



# Lissage et estimation fonctionnelle avec R

---

**Christophe POUZAT**

*Laboratoire de Physiologie Cérébrale*

*CNRS ULR 8118, Université Paris-Descartes*

# Lissage et estimation fonctionnelle avec R

Christophe Pouzat

Laboratoire de Physiologie Cérébrale, CNRS UMR 8118, Université  
Paris-Descartes

e-mail: [christophe.pouzat@gmail.com](mailto:christophe.pouzat@gmail.com)

web:

[http://www.biomedicale.univ-paris5.fr/phycerv/C\\_Pouzat.html](http://www.biomedicale.univ-paris5.fr/phycerv/C_Pouzat.html)

12 Février 2009

# De quoi va-t-on parler ?

Préliminaires : les données

Caractérisation des réponses aux odeurs

Le problème

Homogénéité et stabilisation de la variance

Splines de lissage

General Smoothing Spline

La fonction `smooth.spline`

Retour aux données

La suite

# Enregistrement *in vivo* dans le premier relais olfactif d'un insecte

Lissage et  
estimation  
fonctionnelle avec  
R

Christophe Pouzat

Préliminaires : les  
données

Réponses aux  
odeurs

Le problème

Variance

Splines de lissage

gss

smooth.spline



Retour aux  
données

La suite



Une blatte (*Periplaneta americana*) “en position” avec la sonde d’enregistrement. Photos par Laurent Moreaux et Antoine Chaffiol.

# Données brutes et détection



Vue de l'extérieur, l'activité des neurones se manifeste par l'émission d'impulsions électriques très brèves : **les potentiels d'actions**. Enregistrements par Nicole Lindemann et Antoine Chaffiol.

## D'autres techniques sont aussi applicables à ce système

Lissage et estimation fonctionnelle avec R

Christophe Pouzat

Préliminaires : les données

Réponses aux odeurs

Le problème

Variance

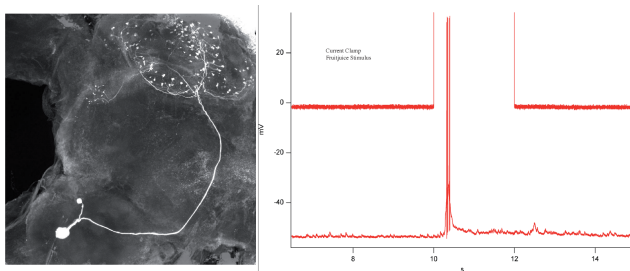
Splines de lissage

gss

smooth.spline


Retour aux données

La suite



Un exemple d'enregistrement de patch-clamp couplé à l'imagerie calcique. Ici **une cellule unique est enregistrée**. Données obtenues par Moritz Paehler et Peter Kloppenburg (Université de Cologne).

# Propriétés des décharges "brutes"

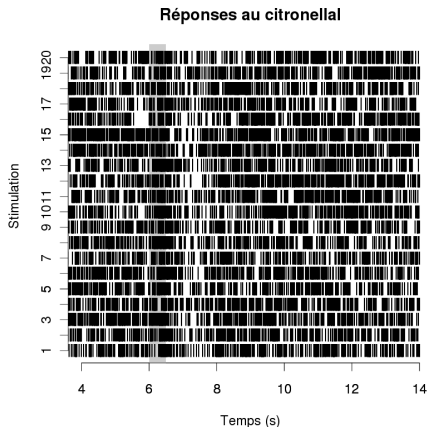


Sur des temps courts (ici 5 s) les décharges sont bien approximées par des **processus de Poisson**.

# Un exemple de réponse à une stimulation olfactive

Lissage et estimation fonctionnelle avec R

Christophe Pouzat



Préliminaires : les données

Réponses aux odeurs

Le problème

Variance

Splines de lissage

gss

smooth.spline


Retour aux données

La suite

Il est difficile de distinguer quoi que ce soit avec ce type de représentation (la valve contrôlant l'arrivée de l'odeur est ouverte dans la partie grisée).




