

Bi7491 Regresní modelování

---

# Dodatky ke zobecněným lineárním modelům

# Co byste měli vědět a umět po dnešní hodině ?

- ➔ Chápat princip analýzy deviation
- ➔ Umět na definovat Poissonův model a popsát jeho užití
- ➔ Umět vysvětlit pojem overdispersion – čím je způsobena a jak ji poznat a řešit
- ➔ Znát základní možnosti modelování ordinálních výsledků

## **Dodatky ke zobecněným lineárním modelům**

---

# **Analýza deviance ve zobecněných lineárních modelech**

# Modely a submodely

- Modelování -  $y$  nahrazujeme  $\hat{\mu}$  prostřednictvím odhadu  $\hat{\beta}$
- Jak moc se vzájemně liší?
- Model s  $n$  parametry  
**MAXIMÁLNÍ MODEL (plný, saturovaný)**  
→ veškerá variabilita do systematické složky
- Model s  $k$  parametry  
**ZKOUMANÝ MODEL**
- když vyloučíme některý prediktor ( $m < k$  parametrů)  
**SUBMODEL**
- Model s 1 parametrem (konstantou – průměrem)  
**NULOVÝ MODEL** → veškerá variabilita do náhodné složky

vždy stejný typ rozdělení, stejná linkovací funkce

# Deviance

- ➔ představuje odchylku zkoumaného modelu od „dokonalého“ maximálního modelu

$$D = 2[l(\mathbf{y}; \mathbf{y}) - l(\hat{\boldsymbol{\mu}}; \mathbf{y})]$$

log-věrohodnost      log-věrohodnost  
maximálního      zkoumaného  
modelu                modelu

- ➔ analogie s analýzou rozptylu – zde formulovaná pomocí změny ve věrohodnosti
- ➔ umožňuje test odchylky od maximálního modelu

# Testování submodelů

$$\Delta D = 2[l(\hat{\mu}; \mathbf{y}) - l(\hat{\mu}_{SUB}; \mathbf{y})]$$

rozdíl deviancí      log-věrohodnost log-věrohodnost  
                              zkoumaného submodelu  
                              modelu

- Deviance je velmi užitečná při srovnání dvou modelů z nichž jeden je podmodelem (submodelen) druhého
- Je-li  $\Delta D > \chi^2_{1-\alpha}(k-m)$ , kde  $m$  ( $k$ ) je počet odhadovaných parametrů submodelu (zkoumaného modelu), pak je submodel nevhodný – přehnaně zjednodušující

# Test významnosti celého modelu vs. maximální model

- srovnání maximálního (plného) modelu se **zkoumaným modelem – REZIDUÁLNÍ DEVIANCE** (odpovídá reziduálnímu součtu čtverců)
- ***Nechybí nám nějaký významný efekt?***

$D > \chi^2_{1-\alpha}$  (počet pozorování – počet parametrů)



NĚCO V MODELU CHYBÍ...

Software uvádí příslušnou statistiku  
Je ale asymptotická – slouží spíš pro orientační kontrolu !!!

# Test významnosti celého modelu vs. nulový model

- srovnání zkoumaného modelu s nulovým modelem  
**NULOVÁ DEVIANCE – REZIDUÁLNÍ DEVIANCE**
- *Vysvětluje vůbec zkoumaný model nějakou informaci?*

