

# Biometrické metody v genetice, odhadů genetických parametrů

## - lineární modely

prof. Ing. Tomáš Urban, Ph.D.  
[urban@mendelu.cz](mailto:urban@mendelu.cz)



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

Tato prezentace je spolufinancována  
Evropským sociálním fondem  
a státním rozpočtem České republiky

## Proč biometrické metody v genetice

### Cíle

- Popsat genetickou strukturu populací (odhad komponent variance a kovariance) a popsat změny genetické výstavby populací
- Na znalosti genetické struktury populací jsou založeny šlechtitelské programy

### Možnosti biometrických metod:

1. Odhady výkonnosti populací – čistokrevné i hybridní
2. odhady genetických parametrů -  $h^2$ ,  $r_{op}$ ,  $r_G$ , ...
3. odhady plemenné hodnoty (PH) – rozdíly mezi jedincem a vrstevníky, očištěný od negenetických vlivů (realizace šlecht. programů)
4. Stanovení selekčního (genetického) zisku
5. Optimalizace selekčních a hybridizačních programů

Uplatnění poznatků: molekulární a biochemické genetiky, cytogenetiky, imunogenetiky a genové manipulace v genetice populací



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

Tato prezentace je spolufinancována  
Evropským sociálním fondem  
a státním rozpočtem České republiky

# Kvantitativní genetik – hodnocení pomocí modelů

## Biometrika v genetice ( $\approx$ kvantitativní genetik)

Účinek polygenů se sleduje na základě počtu pravděpodobnosti (hromadné jevy).

Společné efekty více genů vytváří proměnlivost, většinou s normálním rozdělením, kterou lze analyzovat matematicko-statistickými operacemi.

Teorie: přenos GI u kvantitativních vlastností je **polygenní (velký počet lokusů s mendelistickým přenosem + větší či menší vliv prostředí - vnitřní a vnější)**.

Operační metody pro analýzu přenosu této GI: **biometrické**.



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

Tato prezentace je spolufinancována  
Evropským sociálním fondem  
a státním rozpočtem České republiky

## Analýza variance (ANOVA)

Funkce ANOVA (Fisher 1918):

1. odhad pevných efektů
2. odhad komponent (složek) variance – podíl jednotlivých variancí, např. varianci genotypovou nebo prostředí
3. testování hypotéz o příčinách variance modelem (jak vznikla, velikost vlivu faktorů)

$$\sigma_{celková}^2 = \sigma_1^2 + \sigma_2^2 + \dots + \sigma_k^2$$

ANOVA nebalancované metody	speciální případ nebalancovaných metod ↔	Balancované metody –výjimečné –speciální případ nebalancované metody
1. velké systém rovnic s využitím matic 2. nelze realizovat podle plánu – náhodný efekt (využití u zvířat) 3. hodnotí se chovy, šlechtění (software: Harvey, SAS, BMPD) – <b>metody nejmenších čtverců, maximální věrohodnosti</b>		1. přesnější 2. plánované pokusy (u zvířat toho nelze dosáhnout)
1. otec má 100 potomků, 2. jich má 50 a 3. 10 → to je nebalancované		- stejný počet pozorování ve všech podtřídách

# Biometrické modely - lineární

Biometrické metody spočívají na lineárních biometrických modelech.

## Pravdivý (skutečný, teoretický) model

popisuje data přesně, bez reziduální nebo nevysvětlené variance. Variance  $P$  je vyčerpána faktory. Pravdivý model není nikdy přesně znám.

## Ideální (praktický) model

je vytvořen výzkumníkem, který je tak blízký skutečnému modelu, jak jen to je možné. Takový model by se měl používat k analýzám, ale často není dostatek informací (chybí).

## Operační (pracovní, proveditelný) model

je zjednodušená forma ideálního modelu a je využíván výzkumníky v analýzách. Na této úrovni se vede široká diskuse o nejlepší operační model.



