

Application de méthodes statistiques aux modèles dynamiques pour l'agronomie et l'élevage

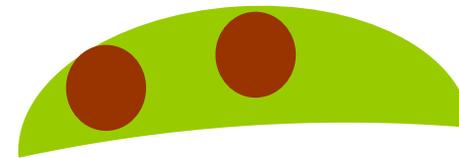
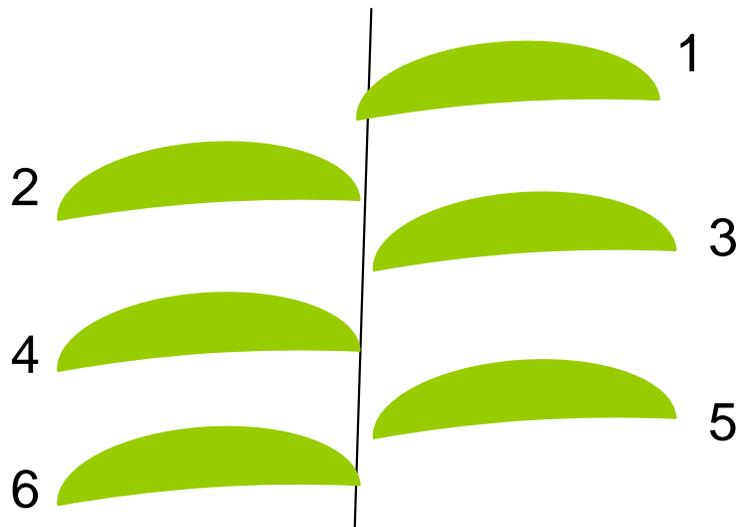
cas d'étude Septolis

Modèle pour septoriose du blé

Daniel Wallach (INRA)



Le système



$Y(t,l)$ = fraction de la
feuille l infectée jour t
(ici $Y(t,l) \sim 0.3$)



Le modèle

- David Gouache, Arvalis Institut du végétal
- D'après Audsley, Milne, Paveley, 2005,
Ann Appli Bot



Équation de base

- Fraction de la feuille l infectée, jour t

$$Y(t, l) = \sum_{i=1}^t I(i, l) y [T(t) - T(i)]$$

$I(i, l)$ = nombre d'infections jours précédents

$y [T(t) - T(i)]$ = taille d'une infection du jour i

Chaque infection a une croissance logistique



Nombre d'infections chaque jour

- Calculer production de spores
- Spores qui arrivent sur chaque feuille
- Spores qui donnent une infection



Production de spores par des infections

- Ça dépend de la surface infectée

$$U(t, l) = 1 - e^{-a[Y(t, l) + I_s \delta(l-6)]}$$



Spores qui arrivent à la feuille l

$$F(t, l) = U_g e^{-kh_g(t)} + \sum_{j=l+1}^6 U(t, j) e^{-kh_j(t)} + \rho U(t, l)$$

