

# Bayesiánská analýza

## IX. Modely kvalitativních a omezených vysvětlujících proměnných

# Obsah tématu

- 1 Jednorozměrné modely
- 2 Model omezených dat – tobit
- 3 Model binární volby – probit
- 4 Uspořádaný probit
- 5 Multinomiální probit
- 6 Rozšíření

- Normální lineární regresní model – omezující (předpoklad normality).
- Kvalitativní vysvětlovaná proměnná.
- Omezená vysvětlovaná proměnná.
- Zavedení latentních dat (mají normální rozdělení).
- Příklady: ekonomie dopravy, ekonomie práce, analýza investiční aktivity firem.

# Obsah tématu

- 1 **Jednorozměrné modely**
- 2 Model omezených dat – tobit
- 3 Model binární volby – probit
- 4 Uspořádaný probit
- 5 Multinomiální probit
- 6 Rozšíření

# Značení

- Vysvětlovaná proměnná  $y^* = (y_1^*, \dots, y_N^*)'$ .

$$y_i^* = x_i' \beta + \epsilon_i.$$

- $x_i = (1, x_{i2}, \dots, x_{ik})'$ .

- Maticově:

$$y^* = X\beta + \epsilon.$$

# Náhodná složka

- 1  $\epsilon$  z vícerozměrného normálního rozdělení se střední hodnotou  $0_N$  a kovarianční maticí  $h^{-1}I_N$ ,
- 2 všechny prvky matice  $X$  jsou pevná čísla (tj. nenáhodné veličiny). Pro náhodné veličiny jsou prvky  $X$  nezávislé na všech prvcích vektoru  $\epsilon$ ;  $p(X|\lambda)$ , kde  $\lambda$  neobsahuje  $\beta$  ani  $h$ .

# Princip odhadu

- Pokud  $y^*$  pozorovatelné – standardní analýza.
- $y^*$  obsahuje latentní data **nějak** propojena s  $y$ .
- Pro „funkčnost“ metod:  $p(\beta, h|y^*, y) = p(\beta, h|y^*)$  (v případě přirozeně konjugované apriorní hustoty) resp.  
 $p(\beta|y^*, y, h) = p(\beta|y^*, h)$  a  $p(h|y^*, y, \beta) = p(h|y^*, \beta)$  (nezávislá apriorní hustota).
- Pokud pozorujeme  $y^*$ , nepřinese dodatečné pozorování  $y$  žádnou novou informaci.
- Standardní posteriorní simulace (Gibbsův vzorkovač): výběry z  $p(\beta, h|y^*)$  a  $p(y^*|y, \beta, h)$  resp.  $p(\beta|y^*, h)$ ,  $p(h|y^*, \beta)$  a  $p(y^*|y, \beta, h)$ .
- Vše kromě  $p(y^*|y, \beta, h)$  umíme generovat.

# Obsah tématu

- 1 Jednorozměrné modely
- 2 Model omezených dat – tobit**
- 3 Model binární volby – probit
- 4 Uspořádaný probit
- 5 Multinomiální probit
- 6 Rozšíření



# Vztah nepozorovaných a pozorovaných dat

- Příklad požadovaných investic.

$$y_i = y_i^* \quad \text{pokud} \quad y_i^* > 0$$

$$y_i = 0 \quad \text{pokud} \quad y_i^* \leq 0$$

- Pokud známe  $y^*$ , známe  $y \Rightarrow p(\beta, h|y^*) = p(\beta, h|y, y^*)$ .

# Posterioční hustota

- Nezávislost latentních proměnných (stejně jako pozorovaná):

$$y_i = y_i^* \quad \text{pokud } y_i^* > 0$$

$$y_i = 0 \quad \text{pokud } y_i^* \leq 0$$

- Využíváme omezené normální rozdělení (vycházíme z předpokladu nepodmíněné normality  $y_i^*$ ).

$$y_i^* = y_i \quad \text{pokud } y_i > 0$$

$$y_i^* | y_i, \beta, h \sim N(x_i' \beta, h^{-1}) 1(y_i^* < 0) \quad \text{pokud } y_i = 0$$

- Standardní analýza + možnost zobecnění pro omezující bod  $c$  (rozšíření i pro neznámý parametr).

# Empirická ilustrace

- BUDE ČASEM DOPLNĚNO!

