

Matematická statistika

Náhodná (stochastická) proměnná přiřazuje pravděpodobnost/hustotu pravděpodobnosti možnému diskrétnímu/spojitému jevu z diskrétní/spojité množiny jevů.

diskrétní příklad: hod kostkou: $p_i = 1/6$ pro $i \in \{1, 2, 3, 4, 5, 6\}$

spojitý příklad: čas rozpadu jádra: $p(t) = ke^{-kt}$

Spojitu náhodnou veličinu v 1D (tj. $x \in \mathbb{R}$) popisuje **distribuční funkce** (hustota pravděpodobnosti, rozdělení/rozložení pravděpodobnosti, probability distribution function (PDF) $p(x)$):

$p(x)dx$ je pravděpodobnost, že nastane jev $x \in [x, x+dx]$

Ve dvou dimenzích definujeme hustotu pravděpodobnosti $p(x, y)$ tak, že jev $x \in [z, x+dx]$ a zároveň $y \in [y, y+dy]$ nastane s pravděpodobností $p(x, y)dx dy$.

Normalizace: $\sum_i p_i = 1$ nebo $\int_{-\infty}^{\infty} p(x)dx = 1$

Kumulativní (integrální) distribuční funkce = pravděpodobnost, že padne náhodná hodnota $x \leq x$:

$$P(x) = \int_{-\infty}^x p(x')dx'$$

Uzávřený interval značím $[a, b]$, aby se nepletly se střední hodnotou.

Rozdelení pravděpodobnosti

2/33 mmfch5

Varování. Ve fyzice a technice nepřesně a volně zaměňujeme symbol x pro náhodnou veličinu a x pro její hodnotu (např. při integraci).

Střední hodnota (též expectation value, očekávaná hodnota; slovo průměr budeme rezervovat pro aritmetický průměr, tj. střední hodnotu výběru)

$$E(x) \equiv \langle x \rangle \equiv \langle x \rangle_{\text{volně}} = \int xp(x)dx \quad \text{nebo} \quad \sum_i x_i p_i$$

Variance, rozptyl, fluktuace, střední kvadratická odchylka, mean square deviation (MSD), disperze

$$\text{Var}(x) \stackrel{\text{volně}}{=} \text{Var}x = ((x - \langle x \rangle)^2) = (\Delta x^2) = (x^2) - (\langle x \rangle)^2, \quad \text{kde } \Delta x = x - \langle x \rangle$$

Směrodatná odchylka, standardní odchylka, standard deviation, root mean square deviation, RMSD

$$\sigma(x) = \sqrt{\text{Var}(x)}$$

též $\sigma(x)$, σ_x , δx , $s(x)$ (odhad σ) ...

'also Mean Square Displacement

Příklady

3/33 mmfch5

Ověřte normalizaci a vypočtěte střední hodnotu a varianci pro následující rozdělení:

a) Rovnoměrné rozdělení v intervalu $[0, 1]$; na počítací např. rnd(0). viz mmfch5.mw

$$\int p(x)dx = \int_0^1 1dx = 1, \quad \langle x \rangle = \int_0^1 xdx = \frac{1}{2}, \quad \text{Var}(x) = \int_0^1 \left(x - \frac{1}{2}\right)^2 dx = \frac{1}{12}, \quad \sigma(x) = \sqrt{\frac{1}{12}}$$

b) Exponenciální rozdělení (t interpretujeme jako čas):

$$p(t) = \begin{cases} ke^{-kt} & \text{pro } t > 0, \\ 0 & \text{pro } t < 0 \end{cases}$$

kde k je kladná konstanta; $p(t)$ je hustota pravděpodobnosti, že atom se rozpadne v čase t

$$\int_0^\infty ke^{-kt}dt = 1, \quad \langle t \rangle = \int_0^\infty tke^{-kt}dt \stackrel{\text{per partes}}{=} \frac{1}{k} = \text{střední doba života } \tau$$

$$\text{Var}(t) = \int_0^\infty (t - \tau)^2 ke^{-kt}dt = \frac{1}{k^2} = \tau^2$$

Další trik vhodný pro výpočet integrálů: $\int_0^\infty e^{-kt} = 1/k$ derivujeme podle parametru k

Funkce náhodné veličiny

plot/mmfch5pr2.sh 4/33 mmfch5

Mějme reálnou náhodnou veličinu x s rozdělením $p(x)$ a reálnou funkci $f(x)$. Veličina (pozorovatelná) $f(x)$ má rozdělení (sčítá se přes všechny kořeny):

$$p_f(y) = \sum_{x:f(x)=y} \frac{p(x)}{|f'(x)|}$$

Příklad 1. Nechť x má rovnoměrné rozdělení v intervalu $[0, 1]$. Jaké rozdělení má $y = -\ln x$?

```
> restart;
> with(Statistics):
> rectf := t->piecewise(t<0, 0, t<1, 1, 0);
> Rect := Distribution(PDF=rectf);
> X := RandomVariable(Rect);
> Mean(X); StandardDeviation(X);
> PDF(-log(X),x);
```

$$y = f(x) \equiv -\ln x \Rightarrow x = e^{-y} \quad (1 \text{ kořen})$$

$$f'(x) = -1/x$$

$$p_f(y) = \sum_{x:f(x)=y} \frac{p(x)}{|f'(x)|}$$

$$= \frac{1}{|e^{-y}|} = |x| = e^{-y}$$

Příklad 2. Nechť x má rovnoměrné rozdělení v intervalu $[-1, 1]$. Jaké rozdělení má $y = \arcsin(x)$?

```
seq 1 1000000 | tabproc 'asin(rnd(-1))' | histogram .031416 | plot :-x:y:o '[99]:x:cos(x)/2:-' z/(.15cos=(.1/d
```