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

Tato prezentace je spolufinancována  
Evropským sociálním fondem  
a státním rozpočtem České republiky

## Pozorování

Vektor pozorování  $y$  obsahuje prvky vyplývající z měření vlastnosti v daných jednotkách

- předpoklad – že se jedná o náhodný výběr z nekonečně velké populace

## Efekty

- \* Efekty (faktory) se vztahují k proměnným, které mohou ovlivňovat nebo být ve vztahu k prvkům ve vektoru pozorování
- \* *Diskrétní efekty* mají obvykle třídy nebo úrovně
- \* „obtěžující efekty“ - musí být zahrnuty → minimalizace  $e$



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

Tato prezentace je spolufinancována  
Evropským sociálním fondem  
a státním rozpočtem České republiky

# Pevné a náhodné efekty

**Pevné efekty** (fixní) jsou ty, v kterých úrovně zahrnují všechny možné úrovně, které lze pozorovat.

**Náhodné efekty** jsou efekty, jejichž úrovně jsou považovány za náhodně vybrané z nekonečně velké populace úrovní.

1. *Kolik úrovní má efekt v modelu?* Jestliže málo, pak je to pravděpodobně pevný efekt, jestliže mnoho, pak se jedná o náhodný efekt.
2. *Je počet úrovní efektu v populaci dost velký na to, aby mohla být považována za nekonečnou?* Jestliže ano, pak je pravděpodobně efekt náhodný.
3. *Budou použity opět stejné úrovně, jestliže by byl experiment opakován podruhé?* Jestliže ano, pak se jedná pravděpodobně o pevný efekt.
4. *Byly úrovně efektu určeny nenáhodným způsobem?* Jestliže ano, pak by měl být efekt určen jako pevný.



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

Tato prezentace je spolufinancována  
Evropským sociálním fondem  
a státním rozpočtem České republiky

## Modely

Lineární modely obsahují řadu efektů (faktorů), které aditivně ovlivňují pozorování

V tradičním smyslu jsou lineární modely složeny ze tří částí:

1. Rovnice.
2. Matice očekávaných hodnot a variančně kovarianční matice náhodných proměnných.
3. Předpoklady a omezení.

### ad 1. Rovnice

Rovnice modelu definuje efekty, které mohou mít vliv na pozorovanou vlastnost. Čím více faktorů pokryjeme, tím je výpočet přesnější, tím více se blížíme k variabilitě způsobenou genotypem.

Lineární funkce určitých parametrů a proměnných:

$$y_{ij} = \mu + b_i + u_j + e_{ijk} \quad y = Xb + Zu + e$$

### ad 2. Matice očekávaných hodnot a VCV

$$E \begin{bmatrix} y \\ u \\ e \end{bmatrix} = \begin{bmatrix} Xb \\ 0 \\ 0 \end{bmatrix} \quad V \begin{bmatrix} u \\ e \end{bmatrix} = \begin{bmatrix} G & 0 \\ 0 & R \end{bmatrix}$$

kde  $G$  a  $R$  jsou základní čtvercové matice s předpokladem nesingularity a pozitivní definovanosti a s prvky, které jsou známé. Takže:  $V(y) = ZGZ' + R$ .

### ad 3. Předpoklady a omezení

informace o datech nebo způsob sběru, náhodnost výběru, podmínkách chovu apod.



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

Tato prezentace je spolufinancována  
Evropským sociálním fondem  
a státním rozpočtem České republiky

# Typy lineárních modelů

## Lineární modely (obecně)

$$y_{ij} = \mu + a_i + e_{ij} \quad e_{ij} \sim N(0, \sigma_e^2); a_i = \text{faktor s } i\text{-tými úrovněmi}$$

## Regresní modely – funkční vztahy

$$y_i = a + bX_i + e_i \quad a - \text{konstanta, } b, \text{ regresní koef., } a, b \text{ odhadujeme MNC nebo MV}$$

## Mnohonásobné regresní vztahy

$$y_i = a + b_1X_{1i} + b_2X_{2i} + b_3X_{3i} + e_i$$

## Modely s pevnými efekty (více faktorové)

$$y_{ijkl} = \mu + a_i + b_j + c_k + e_{ijk}, \quad y_{ijk} = \mu + a_i + b_{ij} + e_{ijk}$$

## Modely s náhodnými efekty

$$y_{ijkl} = \mu + \alpha_i + \beta_j + \gamma_k + e_{ijk} \quad \alpha_i \sim N(0, \sigma_\alpha^2)$$

## Modely se smíšenými efekty

$$y_{ijk} = \mu + a_i + \beta_j + e_{ijk}$$

### smíšené modely se používají k odhadu PH

Komplikují odhad komponent variance

Komplikují odhad fixních efektů



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

Tato prezentace je spolufinancována  
Evropským sociálním fondem  
a státním rozpočtem České republiky

