

Finanční Matematika – 4. přednáška

Martin Panák

15. března 2016

Odhady parametrů negativního binomického rozložení

Příklad Předpokládejme, že máme n řidičů, každý má smlouvu na dobu d_i , za kterou nahlásil k_i škodních událostí. Zkusme modelovat počet nehod daného řidiče pomocí negativního binomického rozložení, jehož parametry a a $\lambda (= \lambda d_i$ pro i -tého řidiče) odvodíme.

Logaritmická věrohodnostní funkce je

$$L(a, \lambda) = \sum_{i=1}^n \sum_{j=0}^{k_i-1} \ln(a+j) + na \ln a - \sum_{i=1}^n (a+k_i) \ln(a+\lambda d_i) + \ln \lambda \sum_{i=1}^n k_i + konst.$$

Pro parametry a a λ pak dostáváme rovnice.

Klasifikace rizika

apriorní, aposteriorní proměnné

Poissonovská regrese

N_i pojistné události

$$N_i \sim Poi(d_i e^{(\beta_0 + \sum_{j=1}^p \beta_j x_{ij})})$$

Klasifikace rizika

apriorní, aposteriorní proměnné

Poissonovská regrese

N_i pojistné události

$$N_i \sim Poi(d_i e^{(\beta_0 + \sum_{j=1}^p \beta_j x_{ij})})$$

Skóre:

$$\beta_0 + \sum_{j=1}^p \beta_j x_{ij}$$

Bayesovská analýza dat

Mějme Bernoulliův proces definovaný náhodnou veličinou $X \sim \text{Bi}(n, \theta)$ s binomickým rozdělením pravděpodobnosti a předpokládejme, že parametr θ je přitom náhodnou veličinou s rovnoměrným rozdělením pravděpodobnosti na intervalu $(0, 1)$. Definujme *šanci na úspěch* v našem procesu jako veličinu $\gamma = \frac{\theta}{1-\theta}$. Jakou hustotu rozdělení má veličina γ ?

Na pravé straně máme ovšem v horní mezi právě měnící se ohrazení γ a dostáváme tedy definiční vztah pro $f(s)$

$$f(s) = \left(\frac{s}{s+1} \right)' = \frac{1}{(s+1)^2}.$$

Hledaná hustota skutečně dává daleko větší pravděpodobnost malým hodnotám šance než velkým.

Jestliže pracujeme v bayesovském přístupu s binomickým modelem rozdělení pravděpodobnosti náhodné veličiny $X \sim \text{Bi}(n, \theta)$, bude nás zajímat její pravděpodobnostní funkce

$f_X(k) = \binom{n}{k} \theta^k (1 - \theta)^{n-k}$. Na tuto funkci se ale můžeme také dívat jako na podmíněnou pravděpodobnost $P(\theta|X = k)$ při apriorním rovnoměrném rozdělení pravděpodobnosti veličiny θ na intervalu $(0, 1)$. Je to tedy právě aposteriorní rozdělení pravděpodobnosti veličiny θ odpovídající výsledku pokusu $X = k$. Následující příklad se týká obecné třídy takovýchto rozdělení pravděpodobnosti.

Najděte základní charakteristiky tzv. **Beta rozdělení** $\beta(a, b)$ s hustotou pravděpodobnosti tvaru

$$f_Y = \begin{cases} C y^{a-1} (1-y)^{b-1} & y \in (0, 1) \\ 0 & \text{jinak.} \end{cases}$$

Najděte základní charakteristiky tzv. **Beta rozdělení** $\beta(a, b)$ s hustotou pravděpodobnosti tvaru

$$f_Y = \begin{cases} C y^{a-1}(1-y)^{b-1} & y \in (0, 1) \\ 0 & \text{jinak.} \end{cases}$$