= spores du sol

+ spores des autres feuilles

+ auto-infection



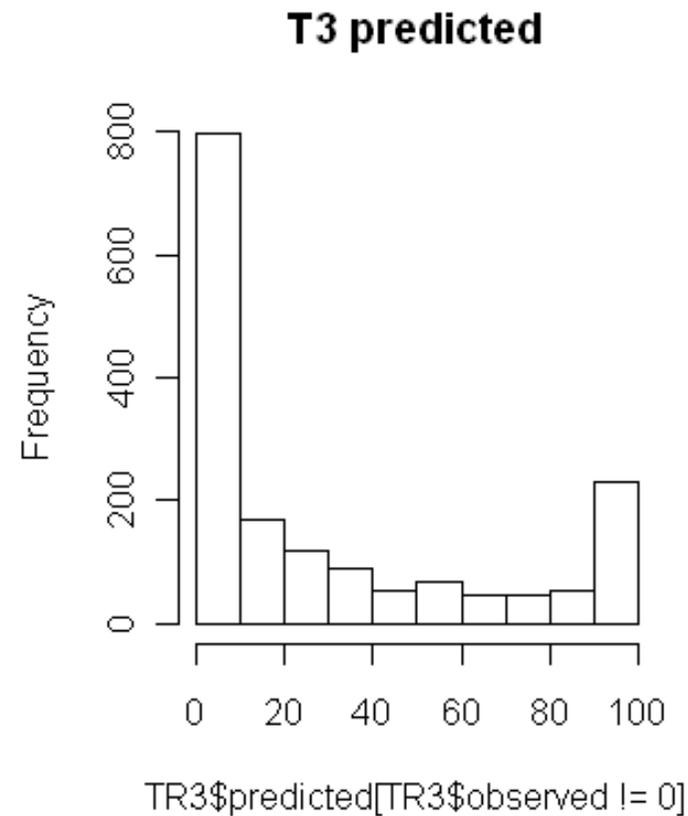
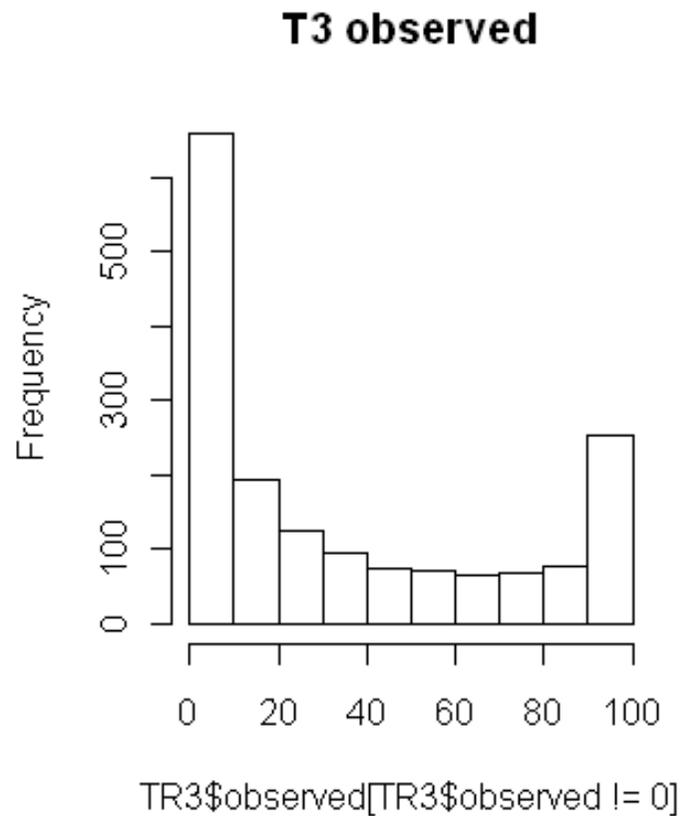
Nombre d'infections

$$I(t, l) = F(t, l) f_{\text{pluie}} f_{\text{niveau maladie}} f_{\text{fraction visible}} f_{\text{fraction saine}}$$



Les données

- 2001 données 157 sites



Les transformations considérées (données et modèle)

data set	data transformation
T1	$y_{sfi} = \sin^{-1} \left(\sqrt{d_{sfi}} \right)$
T2	$y_{sf1} = \sin^{-1} \left(\sqrt{d_{sf1}} \right)$ $y_{sfi} = \sin^{-1} \left(\sqrt{d_{sfi} - d_{sf(i-1)}} \right) \quad i > 1$
T3	$y_{sfi} = d_{sfi}$
T4	$y_{sf1} = d_{sf1}$ $y_{sfi} = d_{sfi} - d_{sf(i-1)} \quad i > 1$



Les paramètres

- Estimer 3 paramètres par moindres carrés
- Autres paramètres de la littérature

$$\hat{\theta} = \arg \min_{\theta} \left[\sum (Y - f(X; \theta, \theta_{lit}))^2 \right]$$

	θ_1 (coeff.mult)	θ_2 (echelle)	θ_3 (prod.inoc)
T1	7.05	13.2	18.6
T2	4.85	11.5	15.9
T3	7.89	14.8	16.9
T4	4.70	11.3	29.5



Objectif

- Estimer la qualité de prédiction
 - Variable: fraction surface infectée, toutes feuilles confondues, toutes dates confondues
 - C'est ce que l'on mesure
 - Population cible: Parcelles agriculteurs de blé en France
 - Critère: erreur de prédiction moyenne, intervalles de confiance