# Vyjádření modelů maticovým zápisem

## Skalární zápis modelu s pevnými efekty:

$$y_{ijk} = \mu + a_i + b_j + e_{ijk}$$

jedna pozorovaná hodnota (zastupuje všechny pozor. hodnoty) je symbolicky znázorněna

## Maticový model s pevnými efekty, kde jsou vyjádřeny všechny pozorované hodnoty

$$\mathbf{y} = \mathbf{Xb} + \mathbf{e}$$

$\mathbf{y}$  – vektor pozorování

$\mathbf{X}$  – incidenční matice (designová, strukturní matice) – uvádí, které pevné efekty jsou obsaženy v  $\mathbf{y}$

$\mathbf{b}$  – vektor odhadovaných parametrů

$\mathbf{e}$  – vektor náhodných efektů:  $\mathbf{e} \sim N(0, I \sigma_e^2)$



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

Tato prezentace je spolufinancována  
Evropským sociálním fondem  
a státním rozpočtem České republiky

# Vybalancovaný pokus

Analýza množství tuku v mléce u 18 dojnic s vlivem efektů stáda a věku:

$a_i$  – stádo ( $i = 1, 2$ );  $b_j$  – věk ( $j = 1, 2, 3$ )

		věk			průměr	
		$b_1$	$b_2$	$b_3$		
stádo	$a_1$	165	136	161	<b>147,78</b>	
		154	116	157		
		148	128	165		
	$a_2$	168	115	112		<b>138,11</b>
		154	142	118		
		120	186	128		
<b>průměr</b>		<b>151,50</b>	<b>137,17</b>	<b>140,17</b>	<b>142,94</b>	

$$\hat{a}_i = \bar{y}_{i..} - \bar{y}...$$

$$\hat{b}_j = \bar{y}_{.j.} - \bar{y}...$$

$$\hat{\mu}_j = \bar{y}...$$

$$a_1 = 4,83$$

$$b_1 = 8,56$$

$$a_2 = -4,83$$

$$b_2 = -5,78$$

$$b_3 = -2,78$$

**Ověřit v SAS !**



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

Tato prezentace je spolufinancována  
Evropským sociálním fondem  
a státním rozpočtem České republiky

The GLM Procedure		
Class Level		
Information	Class	Levels
Values	a	2 1 2
	b	3 1 2 3
Number of observations 18		

Dependent Variable: y					
Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model	3	1106.277778	368.759259	0.71	0.5608
Error	14	7250.666667	517.904762		
Corrected Total	17	8356.944444			
R-Square	Coeff Var	Root MSE	y Mean		
0.132378	15.92054	22.75752	142.9444		
Source	DF	Type IV SS	Mean Square	F Value	Pr > F
a	1	420.5000000	420.5000000	0.81	0.3828
b	2	685.7777778	342.8888889	0.66	0.5312

Aritm. průměr

BLUE / GLM

142,9444	$\mu$	142,94444	
147,7778	A1	4,8333333	147,778
138,1111	A2	-4,8333333	138,111
151,5	B1	8,5555556	151,500
137,1667	B2	-5,7777778	137,167
140,1667	B3	-2,7777778	140,167

GLM Procedure

Least Squares Means

a	y LSMEAN
1	147.777778
2	138.111111
b	y LSMEAN
1	151.500000
2	137.166667
3	140.166667



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

Tato prezentace je spolufinancována  
Evropským sociálním fondem  
a státním rozpočtem České republiky

# Nevybalancovaný pokus

Analýza množství tuku v mléce u 8 dojnic s vlivem efektů stáda a věku:  $a_i$  – stádo ( $i = 1, 2$ );  $b_j$  – věk ( $j = 1, 2, 3$ )