Konstantu C je třeba volit jako reciprokou hodnotu integrálu $\int_0^1 y^{a-1}(1-y)^{b-1} dy$, což je funkce $B(a, b)$, v matematické analýze (ale také technických vědách či fyzice) známá pod názvem **Beta funkce**. Když už známe funkci Gama, která zobecňuje diskrétní hodnoty faktoriálů, vyskočí na nás např. při následujícím výpočtu:

$$\begin{aligned}
\Gamma(x)\Gamma(y) &= \int_0^\infty e^{-t} t^{x-1} dt \cdot \int_0^\infty e^{-s} s^{y-1} ds = \\
&= \int_0^\infty \int_0^\infty e^{-t-s} t^{x-1} s^{y-1} dt ds = \\
&\text{(substitute } t = rq, s = r(1 - q)) \\
&= \int_{r=0}^\infty \int_{q=0}^1 e^{-r} (rq)^{x-1} (r(1 - q))^{y-1} r dq dr = \\
&= \int_{r=0}^\infty e^{-r} r^{x+y-1} dr \cdot \int_{t=0}^1 q^{x-1} (1 - q)^{y-1} dq = \\
&= \Gamma(x + y)B(x, y).
\end{aligned}$$

dostáváme tedy obecný vztah

$$B(a, b) = \frac{\Gamma(a + b)}{\Gamma(a)\Gamma(b)}$$

$$\begin{aligned}\Gamma(x)\Gamma(y) &= \int_0^\infty e^{-t} t^{x-1} dt \cdot \int_0^\infty e^{-s} s^{y-1} ds = \\ &= \int_0^\infty \int_0^\infty e^{-t-s} t^{x-1} s^{y-1} dt ds = \\ &= \int_{r=0}^\infty e^{-r} r^{x+y-1} dr \cdot \int_{t=0}^1 q^{x-1} (1-q)^{y-1} dq = \\ &= \Gamma(x+y)B(x, y).\end{aligned}$$

dostáváme tedy obecný vztah

$$B(a, b) = \frac{\Gamma(a+b)}{\Gamma(a)\Gamma(b)}$$

$$\begin{aligned}\Gamma(x)\Gamma(y) &= \int_0^\infty e^{-t} t^{x-1} dt \cdot \int_0^\infty e^{-s} s^{y-1} ds = \\ &= \int_0^\infty \int_0^\infty e^{-t-s} t^{x-1} s^{y-1} dt ds =\end{aligned}$$

$$= \Gamma(x+y)B(x,y).$$

dostáváme tedy obecný vztah

$$B(a,b) = \frac{\Gamma(a+b)}{\Gamma(a)\Gamma(b)}$$

$$\begin{aligned}
\Gamma(x)\Gamma(y) &= \int_0^\infty e^{-t} t^{x-1} dt \cdot \int_0^\infty e^{-s} s^{y-1} ds = \\
&= \int_0^\infty \int_0^\infty e^{-t-s} t^{x-1} s^{y-1} dt ds = \\
&\text{(substitute } t = rq, s = r(1 - q)) \\
&= \int_{r=0}^\infty \int_{q=0}^1 e^{-r} (rq)^{x-1} (r(1 - q))^{y-1} r dq dr = \\
&= \int_{r=0}^\infty e^{-r} r^{x+y-1} dr \cdot \int_{t=0}^1 q^{x-1} (1 - q)^{y-1} dq = \\
&= \Gamma(x + y)B(x, y).
\end{aligned}$$

dostáváme tedy obecný vztah

$$B(a, b) = \frac{\Gamma(a + b)}{\Gamma(a)\Gamma(b)}$$

a z vlastností Gamma funkce již snadno plyne, že pro přirozená kladná a, b bude platit

$$B(n - k + 1, k + 1) = \frac{k!(n - k)!}{(n + 1)!} = \frac{1}{n + 1} \binom{n}{k}^{-1}.$$

Přímým výpočtem vidíme, že střední hodnota veličiny $X \sim \beta(a, b)$ s beta rozdělením je (využíváme vztah $\Gamma(z + 1) = z\Gamma(z)$)

$$E X = \frac{B(a + 1, b)}{B(a, b)} = \frac{a}{a + b}.$$

Je-li $a = b$ vyjde střední hodnota i medián $\frac{1}{2}$.

