

Quasi-Vraisemblance

Michel Goulard

Unité de Biométrie et d'Intelligence Artificielle, UR 875
Département de Mathématiques et Informatique Appliquées
INRA, Centre de Toulouse, Auzeville

Réunion réseau MSTGA 23 et 24 Nov. 2006

X_1, \dots, X_n i.i.d. $f(x|\theta)$

- moindres carrés : minimise $\sum (S(X_i) - g_i(\theta))^2$
- méthode des moments : résolution de $T_k(X) = M_k(\theta)$
- maximum de vraisemblance : maximise $\sum \log(f(X_i|\theta))$
- minimum contraste : minimum de $K_n(X|\theta)$ avec $K_n(X|\theta) \longrightarrow K(\theta, \theta_0)$

- Quasi-vraisemblance introduite par Wedderburn pour famille exponentielle.
- McCullagh & Nelder dans GLM : corrélation, modèle aléatoire.
- C.C Heyde (1997) “Quasi-likelihood and its applications”, Springer.
- Godambe (1960), Durbin (1960), Godambe (1985), Heyde (1986), Godambe & Heyde (1987)
- Estimation de θ caract de la loi de X_t à partir de $\{X_t, t \in T\}$

1er Exemple Introductif

- X_1, \dots, X_T i.i.d. $E(X_t) = \theta$ $var(X_t) = \sigma^2$
- Gauss-Markov : moyenne empirique meilleur estimateur linéaire sans biais.
- $\mathcal{G} = \{G(X_1, \dots, X_T) = \sum b_t(X_t - \theta), \sum b_t \neq 0\}$

$$G^{(s)} = \left(\sum b_t \right) \frac{\sum b_t(X_t - \theta)}{\sigma^2 \sum b_t^2}$$

G^* optimal dans \mathcal{G} si $var(G^{*(s)}) \geq var(G^{(s)})$

- GM : $G^* = \sum(X_t - \theta)$ est optimal et $G^* = 0$ donne l'estimateur optimal.
- $G^{(s)} = -E(\nabla G)(E(G^2))^{-1} G$, $var(G^{(s)}) = -E(\nabla G^{(s)})$

2ème Exemple introductif

- X_1, \dots, X_T i.i.d. $E(X_t) = \alpha_t(\theta)$ $\text{var}(X_t) = \sigma_t^2(\theta)$

$$\mathcal{H} = \{H(\theta) = \sum b_t(\theta)(X_t - \alpha_t(\theta))\}$$

$$E(\nabla H) = \sum b_t(\theta) \nabla \alpha_t(\theta) \text{ et } E(H^2) = \sum b_t^2(\theta) \sigma_t^2(\theta)$$

- $H^{(s)} = (\sum b_t(\theta) \nabla \alpha_t(\theta)) (\sum b_t^2(\theta) \sigma_t^2(\theta))^{-1} H$

$$H^* = \sum \frac{\nabla \alpha_t(\theta)}{\sigma_t^2(\theta)} (X_t - \alpha_t(\theta))$$

- Solution moindres carrés : solution de

$$H^* + \sum (X_t - \alpha_t(\theta))^2 \nabla \frac{\sigma_t(\theta)}{\sigma_t^3(\theta)} = 0$$

Lien avec vraisemblance

- X_1, \dots, X_T i.i.d. $E(X_t) = \alpha_t(\theta)$, loi de X_t $f_t(X_t|\theta)$
- $\log L = \sum \log f_t(X_t|\theta)$

$$U = \frac{\partial \log L}{\partial \theta} \text{ et } H = \sum b_t(\theta)(X_t - \alpha_t(\theta))$$

- propriétés : $E(U) = 0$, $U^{(s)} = U$
 $E(UH) = -E(\nabla H)$, $\text{corr}^2(U, H) = \text{var}(H^{(s)})/E(U^2)$
- H^* est de corrélation max avec U
 $E((H^* - U)^2)$ est minimum
- si U est dans \mathcal{H} , U est optimal. U linéaire si famille exponentielle linéaire.