# Obsah tématu

- 1 Jednorozměrné modely
- 2 Model omezených dat – tobit
- 3 Model binární volby – probit**
- 4 Uspořádaný probit
- 5 Multinomiální probit
- 6 Rozšíření

# Úvod

- Předpoklad rozhodování mezi dvěma alternativami.
- $U_{ij}$  užitek jednotlivce  $i$  (pro  $i = 1, \dots, N$ ) z volby  $j$  (pro  $j = 0, 1$ ).
- Pravidlo: volba 1 pokud  $U_{1i} \geq U_{0i}$  a volba 0 jinak.
- Výběr závisí na rozdílu v užitech:

$$y_i^* = U_{1i} - U_{0i}.$$

# Probit model

- Diference v užžití odpovídá normálnímu lineárnímu regresnímu modelu.
- Závislost na pozorovaných charakteristikách  $x_i$ .
- Random utility model.

$$\begin{aligned}y_i &= 1 && \text{pokud } y_i^* \geq 0 \\y_i &= 0 && \text{pokud } y_i^* < 0\end{aligned}$$

- Pokud známe  $y^*$ , známe  $y \Rightarrow p(\beta, h|y^*) = p(\beta, h|y, y^*)$ .

# Posteriorní hustota

- Z nezávislosti:

$$p(y^*|y, \beta, h) = \prod_{i=1}^N p(y_i^*|y_i, \beta, h)$$

- Předpoklad normální lineární regrese  $\rightarrow p(y_i^*|\beta, h)$  normální.
- Kombinace s informací o  $y_i \rightarrow p(y_i^*|y_i, \beta, h)$ :

$$y_i^*|y_i, \beta, h \sim N(x_i'\beta, h^{-1})1(y_i^* \geq 0) \quad \text{pokud } y_i = 1$$

$$y_i^*|y_i, \beta, h \sim N(x_i'\beta, h^{-1})1(y_i^* < 0) \quad \text{pokud } y_i = 0$$

# Pravděpodobnosti volby

- Pro dané parametry:

$$\begin{aligned}\Pr(y_i = 1|\beta, h) &= \Pr(y_i^* \geq 0|\beta, h) \\ &= \Pr(x_i'\beta + \epsilon_i \geq 0|\beta, h) = \Pr(\sqrt{h}\epsilon_i \geq -\sqrt{h}x_i'\beta|\beta, h)\end{aligned}$$

- Díky normalitě – poslední člen jedna mínus kumulativní distribuční funkce standardního normálního rozdělení (tj.  $\sqrt{h}\epsilon_i$  odpovídá  $N(0, 1)$ ).
- Značení  $\Phi(a)$  pro CDF  $\rightarrow 1 - \Phi(-\sqrt{h}x_i'\beta)$ .
- Standardní analýza (funkce parametrů).



# Identifikační problém

- Více kombinací hodnot parametrů modelu vede ke stejné hodnotě věrohodnostní funkce.
- Probit: nekonečný počet hodnot parametrů  $\beta$  a  $h$  vede k témuž modelu.
- $\Pr(x_i' \beta + \epsilon_i \geq 0 | \beta, h) = \Pr(x_i' c \beta + c \epsilon_i \geq 0 | \beta, h)$  pro jakoukoli kladnou konstantu  $c$ .
- Transformovaná náhodná veličina  $c \epsilon_i$  má rozdělení  $N(0, c^2 h^{-1}) \rightarrow$  totožné probit modely s jinými koeficienty a přesností chyb.
- Alternativně: hodnoty věrohodnostní funkce stejné pro  $(\beta = \beta_0, h = h_0)$  a  $(\beta = c \beta_0, h = \frac{h_0}{c^2})$ .
- Nelze rozlišit odděleně  $\beta$  a  $h$  (jen identifikace  $\beta \sqrt{h}$ ).
- Řešení: nastavení  $h = 1$  (preferováno) nebo některý z  $\beta$  na 1 (apriorní kladný vliv této proměnné na pravděpodobnost!).

# Empirická ilustrace

- BUDE ČASEM DOPLNĚNO!