Přímo se také spočte rozptyl

$$\text{var } X = E(X - E X)^2 = \frac{ab}{(a + b)^2(a + b + 1)}.$$

Pro $a = b$ tedy dostáváme $\text{var } X = \frac{1}{8a+4}$, což ukazuje, že pro rostoucí $a = b$ klesá rozptyl. V případě $a = b = 1$ dostáváme obyčejné rovnoměrné rozdělení na intervalu $(0, 1)$.

Předpokládejme, že v Bernoulliho procesu je šance zdaru θ náhodná veličina s rozdělením pravděpodobnosti $\beta(a, b)$. Jak bude vypadat rozdělení pravděpodobnosti veličiny $\gamma = \frac{\theta}{1-\theta}$?

Předpokládejme, že v Bernoulliho procesu je šance zdaru θ náhodná veličina s rozdělením pravděpodobnosti $\beta(a, b)$. Jak bude vypadat rozdělení pravděpodobnosti veličiny $\gamma = \frac{\theta}{1-\theta}$?

V již řešeném příkladě jsme měli speciální případ s rovnoměrným rozdělením $\beta(1, 1)$. Můžeme tedy pokračovat v řešení v rovnosti $\|1\|$, kdy jsme tvar tohoto rozdělení použili. Dostáváme nyní na levé straně místo Θ výraz

$$\frac{1}{B(a, b)} \int_0^{\Theta} t^{a-1} (1-t)^{b-1} dt$$

a při derivování musíme použít pravidlo pro derivování integrálu s proměnnou horní mezí. Dostáváme proto pro hledanou hustotu

$$\begin{aligned} B(a, b)f(s) &= \left(\frac{s}{s+1}\right)^{a-1} \left(1 - \frac{s}{s+1}\right)^{b-1} \frac{1}{(s+1)^2} = \\ &= \left(\frac{s^{a-1}}{s+1}\right)^{a+b}. \end{aligned}$$

V případě Bernoulliho procesu popsaného náhodnou veličinou $X \sim \text{Bi}(n, \theta)$ a apriorní pravděpodobnosti náhodné veličiny θ s beta rozdělením, má i aposteriorní pravděpodobnost opět beta rozdělení s vhodnými parametry závislémi na výsledku pokusu. Jaká bude aposteriorní střední hodnota veličiny θ (tj. bayesovský bodový odhad této náhodné veličiny)?

Jak je zdůvodněno v odstavci ?? teoretického sloupce, bude aposteriorní hustota pravděpodobnosti, až na násobek vhodnou konstantou, dána jako součin apriorní hustoty pravděpodobnosti

$$g(\theta) = \frac{1}{B(a, b)} \theta^{a-1} (1 - \theta)^{b-1}$$

a pravděpodobnosti sledované veličiny X za podmínky, že nastala hodnota θ . Dostáváme tedy za předpokladu, že v Bernoulliho procesu nastalo k zdarů, aposteriorní hustotu (použitý znak místo rovnosti značí „proporcionální“)

$$\begin{aligned} g(\theta|X = k) &\propto P(X = k|\theta)g(\theta) \propto \\ &\propto \theta^k (1 - \theta)^{n-k} \theta^{a-1} (1 - \theta)^{b-1} = \\ &= \theta^{a+k-1} (1 - \theta)^{b+n-k-1}. \end{aligned}$$

Dostali jsme tedy, až na konstantu, kterou nemusíme vůbec vyčíslovat, skutečně hustotu aposteriorního rozdělení pro veličinu θ s rozdělením $B(a + k, b + n - k)$.

Její aposteriorní střední hodnota je

$$\hat{\theta} = \frac{a + k}{a + b + n}.$$

Pro n a k jdoucí do nekonečna, tak aby $k/n \rightarrow p$, bude i pro náš aposteriorní odhad platit $\hat{\theta} \rightarrow p$. Je tedy vidět, že při velkých hodnotách n a k bude převažovat pozorovaný podíl úspěšných pokusů nad apriorním předpokladem. Nicméně pro menší hodnoty je apriorní předpoklad naopak velice významný.