Příklad: Giniho koeficient (index)

+ 5/33 mmfch5

Míra nerovnosti příjmu. Příjem x s hustotou pravděpodobnosti $p(x)$, $x \geq 0$.


$$G = \frac{1}{2\langle x \rangle} \int_0^\infty p(x)dx \int_0^\infty p(y)dy |x-y|, \quad G \in [0, 1]$$

Jihoafrická republika: 65% ... USA ≈ Čína: 48% ... ČR: 26% ... Ukrajina: 25%

Příklad. Vypočtěte Giniho koeficient pro:

- a) Diracovu delta-distribuci (všichni berou stejně),
- b) exponenciální rozdělení příjmů.

```
> restart;
> Gini:=p->int(p(x)*int(p(y)*abs(x-y),y=0..infinity),x=0..infinity)
> /2/int(p(x)*x,x=0..infinity)
> assume(a>0);
> p:=x->Dirac(x-a);
> int(p(x),x=0..infinity);
> Gini(p);
> p:=x->exp(-x*a);
> int(p(x),x=0..infinity);
> Gini(p);
```

**Funkce náhodné veličiny: střední hodnota**

6/33 mmfch5

Střední hodnota funkce $f(x)$ vzhledem k náhodné veličině $x \in \mathbb{R}$ s distribuční funkcí $p(x)$:

$$\langle f \rangle = \int f(x)p(x)dx \quad (1)$$

nebo z nové náhodné proměnné $f = f(x)$:

$$\langle f \rangle = \int yp_f(y)dy, \quad p_f(y) = \sum_{x:f(x)=y} \frac{p(x)}{|f'(x)|} \quad (2)$$

Obě střední hodnoty jsou stejné:

$$\langle f \rangle = \int f(x)p(x)dx \stackrel{\text{subst. } y=f(x)}{=} \int \frac{yp(x)}{f'(x)}dy = \int yp_f(y)dy$$

kde v 2. integrálu $x =$ řešení rovnice $f(x) = y$, které zde pro jednoduchost uvažujeme jen jedno a také předpokládáme, že funkce f je rostoucí.

Stat-mech příklad v $3N$ -dimenzionálním prostoru: $f = P$ (tlak), $\tau = (\tau_1, \dots, \tau_N) \in \mathbb{R}^{3N}$:

$$p(\tau) = \frac{e^{-E(\tau)/k_B T}}{\int e^{-E(\tau)/k_B T} d\tau}, \quad \langle P \rangle = \int P(\tau)p(\tau)d\tau$$

Obecně a jednotně $\langle f \rangle_\mu = \int f(x)d\mu(x)$, kde μ je pravděpodobnostní míra, x je měřitelná množina.

Kovariance

7/33 mmfch5

• Kovariance $x \in \mathbb{R}$ a $y \in \mathbb{R}$ dvojrozměrného rozdělení $p(x, y)$

$$\text{Cov}(x, y) = \langle \Delta x \Delta y \rangle = \int \Delta x \Delta y p(x, y)dx dy$$

• Kovariance dvou veličin $f(x)$ a $g(x)$; obdobně u diskrétního či vícerozměrného rozdělení ($\mathbf{x} = \tau$):

$$\text{Cov}(f, g) = \langle \Delta f \Delta g \rangle = \int \Delta f \Delta g p(\tau)d\tau$$

Nezávislé náhodné veličiny

8/33 mmfch5

Náhodné veličiny \mathbf{x} (s rozdělením $p_1(x)$) a \mathbf{y} (s rozdělením $p_2(y)$):

$$p(x, y) = p_1(x)p_2(y) \quad (3)$$

V diskrétním případě (např. dva hody kostkou, $p_{ij} = 1/36$):

$$p_{ij} = p_{1,i}p_{2,j}$$

Je-li $\text{Cov}(\mathbf{x}, \mathbf{y}) = 0$ pak \mathbf{x} a \mathbf{y} jsou ne-korelované, ale nemusí být nezávislé

$$\text{Cov}(\mathbf{x}, \mathbf{y}) = \langle \Delta x \Delta y \rangle_{\mathbf{x}+\mathbf{y}} = \int dx \int dy \Delta x p_1(x) \Delta y p_2(y) = \langle \Delta x \rangle \langle \Delta y \rangle = 0$$

Korelační koeficient

plot/matnum2r.sh 1000000 8/33 mmfch5

$$r(x, y) = \frac{\text{Cov}(x, y)}{\sqrt{\text{Var}(x)\text{Var}(y)}}$$


Příklad. Nechť \mathbf{u}_1 a \mathbf{u}_2 jsou dvě nezávislá rovnoměrná rozdělení v $[0, 1]$. Vypočtěte:

- a) $r(u_1, -u_1)$
- b) $r(u_1^2, u_2^2)$
- c) $r(u_1, u_2 + u_1)$

viz mmmpc5.mw Correlation Coefficient

$\underline{z}^A/\underline{z}^B \cap \underline{z}^C \cap \underline{z}^D$

```
seq 1 1000000 | tabproc "rnd(0)" "rnd(0)" | tabproc A A+B | lr
```

**Součet náhodných proměnných**

firefox https://en.wikipedia.org/wiki/Convolution 9/33 mmfch5

Nechť (\mathbf{x}, \mathbf{y}) jsou dvě spojité náhodné proměnné s rozdělením $p(x, y)$. Rozdělení součtu $\mathbf{x} + \mathbf{y}$ je

$$p_{\mathbf{x}+\mathbf{y}}(z) = \int \int_{x+y=z, z+z+dz} p(x, y)dx dy \stackrel{Y=z-x}{=} \int p(x, z-x)dx dz$$

\Rightarrow

$$p_{\mathbf{x}+\mathbf{y}}(z) = \int p(x, z-x)dx$$

Nechť nyní $p(x, y) = p_1(x)p_2(y)$. Pak

$$p_{\mathbf{x}+\mathbf{y}}(z) = \int p_1(x)p_2(z-x)dx \equiv (p_1 * p_2)(z)$$

$p_1 * p_2$ se nazývá **konvoluce**

Diskrétní příklad

plot/matnum2conv.sh 100000 10/33 mmfch5

Hodíme dvojicí kostek. Jaké rozdělení má součet ok?

