

# Les cycles d'apprentissage de BioSP - Pôle M2SUD

## Automne 2021 - Cycle 1 - Introduction à la statistique

### Bayésienne

- 06/09 Rappels en probabilité (Emily)
- 20/09 Principes de la démarche bayésienne en statistique (Samuel)
- 04/10 Initiation aux modèles graphiques (Emily)
- 18/10 Distributions a priori  
Présentation des logiciels WinBUGS JAGS STAN (Emily)
- 08/11 Vérification et évaluation de modèles (Samuel)
- 22/11 Estimation des distributions a posteriori avec des méthodes numériques (Samuel)
- 29/11 Séminaire 1 d'ouverture : Estimation de la distribution spatio-temporelle de mammifères marins (Matthieu Authier)
- 06/12 Séminaire 2 d'ouverture : Approche bayésienne pour la prévision probabiliste de températures à partir de post-traitements de données d'ensemble (Eric Parent)
- 13/12 Séminaire 3 d'ouverture : Reconstruction de l'histoire évolutive de langues humaines (Robin Ryder)

# Les cycles d'apprentissage de BioSP - Pôle M2SUD

## Automne 2021 - Cycle 1 - Introduction à la statistique

### Bayésienne

- 06/09 Rappels en probabilité (Emily)
- 20/09 **Principes de la démarche bayésienne en statistique**
- 04/10 Initiation aux modèles graphiques (Emily)
- 18/10 Distributions a priori  
Présentation des logiciels WinBUGS JAGS STAN (Emily)
- 08/11 Vérification et évaluation de modèles (Samuel)
- 22/11 Estimation des distributions a posteriori avec des méthodes numériques (Samuel)
- 29/11 Séminaire 1 d'ouverture : Estimation de la distribution spatio-temporelle de mammifères marins (Matthieu Authier)
- 06/12 Séminaire 2 d'ouverture : Approche bayésienne pour la prévision probabiliste de températures à partir de post-traitements de données d'ensemble (Eric Parent)
- 13/12 Séminaire 3 d'ouverture : Reconstruction de l'histoire évolutive de langues humaines (Robin Ryder)

# Principes de la démarche bayésienne en statistique

Eric Parent

18 Mars 2019

Incluant des ajouts de Samuel Soubeyrand pour le cycle d'apprentissage « Introduction à la statistique Bayésienne » – 20 sept. 2021

Hier

## Bayésien en réaction au Fréquentiste?

L'école traditionnelle fréquentiste, la pratique classiquement enseignée en France:

- ▶ présente une *boîte à outils* de recettes probabilistes dont l'utilisateur n'est pas toujours à même de comprendre facilement le fil directeur,
- ▶ raisonne avec *une seule* loi de probabilité: la loi d'échantillonnage.
  - ▶ elle s'interprète selon une perspective de répétition asymptotique,
  - ▶ seules les quantités observables peuvent être probabilisées,
  - ▶ une rupture de pensée de la modélisation à l'inférence.
- ▶ Qu'est ce qu'un intervalle de confiance? Pourquoi 95%?
- ▶ Qu'est ce qu'une erreur de type 1 ? Conditionnelle à quel événement?

La *confiance* ne porte pas sur la valeur éventuelle de l'inconnue, mais sur la recette statistique d'inférence choisie. Comment? Pourquoi?

## Une parenthèse : l'estimation fréquentiste des paramètres

- ▶  $\theta \in \Theta$ : paramètres inconnus intervenant dans l'écriture d'un modèle, symbolisé par  $\mathcal{M}_\theta$
- ▶ Objectif : estimer les paramètres du modèle à partir de données
- ▶ En d'autres termes : évaluer sous quel  $\theta_0 \in \Theta$  ont été obtenues les données sachant que le modèle qui les a générées est contenu dans la classe de modèles  $\{\mathcal{M}_\theta : \theta \in \Theta\}$

- ▶ Cas du modèle de régression:

$$y = \mathcal{M}_\theta(x) + \epsilon$$

où  $y$ : variable réponse,  $x$ : variable explicative,  $\mathcal{M}_\theta$ : fonction déterministe de  $x$ ,  $\epsilon$ : bruit

- ▶ Objectif : estimer  $\theta$  en utilisant les données qui sont, dans le cas le plus simple, des observations répétées et indépendantes de  $(x, y)$ , c'est-à-dire un échantillon  $\{(x_i, y_i) : i = 1, \dots, l\}$

## L'estimateur des moindres carrés:

- ▶ Expression générale:

$$\hat{\theta} = \operatorname{argmin}_{\theta \in \Theta} \sum_{i=1}^I \{y_i - \mathcal{M}_{\theta}(x_i)\}^2$$

- ▶ Cas particuliers: expressions exactes disponibles  
e.g., régression linéaire:  $(y = x'\theta + \epsilon)$ ,  
 $\hat{\theta} = (X'X)^{-1}X'y$
- ▶ Cas général: minimisation via un algorithme numérique itératif (Gauss-Newton, Nelder-Mead, recuit simulé...)