Příklad odhadu nehodovosti

Máme data o nehodovosti $N = 20$ řidičů za posledních $n = 10$ let (k -tá položka označuje počet roků, ve kterých došlo k nehodě u k -tého řidiče):

0, 0, 2, 0, 0, 2, 2, 0, 6, 4, 3, 1, 1, 1, 0, 0, 5, 1, 1, 0.

Předpokládáme, že pravděpodobnosti nehod u jednotlivých řidičů jsou konstanty p_j , $j = 1, \dots, N$.

Odhadněte pro každého řidiče pravděpodobnost, že bude mít nehodu v následujícím roce (např. pro určení jeho individuálního pojistného).¹

¹Tento příklad je převzat z příspěvku M. Friesl, Bayesovské odhady v některých modelech, publikováno v: Analýza dat 2004/II (K. Kupka, ed.), Trilobyte Statistical Software, Pardubice, 2005, pp. 21-33. 

Zavedeme si náhodné veličiny X_{ij} s hodnotami 0, když i -tý řidič v j -tém roce neměl žádnou nehodu, a hodnotami 1 pokud nehodu měl. Jednotlivé roky považujeme za nezávislé, můžeme proto předpokládat, že náhodné veličiny $S_j = \sum_{i=1}^n X_{ji}$ udávající počet nehod za všech $n = 10$ let mají rozdělení $\text{Bi}(n, p_j)$.

Zavedeme si náhodné veličiny X_{ij} s hodnotami 0, když i -tý řidič v j -tém roce neměl žádnou nehodu, a hodnotami 1 pokud nehodu měl. Jednotlivé roky považujeme za nezávislé, můžeme proto předpokládat, že náhodné veličiny $S_j = \sum_{i=1}^n X_{ji}$ udávající počet nehod za všech $n = 10$ let mají rozdělení $\text{Bi}(n, p_j)$.

Samozřejmě bychom mohli odhadnout pravděpodobnosti pro všechny řidiče společně, tj. pomocí aritmetického průměru

$$\hat{p} = \frac{1}{N} \sum_{j=1}^n S_j \frac{1}{n} = \frac{1}{20} \frac{29}{10} = 0,145.$$

Když ale uvážíme homogenost rozdělení veličin X_j , těžko je lze považovat za shodné, proto bude takovýto odhad jistě zavádějící.

Zavedeme si náhodné veličiny X_{ij} s hodnotami 0, když i -tý řidič v j -tém roce neměl žádnou nehodu, a hodnotami 1 pokud nehodu měl. Jednotlivé roky považujeme za nezávislé, můžeme proto předpokládat, že náhodné veličiny $S_j = \sum_{i=1}^n X_{ji}$ udávající počet nehod za všech $n = 10$ let mají rozdělení $\text{Bi}(n, p_j)$.

Samozřejmě bychom mohli odhadnout pravděpodobnosti pro všechny řidiče společně, tj. pomocí aritmetického průměru

$$\hat{p} = \frac{1}{N} \sum_{j=1}^n S_j \frac{1}{n} = \frac{1}{20} \frac{29}{10} = 0,145.$$

Když ale uvážíme homogenost rozdělení veličin X_j , těžko je lze považovat za shodné, proto bude takovýto odhad jistě zavádějící. Opačný extrém, tj. zcela nezávislý a individuální odhad

$$\hat{p}_j = \frac{1}{n} S_j$$

je samozřejmě také nevhodný, protože jistě nechceme předepisovat nulové pojistné, dokud nedojde k první nehodě.