		věk		
		$b_1$	$b_2$	$b_3$
stádo	$a_1$	165 154	136	161
	$a_2$		115 142 186	112

$$\begin{bmatrix} y_{111} \\ y_{112} \\ y_{121} \\ y_{131} \\ y_{221} \\ y_{222} \\ y_{223} \\ y_{231} \end{bmatrix} \approx \begin{bmatrix} 165 \\ 154 \\ 136 \\ 161 \\ 115 \\ 142 \\ 186 \\ 112 \end{bmatrix} = \begin{bmatrix} \mu + a_1 + b_1 + e_{111} \\ \mu + a_1 + b_1 + e_{112} \\ \mu + a_1 + b_2 + e_{121} \\ \mu + a_1 + b_3 + e_{131} \\ \mu + a_2 + b_2 + e_{221} \\ \mu + a_2 + b_2 + e_{222} \\ \mu + a_2 + b_2 + e_{223} \\ \mu + a_2 + b_3 + e_{231} \end{bmatrix} = \begin{bmatrix} 1 & 1 & 0 & 1 & 0 & 0 \\ 1 & 1 & 0 & 1 & 0 & 0 \\ 1 & 1 & 0 & 0 & 1 & 0 \\ 1 & 1 & 0 & 0 & 0 & 1 \\ 1 & 0 & 1 & 0 & 1 & 0 \\ 1 & 0 & 1 & 0 & 1 & 0 \\ 1 & 0 & 1 & 0 & 1 & 0 \\ 1 & 0 & 1 & 0 & 0 & 1 \end{bmatrix} \cdot \begin{bmatrix} \mu \\ a_1 \\ a_2 \\ b_1 \\ b_2 \\ b_3 \end{bmatrix} + \begin{bmatrix} e_{111} \\ e_{112} \\ e_{121} \\ e_{131} \\ e_{221} \\ e_{222} \\ e_{223} \\ e_{231} \end{bmatrix}$$

$y \approx$   $y =$   $Xb + e$   $=$   $X$   $\cdot$   $b$   $+$   $e$

**$b = ?$**

Tato prezentace je spolufinancována Evropským sociálním fondem a státním rozpočtem České republiky

## 2. disperzní (variančně kovarianční, VCV) matice pozorování:

Předpoklad: každý náhodný efekt  $e_{ijk}$  je vybrán ze základního souboru s nulovým průměrem a variancí např. 30

$$V_e = \sigma^2 I = \begin{bmatrix} \sigma_{e_1}^2 & \sigma_{e_1 e_2} & \sigma_{e_1 e_3} & \dots & \dots \\ \sigma_{e_2 e_1} & \sigma_{e_2}^2 & \sigma_{e_2 e_3} & \dots & \dots \\ \sigma_{e_3 e_1} & \sigma_{e_3 e_2} & \sigma_{e_3}^2 & \dots & \dots \\ \dots & \dots & \dots & \dots & \dots \\ \dots & \dots & \dots & \dots & \dots \\ \dots & \dots & \dots & \dots & \dots \end{bmatrix} = \begin{bmatrix} 30 & & & & \\ & 30 & & & \\ & & 30 & & \\ & & & 30 & \\ & & & & 30 \end{bmatrix} = 30 \cdot \begin{bmatrix} 1 & & & & \\ & 1 & & & \\ & & 1 & & \\ & & & 1 & \\ & & & & 1 \end{bmatrix} = 30 I_8 = 30 I = \sigma^2 I$$

\* Maticový zápis:

- je méně názorný než data zapsaná v tabulce
- ALE je kratší a úplnější než model skalární
- musí se definovat matice X (Ta však při větším objemu dat může nabývat velikých rozměrů – nutná výkonná výpočetní technika a softwarové zázemí)

### The GLM Procedure

The GLM Procedure		
Class Level Information		
Class	Levels	
a	2	1 2
b	3	1 2 3
Number of observations		8

Dependent Variable: y

Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model	3	748.575000	249.525000	0.27	0.8465
Error	4	3733.300000	933.325000		
Corrected Total	7	4481.875000			

R-Square	Coeff Var	Root MSE	y Mean
0.167023	20.87130	30.55037	146.3750

Source	DF	Type III SS	Mean Square	F Value	Pr > F
a	1	198.4500000	198.4500000	0.21	0.6687
b	2	283.4500000	141.7250000	0.15	0.8638

Aritm. průměry

BLUE / GLM

146,375	$\mu$		145,867
154,00	A1	6,3	152,167
138,75	A2	-6,3	139,567
159,50	B1	7,33	153,200
144,75	B2	2,03	147,900
136,50	B3	-9,37	136,500

### GLM Procedure

#### Least Squares Means

a y LSMEAN

1	152.166667
2	139.566667

b y LSMEAN

1	153.200000
2	147.900000
3	136.500000



VZDĚLÁVÁNÍ  
financována  
ilním fondem  
ilím republiky

# Řešení nejmenších čtverců pro zobecněný lineární model (GLM)

$$y = Xb + e$$

$$(y - Xb)' (y - Xb) = e'e$$

$$y'y - 2(Xb)'y + (Xb)'Xb = e'e$$

derivace s ohledem, že  $b = 0 \rightarrow$  normální rovnice

$$(X'X) b = X'y$$

$$b = (X'X)^{-1} X'y \quad (V = I \sigma^2_E)$$

Modifikace (Jsou-li pozorování korelovaná a nemají-li stejné variance)

$$(X'V^{-1}X) b = X'V^{-1}y$$

$$b = (X'V^{-1}X)^{-1} X'V^{-1}y \quad (V = V)$$

Řešení poslední rovnice se nazývá řešení „zobecněných nejmenších čtverců“  $\rightarrow$  minimalizuje  $e'e$ .



