

Téma 7.: Aplikace Moivreovy - Laplaceovy věty. Základní pojmy matematické statistiky.

Moivreova - Laplaceova věta tvrdí, že za určitých podmínek lze binomické rozložení aproximovat standardizovaným normálním rozložením. Aproximace se považuje za

vyhovující, když jsou splněny podmínky: $\frac{1}{n+1} < p < \frac{n}{n+1}$ a $n p > 9$ a $n(1-p) > 9$.

Na základě Moivreovy - Laplaceovy věty se používá aproximační vzorec, který složitý výpočet distribuční funkce binomického rozložení nahrazuje jednoduchým hledáním v tabulkách hodnot distribuční funkce standardizovaného normálního rozložení.

Máme náhodnou veličinu $Y_n \sim \text{Bi}(n, p)$. Pak

pravděpodobnostní funkce $P(Y_n = y) = \binom{n}{y} p^y (1-p)^{n-y}$ pro $y = 0, 1, \dots, n$,

distribuční funkce $P(Y_n \leq y) = \sum_{t=0}^y P(Y_n = t) = \sum_{t=0}^y \binom{n}{t} p^t (1-p)^{n-t}$ - složitý výpočet

Aproximační vzorec: $P(Y_n \leq y) \approx \Phi\left(\frac{y - np}{\sqrt{np(1-p)}}\right)$.

Příklad 1.: Pravděpodobnost úspěchu při jednom pokusu je 0,3. S jakou pravděpodobností lze tvrdit, že počet úspěchů ve 100 pokusech bude v mezích od 20 do 40?

Řešení:

Y_{100} - počet úspěchů v posloupnosti $n = 100$ opakovaných nezávislých pokusů, pravděpodobnost úspěchu $p = 0,3$, $Y_{100} \sim \text{Bi}(100, 0,3)$, $E(Y_{100}) = np = 30$, $D(Y_{100}) = np(1-p) = 21$. Vidíme, že podmínky dobré aproximace jsou splněny, protože

$$\frac{1}{101} < 0,3 < \frac{100}{101} \text{ a } np = 30 > 9 \text{ a } n(1-p) = 70 > 9.$$

Aproximační výpočet:

$$\begin{aligned} P(20 \leq Y_{100} \leq 40) &= P(19 < Y_{100} < 41) \approx \left\{ \frac{19 - 30}{\sqrt{21}} < \frac{Y_{100} - 30}{\sqrt{21}} \leq \frac{40 - 30}{\sqrt{21}} \right\} \approx \\ &\approx \Phi\left(\frac{10}{\sqrt{21}}\right) - \Phi\left(-\frac{11}{\sqrt{21}}\right) = \Phi(1,88) - \Phi(-2,40) = \Phi(1,88) + \Phi(2,40) = \\ &= 0,98537 + 0,99180 = 0,97717 \end{aligned}$$

Postup ve STATISTICE:

Otevřeme nový datový soubor o jedné proměnné a jednom případě. Do dlouhého jména této proměnné napíšeme =INormal(10/sqrt(21);0;1)- INormal(-11/sqrt(21);0;1) OK. (Funkce INormal(x;mu;sigma) poskytuje hodnotu distribuční funkce v bodě x normálního rozložení se střední hodnotou mu a směrodatnou odchylkou sigma.) Dostaneme výsledek 0,977263.

Přesný výpočet:

$$P(20 \leq Y_{100} \leq 40) = \sum_{t=20}^{40} \binom{100}{t} 0,3^t (0,7)^{100-t} = 0,978614$$

Postup ve STATISTICE:

Otevřeme nový datový soubor o jedné proměnné a jednom případě. Do Dlouhého jména této proměnné napíšeme =IBinom(40;0,3;100)- IBinom(19;0,3;100) – viz Téma 4, 1a) 4. položka. (Funkce IBinom(x;p;n) poskytuje hodnotu distribuční funkce v bodě x binomického rozložení s parametry p a n.)

Příklad 2.: Pravděpodobnost, že zakoupený elektrospotřebič bude vyžadovat opravu během záruční doby, je rovna 0,2. Jaká je pravděpodobnost, že během záruční doby bude nutno ze 400 prodaných spotřebičů opravit více než 96?