Jako realistický se jeví postup, ve kterém využijeme stejný předpoklad apriorního rozdělení pravděpodobnosti p_j nehodovosti u jednotlivých řidičů. V praxi se zpravidla používá model s Poissonovým rozdělením $Po(\lambda_j)$ u j -tého řidiče s dalšími předpoklady o rozdělení parametru λ mezi řidiči. Docela dobře (a hlavně jednoduše) můžeme také předpokládat, že v našem případě půjde o rozdělení

Jako realistický se jeví postup, ve kterém využijeme stejný předpoklad apriorního rozdělení pravděpodobnosti p_j nehodovosti u jednotlivých řidičů. V praxi se zpravidla používá model s Poissonovým rozdělením $Po(\lambda_j)$ u j -tého řidiče s dalšími předpoklady o rozdělení parametru λ mezi řidiči. Docela dobře (a hlavně jednoduše) můžeme také předpokládat, že v našem případě půjde o rozdělení $p_j \sim \beta(a, b)$ s vhodnými parametry a, b , které by měly odrážet kumulované výsledky všech řidičů. Pojd' me tedy touto cestou.

Víme, že aposteriorní rozdělení pravděpodobností bude $(p_j | S_j = k) = \beta(a + k, b + n - k)$, takže příslušná střední hodnota bude

$$\hat{p}_j^b = \frac{a + k}{a + b + n}.$$

Víme, že aposteriorní rozdělení pravděpodobností bude $(p_j | S_j = k) = \beta(a + k, b + n - k)$, takže příslušná střední hodnota bude

$$\hat{p}_j^b = \frac{a + k}{a + b + n}.$$

Srovnáme si tento odhad s výše uvedeným společným odhadem \hat{p} a individuálním \hat{p}_j . Zaveďme si k tomu hodnoty $p_0 = \frac{a}{a+b}$, tj. střední hodnotu apriorního společného rozdělení pro všechny řidiče, a $n_0 = a + b$. Dostáváme

$$\hat{p}_j^b = \frac{(a + b)a}{(a + b + n)(a + b)} + \frac{nk}{(a + b + n)n} = \frac{n_0}{n_0 + n} p_0 + \frac{n}{n_0 + n} \hat{p}_j,$$

což je lineární kombinace střední hodnoty p_0 a individuálního odhadu \hat{p}_j .

Zbývá nám tedy už jen smysluplně odhadnout neznámé parametry a, b . Víme přitom

$$\begin{aligned} E X_{ji} &= E E(X_{ji}|p) = E p = p_0 \\ \frac{E \operatorname{var}(X_{ji}|p)}{\operatorname{var} E(X_{ji}|p)} &= \frac{E(p(1-p))}{\operatorname{var} p} = a + b = n_0 \end{aligned}$$

a přitom veličiny na levých stranách můžeme přímo odhadnout.

Zbývá nám tedy už jen smysluplně odhadnout neznámé parametry a, b . Víme přitom

$$\begin{aligned} E X_{ji} &= E E(X_{ji}|p) = E p = p_0 \\ \frac{E \operatorname{var}(X_{ji}|p)}{\operatorname{var} E(X_{ji}|p)} &= \frac{E(p(1-p))}{\operatorname{var} p} = a + b = n_0 \end{aligned}$$

a přitom veličiny na levých stranách můžeme přímo odhadnout.

$$E X_{ij} = E E(X_{ji}|p) \simeq \frac{1}{N} \sum_{j=1}^N \hat{p}_j$$

$$E \text{var}(X_{ji}|p) \simeq \frac{1}{N} \sum_{j=1}^N \left(\frac{n}{n-1} \hat{p}_j (1 - \hat{p}_j) \right)$$

$$\text{var} E(X_{ji}|p) \simeq s_{\hat{p}_j}^2 - \frac{1}{nN} \sum_{j=1}^N \left(\frac{n}{n-1} \hat{p}_j (1 - \hat{p}_j) \right),$$

kde $s_{\hat{p}_j}^2$ označuje výběrový rozptyl mezi individuálními odhady (čtenář si může promyslet, že odečtením posledního výrazu vpravo zajišťujeme, aby i poslední odhad byl nestranný).