# Obsah tématu

- 1 Jednorozměrné modely
- 2 Model omezených dat – tobit
- 3 Model binární volby – probit
- 4 Uspořádaný probit**
- 5 Multinomiální probit
- 6 Rozšíření

# Úvod

- Vysvětlované proměnné kvalitativní (dobrý, průměrný, slabý), ale uspořádatelné.
- Klíčový vztah mezi (vektory)  $y^*$  a  $y$  ( $y_i$  má hodnoty  $j = 1, \dots, J$ ;  $J$  je počet uspořádaných alternativ):

$$y_i = j \quad \text{pokud} \quad \gamma_{j-1} < y_i^* \leq \gamma_j,$$

- $\gamma = (\gamma_0, \gamma_1, \dots, \gamma_J)'$  je vektor parametrů, kde  $\gamma_0 \leq \dots \leq \gamma_J$ .
- Normalita regresního modelu pro latentní data:

$$\begin{aligned} \Pr(y_i = j | \beta, \gamma) &= \Pr(\gamma_{j-1} < y_i^* \leq \gamma_j | \beta, \gamma) \\ &= \Pr(\gamma_{j-1} < x_i' \beta + \epsilon_i \leq \gamma_j | \beta, \gamma) \\ &= \Pr(\gamma_{j-1} - x_i' \beta < \epsilon_i \leq \gamma_j - x_i' \beta | \beta, \gamma). \end{aligned}$$

- $\epsilon_i$  z  $N(0, 1)$  (z důvodu identifikace  $h = 1$ ):

$$\Pr(y_i = j | \beta, \gamma) = \Phi(\gamma_j - x_i' \beta) - \Phi(\gamma_{j-1} - x_i' \beta)$$

# Problém identifikace

- Uspořádaný probit: pravděpodobnosti volby na základě normálního rozdělení a volba  $\gamma_0, \dots, \gamma_J$  pro rozdělení pravděpodobností mezi všechny možnosti volby.
- Potřeba více omezení: např. pro  $J = 3$  máme normální rozdělení s volbou střední hodnoty ( $x_i' \beta$ ) a čtyři body (tj.  $\gamma_0, \gamma_1, \gamma_2$  a  $\gamma_3$ ).
- $x_i$  jen úrovněová konstanta a chceme  $\Pr(y_i = 1 | \beta, \gamma) = 0.025$ ,  $\Pr(y_i = 2 | \beta, \gamma) = 0.95$  a  $\Pr(y_i = 3 | \beta, \gamma) = 0.025$ .
- Řešení:  $\beta = 0$ ,  $\gamma_0 = -\infty$ ,  $\gamma_1 = -1.96$ ,  $\gamma_2 = 1.96$  a  $\gamma_3 = \infty$  nebo  $\beta = 1$ ,  $\gamma_0 = -\infty$ ,  $\gamma_1 = -0.96$ ,  $\gamma_2 = 2.96$  a  $\gamma_3 = \infty$  atd.
- Obvyklé řešení problému identifikace:  $\gamma_0 = -\infty$ ,  $\gamma_1 = 0$  a  $\gamma_J = \infty$ .

# Problém identifikace a další intuice

- Alternativně: probit model pro  $J = 2 \Rightarrow \gamma_0 = -\infty, \gamma_1 = 0$  a  $\gamma_2 = \infty$ .
- $y^*$  jako užitek  $\rightarrow$  pravděpodobnosti volby jako integrály na sekvenčních oblastech normálního rozdělení.
- Při mírném zvýšení užitku možnost přechodu jen do sousední kategorie (předpoklad uspořádání alternativ)  $\times$  jinak multinomiální probit.

# Bayesovská analýza I

- Gibbsův vzorkovač s obohacenými daty:  $p(\beta|y^*, \gamma)$ ,  $p(\gamma|y^*, y, \beta)$  a  $p(y^*|y, \beta, \gamma)$ .
- Standardní posteriorní hustoty pro  $\beta$  ( $h = 1$ ),  $p(y_i^*|y_i, \beta, \gamma)$ :

$$y_i^*|y_i = j, \beta, \gamma \sim N(x_i'\beta, 1)1(\gamma_{j-1} < y_i^* \leq \gamma_j).$$

- Podmíněná hustota pro  $\gamma$ ,  $p(\gamma|y_i^*, y_i, \beta)$ .
- Nepravá apriorní hustota (možnost i jiných priorů s mírnými modifikacemi výsledku):  $p(\gamma_j) \propto c$  (zjednodušuje výběr  $\gamma$  v jednom běhu).
- Z volby  $\gamma_0 = -\infty$ ,  $\gamma_1 = 0$  a  $\gamma_J = \infty$ :  $p(\gamma_j|y^*, y, \beta, \gamma_{(-j)})$  pro  $j = 2, \dots, J - 1$ .
- Označení  $\gamma_{(-j)}$ : vektor  $\gamma$  bez prvku  $\gamma_j$ .

$$\gamma_{(-j)} = (\gamma_0, \dots, \gamma_{j-1}, \gamma_{j+1}, \dots, \gamma_J)'$$