$$\Delta D > \chi^2_{1-\alpha}(\text{počet parametrů} - 1)$$

 **MODEL NĚCO VYSVĚTLUJE**

**Software uvádí příslušnou statistiku  
Je ale asymptotická – slouží spíš pro orientační kontrolu !!!**

# VĚROHODNOST

Maximální  
model

Zkoumaný  
model

Submodel

Nulový model

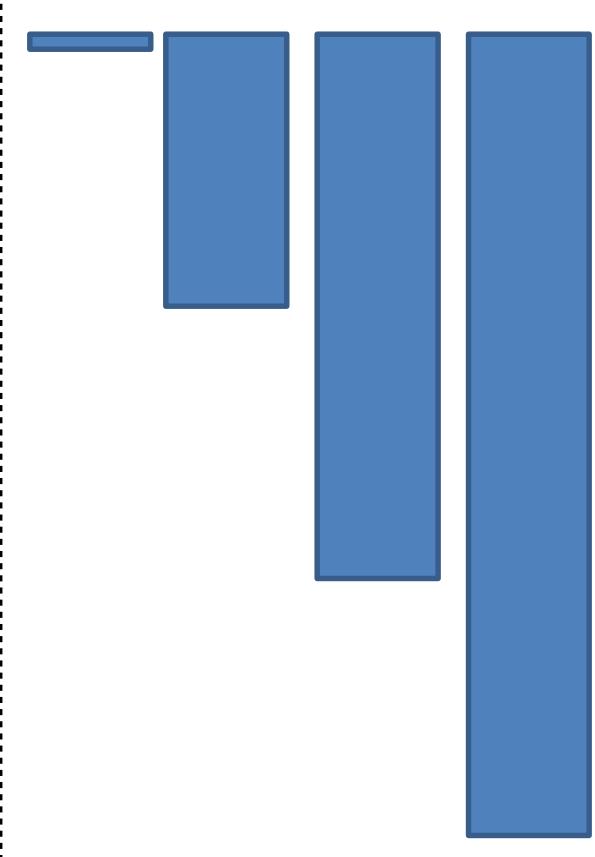
PARAMETRY  $\sigma$

k

m

1

# DEVIANCE



# TESTY

REZIDUÁLNÍ

k-m

SUBMODEL

n-k

k-1

NULOVÁ minus  
REZIDUÁLNÍ

# Akaikeovo informační kritérium

(Akaike information criterion, AIC )

$$AIC = -2l(\hat{\mu}; \mathbf{y}) + 2k$$

AIC= – 2 maximum logaritmované věrohodnosti + 2 počet parametrů modelu

- Čím je hodnota AIC **menší**, tím je model lepší.
- AIC **penalizuje modely s velkým počtem parametrů**
- užití brání „přeučení“ modelu (takový model by dobře neodpovídal novému vzorku)

The image shows the cover of a journal issue. At the top left is the page number 716. To its right is the journal title "IEEE TRANSACTIONS ON AUTOMATIC CONTROL, VOL. AC-19, NO. 6, DECEMBER 1974". Below the title is the article title "A New Look at the Statistical Model Identification". Underneath the article title is the author's name "HIROTUGU AKAIKE, MEMBER, IEEE". The background of the cover is white with some decorative elements.