Řešení:

$n = 400$, $\vartheta = 0,2$, úspěch je nutnost opravy v záruční době

$$n\vartheta = 80, \quad n\vartheta(1-\vartheta) = 64$$

aproximativní výpočet: $P(Y_{400} > 96) \approx 1 - \text{INormal}(16/8;0;1) = 0,022750$

přesný výpočet: $P(Y_{400} > 96) = 1 - \text{IBinom}(96;0,2;400) = 0,021389$

Příklad 3.: Pravděpodobnost narození chlapce je 0,515. Jaká je pravděpodobnost, že mezi 10 000 novorozenci bude

a) stejně nebo více děvčat než chlapců

b) chlapců od 5000 do 5300?

Řešení:

$n = 10000$, $\vartheta = 0,515$, úspěch je narození chlapce

$$n\vartheta = 5150, \quad n\vartheta(1-\vartheta) = 2497,75$$

Úkol (a)

aproximativní výpočet: $P(Y_{10000} \leq 5000) \approx \text{INormal}(-150/\sqrt{2497,75};0;1) = 0,001344$

přesný výpočet: $P(Y_{10000} \leq 5000) = \text{IBinom}(5000;0,515;10000) = 0,001391$

Úkol (b)

aproximativní výpočet: $P(4999 < Y_{10000} \leq 5300) \approx \text{INormal}(150/\sqrt{2497,75};0;1) - \text{INormal}(-151/\sqrt{2497,75};0;1) = 0,997399$

přesný výpočet: $P(4999 < Y_{10000} \leq 5300) = \text{IBinom}(5300;0,515;10000) - \text{IBinom}(4999;0,515;10000) = 0,997400$

Příklad 4.: Pravděpodobnost, že určitý typ výrobku má výrobní vadu, je 0,05. Jaká je pravděpodobnost, že ze série 1000 výrobků bude mít výrobní vadu nejvýše 70?

Řešení:

$n = 1000$, $\vartheta = 0,05$, úspěch je zhotovení vadného výrobku

$$n\vartheta = 50, \quad n\vartheta(1-\vartheta) = 47,5$$

aproximativní výpočet: $P(Y_{1000} \leq 70) \approx \text{INormal}(20/\sqrt{47,5};0;1) = 0,998145$

přesný výpočet: $P(Y_{1000} \leq 70) = \text{IBinom}(70;0,05;1000) = 0,997670$

Vlastnosti důležitých statistik odvozených z jednorozměrného náhodného výběru:

Nechť X_1, \dots, X_n je náhodný výběr z rozložení se střední hodnotou μ , rozptylem σ^2 a distribuční funkcí $\Phi(x)$. Nechť $n \geq 2$. Označme

$$M = \frac{1}{n} \sum_{i=1}^n X_i \quad \text{výběrový průměr,}$$

$$S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - M)^2 \quad \text{výběrový rozptyl,}$$

pro libovolné, ale pevně dané $x \in \mathcal{L}$ označme

$$F_n(x) = \frac{1}{n} \text{ počet těch veličin } X_1, \dots, X_n, \text{ které jsou } \leq x$$

hodnotu výběrové distribuční funkce.

Pak pro libovolné hodnoty parametrů μ , σ^2 a libovolné, ale pevně dané reálné číslo x platí:

$$E(M) = \mu,$$

$$E(S_n^2) = \sigma^2,$$

$$E(F_n(x)) = \Phi(x),$$

Znamená to, že M je nestranným odhadem μ , S^2 je nestranným odhadem σ^2 , pro libovolné, ale pevně dané $x \in \mathcal{L}$ je výběrová distribuční funkce $F_n(x)$ nestranným odhadem $\Phi(x)$.

Příklad 5.: Ve 12 náhodně vybraných prodejnách ve městě byly zjištěny následující ceny určitého výrobku (v Kč): 102, 99, 106, 103, 96, 98, 100, 105, 103, 98, 104, 107. Těchto 12 hodnot považujeme za realizace náhodného výběru X_1, \dots, X_{12} z rozložení, které má střední hodnotu μ a rozptyl σ^2 . Určete nestranné bodové odhady neznámé střední hodnoty μ a neznámého rozptylu σ^2 .