Définition générale

- $\{X_t, t \leq T\}, \{P_\theta, \theta \in \mathbb{R}^p\}$
- fonctions estimantes
 $\mathcal{G} = \{G_T(\{X_t, t \leq T\}, \theta)$ de dimension $p\}$
 $E(G_T(\theta)) = 0$, $E(\nabla G_T)$ et $E(G_T G_T')$ existent.
On va considérer des sous-ensembles \mathcal{H} de \mathcal{G}
- densité $p_T(\theta)$, $U_T(\theta) = p_T^{-1}(\theta) \nabla p_T(\theta)$
- standardisation $G_T^{(s)}(\theta) = -E(\nabla G_T)'(E(G_T G_T'))^{-1} G_T$
- $\mathcal{E}(G_T) = E(G_T^{(s)} G_T^{(s)'}) = E(\nabla G_T)'(E(G_T G_T'))^{-1} E(\nabla G_T)$

Définition générale (suite)

- G^* est optimal ou est un quasi-score, $G^* = 0$ donne l'estimateur de quasi-vraisemblance, G^* est O_F -optimal sur \mathcal{H} :

$\mathcal{E}(G_T^*) - \mathcal{E}(G_T)$ est définie positive.

$E((U_T - G_T^{(s)})(U_T - G_T^{(s)})') - E((U_T - G_T^{*(s)})(U_T - G_T^{*(s)})')$
est définie positive.

$$E((U_T - G_T^{*(s)})G_T^{(s)'}) = 0 = E(G_T^{(s)}(U_T - G_T^{*(s)})')$$

- G_T^* est optimal si

$$E(G_T^{*(s)} G_T^{(s)'}) = E(G_T^{(s)} G_T^{*(s)'}) = E(G_T^{*(s)} G_T^{*(s)'})$$

équivalent à $E(\nabla G_T)^{-1} E(G_T G_T^*)$ constante sur \mathcal{H}

- $h_t(\theta)$ telle que $E(h_t(\theta)) = 0$ et $E(h_t(\theta)h_s(\theta)') = 0$ $s \neq t$
pour $H = \sum a_t(\theta)h_t(\theta)$ alors $a_t^* = E(\nabla h_t)'(E(h_t h_t'))^{-1}$
- Galton-Watson : $E(Z_1|Z_0 = 1) = \theta$ et $E(Z_i|\mathcal{F}_{i-1}) = \theta Z_{i-1}$
 $H^* = \sum \frac{1}{\sigma^2}(Z_i - \theta Z_{i-1})$ qui donne l'estimateur
 $(Z_1 + \dots + Z_T)/(Z_0 + \dots + Z_{T-1})$ qui est le maximum de vrais. pour une certaine famille de lois.

autres exemples

- On utilisera pour choisir des fonctions estimantes des scores obtenus pour certaines lois.
- $dX_t = \theta X_t dt + dW_t$

$$H = \int_0^T b_s dW_s = \int_0^T b_s (dX_s - \theta X_s ds)$$

$$b_s^* = X_s \text{ et } \hat{\theta} = (\int_0^T X_s dX_s) / (\int_0^T X_s^2 ds)$$

- Modèle Linéaire Généralisé : $Y = \mu(\theta) + e$, $E(e) = 0$,
 $cov(e) = V$
 $Q(\theta) = \nabla \mu' V^{-1} (Y - \mu(\theta))$
c'est un quasi -score pour $\{A(\theta)(Y - \mu(\theta))\}$
- Les GEE sont les équations : Quasi-score = 0

un autre exemple

- $X_i = \theta + e_i$
 $E(e_i | \mathcal{F}_{i-1}) = 0$ $E(e_i^2 | \mathcal{F}_{i-1}) = \sigma^2 X_{i-1}^2$

$$H = \sum a_i (X_i - \theta) \text{ avec } a_i \mathcal{F}_{i-1}\text{-mesurable}$$

- Le quasi-score est $\frac{1}{\sigma^2} \sum \frac{(X_i - \theta)}{X_{i-1}^2}$.
- Wedderburn donne $\frac{1}{\sigma^2} \sum \frac{(X_i - \theta)}{E(X_{i-1}^2)}$.

Le premier est meilleur au sens de la variance du quasi-score.

Généralisations pour martingale

- G_T une fonction estimante telle que
 $\langle G \rangle_T = E(G_t G_t' | \mathcal{F}_{t-})$ existe et $\langle G \rangle_T^{-1/2} G_T \longrightarrow N(0, I)$
 $\bar{G}_t(\theta) = \int_0^t E(\nabla dG_s(\theta) | \mathcal{F}_{s-})$
dans le cas discret $E(G_t G_t' | \mathcal{F}_{t-1})$ et
 $\bar{G}_t(\theta) = \sum E(\nabla(G_s(\theta) - G_{s-1}(\theta)) | \mathcal{F}_{s-1})$
- G_T^* est O_A -optimal si : $\bar{G}_T^* \langle G^* \rangle_T^{-1} \bar{G}_T^* - \bar{G}_T \langle G \rangle_T^{-1} \bar{G}_T$
est p.s. définie positive.
- si $\bar{G}_T^{-1} \langle G \rangle_T \bar{G}_T^{-1} < G^* \rangle_T = \bar{G}_T^{*-1} \langle G^* \rangle_T \bar{G}_T^{*-1}$ alors G_T^* est
 O_A -optimal
- si G_T^* est O_A -optimal et $\bar{G}_T^{*-1} \langle G^* \rangle_T \bar{G}_T^{*-1}$ est non-aléatoire
alors G^* est O_F -optimal.

