимы. Если они независимы, $\rho_{X,Y} = 0$ (**обратное неверно!**). Промежуточные значения коэффициента корреляции не позволяют однозначно судить о зависимости случайных величин, но позволяет предполагать степень их зависимости.

Корреляционная функция

Одна из разновидностей — **автокорреляционная функция**:

$$\Psi(\tau) = \int f(t)f(t - \tau) dt \equiv \int f(t + \tau)f(t) dt.$$

Для дискретных случайных величин автокорреляционная функция имеет вид

$$\Psi(\tau) = \langle X(t)X(t - \tau) \rangle \equiv \langle X(t + \tau)X(t) \rangle.$$




Взаимно корреляционная функция

Другая разновидность — кросс–корреляционная функция:

$$(f \star g)(t) \stackrel{\text{def}}{=} \int_{-\infty}^{\infty} f^*(\tau)g(t + \tau) d\tau$$

свертка:

$$(f * g)(x) \stackrel{\text{def}}{=} \int_{-\infty}^{\infty} f(y) g(x - y) dy = \int_{-\infty}^{\infty} f(x - y) g(y) dy.$$




Если X и Y — две независимых случайных величины с функциями распределения вероятностей f и g , то $f * g$ соответствует распределению вероятностей выражения $-X + Y$, а $f * g$ — распределению вероятностей суммы $X + Y$.

ВКФ часто используется для поиска в длинной последовательности более короткой заранее известной, определения сдвига (см. рис).

Связь со сверткой: $f(t) \star g(t) = f^*(-t) * g(t)$, если f и g четны, то $f(t) \star g(t) = f(t) * g(t)$. Через преобразование Фурье:

$$\mathcal{F}(f \star g) = \mathcal{F}(f)^* \cdot \mathcal{F}(g).$$



Применение корреляции

- Расчет спектральной плотности энергии и энергетического содержимого сигнала. $\mathcal{F}(\Psi(\tau)) = G_E(f)$ – образ Фурье автокорреляционной функции есть спектральная плотность энергии; $\Psi(0) = E$ – полная энергия сигнала.
- Детектирование и оценка периодических сигналов в шуме.
- Корреляционное детектирование.

Шум

Шум — беспорядочные колебания различной физической природы, отличающиеся сложной временной и спектральной структурой.

Белый шум, $\xi(t)$, имеет время корреляции много меньше всех характерных времен физической системы; $\overline{\xi(t)} = 0$, $\Psi(t, \tau) = \langle \xi(t + \tau) \xi(t) \rangle = \sigma^2(t) \delta(\tau)$.
Разновидность — AWGN.

Дробовой шум имеет пуассонову статистику $\Rightarrow \sigma_X \propto \sqrt{x}$ и
 $\text{SNR}(N) \propto \sqrt{N}$. Суточные и вековые корреляции.


Шум вида «соль–перец» обычно характерен для изображений, считываемых с ПЗС.



SNR

SNR — безразмерная величина, равная отношению мощности полезного сигнала к мощности шума.

$$\text{SNR} = \frac{P_{\text{signal}}}{P_{\text{noise}}} = \left(\frac{A_{\text{signal}}}{A_{\text{noise}}} \right)^2, \quad \text{SNR}(dB) = 10 \lg \left(\frac{P_{\text{signal}}}{P_{\text{noise}}} \right) = 20 \lg \left(\frac{A_{\text{signal}}}{A_{\text{noise}}} \right).$$



(10, 0, -10 дБ.)



Спасибо за внимание!

mailto

eddy@sao.ru

edward.emelianoff@gmail.com