Řešení:

Vypočteme realizaci výběrového průměru

$$m = \frac{1}{12} (102 + 99 + \dots + 107) = 101,75 \text{ Kč}$$

Vypočteme realizaci výběrového rozptylu:

$$s^2 = \frac{1}{11} [(102 - 101,75)^2 + (99 - 101,75)^2 + \dots + (107 - 101,75)^2] = 2,39 \text{ Kč}^2$$

Výpočet pomocí systému STATISTICA:

Otevřeme nový datový soubor o jedné proměnné (nazveme ji X) a 12 případech. Do proměnné X napíšeme zjištěné ceny.

Statistika – Základní statistiky/tabulky – Popisné statistiky – OK – Proměnné X – OK – Detailní výsledky – vybereme Průměr a Rozptyl – Výpočet. Dostaneme tabulku:

Popisné statistiky (Tabulka15)		
Proměnná	Průměr	Rozptyl
X	101,7500	12,38636

Vlastnosti důležitých statistik odvozených z dvourozměrného náhodného výběru:

Nechť $(X_1, Y_1), \dots, (X_n, Y_n)$ je náhodný výběr z dvourozměrného rozložení s kovariancí σ_{12} a

koeficientem korelace ρ . Označme $S_{12} = \frac{1}{n-1} \sum_{i=1}^n (X_i - M_1)(Y_i - M_2)$ výběrovou kovariancí a

$R_{12} = \frac{S_{12}}{S_1 S_2}$ výběrový koeficient korelace. Pak pro libovolné hodnoty parametrů σ_{12} a ρ platí:

$$E(S_{12}) = \sigma_{12},$$

$$E(R_{12}) \approx \rho \text{ (shoda je vyhovující pro } n \geq 30).$$

Znamená to, že výběrová kovariance S_{12} je nestranným odhadem kovariance σ_{12} , avšak výběrový koeficient korelace R_{12} je vychýleným odhadem koeficientu korelace ρ .

Příklad 6.: Bylo zkoumáno 9 vzorků půdy s různým obsahem fosforu (veličina X). Hodnoty veličiny Y označují obsah fosforu v obilných klíčcích (po 38 dnech), jež vyrostly na těchto vzorcích půdy.

číslo vzorku	1	2	3	4	5	6	7	8	9
X	1	4	5	9	11	13	23	23	28
Y	64	71	54	81	76	93	77	95	109

Těchto 9 dvojic hodnot považujeme za realizace náhodného výběru $(X_1, Y_1), \dots, (X_9, Y_9)$ z dvourozměrného rozložení s kovariancí σ_{12} a koeficientem korelace ρ . Najděte bodové odhady kovariance σ_{12} a koeficientu korelace ρ .

Výpočet pomocí systému STATISTICA:

Otevřeme nový datový soubor o dvou proměnných X a Y 9 případech. Do proměnných X a Y zapíšeme zjištěné hodnoty obsahu fosforu v půdě a v obilných klíčcích.

Výpočet výběrové kovariance: Statistika – Vícerozměrná regrese – Proměnné – Závisle proměnná Y, nezávisle proměnná X – OK – OK – Residua/předpoklady/předpovědi – Popisné statistiky – Další statistiky – Kovariance. Dostaneme tabulku:

Proměnná	Kovariance (Tabulka18)	
	X	Y
X	91,7500	130,0000
Y	130,0000	284,2500

Vidíme, že výběrová kovariance veličin X, Y se realizuje hodnotou 130. (Výběrový rozptyl proměnné X resp. Y nabyly hodnoty 91,75 resp. 284,25.)

Výpočet výběrového koeficientu korelace: V menu Další statistiky vybereme Korelace.

Proměnná	Korelace (Tabulka18)	
	X	Y
X	1,000000	0,804989
Y	0,804989	1,000000

Výběrový koeficient korelace veličin X, Y nabyly hodnoty 0,805, tedy mezi veličinami x, Y existuje silná ořímá lineární závislost.

