

M5VM05 Statistické modelování

11. Konkrétní GLM modely – II.

Jan Koláček (kolacek@math.muni.cz)

Ústav matematiky a statistiky, Přírodovědecká fakulta, Masarykova univerzita, Brno



Motivace

Na minulé přednášce jsme si uvedli zobecněné lineární modely pro alternativní, binomická a poissonovská data. Tato přednáška navazuje na přednášku minulou. Nejprve budeme zkoumat problémy příliš velkého nebo příliš malého rozptylu v datech. Dále pak nastíníme modelování multinomických dat a jeho využití v testování nezávislosti v kontingenčních tabulkách.

Overdispersion, underdispersion

Předpokládáme, že náhodný výběr $\mathbf{Y}_n = (Y_1, \dots, Y_n)^\top$ z rozdělení exponenciálního typu se řídí GLM modelem, tj.

$$f(\mathbf{y}, \boldsymbol{\theta}) = \prod_{i=1}^n f(y_i, \theta_i) = \exp \left\{ \sum_{i=1}^n \frac{y_i \theta_i - \gamma(\theta_i)}{\psi_i(\phi)} + d(y_i, \phi) \right\}.$$

Předpokládejme, že platí

$$\psi_i(\phi) = \frac{\phi}{\omega_i} > 0,$$

kde $\omega_i > 0$ jsou známé **apriorní váhy** a $\phi > 0$ je neznámý **rušivý parametr**.
Škálová deviace

$$\begin{aligned} D &= 2 \left[l^*(\hat{\boldsymbol{\beta}}_{max}; \mathbf{Y}) - l^*(\hat{\boldsymbol{\beta}}; \mathbf{Y}) \right] \\ &= \frac{1}{\phi} 2 \sum_{i=1}^n \omega_i \left[Y_i (\hat{\theta}_{i,max} - \hat{\theta}_i) - \gamma(\hat{\theta}_{i,max}) + \gamma(\hat{\theta}_i) \right] \\ &= \frac{1}{\phi} D^* \end{aligned}$$

a D^* nazveme **neškálovou deviací** (unscaled deviance).

Overdispersion, underdispersion

Protože platí

$$D = \frac{1}{\phi} D^* \stackrel{A}{\sim} \chi^2(n - k) \quad \Rightarrow \quad ED = \frac{1}{\phi} ED^* \approx n - k,$$

pak

$$\hat{\phi}_{D^*} = \frac{D^*}{n - k}.$$

Další často používanou mírou vhodnosti modelu je tzv. zobecněná Pearsonova statistika

$$X^2 = \sum_{i=1}^n \frac{(Y_i - \hat{\mu}_i)^2}{V(\hat{\mu}_i)} \stackrel{A}{\sim} \chi^2(n - k)$$

a proto dalším momentovým odhadem založeným na této statistice je

$$\hat{\phi}_{X^2} = \frac{X^2}{n - k}.$$

Overdispersion, underdispersion

Přehled rušivých parametrů

Rozdělení	ϕ
Normální rozdělení	σ^2
Poissonovo rozdělení	1
Binomické rozdělení	1
Gamma rozdělení	$1/\alpha$

Overdispersion, underdispersion

V prostředí R je k řešení tohoto problému k dispozici modifikovaná volba pro třídu exponenciálního rozdělení. V případě binomického rozdělení máme možnost volby

```
family=quasibinomial
```

a pro Poissonovo rozdělení

```
family=quasipoisson.
```

Nejde o nový typ exponenciálního rozdělení, ale o změnu ve výpočtu druhého momentu, pro jehož odhad se použije jednoduchý momentový odhad disperzního parametru ϕ . Výsledná korekce rozptylu je pak důležitá při testování hypotéz, neboť zohledňuje vyšší/nižší variabilitu v datech a zabraňuje tak nadbytku/nedostatku falešně pozitivních výsledků testů hypotéz o parametrech modelu.

Příklad

Příklad 1

V souboru „*bees.RData*“ jsou uvedeny údaje o aktivitě včel v závislosti na čase. Jednou z důležitých charakteristik při zkoumání včelí aktivity je počet včel, které opustí úl kvůli práci ve vnějším prostředí. Studie se zabývala měřením této veličiny během několika slunečných dní v závislosti na čase během dne. Datový soubor obsahuje tyto proměnné

number počet včel, které opustily úl
time čas, kdy byl tento údaj zaznamenán


Modelujte závislost počtu včel, které opustí úl, na čase během dne.

Řešení. Pro modelování závislosti použijeme poissonovský model s kanonickou linkovací funkcí. Do modelu vstupuje jediná vysvětlující proměnná *time* a přidáme také její druhou mocninu.