- $p_2(2) = p(\square)\rho(\square) = 1/36$
- $p_2(3) = p(\square)\rho(\square) + p(\square)\rho(\square) = 2/36$
- $p_2(4) = p(\square)\rho(\square) + p(\square)\rho(\square) + p(\square)\rho(\square) = 3/36$
- $p_2(5) = p(\square)\rho(\square) + p(\square)\rho(\square) + p(\square)\rho(\square) + p(\square)\rho(\square) = 4/36$
- $p_2(6) = p(\square)\rho(\square) + p(\square)\rho(\square) + p(\square)\rho(\square) + p(\square)\rho(\square) + p(\square)\rho(\square) = 5/36$
- $p_2(7) = p(\square)\rho(\square) + p(\square)\rho(\square) + p(\square)\rho(\square) + p(\square)\rho(\square) + p(\square)\rho(\square) + p(\square)\rho(\square) = 6/36$
- $p_2(8) = p(\square)\rho(\square) + p(\square)\rho(\square) + p(\square)\rho(\square) + p(\square)\rho(\square) + p(\square)\rho(\square) + p(\square)\rho(\square) = 5/36$
- $p_2(9) = p(\square)\rho(\square) + p(\square)\rho(\square) + p(\square)\rho(\square) + p(\square)\rho(\square) + p(\square)\rho(\square) = 4/36$
- $p_2(10) = p(\square)\rho(\square) + p(\square)\rho(\square) + p(\square)\rho(\square) + p(\square)\rho(\square) + p(\square)\rho(\square) = 3/36$
- $p_2(11) = p(\square)\rho(\square) + p(\square)\rho(\square) = 2/36$
- $p_2(12) = p(\square)\rho(\square) = 1/36$

$$\sum_{i=2}^{12} p_2(i) = 1$$

```
seq 1 100000 | tabproc "rnd(6)+rnd(6)+2" | histogr 1.5 12.5 1 | plot -
```

Spojity příklad

Jaké rozdělení má $u_1 - u_2$, jsou-li u_i nezávislá náhodná čísla v intervalu $[0, 1)$?

$$p(x) = \begin{cases} 1 & \text{pro } 0 < x < 1 \\ 0 & \text{jindy} \end{cases}$$

$$p_2(z) = \int_{-\infty}^{\infty} p(x+1)p(z-x)dx = \int_{-1}^0 p(z-x)dx = \int_0^1 p(z+x)dx$$

$$= \begin{cases} \int_0^{1-z} p(z+x)dx = \int_0^{1-z} 1dx = 1-z & \text{pro } 1 > z > 0 \\ \int_0^{1+z} p(z+x)dx = \int_0^{1+z} 1dx = 1+z & \text{pro } -1 < z < 0 \\ 0 & \text{jindy} \end{cases}$$

$$p_2(z) = \begin{cases} 1-|z| & \text{pro } |z| < 1 \\ 0 & \text{jindy} \end{cases}$$

seq 1 100000 | tabproc "rnd(0)-rnd(0)" | histogr -1.5 1.5 .1 | plot -

plot/matnum2conv2.sh 200000 11/33 mmfch5

Gaussovo rozdělení a Čebyšovova nerovnost

16/33 mmfch5

Pro náhodnou proměnnou x s normálním rozdělením platí: $\text{erfc}(x) = 1 - \text{erf}(x) = \frac{2}{\sqrt{\pi}} \int_x^{\infty} e^{-t^2} dt$

$$\text{prob}(|x - \langle x \rangle| \geq t\sigma(x)) = 2 \int_t^{\infty} \frac{e^{-t^2/2}}{\sqrt{2\pi}} dt = \text{erfc}(t/\sqrt{2})$$

např.: $\text{prob}(|x - \langle x \rangle| \geq 2\sigma(x)) = 0.0455 \approx 5\%$

Čebyšovova nerovnost: Pro obecnou náhodnou proměnnou x s konečným průměrem i variancí platí:

$$\text{prob}(|x - \langle x \rangle| \geq t\sigma(x)) \leq \frac{1}{t^2}$$

např.: $\text{prob}(|x - \langle x \rangle| \geq 2\sigma(x)) = 25\%$

prob(x - \langle x \rangle \leq t\sigma(x))	
t	normální nejhorší
1	68.27 % 0 %
2	95.45 % 75 %
3	99.73 % 88.89 %
5	99.999943 % 96 %

Důkaz. Definujme (jako v C/C++): $(x \leq 1) = \begin{cases} 1 & \text{pro } x \leq 1, \\ 0 & \text{jindy.} \end{cases}$

$$\text{prob}(|x - \langle x \rangle| \geq t\sigma(x)) = \langle |x - \langle x \rangle| \geq t\sigma(x) \rangle = \left\langle \left(\frac{x - \langle x \rangle}{\sigma(x)} \right)^2 \geq 1 \right\rangle \leq \left\langle \left(\frac{x - \langle x \rangle}{\sigma(x)} \right)^2 \right\rangle = \frac{1}{t^2}$$

rovnost pro: $X = \begin{cases} -1, & p = \frac{1}{2t^2} \\ 0, & p = 1 - \frac{1}{t^2} \\ +1, & p = \frac{1}{2t^2} \end{cases}$