Modèle signal + bruit

- $X_t = A_t + M_t$ et $M_t = \sum m_s$ ou $dX_t = dA_t + dM_s$
- fonctions estimantes
 $G_t = \sum \alpha_s(\theta) m_s(\theta)$ avec $\alpha_s \mathcal{F}_{s-1}$ -mesurable
 $G_t = \int_0^t \alpha_s(\theta) dM_s(\theta)$ avec α_s predictable
- solution de Hutton-Nelson :

$$G_{*t} = \sum (E(\nabla m_s | \mathcal{F}_{s-1}))' (E(m_s m_s' | \mathcal{F}_{s-1}))^{-1} m_s$$

$$G_{*t} = \int_0^t (d\bar{M}_s)' (d \langle M \rangle_s)^{-1} dM_s$$

Deux exemples

- $dV_t = (-\rho V_t + \lambda)dt + dM(t)$ avec $\langle M \rangle_t = \sigma^2 t$ (Kallianpur 1983) $\nabla dM(s) = -(-V_t, 1)$ et $d \langle M \rangle_t = \sigma^2$
 $G_T^* = \frac{1}{\sigma^2} \int_0^T (-V_t, 1)' (dV_t - (-\rho V_t + \lambda)dt)$

$$\begin{cases} \int_0^T V(t) dV(t) &= \int_0^T (-\rho V_t + \lambda) V_t dt \\ \int_0^T dV(t) &= \int_0^T (-\rho V_t + \lambda) dt \end{cases}$$

- $X_t = (\theta + \eta_t)X_{t-1} + \varepsilon_t$ avec
 $E(\eta_t | \mathcal{F}_{t-1}) = 0$ $E(\varepsilon_t | \mathcal{F}_{t-1}) = 0$ $E(\varepsilon_t^2 | \mathcal{F}_{t-1}) = \sigma^2 X_{t-1}$

$$X_t = \theta X_{t-1} + u_t \quad \nabla m_t = X_{t-1} \quad \text{et} \quad G_T^* = \sum \frac{X_{t-1}}{E(u_t^2 | \mathcal{F}_{t-1})} (X_t - \theta X_{t-1})$$

si η_t et ε_t indép. et $E(\eta_t^2 | \mathcal{F}_{t-1}) = \tau^2$

$E(u_t^2 | \mathcal{F}_{t-1}) = X_{t-1}(\sigma^2 + \tau^2 X_{t-1})$ calcul possible.

Propriétés asymptotiques et tests

- Des développements asymptotiques sont faits :
consistance, normalité pour les fonctions estimantes et
pour les estimateurs.
- Zones de confiance : normalité et χ^2 , optimalité des zones.
- Tests d'Hypothèses : $F'\theta = d$ contre $F'\theta \neq d$

Quasi-vraisemblance asymptotique

- préalables :

A_n est asymptotiquement définie positive si il existe D_n telle que $A_n - D_n$ est définie positive et $\|D_n\| \rightarrow 0$

$$A = A^{1/2} A^{r/2}$$

$$G_T^{(n)} = (E(\nabla G_T))^{-1} G_T$$

- Q_T est un quasi-score asymptotique si

$$E(Q_T^{(n)} Q_T^{(n)'})^{-1/2} E(G_T^{(n)} G_T^{(n)'}) E(Q_T^{(n)} Q_T^{(n)'})^{-r/2} - I$$

est asymptotiquement définie positive.

Modèle auto-normal

- $y_i | y_{[i]}$ suit une $N(\beta w_i' y, \tau_i^2)$

y suit une $N(0(I - \beta W)^{-1} M)$ avec $M = \text{diag}(\tau_i^2)$

- logvraisemblance donne le score

$$-y' W M^{-1} y + \frac{\partial \log(|I - \beta W|)}{\partial \beta}$$

- approche quasi-vraisemblance : $\sum a_i (y_i - \beta w_i' y)$

$$G^* = \sum \frac{w_i' y (y_i - \beta w_i' y)}{\tau_i^2} = y' W M^{-1} y - \beta y' W M^{-1} W' y$$

- Pseudo-vraisemblance : maximum de $\sum \frac{1}{2\tau_i^2} (y_i - \beta w_i' y)^2$
La nullité de la dérivée conduit à la même équation que la QV précédente.