Upozornění: Výběrový koeficient korelace lze pomocí systému STATISTICA vypočítat i jiným způsobem: Statistika – Základní statistiky/tabulky – Korelační matice – OK – 1 seznam proměnných – X, Y – OK – Výpočet. Ve výsledné tabulce máme též realizace výběrových průměrů a směrodatných odchylek.

Proměnná	Korelace (Tabulka18)			
	Průměry	Sm.odch.	X	Y
X	13,00000	9,57862	1,000000	0,804989
Y	80,00000	16,85972	0,804989	1,000000

Vzorce pro meze $100(1-\alpha)\%$ empirického intervalu spolehlivosti pro střední hodnotu μ při známém rozptylu σ^2 :

$$\text{Oboustranný: } d = n - \frac{\sigma}{\sqrt{n}} u_{1-\alpha/2}, \quad h = n + \frac{\sigma}{\sqrt{n}} u_{1-\alpha/2}.$$

$$\text{Levostranný: } d = m - \frac{\sigma}{\sqrt{n}} u_{1-\alpha}.$$

$$\text{Pravostranný: } h = m + \frac{\sigma}{\sqrt{n}} u_{1-\alpha}.$$

Příklad 7.: Při kontrolních zkouškách životnosti 16 žárovek byl stanoven odhad $m = 3000$ h střední hodnoty jejich životnosti. Z dřívějších zkoušek je známo, že životnost žárovky se řídí normálním rozložením se směrodatnou odchylkou $\sigma = 20$ h. Vypočtete

- 99% empirický interval spolehlivosti pro střední hodnotu životnosti
- 90% levostranný empirický interval spolehlivosti pro střední hodnotu životnosti
- 95% pravostranný empirický interval spolehlivosti pro střední hodnotu životnosti.

Upozornění: Výsledek zaokrouhlete na jedno desetinné místo a vyjádřete v hodinách a minutách.

Řešení:

ad a)

$$d = n - \frac{\sigma}{\sqrt{n}} u_{0,995} = 3000 - \frac{20}{\sqrt{16}} 2,57583 = 2987,1,$$

$$h = n + \frac{\sigma}{\sqrt{n}} u_{0,995} = 3000 + \frac{20}{\sqrt{16}} 2,57583 = 3012,9$$

2987 h a 6 min < μ < 3012 h a 54 min s pravděpodobností aspoň 0,99

Výpočet pomocí systému STATISTICA

Otevřeme nový datový soubor o dvou proměnných d, h a jednom případě.

Do Dlouhého jména proměnné d napíšeme vzorec =3000-20/sqrt(16)*VNormal(0,995;0;1)

Do Dlouhého jména proměnné h napíšeme vzorec =3000+20/sqrt(16)*VNormal(0,995;0;1)

ad b)

$$d = n - \frac{\sigma}{\sqrt{n}} u_{0,9} = 3000 - \frac{20}{\sqrt{16}} 1,28155 = 2993,6$$

2993 h a 36 min < μ s pravděpodobností aspoň 0,9

Výpočet pomocí systému STATISTICA

Otevřeme nový datový soubor o jedné proměnné d a jednom případě.

Do Dlouhého jména proměnné d napíšeme vzorec =3000-20/sqrt(16)*VNormal(0,9;0;1)

ad c)

$$h = n + \frac{\sigma}{\sqrt{n}} u_{0,975} = 3000 + \frac{20}{\sqrt{16}} 1,95996 = 3009,8$$

3009 h a 48 min > μ s pravděpodobností aspoň 0,95

Výpočet pomocí systému STATISTICA

Otevřeme nový datový soubor o jedné proměnné h a jednom případě.

Do Dlouhého jména proměnné h napíšeme vzorec =3000+20/sqrt(16)*VNormal(0,975;0;1)

Užitečný odkaz: na adrese <http://www.prevody-jednotek.cz> je program, s jehož pomocí lze převádět různé fyzikální jednotky, v našem případě hodiny na minuty.