## **Dodatky ke zobecněným lineárním modelům**

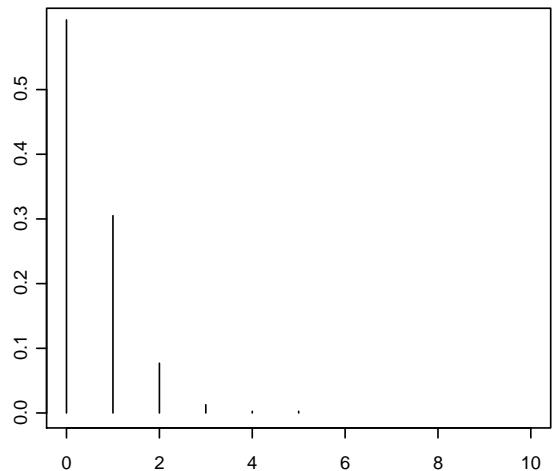
---

### **Poissonova regrese**

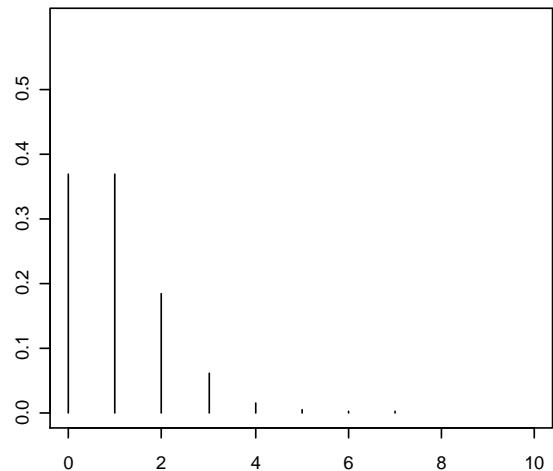
# Poissonovo rozdělení

- Diskrétní rozdělení, které **popisuje počet výskytů sledované události na danou jednotku** (času, plochy, objemu), když se tyto události vyskytují vzájemně **nezávisle** s konstantní intenzitou (**jediný** parametr  $\lambda$ ).
- Jedná se o zobecnění binomického rozdělení pro  $n \rightarrow \infty$  a  $p \rightarrow 0$ .
- Pravděpodobnostní funkce:  $P(X = x) = p_x(x; \lambda) = \frac{\lambda^x e^{-\lambda}}{x!}, x \geq 0$
- Střední hodnota, rozptyl:  $EX = \lambda, DX = \lambda$
- **Příklady:** průměrný výskyt mutací bakterií na 1 Petriho misku, počet krvinek v poli mikroskopu, počet žížal vyskytujících se na 1 m<sup>2</sup>, počet pooperačních komplikací během určitého časového intervalu po výkonu.

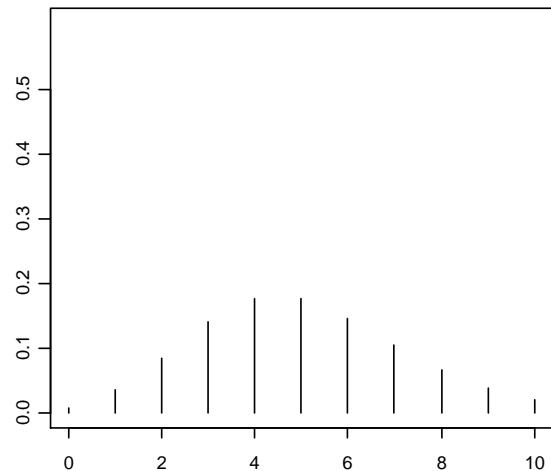
**lambda = 0.5**



**lambda = 1**



**lambda = 5**



# Formulace Poissonova modelu

- ➡ Uvažujeme výsledek vyjádřený počtem (událostí, objektů), který chceme vztáhnout ke známým vysvětlujícím proměnným – modelujeme pomocí Poissonova rozdělení

$$Y_i \sim Po(\lambda_i)$$

$$i = 1, \dots, n$$

# Formulace Poissonova modelu

Normální lineární regresní model:

$$EY_i = \beta_0 + \beta_1 x_{i1} + \dots + \beta_p x_{ip}$$

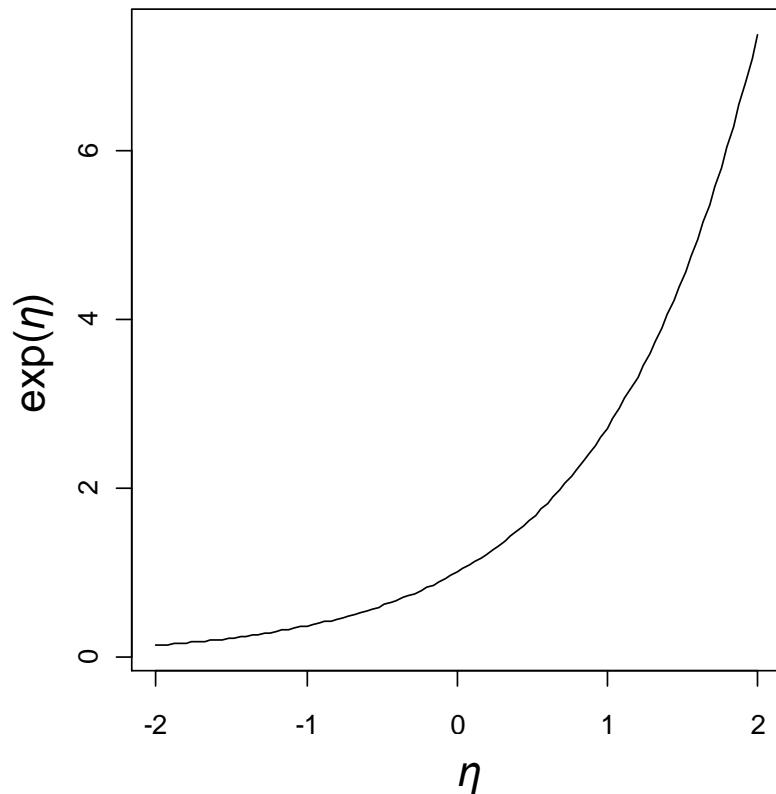
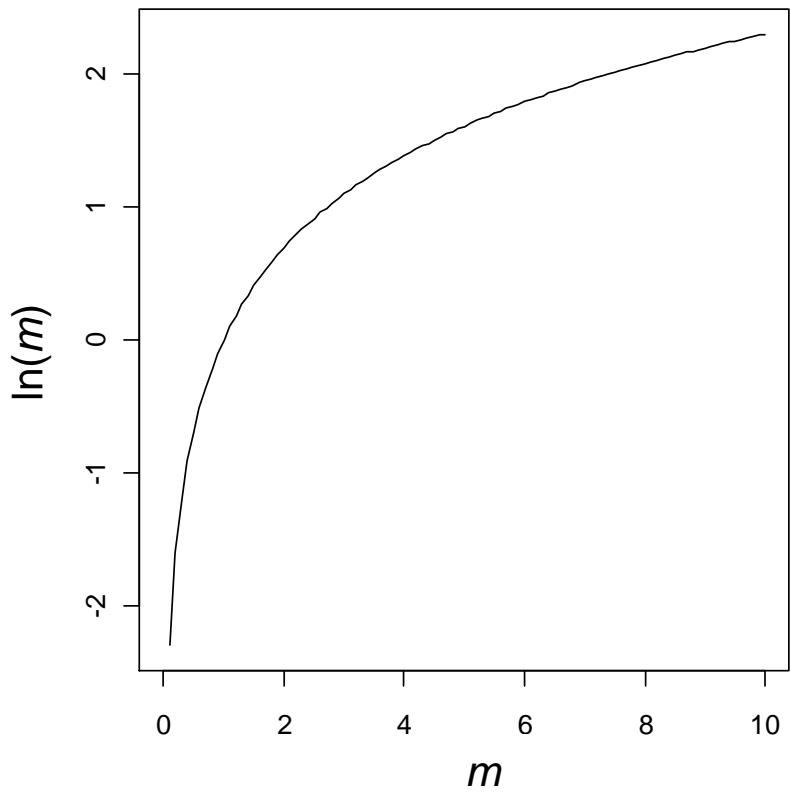
$$i = 1, \dots, n$$

Poissonův regresní model – modelujeme **očekávaný počet událostí**:

$$\ln(m_i) = \beta_0 + \beta_1 x_{i1} + \dots + \beta_p x_{ip}$$

$$i = 1, \dots, n$$

# Linkovací funkce



# Interpretace koeficientů - příklad

Subjekt 1:

$$\ln(m_1) = \beta_0$$

$$m_1 = \exp(\beta_0)$$

Subjekt 2:

$$\ln(m_2) = \beta_0 + \beta_1$$

$$m_2 = \exp(\beta_0 + \beta_1)$$

Parametr  
asociovaný  
s nějakým  
binárním  
prediktorem

Risk ratio (relativní riziko) nějaké události:

$$RR(2,1) = \frac{m_2}{m_1} = \frac{\exp(\beta_0 + \beta_1)}{\exp(\beta_0)} = \frac{\exp(\beta_0)\exp(\beta_1)}{\exp(\beta_0)} = \exp(\beta_1)$$

Exp(odhad parametru) PŘEDSTAVUJE RELATIVNÍ RIZIKO SPOJENÉ S DANÝM PREDIKTOREM

# Model incidence (míry)

$$\text{Incidence} = \frac{\text{počet nových případů}}{\text{součet „osoboroků“ v riziku}}$$