Součet nezávislých náhodných proměnných

12/33 mmfch5

Střední hodnota i variance součtu nezávislých náhodných veličin jsou aditivní. Přímo z (3):

$$\begin{aligned} \langle x + y \rangle &= \int p_1(x)p_2(y)(x+y)dxdy \\ &= \int p_1(x)p_2(y)xdxdy + \int p_1(x)p_2(y)ydx dy = \int p_1(x)xdx + \int p_2(y)dy = \langle x \rangle + \langle y \rangle \end{aligned}$$

Pomocí konvoluce distribučí:

$$\begin{aligned} \langle x + y \rangle &= \int zp_{x+y}(z)dz = \int zp_1(x)p_2(z-x)dxdz \\ y := z-x &\quad \int (x+y)p_1(x)p_2(y)dxdy = \langle x \rangle_1 + \langle y \rangle_2 = \langle x \rangle + \langle y \rangle \end{aligned}$$

A variance:

$$\text{Var}(x+y) = \langle (\Delta x + \Delta y)^2 \rangle_{x+y} = \langle (\Delta x)^2 \rangle_{x+y} + 2\langle \Delta x \Delta y \rangle_{x+y} + \langle (\Delta y)^2 \rangle_{x+y} = \text{Var}(x) + \text{Var}(y)$$

Centrální limitní věta I

show/convol.sh 200000 13/33 mmfch5

Součet n stejných nezávislých rozdělení s konečnou střední hodnotou a konečnou variancí je pro velké n rovno Gaussovo rozdělení (normálnímu rozdělení) se střední hodnotou $n\langle x \rangle$ a variancí $n\text{Var}x$.

Distribuční funkce normálního rozdělení se střední hodnotou μ a směrodatnou odchylkou σ :

$$p(x) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(x-\mu)^2}{2\sigma^2}\right)$$

Račte si ověřit, že:

$$\begin{aligned} \int p(x)dx &= 1 \\ \langle x \rangle &= \int xp(x)dx = \mu \\ \text{Var}x &= \int (x-\mu)^2 p(x)dx = \sigma^2 \end{aligned}$$

Centrální limitní věta II

show/galton.sh 14/33 mmfch5

Součet n stejných nezávislých rozdělení s konečnou střední hodnotou a konečnou variancí je pro velké n rovno Gaussovo rozdělení se střední hodnotou $n\langle x \rangle$ a variancí $n\text{Var}x$.

Příklad. Uvažujme diskrétní rozdělení b : $p(-1/2) = p(1/2) = 1/2$. Aproximujte součet n takových rozdělení.

$$\begin{array}{ll} n=1 & p(-1/2)=1/2, p(1/2)=1/2, \text{Var}b=1/4 \\ n=2 & p(-1)=1/4, p(0)=1/2, p(1)=1/4, \text{Var}b^2=2/4 \\ n=3 & p(\pm 3/2)=1/8, p(\pm 1/2)=3/8, \text{Var}b^3=3/4 \end{array}$$

$\tau = 0$

$\tau = \Delta\tau$

$\tau = 2\Delta\tau$

$\tau = 3\Delta\tau$

$2\Delta x$

Pro jednoduchost uvažujme jen sudé n . Pak pro $k = -n/2 \dots n/2$:

$$p(k) = \binom{n}{n/2+k} 2^{-n} \approx \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{k^2}{2\sigma^2}\right), \quad \sigma^2 = \text{Var}(b^n) = \frac{n}{4}$$

Důkaz: potřebujeme Stirlingův vzorec ve tvaru $n! \approx n^n e^{-n} \sqrt{2\pi n}$, nebo viz další stránka

Distribuční funkce normálního rozdělení se střední hodnotou μ a směrodatnou odchylkou σ :

$$p(x) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(x-\mu)^2}{2\sigma^2}\right)$$

Ověření centrální limitní věty z binomického rozdělení

+ 15/33 mmfch5

$$\binom{n}{\frac{n}{2}+1} = \frac{n!}{(\frac{n}{2}-1)!(\frac{n}{2}+1)!} = \frac{n!}{(\frac{n}{2})!(\frac{n}{2}) \cdot (\frac{n}{2})!(\frac{n}{2}+1)} = \binom{n}{\frac{n}{2}} \times \frac{\frac{n}{2}}{\frac{n}{2}+1}$$

$$\ln p(\frac{n}{2}, 1) = \ln p(\frac{n}{2}, 0) + \ln \frac{\frac{n}{2}}{\frac{n}{2}+1} \approx \ln p(\frac{n}{2}, 0) - \frac{2}{n}$$

Další člen

$$\ln p(\frac{n}{2}, 2) = \ln p(\frac{n}{2}, 1) + \ln \frac{\frac{n}{2}-1}{\frac{n}{2}+2} \approx \ln p(\frac{n}{2}, 1) - \frac{6}{n}$$

a obecně

$$\ln p(n, k) \approx \ln p(n, 0) - 2 \sum_{j=1}^k \frac{2k-1}{n}, \quad \sum_{j=1}^k (2k-1) \approx \int_0^k (2k-1)dk = k(k-1) \approx k^2$$

Obdobně pro záporná k . V limitě velkých k a n tedy


$$p(n, k) \approx p(n, 0) \exp\left(-\frac{k^2}{n/2}\right)$$

Po normalizaci dostaneme kážené

Gaussovo rozdělení a Čebyšovova nerovnost

16/33 mmfch5

Pro náhodnou proměnnou x s normálním rozdělením platí: $\text{erfc}(x) = 1 - \text{erf}(x) = \frac{2}{\sqrt{\pi}} \int_x^{\infty} e^{-t^2} dt$



$$\text{prob}(|x - \langle x \rangle| \geq t\sigma(x)) = 2 \int_t^{\infty} \frac{e^{-t^2/2}}{\sqrt{2\pi}} dt = \text{erfc}(t/\sqrt{2})$$

např.: $\text{prob}(|x - \langle x \rangle| \geq 2\sigma(x)) = 0.0455 \approx 5\%$