Qualité d'ajustement

$$MSE = \sum (y_i - f(X_i; \hat{\theta}_{MV}))^2 / N = \hat{\sigma}_{MV}^2$$

$$MSE = \text{biais}^2 + SDSD + LCS$$

$$\text{biais}^2 = \left[(1/N) \sum (y_i - f(X_i; \hat{\theta}_{MV})) \right]^2$$

$$SDSD = (\sigma_y - \sigma_{f(X; \hat{\theta}_{MV})})^2$$

$$LCS = 2\sigma_y \sigma_{f(X; \hat{\theta}_{MV})} r$$

$$EF = 1 - \frac{\sum (y_i - f(X_i; \hat{\theta}_{MV}))^2}{\sum (y_i - \bar{y})^2}$$



Résultats

	eff	MSE	biais ²	SDSD	LCS
TR1	0.62	478	26	3	449
TR2	0.59	519	73	32	414
TR3	0.62	477	17	1	459
TR4	0.59	513	66	29	418



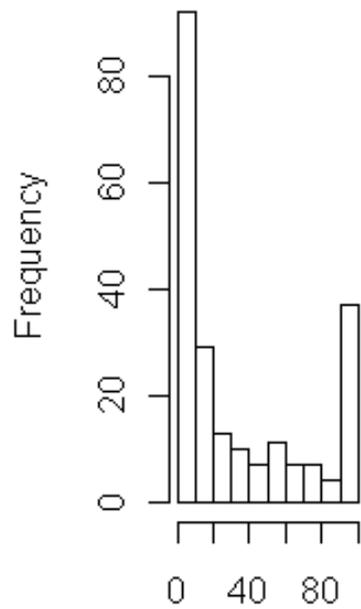
Erreur de prédiction

- En général, si on utilise les mêmes données pour estimer les paramètres et pour estimer MSE, alors MSE sous estime MSEP
- Mais l'erreur dépendra de $p/n = 3/2001$.
- On devrait pouvoir estimer MSEP par MSE

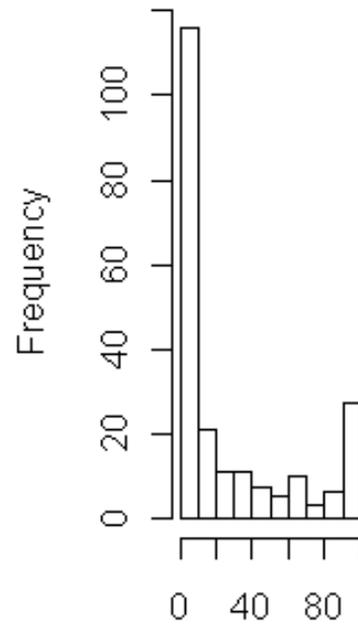


Données 2008

observed damage

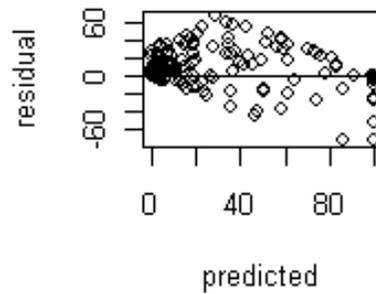


predicted damage

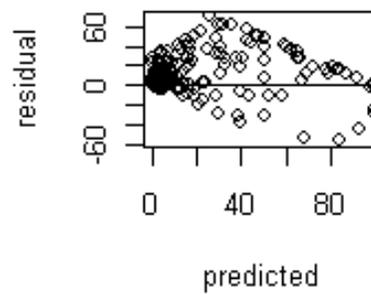


Erreurs de prédiction

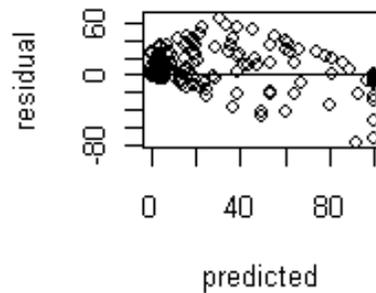
TR1S for original data



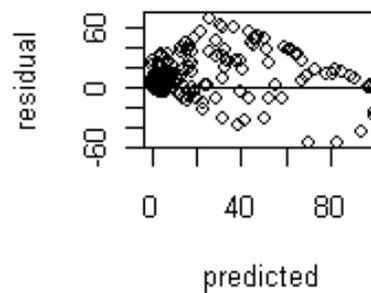
TR2S for original data



TR3S



TR4S for original data



Qualité de prédiction

	asin	asinDiff	dégâts	dégâtsDiff
efficience	0.73	0.68	0.73	0.69
MSEP	341	392	331	386
biais ²	31	63	24	60
SDSD	9	37	5	36
LCS	302	293	303	291
nombre valeurs extrêmes	14	15	13	14