Protože pro uvedená data takto dostáváme $n_0 \simeq 3,8643$ a $p_0 \simeq 0,1450$, vyjde nám bayesovský odhad individuální pravděpodobnosti nehod

$$\hat{p}_j^b = 0,154 \cdot 0,145 + 0,846 \cdot \hat{p}_j.$$

$$E X_{ij} = E$$

$$E \text{var}(X_{ji}|p) \simeq \frac{1}{N} \sum_{j=1}^N \left(\frac{n}{n-1} \hat{p}_j (1 - \hat{p}_j) \right)$$

$$\text{var} E(X_{ji}|p) \simeq s_{\hat{p}_j}^2 - \frac{1}{nN} \sum_{j=1}^N \left(\frac{n}{n-1} \hat{p}_j (1 - \hat{p}_j) \right),$$

kde $s_{\hat{p}_j}^2$ označuje výběrový rozptyl mezi individuálními odhady (čtenář si může promyslet, že odečtením posledního výrazu vpravo zajišťujeme, aby i poslední odhad byl nestranný).

Protože pro uvedená data takto dostáváme $n_0 \simeq 3,8643$ a $p_0 \simeq 0,1450$, vyjde nám bayesovský odhad individuální pravděpodobnosti nehod

$$\hat{p}_j^b = 0,154 \cdot 0,145 + 0,846 \cdot \hat{p}_j.$$

$$E X_{ij} = E$$

$$\text{var } E(X_{ji}|p) \simeq s_{\hat{p}_j}^2 - \frac{1}{nN} \sum_{j=1}^N \left(\frac{n}{n-1} \hat{p}_j (1 - \hat{p}_j) \right),$$

kde $s_{\hat{p}_j}^2$ označuje výběrový rozptyl mezi individuálními odhady (čtenář si může promyslet, že odečtením posledního výrazu vpravo zajišťujeme, aby i poslední odhad byl nestranný).

Protože pro uvedená data takto dostáváme $n_0 \simeq 3,8643$ a $p_0 \simeq 0,1450$, vyjde nám bayesovský odhad individuální pravděpodobnosti nehod

$$\hat{p}_j^b = 0,154 \cdot 0,145 + 0,846 \cdot \hat{p}_j.$$

$$E X_{ij} = E E(X_{ji}|p) \simeq \frac{1}{N} \sum_{j=1}^N \hat{p}_j$$

$$E \text{var}(X_{ji}|p) \simeq \frac{1}{N} \sum_{j=1}^N \left(\frac{n}{n-1} \hat{p}_j (1 - \hat{p}_j) \right)$$

$$\text{var} E(X_{ji}|p) \simeq s_{\hat{p}_j}^2 - \frac{1}{nN} \sum_{j=1}^N \left(\frac{n}{n-1} \hat{p}_j (1 - \hat{p}_j) \right),$$

$$E X_{ij} = E E(X_{ji}|p) \simeq \frac{1}{N} \sum_{j=1}^N \hat{p}_j$$

$$E \text{var}(X_{ji}|p) \simeq \frac{1}{N} \sum_{j=1}^N \left(\frac{n}{n-1} \hat{p}_j (1 - \hat{p}_j) \right)$$

$$\text{var} E(X_{ji}|p) \simeq s_{\hat{p}_j}^2 - \frac{1}{nN} \sum_{j=1}^N \left(\frac{n}{n-1} \hat{p}_j (1 - \hat{p}_j) \right),$$

kde $s_{\hat{p}_j}^2$ označuje výběrový rozptyl mezi individuálními odhady (čtenář si může promyslet, že odečtením posledního výrazu vpravo zajišťujeme, aby i poslední odhad byl nestranný).

Protože pro uvedená data takto dostáváme $n_0 \simeq 3,8643$ a $p_0 \simeq 0,1450$, vyjde nám bayesovský odhad individuální pravděpodobnosti nehod

$$\hat{p}_j^b = 0,154 \cdot 0,145 + 0,846 \cdot \hat{p}_j.$$

Jde tedy o kombinaci spolehlivého odhadu $\hat{p} = 0,145$ kolektivní pravděpodobnosti p_0 s individuálním (frekvenčním) odhadem \hat{p}_j , který je pořízen z malého počtu pozorování $n = 10$ u jediného řidiče.