Čebyšovova nerovnost: Pro obecnou náhodnou proměnnou x s konečným průměrem i variancí platí:

$$\text{prob}(|x - \langle x \rangle| \geq t\sigma(x)) \leq \frac{1}{t^2}$$

např.: $\text{prob}(|x - \langle x \rangle| \geq 2\sigma(x)) = 25\%$

Důkaz. Definujme (jako v C/C++): $(x \leq 1) = \begin{cases} 1 & \text{pro } x \leq 1, \\ 0 & \text{jindy.} \end{cases}$

$$\text{prob}(|x - \langle x \rangle| \geq t\sigma(x)) = \langle |x - \langle x \rangle| \geq t\sigma(x) \rangle = \left\langle \left(\frac{x - \langle x \rangle}{\sigma(x)} \right)^2 \geq 1 \right\rangle \leq \left\langle \left(\frac{x - \langle x \rangle}{\sigma(x)} \right)^2 \right\rangle = \frac{1}{t^2}$$

rovnost pro: $X = \begin{cases} -1, & p = \frac{1}{2t^2} \\ 0, & p = 1 - \frac{1}{t^2} \\ +1, & p = \frac{1}{2t^2} \end{cases}$

Názvosloví kolísá podle obooru...

Statistika, statistic, estimator, odhad, „statistický algoritmus“, (úzeji) „statistický funkcionál, v metrologii „měřicí funkce“, measurement function, je vzorec/algorithmus, podle kterého počítáme výsledek z vzorku náhodných veličin (v metrologii z dat). Statistika je také náhodnou veličinou.

Další dělení: bodový odhad (point estimation): výsledkem je číslo, intervalový odhad: výsledkem je interval, kde s jistotou pravděpodobnosti leží výsledek.

Příklady: aritmetický průměr, parametry modelu při fitování metodou nejmenších čtverců.

Standardní chyba bodové statistiky = směrodatná (standardní) odchylka (odmocnina variance) rozdělení (rozdělovač funkce) této statistiky.

Nejistota (uncertainty) v metrologii zahrnuje kritické posouzení systematických, náhodných, diskretačních aj. chyb. Obdobně „standardní nejistota“.

Angličtina rozlišuje:

estimation (whole process), statistic = estimator (formula, algorithm), estimate (final number)

statistics = field of mathematics


Aritmetický průměr jako příklad statistiky

18/33 mmfch5

Mějme **vzorek** (výběr, sample) náhodné veličiny

Příklady:

- velikost bohat 1000 lidí
- 100x hodíme kostkou
- tlak v průběhu simulace



Aritmetický průměr (vzorku, výběru), výběrový průměr, sample mean

$$\bar{x}_n = \frac{1}{n} \sum_{i=1}^n x_i$$

pro jednoduchość píše \bar{x} místo \bar{x}_n

$$\langle \bar{x}_n \rangle = \langle \bar{x} \rangle$$

$$\sigma(x) \equiv \sqrt{\text{Var}x}$$

Spočtěme varianci veličiny \bar{x}_n :

$$\text{Var}(\bar{x}_n) = \langle (\bar{x}_n - \langle \bar{x} \rangle)^2 \rangle = \left\langle \left(\frac{1}{n} \sum_{i=1}^n \Delta x_i \right)^2 \right\rangle = \frac{1}{n^2} (n \text{Var}x) = \frac{\text{Var}x}{n} \equiv \frac{\sigma(x)^2}{n}$$

kde jsme předpokládali, že x_i jsou nezávislé, $\langle \Delta x_i \Delta x_j \rangle = 0$ pro $i \neq j$.

Směrodatná (standardní) odchylka jako příklad statistiky

19/33 mmfch5

Jak odhadnout rozptyl $\text{Var}x = \sigma(x)^2$? Neznáme střední hodnotu $\langle x \rangle$, ale jen její odhad, \bar{x}_n .

$$\begin{aligned} \sigma^2(x) &= \langle (x - \langle x \rangle)^2 \rangle \approx \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x}_n)^2 = \frac{1}{n} \sum_{i=1}^n \left(x_i - \frac{1}{n} \sum_{j=1}^n x_j \right)^2 \\ &= \frac{1}{n} \left[\left(1 - \frac{1}{n} \right) x_1 - \frac{1}{n} x_2 - \frac{1}{n} x_3 - \dots \right]^2 + \frac{\text{další členy}}{n-1} \\ &\quad \left\langle \left(\frac{1}{n} \Delta x_1 - \frac{1}{n} \Delta x_2 - \dots \right)^2 \right\rangle = \left[\left(1 - \frac{1}{n} \right)^2 + (n-1) \frac{1}{n^2} \right] \sigma(x)^2 = \frac{n-1}{n} \sigma(x)^2 \\ &\quad \left\langle \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x}_n)^2 \right\rangle = \sigma(x)^2 \end{aligned}$$

Vzorec v $\langle \cdot \rangle$ je nestraný odhad variance $\sigma(x)^2$

$$\text{Nestraný odhad } \sigma(\bar{x}_n)^2 \text{ dostaneme vydělením } n: \sigma(\bar{x}_n) \approx s_n(\bar{x}_n) = \sqrt{\frac{1}{n(n-1)} \sum_{i=1}^n (x_i - \bar{x}_n)^2}$$

Směrodatná (standardní) odchylka jako příklad statistiky

Výběrový rozptyl (corrected sample variance): **Výběrový rozptyl aritmetického průměru:**

$$\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x}_n)^2$$

kde 1 = počet stupňů volnosti. Protože platí

$$\left\langle \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x}_n)^2 \right\rangle = \sigma^2(x) = \text{Var}x$$

jeho odmocnina je vychýleným odhadem standardní chyby aritmetického průměru

"Korekci" -1 zavedl Friedrich Wilhelm Bessel, bez korekce máme (uncorrected) sample variance, český termín neznám.