Intervalles de confiance



Calcul des intervalles de confiance

- La variance d'une prédiction

$$\begin{aligned}\hat{\text{var}}(\hat{y}) &= z_i^T (\text{var } \hat{\theta}_{MV}) z_i + \hat{\sigma}_{MV}^2 \\ &= \hat{\sigma}_{MV}^2 z_i^T (Z^T Z)^{-1} z_i + \hat{\sigma}_{MV}^2\end{aligned}$$

- L'intervalle de confiance

$$CI_{\alpha} = \left[\hat{y} - t_{n-p}^{\alpha/2} \sqrt{\hat{\text{var}}(\hat{y})}, \hat{y} + t_{n-p}^{\alpha/2} \sqrt{\hat{\text{var}}(\hat{y})} \right]$$



Hypothèses

$$y_{sfi} = f_{fi}(X_{sfi}; \theta) + \varepsilon_{sfi}$$

$$E(\varepsilon_{sfi} | X_{sfi}) = 0$$

espérance des erreurs=0

$$\text{var}(\varepsilon_{sfi} | X_{sfi}) = \sigma^2$$

variance constante

$$\varepsilon_{sfi} | X_{sfi} \square N(0, \sigma^2)$$

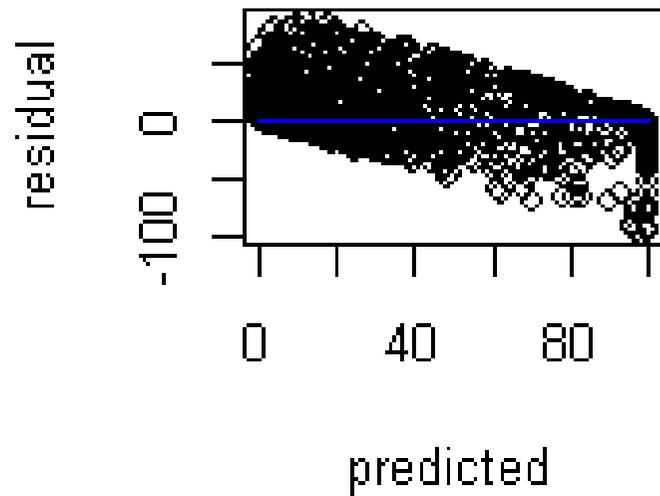
distribution normale

ε_{sfi} indépendants

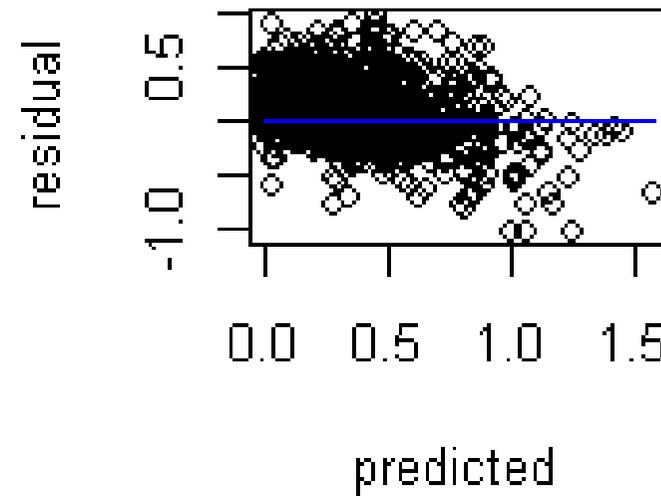
erreurs indépendantes



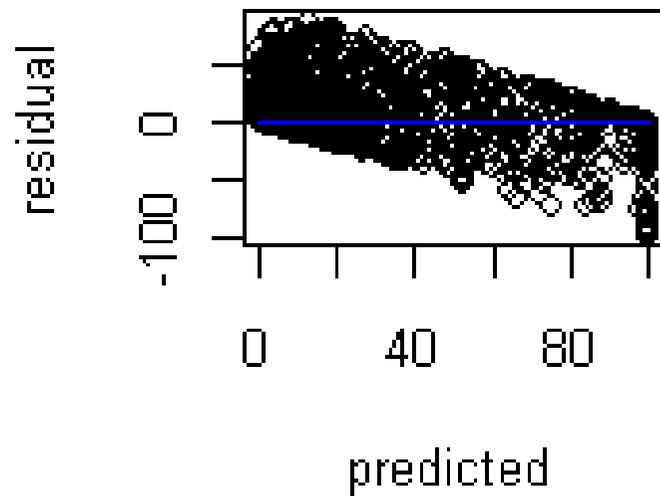
TR1S obs-pred AS



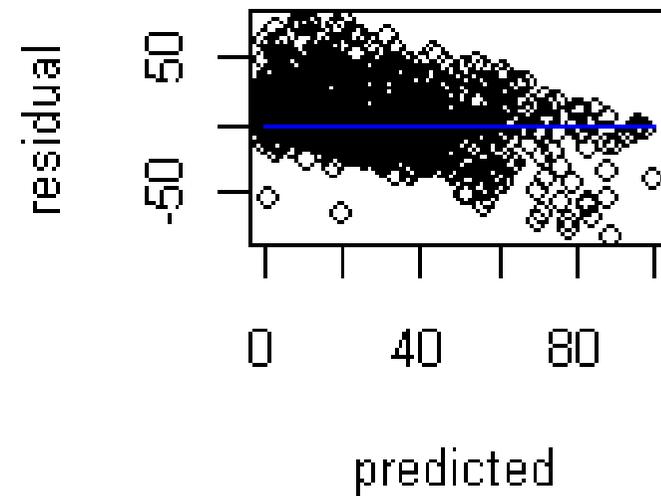
TR2S obsDiff-predDiff AS



TR3S obs-pred



TR4S obsDiff-predDiff

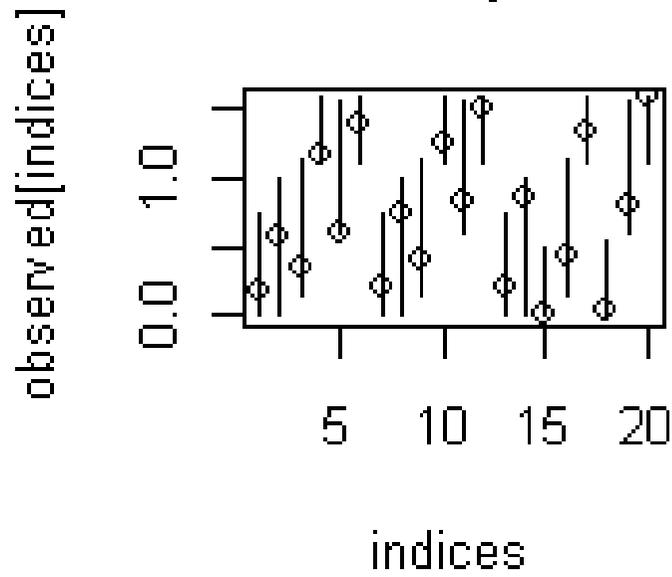


Conclusions sur hypothèses

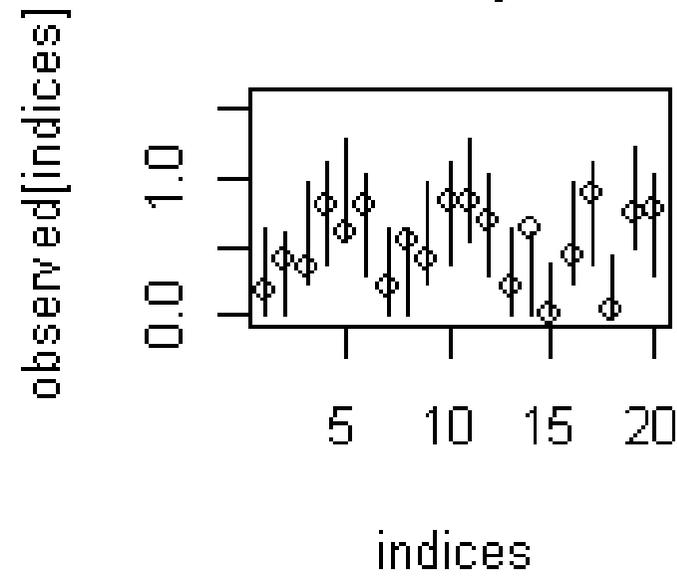
- Toutes fausses



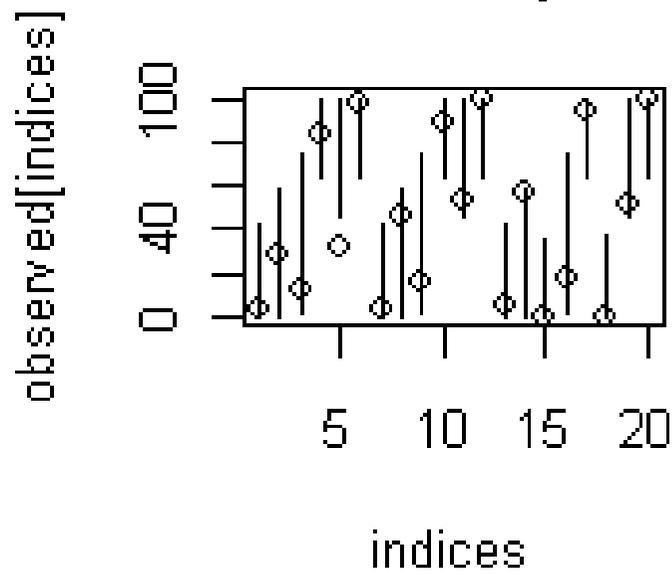
TR1S obs-pred AS



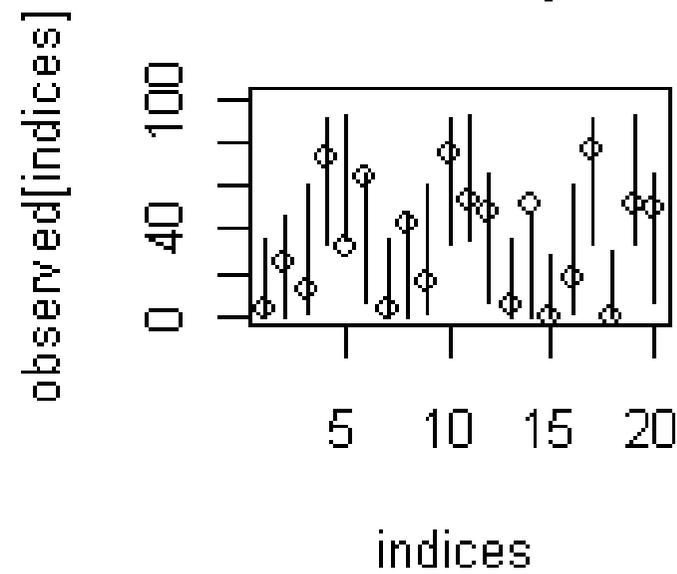
TR2S obsDiff-predDiff AS



TR3S obs-pred



TR4S obsDiff-predDiff



Fraction dans l'intervalle

	Fraction in 90% CI	ave obs value	ave length CI	min	max
TR1	0.86	0.51	69	0	1.57
TR2	0.87	0.26	53	0	1.57
TR3	0.89	30	45	0	100
TR4	0.86	17	38	0	100



Conclusions

- On traite le modèle comme un modèle de régression non-linéaire classique, avec 3 paramètres.
- Et le fait que c'est un modèle mécaniste?
 - Equations dynamiques.
 - Mais on regarde équations après intégration
 - Beaucoup de paramètres
 - Mais on n'a estimé que 3.
 - Beaucoup de variables explicatives
 - Mais on ne regarde que les prédictions (et non pas l'effet de chaque variable explicative)



THE END (for now)