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

Tato prezentace je spolufinancována  
Evropským sociálním fondem  
a státním rozpočtem České republiky



# Biometrické odhady genetických parametrů

Problémy aplikace kvantitativní genetiky na populace zvířat jsou ve skutečnosti problémy **statistických odhadů**

**Šlechtění** je založeno na **znalosti genetické struktury populací**, kterou *zatím* pro kvant. vlastnosti nelze určovat přímo (frekvence alel a genotypů)

⇒ nutné analyzovat efekty, příčiny genetické a prostředí, které se podílejí na celkové proměnlivosti

2 parametrů ⇒ **variance a kovariance.**

## Realizace

odhad PH jedince (**OPH**)

(*Estimate of Breeding Value* – **EBV**)

odhad genotypových hodnot skupin jedinců

- který z odhadů je nejlepší odhad ??



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

Tato prezentace je spolufinancována  
Evropským sociálním fondem  
a státním rozpočtem České republiky

## Nejlepší odhady

<b>BLUE</b>	<b>Best Linear Unbiased Estimators</b> - nejlepší lineární nevychýlené odhady (nejmenších čtverců)
<b>Nejlepší - Best</b>	- <b>nejlepší odhad průměru populace</b> = náhodný vzorek (reprezentativní, dostatečný počet), pak je nejlepším odhadem - <b>nejlepší odhad PH</b> - souhrnná PH = vložit do selekčního indexu, který hodnotí všechny PH pro všechny hodnocené vlastnosti; nejlepším odhadem je hodnota, která maximalizuje genetický zisk - <b>minimální variance</b> = metodou nejmenších čtverců (metoda odhadu), které minimalizují varianci, tyto odhady jsou nejlepší, ale i nestranné (nevychýlené) a lineární
Využíváme:	<b>lineární modely</b> – každý odhad je počítán jako lineární kombinace pozorovaných hodnot <b>nevychýlený</b> – při opakovaném odhadu je střední hodnota odhadu identická se skutečnými parametry

odhad  $\hat{b}$  je nevychýleným parametrem  $b$ , když  $E(\hat{b}) = b$

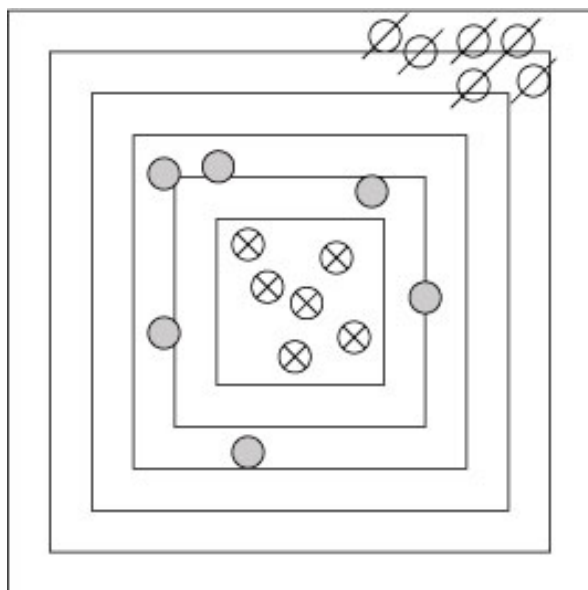


INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

Tato prezentace je spolufinancována  
Evropským sociálním fondem  
a státním rozpočtem České republiky

# Nevychýlenost (vyrovnanost) a přesnost (variabilita)

- (model terče)



- ⊘ - nepřesná (vychýlená) s nízkou variabilitou
- - přesná (nevychýlená) s velkou variabilitou
- ⊗ - přesná (nevychýlená) s nízkou variabilitou  
- nejlepší odhad

⇒ použít metodu BLUE - metoda odhadu nejmenších čtverců s pevnými efekty



Tato prezentace je spolufinancována Evropským sociálním fondem a státním rozpočtem České republiky