## L'estimateur du maximum de vraisemblance:

- ▶ Hypothèse distributionnelle pour le bruit

E.g.,  $Y_i = \mathcal{M}_\theta(x_i) + \epsilon_i$ , les  $\epsilon_i$  sont indépendants et identiquement distribués (i.i.d.) selon la loi Normale( $0, \sigma^2$ ) où  $\sigma > 0$

( $Y_i$  est la variable aléatoire qui, à travers l'échantillonnage, prend la valeur observée  $y_i$ )

- ▶ La vraisemblance est, sous une telle hypothèse, la loi jointe des  $Y_i$  sachant les  $x_i$

Dans l'ex gaussien, loi conditionnelle de  $Y$ :

$$Y \mid X = x \sim \text{Normale}(\mathcal{M}_\theta(x), \sigma^2).$$

densité de probabilité de  $Y$  sachant  $X = x$ :

$$y \mapsto f_{Y|X}(y|x; \theta, \sigma) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left(-\frac{(y - \mathcal{M}_\theta(x))^2}{2\sigma^2}\right).$$

vraisemblance:

$$L(\theta; (y_i, x_i) : i = 1, \dots, l, \sigma) = \prod_{i=1}^l f_{Y|X}(y_i|x_i; \theta, \sigma).$$

- ▶ Il faut ensuite maximiser la vraisemblance par rapport à  $\theta$ :

$$\hat{\theta} = \operatorname{argmax}_{\theta \in \Theta} L(\theta; (y_i, x_i) : i = 1, \dots, l, \sigma)$$

- ▶ Expression analytique de  $\hat{\theta}$  pour certains modèles
- ▶ Dans le cas général, maximisation via un algorithme numérique itératif
  - ▶ Gauss-Newton, Nelder-Mead, recuit simulé
  - ▶ EM: *Expectation-Maximization*
  - ▶ MCEM: *Monte Carlo Expectation-Maximization*
  - ▶ ...

## Mesurer l'incertitude de $\hat{\theta}$

... et plus généralement décrire les propriétés de  $\hat{\theta}$

- ▶ Une estimation ponctuelle ne suffit pas
- ▶ Le  $\hat{\theta}$  est-il éloigné du  $\theta$  "vrai", noté  $\theta_0$ ?
- ▶ **Il faut** fournir des mesures de l'incertitude de  $\hat{\theta}$   
ex: variances d'estimation, intervalles de confiance, distributions...
- ▶ Les mesures d'incertitude doivent prendre généralement en compte:
  - ▶ l'aléa lié à l'échantillonnage
  - ▶ la structure probabiliste de l'aléa  $\epsilon$

## Mesurer l'incertitude de $\hat{\theta}$

- ▶ A l'aide d'un argument exact:

ex:  $y = x'\theta + \epsilon$ ,  $\epsilon \sim_{indep.} \text{Normale}(0, \sigma^2)$ ,  $\sigma^2$   
connu,  $\hat{\theta} \sim \text{Normale}(\theta_0, \sigma^2(\mathcal{X}'\mathcal{X})^{-1})$

## Mesurer l'incertitude de $\hat{\theta}$

- ▶ A l'aide d'un argument exact:

ex:  $y = x'\theta + \epsilon$ ,  $\epsilon \sim_{indep.} \text{Normale}(0, \sigma^2)$ ,  $\sigma^2$   
connu,  $\hat{\theta} \sim \text{Normale}(\theta_0, \sigma^2(\mathcal{X}'\mathcal{X})^{-1})$

- ▶ A l'aide de l'asymptotique (quand  $l \rightarrow \infty$ ):

Sous des hypothèses de régularité, l'estimateur  $\hat{\theta}$   
du minimum de contraste est consistant et  
asymptotiquement normal:

- ▶  $\hat{\theta}$  converge en probabilité vers  $\theta_0$
- ▶  $\sqrt{l}(\hat{\theta} - \theta_0)$  converge en loi vers la loi  
 $\text{Normale}(0, \mathcal{J}_{\theta_0}^{-1} \Gamma_{\theta_0} \mathcal{J}_{\theta_0}^{-1})$