# Bayesovská analýza II

- $p(\gamma_j | y^*, y, \beta, \gamma_{(-j)})$  snadno odvoditelná  $\rightarrow$ .
  - 1 Hustota podmíněna vektorem  $\gamma_{(-j)} \Rightarrow \gamma_j$  musí ležet v  $[\gamma_{j-1}, \gamma_{j+1}]$ .
  - 2 Hustota podmíněna vektorem  $y$  a  $y^* \Rightarrow$  lze vyvodit jaké hodnoty latentních dat odpovídají příslušným hodnotám skutečných dat.
  - 3 V argumentech podmíněné hustoty není přítomna žádná další informace o  $\gamma_j$ .

- Rovnoměrné rozdělení:

$$\gamma_j | y^*, y, \beta, \gamma_{(-j)} \sim U(\bar{\gamma}_{j-1}, \bar{\gamma}_{j+1})$$

- Pro  $j = 2, \dots, J - 1$ , kde

$$\bar{\gamma}_{j-1} = \max \{ \max \{ y_i^* : y_i = j \}, \gamma_{j-1} \}$$

$$\bar{\gamma}_{j+1} = \min \{ \min \{ y_i^* : y_i = j + 1 \}, \gamma_{j+1} \}$$

- $\max \{ y_i^* : y_i = j \}$  označuje maximální hodnotu latentních dat mezi všemi jednotlivci, kteří si zvolili alternativu  $j$  (analogicky  $\min \{ y_i^* : y_i = j + 1 \}$ ).



# Obsah tématu

- 1 Jednorozměrné modely
- 2 Model omezených dat – tobit
- 3 Model binární volby – probit
- 4 Uspořádaný probit
- 5 Multinomiální probit**
- 6 Rozšíření

# Úvod

- Více alternativ volby.
- $y_i$  pro  $\{j = 0, \dots, J\} \rightarrow J + 1$  alternativ, kdy  $J > 1$ .
- Motivace:  $U_{ji}$  je užitek  $i$ -tého jednotlivce volícího alternativu  $j$  (pro  $i = 1, \dots, N$  a  $j = 0, \dots, J$ ).
- Alternativa 0 jako základní volba a definujeme latentní proměnnou:

$$y_{ji}^* = U_{ji} - U_{0i}$$

pro  $j = 1, \dots, J$ .

- Multinomiální probit model předpokládá:

$$y_{ji}^* = x'_{ji}\beta_j + \epsilon_{ji}$$

- $x_{ji}$  je  $k_j$ -rozměrný vektor obsahující vysvětlující proměnné, které ovlivňují užitek spojený s volbou  $j$  (relativně vzhledem k volbě 0),  $\beta_j$  je odpovídající vektor regresních koeficientů a  $\epsilon_{ji}$  je chybový člen regrese.

## Značení I

- $J$  rovnic  $\Rightarrow$  simulátor pro SUR model v kombinaci s metodami poskytujícími výběry pro latentní rozdíly užiteků.
- Přepis do SUR modelu:  $y_i^* = (y_{1i}^*, \dots, y_{Ji}^*)'$ ,  $\epsilon_i = (\epsilon_{1i}, \dots, \epsilon_{Ji})'$ ,

$$\beta = \begin{pmatrix} \beta_1 \\ \cdot \\ \cdot \\ \beta_J \end{pmatrix} \quad X_i = \begin{pmatrix} x'_{1i} & 0 & \cdot & \cdot & 0 \\ 0 & x'_{2i} & 0 & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & 0 \\ 0 & \cdot & \cdot & 0 & x'_{Ji} \end{pmatrix}$$

- Definujeme  $k = \sum_{j=1}^J k_j$  a

$$y_i^* = X_i \beta + \epsilon_i$$

# Značení II

- Dále:

$$y^* = \begin{pmatrix} y_1^* \\ \cdot \\ \cdot \\ y_N^* \end{pmatrix} \quad \epsilon = \begin{pmatrix} \epsilon_1 \\ \cdot \\ \cdot \\ \epsilon_N \end{pmatrix} \quad X = \begin{pmatrix} X_1 \\ \cdot \\ \cdot \\ X_N \end{pmatrix}$$