## Nejlepší předpovědi

<p><b>BLUP</b></p>	<ul style="list-style-type: none"> <li>- <b>Best Linear Unbiased Prediction</b></li> <li>- nejlepší lineární nevychýlená předpověď <b>NLNP</b> (metoda nejmenších čtverců)</li> <li>- metoda odhadu nejmenších čtverců <u>náhodných nebo smíšených modelů</u></li> </ul>
<p>smíšený model: mnohovlastnostní (multitrait)</p>	<p><b><math>y = Xb + Zu + e</math></b></p> <p><b>X, Z</b> – incidenční matice, udávající, které efekty jsou obsaženy v pozorování</p> <p><b>b</b> – vektor obsahující všechny fixní efekty (fixní genetické rozdíly a systematické vlivy prostředí)</p> <p><b>u</b> – vektor všech náhodných systematických efektů (stádo, rok, sezóna); obsahuje také OPH</p> <p><b>e</b> – náhodné nesystematické zbytkové efekty</p>
<p>Metody</p>	<p>Metoda nejmenších čtverců (LS) nebo zobecněných nejmenších čtverců (GLM), metoda maximální věrohodnosti (ML) nebo restringované maximální věrohodnosti (REML)</p>



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

Tato prezentace je spolufinancována Evropským sociálním fondem a státním rozpočtem České republiky

# Způsob řešení pro výběr odhadců je mnoho

Ve šlechtění se v současné době využívá metoda

- nejmenších čtverců (*least square* – LS)
- zobecněných nejmenších čtverců (*generalized least square* – GLM)
- metoda maximální věrohodnosti (*maximum likelihood* – ML)
- či její modifikovaná metoda restringované maximální věrohodnosti (REML)



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

Tato prezentace je spolufinancována  
Evropským sociálním fondem  
a státním rozpočtem České republiky

## Metody založené na ML

Maximum Likelihood (ML)

REstricted Maximum Likelihood (REML)

**maximilizuje pravděpodobnost pozorovaných dat daných parametrů**

nebalancovaná data

komplexní rodokmenová struktura (matice příbuznosti)

simultánní korekce pro fixní efekty

Vyžaduje známou distribuci (normální)

Odhady jsou nevychýlené a jsou vždy v parametrovém prostoru



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

Tato prezentace je spolufinancována  
Evropským sociálním fondem  
a státním rozpočtem České republiky

## Funkce hustoty pravděpodobnosti normálního rozdělení:

$$f(y) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\frac{(y-\mu)^2}{\sigma^2}}$$

Očekávané průměry  $E(y) = Xb$  a  $\text{var}(y) = V$

## Logaritmus věrohodnostní funkce:

$$L(b, V | X, y) = -\frac{1}{2} N \log(2\pi) - \frac{1}{2} \log(|V|) - \frac{1}{2} (y - Xb)' V^{-1} (y - Xb)$$

Rovnice dává pravděpodobnost parametrů  $(b, V)$  daných dat  $(X, y)$

Na pravé straně

první dva výrazy jsou očekávané hodnoty

**poslední výraz je součet čtverců**

**První derivace:**  $\delta(\log L) / \delta b = -2X'V^{-1}(y - Xb)$

**Derivace = 0**  $\hat{b} = (X'V^{-1}X)^{-1}X'V^{-1}y$  **Stejně jako pro LS odhady**



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

Tato prezentace je spolufinancována  
Evropským sociálním fondem  
a státním rozpočtem České republiky

## Příklad algoritmu REML

- 1 Řešení rovnic smíšeného modelu s a priori hodnotou komponent variance (poměr)

$$\begin{bmatrix} X'X & X'Z \\ Z'X & Z'Z + \lambda A^{-1} \end{bmatrix} \begin{bmatrix} \hat{b} \\ \hat{a} \end{bmatrix} = \begin{bmatrix} X'y \\ Z'y \end{bmatrix}$$

- 2 Řešení komponent variance z MME

$$\sigma_a^2 = [ \hat{a}' A^{-1} \hat{a} + \text{tr}(A^{-1}C) \sigma_e^2 ] / q$$

$$\sigma_e^2 = [ y'y - \hat{b}' X'y - \hat{a}' Z'y ] / (N - r(X))$$

Nové  $\lambda (= \sigma_e^2 / \sigma_a^2)$  a iterovat mezi 1 a 2



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

Tato prezentace je spolufinancována  
Evropským sociálním fondem  
a státním rozpočtem České republiky