Modèle conditionnels

Si $p(y_i|y_{[i]}, \theta)$ on peut prendre $G = \sum a_i \frac{\partial \log p(y_i|y_{[i]}, \theta)}{\partial \theta}$

$$G^* = \sum E\left(\frac{\partial^2 \log p_i(\theta)}{\partial \theta^2}\right)' \left(E\left(\frac{\partial \log p_i(\theta)}{\partial \theta} \frac{\partial \log p_i(\theta)'}{\partial \theta}\right)\right)^{-1} \frac{\partial \log p_i(\theta)}{\partial \theta}$$

Espérances conditionnelles ?

Relations avec PV ?

Intérêts ?

QV composée, Projection, Nuisance

- Plusieurs $G_{i,T}(\theta)$ on cherche $H = \sum \alpha_{i,T} G_{i,T}(\theta) = \alpha' G$

$$H^* \text{ à partir de } \alpha^{*'} = E(GG')^{-1} E(\nabla G)$$

- $F'\theta = d$, G fonct. estimante, $P_V = F(F'V^{-1}F)^{-1}F'V^{-1}$

$$(M1) \ G(\hat{\theta}) = 0 \text{ et } \tilde{\theta} = (I - P_V)' \hat{\theta} + V^{-1} F(F'V^{-1}F)^{-1} d$$

$$(M2) \ (I - P_V)G(\tilde{\theta}) = 0 \text{ et } F'\tilde{\theta} = d$$

$$(M3) \ G(\tilde{\theta}) + F\lambda = 0 \text{ et } F'\tilde{\theta} = d$$

Optimalité en prenant $V = \mathcal{E}(G)$, les méthodes sont équivalentes (au premier ordre), si Q est un Quasi-Score il y a optimalité par rapport à tous les G .

- $\theta' = (\phi', \psi')$ si Q est un Quasi-Score alors Q est optimal pour l'estimation de ϕ .

de EM à Projection-Solution

$X = (Y, Z)$, Y est observé

$$\frac{\partial \log L(\theta; Y)}{\partial \theta} = E_{\theta} \left(\frac{\partial \log L(\theta; X)}{\partial \theta} \mid Y \right)$$

étape maximisation : Max $E_{\theta_0}(\log L(\theta; X) \mid Y)$

moralement on cherche à résoudre $\frac{\partial \log L(\theta; Y)}{\partial \theta} = 0$ en résolvant

$$\frac{\partial}{\partial \theta} E_{\theta^{(p)}}(\log L(\theta; X) \mid Y) = 0$$

à cause de

$$\frac{\partial \log L(\theta; Y)}{\partial \theta} = \left(\frac{\partial}{\partial \theta} E_{\theta_0}(\log L(\theta; X) \mid Y) \right)_{\theta_0=\theta}$$

- $Q(\theta|X)$ Quasi-Score sur \mathcal{H}_X pour X
- Projection :
 $H(\theta|\theta_0; Y)$ tel qu'il réalise le min pour G dans \mathcal{H}_Y de

$$E_{\theta_0}(\|G(\theta; Y) - Q(\theta|X)\|^2)$$

- Solution : $\theta^{(p+1)}$ tel que

$$H(\theta^{(p+1)}|\theta^{(p)}; Y) = 0$$

- si $\theta^{(p)} \longrightarrow \tilde{\theta}$
alors $H(\tilde{\theta}|\tilde{\theta}; Y)$ est un Quasi-Score sur \mathcal{H}_Y

Au-delà de la vraisemblance

- L'approche Quasi-Vraisemblance permet d'étendre le RELM au cas non-gaussien.
- Généralisation du score d'une diffusion à $dX_t = dA_t + dM_t$
- Champ de Markov caché :
 $y = \beta Wy + \varepsilon$ avec $E(\varepsilon_i | y_{[i]}) = 0$ $var(y_i | y_{[i]}) = \tau^2$
observation de $z = By + \eta$, B connu, $E(\eta) = 0$,
 $var(\eta) = \sigma^2 I$

Estimer y à β connu en combinant $A\varepsilon$ et $B\eta$

$$y = \left(\frac{I - \beta W}{\tau^2} + \frac{B' B}{\sigma^2} \right)^{-1} \frac{B' z}{\sigma^2}$$

Estimer β avec $\varepsilon' S \varepsilon - E(\varepsilon' S \varepsilon)$, S matrice à trouver

conduit à $y' Wy - tr(W(I - \beta W)^{-1}) = 0$

(autre solution utiliser $y' Wy - \beta y' W W' y$)