Hodnota reziduální deviace (4 879,3) je nepoměrně vyšší než počet stupňů volnosti (501). Je zřejmé, že došlo k „overdispersion“ a v jazyce *R* je třeba volit *family=quasipoisson*. Použití této volby neovlivňuje odhady koeficientů, ale mění jejich hodnoty variability, což se projeví např. v intervalu spolehlivosti.

Příklad


Bees activity



Obrázek : Odhad regresní funkce **bez** vyrovnání se s problematikou velkého rozptylu.

Příklad

Bees activity



Obrázek : Odhad regresní funkce s vyrovnáním se s problematikou velkého rozptylu.

Modely pro multinomická data

Náhodný výběr $\mathbf{Y} = \mathbf{Y}_n = (Y_1, \dots, Y_n)^T$, pro který $n = J \cdot K$, tj.

$$\mathbf{Y} = \mathbf{Y}_n = (Y_1, \dots, Y_n)^T = (Y_{11}, \dots, Y_{1K}, \dots, Y_{J1}, \dots, Y_{JK})^T.$$

Předpokládejme, že náhodný výběr \mathbf{Y} je z Poissonova rozdělení, tj.

$$Y_{jk} \sim Po(\lambda_{jk}) \quad j = 1, \dots, J; k = 1, \dots, K$$

s tzv. **celkovou** dodatečnou podmínkou

$$N = \sum_{j=1}^J \sum_{k=1}^K y_{jk} \quad N \in \mathbb{N}^+,$$

kde y_{jk} jsou realizace náhodných veličin Y_{jk} .

Modely pro multinomická data

Rozdělení náhodného vektoru \mathbf{Y} za podmínky $Z_{..} = N$ je **multinomické**

$$p_{\mathbf{Y}|Z_{..}=N}(\mathbf{y}) = \begin{cases} N! \prod_{j=1}^J \prod_{k=1}^K \frac{\pi_{jk}^{y_{jk}}}{y_{jk}!} & \text{pro } y_{jk} = 0, 1, \dots, N; \quad j = 1, \dots, J; \\ & \quad k = 1, \dots, K, \\ & \quad \sum_{j=1}^J \sum_{k=1}^K y_{jk} = N \quad \sum_{j=1}^J \sum_{k=1}^K \pi_{jk} = 1 \\ 0 & \text{jinak} \end{cases},$$

tj.

$$\mathbf{Y}|Z_{..} = N \sim Mn(N, \pi_{11}, \dots, \pi_{1K}, \dots, \pi_{J1}, \dots, \pi_{JK}),$$

přičemž

$$EY_{jk} = N\pi_{jk}$$

$$DY_{jk} = N\pi_{jk}(1 - \pi_{jk})$$

$$C(Y_{jk}, Y_{j'k'}) = -N\pi_{jk}\pi_{j'k'}$$

Kontingenční tabulky

Realizace náhodných veličin i teoretické pravděpodobnosti lze uspořádat do tzv. **kontingenční tabulky**:

Kontingenční tabulka četností

faktor <i>A</i>	faktor <i>B</i>				Σ
	B_1	B_2	\cdots	B_K	
A_1	y_{11}	y_{12}	\cdots	y_{1K}	$N_{1.}$
A_2	y_{21}	y_{22}	\cdots	y_{2K}	$N_{2.}$
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
A_J	y_{J1}	y_{J2}	\cdots	y_{JK}	$N_{J.}$
Σ	$N_{.1}$	$N_{.2}$	\cdots	$N_{.K}$	$N = N_{..}$

Kontingenční tabulky

Kontingenční tabulka pravděpodobností

faktor A	faktor B				Σ
	B_1	B_2	\dots	B_K	
A_1	π_{11}	π_{12}	\dots	π_{1K}	$\pi_{1.}$
A_2	π_{21}	π_{22}	\dots	π_{2K}	$\pi_{2.}$
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
A_J	π_{J1}	π_{J2}	\dots	π_{JK}	$\pi_{J.}$
Σ	$\pi_{.1}$	$\pi_{.2}$	\dots	$\pi_{.K}$	$\pi_{..} = 1$

Kontingenční tabulky

Nejčastěji se v kontingenčních tabulkách testuje hypotéza, že

faktory A a B jsou nezávislé

tj.

faktor A	faktor B			Σ
	...	B_k	...	
:	:	:	:	:
A_j	...	$\pi_{j.} \pi_{.k}$...	$\pi_j.$
:	:	:	:	:
Σ	...	$\pi_{.k}$...	1

$$\pi_{jk} = \pi_{j.} \pi_{.k}, \text{ takže potom } EY_{jk} = N\pi_{j.} \pi_{.k}, \text{ přičemž } \sum_{j=1}^J \pi_{j.} = \sum_{k=1}^K \pi_{.k} = 1.$$

Log-lineární modely

Pro model s **celkovou dodatečnou podmínkou** lze hypotézu o **nezávislosti dvou faktorů** definovat takto

$$EY_{jk} = N\pi_j.\pi_{.k}, \quad \text{přičemž} \quad \sum_{j=1}^J \pi_{j.} = 1 \quad \text{a} \quad \sum_{k=1}^K \pi_{.k} = 1.$$