Ale odmocnina výběrového rozptylu (výběrová směrodatná odchylka) je vychýlený odhad $\sigma(x)$.

Poznámky k výpočtu:

$$\langle (x - \langle x \rangle)^2 \rangle = \langle x^2 \rangle - \langle x \rangle^2$$

$$\frac{1}{n} \sum_{i=1}^n \left(x_i - \frac{1}{n} \sum_{j=1}^n x_j \right)^2 = \frac{1}{n} \sum_{i=1}^n x_i^2 - \left(\frac{1}{n} \sum_{i=1}^n x_i \right)^2 \quad \text{nevýhodné, pokud } \sigma(x) \ll x_i$$

Souhrn

21/33
mmfch5

Pro zpracování nekorelovaných dat metodou aritmetického průměru, se stejnými vahami dat:

Směrodatná (standardní) odchylna náhodné proměnné x = standardní chyba jednoho měření

$$\sigma(x) = \sqrt{(x - \bar{x})^2}$$

je approximována vzorcem

$$s_n(x) = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x}_n)^2}$$

Směrodatná (standardní) chyba aritmetického průměru z n nezávislých měření náhodné proměnné \bar{x} = standardní chyba (nejistota), se kterou \bar{x}_n approximuje (x) , je

$$\sigma(\bar{x}_n) = \frac{\sigma(x)}{\sqrt{n}}$$

a my ji počítáme (= approximujeme) vzorcem

$$s_n(\bar{x}_n) = \sqrt{\frac{1}{n(n-1)} \sum_{i=1}^n (x_i - \bar{x}_n)^2}$$

Zvyky a zložky

22/33
mmfch5

Jak udávají nejistotu měřených hodnot různé obory:

Fyzika: $Q = 123.4 \pm 0.5 \equiv 123.4(5) \equiv 123.45$

kde $0.5 = \sigma(Q)$ = odhadnutá směrodatná/standardní chyba/nejistota statistiky Q (např. $Q = \bar{x}$) počítané z výběru (sample), také standardní/směrodatná odchylna (rozumí se aritmetickému průměru či jiné statistice) nepřesně jen: (odhadnutá) chyba/nejistota, standardní/směrodatná odchylna

V případě normálního rozdělení s pravděpodobností 68% platí $(Q) \in 123.4 \pm 0.5$

Biologie, ekonomie, inženýrství, politologie, farmakologie: $Q = 123.4 \pm 1.0$

$$\pm 1.0 = \pm 2\sigma(Q) = \text{interval spolehlivosti (confidence interval) na hladině (spolehlivosti) 95 \% nepřesně jen: } \pm 1.0 = \text{interval spolehlivosti, } 1.0 = \text{chyba/nejistota, ...}$$

V případě normálního rozdělení s pravděpodobností 95 % platí $(Q) \in 123.4 \pm 1.0$

Chemie: často ignorováno; pokud udáno, tak nikdo neví, jaká je hladina spolehlivosti

„Fyzikální jistota“ začíná na $\pm 5\sigma(Q)$ (hladina spolehlivosti 0.999 999 43)

Vždy nutno udat typ chyby/nejistoty resp. hladinu spolehlivosti

α = hladina významnosti (significance level), často 5 %


$1 - \alpha$ = hladina spolehlivosti (confidence level), často 95 %

Příklad

23/33
mmfch5

Volební model podle agentury CVM

Listopad 2018



V průzkumu volebních preferencí bylo dotázáno 1080 lidí. Ve výsledcích jsou udány intervaly spolehlivosti, neznáme však použitou hladinu spolehlivosti (tj. s jakou pravděpodobností je skutečná hodnota uvnitř intervalu). Odvodte tuto hladinu z dat.

Rada: Vypočtěte nejprve varianci náhodné proměnné x , která je 1 s pravděpodobností p a 0 s pravděpodobností $1 - p$.

$$\% 56 : (d - \bar{x})^2$$

Rešení příkladu

24/33
mmfch5

$$x = \begin{cases} 1 & \text{s pravděpodobností } p \\ 0 & \text{s pravděpodobností } 1 - p \end{cases}$$

$$(x) = 1 \cdot p + 0 \cdot (1 - p) = p$$

$$\text{Var } x = ((x - p)^2) = (1 - p)^2 \cdot p + (0 - p)^2 \cdot (1 - p) = p(1 - p)$$

Předpokládáme platnost centrální limitní věty. Měřená veličina je

$$P_{\text{partaj}} = \frac{1}{N} \sum_{i=1}^N x \quad (N = 1080)$$

$$\sigma^2 = \text{Var } P_{\text{partaj}} = \frac{\text{Var } x}{N} = \frac{p(1-p)}{N}$$

$$\rho_{\text{ANO}} = 0.295, \sigma_{\text{ANO}} = \sqrt{\frac{p(1-p)}{N}} = 0.0139$$

$$\text{interval spolehlivosti: } \pm \frac{0.324 - 0.268}{2} = 0.028 = t\sigma, \quad t = 2.02$$

$$\text{erf}(t/\sqrt{2}) = 0.956 \approx 95\%$$

Testování hypotéz

25/33
mmfch5

Nulová hypotéza, H_0 : Hypotéza, že vlastnost (určitá hodnota veličiny [statistiky], rozdíl. aj.) odvozená ze vzorku dat je vysvětlitelná chybou vzorkování nebo experimentálními chybami a odchylka není signifikantní: „není efekt“, „není rozdíl“, „zádná změna“, „lék je neúčinný“.

