



Sélection de modèles pour la détection-estimation conjointe de l'activité cérébrale en IRMf

Christine Bakhous

Encadrants :

Florence Forbes

Michel Dojat

Philippe Ciuciu

Inria
INVENTEURS DU MONDE NUMÉRIQUE

NeuroSpin



Plan :




- **Introduction**
- **Modèle Linéaire Généralisé (GLM)**
- **GLM & IRMf ———▶ PyHrf**
- **Méthode de Monte Carlo Chaîne de Markov (MCMC)**
- **Premiers résultats**
- **Perspectives**

Introduction:


Protocole d'activation cérébrale

Activations neuronales

Paradigme expérimental



96x96x39x128



temps

Signal 3D + temps :

Effet *BOLD* = *Blood Oxygenation Level Dependent signal*

Introduction:

Analyse en IRMf

Spécialisation

Intégration

- Attribuer une fonction à une région donnée

1) Détection et localisation des activations à une stimulation donnée

2) Estimation de l'hémodynamique

Plus la fonction évolue



Plus la spécialisation et l'intégration sont reliées

- Etudier la connectivité fonctionnelle





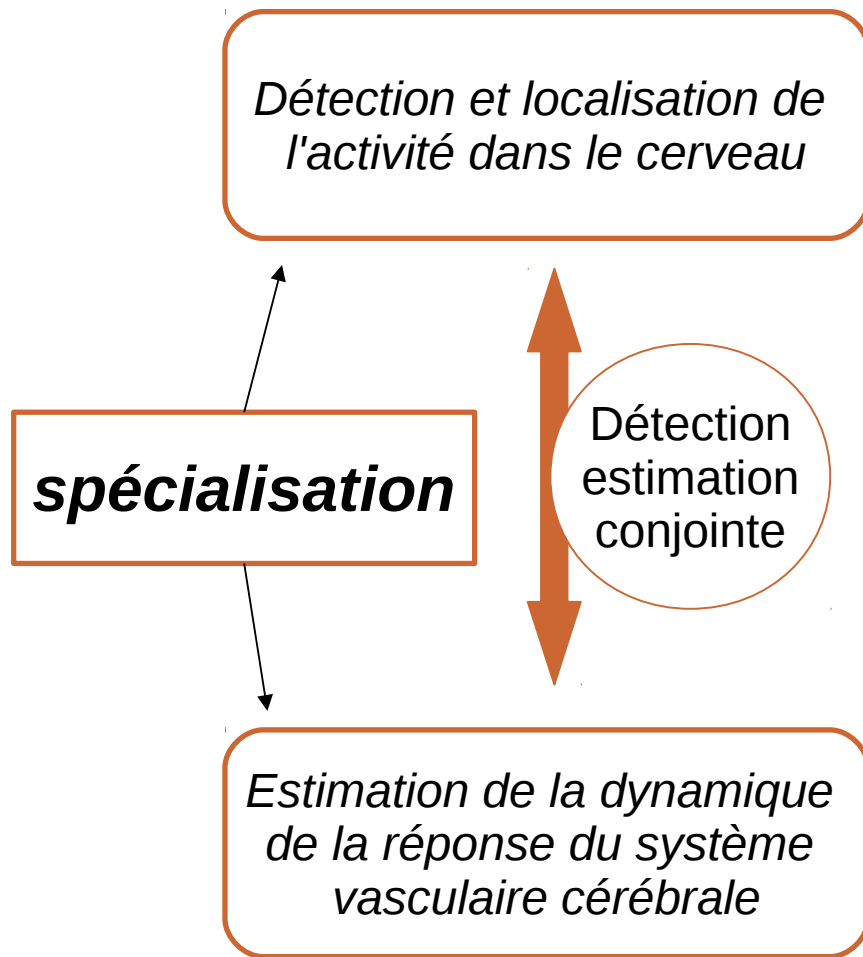
- s'intéresse de plus en plus aux données de repos (pas de paradigme expérimental)

- Ex:

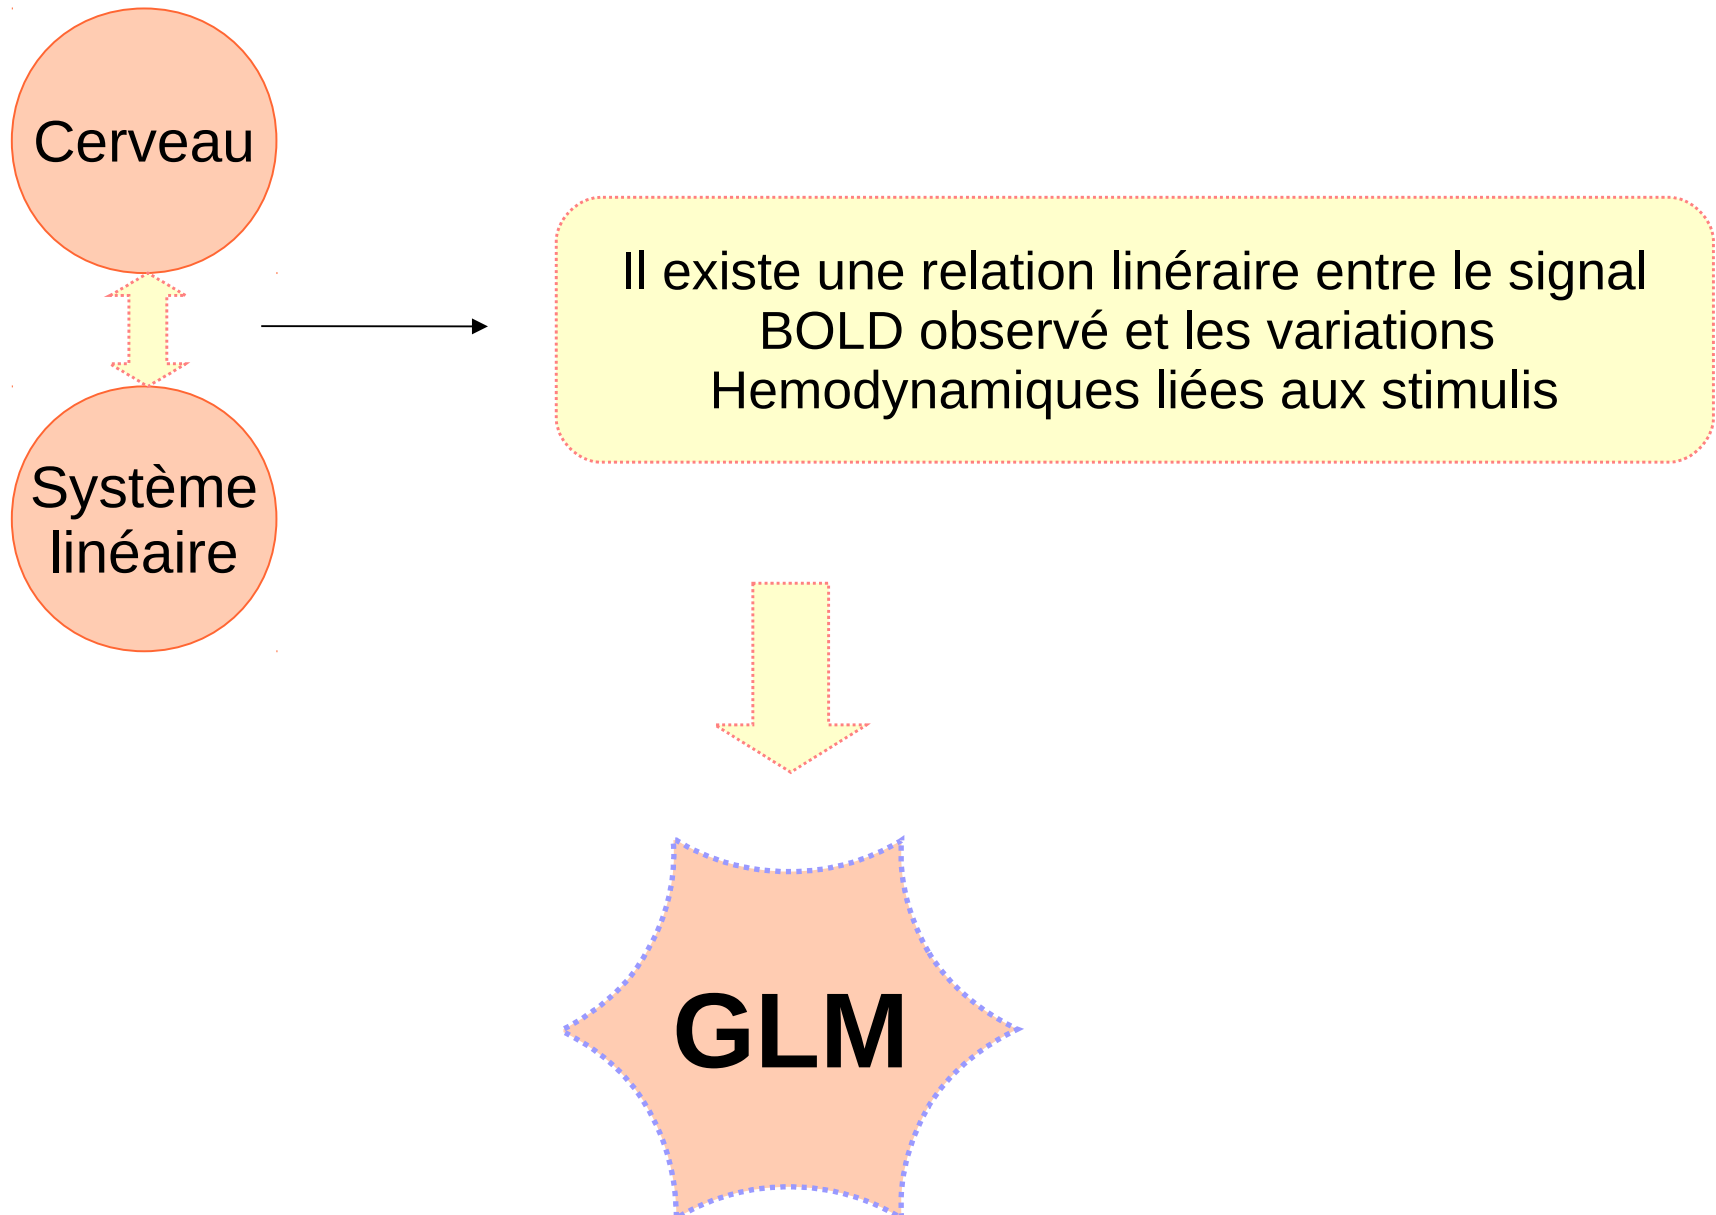
- Etude intra-sujets:
ACP, ACI

- Etude inter-sujets:
CanICA

Introduction:



Introduction:





Modèle linéaire généralisé GLM:

Nelder
&
Wedderburn
1972

Exprimé de façon linéaire une variable
observée à l'aide de variables
explicatives



Régression
linéaire
multiple

Variable observée	Variables explicatives
$Y_j : j = 1, \dots, n$	$X_{j,r} : j = 1, \dots, n$ $r = 1, \dots, R$

β_r
Paramètres
à estimer

ε
L'erreur
(bruit)

$$y_1 = \beta_0 + \beta_1 x_{1,1} + \beta_2 x_{1,2} + \dots + \beta_R x_{1,R} + \varepsilon_1$$

$$y_2 = \beta_0 + \beta_1 x_{2,1} + \beta_2 x_{2,2} + \dots + \beta_R x_{2,R} + \varepsilon_2$$


⋮

$$y_n = \beta_0 + \beta_1 x_{n,1} + \beta_2 x_{n,2} + \dots + \beta_R x_{n,R} + \varepsilon_n$$

[1] Nelder J.A. & Wedderburn R.W.M. 1972. Generalized linear models. Journal of the Royal Statistical Society A 135 :370-384.
[2] McCullagh P. & Nelder J.A. 1989. Generalized linear models (second edition). Chapman & Hall, London.

Modèle linéaire généralisé GLM:

$$\begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{pmatrix} = \begin{pmatrix} 1 & x_{1,1} & x_{1,2} & \dots & x_{1,R} \\ 1 & x_{2,1} & x_{2,2} & \dots & x_{2,R} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & x_{n,1} & x_{n,2} & \dots & x_{n,R} \end{pmatrix} \begin{pmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_R \end{pmatrix} + \begin{pmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_n \end{pmatrix}$$



$$Y = X\beta + \varepsilon$$

1995



SPM


**Analyse
en
IRMF**

GLM & IRMf:


$$Y = (X * h) \beta + \epsilon$$

Filtre hemodynamique représenté par la HRF

Stationnarité



Linéarité



Additivité

Les contributions des différents stimuli sont additionnées



GLM & PyHrf (DEC):

Détection

Problème interdépendants



Estimation

Traitement
conjoint
préférable

2003

Philippe
Ciuciu

PyHrf
(Détection/
estimation
conjointe)

Salima Makni (2006) (MCMC)
- Indépendance entre voxels
(approche univariée)

Thomas Vincent (2010) (MCMC)
- Introduction d'une dépendance spatiale
entre les voxels de la parcelle

**Lotfi Chaari
(2010)**
(DEC - VEM)

**Christine Bakhous
(2010)**
(Selection de
Modèles - MCMC)

L'estimation permet
de prendre en compte
la **variabilité
hemodynamique**

La **corrélation
spatiale** est
prise en compte
grâce à un filtrage
adaptatif
basé sur les champs
de Markov

GLM & PyHrf (DEC):

Salima Makni (2006) (MCMC)

- Indépendance entre voxels
(approche univariée)

Thomas Vincent (2010) (MCMC)

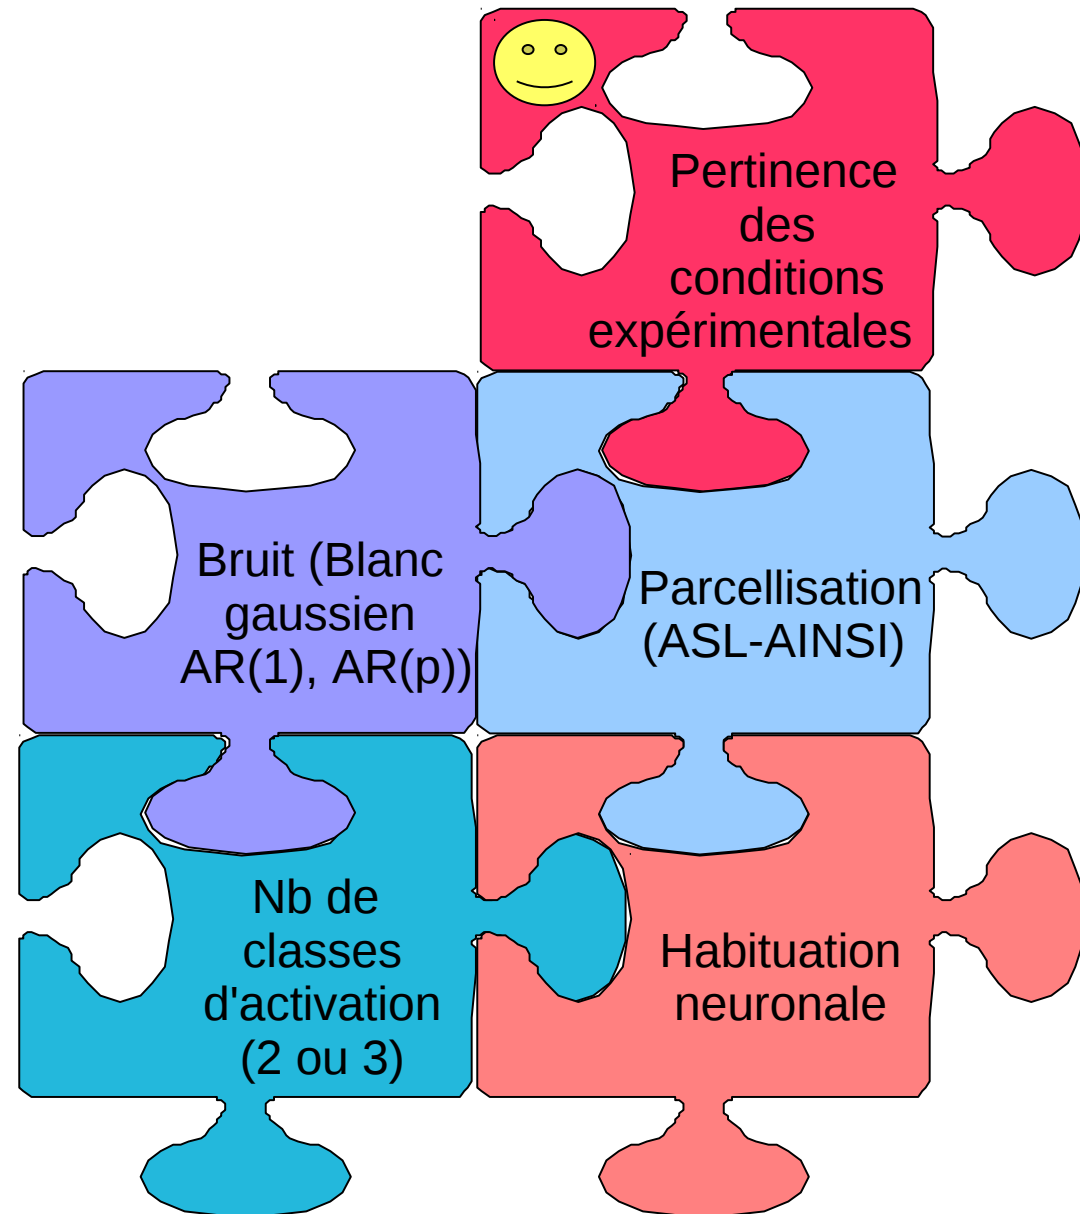
- Introduction d'une dépendance spatiale
Entre les voxels de la parcelle

**Lotfi Chaari
(2010)**
(DEC - VEM)

**Christine Bakhous
(2010)**
(Selection de
Modèles - MCMC)



*Choisir le modèle
le plus adapté
aux données*





GLM & PyHrf (DEC):


Approche parcellique
(plusieurs outils de parcellisation dans pyhrf)

**HRF
parcelle**

**Forme
constante** → h



**Amplitude
variable** → a

$$y_j = \sum_{m=1}^M a_j^m X^m h_{\gamma} + P \ell_j + b_j$$



Dérives basses fréquences

X



Comment estimer les paramètres du modèle ?



Méthodes de Monte Carlo par chaîne de Markov:

On a: Des données y
Des paramètres à estimer a, h, l, \dots

Echantillonneur de Gibbs:

Permet de générer une séquences d'échantillons à partir de leur probabilité jointe a posteriori $p(x_1, x_2 / y)$

$$\begin{aligned} \text{Itération } t+1 \quad x_1^{t+1} &\sim p(x_1 / y, x_2^t) \\ x_2^{t+1} &\sim p(x_2 / y, x_1^{t+1}) \end{aligned}$$

Après T itérations l'échantillon (x_1, x_2) obtenu suit la loi $p(x_1, x_2 / y)$



Comment calculer $p(x_1, x_2 / y), p(x_1 / y, x_2), p(x_2 / y, x_1)$?



Méthodes de Monte Carlo par chaîne de Markov:

Règle de Bayes:

$$p(x_1, x_2, \dots, x_k / y) \propto p(y / x_1, x_2, \dots, x_k) p(x_1, x_2, \dots, x_k)$$

a posteriori :

distributions des paramètres du modèle sachant les données


vraisemblance:

distribution des données sachant les paramètres du modèle

a priori:

distributions des paramètres du modèle (fixés à l'avance)

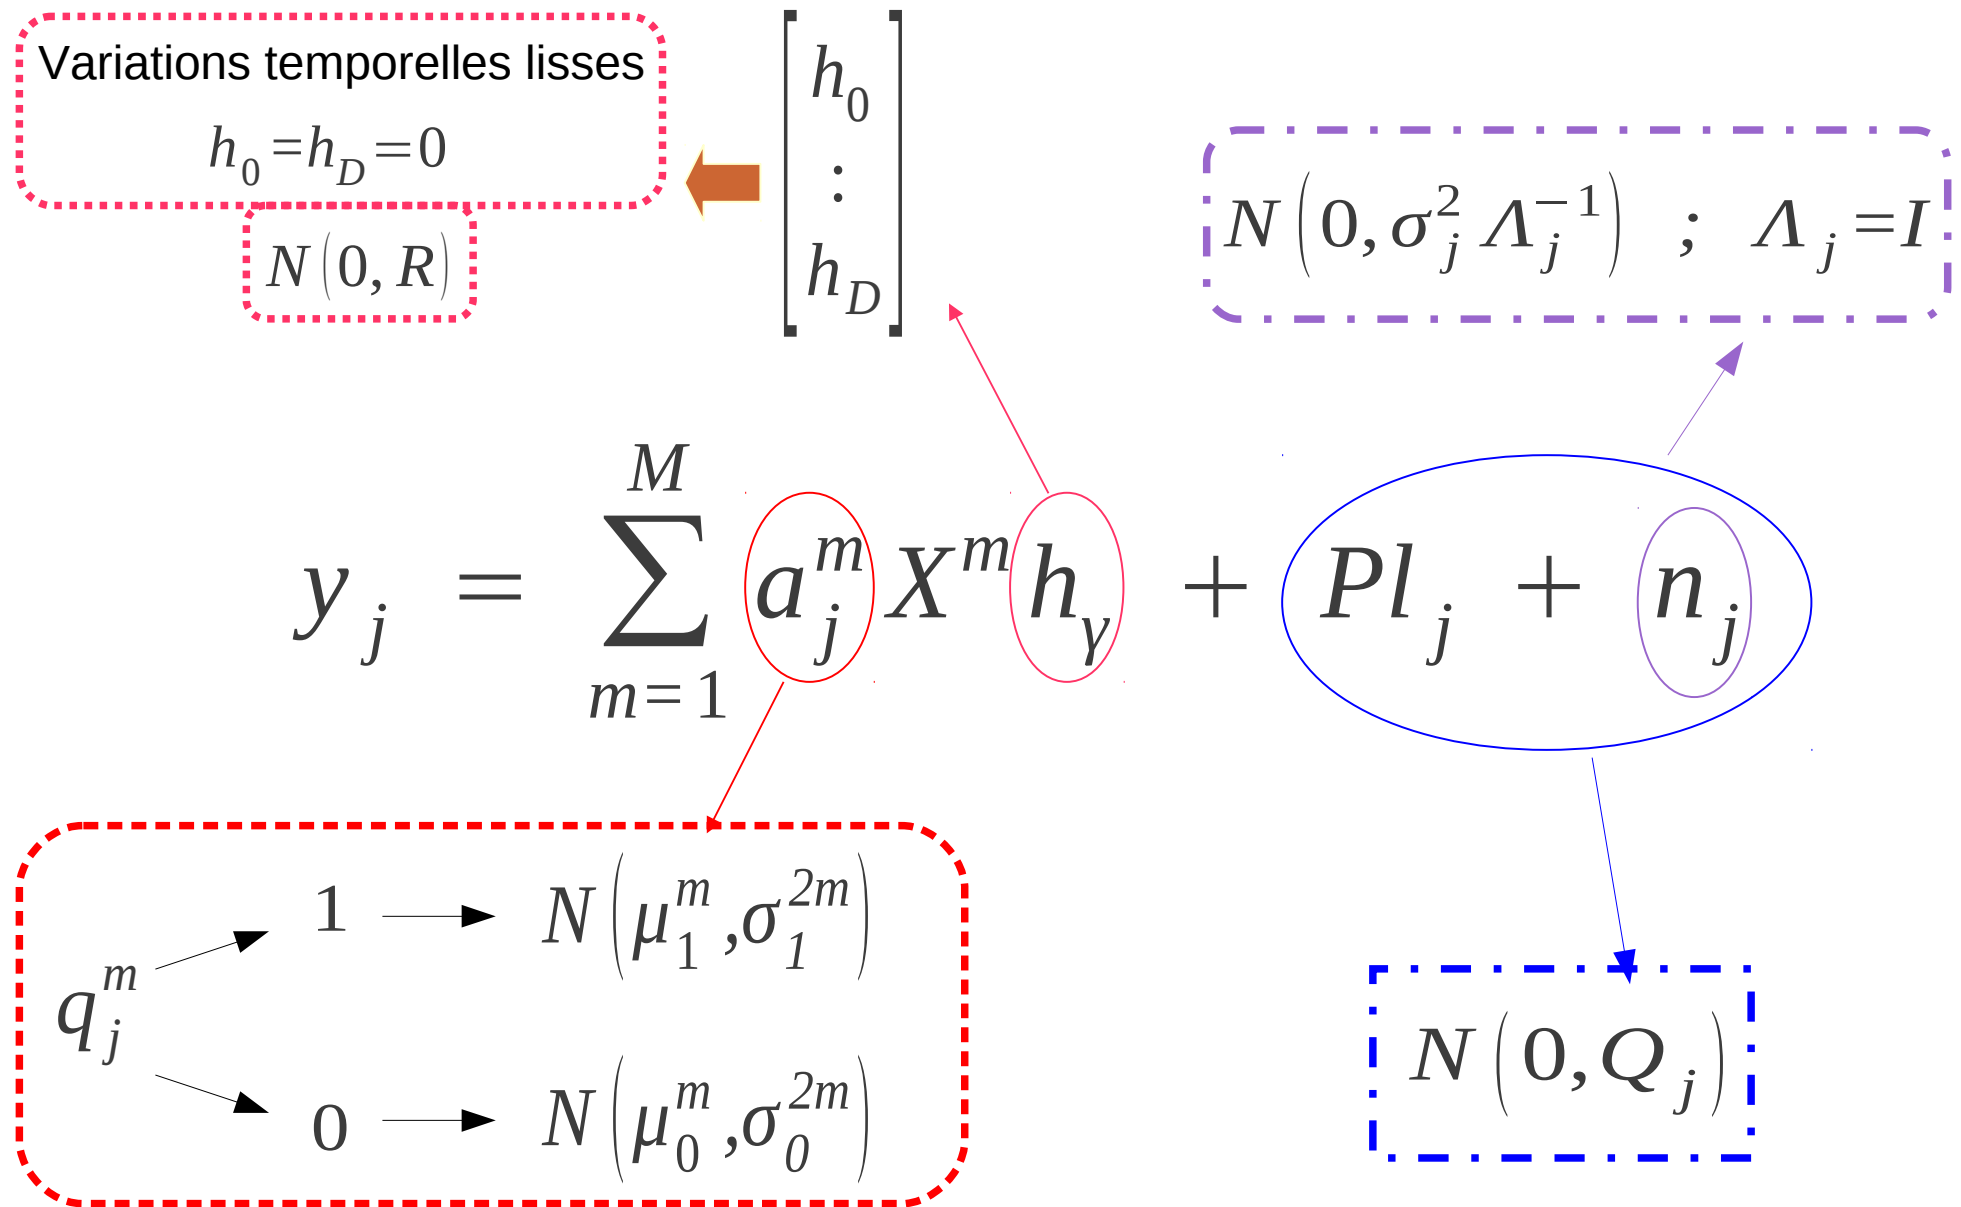
$$p(x_1 / y, x_2, \dots, x_k) \propto p(y / x_1, x_2, \dots, x_k) p(x_1 / x_2, \dots, x_k)$$



MCMC sont coûteuses en temps de calcul



Méthodes de Monte Carlo par chaîne de Markov:






Selection de modèles (Pertinence des conditions expérimentales):


Pertinence :

Les conditions expérimentales influencent des régions cérébrales précises

Paradigme audio/
visuel



Tâche Auditive
(Bruit pour la parcelle visuelle)




Tâche visuelle
(Bruit pour la parcelle Auditive)

But : Améliorer la Détection/Estimation en éliminant les conditions non pertinentes

$$y_j = \sum_{m=1}^M a_j^m w_\gamma^m X^m h_\gamma + P \ell_j + b_j$$

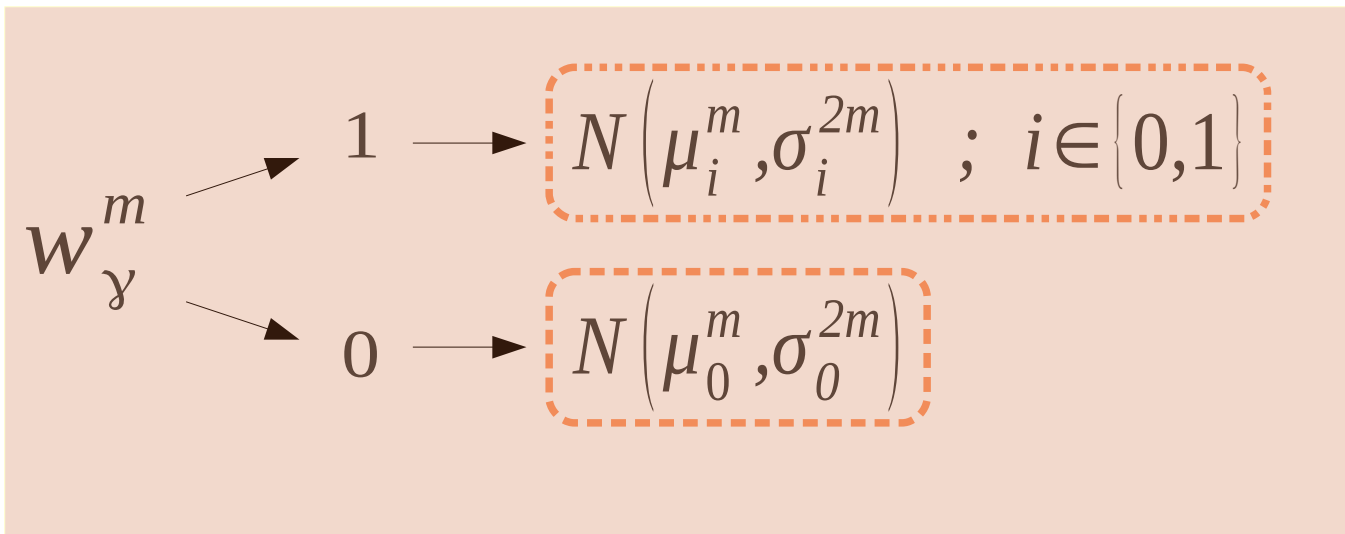
Variable binaire exprimant la pertinence de la condition

$$Pr(w = 1 / q^m) = S \left(\frac{1}{J_y} \sum_{j=1}^{J_y} q_j^m \right)$$



Selection de modèles (Pertinence des conditions experimentales):

$$y_j = \sum_{m=1}^M a_j^m w_\gamma^m X^m h_\gamma + Pl_j + n_j$$

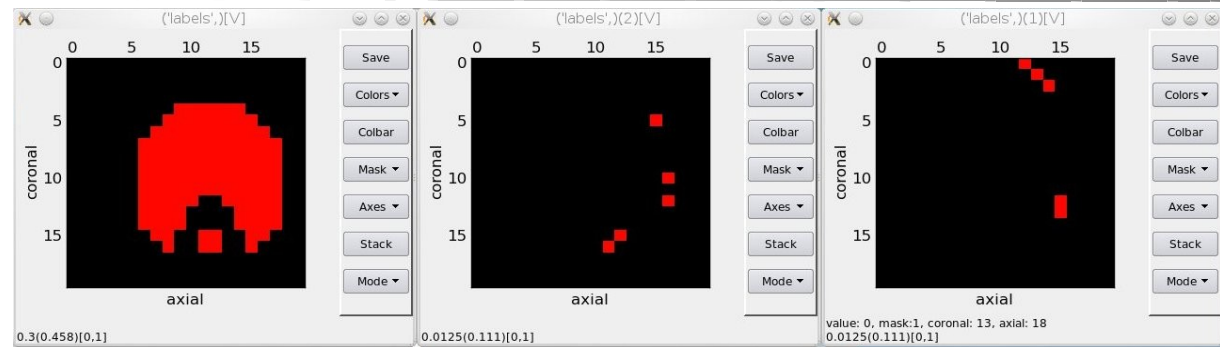




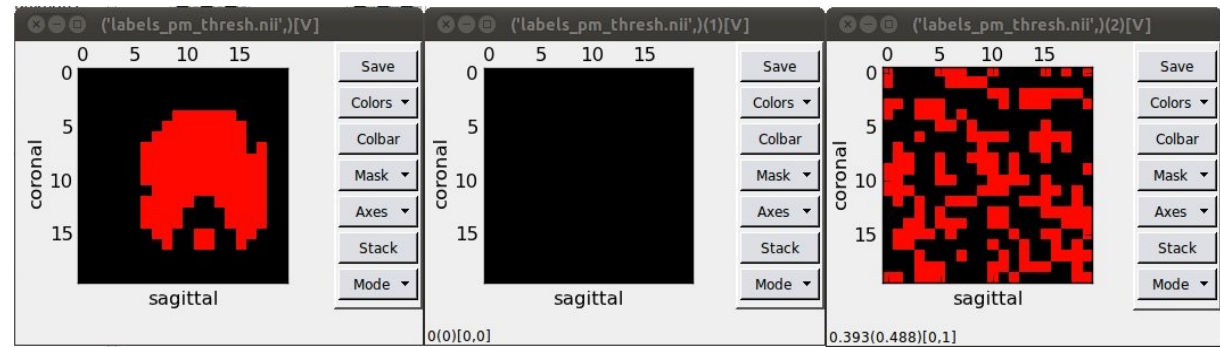
Sélection de modèles (premiers résultats):

Variance_bruit = 0.3
 1000 Iterations
 $\tau_1 = 1000$
 $\tau_2 = 0.29$

$$w_{estim} = [100]$$




Labels simulés



Labels estimés (ancien modèle)




Labels estimés (nouveau modèle)



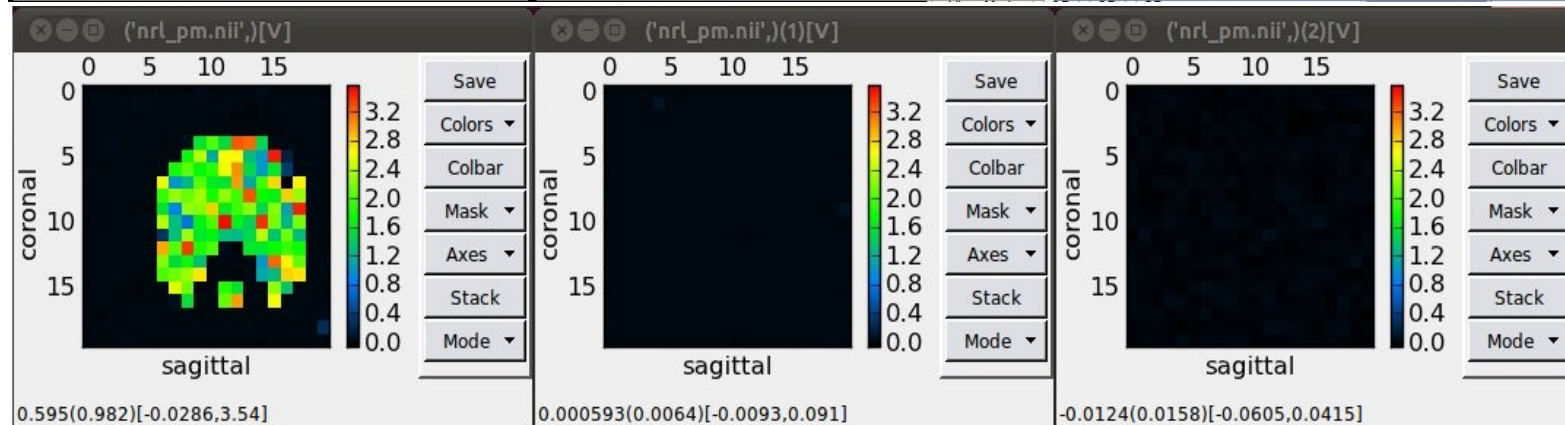
- HRF simulée
- HRF estimée (Ancien modèle)
- HRF estimée (Nouveau modèle)



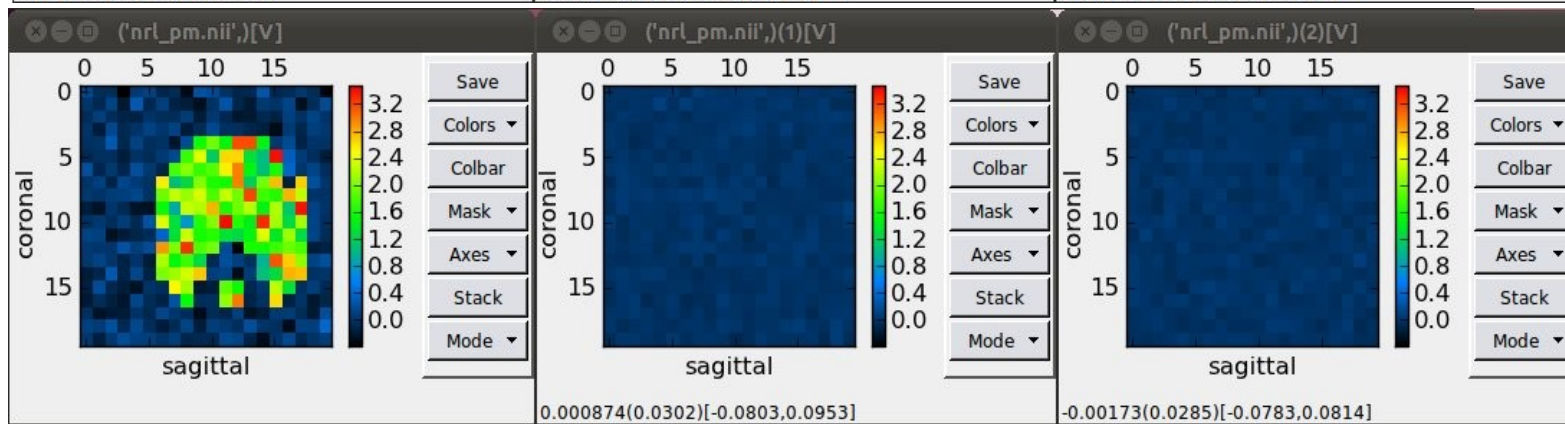
Sélection de modèles (premiers résultats):



NRLs simulés



NRLs estimés (ancien modèle)




NRLs estimés (nouveau modèle)




Sélection de modèles (premiers résultats):

$$Error_{j,cond_m} = \left(a_{j,simul}^m - a_{j,estim}^m \right) \quad j \in J_\gamma$$



NRLs error
(ancien modèle)




NRLs error
(nouveau modèle)




Sélection de modèles (premiers résultats):

Simulation



Estimation



Moyenne Active			Variance Active	Variance Inactive
Condition 1	Condition 2	Condition 3		
2	0.2	0.3	0.5	0.005

Param \ Cond	Condition 1		Condition 2		Condition 3	
	Nouveau modèle	Ancien modèle	Nouveau modèle	Ancien modèle	Nouveau modèle	Ancien modèle
nrl_rmse	0.031	0.0216	0.0167	0.0156	0.0136	0.0135
Moy_Act estim	1.96	1.99	4.66	4.73	4.94	-0.0249
Var_Act estim	0.488	0.535	0.698	$1.36 * 10^4$	0.626	0.00718
Var Inact estim	0.0663	0.000534	0.072	0.000162	0.0909	$5.84 / 10^5$



Perspectives:

1) Etude de la pertinence des conditions:

- a- validation du nouveau modèle sur données réelles
- b- Passage en DEC-VEM, comparaison avec DEC-MCMC


2) Sélection de modèle:

- Nombre de classes (2 ou 3)
- Intérêt de l'ASL pour la parcellisation
- Etude du phénomène d'habituation
- Modèle du bruit

Merci ...



PyHrf & SPM (CERVOX):



Paradigme événementiel