V GLM s **log-lineární linkovací funkcí** máme $\eta_{jk} = \log EY_{jk} = \mathbf{x}_{jk}^\top \boldsymbol{\beta}$, tedy

$$\eta_{jk} = \log EY_{jk} = \log(N\pi_j.\pi_{.k}) = \underbrace{\mu}_{=\log N} + \underbrace{\alpha_j}_{=\log \pi_{j.}} + \underbrace{\beta_k}_{=\log \pi_{.k}}.$$

Pokud bychom nepředpokládali nezávislost faktorů A a B, dostaneme **maximální model**

$$\eta_{jk} = \log EY_{jk} = \log(N\pi_{jk}) = \underbrace{\mu}_{=\log N} + \underbrace{\alpha_j + \beta_k + (\alpha\beta)_{jk}}_{=\log \pi_{jk}}$$

Hypotéza nezávislosti dvou faktorů v kontingenčních tabulkách je ekvivalentní s hypotézou neexistence interakcí v analýze rozptylu (deviace), tj.

$$H_0 : (\alpha\beta)_{jk} = 0 \quad j = 1, \dots, J; \quad k = 1, \dots, K.$$

Příklad

Příklad 2

V následující kontingenční tabulce jsou obsaženy údaje studie 400 pacientů o počtech různých typů onemocnění rakovinou kůže (*Malignant Melanoma*) v závislosti na části těla, kde se vyskytují.


Typ rakoviny	Část těla		
	končetiny	hlava a krk	trup
<i>Hutchinson's melanotic freckle</i>	10	22	2
<i>neurčitý</i>	28	11	17
<i>Nodular</i>	73	19	33
<i>Superficial spreading melanoma</i>	115	16	54

Na hladině významnosti $\alpha = 0,05$ testujte hypotézu, zda typ rakoviny kůže závisí na části těla, kde se vyskytuje.

Příklad


Řešení Nejprve definujeme oba log-lineární modely, tj. model m_1 , který předpokládá nezávislost obou faktorů a model m_2 , který počítá i s interakcemi. Model m_1 je tedy submodelem modelu m_2 . K testování využijeme analýzu deviace, Pearsonův test. Jeho p -hodnota vychází $2,05 \times 10^{-9}$ a proto zamítáme hypotézu o nezávislosti typu rakoviny kůže na části těla, kde se vyskytuje. Výsledky obou modelů lze také znázornit pomocí mozaikového grafu.

Příklad



Obrázek : Mozaikový graf pro model, který předpokládá nezávislost.

Příklad



Obrázek : Mozaikový graf pro model s interakcemi.

Úlohy k procvičení I

Příklad 2.1

V souboru „sharks.RData“ jsou k dispozici data, která popisují počty napadení žraloky na Floridě v letech 1946 až 1999. Známe také velikost populace. Datový soubor obsahuje tyto proměnné:

<i>Year</i>	rok
<i>Population</i>	velikost populace
<i>Attacks</i>	počet napadení žraloky
<i>Fatalities</i>	počet úmrtí způsobených žraloky

Nejprve vykreslete bodový graf počtu napadení na 1 milión obyvatel v závislosti na čase. Pro modelování použijte binomický i poissonovský model s kanonickou linkovací funkcí. Pro matici plánu uvažujte kubický polynom v proměnné *Year*.

Úlohy k procvičení II

Příklad 2.1

Predikce obou modelů i s intervalem spolehlivosti pro regresní funkci vykreslete do obrázku. Zkoumejte také, jestli nenastal problém příliš velkého nebo příliš malého rozptylu. Pokud ano, předefinujte model a výsledky znovu vykreslete do obrázku. Pomocí výsledného modelu odhadněte, kolik útoků (na 1 milión obyvatel) způsobí žraloci na Floridě v roce 2013 a také v jakém intervalu se tato hodnota s 95% pravděpodobností bude pohybovat.

[Nastal problém příliš velkého rozptylu. Odhad: 33,96 útoků na 1 milión obyvatel, interval spolehlivosti: [3,207;359,55].]

Úlohy k procvičení

Příklad 2.2

V následující kontingenční tabulce jsou obsaženy údaje o počtech různých typů onemocnění horních cest dýchacích (*Respiratory Tract Infections*) v závislosti na čase.

Diagnóza	Časové období				
	1-3/96	4-6/96	7-9/96	10-12/96	1-3/97
Acute bronchitis	113	58	40	108	100
Acute sinusitis	99	37	23	50	32
URI	410	228	125	366	304
Pneumonia	60	43	30	56	45

Na hladině významnosti $\alpha = 0,05$ testujte hypotézu, zda onemocnění horních cest dýchacích závisí na čase.

[závisí]