- ➔ Popsaný model lze využít pro modelování incidence onemocnění (výskytu událostí apod.)
- ➔ Nezbytné, pokud se pro jednotlivá pozorování liší např. doba sledování
- ➔ Do modelu je nezbytné uvést jmenovatele – součet osoboroků v riziku  
(person-years at risk), označ.  $d_i$
- ➔ V rámci softwarových nástrojů se specifikuje jako tzv. offset:

$$\ln\left(\frac{m_i}{d_i}\right) = \beta_0 + \beta_1 x_{i1} + \dots + \beta_p x_{ip}, i = 1, \dots, n$$

$$\ln(m_i) - \ln(d_i) = \beta_0 + \beta_1 x_{i1} + \dots + \beta_p x_{ip}, i = 1, \dots, n$$

$$\ln(m_i) = \ln(d_i) + \beta_0 + \beta_1 x_{i1} + \dots + \beta_p x_{ip}, i = 1, \dots, n$$

# Model incidence (míry)

$$\text{Incidence} = \frac{\text{počet nových případů}}{\text{součet „osoboroků“ v riziku}}$$

- ➔ Popsaný model lze využít pro modelování incidence onemocnění (výskytu událostí apod.)
- ➔ Nezbytné, pokud se pro jednotlivá pozorování liší např. doba sledování
- ➔ Do modelu je nezbytné uvést jmenovatele – součet osoboroků v riziku (person-years at risk), označ.  $d_i$
- ➔ V rámci softwarových nástrojů se specifikuje jako tzv. offset
- ➔ Interpretace  $\exp(\beta)$  – poměr incidencí

# Ověření splnění předpokladů

- 1. Linkovací funkce –  $\ln(.)$**
- 2. Správnost lineárního prediktoru** – netřeba přidávat další proměnné, transformovat proměnné, nebo přidat interakce mezi proměnnými
- 3. Správnost předpokládaného rozptylu výsledků** – dáno vzorcem pro Poissonovo rozdělení

## Obdobně jako u logistické regrese

- analýza reziduí a vlivu
- analýza deviance

## Dodatky ke zobecněným lineárním modelům

---

„Nadměrný rozptyl“ - *overdispersion*

# Probíraná rozdělení v GLM

➔ prozatím jsme se věnovali logistické a poissonově regresi...

# Binomické rozdělení

- Diskrétní rozdělení, které **popisuje počet výskytů sledované události** (ve formě nastala/nenastala) **v sérii  $n$  nezávislých experimentů**, kdy v každém experimentu **je stejná pravděpodobnost výskytu** události a je  $p = \theta$ .
- Pravděpodobnostní funkce:

$$P(X = k) = \binom{n}{k} \theta^k (1 - \theta)^{n-k}$$

- Střední hodnota

$$E(X) = n\theta$$

- Rozptyl

$$D(X) = n\theta(1 - \theta)$$

# Poissonovo rozdělení

- Diskrétní rozdělení, které **popisuje počet výskytů sledované události na danou jednotku** (času, plochy, objemu), když se tyto události vyskytují vzájemně **nezávisle** s konstantní intenzitou (**jediný** parametr  $\lambda$ ).
- Jedná se o zobecnění binomického rozdělení pro  $n \rightarrow \infty$  a  $p \rightarrow 0$ .
- Pravděpodobnostní funkce:  $P(X = x) = p_x(x; \lambda) = \frac{\lambda^x e^{-\lambda}}{x!}, x \geq 0$
- Střední hodnota, rozptyl: 
$$EX = \lambda, DX = \lambda$$
- **Příklady:** průměrný výskyt mutací bakterií na 1 Petriho misku, počet krvinek v poli mikroskopu, počet žížal vyskytujících se na 1 m<sup>2</sup>, počet pooperačních komplikací během určitého časového intervalu po výkonu.

# Střední hodnota a rozptyl

- ➔ prozatím jsme se věnovali logistické a poissonově regresi...
- ➔ v těchto rozděleních jsou spjaty střední hodnota a rozptyl:
  - ➔ v Poissonově rozdělení platí  
je li střední hodnota 1,5, je rozptyl rovněž 1,5  
(návštěv na urgentním příjmu za hodinu, moučných červů v dl mouky,...)
  - ➔ v Binomickém rozdělení platí  
je li střední hodnota 1,5, je rozptyl 0,75  
(v situaci, kdy např. odhadujeme počet chlapců mezi třemi potomky)