## Mesurer l'incertitude de $\hat{\theta}$

- ▶ A l'aide d'un argument exact:

ex:  $y = x'\theta + \epsilon$ ,  $\epsilon \sim_{indep.} \text{Normale}(0, \sigma^2)$ ,  $\sigma^2$  connu,  $\hat{\theta} \sim \text{Normale}(\theta_0, \sigma^2(\mathcal{X}'\mathcal{X})^{-1})$

- ▶ A l'aide de l'asymptotique (quand  $I \rightarrow \infty$ ):

Sous des hypothèses de régularité, l'estimateur  $\hat{\theta}$  du minimum de contraste est consistant et asymptotiquement normal:

- ▶  $\hat{\theta}$  converge en probabilité vers  $\theta_0$
- ▶  $\sqrt{I}(\hat{\theta} - \theta_0)$  converge en loi vers la loi  $\text{Normale}(0, \mathcal{J}_{\theta_0}^{-1} \Gamma_{\theta_0} \mathcal{J}_{\theta_0}^{-1})$

- ▶ A l'aide de simulations (bootstrap (non-)paramétrique):

1. Simuler  $B$  jeux de données
  - ▶ soit sous le modèle  $\mathcal{M}_{\hat{\theta}}$
  - ▶ soit par ré-échantillonnage des données
2. Estimer  $\theta$  pour les  $B$  jeux de données
3. Utiliser les  $B$  estimations de  $\theta$  pour caractériser la loi de  $\hat{\theta}$

## Bayésien en réaction au Fréquentiste?

L'école traditionnelle fréquentiste, la pratique classiquement enseignée en France:

- ▶ présente une *boîte à outils* de recettes probabilistes dont l'utilisateur n'est pas toujours à même de comprendre facilement le fil directeur,
- ▶ raisonne avec *une seule* loi de probabilité: la loi d'échantillonnage. ->càd la loi des données
  - ▶ elle s'interprète selon une perspective de répétition asymptotique,
- ▶ seules les quantités observables peuvent être probabilisées,
- ▶ une rupture de pensée de la modélisation à l'inférence.
- ▶ Qu'est ce qu'un intervalle de confiance? Pourquoi 95%?
- ▶ Qu'est ce qu'une erreur de type 1 ? Conditionnelle à quel événement?

affirmation<-  
contestable

La *confiance* ne porte pas sur la valeur éventuelle de l'inconnue, mais sur la recette statistique d'inférence choisie. Comment? Pourquoi?

Aujourd'hui

# Le raisonnement bayésien

- ▶ repose sur la notion de probabilité *personnelle*.
- ▶ la probabilité (bayésienne) doit être interprétée comme un degré de croyance, un pari quant à la connaissance d'une quantité incertaine. Toute probabilité est conditionnelle.
- ▶ la probabilité (bayésienne) se met à jour quand on dispose d'information (l'assimilation de données permet l'apprentissage statistique)
- ▶ la cohérence du raisonnement bayésien est garantie grâce aux règles mathématiques du calcul des probabilités.
- ▶ Conditionner son raisonnement aux données et aux hypothèses aide à ne pas perdre de vue la différence entre le *petit monde* du formel et le *grand monde* du réel.

## Petite histoire de la pensée bayésienne:

- ▶ Thomas Bayes (1701-1761) et Pierre-Simon de Laplace (1749-1827)
- ▶ R.O. vs Stats théoriques 18ème->Poincaré->Alan Turing->1950
- ▶ Wald->Definetti, Savage, Jeffrey, Lindley—>1990
- ▶ 1990 -> Berger, Robert, O'Hagan, Dawid, Marin, Gelman, etc. Computational Bayes & Machine Learning

Lire: **S. Mac Grayne (2012): The theory that would not die...**

## Une mise en pratique facile

Pour construire un modèle bayésien, il faut une *loi a priori* et un *modèle d'échantillonnage*:

- ▶ L'existence mathématique de ces deux composantes a été prouvée dans des conditions de structuration a minima d'un raisonnement prédictif en présence d'incertitude (théorème dit de représentation de DeFinetti-Savage-Hewitt)
- ▶ La loi a posteriori est proportionnelle au produit vraisemblance  $\times$  prior.
- ▶ La loi a posteriori est l'objet qui récapitule toute l'inférence.
- ▶ Conceptuellement simple: l'inférence cherche à exprimer ce que l'on sait sur les inconnues du problème sachant ce qui est connu (ou assumé comme tel).

