

**Pascal Irz**


**Michaël Levi-Valensin**

Commissariat Général au  
Développement Durable, Orléans

# Tendance nationale de l'Indice Poisson Rivière estimée par un Modèle Additif Généralisé



# Cadre institutionnel



## Missions du SOeS

- Systèmes d'informations sur la biodiversité et l'eau
- Production d'indicateurs nationaux et/ou régionaux
- Synthèses thématiques
- Information du public

## Travaux engagés

- Expérimentation des méthodes d'estimation de tendances (modélisation statistique)
- Précurseurs à la fois sur les types de modèles testés et sur l'utilisation de R






# Les acteurs sont nombreux



Ministère de l'Environnement, de l'Énergie et de la Mer

# Objectif

Evaluer si la qualité des cours d'eau, mesurée par l'état des communautés de poissons, tend à s'améliorer, ou à se dégrader sur le « long terme »



Recours à l'IPR



# Qu'est-ce que l'IPR ?

- ✓ Outil d'évaluation de la qualité des cours d'eau<sup>1</sup> produit par l'Onema<sup>2</sup>
- ✓ La situation de référence dépend de 9 variables environnementales
- ✓ Pour chacune des 7 métriques


*Score = métrique prédite en situation de référence – métrique observée*

- ✓  $Note\ IPR = \sum_{i=1}^7 Score$
- ✓ IPR varie de 0 (conforme à la référence) à l'infini
- ✓ 5 classes de qualité

Note de l'IPR	Classe de qualité
<7	Excellente
]7-16]	Bonne
]16-25]	Médiocre
]25-36]	Mauvaise
>36	Très mauvaise


<sup>1</sup> Oberdorff *et al.* 2002 Development and validation of a fish-based index for the assessment of "river health" in France. *Freshw. Biol.* 47, 1720–1734.

<sup>2</sup> Onema, 2006. L'indice poissons rivière (IPR) - Notice de présentation - Edition avril 2006. Office National de l'Eau et des Milieux Aquatiques, Vincennes, France.



# Variabilité du réseau de stations

N ~ 2500 pêches sur 19 ans



# Comment estimer une tendance d'évolution par modélisation statistique ?

## Difficultés : Nombreux biais possibles

- ✓ Variabilité du réseau de stations
- ✓ Variabilité des saisons d'échantillonnage

## Modèle additif

- linéaire si la forme de la relation est linéaire : GLM, ANOVA
- généralisé si la relation est non linéaire mais indéterminée *a priori* (fonction spline ou smooth) : GAM

Modèle pour données répétées => effet aléatoire

$$y_{i,t} = \eta_t + \gamma_i + \varepsilon_{i,t}$$



avec  $t \in \{1, T\}$  l'année d'observation et  $i \in \{1, \dots, N\}$  l'index de station.



# Prétraitement de l'indice

- ✓ *Distribution asymétrique de l'IPR -> normalisation et inversion*

$$IPR \rightarrow \max(\ln(IPR)) - \ln(IPR)$$



# Choix du modèle

Modélisation NDQ ~ *année* + covariables

## ✓ **Covariables**

- Mesures répétées -> *code station*
- Données spatialisées -> *coordonnées, bassin*
- Saisonnalité -> *jour de pêche* codé de 1 à 365

## ✓ **Spécifications**

- *Bassin en effet aléatoire*
- *Code.station en effet aléatoire « emboîté » dans le bassin*
- *Spline (longitude, latitude)*
- *Année -> soit qualitative pour indice annuel, soit quantitative (comme dans les régressions de Poisson, logiciel TRIM\*)*

\*TRends and Indices for Monitoring data

# Package mgcv

- *Mixed GAM Computation Vehicle* : nombreux modèles linéaires et additifs avec des fonctions splines et smooth
- Fonction **gam**
- « *Backfitting algorithm* » pour les termes de lissage et validation croisée généralisée (GCV) pour ajuster le paramètre de lissage
- Pour des modèles mixtes (avec effets aléatoires), en grande dimension, fonction **bam** (*Big Additive Models*)
  - moins d'espace mémoire
  - scinde les données en morceaux (« *chunks* »)



# L'année en variable qualitative

```
Mod <- bam (NDQ ~ as.factor(annee) + s(jour.annee, bs = "cc") +  
s(code.station, bs = "re") + s(xlambert93, ylambert93) +  
s(bassin, bs = "re" )
```

- Extraction des éléments du modèle `summary(mod)$p.table`

coefficients annuels entre 1996 et 2013, écarts à la modalité de référence en 1995

**Std.Error** : erreur-type


- Représentation des tendances annuelles (ggplot2)

Indices en base 100 :

$\text{ind100} = 100 * (1 + \text{Estimate})$

Intervalles de confiance :

$\text{ind100} \pm 1.96 * (100 * \text{Std.Error})$





# L'année en variable quantitative

```
Mod <- bam ( logipr ~ s(annee) + s(jour.annee, bs = "cc") +  
s(code.station, bs = "re") + s(xlambert93, ylambert93) +  
s(bassin, bs = "re") )
```

*plot.gam(mod) : courbes splines  
des effets aléatoires année et  
jour*

## Notes de qualité

- inférieures à la moyenne  
jusqu'à début sept.  
(*jour.annee < 250*)
- supérieures à la moyenne  
de mi-sept. à mi oct.  
(*260 < jour.annee < 290*)



# Des prolongements de l'étude

## Sur l'IPR

- Tests de robustesse par bootstrap des estimations et des intervalles de confiance
- Cartographie et mesure de l'autocorrélation spatiale des résidus (package **ape**, fonction **I.Moran**)
- [Document de travail](#)

## Tests pour

- d'autres éléments de faune et flore
  - concentrations de macropolluants des eaux superficielles sur des bassins
- ⇒ Besoin de collaborations avec le monde académique

## Véritables développements spatio-temporels



## *Et des travaux qui se poursuivent autour de R*

- Au SOeS, utilisation de SAS pour la plupart des traitements statistiques
- Réflexion engagée sur l'utilisation progressive de R : comparatif des fonctionnalités, coût des licences  
*En ce qui concerne la modélisation, R s'avère plus adapté que SAS*
- Constitution d'un Groupe de Référents R : mise en place de formations





Merci de votre attention