Alternativní hypotéza, H_1 : Hypotéza, že naměřená odchylna od nulové hypotézy je signifikantní: „efekt existuje“, „lék je účinný“. Abychom ji přijali, potřebujeme dostatečně silný důvod (evidence), což se vyjadřuje:

• hladinu spolehlivosti (confidence level) $1 - \alpha$: alternativní hypotéza platí s pravděpodobností větší než $1 - \alpha$; často $1 - \alpha = 95\%$

• hladinu významnosti (significance level) α ; často $\alpha = 5\%$

Výsledky testu:

• Zamítlíme (reject) H_0 : máme dost silné důvody pro H_1 . „Lék je účinný.“ Můžeme se mylit s pravděpodobností menší než α : **chyba I. druhu**, falešně pozitivní (přijetí alternativní hypotézy, false positive).

• Nezamítlíme (fail to reject) H_0 : nemáme dost silné argumenty pro přijetí H_1 . „Nemáme dost silné důvody k tvrzení, že lék je účinný“, „lék je asi nedostatečně účinný“. Můžeme se mylit (**chyba II. druhu**), falešně negativní (přijetí alternativní hypotézy, false negative).

Příklad 1 – oboustranný odhad

26/33
mmfch5

Příklad: Studentky si měří tep (PR, pulse rate). Ze $n = 100$ měření jsme dostali: $\bar{P}R_n = 73.6(9) \text{ min}^{-1}$; tj. $s_n(\bar{P}R_n) = 0.9$.

a) Souhlasí tento údaj s literaturou, která udává průměrnou hodnotu 72 pro ženy tohoto věku?


• Nulová hypotéza: $(PR) = 72$

• Alternativní hypotéza: $(PR) \neq 72$

Pro $n = 100$ můžeme předpokládat, že rozdělení $\bar{P}R_n$ je normální a $s_n(\bar{P}R_n)$ je dostatečně přesné (centrální limitní věta)

$$t = \frac{\bar{P}R_n - (PR)_{\text{null}}}{s_n(\bar{P}R_n)} = \frac{73.6 - 72}{0.9} = 1.78 \quad ("1.78\sigma")$$

$$p = 2 \int_{|t|>t} \frac{e^{-x^2/2}}{\sqrt{2\pi}} dx = \text{erfc}(k/\sqrt{2}) = 0.075 > \alpha = 0.05$$



Na hladině významnosti 5 % nemůžeme zamítout nulovou hypotézu. To, že se měření odchyluje od 72, může být náhoda. Pokud se mylíme, je to chyba II. druhu.

Viz [mmpc5.mw Normal distribution example](#)

Příklad 2 – jednostranný odhad

27/33
mmfch5

Příklad: Studenti si měří tep (PR, pulse rate). Ze $n = 100$ měření jsme dostali: $\bar{P}R_n = 73.6(9)$; tj. $s_n(\bar{P}R_n) = 0.9$.

b) Jsou studenti nervozní? (Platí $PR > 72$, kde 72 je střední hodnota je udávaná hodnota pro muže tohoto věku?)


• Nulová hypotéza: $(PR) \leq 72$

• Alternativní hypotéza: $(PR) > 72$

Pro $n = 100$ můžeme předpokládat, že rozdělení $\bar{P}R_n$ je normální a $s_n(\bar{P}R_n)$ je dostatečně přesné (centrální limitní věta)

$$t = \frac{\bar{P}R_n - (PR)_{\text{null}}}{s_n(\bar{P}R_n)} = \frac{73.6 - 72}{0.9} = 1.78$$

$$p = \int_t^\infty \frac{e^{-x^2/2}}{\sqrt{2\pi}} dx = \frac{\text{erfc}(k/\sqrt{2})}{2} = 0.038 < \alpha = 0.05$$



Na hladině významnosti 5 % nulovou hypotézu zamítne. Studenti jsou nervozní. Pokud se mylíme, je to chyba I. druhu. Ale spíš (na 96 %) se nemylíme.

Studentovo t-rozdělení

28/33
mmfch5

Ukázali jsme, že náhodná proměnná \bar{x}_n má Gaussovo rozdělení se střední hodnotou $(\bar{x}_n) = (x)$ a směrodatnou odchylkou $\sigma(\bar{x}_n) = \sqrt{\text{Var } x/n}$. Ale známe jen jejich odhady, takže nemůžeme tvrdit, že \bar{x}_n je v mezech \pm odhadnutého $\sigma(\bar{x}_n)$ s pravděpodobností 68 %.

Definujeme Studentovo rozdělení t s parametrem v (počet stupňů volnosti) jako rozdělení následující náhodné proměnné:

$$\frac{\bar{x}_{v+1} - (x)}{\sigma(\bar{x}_{v+1})}$$

$$\Gamma(x) = \int_0^\infty x^{n+1} e^{-x} dx, \quad \Gamma(n) = (n-1)!, \quad \Gamma(n+\frac{1}{2}) = \sqrt{\pi} \cdot \frac{3}{2} \cdot \frac{5}{2} \cdots \left(n-\frac{1}{2}\right)$$

Distribuční funkce je

$$t_v(x) = \frac{\Gamma(\frac{v+1}{2})}{\sqrt{v\pi} \Gamma(\frac{v}{2})} \left(1 + \frac{x^2}{v}\right)^{-\frac{v+1}{2}}$$

Limita pro velké vzorky je normalizované normální rozdělení

$$\lim_{v \rightarrow \infty} t_v(x) = \frac{1}{\sqrt{2\pi}} e^{-x^2/2}$$

Bacha, $t_1(x)$ má nekonečný rozptyl a (striktně) nefelovánou střední hodnotu.

