

AMÉLIORER LA SÉLECTION ET LA PRÉCISION DES MODÈLES DE SURVIE : UNE APPROCHE BAYÉSIENNE SPIKE AND SLAB

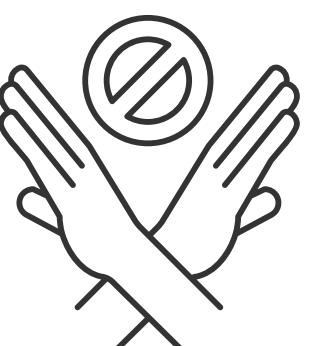
Université de Lyon | Ecole doctorale E2M2

Présenté par Joanna Pautonnier (Doctorante 1ère année)
Encadrement de thèse : Pr Pascal Roy (60%) / Pr David Causseur (40%)
Financement : PEPR Santé Numérique
12 décembre 2025

Introduction



Les modèles de survie prédictifs sont de plus en plus utilisés en médecine de précision.



Limites actuelles : absence d'indicateurs fiables d'incertitude quand le modèle est trop complexe (GAM pénalisés).



Objectif première partie de thèse : Évaluer et améliorer les propriétés prédictives globales et contextualisées de modèles de survie et leurs incertitudes.

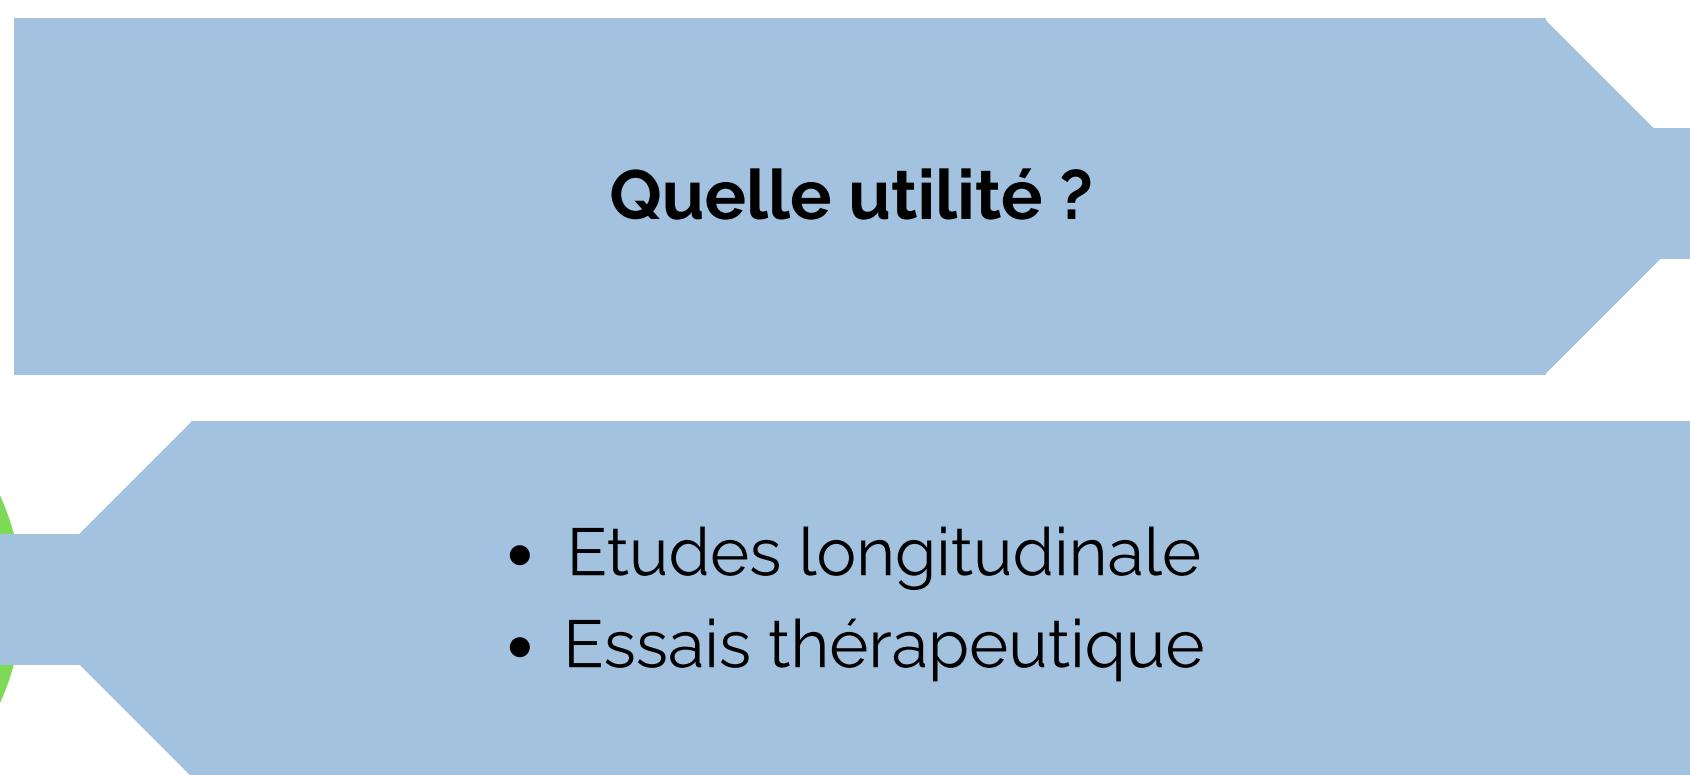




Qu'est-ce que l'analyse de données de durée de survie ?

Etude des délais de la survenu d'un évènement.





LES INDICATEURS EN SURVIE



FONCTION DE SURVIE

Probabilité de survivre jusqu'à un temps t.

$$S(t) = P(T_i > t)$$

LES INDICATEURS EN SURVIE



FONCTION DE SURVIE

Probabilité de survivre jusqu'à un temps t .

$$S(t) = P(T_i > t)$$

DENSITÉ DE PROBABILITÉ

Probabilité de mourir dans un petit intervalle de temps entre t et $t+dt$, à t fixé.

$$f(t) = \lim_{dt \rightarrow 0} \frac{P(t \leq T_i \leq t + dt)}{dt}$$

LES INDICATEURS EN SURVIE



FONCTION DE SURVIE

Probabilité de survivre jusqu'à un temps t .

$$S(t) = P(T_i > t)$$

DENSITÉ DE PROBABILITÉ

Probabilité de mourir dans un petit intervalle de temps entre t et $t+dt$.

$$f(t) = \lim_{dt \rightarrow 0} \frac{P(t \leq T_i \leq t + dt)}{dt}$$

TAUX DE HAZARD

Densité conditionnelle au fait d'avoir survécue jusqu'à ce temps.

$$h(t) = \lim_{dt \rightarrow 0} \frac{P(t \leq T_i \leq t + dt \mid T_i > t)}{dt} = \frac{f(t)}{S(t)}$$

LES INDICATEURS EN SURVIE



Probabilité de mourir dans un petit intervalle après t
sachant qu'on a survécu jusqu'à t.

—

sans unité

Petit intervalle de temps

—

en unité de temps
(jours, mois ect.)

Le taux de hazard est une vitesse/force d'évènement instantanée et s'exprime en évènement par temps.

TAUX DE HAZARD

Densité conditionnelle
au fait d'avoir survécue
jusqu'à ce temps.

$$h(t) = \lim_{dt \rightarrow 0} \frac{P(t \leq T_i \leq t + dt \mid T_i > t)}{dt} = \frac{f(t)}{S(t)}$$

LES INDICATEURS EN SURVIE



Survie en fonction du taux de hazard :

$$S(t) = \exp\left(- \int_0^t h(u) du\right)$$



Hazard

- Vision : la force de mortalité à chaque instant t.
- L'histoire racontée : révèle l'évolution du risque.
- Pour le clinicien : comprendre le "Pourquoi/Quand".

Survie

- Vision : la probabilité de n'avoir pas subi l'événement jusqu'à t.
- L'histoire racontée : lisse les variations pour donner un bilan global.
- Pour le clinicien : faire la prédition individuelle (Prognostic).

DU MODÈLE DE COX À LA MODÉLISATION FLEXIBLE PAR SPLINES

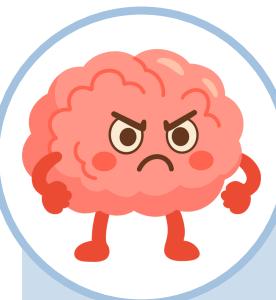
Modèle semi-paramétrique sur le risque instantané :

$$h(t|X) = h_0(t) \exp(X\beta)$$

Taux de base :
dépend uniquement
du temps.

Dépend uniquement des patients,
pas du temps :

- β : vecteur de paramètres (à estimer)
- X: vecteur de covariables (mesuré)



Hypothèse de proportionnalité :

- β ne dépend pas du temps = l'effet est constant dans le temps

→ **SOUVENT FAUSSE.**

DU MODÈLE DE COX À LA MODÉLISATION FLEXIBLE PAR SPLINES



Non estimation du taux de base

- $h_0(t)$: difficile à estimer.
- Le rapport des hazards entre individu ne dépend pas de $h_0(t)$: suffisant pour estimer les effets

$$\frac{h(t|X_i)}{h(t|X_j)} = \exp(\beta(X_i - X_j))$$

- **Vraisemblance partielle (ne dépend que des rapports)** : Sachant qu'un décès s'est produit à l'instant t_i parmi le groupe, quelle est la probabilité que ce soit l'individu i plutôt qu'un autre ?

risque du patient i

$$L_i(\beta) = \frac{h_0(t_i)\exp(X_i\beta)}{\sum_{j \in R(t_i)} h_0(t_i)\exp(X_j\beta)} = \frac{\exp(X_i\beta)}{\sum_{j \in R(t_i)} \exp(X_j\beta)}$$

somme des risques de tous les patients présents à cet instant

→ **Sans taux de base estimé**

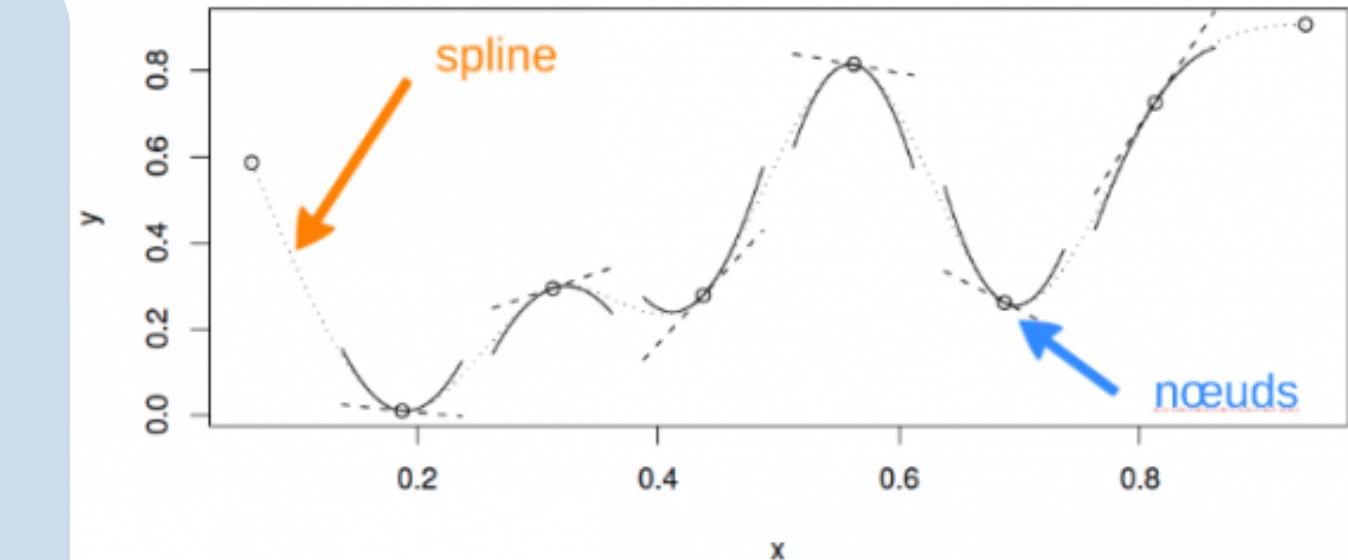
- **pas de prédictions individuelles possible.**
- **pas de compréhension de l'évolution du risque dans le temps**

DU MODÈLE DE COX À LA MODÉLISATION FLEXIBLE PAR SPLINES

Modélisation flexible par splines + vraisemblance totale

1. **Le risque de base** n'est plus un paramètre de nuisance mais une fonction lisse estimée ($f(t)$).
2. **L'effet des variables** : peut être fonction du temps (interaction $X * \text{temps}$).

$$\ln(h(t|X)) = f(t) \sum g_j(t) X_j$$



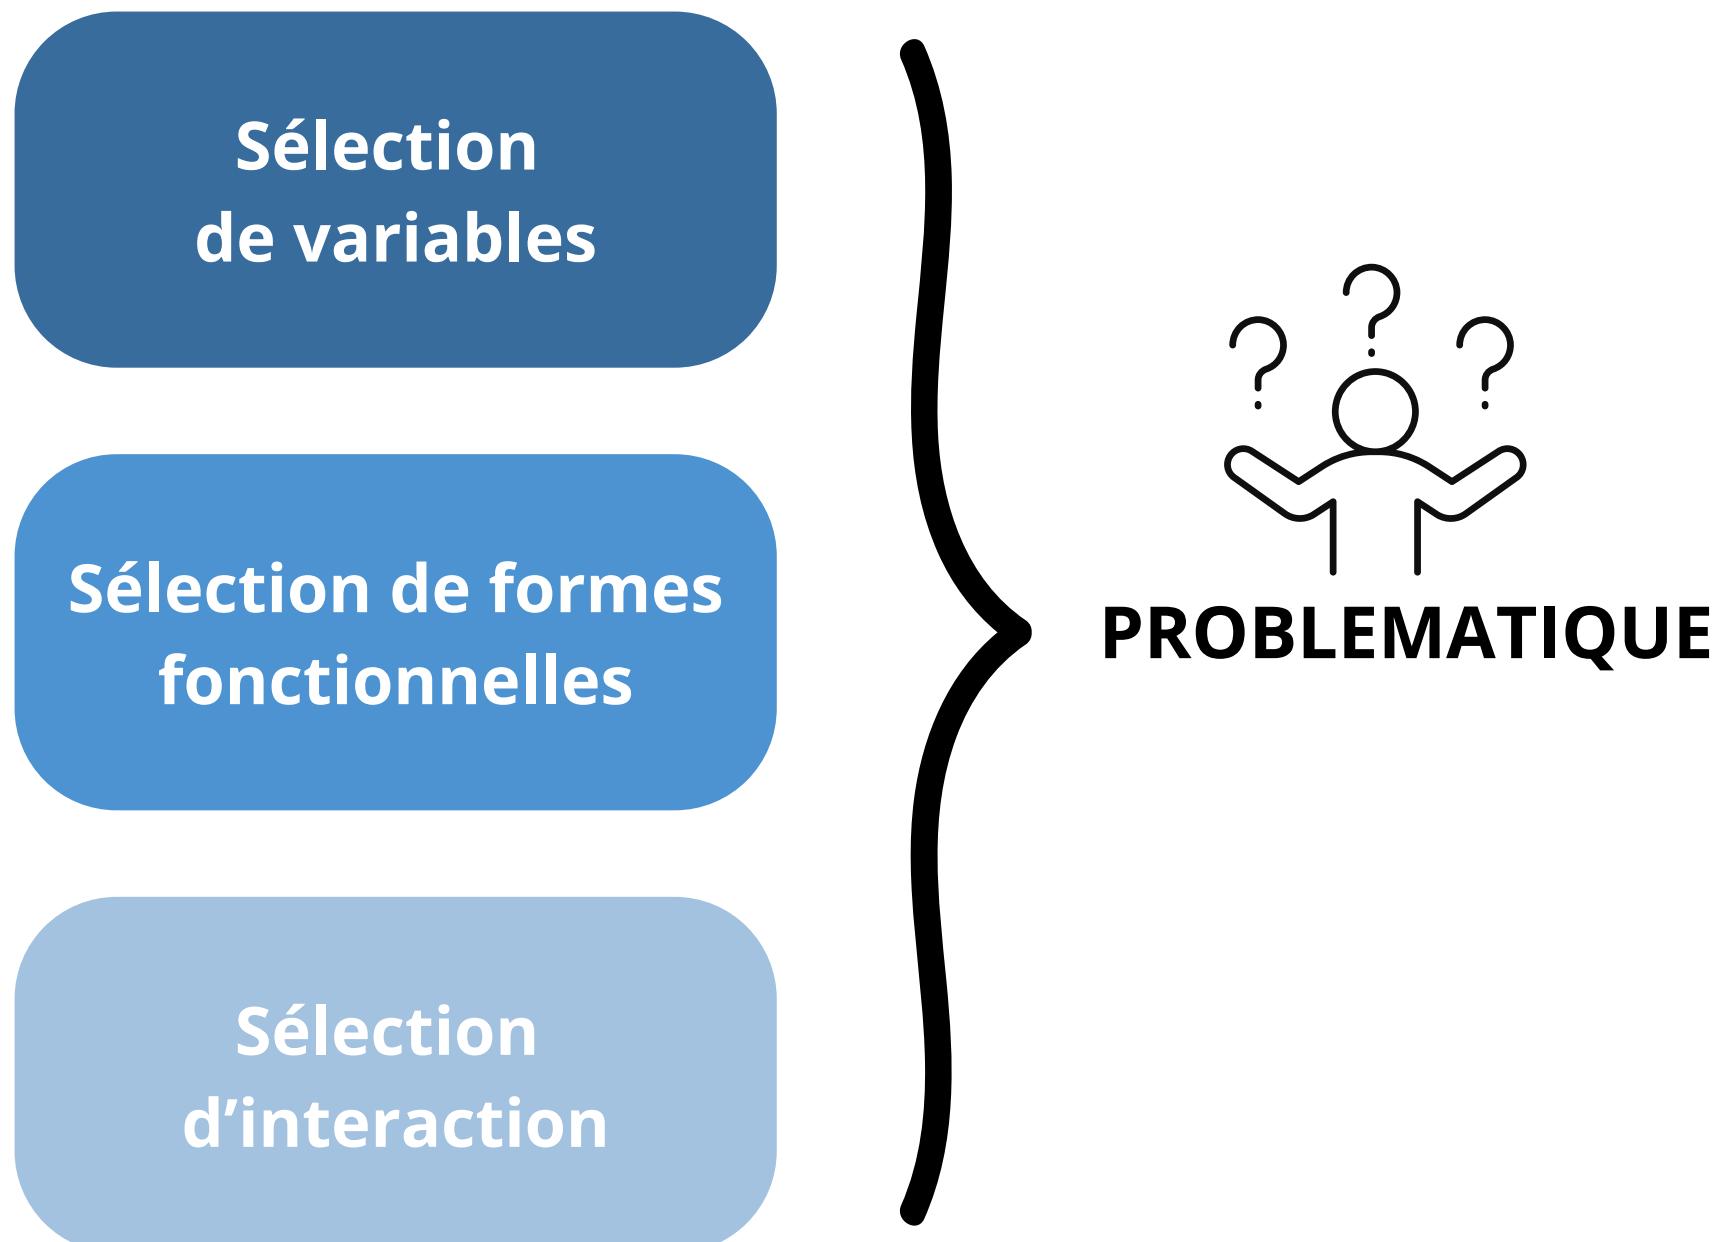
Spline : Fonctions polynomiales définies par morceaux



Avantages :

- Taux de base est estimé
- Pas d'hypothèse de proportionnalité

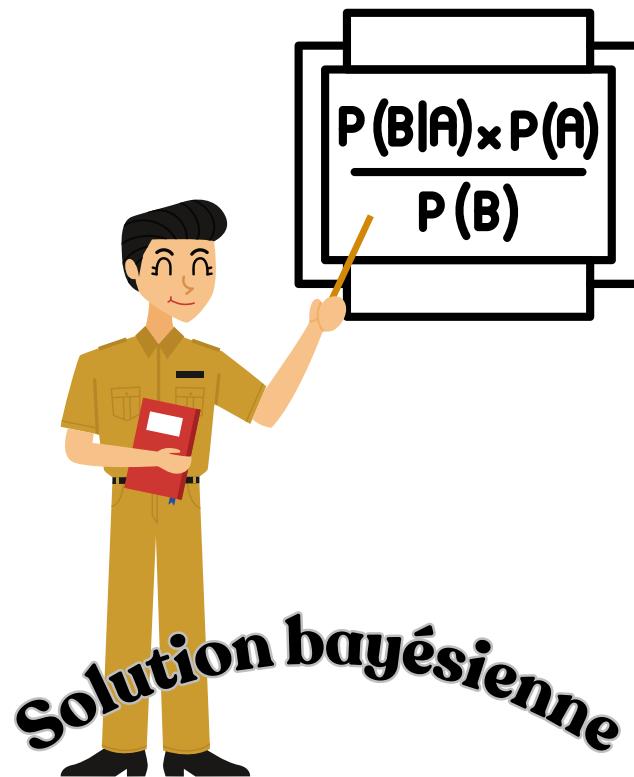
CONSTRUIRE UN MODÈLE : ÉTAPES CLÉS



ACTUELLEMENT EN FRÉQUENTISTE

- Méthodes de sélection : couteux en temps
- Intervalle de **CONFiance** présent mais pas exacte pour les modèles complexes.
- Absence d'intervalle de prédiction généralement.

Introduction

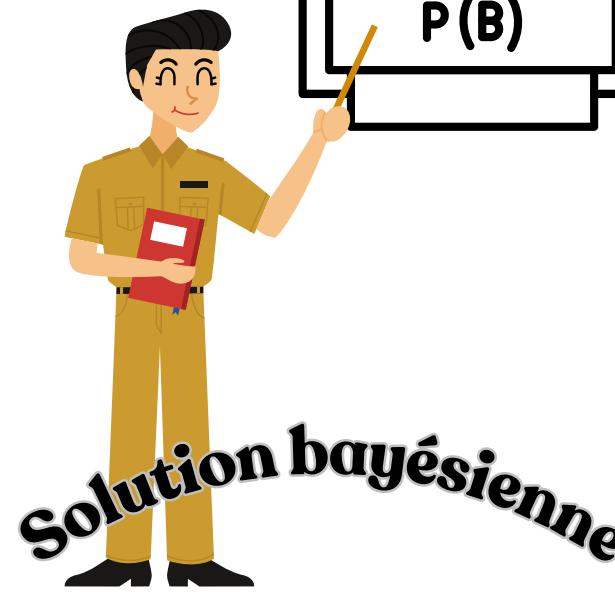


Accès aux distributions a posteriori.

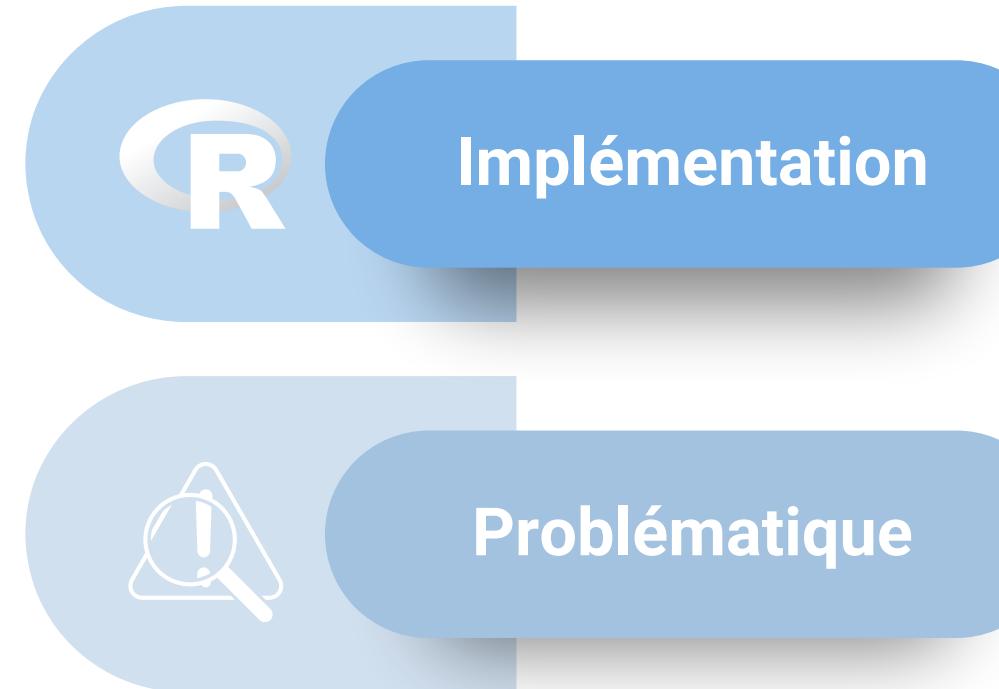
Prior (**spike and slab**, Laplace, gaussien...) : sélection automatique des variables + contrôle de la complexité.

Modèle de COX : Package R brms, BayesSurvive, psbcGroup, BMA..

Hypothèse de proportionnalité souvent fausses + taux de base non modélisé

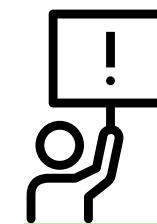


Solution bayésienne



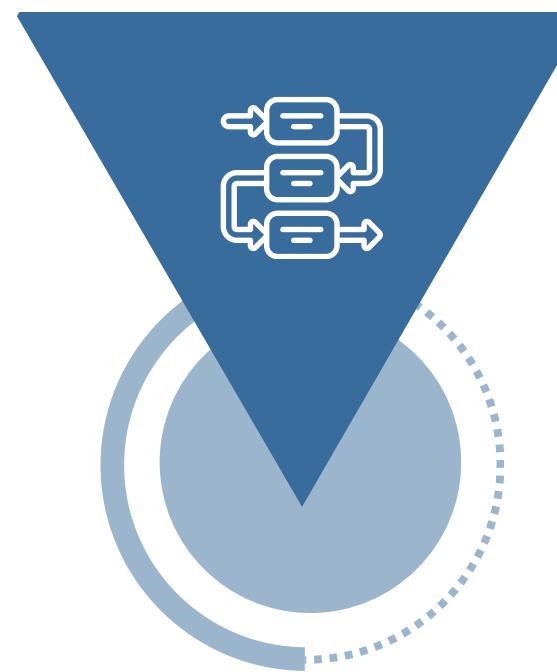
Approximation du Hazard par Poisson piecewise :
Package R **SpikeSlabGAM** de F. Scheipl (2011)

Approximation de poisson : Duplication massive des
données. => Problème computationnel



**Objectif : développer une alternative bayésienne directe de
SpikeSlabGAM pour les modèles de taux.**

OBJECTIF DE LA PRÉSENTATION



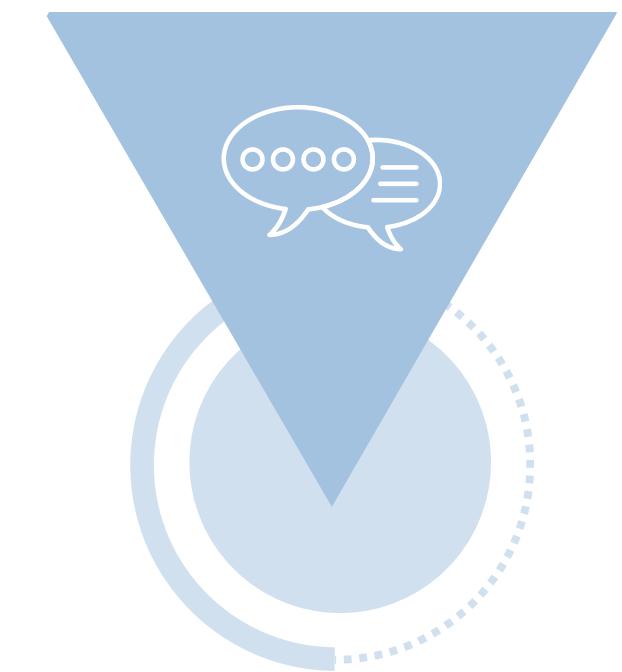
Cadre
méthodologique



Implémentation
proposée



Résultats
préliminaires
obtenus par
simulation



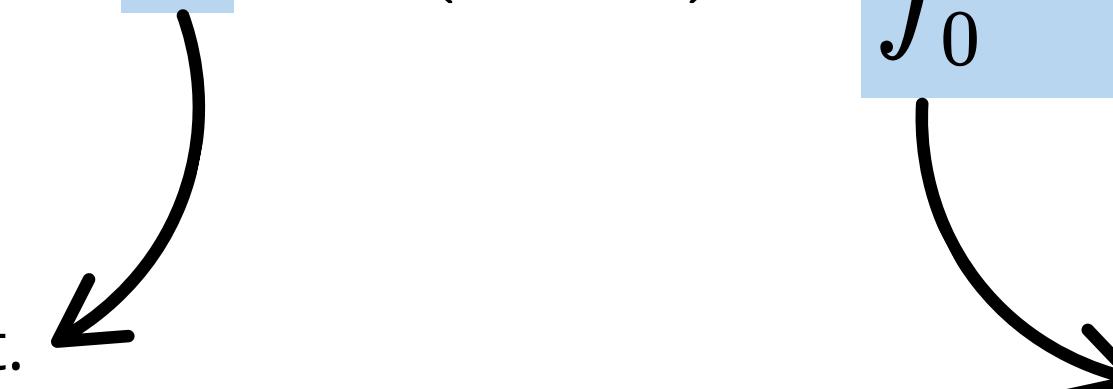
Discussion et
perspectives pour
la suite

EQUIVALENCE LOG-VRAISEMBLANCE DU TAUX VS APPROXIMATION DE POISSON



Pour un individu i: $L_i(\beta) = \delta_i \log(h(t_i)) - \int_0^{t_i} h(u) du$

Indicateur d'évènement.



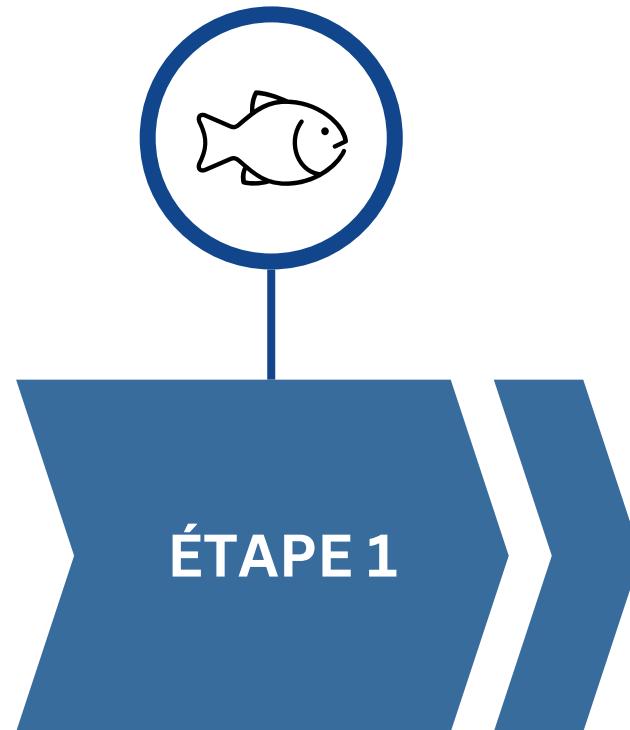
Difficulté : l'intégrale n'a souvent pas de solution analytique.

➡ Approximation numérique : Gauss-Legendre.



Globale : somme des contributions individuelles

EQUIVALENCE LOG-VRAISEMBLANCE DU TAUX VS APPROXIMATION DE POISSON

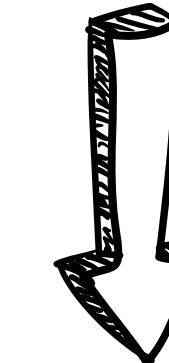


Vraisemblance
de poisson



On suppose que δ_i suit une loi de poisson $\delta_i \sim \mathcal{P}(\mu_i)$
La vraisemblance du modèle est :

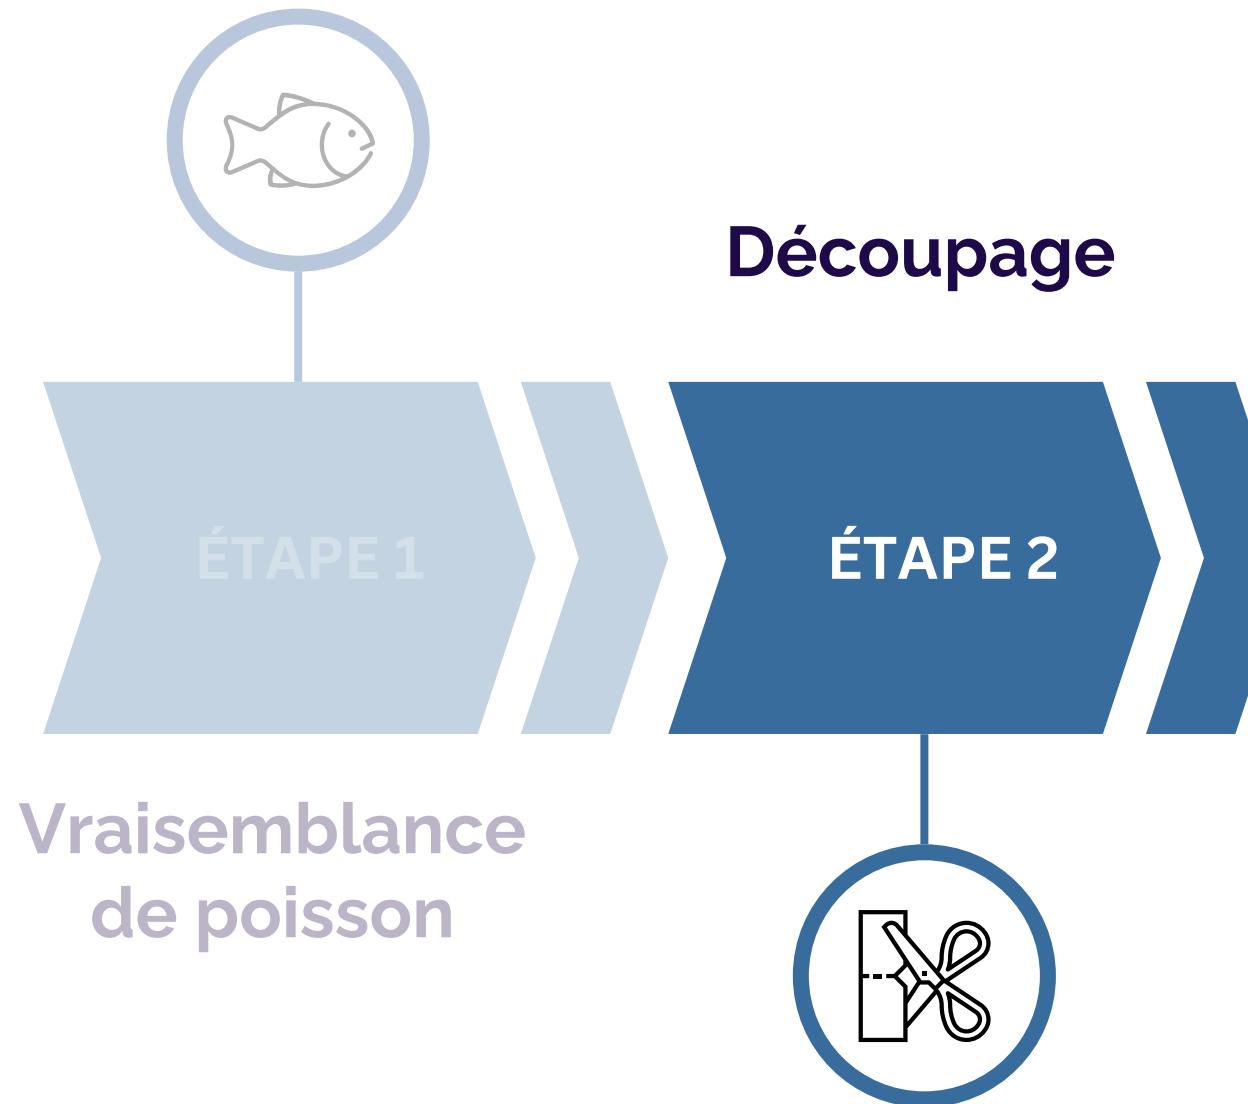
$$l^{\text{Poisson}}(\beta) = \prod_{i=1}^n \frac{\mu_i^{\delta_i} e^{-\mu_i}}{\delta_i!}$$



log-vraisemblance

$$L^{\text{Poisson}}(\beta) = \sum_{i=1}^n \left[\delta_i \log(\mu_i) - \log(\delta_i!) - \mu_i \right]$$

EQUIVALENCE LOG-VRAISEMBLANCE DU TAUX VS APPROXIMATION DE POISSON



On découpe nos données en m intervalles de temps $[d_j; d_{j+1}]$

La log-vraisemblance pour un individu i à un intervalle de temps j est :

$$\mathcal{L}_{ij}^{poisson}(\beta) = \delta_{ij} \log(\mu_{ij}) - \log(\delta_{ij}!) - \mu_{ij}$$

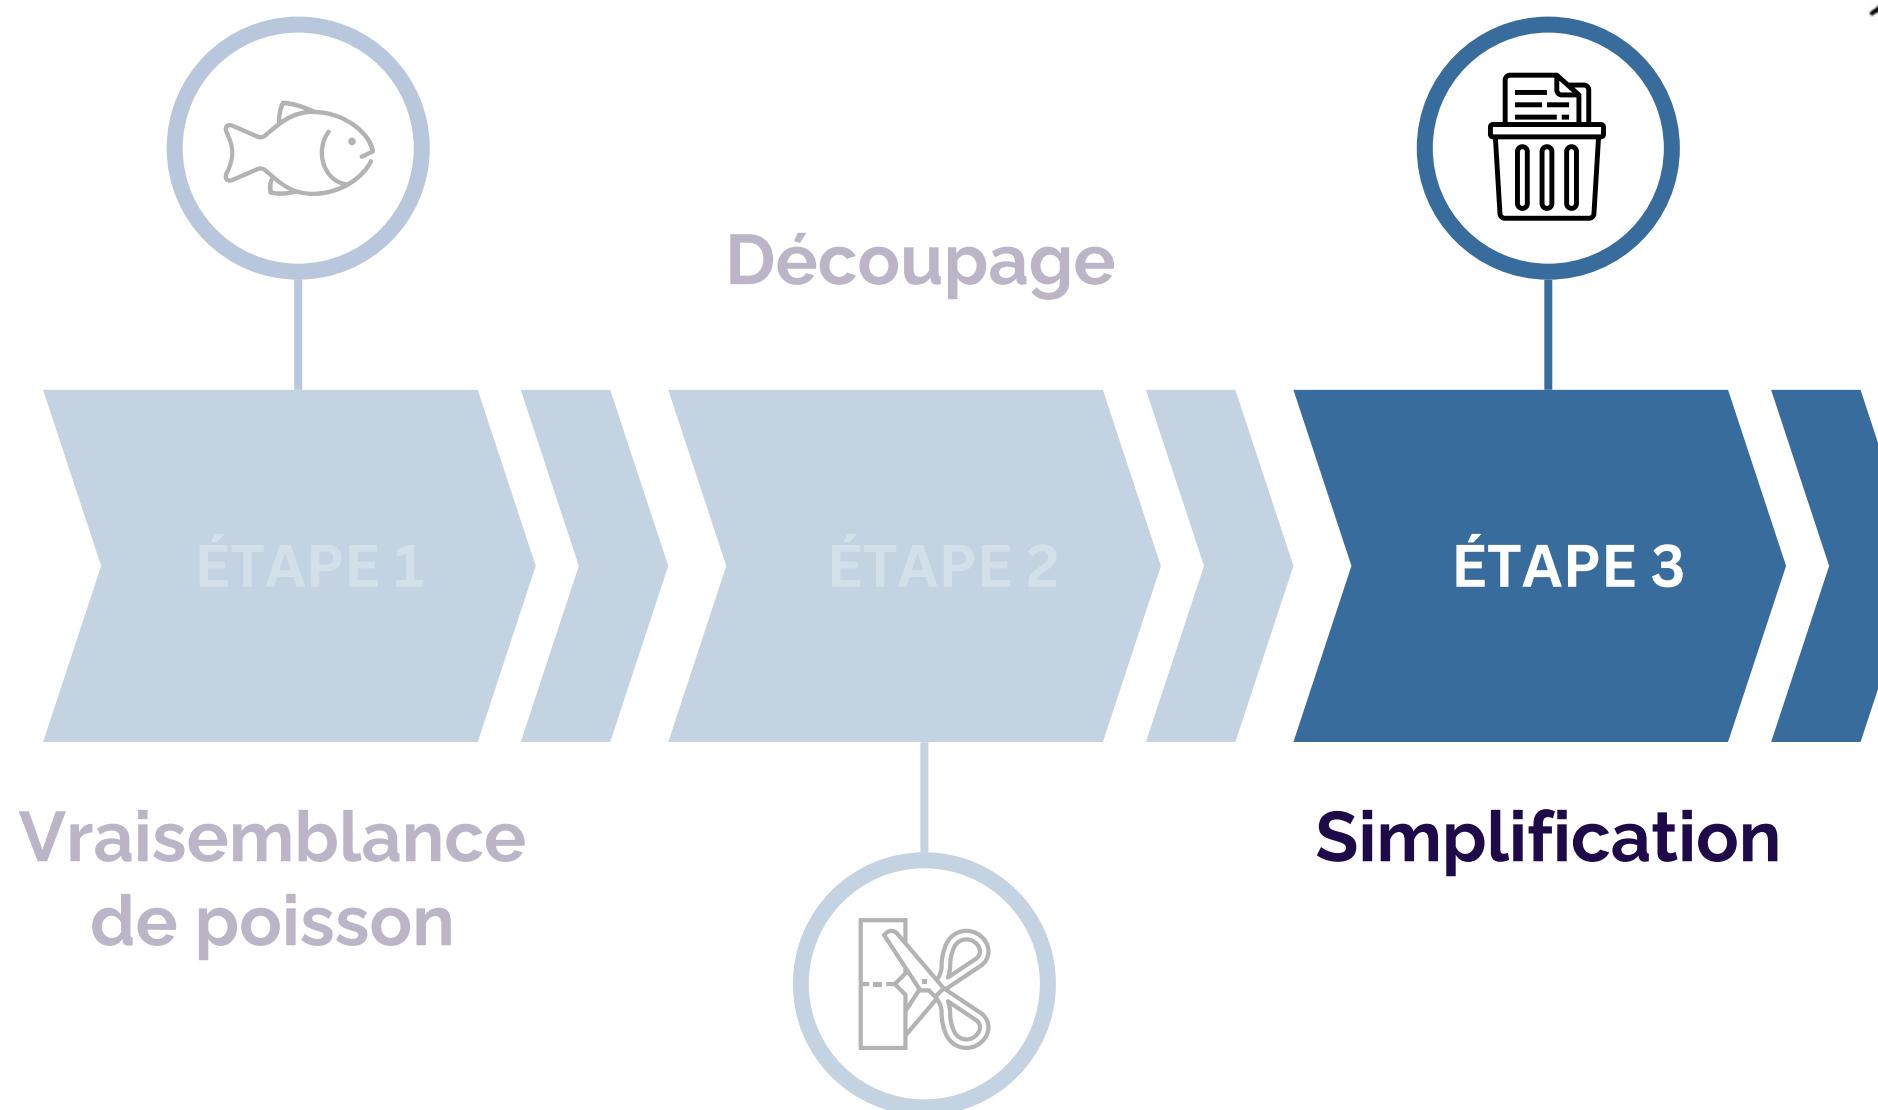


$$\mu_{ij} = (d_{j+1} - d_j)h(r_{ij}; x_i),$$

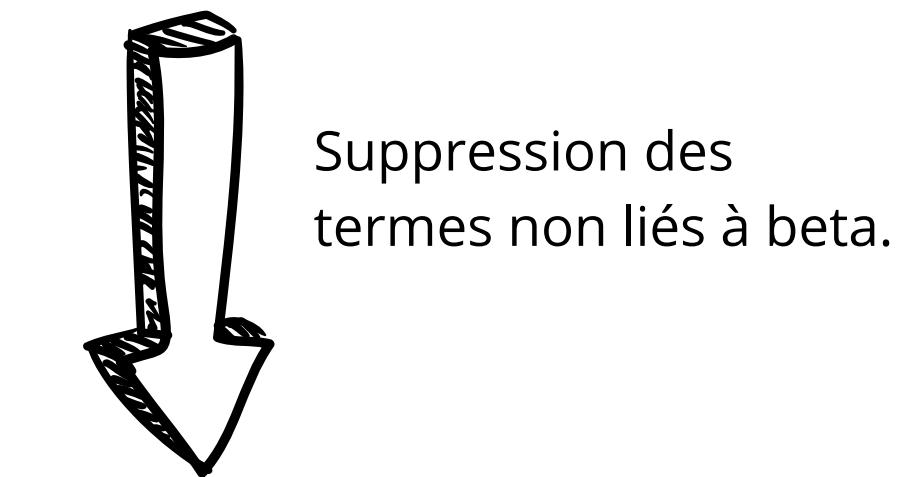
- $(d_{j+1} - d_j)$: durée de l'intervalle
- $h(r_{ij}; x_i)$: le taux calculé à un point milieu

$$\begin{aligned} \mathcal{L}_{ij}^{poisson}(\beta) &= \delta_{ij} \log(h(r_{ij}; x_i)) + \delta_{ij} \log((d_{j+1} - d_j)) \\ &\quad - \log(\delta_{ij}!) - (d_{j+1} - d_j)h(r_{ij}; x_i) \end{aligned}$$

EQUIVALENCE LOG-VRAISEMBLANCE DU TAUX VS APPROXIMATION DE POISSON



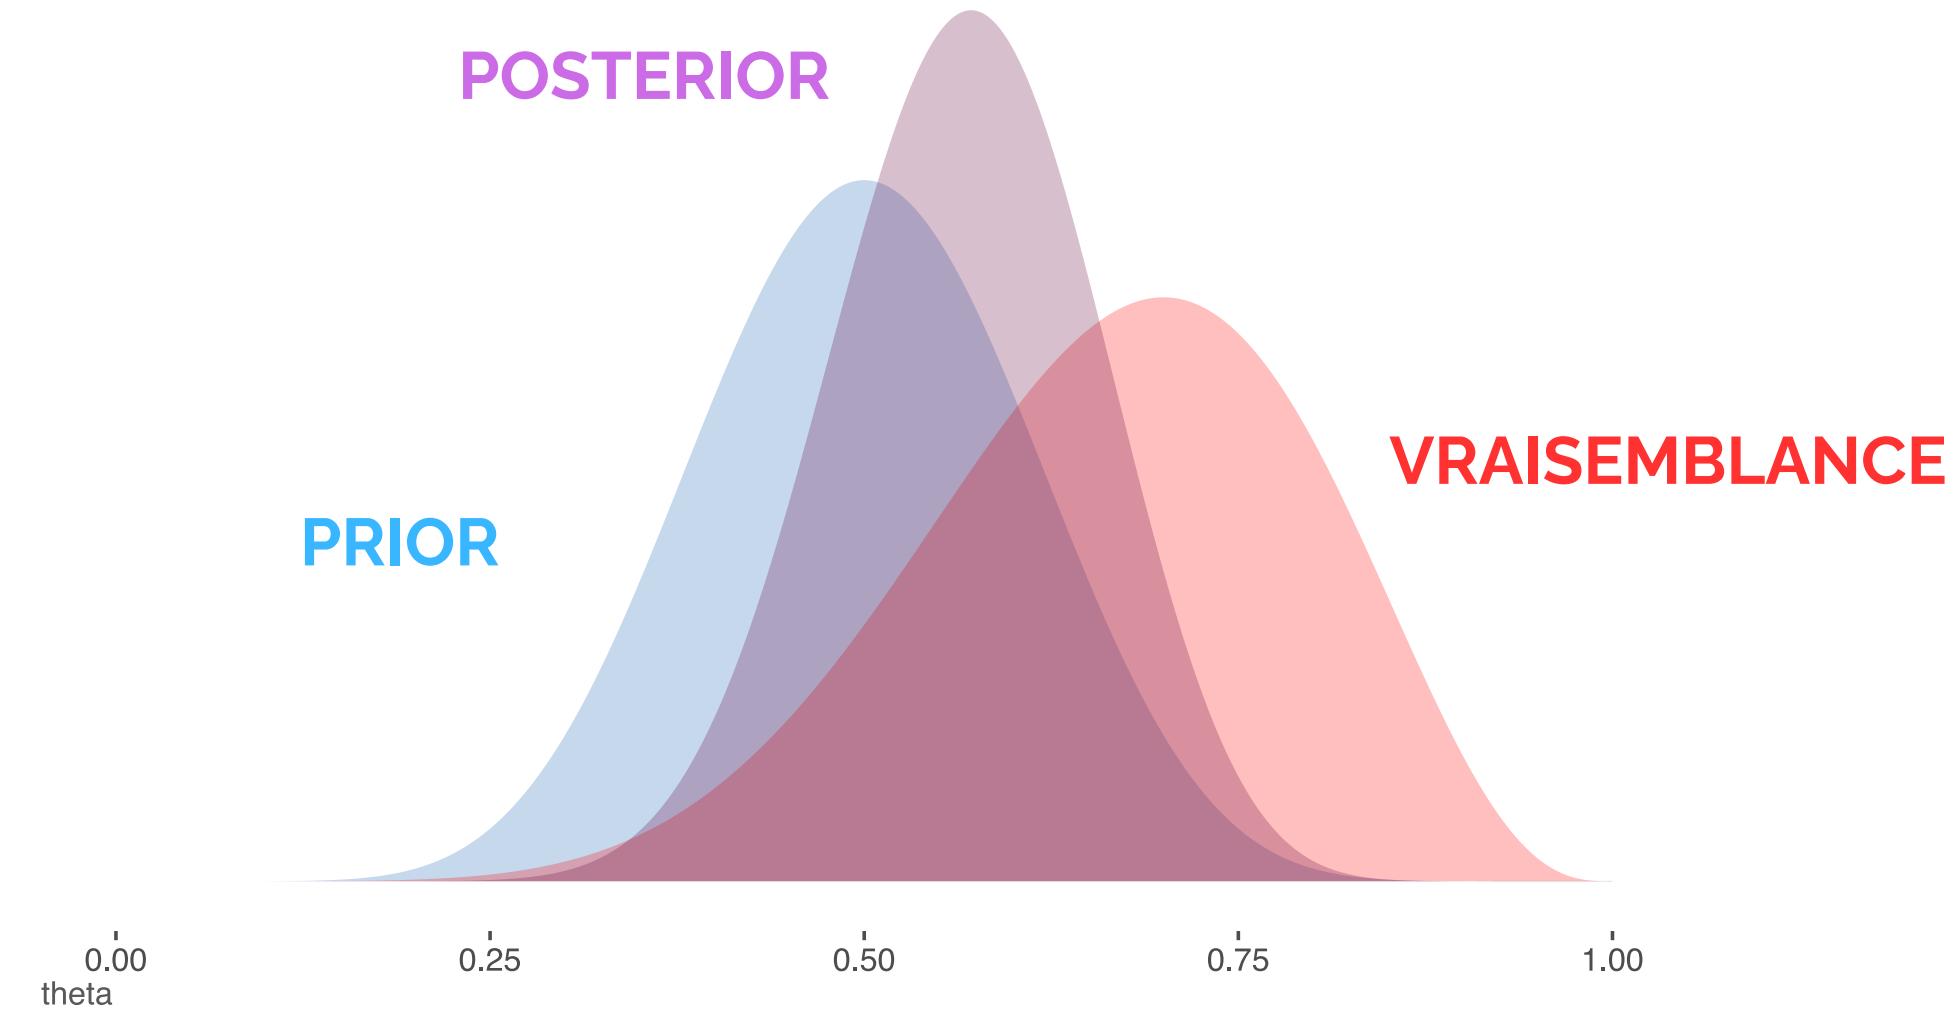
$$\begin{aligned}\mathcal{L}_{ij}^{poisson}(\beta) &= \delta_{ij} \log(h(r_{ij}; x_i)) + \delta_{ij} \log((d_{j+1} - d_j)) \\ &\quad - \log(\delta_{ij}!) - (d_{j+1} - d_j)h(r_{ij}; x_i)\end{aligned}$$



$$\mathcal{L}_{ij}^{poisson}(\beta) = \delta_{ij} \log(h(r_{ij}; x_i)) - (d_{j+1} - d_j)h(r_{ij}; x_i)$$

où $(d_{j+1} - d_j)h(r_{ij}; x_i) \approx \int_d^{d+1} h(u; x_i) du$

\approx log-vraisemblance du taux

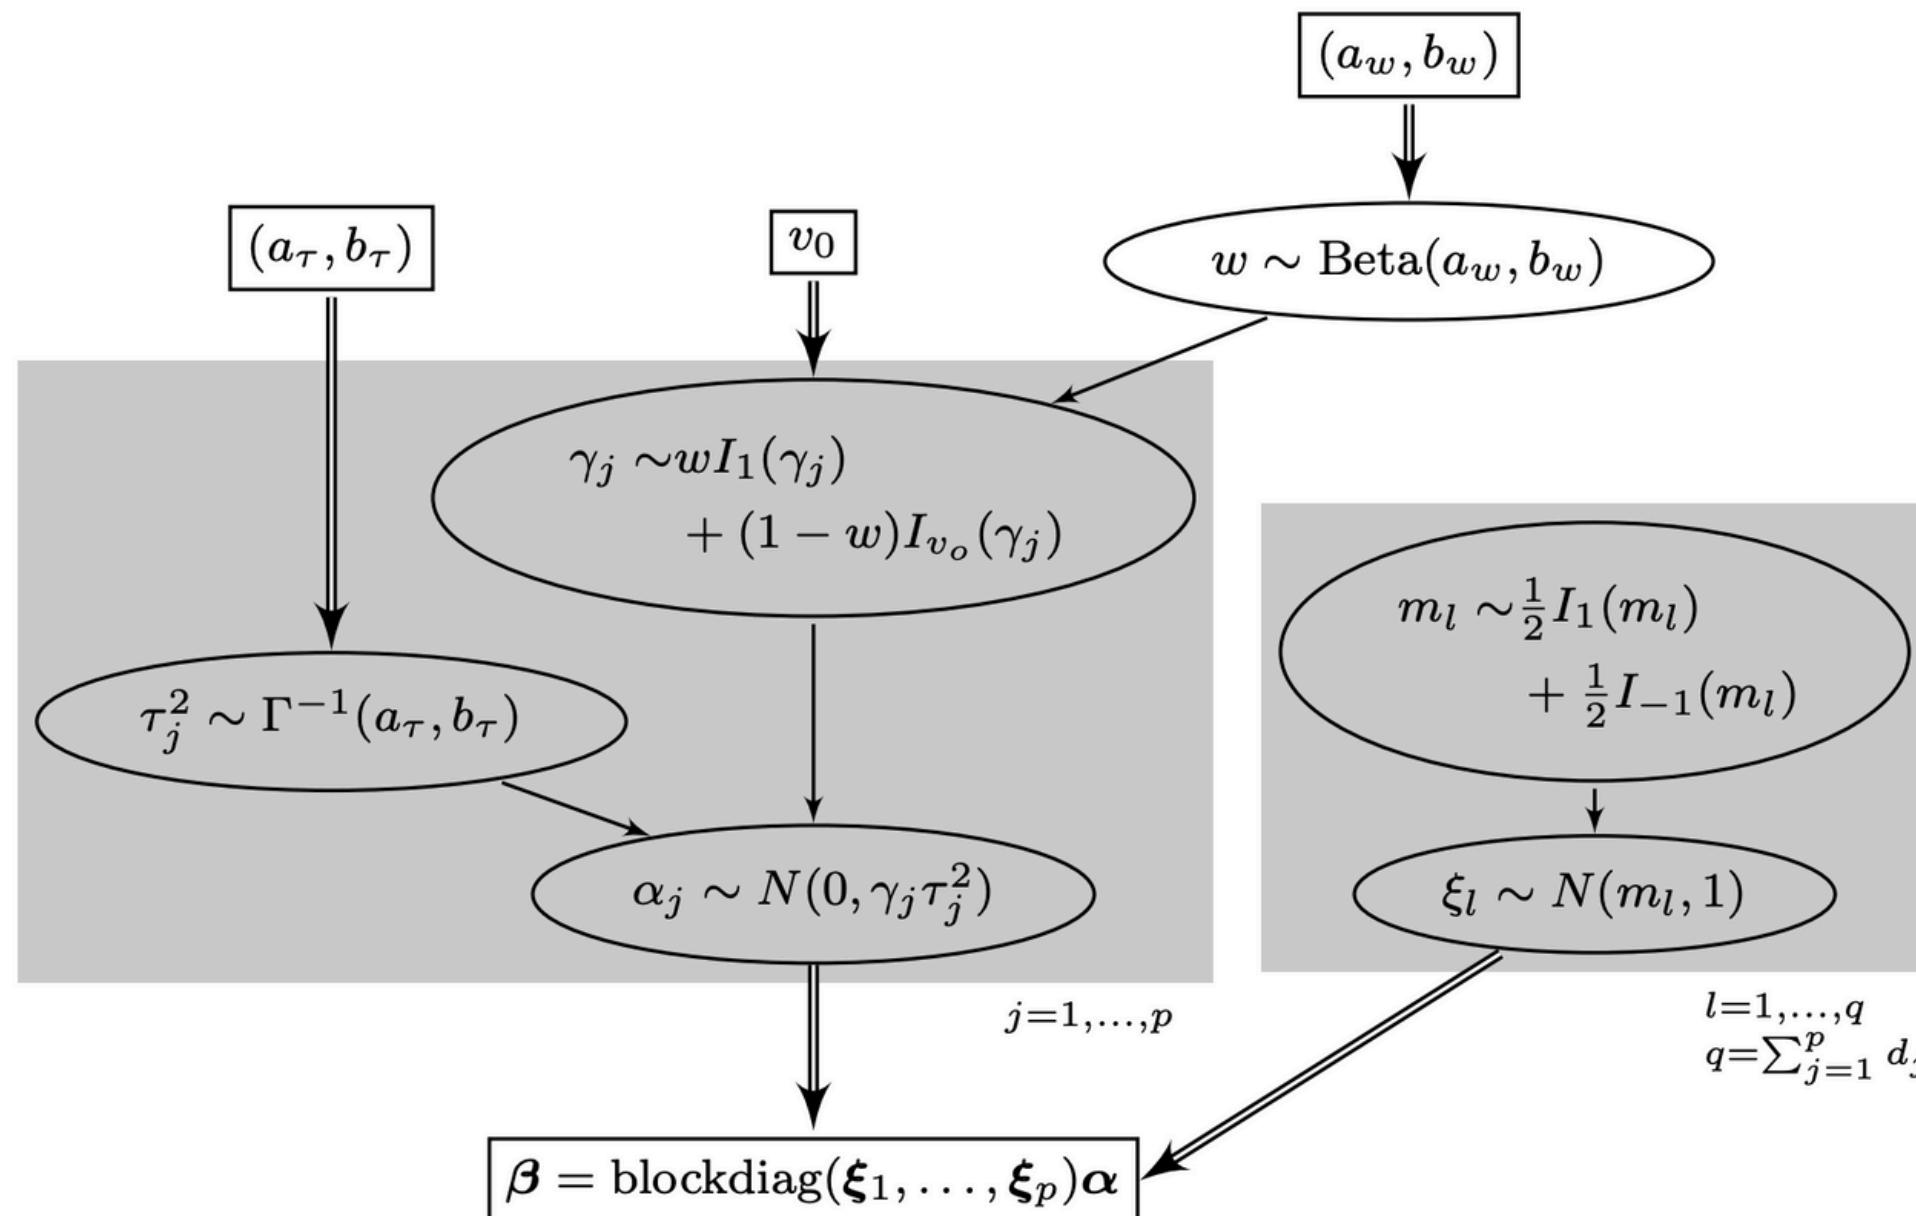


$$P(\beta | \text{données}) = \frac{P(\text{données} | \beta) \times P(\beta)}{P(\text{données})}$$

$$P(\beta | \text{données}) \propto P(\text{données} | \beta) \times P(\beta)$$

$$\text{posterior} \propto \text{vraisemblance} \times \text{prior}$$

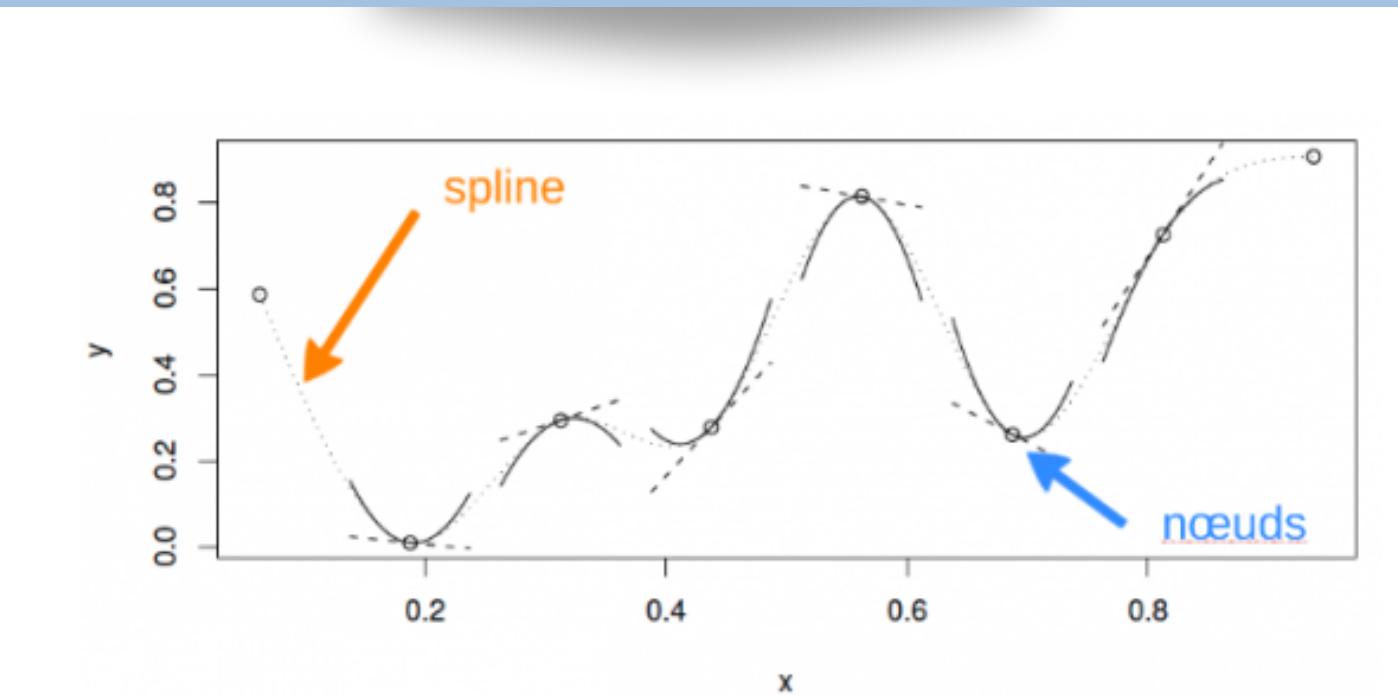
PRIOR



β : vecteur de coefficients du modèle.

α : importance du bloc/effet de la variable.

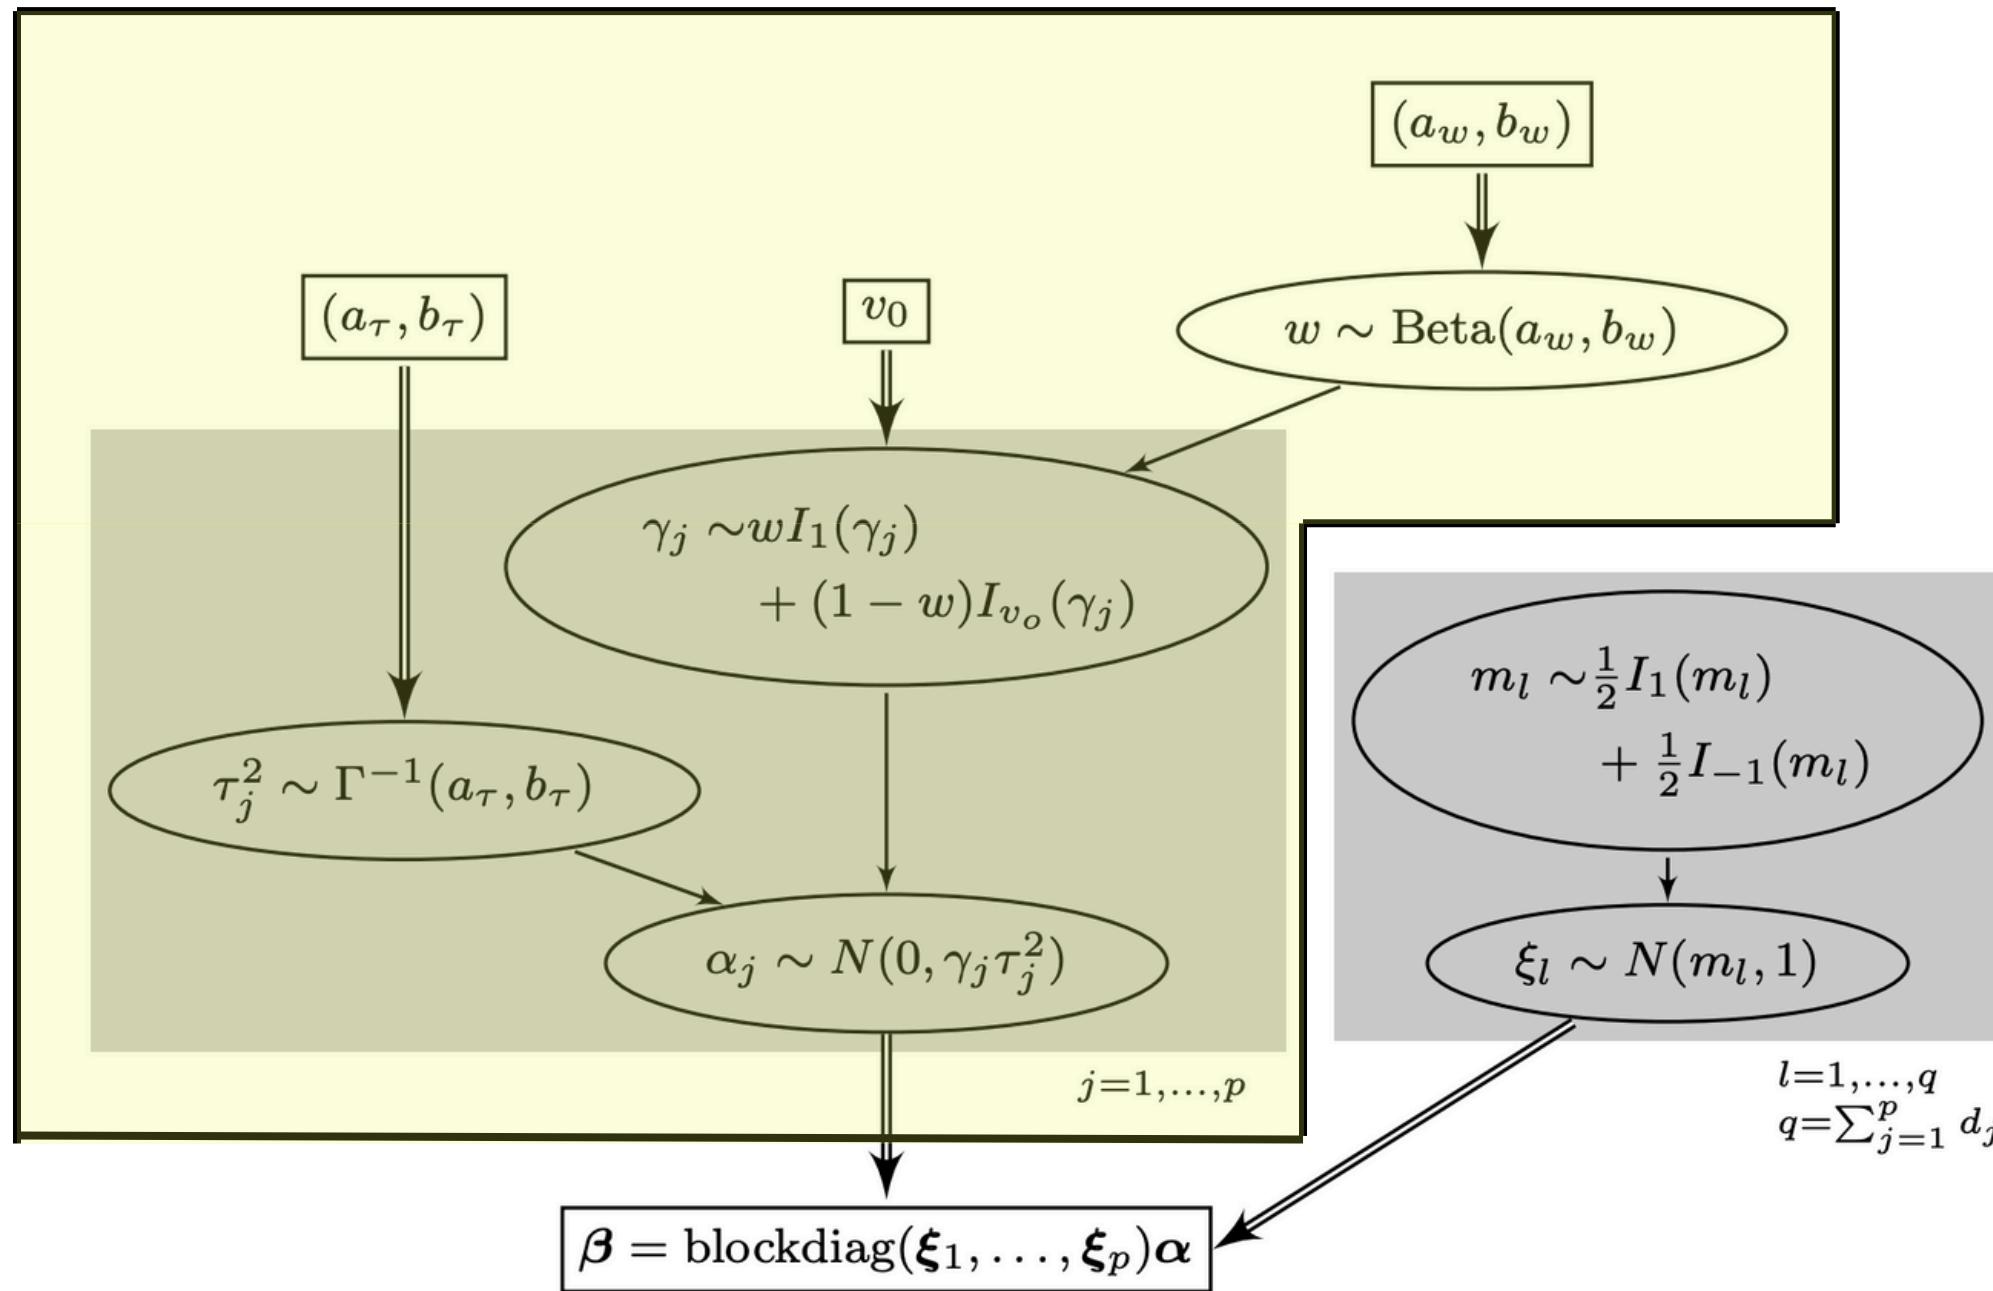
ξ : redistribue α entre les bases de la spline.



Spline : Fonctions polynomiales
définies par morceaux

Figure 1. Graphe acyclique dirigé du prior peNMIG. Source : Scheipl, 2011.

PRIOR



α_j : importance du bloc j

- Pour les effets linéaires : effet linéaire de la variable.
- Pour les splines : effet de la spline.

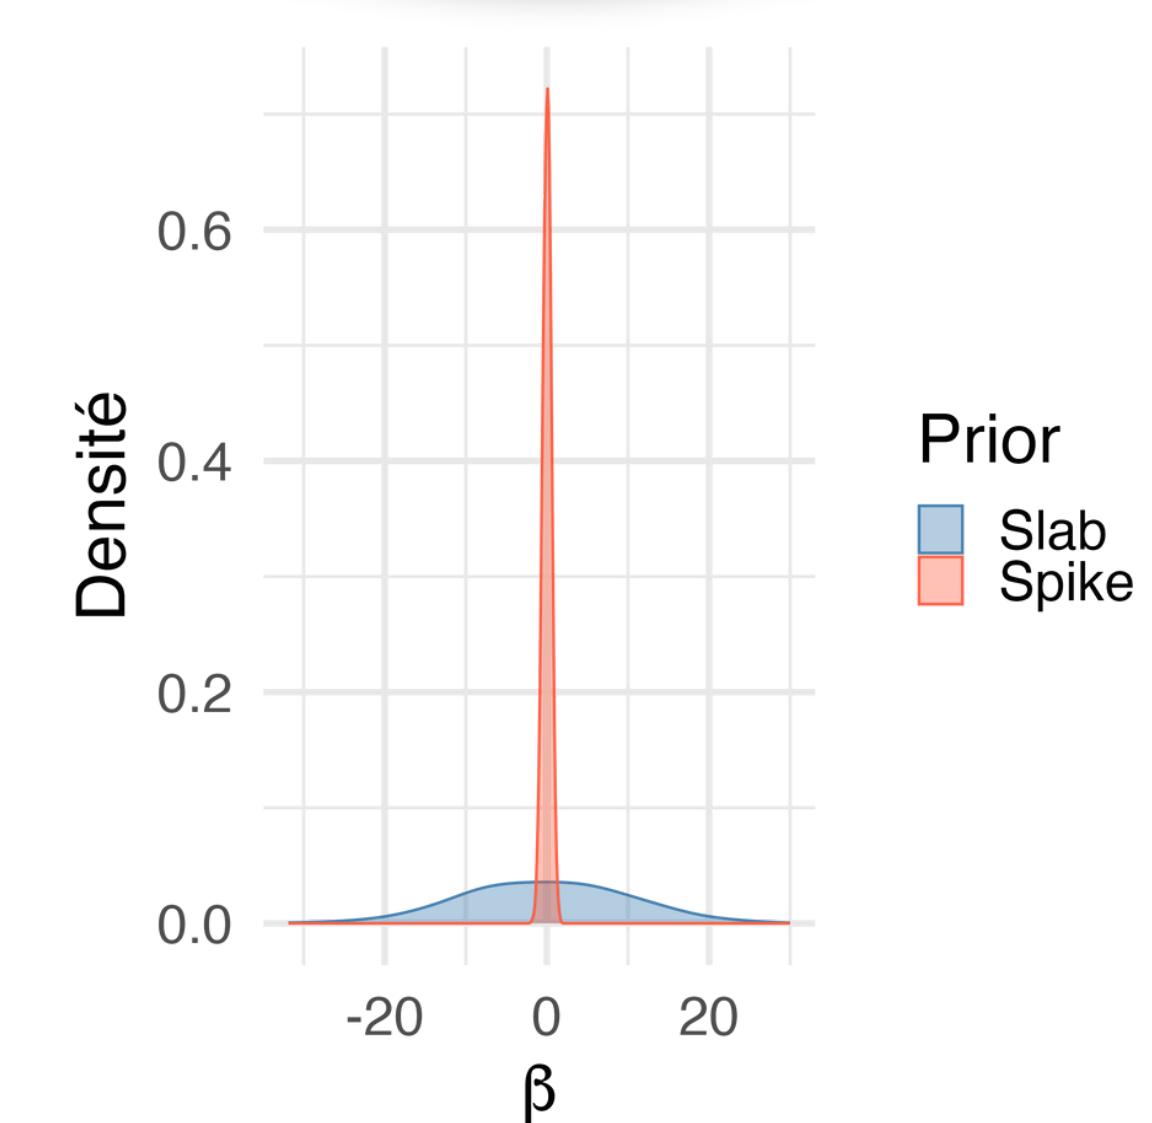
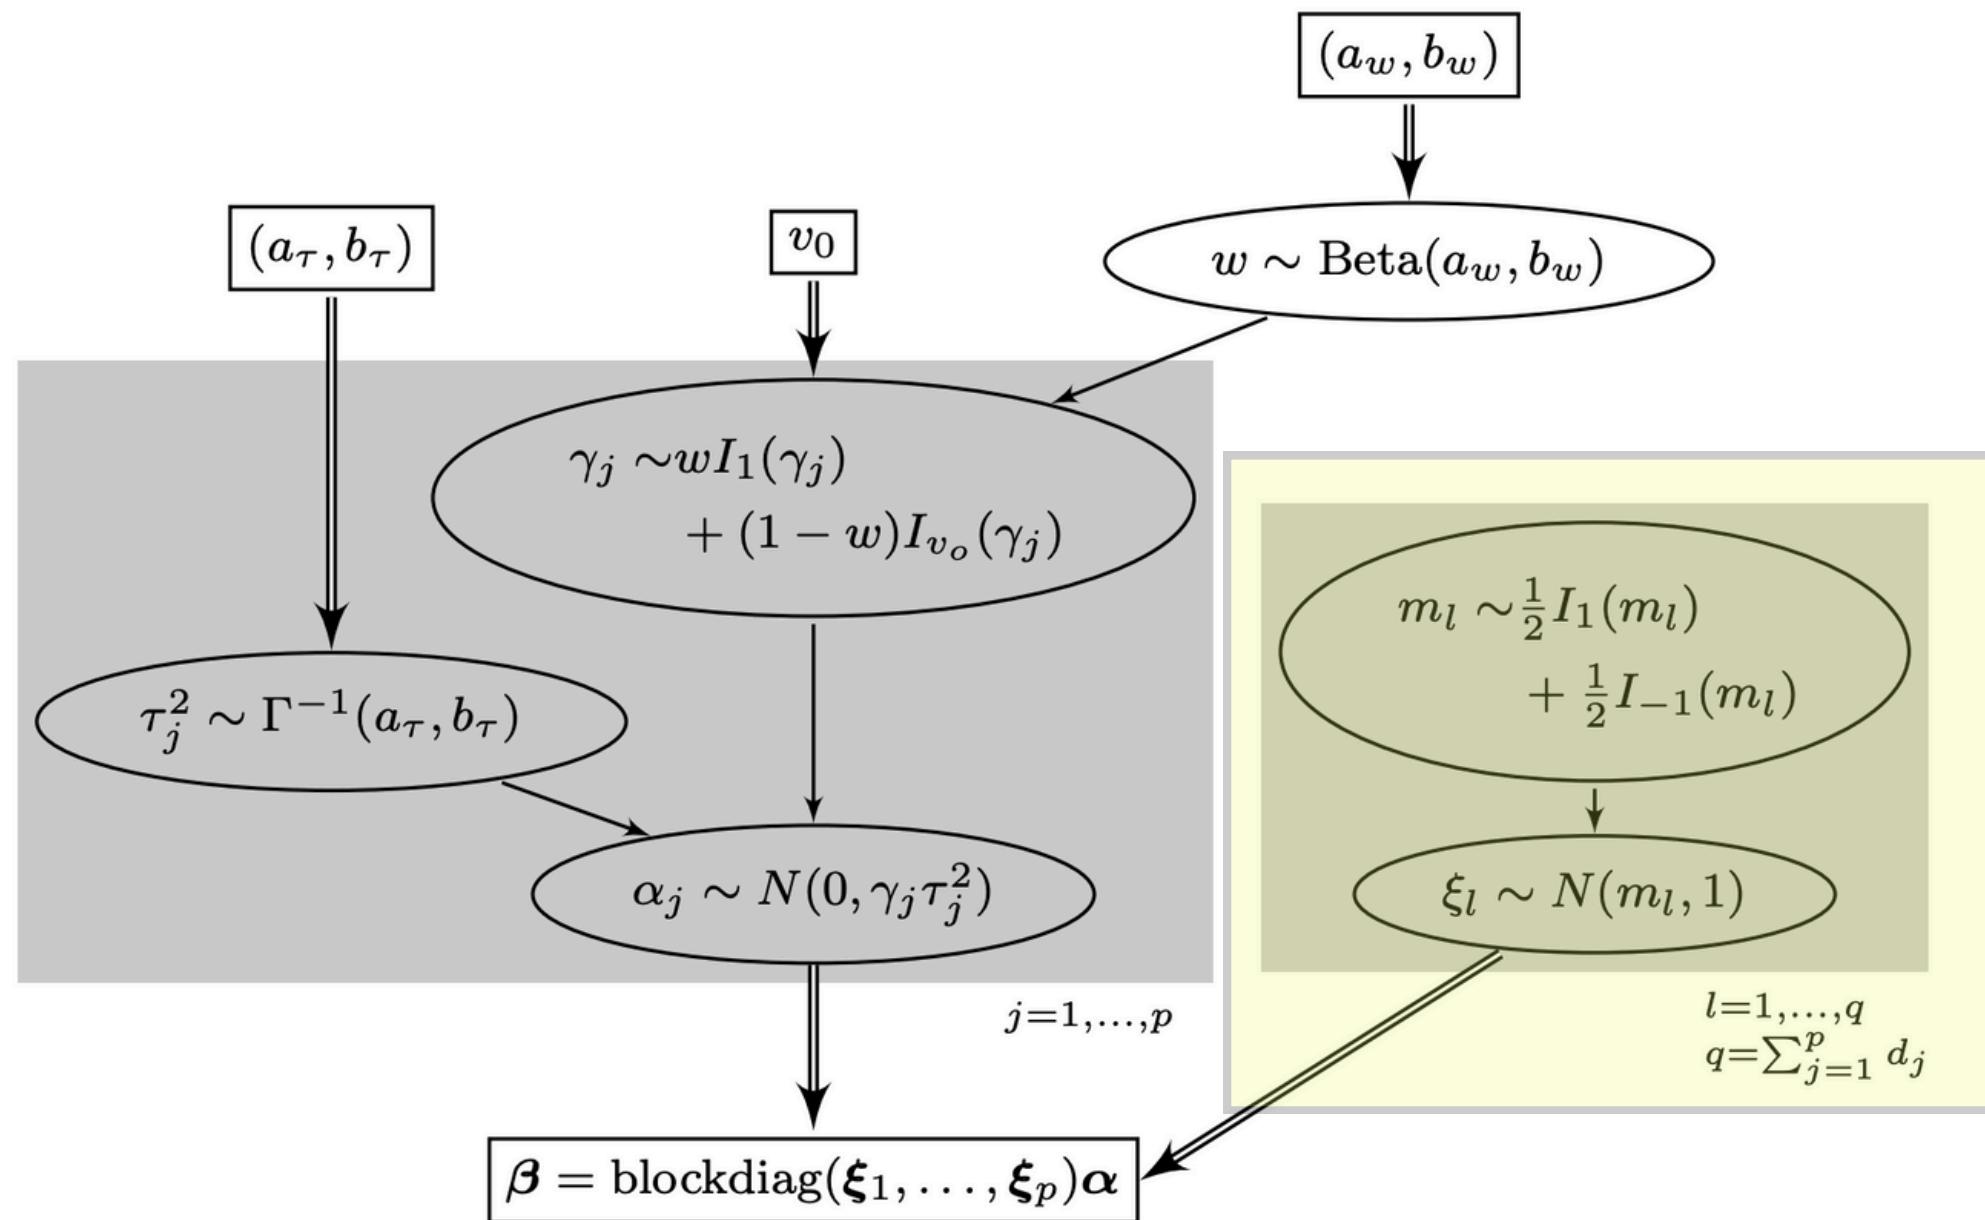


Figure 1. Graphe acyclique dirigé du prior peNMIG. Source : Scheipl, 2011.

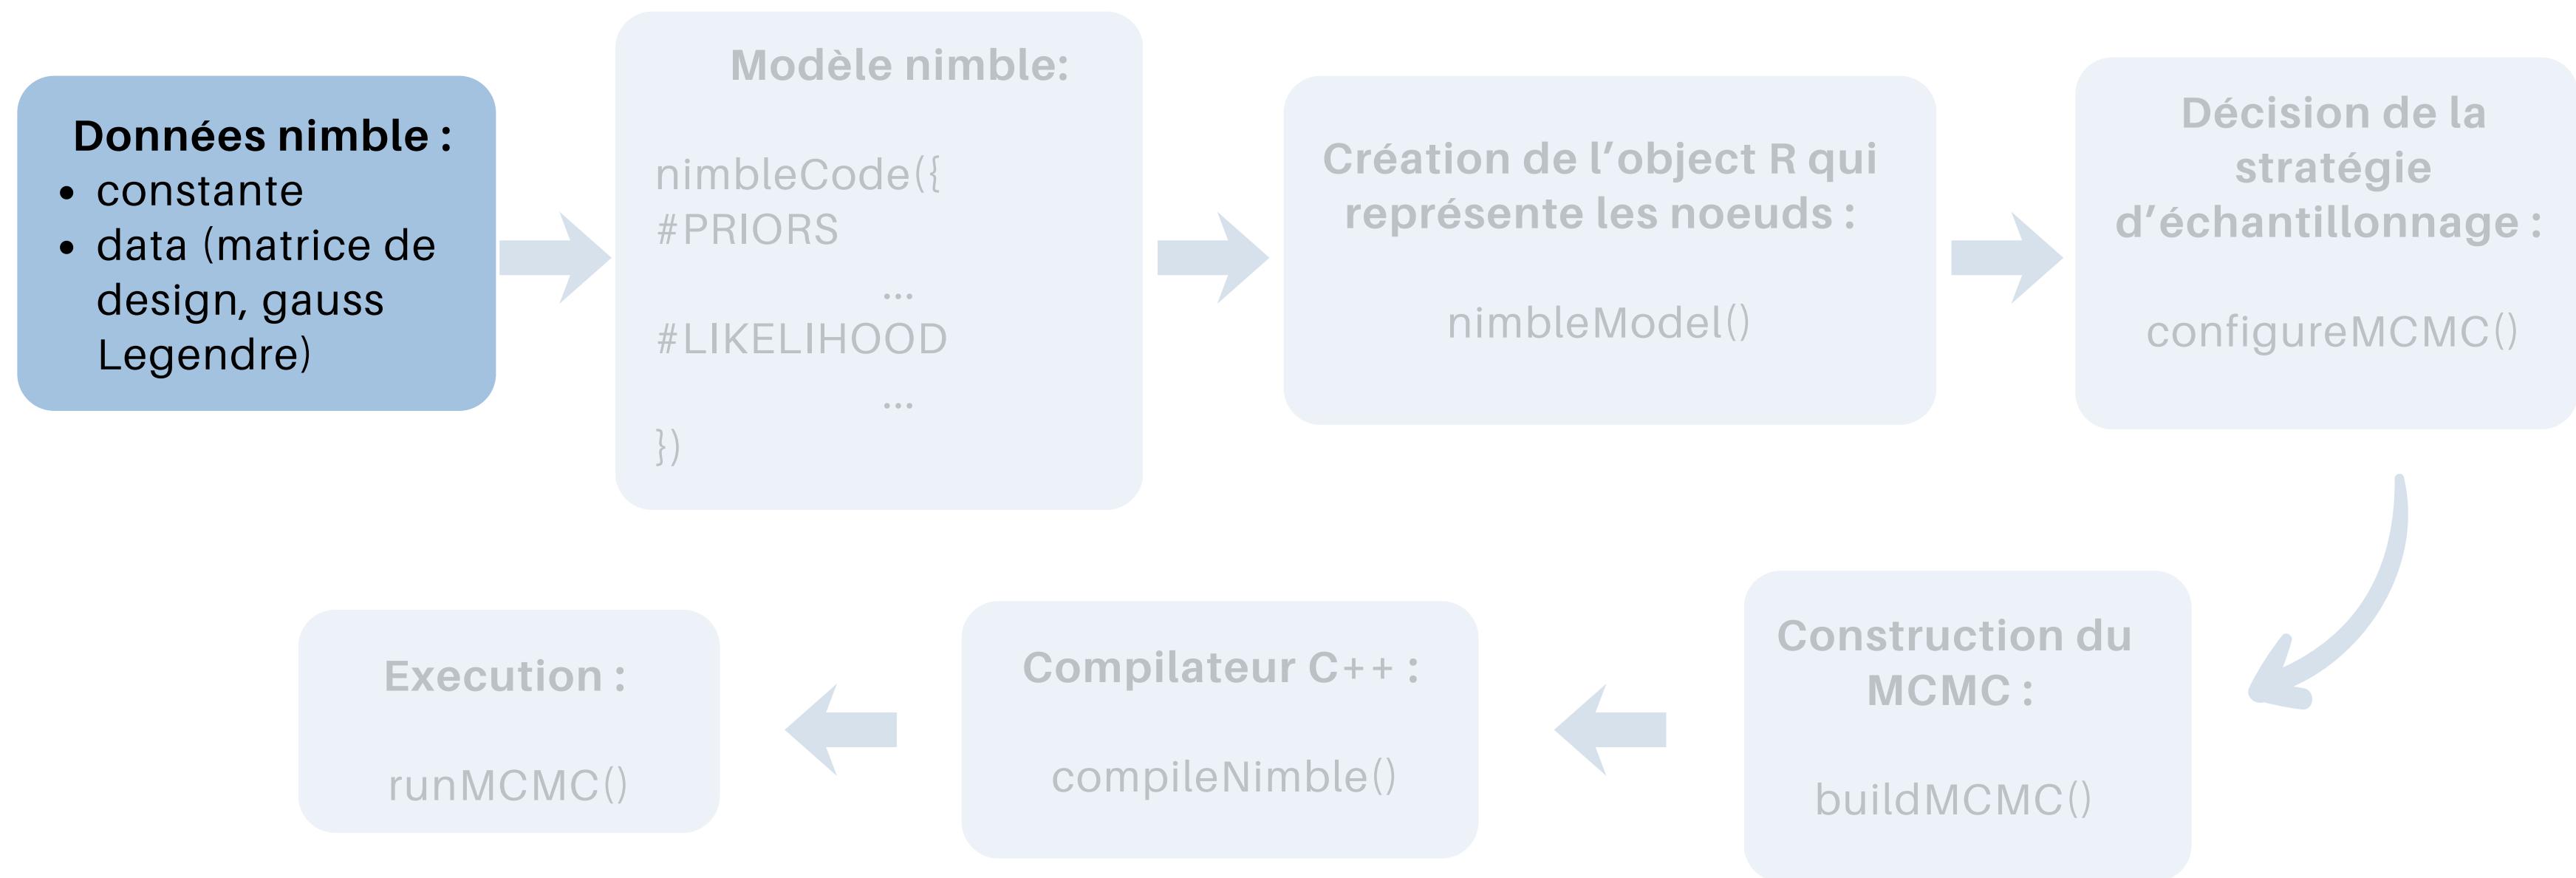
PRIOR



ξ_l : redistribuent α_j entre les différentes composantes du bloc (par ex. les différentes fonctions de base spline).

Figure 1. Graphe acyclique dirigé du prior peNMIG. Source : Scheipl, 2011.

Méthode



Package R nimble

1

FORMULE

$$\text{Surv}(t, \text{status}) \sim t + x_1 + x_2$$

OU

$$\text{Surv}(t, \text{status}) \sim \text{lin}(t) + \text{sm}(t) + \text{lin}(x_1) + \text{lin}(x_2)$$

2

MATRICE DE DESIGN

Création de matrice de design pour chaque terme du modèle :

- **U()** : intercept, terme non soumis à la sélection

1

FORMULE

$$\text{Surv}(t, \text{status}) \sim t + x_1 + x_2$$

OU

$$\text{Surv}(t, \text{status}) \sim \text{lin}(t) + \text{sm}(t) + \text{lin}(x_1) + \text{lin}(x_2)$$

2

MATRICE DE DESIGN

Création de matrice de design pour chaque terme du modèle :

- **U()** : intercept, terme non soumis à la sélection
- **fct()**: terme facteur
 - a. création de la matrice de design à partir de la **matrice de contraste**
 - b. **Mise à l'échelle** : Norme de Frobenius standardisée = 0.5

1

FORMULE

$$\text{Surv}(t, \text{status}) \sim t + x_1 + x_2$$

OU

$$\text{Surv}(t, \text{status}) \sim \text{lin}(t) + \text{sm}(t) + \text{lin}(x_1) + \text{lin}(x_2)$$

2

MATRICE DE DESIGN

Création de matrice de design pour chaque terme du modèle :

- **U()** : intercept, terme non soumis à la sélection
- **fct()**: terme facteur
- **lin()**: terme linéaire
 - a. **Transformation** : polynome orthogonal de degré 1 (centré)
 - b. **Mise à l'échelle** : Norme de Frobenius standardisée = 0.5

1

FORMULE

$$\text{Surv}(t, \text{status}) \sim t + x_1 + x_2$$

OU

$$\text{Surv}(t, \text{status}) \sim \text{lin}(t) + \text{sm}(t) + \text{lin}(x_1) + \text{lin}(x_2)$$

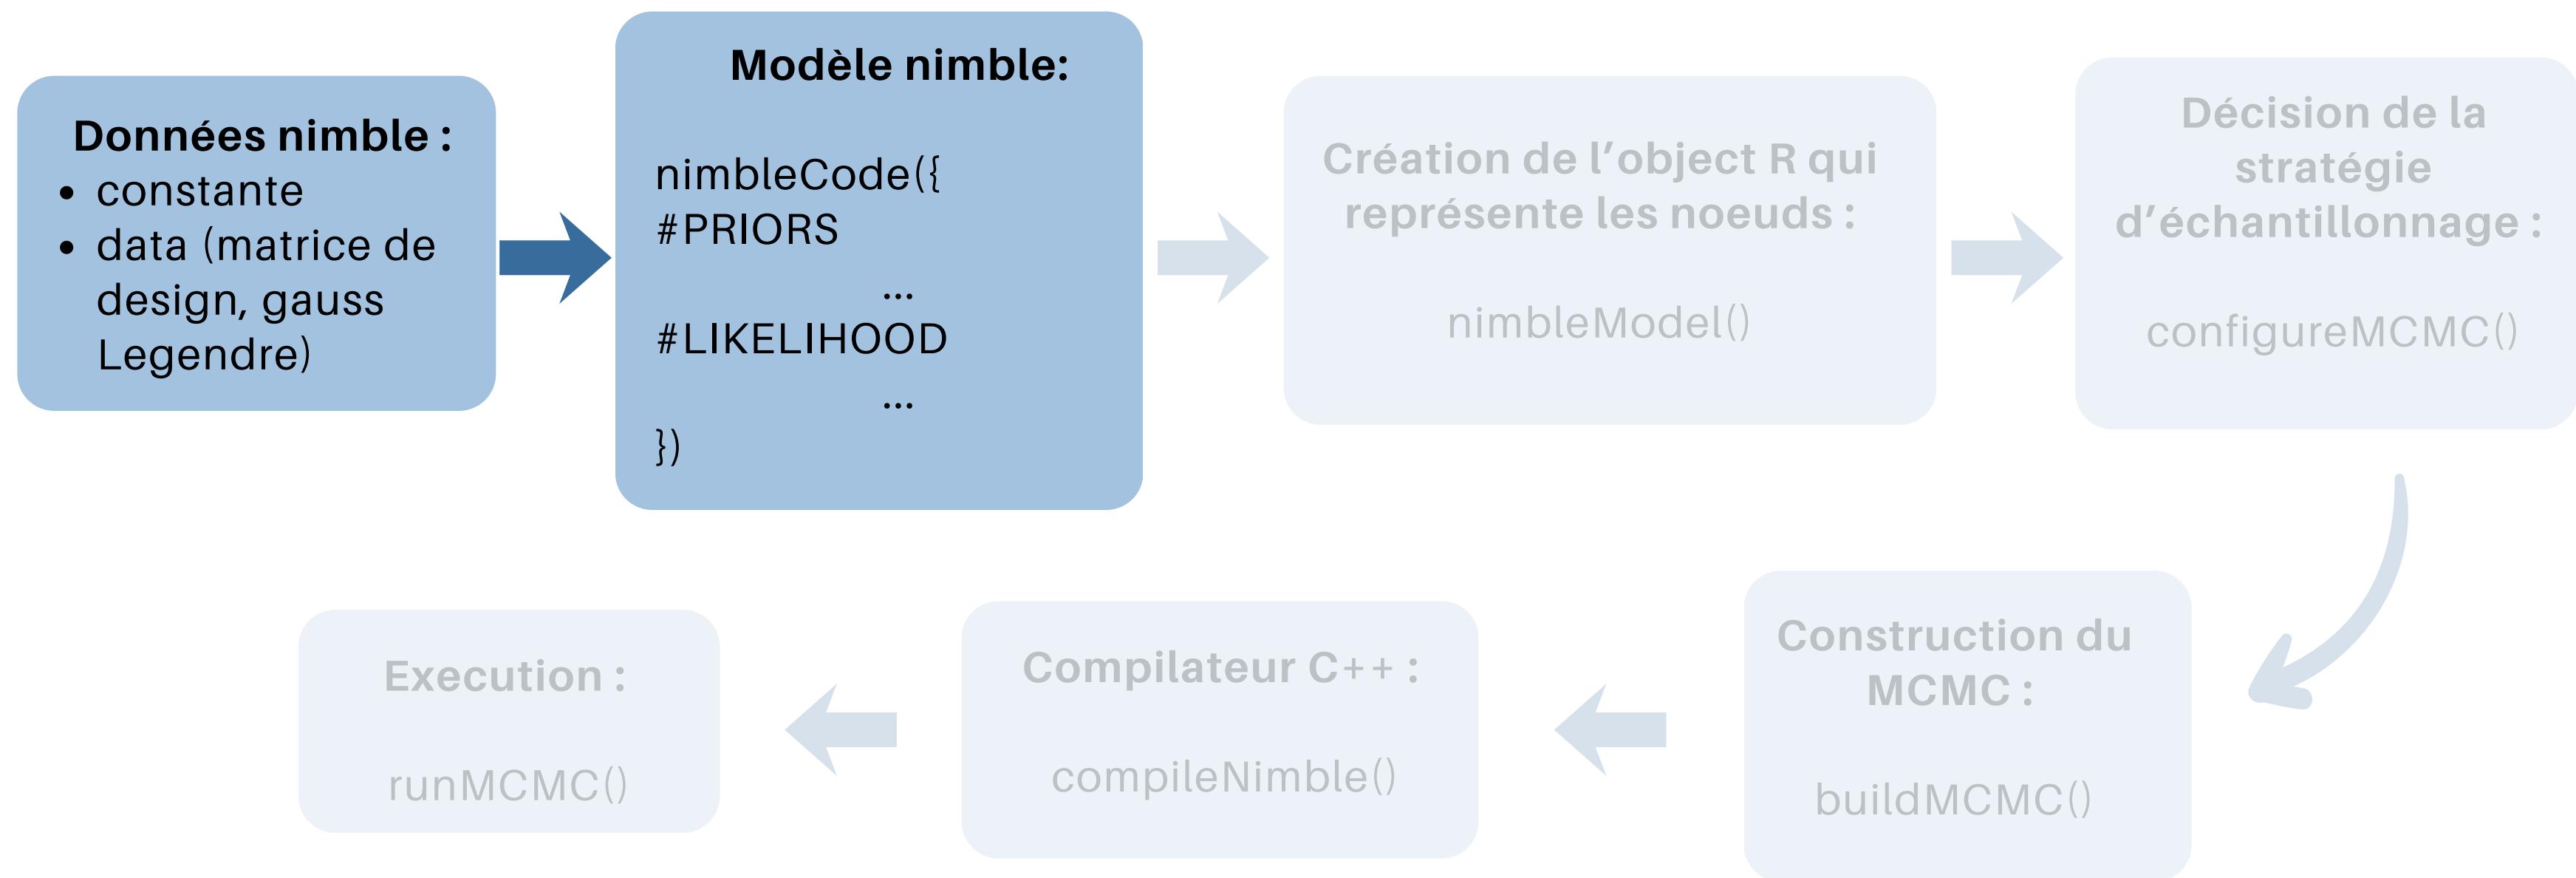
2

MATRICE DE DESIGN

Création de matrice de design pour chaque terme du modèle :

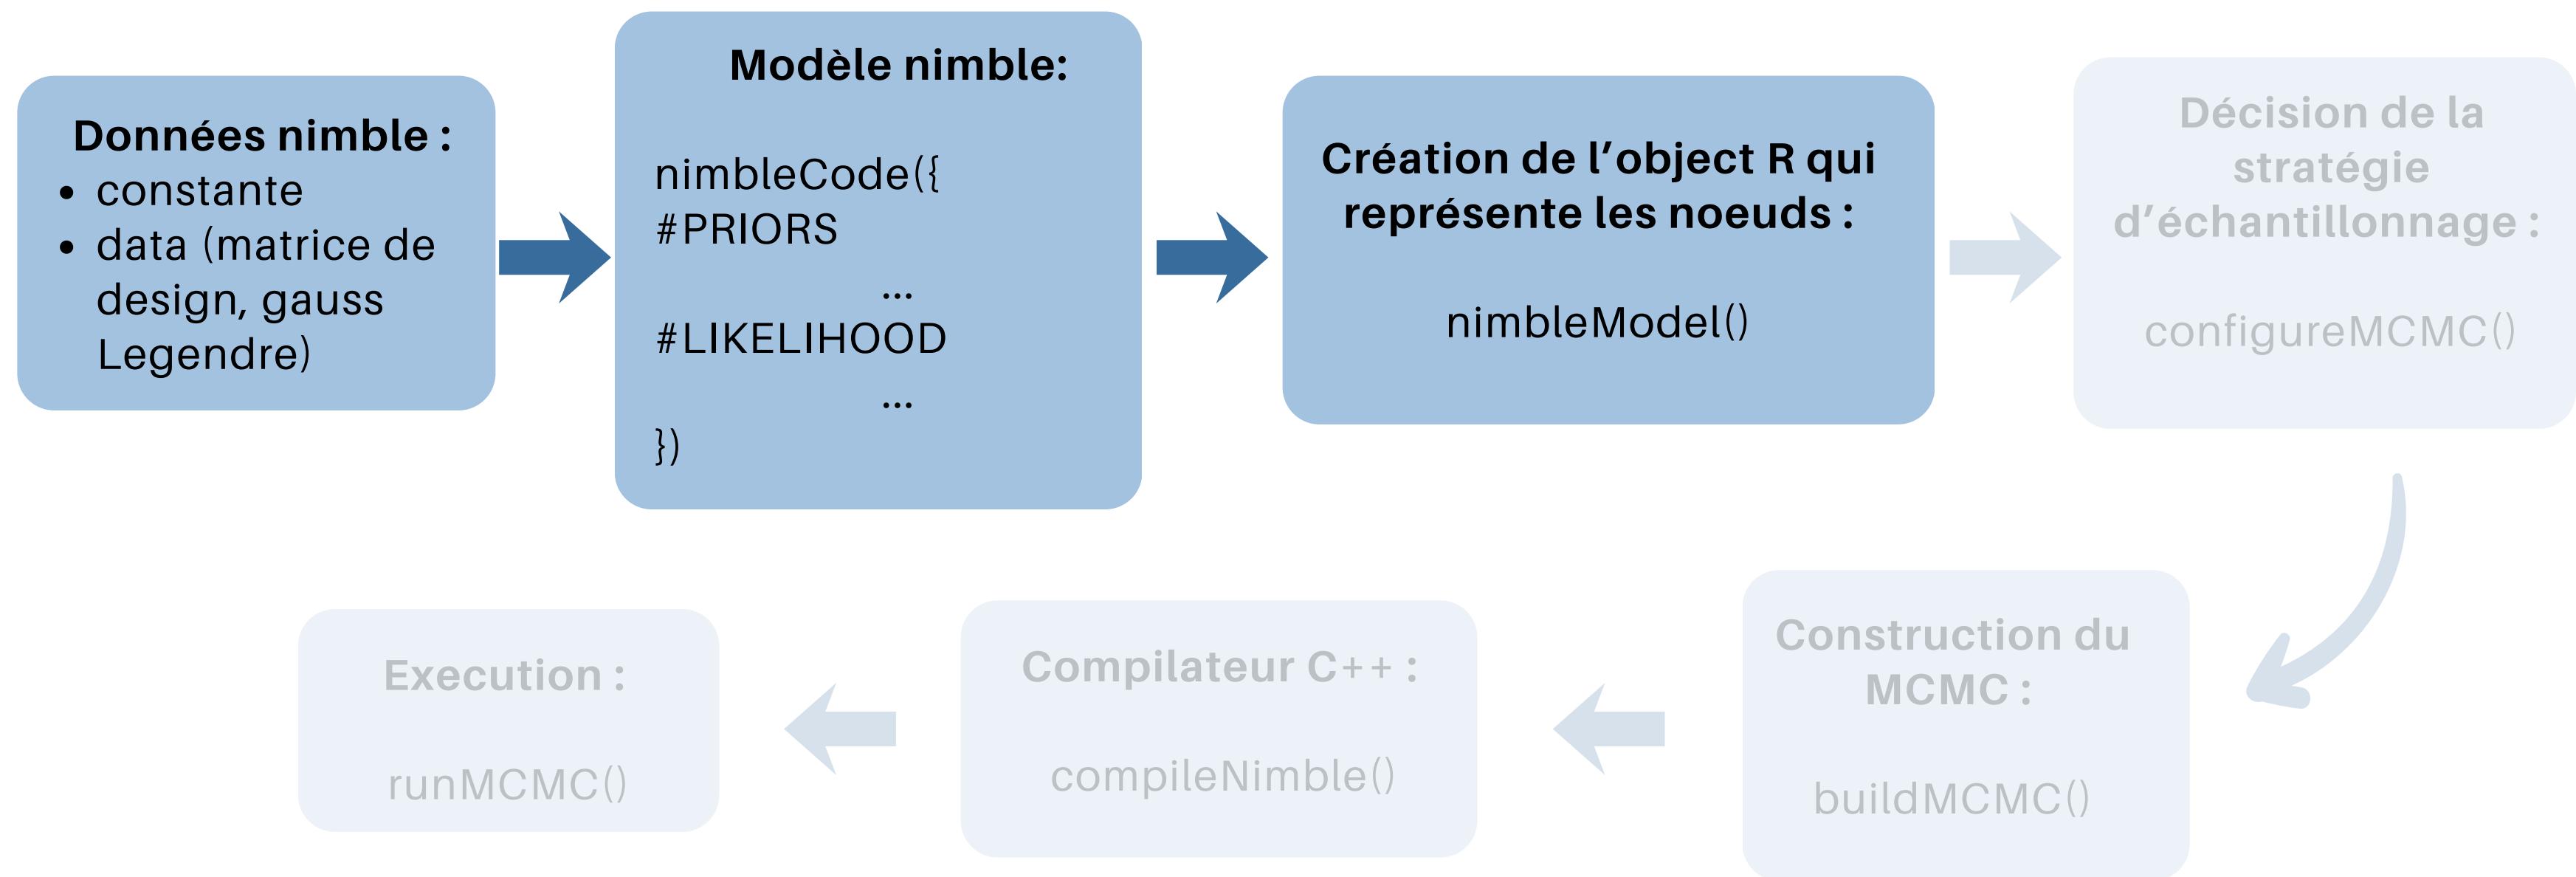
- **U()** : intercept, terme non soumis à la sélection
- **fct()**: terme facteur
- **lin()**: terme linéaire
- **sm()**: terme non-linéaire
 - a. **Base Initiale** : B-Splines + Pénalité P (différences finies d'ordre 2)
 - b. **Séparation** des composantes constante/linéaire de celles non-linéaires.
(projection orthogonale)
 - c. **Mise à l'échelle** : Norme de Frobenius standardisée globale = 0.5

Méthode



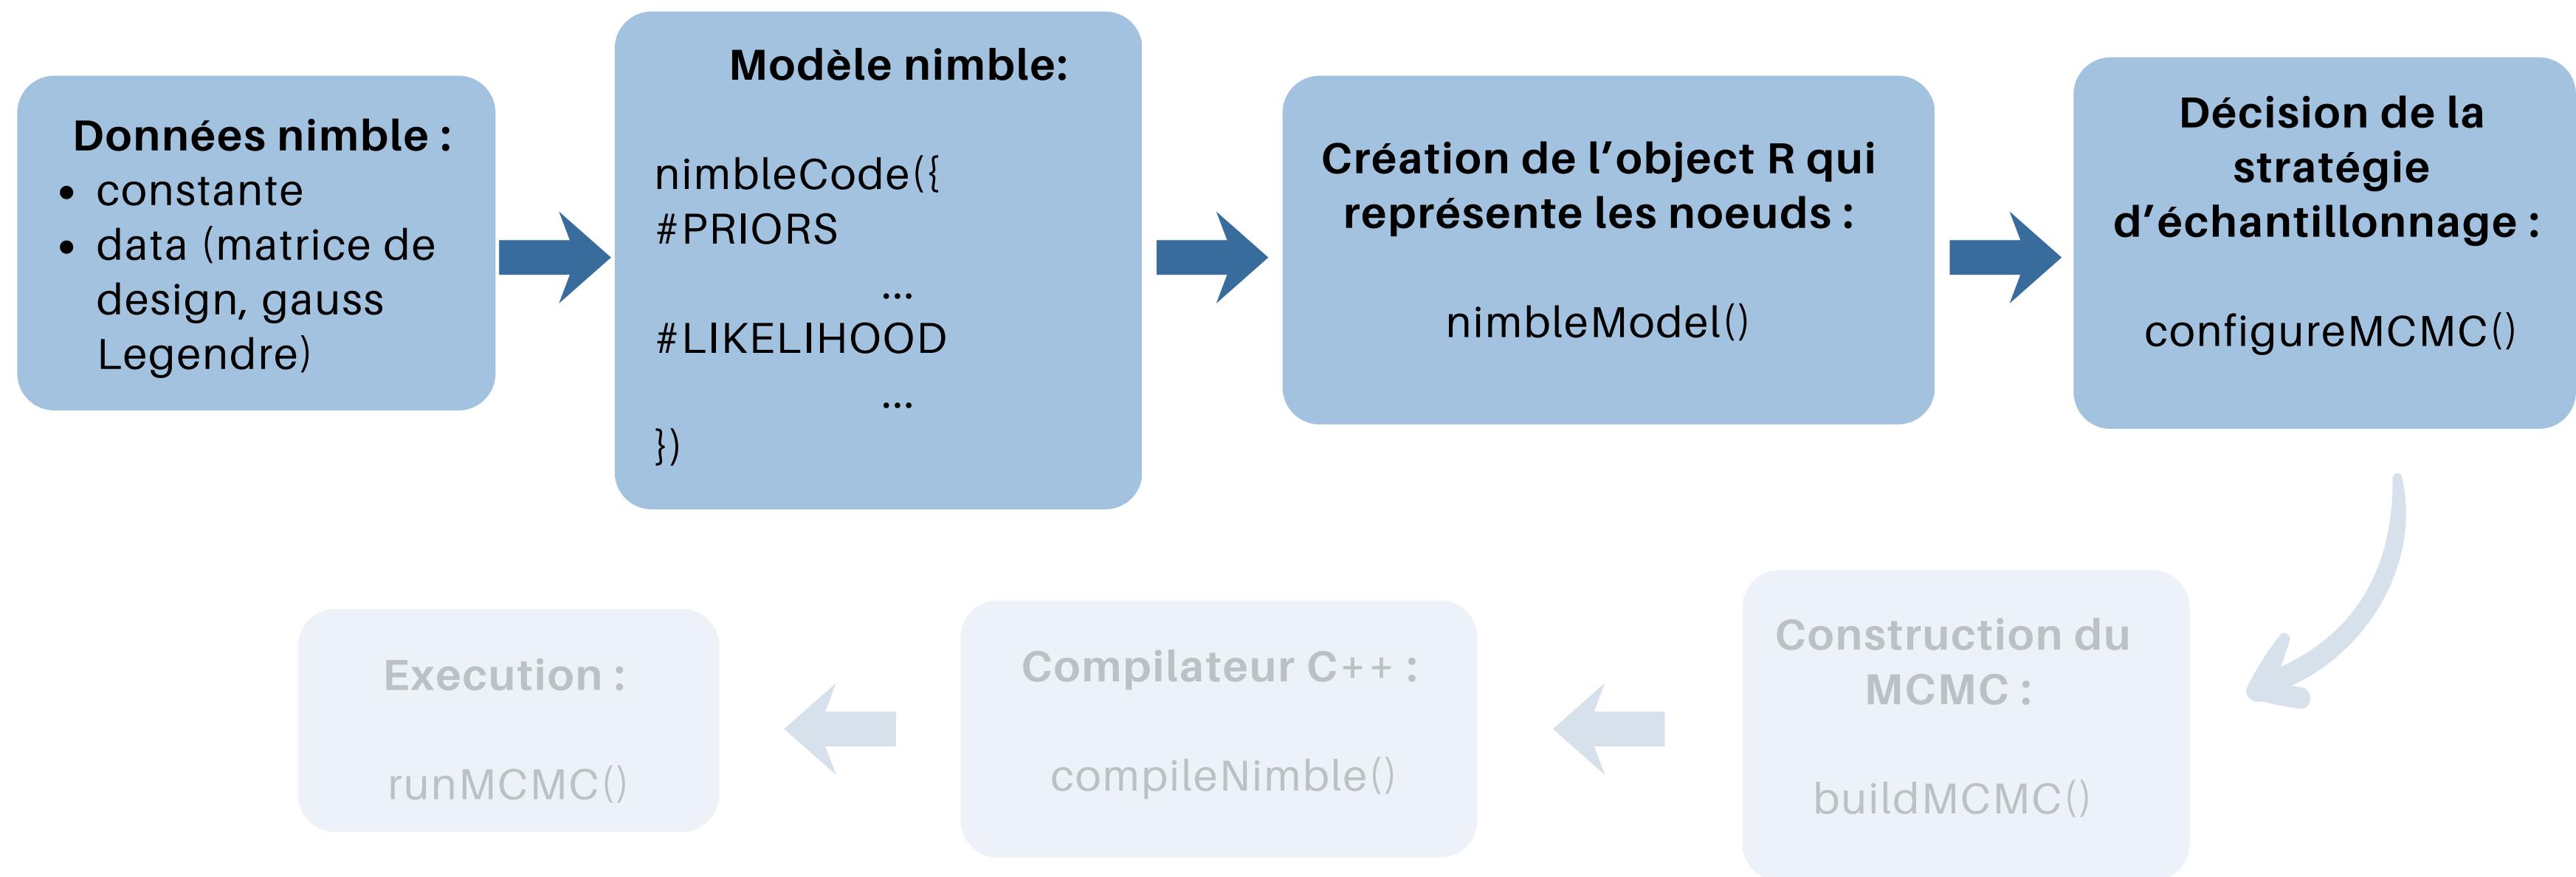
Package R nimble

Méthode



Package R nimble

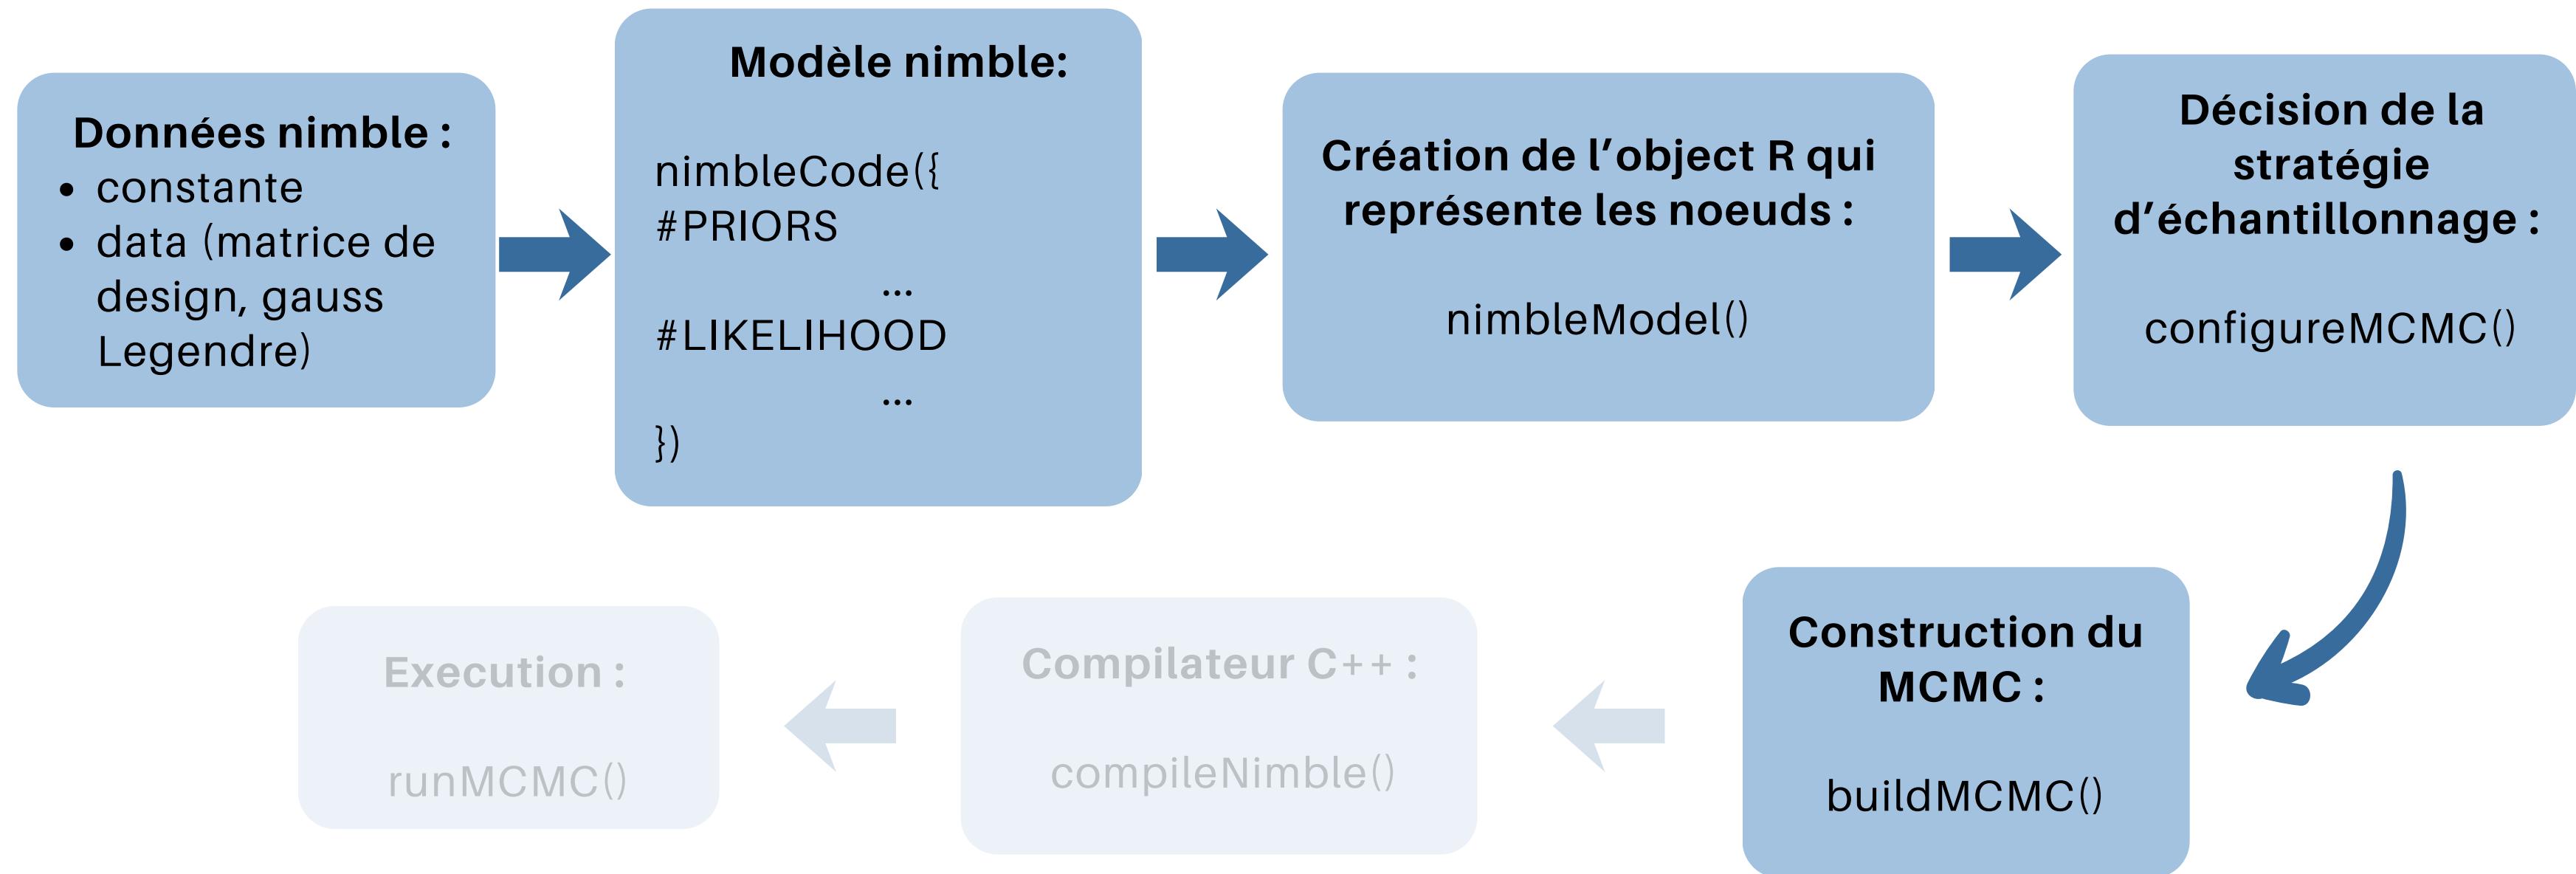
Méthode



Package R nimble

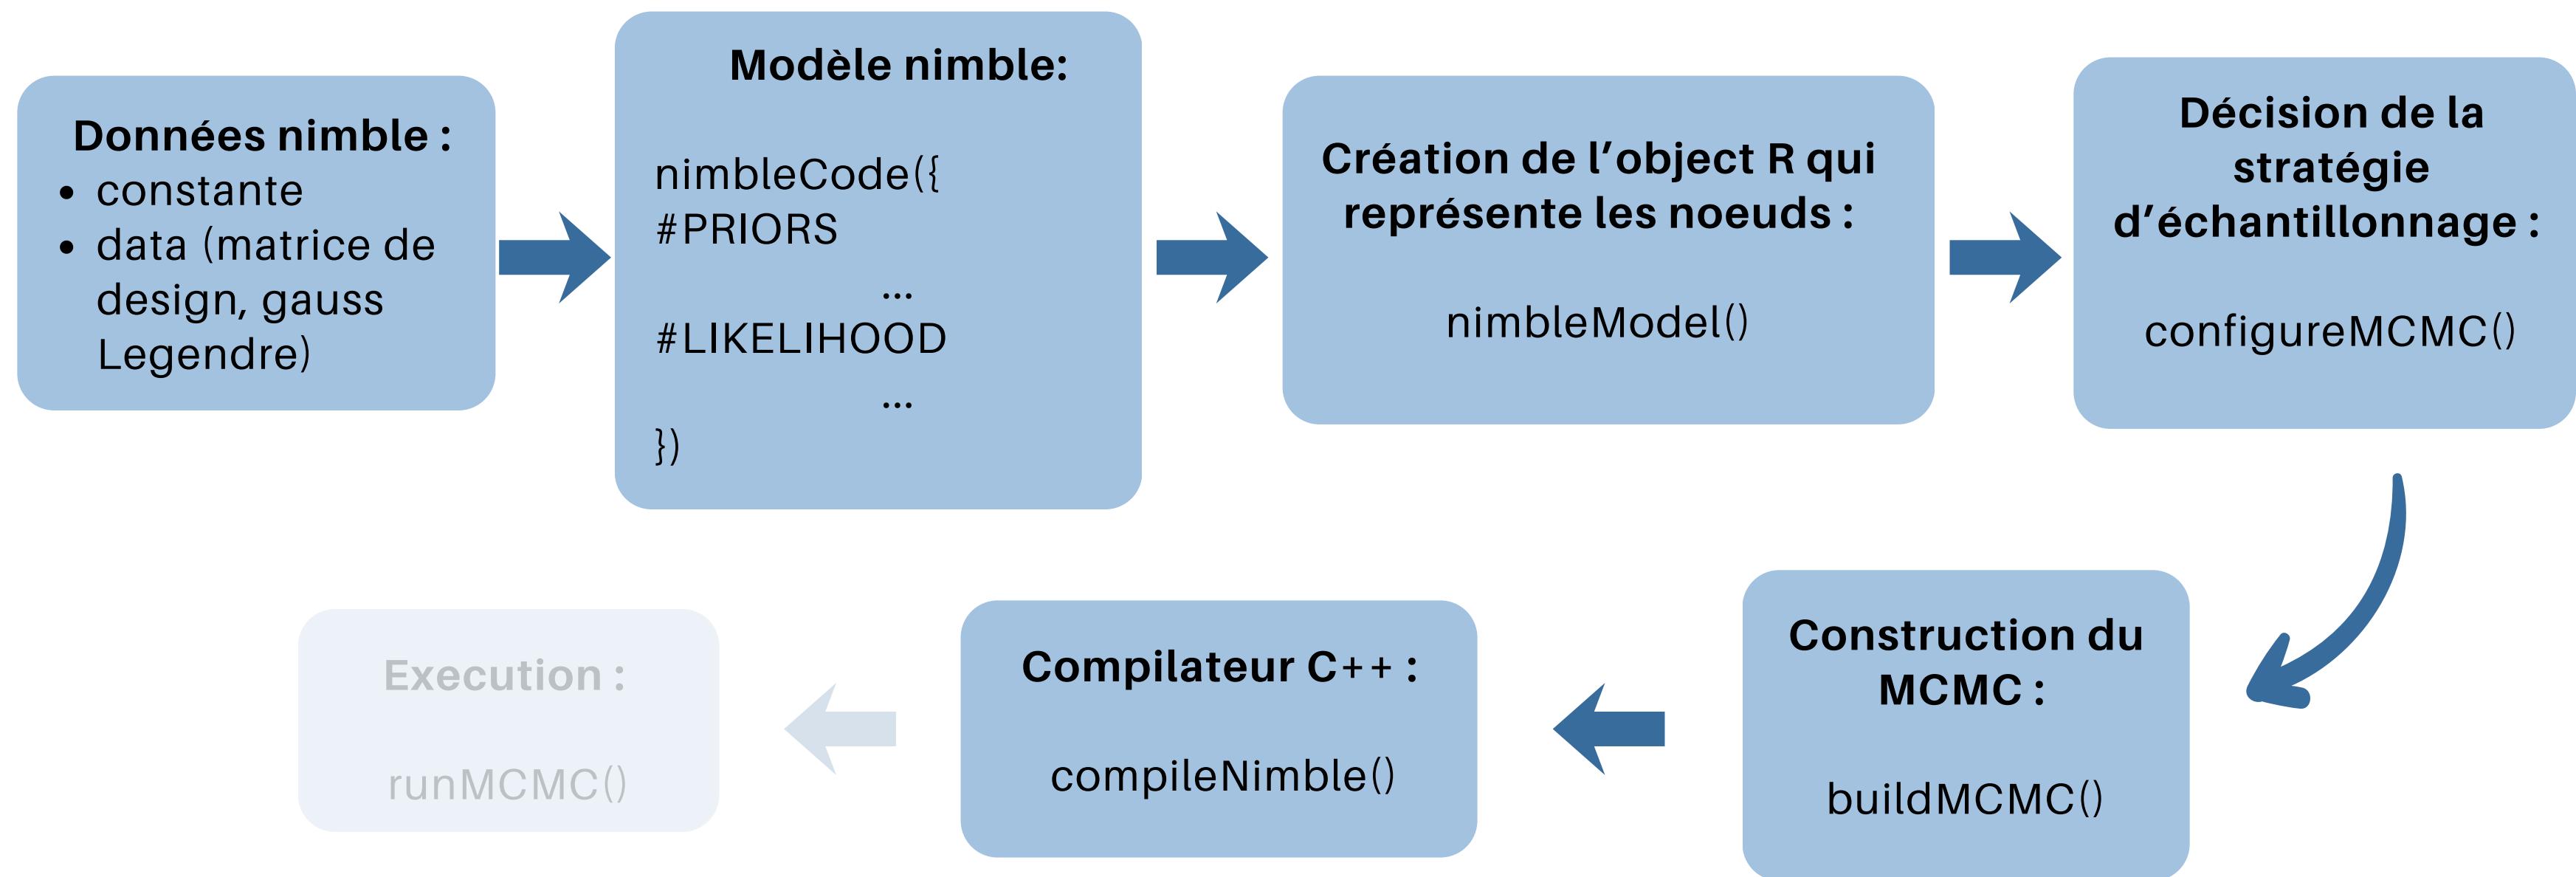
Paramètres	Sampler	Pourquoi ?	Description
Binaires (gamma, m)	Gibbs sampling pour valeurs binaires	Discret (0 ou 1)	<p>Calcule $P(1 \dots)$ vs $P(0 \dots)$:</p> $p_j = \frac{P(1 \dots)}{P(0 \dots) + P(1 \dots)}$ <p>et tire dans une loi de bernouilli avec une probabilité p_j</p>
Tau	Conjugate (Gibbs)	Prior Gamma + Likelihood Normale	Échantillonnage exact, très rapide.
Autres (alpha, ski, w)	RW (Random Walk)	Conjugaison brisée (Zero Trick / Formules)	Exploration locale "Essai-Erreur" (Metropolis).

Méthode



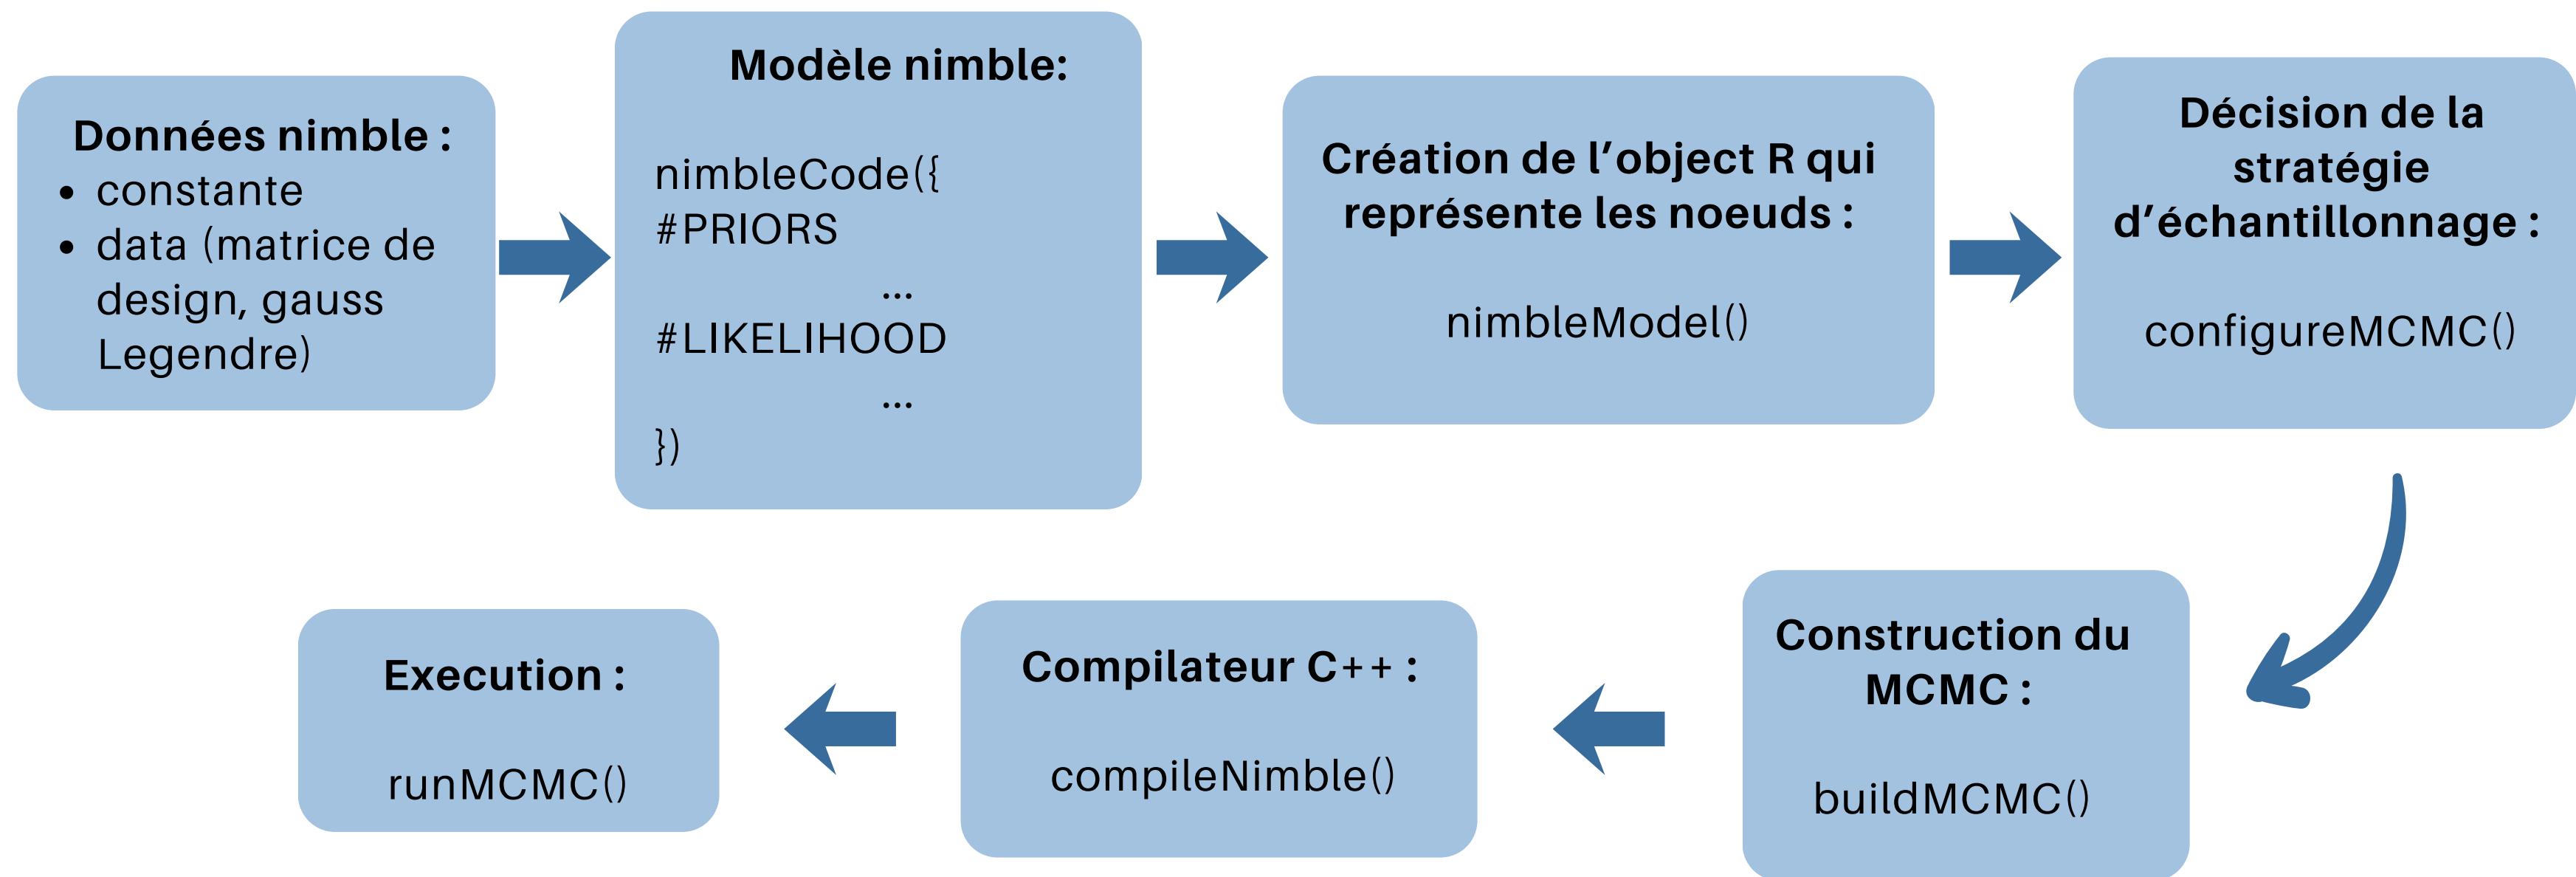
Package R nimble

Méthode



Package R nimble

Méthode



Package R nimble

ETUDE DE SIMULATION PRELIMINAIRE

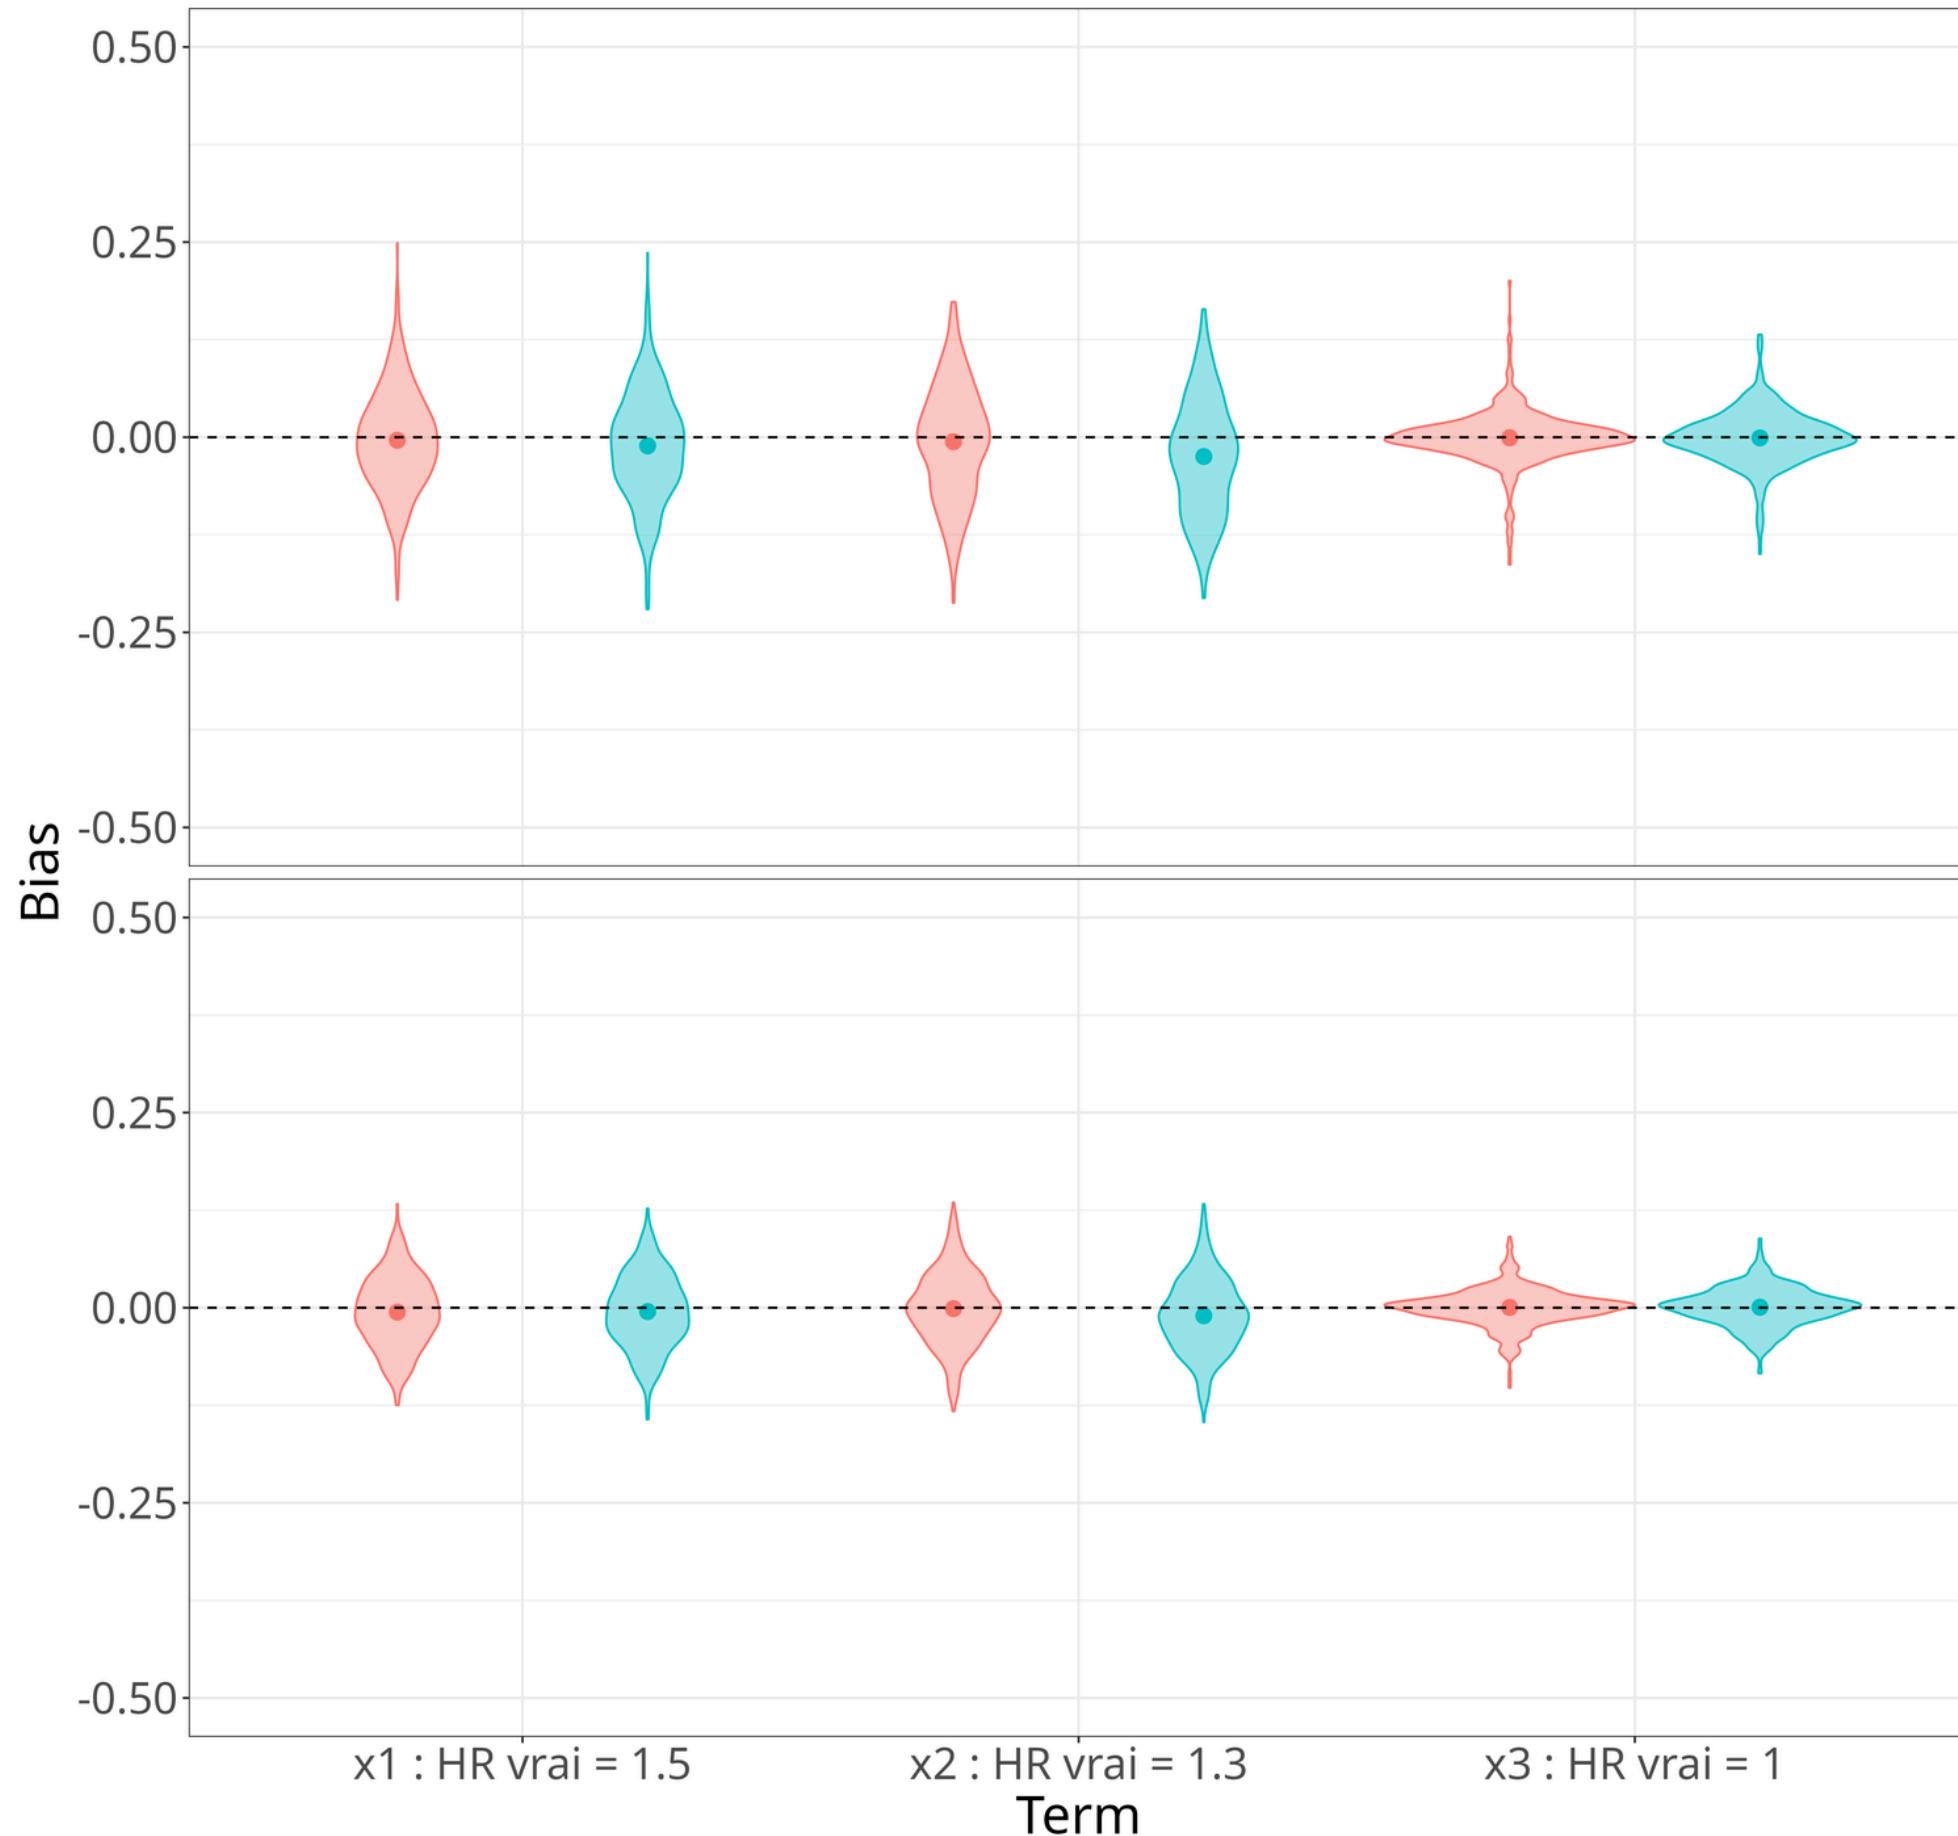


Objectif : comparer le modèle bayésien de taux développé (spikeSlabHazard) vs approximation Poisson (spikeSlabGAM).



- Deux tailles d'échantillon : **500 et 1000 individus**
- **500 jeux** de données indépendants par taille
- **Covariables** : 3 variables ~ $N(0,1)$
 - Effet réel : **x1 (HR = 1.5), x2 (HR = 1.3)**
 - Pas d'effet : x3
- **Taux de base** : B-splines cubiques (degré 3, nœuds internes à 2.12 et 3.92)
- Critère de précision des estimations :
 - Biais
 - Erreur quadratique moyenne (MSE)
- Probabilité de couverture
- Probabilités d'inclusion

Résultats

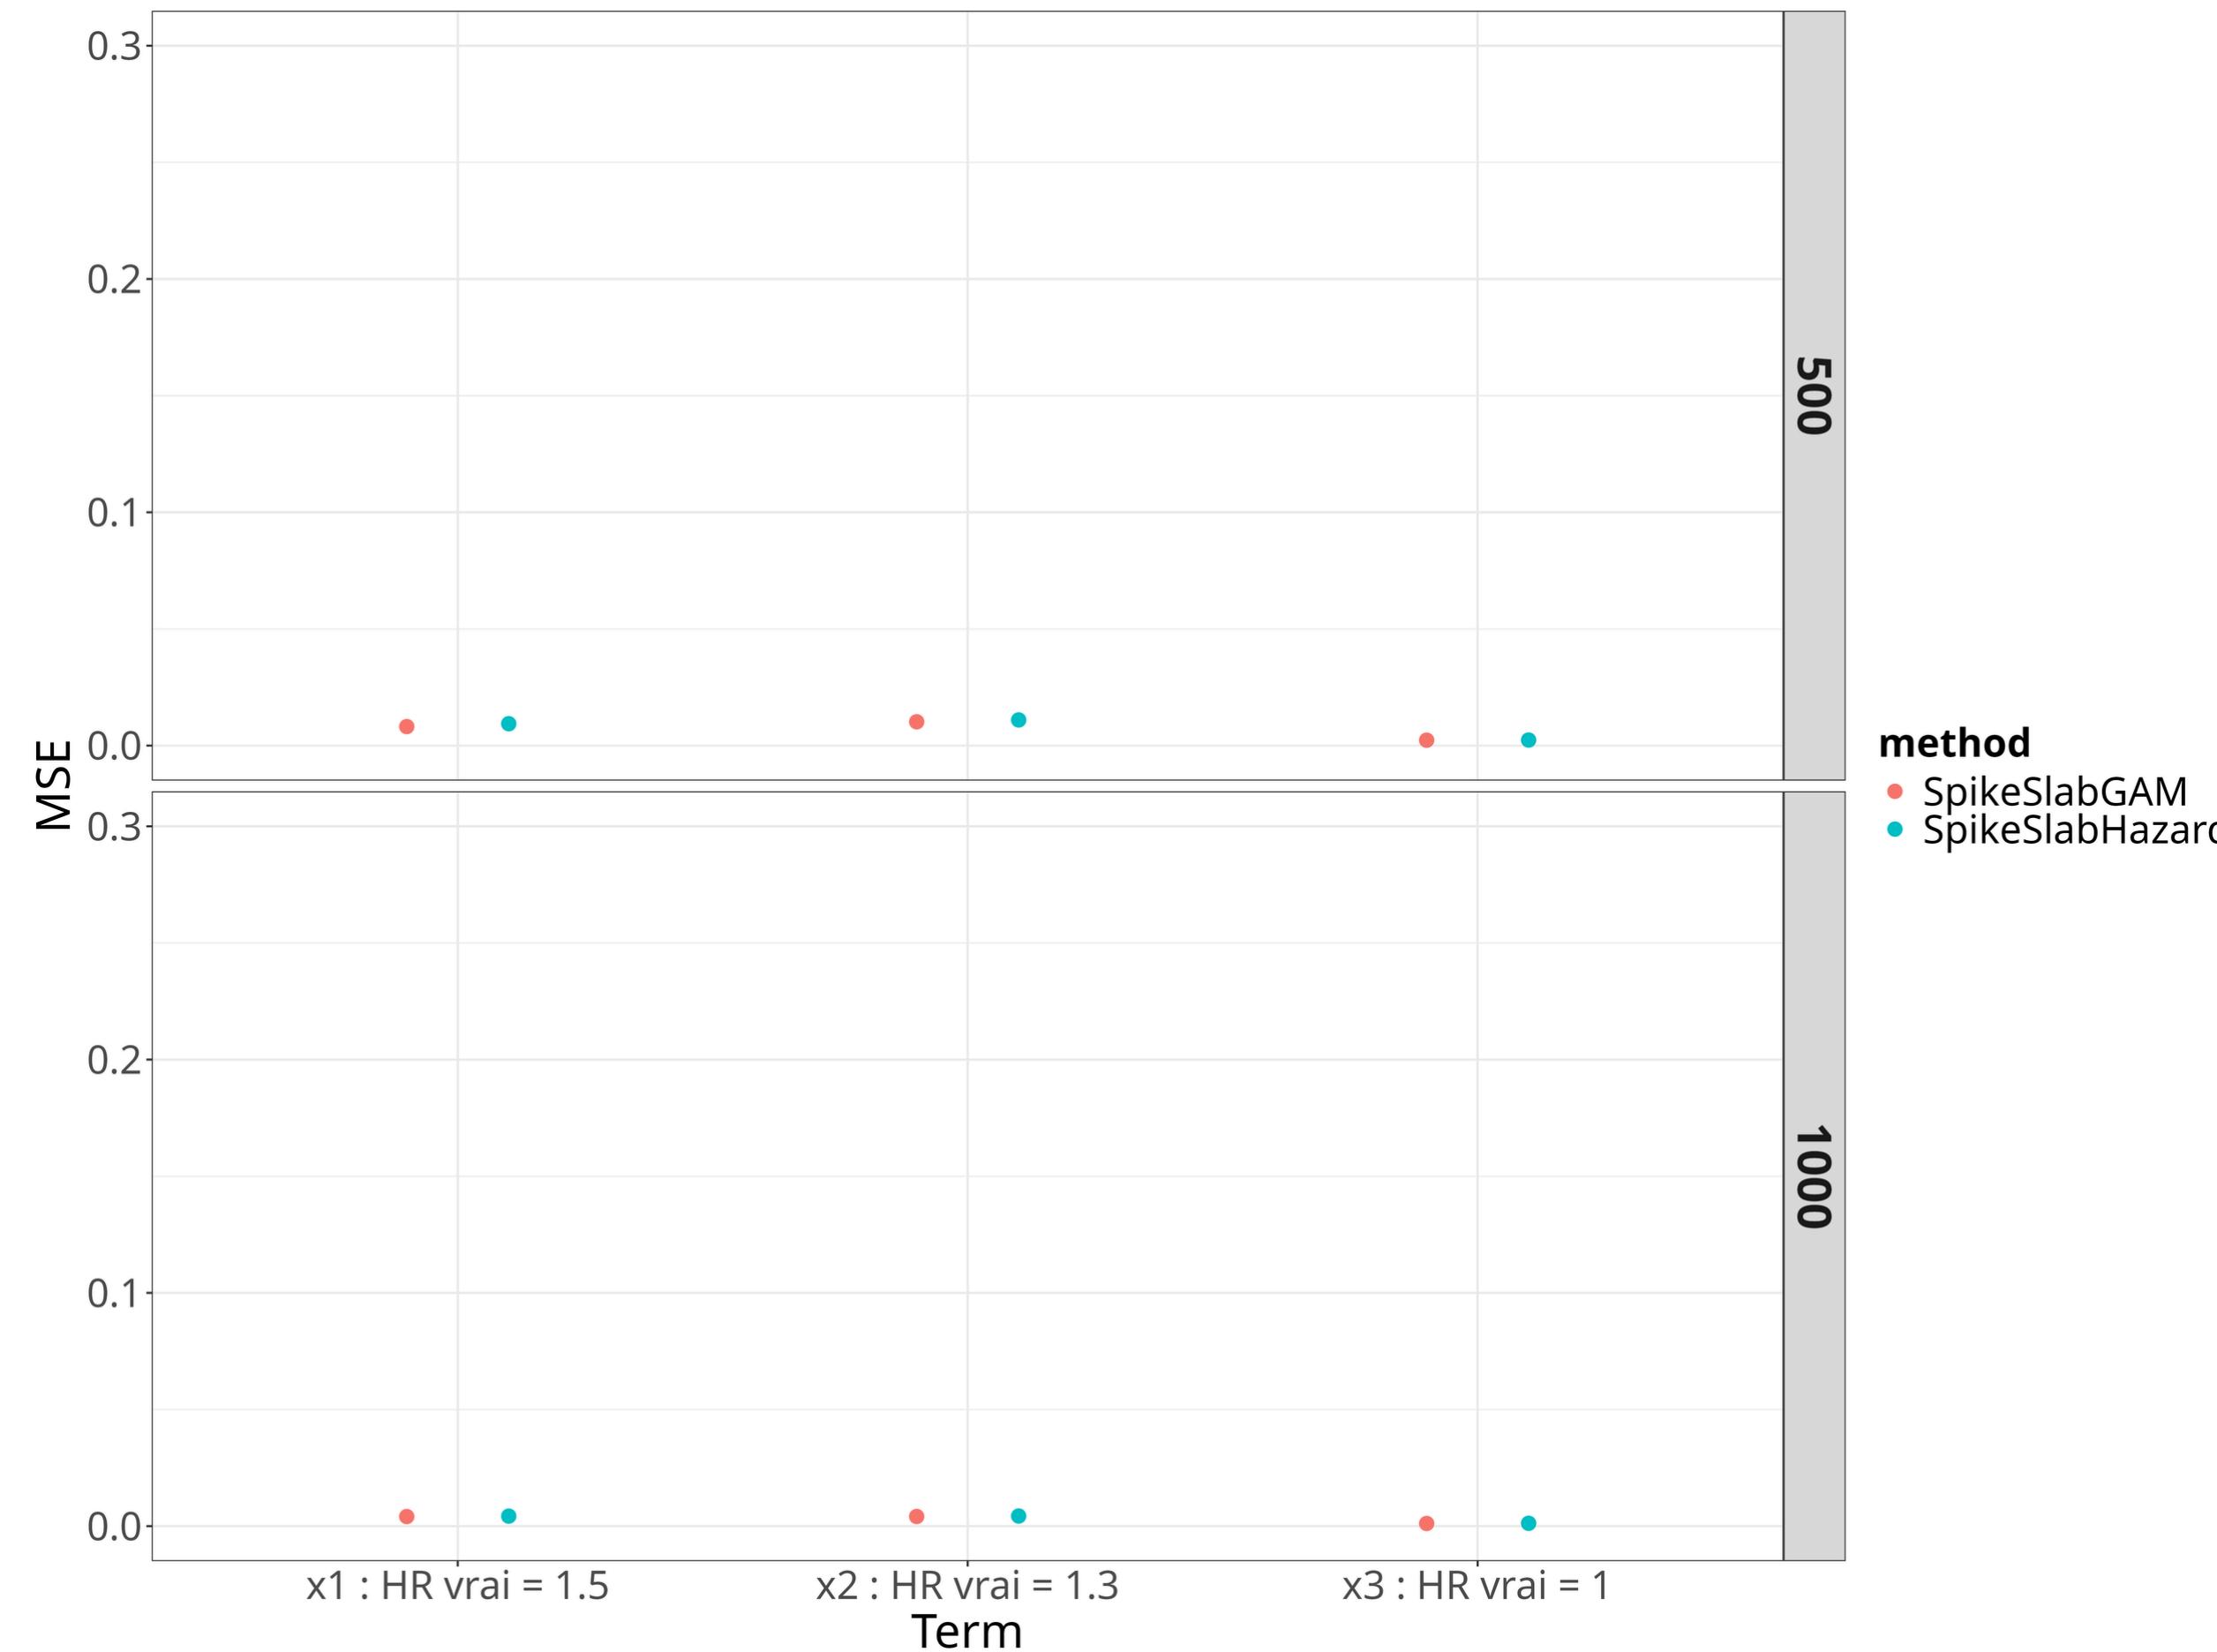


Biais négligeable pour les deux méthodes, biais standardisé<40% :

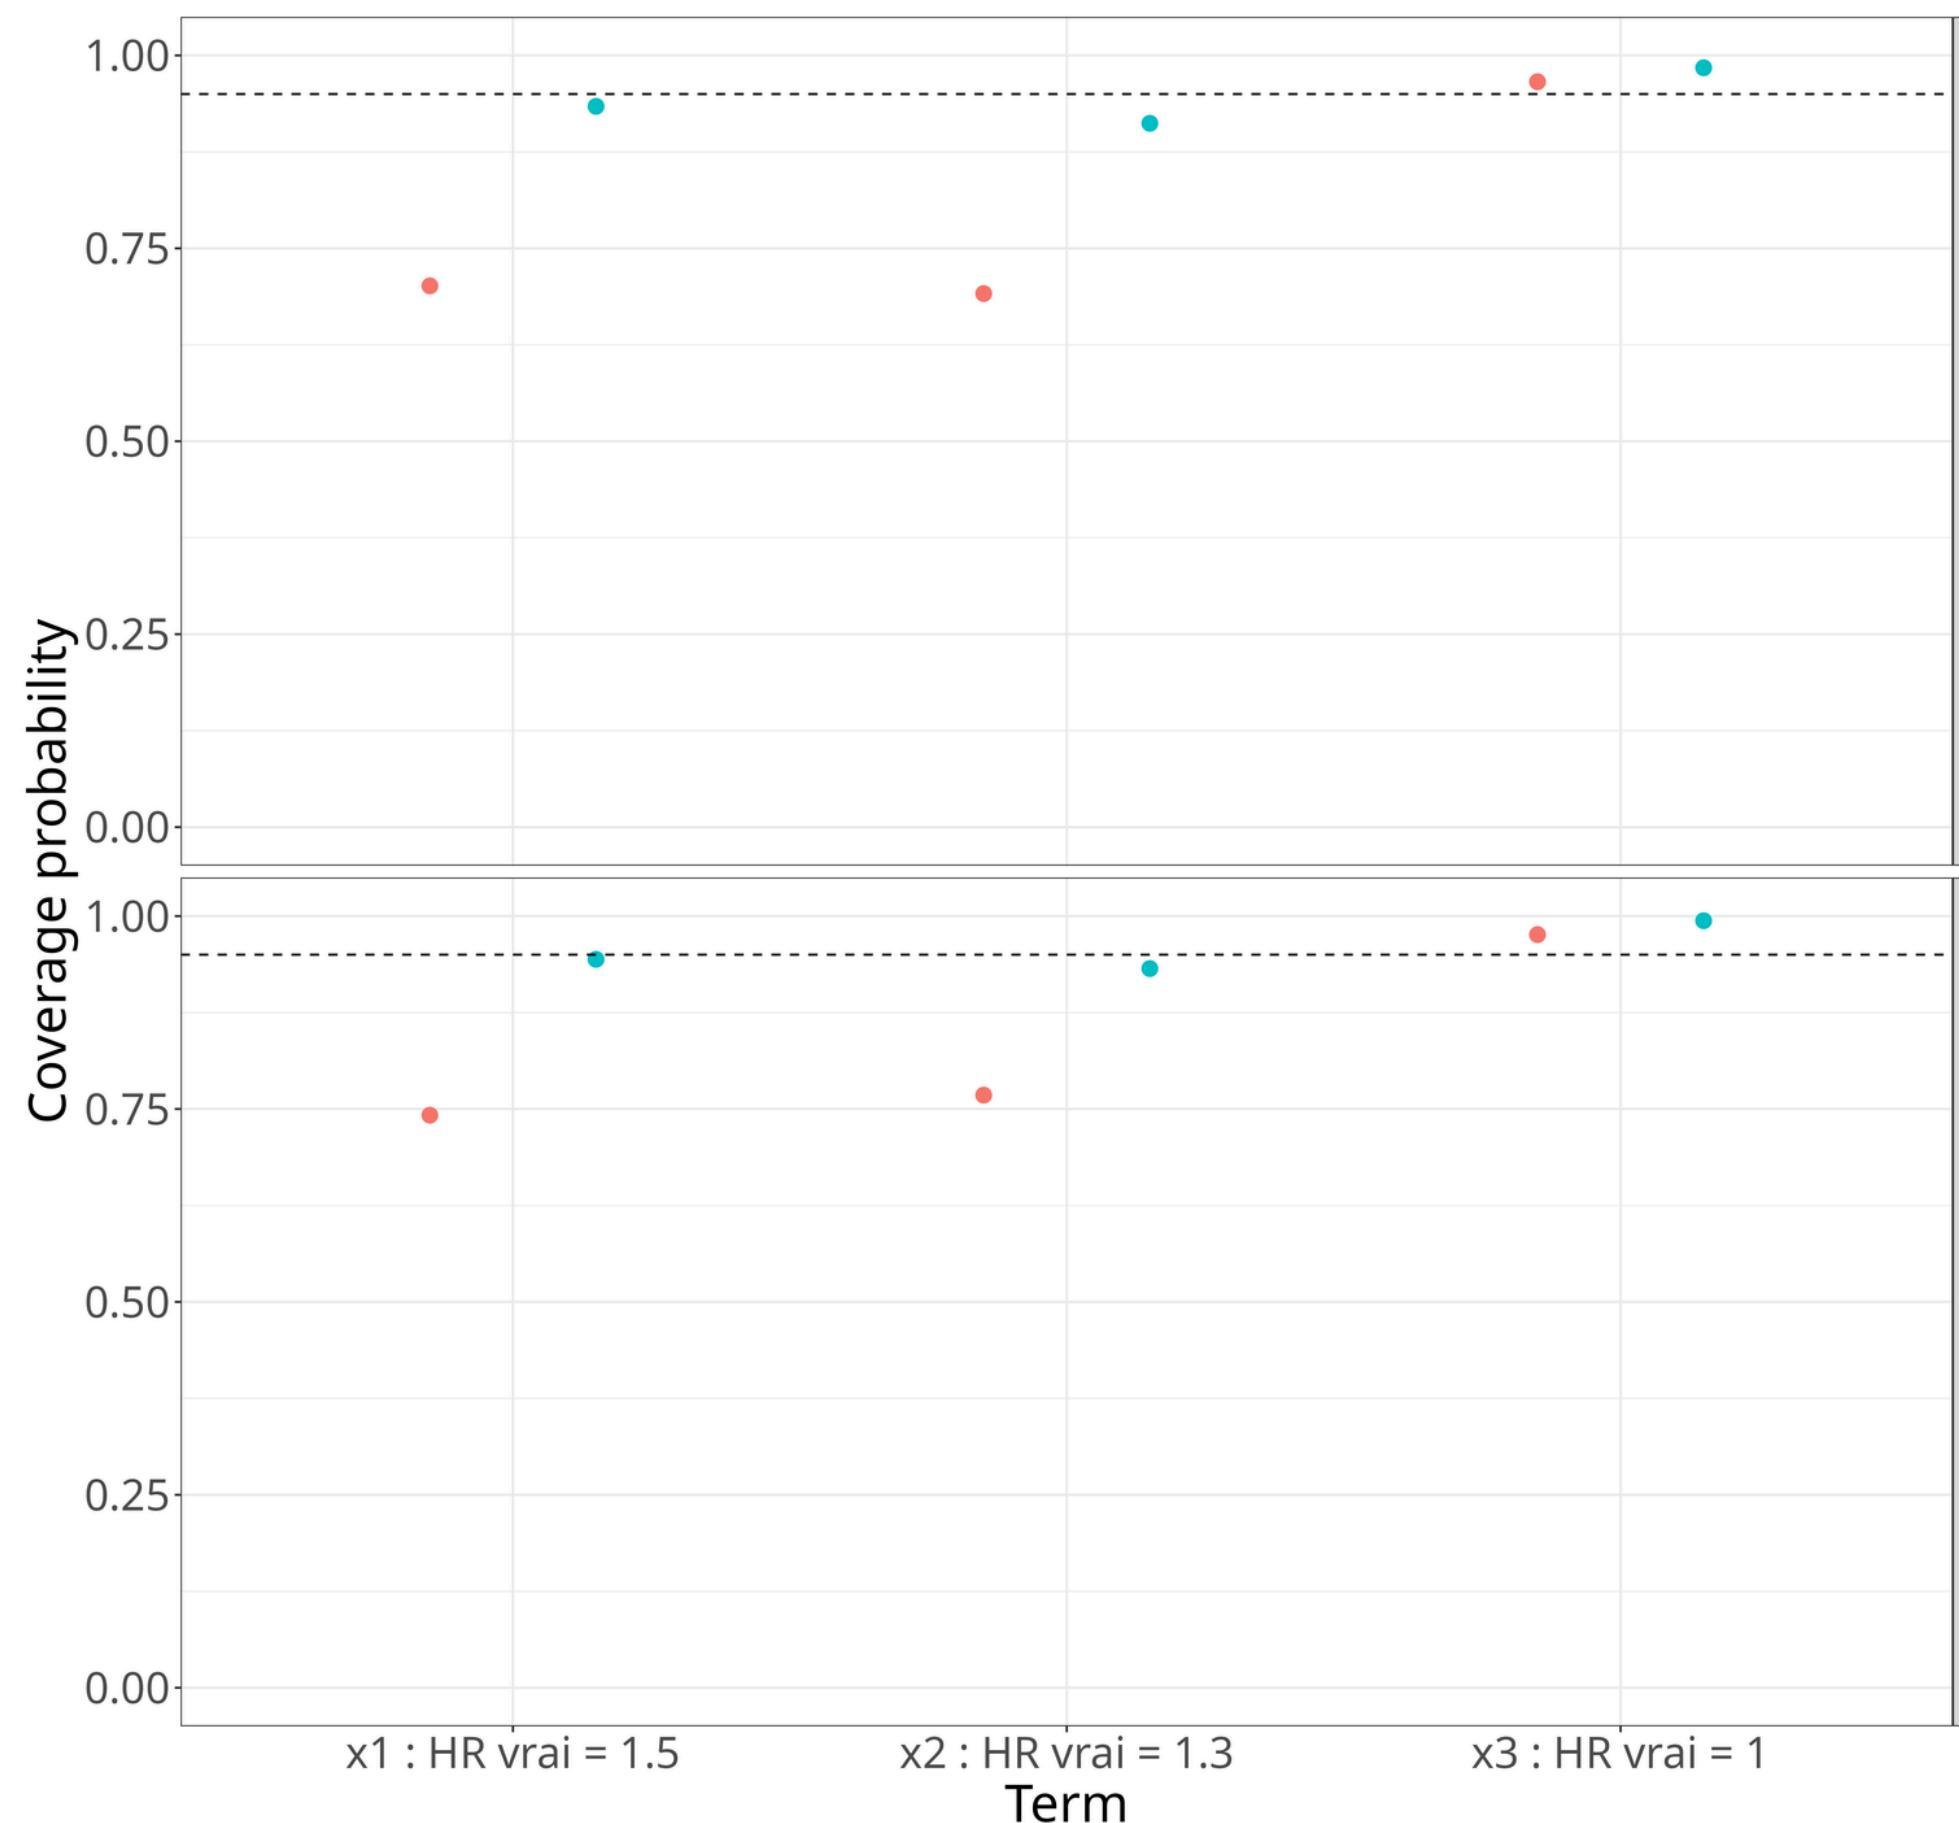
$$\left(\frac{\hat{\beta} - \beta}{\text{SE}(\hat{\beta})} \right) * 100$$

method
• SpikeSlabGAM
• SpikeSlabHazard

Résultats



Résultats



Exemple pour design : $n=500$

	sd théorique	sd empirique		
x1	0.066	0.032	0.068	0.064
x2	0.065	0.036	0.072	0.071
x3	0.044	0.019	0.0345	0.0341

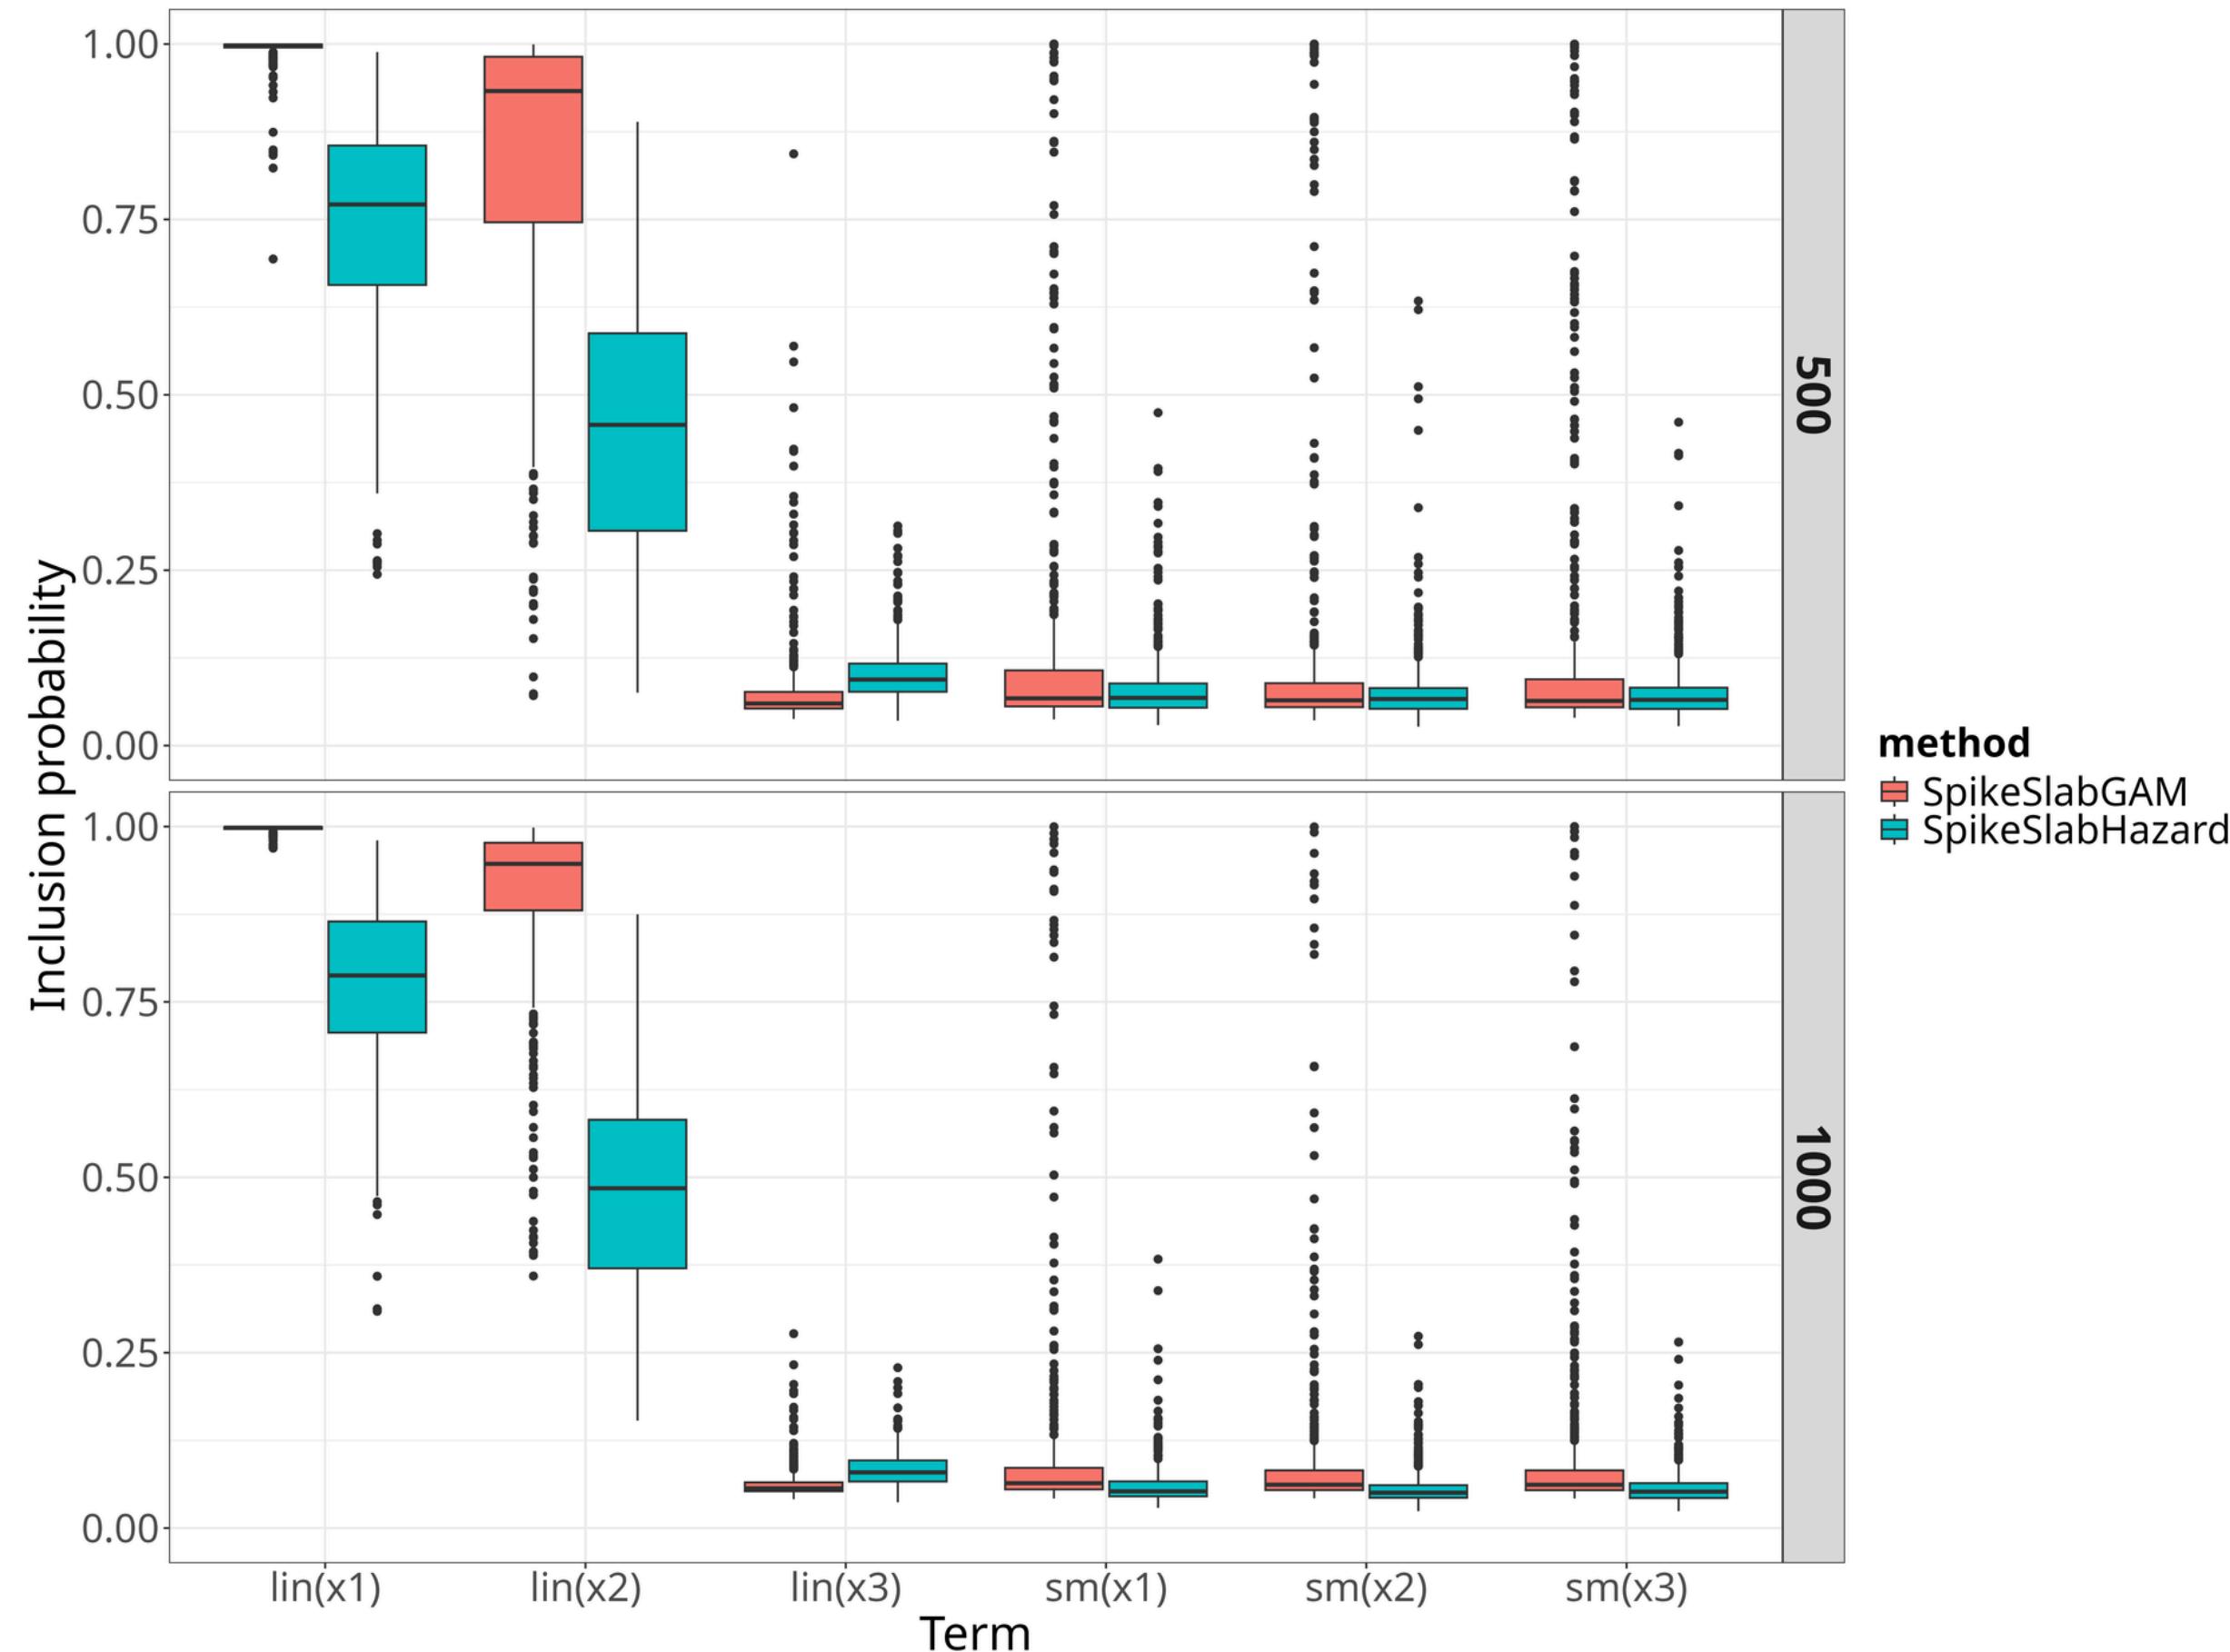


**Différence de probabilité de couverture
dû à une différence entre sd théorique et
empirique.**

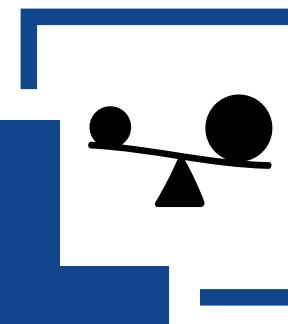
method

- SpikeSlabGAM
- SpikeSlabHazard

Résultats

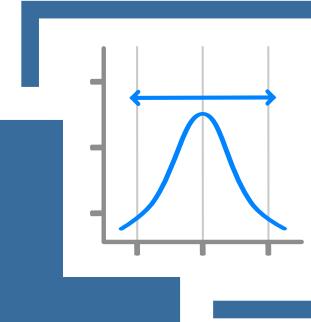


Biais, MSE



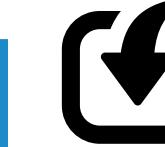
- Spike Slab Hazard : négligeable
- Spike Slab GAM : négligeable

Probabilité de couverture



- Spike Slab Hazard : correct
- Spike Slab GAM : sous-couverture

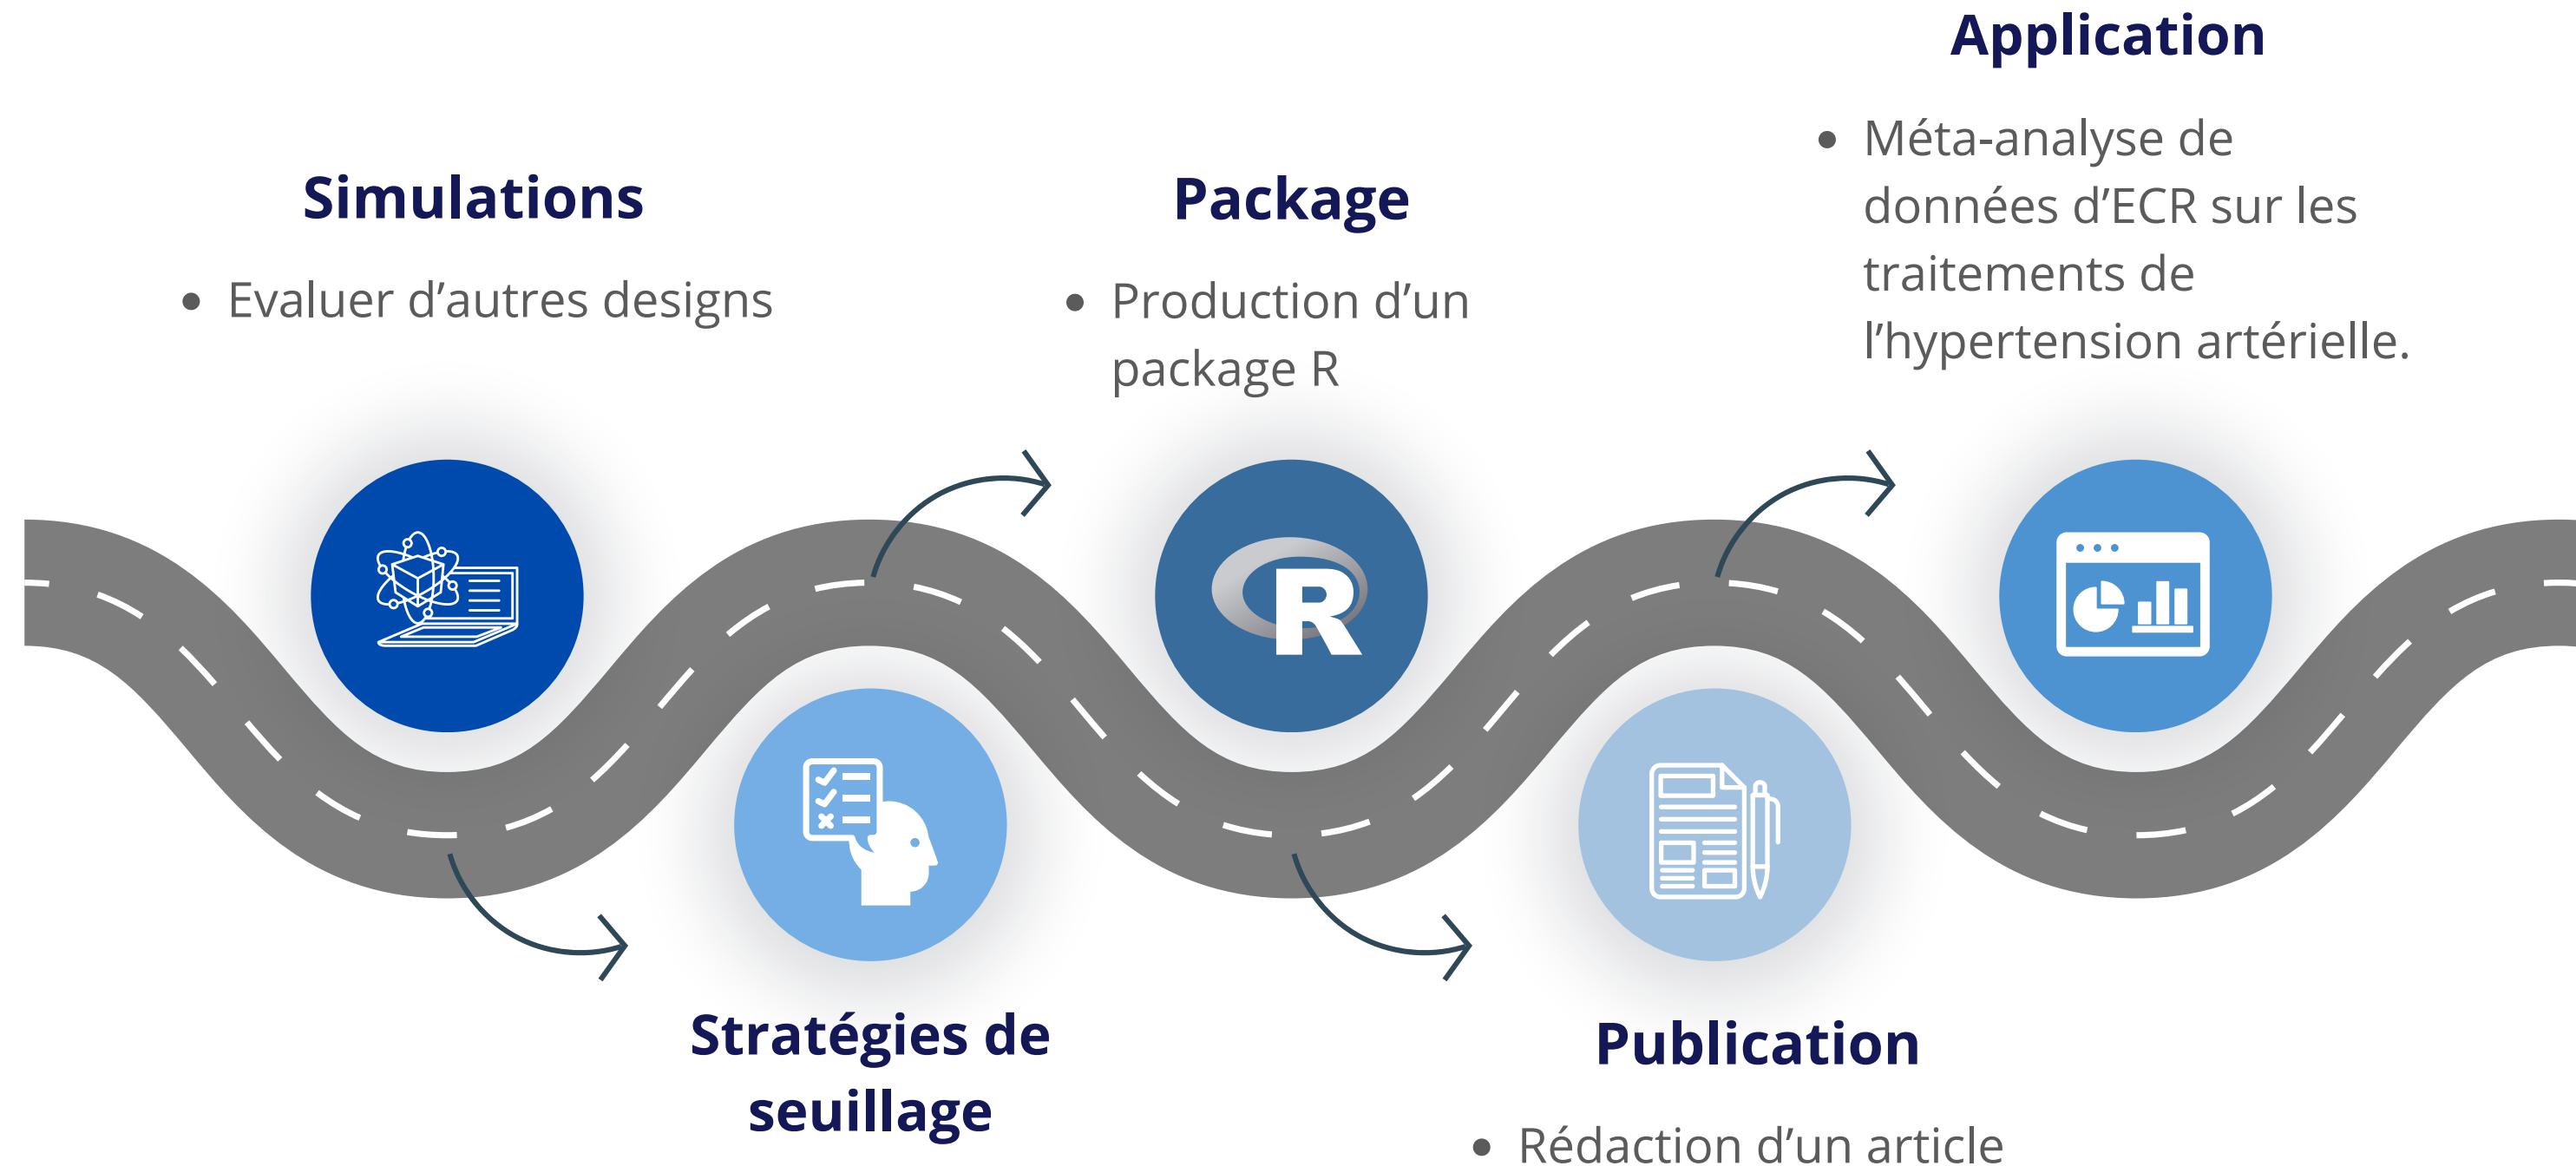
Probabilité d'inclusion



- Spike Slab Hazard : sélection moins marquée
- Spike Slab GAM : plus élevée pour les covariables actives

CONCLUSION

- SpikeSlabGAM → favorise davantage l'inclusion
- SpikeSlabHazard → plus prudent, mais inclusion moins tranchée.



Merci