

Genetika ve šlechtění zvířat

část 8. (rough draft version)

9 Odhad PH – BLUP AM

V animal modelu (AM) se hodnotí každé zvíře samostatně a současně v závislosti na užitkovosti příbuzných jedinců hodnocené populace. Veškeré příbuzenské vztahy (pokud jsou známé) jsou zahrnuty do aditivně genetické matice příbuznosti. V AM je pro každé zvíře sestavena zvláště rovnice a to je velký problém – mnoho rovnic.

BLUP - AM se provádí pomocí distribuční funkce $f(T/y)$

T – hledané veličiny (vektor)

y – naměřené užitkovosti (vektor)

Parciální **derivací** distribuční funkce (první derivace = 0 \Rightarrow směrnice tečny je nulová – extrém) \Rightarrow hledáme průběh a extrém funkce \Rightarrow pomocí soustavy normálních rovnic (maticová soustava) – **Mixed Model Equation (MME)** – **SMÍŠENÉ MODELY**:

$$(W'R^{-1}W + H^{-1})T = W'R^{-1}y$$

W – matice plánu experimentu, incidenční, designová (odhad PH) – rozepisuje se na matice X a Z !

R – kovarianční matice reziduí (chyb v datech)

H – kovarianční matice mezi hledanými veličinami

T – hledaná veličina



Dále se řeší modelová rovnice (maticový zápis):

- smíšený lineární model $y_{ijk} = b_i + u_j + e_{ijk}$ ¹

užitkovost = součet faktorů, které ji ovlivňují

$$y = Xb + Zu + e$$

Aditivní plemenné hodnoty jsou náhodnými efekty se známou variančně -kovarianční maticí. U vektorů u a e se předpokládá, že mají normální rozdělení a tedy odhadovaná střední hodnota je $E(u) = E(e) = 0$. Vektor pozorování y má multivariátní normální rozdělení s průměrem Xb ($E(y) = Xb$) a variancí V (variančně kovarianční matice vektoru pozorování) vypočítanou jako:

$$V = V(Zu + e) = ZGZ' + R \quad !$$

kde G je variančně kovarianční matice vektoru náhodných efektů $u \sim V(u)$ a R je variančně kovarianční matice reziduálních chyb $\sim V(e)$.

Nejsou-li otcové příbuzní pak je $G = I\sigma_o^2$, kde I je jednotková matice a σ_o^2 je ¼ aditivní genetické varianci (protože každý otec dá ½ svých genů dcerám a po umocnění pro získání variance získáme ¼ aditivní genetické variance).

¹ P_i – efekt plemene i (pevný efekt), u_j – efekt otce j na produkci jeho dcer (náhodný efekt)

Jsou-li otcové příbuzní pak $\mathbf{G} = \mathbf{A} \sigma_0^2$, kde \mathbf{A} je matice příbuznosti mezi otcí s jedničkami na diagonále a mimo diagonální prvky zobrazují podíl genů, které dva jedinci mají od společného předka. Obě matice jsou symetrické ($\mathbf{G} = \mathbf{G}'$ a $\mathbf{A} = \mathbf{A}'$).

Nejlepší lineární nevychýlená předpověď (BLUP) vektoru \mathbf{u} je:

$$\hat{\mathbf{u}} = \mathbf{GZ}' \mathbf{R}^{-1} (\mathbf{y} - \mathbf{X}\hat{\mathbf{b}}) !$$

kde $\hat{\mathbf{b}}$ je odhadce pevných efektů získaných metodou zobecněných nejmenších čtverců (GLS) – viz níže.

Rovnice $\mathbf{y} = \mathbf{Xb} + \mathbf{Zu} + \mathbf{e} \Rightarrow$ se rozepisuje do soustavy normálních rovnic smíšeného modelu (MME)

$$\begin{array}{ccc} \left[\begin{array}{cc} \mathbf{X}' \mathbf{R}^{-1} \mathbf{X} & \mathbf{X}' \mathbf{R}^{-1} \mathbf{Z} \\ \mathbf{Z}' \mathbf{R}^{-1} \mathbf{X} & \mathbf{Z}' \mathbf{R}^{-1} \mathbf{Z} + \mathbf{H}' \end{array} \right] \cdot \begin{bmatrix} \hat{\mathbf{b}} \\ \hat{\mathbf{u}} \end{bmatrix} & = & \begin{bmatrix} \mathbf{X}' \mathbf{R}^{-1} \mathbf{y} \\ \mathbf{Z}' \mathbf{R}^{-1} \mathbf{y} \end{bmatrix} \\ \text{Matice} & \boxed{\begin{array}{c} \mathbf{T}^2 \\ \mathbf{S} \end{array}} & \\ & \mathbf{M} \cdot \mathbf{T} = \mathbf{S} & \\ & \mathbf{T} = \mathbf{M}^{-1} \cdot \mathbf{S} & ^3 \end{array}$$

\mathbf{y}	– vektor naměřených užitkovostí (n)	($n \times 1$)
\mathbf{X}	– incidenční matice udávající plán pokusu pevných efektů X	($n \times p$)
\mathbf{Z}	– incidenční matice udávající plán pokusu náhodných efektů Z	($n \times q$)
\mathbf{b}	– vektor odhadů pevných efektů (odhad úrovní p)	($p \times 1$)
\mathbf{u}	– vektor odhadů náhodných efektů; $\mathbf{u} \sim PH$ (odhad úrovní q)	($q \times 1$)
\mathbf{e}	– vektor nekontrolovaných náhodných reziduálních efektů (vektor reziduálních odchylek, u kterých se předpokládá, že jsou nezávislé na náhodných genetických efektech)	($n \times 1$)
\mathbf{H}'	– kovarianční matice inverzní	

Stejně jako v modelu s pevnými efekty se obecně předpokládá, že rezidua jsou nekorelována a mají stejnou, konstantní varianci. Pak $\mathbf{R} = \mathbf{I} \sigma_e^2$, kde σ_e^2 je reziduální variance a $\mathbf{R}^{-1} = \mathbf{I} / \sigma_e^2$. Takže soustava normálních rovnic může být zjednodušena vynásobením obou stran reziduální variancí (maticí \mathbf{R}) a získáme rovnice:

$$\begin{bmatrix} \mathbf{X}' \mathbf{X} & \mathbf{X}' \mathbf{Z} \\ \mathbf{Z}' \mathbf{X} & \mathbf{Z}' \mathbf{Z} + \mathbf{G}' \sigma_e^2 \end{bmatrix} \cdot \begin{bmatrix} \hat{\mathbf{b}} \\ \hat{\mathbf{u}} \end{bmatrix} = \begin{bmatrix} \mathbf{X}' \mathbf{y} \\ \mathbf{Z}' \mathbf{y} \end{bmatrix}$$

Pokud předpovídáme plemennou hodnotu pomocí AM (jsou známy příbuzenské vztahy mezi jedinci) nabývají rovnice tvar:

$$\begin{bmatrix} \mathbf{X}' \mathbf{X} & \mathbf{X}' \mathbf{Z} \\ \mathbf{Z}' \mathbf{X} & \mathbf{Z}' \mathbf{Z} + \mathbf{A}' K \end{bmatrix} \cdot \begin{bmatrix} \hat{\mathbf{b}} \\ \hat{\mathbf{u}} \end{bmatrix} = \begin{bmatrix} \mathbf{X}' \mathbf{y} \\ \mathbf{Z}' \mathbf{y} \end{bmatrix}$$

$\mathbf{X}' \mathbf{X}$ – diagonální matice s řádky a sloupcí rovno počtu úrovní pevného efektu (např. počtu plemen), diagonální prvky jsou počty záznamů v korespondující úrovni efektu (konkrétního plemene), mimodiagonální prvky jsou rovny nule

² \mathbf{T} chceme určit!

³ \mathbf{M} – matice koeficientů; \mathbf{T} – vektor řešení

Z'Z – diagonální matice, kde každý diagonální prvek je roven počtu záznamů (počtu dcer) každé úrovně náhodného efektu (otce)

X'Z – matice s počtem řádků rovno počtu úrovní pevných efektů (počet plemen) a počtem sloupců rovno počtu úrovní náhodných efektů (počet otců); každý prvek bude číslo záznamů v odpovídající kombinaci pevného x náhodného efektu (plemeno x otec)

Z'X – matice je transponovaná matice **X'Z**

X'y – vektor jehož délka bude rovna počtu úrovní pevného efektu (počtu plemen) a každý prvek je součet hodnot v odpovídající úrovni efektu (plemene)

Z'y – vektor jehož délka bude rovna počtu úrovní náhodného efektu (počtu otců) a každý prvek je součet hodnot v odpovídající úrovni efektu (užitkovost všech dcer po každém otci)

A – aditivně genetická matice příbuznosti, jejíž prvky a_{ii} jsou rovny $(1 + F_Z)$ (F_Z koeficient inrídingu) a prvky a_{ij} jsou rovny koeficientům příbuznosti R_{ij} mezi jedinci i a j .

$$\text{koeficient inrídingu: } F_Z = a_{ii} = \sum \left(\frac{1}{2}\right)^{n_1+n_2+1} \cdot (1 + F_A)$$

$$\text{koeficient příbuznosti: } R_{XY} = a_{ij} = a_{ji} = \sum \left(\frac{1}{2}\right)^{n_1+n_2} (1 + F_A)$$

n_1 - počet generací mezi rodičem X a jedincem Z a společným předkem A

n_2 - počet generací mezi rodičem Y a jedincem Z a společným předkem A

F_A - koeficient inrídingu předka A (společného předka)

Σ - sumace příbuznosti pro více úseků jedinců X a Y ke společným předkům

$$K = \frac{\sigma_e^2}{\sigma_u^2} = \frac{\sigma_e^2}{\sigma_A^2} \quad (\text{někdy označováno jako } \lambda \text{ nebo } \alpha)$$

$$= \frac{1-h^2}{h^2} \quad \text{např. při sledování vlastní užitkovosti}$$

$$= \frac{4-h^2}{h^2} \quad \text{např. při sledování užitkovosti dcer (polosester) po býcích}$$

Řešení rovnic smíšeného modelu může být obtížné získat, protože řešení rovnic je prováděno invertováním matic, což je pro běžné výpočty u velkých populací HZ méně vhodné: $\mathbf{T} = \mathbf{M}^{-1} \cdot \mathbf{S}$. Přesné řešení vyžaduje inverzi matice koeficientů (**M**), která je zpravidla menší než matice **V**. Počet řádků a sloupců matice **V** je rovna celkovému počtu pozorování, zatímco v matici **M** jsou rovny počtu úrovní efektů zahrnutých do modelu, což je obecně mnohem méně.

Je-li zahrnuto do modelové rovnice více faktorů, může být získáno přibližné řešení iterativními postupy (**iteracemi**) – řešení jednotlivých rovnic izolovaně, a jejich řešení je využito v dalších rovnicích s cílem stabilizace řešení, kdy se již nemění od jednoho iteračního kola k druhému. Existuje mnoho iteračních metod aplikovatelné na rovnice smíšeného modelu. Nejpoužívanější metodou jsou iterace Gauss-Seidel, protože je relativně rychlá a spolehlivě konverguje a poskytuje řešení rovnic. Animal model vyžaduje několik stovek kol iterací, než se získá přibližná konvergence.

Př. BLUP – AM Best Linear Unbiased Prediction – Animal Model

$$y_{ijk} = \mu + SRO_i + g_j + e_{ijk}$$

y_{ijk} [~y] naměřená užitkovost

μ [~X] populační průměr

SRO_i [~b] stádo x rok x období (působení chovatele na zvířata, na jejich užitkovost)

[~ u] efekt jedince (genetický) – ten chceme určit - **PH**!

e_{ijk} [~e] reziduum

BLUP

AM (animal model)

RAM (redukovaný AM)
(gametický model)

} pro 1 nebo více vlastností

AM = Animal Model = individuální model

- vylepšený BLUP
 - nebereme v úvahu jen naměřenou užitkovost jedince, ale i všechny příbuzenské vztahy (např. odhad mléčné užitkovosti býka na základě užitkovosti dcer)

Porovnání zobecněného lineárního modelu GLM (*general linear model*), který obsahuje jen pevné efekty, se smíšeným modelem MM (*mixed model*):

GLM	MM
$y_{ij} = \mu + b_i + e_{ij}$	$y_{ijk} = \mu + b_i + u_j + e_{ijk}$
$\mathbf{y} = \mathbf{X}\mathbf{b} + \mathbf{e}^*$	$\mathbf{y} = \mathbf{X}\mathbf{b} + \mathbf{Z}\mathbf{u} + \mathbf{e}$
$\mathbf{e}^* \sim (0, \mathbf{V})$	$\mathbf{u} \sim (0, \mathbf{G})$ $\mathbf{e} \sim (0, \mathbf{R})$
$\mathbf{y} \sim (\mathbf{X}\mathbf{b}, \mathbf{V})$	$\mathbf{y} \sim (\mathbf{X}\mathbf{b}, \mathbf{V}) = (\mathbf{X}\mathbf{b}, \mathbf{Z}\mathbf{G}\mathbf{Z}^\top + \mathbf{R})$

$\sim (a, b)$ znamená, že náhodná proměnná má průměr a a varianci b
ve smíšeném modelu je vektor reziduálních efektů rozdělen do dvou komponent $\epsilon = \mathbf{Z}\boldsymbol{\beta} + \boldsymbol{\epsilon}$

Ve smíšeném modelu pozorujeme \mathbf{y} , \mathbf{X} a \mathbf{Z} , zatímco \mathbf{b} , \mathbf{u} , \mathbf{R} a \mathbf{G} jsou obecně neznámé. Takže smíšené modely nám umožňují:

- 1) odhadovat vektory pevných \mathbf{b} a náhodných efektů \mathbf{u}
 - 2) odhadovat kovarianční matice \mathbf{G} a \mathbf{R} (u kterých se předpokládá, že jsou funkcemi několika neznámých komponent variance)

Pro **pevné efekty** platí **BLUE** (nejlepší lineární nevychýlený odhad): $E(\hat{b} - b)^2 = \min$.

Řešení náhodných efektů je **BLUP** (nejlepší lineární nevychýlená předpověď)

$E(\hat{u} - u)^2 = \min$, protože náhodné efekty nejsou parametry a jejich řešení se nazývají prediktory „*predictors*“ a naopak u pevných efektů hovoříme o odhadcích „*estimators*“.⁴

⁴ Odhadujeme pevné efekty a předpovídáme náhodné efekty !!

BLUE a **BLUP** jsou *nejlepší*, protože minimalizují výběrovou varianci; *lineární* v tom smyslu, že jsou lineárními funkčemi pozorovaných fenotypů y ; *nevychýlené* ve smyslu, že $E[BLUE(b)] = b$ a $E[BLUP(u)] = u$.

Pro smíšený model $y = \mathbf{X}\mathbf{b} + \mathbf{Z}\mathbf{u} + \mathbf{e}$ platí:

BLUE pro pevné efekty \mathbf{b} : $\hat{\mathbf{b}} = (\mathbf{X}'\mathbf{V}^{-1}\mathbf{X})^{-1}\mathbf{X}'\mathbf{V}^{-1}\mathbf{y}$

kde $\mathbf{V} = \mathbf{Z}\mathbf{G}\mathbf{Z}' + \mathbf{R}$

Jedná se o odhadce zobecněných nejmenších čtverců (GLS)

BLUP pro náhodné efekty \mathbf{u} : $\hat{\mathbf{u}} = \mathbf{G}\mathbf{Z}'\mathbf{V}^{-1}(\mathbf{y} - \mathbf{X}\hat{\mathbf{b}})$

(Henderson, 1963)

Praktická aplikace obou rovnic vyžaduje známé komponenty variance. Před analýzami BLUP je nutné odhadnout komponenty variance pomocí ANOVA nebo REML.

- historie (výpočty ovlivňuje úroveň výpočetní techniky)

- Bayes (1763) – BLUP (myšlenka již 200 let stará)

- Henderson (1949) – AM

- nelineární postupy

Materiály určené pro studenty specializace „Genetika a šlechtění hospodářských zvířat“ pro předmět **Genetika ve šlechtění zvířat** (letní semestr 2006).

Dr. Ing. Tomáš Urban

ÚMFGZ – pracoviště genetiky MZLU v Brně

<http://www.af.mendelu.cz/genetika/>

urban@mendelu.cz

březen '06

© Urban 2006