- Model:

$$y^* = X\beta + \epsilon$$

## Další předpoklady

- $\epsilon_i$  nezávisle a stejnoměrně rozděleny,  $N(0, H^{-1})$  pro  $i = 1, \dots, N$ , kdy  $H$  je matice přesností chyb rozměrů  $J \times J$ .
- Alternativně:  $\epsilon$  odpovídá  $N(0, \Omega)$ , kde  $\Omega$  je blokově diagonální matice rozměru  $NJ \times NJ$ :

$$\Omega = \begin{pmatrix} H^{-1} & 0 & \cdot & \cdot & 0 \\ 0 & H^{-1} & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & 0 \\ 0 & \cdot & \cdot & 0 & H^{-1} \end{pmatrix}$$

- Vztah latentních a pozorovaných proměnných:

$$\begin{aligned} y_i &= 0 & \text{pokud} & & \max(y_i^*) < 0 \\ y_i &= j & \text{pokud} & & \max(y_i^*) = y_{ji}^* \geq 0 \end{aligned}$$

- $\max(y_i^*)$  je maximum  $J$ -rozměrného vektoru  $y_i^*$ .

# Posteriorní hustota

- Gibbsův vzorkovač:  $p(\beta|y^*, H)$  a  $p(H|y^*, \beta)$ , a jistou podobu vícerozměrného ohraničeného normálního rozdělení pro podmíněnou hustotu  $p(y^*|y, \beta, H)$ .
- Nezávislost chování mezi jendotlivci:

$$p(y^*|y, \beta, H) = \prod_{i=1}^N p(y_i^*|y_i, \beta, H)$$

- $p(y_i^*|\beta, H)$  odpovídá normální hustotě pravděpodobnosti + informace i  $y_i$ :

$$y_i^*|y_i, \beta, H \sim N(X_i'\beta, H^{-1})1(\max(y_i^*) < 0) \quad \text{pokud } y_i = 0$$

$$y_i^*|y_i, \beta, H \sim N(X_i'\beta, H^{-1})1(\max(y_i^*) = y_{ji}^* \geq 0) \quad \text{pokud } y_i = j$$

- Ekonometrická analýza mnoho let mimo oblast hlavního zájmu (jak z hlediska bayesovského, tak i klasického přístupu)  $\Leftrightarrow$  výpočetní obtíže vztahující se k ohraničenému normálnímu rozdělení.

# Bayesiánská analýza I

- $\beta$  a  $H$ : nezávislá normální-Wishartova apriorní hustota (využití výsledků pro SUR model).
- Problém identifikace: jednorozměrný probit model nastavoval  $h = 1$ .
- Multinomiální probit model: složitější.
- Kovarianční matice chyb  $\Sigma = H^{-1}$  a  $\sigma_{ij}$  jako  $ij$ -tý prvek matice  $\Sigma \rightarrow$  standardní způsob řešení identifikovatelnosti volbou  $\sigma_{11} = 1$ .
- Za těchto podmínek  $p(H|y^*, \beta)$  nebude odpovídat Wishartovu rozdělení a nelze tak využít výsledky analýzy SUR modelu.
- Možnost řešení (viz literatura): ignorovat problém a prezentovat výsledky pro  $\frac{\beta}{\sigma_{11}}$ .
- Práce s neidentifikovanými modely záludná  $\rightarrow$  nebezpečná práce s neinformativními apriorními hustotami (výpočetní problémy).
- Obvyklá bayesovská analýza multinomiálního probit modelu s využitím informativní apriorní hustoty ovšem s ignorováním identifikačních omezení.

# Bayesiánská analýza II

- McCulloch, Polson, Rossi (2000):  $\epsilon_j$  odpovídá  $N(0, \Sigma)$ .
- Rozdělení vektoru  $\epsilon_j$  do podoby

$$\epsilon_j = \begin{bmatrix} \epsilon_{1j} \\ v_j \end{bmatrix}$$

kde  $v_j = (\epsilon_{2j}, \dots, \epsilon_{Jj})'$ .

- Rozdělení matice  $\Sigma$ :

$$\Sigma = \begin{bmatrix} \sigma_{11} & \delta' \\ \delta & \Sigma_v \end{bmatrix}$$



# Bayesiánská analýza III

- Zákony pravděpodobnosti:  $p(\epsilon_i) = p(\epsilon_{1i})p(v_i|\epsilon_{1i})$ .
- Z vlastností vícerozměrného rozdělení:

$$\begin{aligned}\epsilon_{1i} &\sim N(0, \sigma_{11}) \\ v_i|\epsilon_{1i} &\sim N\left(\frac{\delta}{\sigma_{11}}\epsilon_{1i}, \Phi\right),\end{aligned}$$

- $\Phi = \Sigma_v - \frac{\delta\delta'}{\sigma_{11}}$ .
- Místo s maticí  $\Sigma$  rozměru  $J \times J$  pracujeme s parametry  $\sigma_{11}$ ,  $\delta$  a  $\Phi \rightarrow$  nastavení  $\sigma_{11} = 1$  a volba apriorní hustoty pro  $\delta$  a  $\Phi$ .