## Le raisonnement conditionnel

- ▶ Deux quantités seulement en Bayes : les non observables  $\theta$  et les observables  $Y$ .
- ▶ Les valeurs manquantes, les paramètres, les valeurs à prévoir, . . .  $\in \theta$ !
- ▶ le modèle bayésien demande  $[\theta]$  et  $[Y|\theta]$
- ▶ l'inférence bayésienne : ce que l'on sait sur les inconnues au vu des observées  $[\theta|Y]$
- ▶ mise à jour séquentielle facile !
- ▶ exemple des tirages binomiaux et normaux.
- ▶ réseaux bayésiens et DAG. (Éric)

## La machinerie bayésienne

# Inférence Bayésienne = Apprentissage à partir des données

- ▶ Qui : Vous!
- ▶ Quoi ? Notations:  $Y, y, \theta, [\bullet|\bullet]$
- ▶ Construction: Prior, vraisemblance

$$[y|\theta] \times [\theta] = [\theta, Y] = [\theta|Y] \times [Y]$$

Y

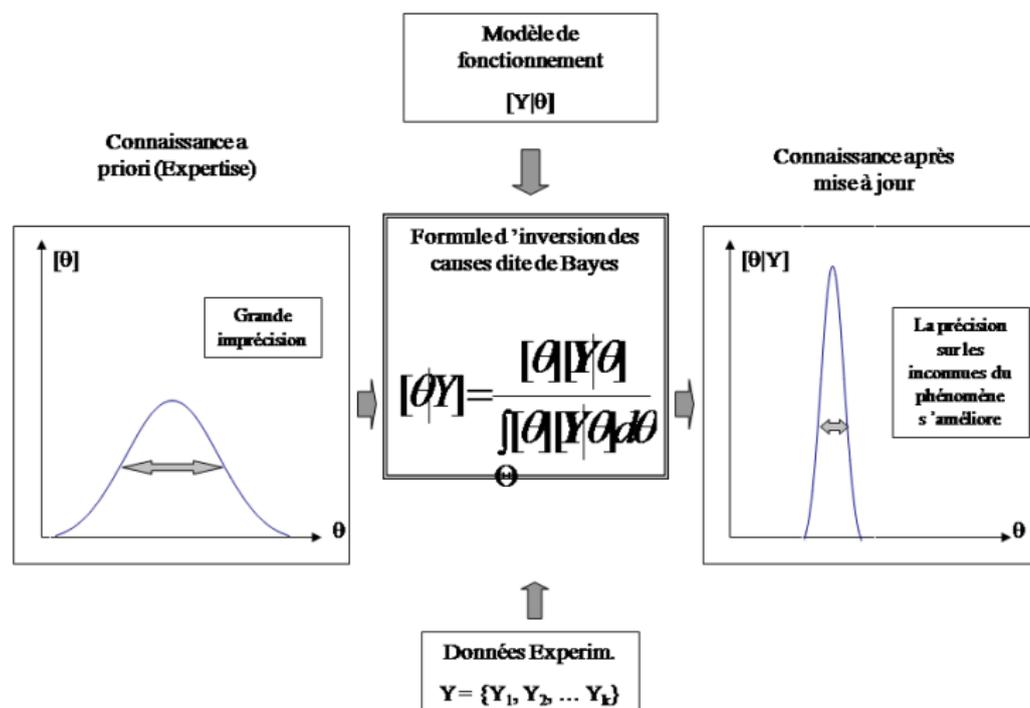
- ▶ Dédution? Posterior, prédictive

$$[\theta|Y = y] \propto [y|\theta] \times [\theta]$$

- ▶ Prédiction? Intégration sur l'inconnue

$$[Y = y] = \int_{\theta} [Y = y|\theta] \times [\theta] d\theta$$

# La machinerie bayésienne = apprentissage statistique



## Exemple (1750 < <1990): conjugaison beta-binomiale

- ▶  $Y \sim \text{dbin}(\theta, n)$  :

$$[Y | \theta] = \frac{\Gamma(n+1)}{\Gamma(y+1)\Gamma(n-y+1)} \theta^y (1-\theta)^{n-y}$$

