

Modèles d'extrêmes et prédicteurs

Olivier Mestre ^(1,2)

(1) Météo-France, Ecole Nationale de la Météorologie, Toulouse, France

(2) Université Paul Sabatier, LSP, Toulouse, France

Basé sur des études réalisées en collaboration avec :

Stéphane Hallegatte (CIRED, Météo-France)

Sébastien Denvil (IPSL/LMD)

Fabrice Chauvin (CNRM/GMGEC)

Extrêmes

- Une réponse à des **problèmes concrets**
 - dimensionnement d'ouvrages de BTP
 - hydrologie, crues, inondations
 - assurances
 - pollution...
- Paramètres : précipitations, vitesse du vent, température, hauteurs de neige...
- Un problème **délicat à traiter** :
 - estimation d'événements très rares ou... qui n'ont jamais eu lieu !
 - estimation de quantiles d'ordre très élevé, extrapolation

Risque

- **RISQUE**

X : variable étudiée, de loi

x : seuil de dimensionnement

r : Risque= $P[X > x]$

Commanditaire : fixe le risque r

Météo-France : estime x

x = Quantile d'ordre 1-r de la loi de la variable X

Durée de retour


- DUREE DE RETOUR

- Usuellement, le risque r est exprimé comme comme une **durée moyenne entre deux événements** $\{X > x\}$
- Echantillon de données quotidiennes

Seuil de durée de retour 20 ans


=

Quantile d'ordre 0,99983 de la distribution de X




Théorème des valeurs extrêmes

- Illustration par l'exemple...



Théorème des valeurs extrêmes



ATTENTION

- Il existe des contre-exemples.
- En particulier :

**LE THEORÊME DES VALEURS EXTRÊMES NE S'APPLIQUE PAS
AUX LOIS DISCRETES**

- Les paramètres géophysiques ne sont pas distribués comme des lois pures

Vérifier l'adéquation du modèle basé sur les lois d'extrêmes !

Loi GEV

- **PRESENTATION UNIFIEE : $GEV(\mu, \sigma, \xi)$**

On introduit le **paramètre de forme ξ**


$\xi=0$ **Gumbel** lois non bornées
queues légères (\downarrow exponentielle)

$\xi>0$ **Fréchet**
lois non bornées, queues lourdes (\downarrow puissance)

$\xi<0$ **Weibull**
lois bornées

La GEV par l'exemple

- Petite manip!



Fonction de répartition

- Fonction de répartition G

$$P[M_N < x] = G(x) = \exp \left[- \left(1 + \xi \cdot \left(\frac{x - \mu}{\sigma} \right) \right)^{-\frac{1}{\xi}} \right]$$

- Quantile associé à la durée de retour T

$$x_T = \mu - \frac{\sigma}{\xi} \left[1 - \left(-\ln \left(1 - \frac{1}{T} \right) \right)^{-\xi} \right]$$

- Avantages

- Max annuels: seuil de durée de retour 20 ans = quantile $0,95=1-1/20$
- **La loi est théoriquement connue**

Estimons un seuil de durée de retour

- Librairie « `extRemes` » sous R
- Précipitations au pas de temps quotidien à Toulouse

Alternatives

- **METHODES A SEUIL**

Loi des dépassement d'un seuil (seuil élevé)

- **K plus grandes valeurs**

- **Processus de points**

Extrêmes et covariables

- **BUT**

- Etudier l'influence de covariables sur les extrêmes
- Etudier l'évolution des extrêmes (covariable = temps)



- **Principe**

- Modéliser les paramètres en fonction des covariables
- Giacomo Parsimoni (1725-1755)

« De deux modèles d'égale beauté, choisir le moins compliqué »




Maxima annuels de températures à Toulouse




Exemple : Minima annuels de températures à Toulouse

EVOLUTION DES MINIMA ANNUELS DE TN



EVOLUTION DES MINIMA ANNUELS DE TX






Problème...