Opet tep

29/33
mmfch5

Osm důchodců před odběrem vzorku ze sliznice nosohltanu mělo následující hodnoty tepu:

$$[91, 83, 67, 79, 86, 87, 72, 75]$$

Průměrný tep v tomto věku je 75. Jsou důchodci nervozní?

$$\bar{P}R_n = 80, s_n(\bar{P}R_n) = 2.91, PR = 80.0(29)$$

• Nulová hypotéza: $(PR) \leq 75$

• Alternativní hypotéza: $(PR) > 75$

$$t = \frac{\bar{P}R_n - (PR)_{\text{null}}}{s_n(\bar{P}R_n)} = \frac{80 - 75}{2.91} = 1.719, \quad p = \int_t^\infty t_{n-1}(x) dx = 0.065 > 0.05$$

Závěr: Nemáme dostatečný důvod k tvrzení, že důchodci jsou nervozní

Pozn.: v případě (nesprávného) použití normálního rozdělení místo Studentova bychom dostali $p = 0.043 < 0.05$ a tvrdili bychom neoprávněně, že důchodci jsou nervozní. Tento rozdíl mezi normálním a Studentovým výsledkem by se zvětšoval pro hladiny spolehlivosti velmi blízko 1.

Porovnání dvou výběrů – stejně variance

30/33
mmfch5

Máme dvě sady měření takové, že můžeme předpokládat, že očekávané rozptyly v obou sadách jsou stejné (alespoň přibližně).

Porovnáváme 2 výběry (n a m dat) ze stejného souboru.

Tvrzení. Náhodná veličina

$$\frac{\bar{x}_n - \bar{y}_m}{s_n \sqrt{1/n + 1/m}}, \quad \text{kde } s^2 = \frac{(n-1)[s_n(x)]^2 + (m-1)[s_m(y)]^2}{n+m-2}$$

má Studentovo rozdělení s $v = n + m - 2$.

• s_n je výběrová směrodatná odchylna (tj. s Besselovou korekcí)

Nulová hypotéza (oboustranný test two-tailed): $(x) = (y)$

Nulová hypotéza (jednostranný test one-tailed): $(x) > (y)$

Applety např.:

• <https://stattrek.com/online-calculator/t-distribution.aspx>

• <http://www.statskingdom.com/t-student.html>

• <https://planetcalc.com/5019/>

Excel, LibreOffice: T.TEST(array1, array2, tails, type) vrací p

tails={1=one tail, 2=two tails}

type={1=paired, 2=two samples, equal variances, 3=two samples, unequal variances}

Porovnání dvou výběrů – různé variance

31/33
mmfch5

(Welschův t-test) Porovnáváme 2 výběry (n a m dat) z různého souboru, takže nemůžeme předpokládat rovnost variancí

Tvrzení: Náhodná veličina

$$t = \frac{\bar{x}_n - \bar{x}_m}{s_{\Delta}}, \text{ kde } s_{\Delta}^2 = \frac{[s_n(x)]^2}{n} + \frac{[s_m(x)]^2}{m}$$

má **přibližně** Studentovo rozdělení s počtem stupňů volnosti

$$\nu = \frac{\left(\frac{[s_n(x)]^2}{n} + \frac{[s_m(x)]^2}{m} \right)^2}{\frac{[s_n(x)]^4}{n^2(n-1)} + \frac{[s_m(x)]^4}{m^2(m-1)}}$$

Nulová hypotéza: Rovnají se střední hodnoty?

Nepoužívat F-test (zda variance dvou výběrů jsou stejné) k rozhodnutí, zda aplikovat Studentův nebo Welschův test!

Pilulka na COVID-19 umutuje virus k smrti

pluma /home/jiri/macsimus/c/mc/binbin.c 33/33
mmfch5

Podle J. Pazdery (OSEL): Molnupiravir snížil riziko hospitalizace nebo úmrtí přibližně o 50 %; 7,3 % pacientů, kteří dostávali molnupiravir, bylo bud' hospitalizováno, nebo zemřelo do 29. dne po randomizaci (28/385), ve srovnání se 14,1 % pacientů léčených placebem (53/377); $p = 0,0012$. Ověřte hodnotu p .

Problémy:

• Data jsou diskrétní [0,1,0,0,1,...], kde 0 = pacient se uzdravil, 1 = pacient hospitalizován/zemřel, zatímco standardní t-test je odvozen v \mathbb{R} .

• Variance nejsou stejné, ale je mezi nimi vztah.

p	metoda
0.0011723	Studentův test pro diskrétní data, stejné variance
0.0012116	Studentův test pro diskrétní data, různé variance
0.0011521	Obě σ vypočteny z binomického rozdělení, pak použijeme normální rozdělení
0.0011920	Obě σ vypočteny z binomického rozdělení, pak Studentovo rozdělení (nejlepší ze snadno dostupných metod – jediná approximace je „data jsou diskrétní“)
0.0011878(8)	„Přesně“ (MC simulace, viz binbin.c)

Příklad (viz mmmpc5.mw)

32/33
mmfch5

Firma vyrábí podpěry pro příliš dlouhé jezevčíky. Zadala dvěma agenturám měření spodní výšky jezevčíka.

Firma SmileyDog: $x/\text{cm} = [12.1, 20, 15.1, 20.8, 19.7]$

Firma HappyDog: $y/\text{cm} = [18.9, 10.1, 12.1, 9.2, 12.4, 16.7, 12.7]$

- a) Jsou oba výsledky v souladu (na hladině spolehlivosti 95%)?
- b) Jaký je nejlepší odhad výšky podpěry?



b) 15,0(12) cm

(dlouho odmitnout totto tvrzem neni dost pesadny)

$t = 2,08, p = 0,064 \leftrightarrow$ obé sady měřen až souhlasí

a) Předpokládáme stejnou rozdíly: