

# **Introduction sur la régression dite “aléatoire” et son utilisation dans l'amélioration génétique des animaux domestiques**

J.L. Gourdine

*INRA, Unité de Recherches Zootechniques, Domaine Duclos, 97170  
Petit-Bourg, Guadeloupe.*

*Séminaire AOC du 08/12/2005, Université Antilles-Guyane , Fouillole, Guadeloupe*

## Amélioration génétique ???

L'ensemble des techniques utilisées pour modifier le potentiel héréditaire des animaux.

Objectif : fournir à l'éleveur un animal qui réponde à ses souhaits en recherchant une adéquation optimale entre le matériel génétique et les conditions du milieu.

# Amélioration génétique ???

Avant :

Méthodes empiriques



Maintenant :

Programmation

**Avant : « Puisque leurs mères, qui sont demi-sœurs, sont bonne productrices, je garderais certains de ces veaux pour en faire des reproducteurs.»**



**Maintenant : « A partir de l'évaluation génétique basée sur la résolution des équations du modèle mixte, les meilleures valeurs génétiques sont estimées pour les veaux 5 et 18. »**

# Régression aléatoire ???


**Random Regression Models (RRM)**  
**(Henderson, 1982 ; Laird et Ware, 1982)**

↗ Etude et utilisation des RRM au cours de ces 8 dernières années :

**7th World Congress on Genetics Applied to Livestock Production, 2002, Montpellier :**

**24 papiers sur RRM**

## Contexte économique



## Contexte économique

↗ Programmes avec minimisant les coûts et optimisant un système de prod. animale écologique et durable.



Collecte de l'information :

données de type longitudinal

(ex. poids vif; prod. laitière, etc ...)

## Contexte économique

Outils statistiques particuliers pour traiter ce type de données et estimer la valeur génétique

(Valeur génétique : quantification des effets moyens des gènes intervenant pour le caractère étudié et transmissibles à la descendance.)

## Modèle génétique de base

$$Y_{ijk} = m_j + a_i + e_{ijk}$$

$Y_{ijk}$ : k<sup>ème</sup> performance de l'individu i réalisée dans les conditions du milieu j

## Modèle génétique de base

$$Y_{ijk} = m_j + a_i + e_{ijk}$$

**$m_j$ : somme des effets du milieu identifiés à laquelle est soumise la performance (ex. moyenne générale, saison) : EFFETS FIXES**

## Modèle génétique de base

$$Y_{ijk} = m_j + a_i + e_{ijk}$$

**a<sub>i</sub>: valeur génétique de l'animal i (écart à la moyenne)**

Déterminisme polygénique : nombreux gènes à effets faibles a<sub>il</sub> sur la performance de l'animal i

$$a_i = \sum_l a_{il}$$



a<sub>i</sub> ~ N ( 0 , σ<sup>2</sup><sub>a</sub>) (loi des grands nombres)

Ex. : Pour deux individus i et m demi-frères,  
on a : Cov(a<sub>i</sub>a<sub>m</sub>) = σ<sup>2</sup><sub>a</sub>/4

## Modèle génétique de base

$$Y_{ijk} = m_j + a_i + e_{ijk}$$

$a_i$ : valeur génétique de l'animal i (écart à la moyenne)

L'ensemble des effets génétiques  $\{a_i\}_i \sim N_N(0, A\sigma^2_a)$

A : matrice de parenté



Information avant observations = lien de parenté :

$a_i$  est un effet aléatoire du modèle

# Modèle génétique de base

$$Y_{ijk} = m_j + a_i + e_{ijk}$$

**$e_{ijk}$ : résiduelle. EFFETS ALEATOIRES**

$$e_{ijk} \sim N(0, \sigma_e^2)$$

## Modèle génétique de base

$$Y_{ijk} = m_j + a_i + e_{ijk}$$

$Y_{ijk}$ : k<sup>ème</sup> performance

$m_j$ : effets du milieu **EFFETS FIXES**

$a_i$ : valeur génétique. **EFFETS ALEATOIRES**

$e_{ijk}$ : résiduelle. **EFFETS ALEATOIRES**

## MODELE MIXTE

## Structure de base d'un RRM

$$Y_{it} = F + g(t) + r(a, x, k_A)_i + r(p_e, x, k_R) + e_{it}$$

$Y_{it}$ : observation sur animal i à l'instant t

F : ensemble des effets fixes indépendants de t

g(t) : fonction ajustant la trajectoire phénotypique de l'individu « moyen » de la population

## Structure de base d'un RRM

$$Y_{it} = F + g(t) + r(a, x, k_A)_i + r(p_e, x, k_R)_i + e_{it}$$

$r(a, x, k_A)$  : fonction de régression aléatoire.

- $a$  : effets génétiques additifs
- $x$  : vecteur des covariables de temps
- $k_A$  : ordre de la fonction de régression

$r(a, x, k_A)_i = a_{i1} \times x_{t1} + a_{i2} \times x_{t2} + \dots + a_{ikA} \times x_{tkA}$  avec :

- $a_{ij}$  : coefficients de régression aléatoire pour les effets génétiques additifs

## Structure de base d'un RRM

$$Y_{it} = F + g(t) + r(a, x, k_A)_i + r(p_e, x, k_R) + e_{it}$$

$r(p_e, x, k_R)$  : fonction de régression aléatoire.

- $p_e$  : effets d'environnement permanent
- $x$  : vecteur des covariables de temps
- $k_R$  : ordre de la fonction de régression

## Structure de base d'un RRM

$$Y_{it} = F + g(t) + r(a, x, k_A)_i + r(p_e, x, k_R) + e_{it}$$

Objectif des fonctions de régression aléatoire :

- modéliser les écarts individuels (dû aux effets aléatoires) à la trajectoire phénotypique moyenne
- fournir une description du potentiel génétique de l'animal sur la période considérée

# Structure de base d'un RRM

Modélisation des écarts individuels :

**utilisation des polynômes orthogonaux de Legendre**

( standardisés à l'intervalle [ - 1 ; + 1 ] ) comme covariables de temps (Kirkpatrick et coll., 1990)

car :

- faciles à calculer
- Réduction des corrélations des paramètres à estimer => facilite la convergence des procédures d'estimation

## Structure de base d'un RRM

Définition d'une famille de polynômes orthogonaux :

Soit  $\mathfrak{I}$  l'ensemble des fonctions continues sur  $J = [a; b]$

La famille  $\{P_n\}_{n \in \mathbb{N}}$  de polynômes orthogonaux vérifient :

$$\begin{cases} \forall k \neq l, \int_a^b P_k(t)P_l(t)dt = 0 \\ \forall k \in \mathbb{N}, \int_a^b P_k^2(t)dt = 1 \end{cases}$$

On ramène à  $[-1; 1]$  par changement de variable affine

$$w = \frac{2(t - t_{\min})}{(t_{\max} - t_{\min})} - 1$$

# Structure de base d'un RRM

Polynômes de Legendre :

Formule générale :

$\forall k \in \mathbb{N}, \forall t \in \mathfrak{R},$

$$\varphi_k(t) = \left(\frac{2k+1}{2}\right)^{\frac{1}{2}} \frac{1}{2^k k!} \frac{d^k}{dt^k} \left[(t^2 - 1)^k\right]$$

$\forall k \in \mathbb{N}, \forall t \in \mathfrak{R},$

$$\varphi_0(t) = \sqrt{\frac{1}{2}}; \varphi_1(t) = \sqrt{\frac{3}{2}} \times t; \varphi_2(t) = \frac{1}{2} \sqrt{\frac{5}{2}} \times (3t^2 - 1)$$

# Structure de base d'un RRM

Réécriture du modèle RRM:

$$Y_{it} = F + g(t) + r(a, x, k_A)_i + r(p_e, x, k_R) + e_{it}$$

$$y_{it} = F + g(t) + \sum_{m=0}^{k_A-1} \alpha_{im} \varphi_m(t_{ij}^*) + \sum_{m=0}^{k_R-1} \gamma_{im} \varphi_m(t_{ij}^*) + \varepsilon_{ij}$$

$\alpha_{im}$  : coefficients de régression aléatoire pour les effets génétiques additifs

$\gamma_{im}$  : coefficients de régression aléatoire pour les effets d'environnement permanent

$\varphi_m(t_{ij}^*)$  : m<sup>ème</sup> polynôme de Legendre pour le temps  $t_{ij}^*$  standardisé ( $t_{ij}^* \in [-1 ; +1]$ )

# Structure de base d'un RRM

Notation Matricielle RRM:

$$\mathbf{Y} = \mathbf{X}\mathbf{b} + \mathbf{Z}_1\mathbf{a} + \mathbf{Z}_2\mathbf{p} + \mathbf{e}$$

$\mathbf{Y}$  : vecteur de N observations

$\mathbf{b}$ : vecteur des effets fixes;  $\mathbf{X}$  matrice d'incidence

$\mathbf{a}$  : vecteur des  $k_A$  coefficients de régression aléatoire pour les effets génétiques additifs;  $\mathbf{Z}_1$  : matrice d'incidence

$\mathbf{p}$  : vecteur des  $k_R$  coefficients de régression aléatoire pour les effets d'environnement permanent;  $\mathbf{Z}_2$  : matrice d'incidence

## Structure de base d'un RRM

$$\text{Var} \begin{pmatrix} a \\ p \\ e \end{pmatrix} = \begin{pmatrix} A \otimes G & 0 & 0 \\ 0 & I \otimes P & 0 \\ 0 & 0 & R \end{pmatrix}$$

A : matrice de parenté

G : matrice de variance-covariance pour les effets génétiques additifs

P : matrice de variance-covariance pour les effets d'environnement permanent

I : matrice identité

R : matrice de variance- covariance résiduelle

⊗ : produit de Kronecker ou produit tensoriel

# Structure de base d'un RRM

Rappel :  $\otimes$  produit de Kronecker ou produit tensoriel

Soient deux matrices

$$A_{m \times n} = (a_{ij}) \text{ et } B_{p \times r} = (b_{ij}),$$

on a:

$$A \otimes B_{mp \times nr} = \begin{pmatrix} a_{11}B & a_{12}B & \cdots & a_{1n}B \\ a_{21}B & \vdots & \cdots & \vdots \\ \vdots & \vdots & \cdots & \vdots \\ a_{n1}B & a_{n2}B & \cdots & a_{nn}B \end{pmatrix}$$

# Structure de base d'un RRM

Estimation des paramètres b, a et p :

équations du modèle mixte

$$\begin{pmatrix} X'R^{-1}X & X'R^{-1}Z_1 & X'R^{-1}Z_2 \\ Z_1'R^{-1}X & Z_1'R^{-1}Z_1 + A^{-1} \otimes G^{-1} & Z_1'R^{-1}Z_2 \\ Z_2'R^{-1}X & Z_2'R^{-1}Z_1 & Z_2'R^{-1}Z_2 + I \otimes P^{-1} \end{pmatrix} \times \begin{pmatrix} \hat{b} \\ \hat{a} \\ \hat{p} \end{pmatrix}$$

$$= \begin{pmatrix} X'R^{-1}y \\ Z_1'R^{-1}y \\ Z_2'R^{-1}y \end{pmatrix}$$

# Structure de base d'un RRM

Propriétés statistiques :

- si  $G$ ,  $P$  et  $R$  sont connues alors :

$\hat{b}$  : meilleur estimateur sans biais de  $b$  (BLUE)

$\hat{a}$  et  $\hat{p}$  : meilleures prédictions sans biais de  $a$  et  $p$  (BLUP)

Pour estimer  $G$ ,  $P$  et  $R$  (méthode REML) :

- hypothèse de normalité des variables aléatoires
- EBLUE (empirical best linear unbiased estimator)
- EBLUP (empirical best linear unbiased predictor)

## Exemple :

**Étude de la variabilité génétique de la croissance de la vache de race Créole  
(Gourdine, Menendez-Buxadera et Naves, 2002)**



### Structure des données :

- 227 vaches dont 117 mères
- critère de sélection : PV18
- mesures de la naissance jusqu'à 10 ans

**Question : la sélection peut-elle se faire plus tôt ?**

**Aide à la réponse : utilisation des RRM et résolution des équations du modèle mixte**



Soit  $y_{ij}$  le  $j^{\text{ème}}$  poids vif mesuré sur la vache  $i$  à l'âge  $t_{ij}$

$$Y_{ij} = \text{Effets fixes } (F_i + \sum_m (\beta_m t_{ij}^m)_{m=0, \dots, 3}) \\ + \text{Effets aléatoires } (g(t_{ij}) + r(t_{ij}) + e_{ij})$$

**F** : effet du numéro de portée de la mère sur la croissance de l'animal

$\sum (\beta_m t_{ij}^m)$  : relation âge-poids de la vache « moyenne »

**g** : fonction de régression aléatoire pour les effets génétiques additifs

**r** : fonction de régression aléatoire pour les effets d'environnement permanent



**e** : bruit de fond



Est-il possible de sélectionner plus tôt?

## Estimation de la partie aléatoire : écart individuels à la trajectoire moyenne

$$\text{Héritabilité} = \frac{\text{Variation génétique additive}}{\text{Variation phénotypique totale}}$$



## Conclusion

**RRM : méthode standard en analyse génétique quantitative (données longitudinales).**

**Mais : ce n'est pas une fin :**

- **Système d'évaluation en constante évolution**
- **Recherches dynamiques (fonction Splines, Bayesien estimation, RRM multivariate)**

## Quelques références bibliographiques

- Henderson C.R. (1982): *Analysis of covariance in the mixed model : higher level, nonhomogeneous and random regressions.* Biometrics 38, 623-640
- Laird N.M and Ware J.H (1982) : *Random effects models for longitudinal data.* Biometrics 38, 963-974
- Gilmour AR, Thompson R, Cullis BR (1995) : *Average Information REML, an efficient algorithm for variance parameters estimation in linear mixed models.* Biometrics 51, 1440-1450
- Menéndez-Buxadéra A. (2004) : *Basic principles and importance of the utilization of random regression models in animal breeding programs.* CRAG : 46 pp.
- Fischer T.M, Gilmour A.R, van der Werf J.H.J. *Computing approximate standard errors for genetic parameters derived from random regression models fitted by average information REML.* Genetics Selection Evolution. 36, 363-369.
- Meyer K. (2005) : *Advances in methodology for random regression analyses.* Australian Journal of Experimental Agriculture 45, 847–858