# *Overdispersion v praxi*

→ v praxi rozdělení výsledků nemusí přesně odpovídat předpokladům

## → DŮVOD

- výsledky nejsou vzájemně zcela nezávislé
  - (více měření u jednoho pacienta/lékaře/laboratoře, autokorelace v časových řadách, ...)
- naše naměřené a zkoumané prediktory kompletně nespecifikují výsledek

## → INDIKACE

- velmi vysoká reziduální variabilita (vysoká významnost testu)

## → ŘEŠENÍ

- přidat více prediktorů (pokud ale ten důležitý byl změřen)
- odhadnout a využít zvlášť disperzní parametr  
`family=quasibinomial / quasipoisson`

## **Dodatky ke zobecněným lineárním modelům**

---

### **Multinomiální modely**

# Ordinální výsledek

- ➔ kategorie lze seřadit, ale jen obtížně k nim lze přiřadit číselnou hodnotu  
(např. stadium choroby)
- 

- ➔ opět vycházíme z lineárního prediktoru

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

- ➔ modelovat binomicky? modelovat nějaké skóre?  
ani jedno nemusí být vhodné

# Ordinální výsledek

- ➔ Příklad: modelujeme stadium fibrózy jater ( $Y_i = 0, 1, 2, 3$ ) pomocí tří krevních markerů
- ➔ kumulativní pravděpodobnosti (od shora) jednotlivých stadií:

$$q_{i,3} = p_{i,3} \quad \text{pravděpodobnost kategorie 3} \quad \text{cut-off mezi 2 a 3}$$

$$q_{i,2} = p_{i,2} + p_{i,3} \quad \text{pravděpodobnost kategorie 2 a více} \quad \text{cut-off mezi 1 a 2}$$

$$q_{i,1} = p_{i,1} + p_{i,2} + p_{i,3} \quad \text{pravděpodobnost kategorie 1 a více} \quad \text{cut-off mezi 0 a 1}$$

- ➔ kdybychom použili logistickou regresi pro spojené kategorie 2 a více

$$\eta_i = \text{logit}(q_{i,2}) = \ln\left(\frac{q_{i,2}}{1 - q_{i,2}}\right) = \alpha + \beta_1 x_{i1} + \beta_2 x_{i2} + \beta_3 x_{i3}$$

# Model proporcionálních šancí

**Předpoklad: Vliv proměnné nezávisí na volbě cut-off (!)**

➔ Model proporcionálních šancí pro kumulativní logit

$$j = 1, 2, 3$$

$$\begin{aligned}\eta_{i,j} &= \text{logit}(q_{i,j}) = \ln\left(\frac{q_{i,j}}{1-q_{i,j}}\right) = \ln\left(\frac{\text{P}(Y_i \geq j)}{1-\text{P}(Y_i \geq j)}\right) \\ &= \alpha_j + \beta_1 x_{i1} + \beta_2 x_{i2} + \beta_3 x_{i3}\end{aligned}$$

➔ v měřítku **pravděpodobností**

$$q_{i,j} = q_j(x_i) = \frac{\exp(\alpha_j + \beta_1 x_{i1} + \beta_2 x_{i2} + \beta_3 x_{i3})}{1 + \exp(\alpha_j + \beta_1 x_{i1} + \beta_2 x_{i2} + \beta_3 x_{i3})}$$