# Bayesiánská analýza III

- Obvykle normální apriorní hustota pro  $\delta$  a Wishartova apriorní hustotu pro  $\Phi^{-1}$ .

$$p(\delta, \Phi^{-1}) = p(\delta)p(\Phi^{-1})$$

$$p(\delta) = f_N(\delta | \underline{\delta}, \underline{V}_\delta)$$

$$p(\Phi^{-1}) = f_W(\Phi^{-1} | \underline{\nu}_\Phi, \underline{\Phi}^{-1})$$

- Podmíněné posteriorní hustoty:

$$p(\delta | y^*, \Phi, \beta) = f_N(\delta | \bar{\delta}, \bar{V}_\delta)$$

$$p(\Phi^{-1} | y^*, \delta, \beta) = f_W(\Phi^{-1} | \bar{\nu}_\Phi, \bar{\Phi}^{-1})$$

# Bayesiánská analýza III

- Posteriorní parametry:

$$\bar{V}_\delta = \left( \underline{V}_\delta^{-1} + \Phi^{-1} \sum_{i=1}^N \epsilon_{1i}^2 \right)^{-1}$$

$$\bar{\delta} = \bar{V}_\delta \left( \underline{V}_\delta^{-1} \underline{\delta} + \Phi^{-1} \sum_{i=1}^N v_i \epsilon_{1i} \right)$$

$$\bar{\Phi}^{-1} = \left[ \underline{\Phi} + \sum_{i=1}^N (v_i - \epsilon_{1i} \delta)(v_i - \epsilon_{1i} \delta)' \right]^{-1}$$

$$\bar{v}_\Phi = \underline{v}_\Phi + N$$

- Podmíněné hustoty  $\rightarrow \epsilon_i = (\epsilon_{1i}, v_i')$  známý vektor.
- Kritika multinomiálního probitu kvůli přeparametrizaci v důsledku mnoha alternativ ( $\Sigma$ )  $\rightarrow$  nepřesné odhady.
- Informativní priory pro dodatečnou strukturu: např. diagonální  $\Sigma$  (pokud rozumné, zjednodušení výpočtu a řešení přeparametrizace).

# Empirická ilustrace

- BUDE ČASEM DOPLNĚNO!

# Obsah tématu

- 1 Jednorozměrné modely
- 2 Model omezených dat – tobit
- 3 Model binární volby – probit
- 4 Uspořádaný probit
- 5 Multinomiální probit
- 6 Rozšíření**

# Varianty probit a tobit

- Panelová data pro probit:

$$y_{it}^* = x_{it}'\beta_i + \epsilon_{it}$$

- Metody z části věnované panelovým datům.
- Panelový multinomiální probit model s náhodnými koeficienty: odvození v rámci multinomiálního probit modelu, modelu náhodných koeficientů a SUR modelu.
- Multinomiální časový probit model (*multinomial multiperiod probit model*): řešení problému autokorelace.
- Modulární podstata nástrojů (kombinovatelnost): nelineárnost vztahů, heteroskedasticita (jak pro probit tak i pro tobit).

# Další varianty

- Lineární regresní modly s jiným rozdělením náhodných chyb.
- Vysvětlovaná proměnná počet: Poissonovo rozdělení.
- Vysvětlovaná proměnná doba trvání: Weibullovo rozdělení.
- Modely volby logit: logistické rozdělení.
- Řádivý uspořádaný logit (rank ordered logit), multinomiální logit (preferován při více alternativách – výpočetní nenáročnost).

# Nezávislost irelevantních alternativ

- Předpoklad použití multinomiálního logitu (ne vždy splněná vlastnost)!
- Podíly šancí se s přidáním alternativy nemění.
- Dopravní příklad: auto ( $Y = 0$ ), veřejná doprava ( $Y = 1$ ), kolo ( $Y = 2$ ).
- Porušení: auto ( $Y = 0$ ), červený autobus ( $Y = 1$ ), modrý autobus ( $Y = 2$ ).
- Řešení skrze vnořený (nested) logit model: nejdříve auto  $\times$  hromadná doprava  $\rightarrow$  po volbě hromadné dopravy logit pro červený  $\times$  modrý autobus.