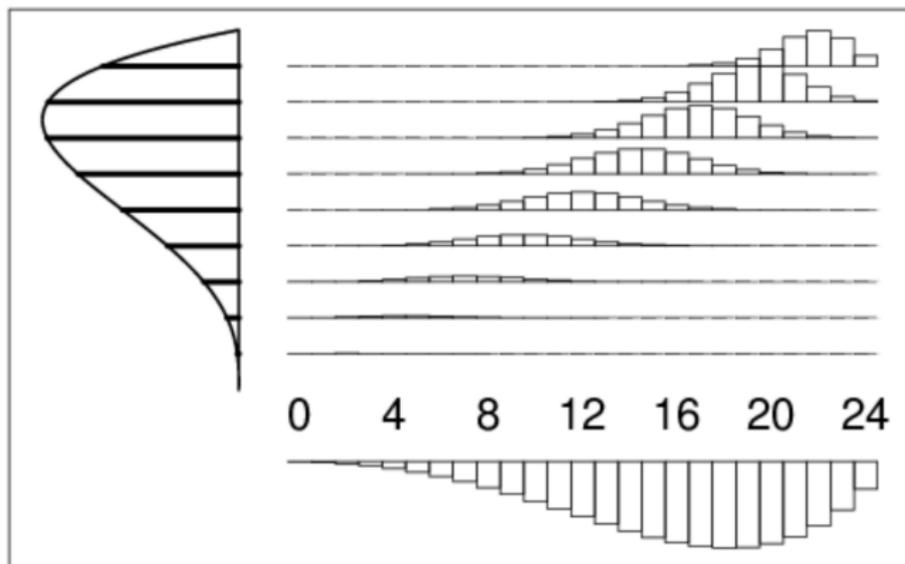
- ▶  $\theta \sim \text{dbeta}(a, b)$  :

$$[\theta] = \frac{\Gamma(a+b)}{\Gamma(a)\Gamma(b)} \theta^{a-1} (1-\theta)^{b-1}$$

- ▶  $\theta | Y \sim \text{dbeta}(a+y, b+n-y)$
- ▶ Application  $n = 24, y = 10, a = 3, b = 2$

$$\begin{aligned} [\theta|Y] &= [Y|\theta][\theta]/[Y] \\ &\propto [Y|\theta][\theta] \\ &= \frac{\Gamma(n+1)}{\Gamma(y+1)\Gamma(n-y+1)}\theta^y(1-\theta)^{n-y} \\ &\quad \times \frac{\Gamma(a+b)}{\Gamma(a)\Gamma(b)}\theta^{a-1}(1-\theta)^{b-1} \\ &\propto \theta^{a+y-1}(1-\theta)^{b+n-y-1} \end{aligned}$$

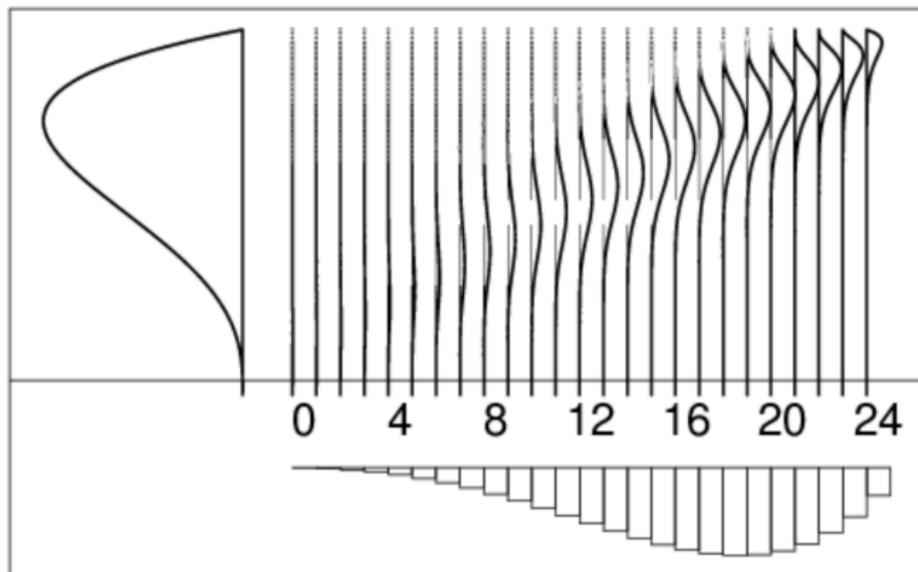
Exemple: conjugaison beta-binomiale  $[\theta, Y] = [Y|\theta] \times [\theta]$



axe vertical:  $\theta$

axe horizontal:  $Y = y$

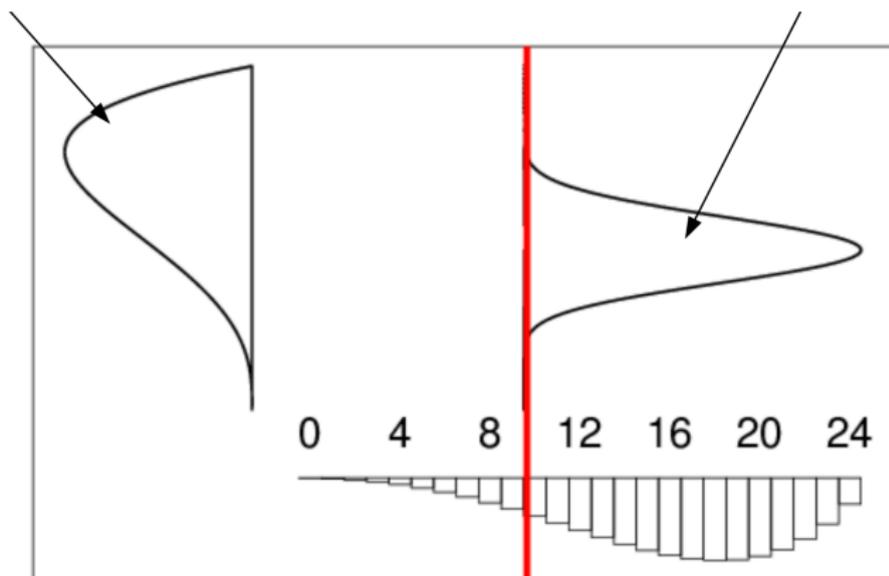
Exemple: conjugaison beta-binomiale  $[\theta, Y] = [\theta|Y] \times [Y]$



axe vertical:  $\theta$

axe horizontal:  $Y = y$

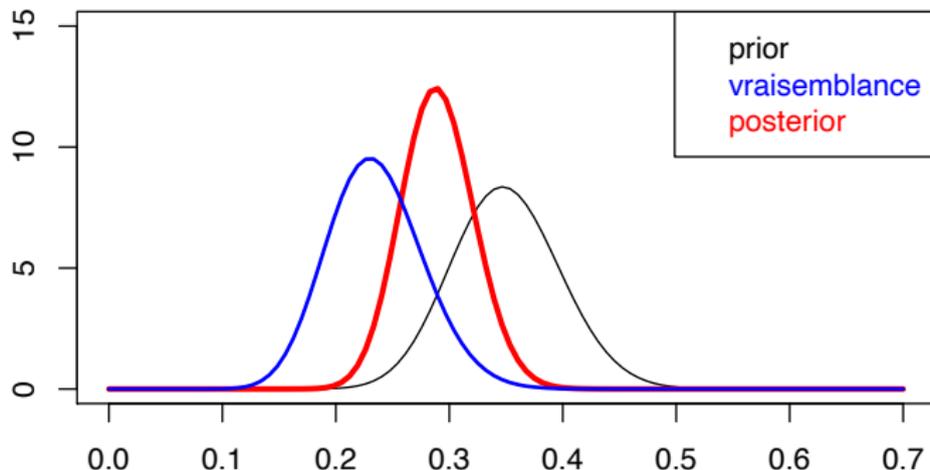
Exemple: conjugaison beta-binomiale  $[\theta|Y] \propto [\theta, Y]$



axe vertical:  $\theta$

axe horizontal:  $Y = y$

## Apprentissage = Mise à jour



- ▶ Plus d'information dans la loi *a posteriori*
- ▶ Compromis de synthèse! cf. positionnement central
- ▶ Poids relatif des sources d'information

# Le paradigme bayésien de l'apprentissage statistique

- ▶ *Le posterior d'aujourd'hui est le prior de demain*
- ▶ Natures de l'incertitude
- ▶ Cohérence probabiliste
- ▶ Théorèmes asymptotiques
- ▶ Théorie de la décision statistique
- ▶ Psychologie cognitive

## Estimateurs bayésiens et autres inférences

**Toutes** les inférences sont obtenues à partir du posterior  $[\theta|y]$   
(Sophie)

- ▶ best guess? MAP, Posterior mean  $\hat{\theta}(Y) = \int_{\theta} \theta [\theta|Y] d\theta$ ,

posterior variance, etc.

- ▶  $[a,b]$  intervalle bayésien de crédibilité à 70% (le plus court)

$$[a < \theta < b|y] = 0.7$$

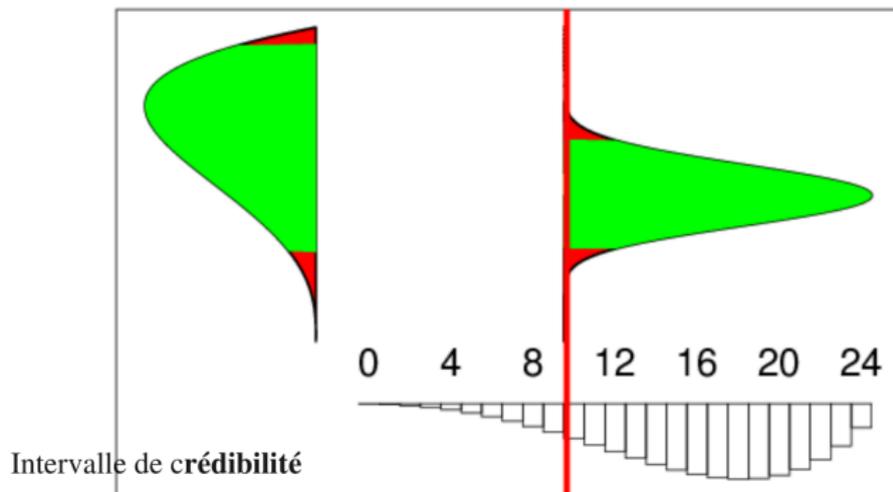
- ▶ décision sous critère d'utilité  $u(\theta, d)$

$$d^* = \text{ArgMin}_d \int_{\theta} u(\theta, d) [\theta|Y] d\theta$$

- ▶ prédictive et prévisions probabilistes

$$[Y_{new}|y] = \int_{\theta} [Y_{new}|\theta] \times [\theta|Y = y] d\theta$$

Exemple: conjugaison beta-binomiale  $[\theta|Y] \propto [\theta, Y]$



axe vertical:  $\theta$

axe horizontal:  $Y = y$

La loi a priori

## La conjugaison normal-normale

- ▶  $Y|\mu, \sigma \sim \text{dnorm}(\mu, \sigma^{-2})$  :

$$[Y|\mu, \sigma] = \frac{1}{\sigma\sqrt{2\pi}} \exp\left(-\frac{(Y-\mu)^2}{2\sigma^2}\right)$$

- ▶  $\mu|\sigma \sim \text{dnorm}(m_0, s_0^{-2})$
- ▶  $\mu|Y, \sigma \sim \text{dnorm}(m_1, s_1^{-2})$

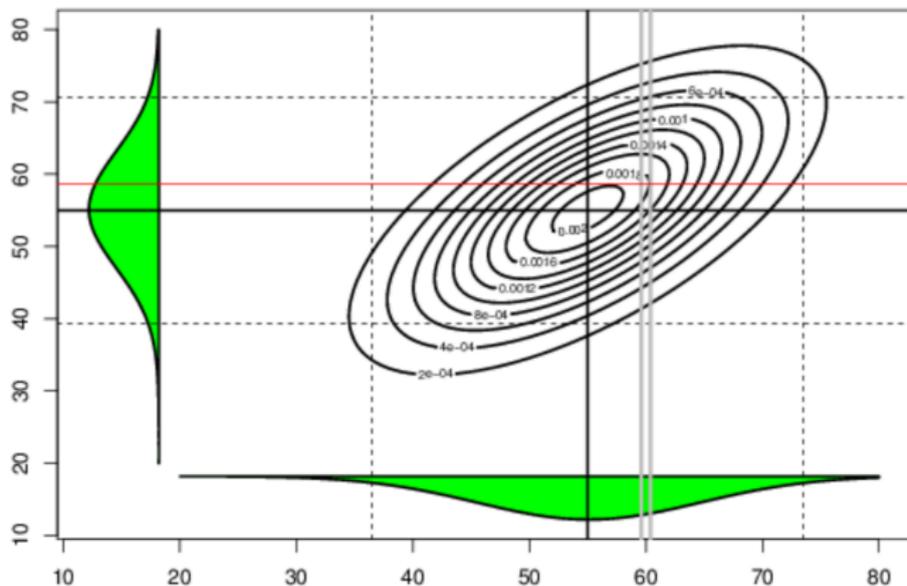
$$s_1^{-2} = s_0^{-2} + \sigma^{-2}$$

$$s_1^{-2}m_1 = s_0^{-2}m_0 + \sigma^{-2}y$$

- ▶ Application:  $\sigma = 5, m_0 = 55, s_0 = 8$

## Exemple: conjugaison normale-normale

$$[\mu, Y] = [Y|\mu] \times [\mu]$$



axe vertical:  $\mu$

axe horizontal:  $Y = y$

## Le prior, un nouvel objet pas compliqué ?

- ▶ Souvent l'homme de l'art ont une opinion préalable à l'expérience à propos des inconnues.
- ▶ Encoder cette opinion à l'aide d'une loi a priori!
- ▶ la loi a priori peut être vague, multiple pour refléter diverses opinions, informative, non informative selon divers critères
- ▶ le prior peut souvent s'interpréter grâce une taille d'échantillon équivalent de données virtuelles.
- ▶ En plus du support des observations, l'approche bayésienne demande de probabiliser (conjointement) l'espace des inconnues, . . . mais tous les résultats d'estimation fréquentistes peuvent être retrouvés comme des cas particuliers de l'inférence bayésienne.