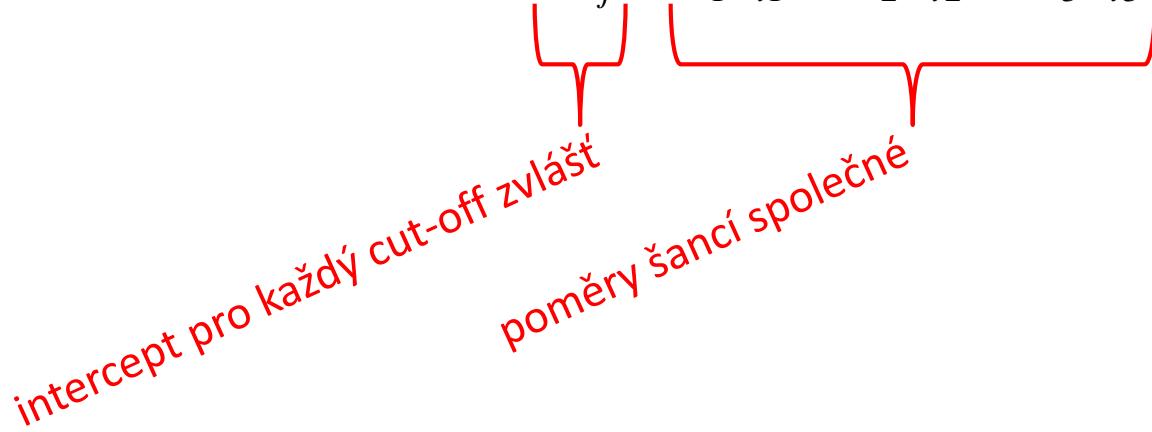
# Proporcionalita

- ➔ Model proporcionálních šancí pro kumulativní logit

$j = 1, 2, 3$

$$\eta_{i,j} = \text{logit}(q_{i,j}) = \ln\left(\frac{q_{i,j}}{1-q_{i,j}}\right) = \ln\left(\frac{\text{P}(Y_i \geq j)}{1-\text{P}(Y_i \geq j)}\right)$$

$$= \alpha_j + \beta_1 x_{i1} + \beta_2 x_{i2} + \beta_3 x_{i3}$$



# Proporcionalita

- ➔ Model proporcionálních šancí pro kumulativní logit

$j = 1, 2, 3$

$$\begin{aligned}\eta_{i,j} &= \text{logit}(q_{i,j}) = \ln\left(\frac{q_{i,j}}{1-q_{i,j}}\right) = \ln\left(\frac{\text{P}(Y_i \geq j)}{1-\text{P}(Y_i \geq j)}\right) \\ &= \alpha_j + \beta_1 x_{i1} + \beta_2 x_{i2} + \beta_3 x_{i3}\end{aligned}$$

- ➔ odhadnuté pravděpodobnosti

$$p_{i,3} = q_{i,3}$$

$$p_{i,2} = q_{i,2} - q_{i,3}$$

$$p_{i,1} = q_{i,1} - q_{i,2}$$

$$p_{i,0} = 1 - q_{i,1}$$

# Interpretace

Výsledek modelování: závislost stadia fibrózy na krevních markerech

Byla provedena log2 transformace markerů – odhadujeme účinek  
zdvojnásobení jejich hodnot

Marker	Effect of Doubling	Effect of 1 SD on log-scale	P-Value
ha	1.48 (1.07, 2.04)	1.52	0.019
p3np	2.28 (1.37, 3.79)	1.69	0.0016
ykl40	1.72 (1.24, 2.39)	1.46	0.0011

- ➔ všechny markery jsou spojeny se stadiem choroby
- ➔ zdvojnásobení hodnoty markeru ykl40 dává o 72% vyšší šanci fibrózy vyššího stadia

Andersen & Skovgaard, 2010

# **Logistický a Poissonův model**

---

**Závěr**

# Co byste měli vědět a umět po dnešní hodině ?

- ➔ Chápat princip analýzy deviation
- ➔ Umět na definovat Poissonův model a popsát jeho užití
- ➔ Znát interpretaci probíraných modelů a jejich koeficientů
- ➔ Umět vysvětlit pojem overdispersion – čím je způsobena a jak ji poznat a řešit
- ➔ Znát základní možnosti modelování ordinálních výsledků

# **Dodatky ke zobecněným lineárním modelům**

---

## **Cvičení**

➔ V adresáři naleznete článek:

Lee a kol.: Predicting Mortality Among Patients Hospitalised for Heart Failure

➔ Úkoly:

1. Co představuje závisle proměnnou (výsledek)?
2. Jaký model byl využit pro modelování vztahu mezi prediktory a výsledkem?
3. Jaká byla modelovací strategie pro výběr prediktorů?
4. Byla ověřena celková shoda mezi pozorovanými a predikovanými odhady rizika (kalibrace)? Jak?
5. Najděte některé odlišnosti ve výsledcích univariátní a multivariátní analýzy?
6. Jak interpretujete výsledky multivariátního modelu (tabulka 3)?