

Statistique et aide à la décision

Session 4

David Causeur
Agrocampus Ouest
IRMAR CNRS UMR 6625

Plan

1 Comparaison de modèles

2 Choix du meilleur modèle

Test du rapport de vraisemblance

Illustration. Le lien entre l'indice de couleur a et la maturité est-il le même pour toutes les variétés d'abricots ?

Modèle \mathcal{M}_1 pour la maturité d'un abricot :

$$\begin{cases} \log \frac{\pi_{2i}(x)}{\pi_{1i}(x)} &= \mu^{(2)} + \alpha_i^{(2)} + (\beta^{(2)} + \gamma_i^{(2)})x \\ \log \frac{\pi_{3i}(x)}{\pi_{1i}(x)} &= \mu^{(3)} + \alpha_i^{(3)} + (\beta^{(3)} + \gamma_i^{(3)})x \end{cases}$$

où $\pi_{ki}(x)$ est la probabilité qu'un abricot de variété i , dont l'indice a vaut x , soit dans le stade k de maturité.

Sous H_0 , $\gamma_i^{(k)} = 0$, pour tout i , pour tout k .



Test du rapport de vraisemblance

Comparaison des modèles \mathcal{M}_0 et \mathcal{M}_1 :

\mathcal{M}_0 : sous-modèle de \mathcal{M}_1 obtenu avec $\gamma_i = 0$, pour tout i .

Statistique de test du rapport de vraisemblance :

$LRT = \mathcal{D}_0 - \mathcal{D}_1$, où \mathcal{D}_0 est la déviance résiduelle de \mathcal{M}_0
et \mathcal{D}_1 est la déviance résiduelle de \mathcal{M}_1 .

Loi de LRT sous H_0 :

$LRT \underset{H_0}{\sim} \chi_q^2$, où q est la différence entre
les nombres de paramètres de \mathcal{M}_1 et \mathcal{M}_0 .



```
anova(mod0, mod1, test="Chisq")
```

Plan

1 Comparaison de modèles

2 Choix du meilleur modèle

Sélection de variables explicatives

Quel modèle \mathcal{M}_k avec $k \leq K$ variables explicatives est suffisant pour expliquer le stade de maturité ?

Choix parmi 2^K modèles non-emboîtés

Sélection de variables explicatives

Le **Critère d'Information d'Akaike** $AIC_{x,y}(\hat{\beta})$ est défini ainsi :

$$AIC_{x,y}(\hat{\beta}) = \mathcal{D}_{x,y}(\hat{\beta}) + 2p,$$

où p est le nombre de paramètres du modèle.

$AIC_{x,y}(\hat{\beta})$ estime la **perte d'information** lorsque l'on utilise le modèle estimé avec $\hat{\beta}$ plutôt que le vrai modèle ayant généré les données.

Sélection de variables explicatives

Le **Critère d'Information Bayésien** $BIC_{x,y}(\hat{\beta})$ est défini ainsi :

$$BIC_{x,y}(\hat{\beta}) = \mathcal{D}_{x,y}(\hat{\beta}) + p \ln(n),$$

où p est le nombre de paramètres du modèle.

$BIC_{x,y}(\hat{\beta})$ estime la **perte d'information** lorsque l'on utilise le modèle estimé avec $\hat{\beta}$ plutôt que le vrai modèle ayant généré les données **dans le périmètre des modèles paramétriques considérés**.

Sélection de variables explicatives

Quel modèle \mathcal{M}_k avec $k \leq K$ variables explicatives est suffisant pour expliquer le stade de maturité ?

Choix parmi 2^K modèles non-emboîtés

- Parmi les modèles \mathcal{M}_k : le modèle \mathcal{M}_k^* avec la plus petite déviance résiduelle \mathcal{D}_k^* est le **champion**
- Le **champion des champions** \mathcal{M}^* est le modèle \mathcal{M}_k^* avec le plus petit AIC (ou BIC)

▶ `bestglm(Xy, family, method, IC)`

▶  R Studio®

Sélection de variables explicatives

AIC ou BIC ?

- Si le but est de prédire, minimiser AIC est recommandé.
- Si le but est d'ajuster un modèle aux données, minimiser BIC doit être privilégié.

Minimiser BIC conduit à choisir des modèles **plus parcimonieux**

Algorithmes sous-optimaux

Si $K > 15$ explanatory variables, recherche forward (ou backward) stepwise

- **Etape 1** : \mathcal{M}_1^*
 - **Etape k** : \mathcal{M}_k^* parmi les modèles complétant \mathcal{M}_{k-1}^* en ajoutant une variable explicative.
 - **Stop** si le BIC de \mathcal{M}_k^* est plus grand que celui de \mathcal{M}_{k-1}^* .
- ▶ stepwise (mod, direction, criterion)
- ▶  Studio®