- **Variations conjointes de paramètres non indépendants**

modèles paramétriques difficiles à formuler *a priori*





Modèles additifs

- Philosophie

**Approche basée sur les données
Plutôt que basée sur un modèle**

Technique exploratoire

- Inférence : approximations uniquement
- 

Modèles additifs

- Modèles additifs:

Une manière efficace de faire de la régression non-linéaire

- ATTENTION!

**ADAPTE A UN FAIBLE NOMBRE DE
PREDICTEURS**

2, 3 au maximum

Modèles linéaires et additifs

- **Modèle linéaire gaussien** : $IE[Y]=\beta_0+\beta_1X_1+\beta_2X_2$
- **Modèle additif gaussien** : $IE[Y]=S_1(X_1)+S_2(X_2)$

S_1, S_2 fonctions « lisses » des prédicteurs X_1, X_2 , (LOESS, SPLINE)

Estimation de S_1, S_2 : « Backfitting »

- **PRINCIPE DU BACKFITTING**

$Y=S_1(X_1)+e \rightarrow$ estimation S_1^*

$Y-S_1^*(X_1)=S_2(X_2)+e \rightarrow$ estimation S_2^*

$Y-S_2^*(X_2)=S_1(X_1)+e \rightarrow$ estimation S_1^{**}

$Y-S_1^{**}(X_1)=S_2(X_2)+e \rightarrow$ estimation S_2^{**}

$Y-S_2^{**}(X_2)=S_1(X_1)+e \rightarrow$ estimation S_1^{***}

Etc... jusqu'à convergence

Modèles Additifs Généralisés (GAM)

- Extension à des variables non gaussiennes
- Modèles additifs généralisés (GAM) : modèles additifs du paramètre naturel de lois de la famille exponentielle (Poisson, Binomial, Gamma, Gauss...).

$$g[\mu]=\theta=S_1(X_1)+S_2(X_2)$$

- Modèles « Vecteurs Additifs Généralisés » (VGAM): généralisation du concept de régression...

Modélisation VGAM de la GEV

- **Comment?**

Modélisation VGAM : Yee & Wild, 1996

Implémentation : package **VGAM sous R** (Yee, 2006)

Algorithme *vector backfitting* et *vector spline*.

- **Attention**

- Peu de prédicteurs
- Intervalles de confiance ponctuels : pas de matrice de covariance des estimateurs
- Convergence parfois difficile à obtenir. Utiliser des fonctions de lien: $\log(\sigma)$



Exemple

Evolution des maxima de températures dans un GCM

Avec Sébastien Denvil, LMD







Données

- **Maxima annuels de température**
- **Période 1860-2100**
- **Modèle IPSL GCM (5ème IPCC)**
- **Concentration des gaz à effet de serre et des aérosols**
avant 2000 : observations
2000-2100 : SRES-A2 IPCC


Exemple : point de grille sur la France

- Rôle majeur joué par le CO₂. Légère modulation au cours du temps.
- $\mu = f_1(\text{CO}_2) + f_2(\text{YEAR})$ $\sigma = g_1(\text{CO}_2) + g_2(\text{YEAR})$ $\xi = \text{constant}$




Exemple : point de grille sur la France

- Evolution du quantile 0,90 sur la France




Paramètres de la GEV




Paramètres de la GEV

$\mu : 2000$




Paramètres de la GEV

μ : 2100




μ :2100-2000 différence


$\delta(\mu) : 2100 - 2000$




Paramètres de la GEV




Paramètres de la GEV



σ :2100-2000 différence




Paramètres de la GEV




Quantile 0,90 du TX annuel

1860 : 90th PERCENTILE OF TEMPERATURE ANNUAL MAXIMA




Quantile 0,90 du TX annuel

2000 : 90th PERCENTILE OF TEMPERATURE ANNUAL MAXIMA




Quantile 0,90 du TX annuel

2100 : 90th PERCENTILE OF TEMPERATURE ANNUAL MAXIMA



Quantile 0,90 du TX annuel : Différence 2100-2000





Exemple


Energie intégrée maximale (PDI) des cyclones sur l'Atlantique Nord

Avec Stéphane Hallegatte, CIRED, ENM



PDI maximale annuelle

- Période : 1880-2005



- Prédicteurs potentiels : NAO, SOI, AMO, SST, Température Globale

Modélisation VGAM de la GEV

- Pourquoi?