# Estimation de la fréquence de décharge instantanée par moyennage des réponses



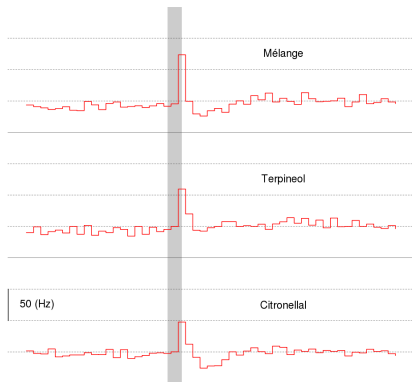
En “moyennant” les réponses des 20 stimulations et en discrétisant le temps on obtient quelque chose de plus clair (taille de la fenêtre de discrétisation : 10 ms).

# Estimation de la fréquence de décharge instantanée par moyennage des réponses



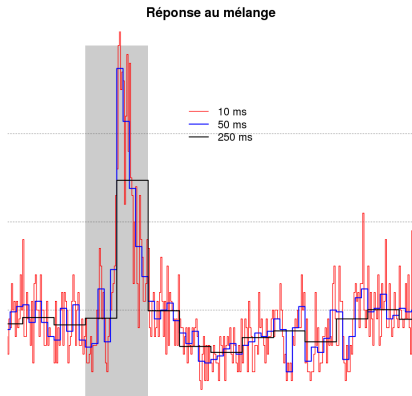
En “moyennant” les réponses des 20 stimulations et en discrétisant le temps on obtient quelque chose de plus clair (taille de la fenêtre de discrétisation : 50 ms).

# Estimation de la fréquence de décharge instantanée par moyennage des réponses



En “moyennant” les réponses des 20 stimulations et en discrétisant le temps on obtient quelque chose de plus clair (taille de la fenêtre de discrétisation : 250 ms).

# Le problème : quelle taille de bin choisir ?



Décharge du réseau entre 5.5 et 8.5 s en réponse au mélange.

# Un peu de formalisme

- ▶ Toutes les fonctions de  $\mathbb{R}$  que nous allons voir considèrent (au moins dans leur version de base) que les observations,  $Y_i$ , et le prédicteur (variable indépendante),  $x_i$  ( $i = 1, \dots, n$ ) sont reliés par le modèle de régression :

$$Y_i = \eta(x_i) + \epsilon_i, \quad i = 1, \dots, n$$

- ▶ Les  $\epsilon_i$  sont supposés être des variables aléatoires **indépendantes** et **identiquement distribuées** (IID) de moyenne 0 et de variance  $\sigma^2$ .

# Homogénéité de la variance

- ▶ Avant d'aller plus loin il peut-être utile de vérifier que l'hypothèse IID pour les  $\epsilon_i$  est raisonnable.
- ▶ On peut le faire avec un Bootstrap en ré-échantillonnant les 20 stimulations.
- ▶ Commençons par calculer le nombre total d'événements par bin :

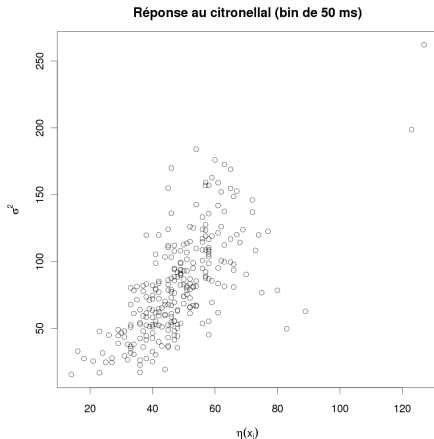
```
> citronC <- sapply(allCitron,  
+ fonction(l) {  
+ hist(l,seq(1,14,0.05),plot=FALSE)$counts  
+ } )  
> citronC.hat <- apply(citronC,1,sum)
```

# Homogénéité de la variance

- ▶ L'estimateur de bootstrap du nombre total d'événements par bin est alors :

```
> citronC.boot <- sapply(1:1000,  
+ function(idx) {  
+ myCol <- sample(1:20,20,replace=TRUE)  
+ bootD <- citronC[,myCol]  
+ apply(bootD,1,sum)  
+ }  
+ )  
> citronC.hat.var <- apply(citronC.boot,1,var)
```

# Homogénéité de la variance



Ici les  $\epsilon_i$  dépendent clairement des  $\eta(x_i)$ .



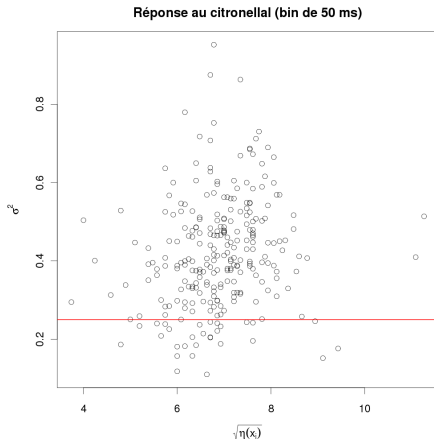
# Stabilisation de la variance

- ▶ On se souvient que les décharges spontanées correspondent approximativement à des processus de Poisson (homogènes).
- ▶ On peut alors penser que les réponses aux odeurs correspondent approximativement à des processus de Poisson inhomogène.
- ▶ On se souvient aussi qu'une distribution de Poisson de paramètre  $\geq 15$  est approximativement gaussienne avec une variance égale à la moyenne.
- ▶ On se souvient peut-être que la racine carrée d'une variable aléatoire de Poisson (de paramètre  $\geq 15$ ) est approximativement gaussienne de variance 0.25 **quelque soit la valeur du paramètre.**

# Stabilisation de la variance





```
> citronSC.hat <- sqrt(apply(citronC,1,sum))  
> citronSC.hat.var <- apply(sqrt(citronC.boot),  
+ 1,var)
```

# Stabilisation de la variance



Ici les  $\epsilon_i$  dépendent nettement moins des  $\sqrt{\eta(x_i)}$ .

# Distribution des $\sqrt{\eta(x_i)}$



Graphes quantiles-quantiles des  $\sqrt{\eta(x_i)}$  obtenus par bootstrap (réponse au citronnellal, bin de 50 ms).

# Smoothing Splines 1

Given data :


$$Y_i = \eta(x_i) + \epsilon_i, \quad i = 1, \dots, n$$

where  $x_i \in [0, 1]$  and  $\epsilon_i \sim N(0, \sigma^2)$ , we want to find  $\eta_\lambda$  minimizing :

$$\frac{1}{n} \sum_{i=1}^n (Y_i - \eta_\lambda(x_i))^2 + \lambda \int_0^1 \left( \frac{d^2 \eta_\lambda}{dx^2} \right)^2 dx$$

# Smoothing Splines 2

**A simple example with simulated data**



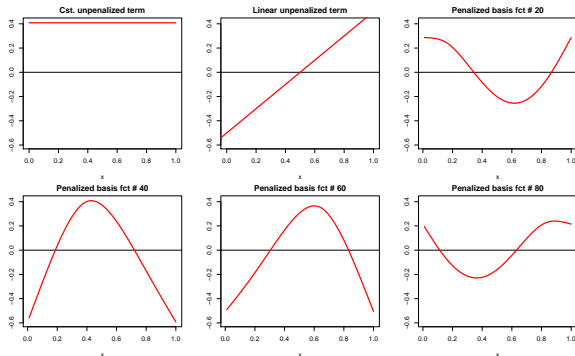
# Smoothing Splines 3

It can be shown (but it's not exactly trivial) that, for a given  $\lambda$ , the solution of the functional minimization problem can be expressed on a **finite** basis :

$$\eta_{\lambda}(x) = \sum_{\nu=0}^{m-1} d_{\nu} \phi_{\nu}(x) + \sum_{i=1}^n c_i R_1(x_i, x)$$

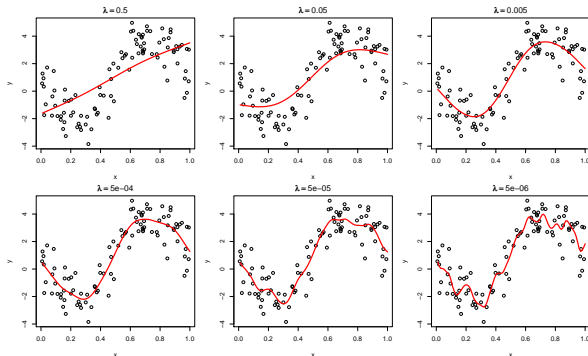
where the functions,  $\phi_{\nu}()$ , and  $R_1(x_i, )$ , are known.

# Smoothing Splines 4





# Smoothing Splines 5 : What about $\lambda$ ?



Préliminaires : les  
données

Réponses aux  
odeurs

Le problème

Variance

Splines de lissage

gss

smooth.spline

Retour aux  
données

La suite

# Smoothing Splines 6 : Cross-Validation

Ideally we would like  $\lambda$  such that :

$$\frac{1}{n} \sum_{i=1}^n (\eta_\lambda(x_i) - \eta(x_i))^2$$

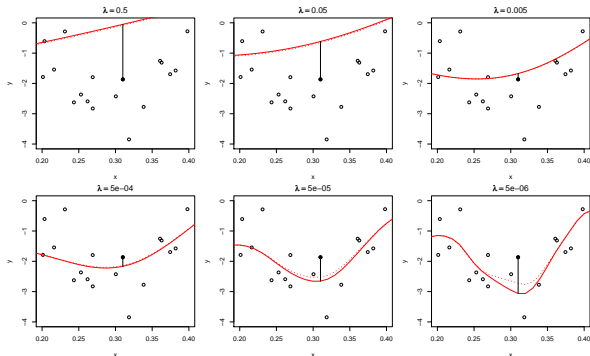
is minimized... but we don't know the true  $\eta$ . So we choose  $\lambda$  minimizing :

$$V_0(\lambda) = \frac{1}{n} \sum_{i=1}^n (\eta_\lambda^{[i]}(x_i) - Y_i)^2$$


where  $\eta_\lambda^{[k]}$  is the minimizer of the “delete-one” functional :

$$\frac{1}{n} \sum_{i \neq k} (Y_i - \eta_\lambda(x_i))^2 + \lambda \int_0^1 \left( \frac{d^2 \eta_\lambda}{dx^2} \right)^2 dx$$

# Smoothing Splines 7



# Smoothing Splines 8



Préliminaires : les  
données

Réponses aux  
odeurs

Le problème

Variance

**Splines de lissage**

`gss`

`smooth.spline`

Retour aux  
données

La suite

# Smoothing Splines 9 : The Theory (worked out by Grace Wahba) also gives us confidence bands

Lissage et  
estimation  
fonctionnelle avec  
R

Christophe Pouzat

Préliminaires : les  
données

Réponses aux  
odeurs

Le problème

Variance


**Splines de lissage**

gss

smooth.spline

Retour aux  
données

La suite

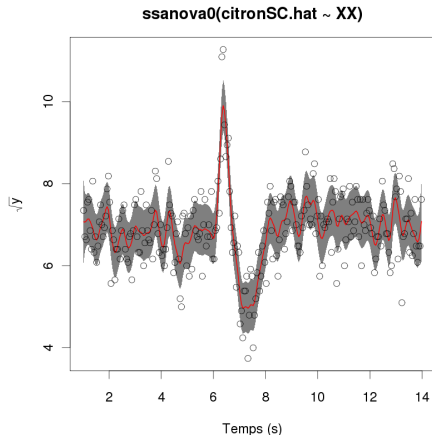


# General Smoothing Spline

- ▶ La méthodologie des splines de lissage avec paramètre de lissage estimé par validation croisée est mise en oeuvre dans le paquet **gss** (General Smoothing Spline) développé par **Chong Gu** (Université de Purdue).
- ▶ Nous utilisons d'abord la fonction `ssanova0` :

```
> XX <- seq(1.025,13.975,0.05)
> GF1 <- ssanova0(citronSC.hat ~ XX)
```

# Ajustement avec ssanova0



Les intervalles de confiance sont obtenus avec :

```
> estGF1 <- predict(GF1,  
+ newdata=data.frame(XX=XX),se=TRUE)
```

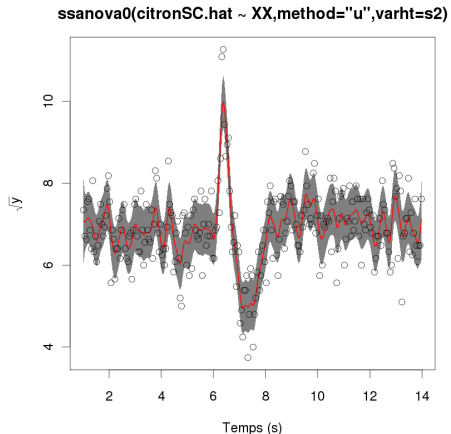
# Variation autour de `ssanova0`

- ▶ Avec `ssanova0` il est possible de fixer la variance des  $\epsilon_i$  au moment de la validation croisée :

```
> s2 <- mean(citronSC.hat.var)
> GF2 <- ssanova0(citronSC.hat ~ XX,
+ method="u", varht=s2)
```



# Variation autour de ssanova0



Il n'y a pas grande différence.

Préliminaires : les  
données

Réponses aux  
odeurs

Le problème

Variance

Splines de lissage

**gss**

smooth.spline

Retour aux  
données

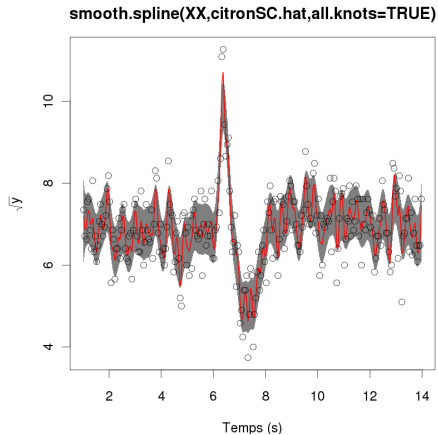
La suite

# Fonction `smooth.spline`

- ▶ Le paquet `stats` contient la fonction `smooth.spline` similaire à `ssanova0` mais “moins puissante”.
- ▶ `smooth.spline` ne génère pas d’intervalles de confiance.

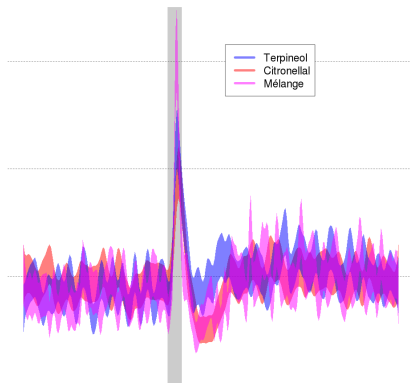
```
> SF <- smooth.spline(XX,citronSC.hat,  
+ all.knots=TRUE)
```

# Fonction smooth.spline



Les intervalles de confiance sont ceux de `ssanova0`.

# Retour aux données



Lissage et  
estimation  
fonctionnelle avec  
R

Christophe Pouzat

Preliminaires : les  
donnees

Reponses aux  
odeurs

Le probleme

Variance

Splines de lissage

gss

smooth.spline

Retour aux  
donnees

La suite

- ▶ On peut “jouer” avec d’autres arguments de `smooth.spline`, mais globalement, l’essentiel a été couvert.
- ▶ `ssanova0` peut-être utilisée avec **plusieurs prédicteurs**.
- ▶ Le paquet `gss` met en oeuvre des tests pour évaluer le rôle de différents prédicteurs.
- ▶ Avec `gss`, les  $\epsilon_i$  peuvent avoir une distribution binomiale, Poisson, inverse gaussienne, etc. Il faut alors utiliser la fonction `gssanova0`.