Variations conjointes de paramètres non indépendants: les modèles paramétriques sont difficiles à formuler





μ , σ modélisés comme des fonctions souples de covariables
 ξ reste constant

$$\mu = \mu_0 + f_1(X_1) + f_2(X_2)$$

$$\sigma = \sigma_0 + g_3(X_3) + g_4(X_4)$$

$$\xi = \xi_0$$

Estimation des effets additifs




Modèle VGLM de la PDI


- Modèle paramétrique suggéré par les résultats du VGAM
- μ modélisé comme une fonction linéaire de SOI et SST
- σ modélisé comme une fonction linéaire de SST+modèle à rupture en SOI
- Inférence (tests de déviance)
 - Approximation Gumbel valide (p value : 0.36)
 - Rupture autour de -0.55hPa

Paramètres de la distribution Gumbel

PDI location parameter




PDI scale parameter




Quantile 0.90 de la PDI max annuelle

extreme PDI 90th quantile




Erreur-type (méthode Delta)

Standard error of extreme PDI 90th quantile




Model fit

HISTOGRAM OF MODELLED PDI




Prediction

OBSERVED vs MODELLED PDI (MEDIAN, Q90)




Reliability plots

- Learning



- Cross validation



CONCLUSION

- GAM & VGAM
- Basé sur les données
- Technique exploratoire flexible
- Inférences moins précises
- Pas beaucoup de prédicteurs
- Problèmes de convergence possibles



Bibliographie

- GAM

Hastie & Tibshirani, 1990

Generalized Additive Models, Monographs on statistics and applied probability 43, Chapman & Hall/CRC, 335 p.

- VGAM

Yee & Wild, 1996

Vector Generalized Additive Models

JRSS series B, Vol. 58, n°3, pp. 481-493

Bibliographie

- VGAM et extremes

Yee & Stephenson, 2007

Vector Generalized and Additive Extreme Value Models.

Chavez-Demoulin & Davison, 2005

Generalized Additive Modelling of sample extremes

Applied Statistics 54, 207-222.

Calcul


- Librairies R

« gam » Hastie

« VGAM » Yee, 2006





Nombre annuel de Cyclones

- Nombre de cyclones ~ distribution Poisson





Facteurs influençant le nombre de cyclones

- Modélisation GAM, prédicteurs (YEAR,SST,SOI,NAO)



Modèle GAM


- $\text{Log}(\lambda) = \beta_0 + S_1(\text{SST}) + S_2(\text{SOI})$



Modèle paramétrique

- “Modèle à ruptures” (avec contrainte de continuité) en SOI mis en évidence par le GAM
- $\log(\lambda)$ $= \beta_0 + \beta_{\text{SOI}}^{(1)} \text{SOI} + \beta_{\text{SST}} \text{SST}$ $\text{SOI} < K$
 $= \beta_0 + \beta_{\text{SOI}}^{(1)} \text{SOI} + \beta_{\text{SOI}}^{(2)} (\text{SOI} - K) + \beta_{\text{SST}} \text{SST}$ $\text{SOI} \geq K$
- Meilleur ajustement obtenu pour $K=1$
log-likelihood=-316.16, à comparer avec -318.71 (linéarité)
p value=0.02
- L'estimation du nombre de cyclones s'en déduit directement en fonction de SOI et SST

Nombre de cyclones prévu



Observé vs prévu: $r=0.6$