# Distributions *a priori* informatives (Olivier)

-> Emily

Le processus d'élicitation : dialogue entre un expert et le statisticien pour encoder les jugements sous forme probabiliste.

- ▶ difficile : langage
- ▶ imprécis : quantitatif à partir de qualitatif
- ▶ robustesse : temps limité, tâche complexe

Une analyse de robustesse est nécessaire. . .

On dispose quelquefois de données historiques ou de données de phénomènes similaires

## Distributions *a priori* NON-informatives (Olivier)

-> Emily

Un refus de s'engager sur la construction d'un prior pour un tas de raisons plus ou moins bonnes, mais...

PAS DE CONSENSUS sur ce que signifie l'ignorance *a priori*

- ▶ invariance par rapport à certaines transformations
- ▶ invariance du prior par reparamétrisation
- ▶ laisser parler les données = recours à une mesure de désordre (entropie)
- ▶ ...

La loi a posteriori:  $[\theta|y] \propto [y|\theta] \times [\theta]$

## Comment obtenir la loi a posteriori? le bayésien computationnel! (Samuel)

- ▶ Avancées récentes extraordinaires des algorithmes de simulation Monte Carlo pour l'inférence!
- ▶ Outils commodes disponibles pour le praticien: BUGS & Jags, STAN, Greta, Nimble,... (Matthieu, Sophie) -> Emily
- ▶ De plus en plus de travaux bayésiens appliqués à cause de la facilité computationnelle. Les calculs théoriques d'intégration ou de transformation sont remplacés par des calculs empiriques sur échantillons générés.
- ▶ Des alternatives bayésiennes intéressantes aux fonctions standard de R: lm, glm, lmer, etc. mais aussi de nouvelles fonctionnalités originales.
- ▶ Un effet de mode, pourquoi pas?

Et après?

## Science et subjectivité

- ▶ Deux statisticiens face au même jeu de données aboutiront généralement à des conclusions différentes!
- ▶ Les questions scientifiques donnent lieu à des controverses. Travail d'une communauté avec débat et reproductibilité pour accepter une interprétation.
- ▶ En statistique bayésiennes, les opinions a priori non *peremptoires* s'inclinent et convergent devant l'accumulation des données.

## S'aventurer hors des sentiers battus... du modèle normal

- ▶ La loi normale est la pierre angulaire de la statistique fréquentiste (TCL asymptotique)
- ▶ Bayes pour l'étude de comportement avec peu de données
- ▶ Modélisation plus flexibles pour données Zéro inflatées, données "non missing at random", queues lourdes, outliers, etc. . .
- ▶ les modèles hiérarchiques: représenter les incertitudes et les quantifier. Tirer le meilleur parti de l'information disponible. (David)
- ▶ Les modèles simples sont difficiles à justifier en Bayes, mais les modèles complexes deviennent marginalement bien plus faciles à construire et à manier.

Just do it!

## Si vous coincez. . .

- ▶ Réviser les notions d'intervalle de confiance *fréquentiste* et de *test*
- ▶ Revoir les lois de la famille exponentielle : normale, gamma, binomiale, beta.
- ▶ Dessiner sous R pour le modèle beta-binomial:
  - ▶ prior, vraisemblance, posterior, prédictive pour  $n = 24, y = 10, a = 3, b = 2$
  - ▶ la collection de posteriors  $[\theta|y]$ 
    - ▶ pour  $y$  allant de 0 à  $n = 24$
    - ▶ pour  $n$  allant de 12 à 120,  $\frac{y}{n}$  maintenu à  $\frac{10}{24}$
- ▶ **Aller surfer** sur le blog de *Christian Robert*, sur celui d'*Andrew Gelman*

## Bayesians versus Frequentists

## Considérer les paramètres comme des variables aléatoires. . .

Et utiliser des priors non informatifs, tant qu'à faire. . .

- ▶ Hérésie fréquentiste: noter  $f_{\theta}(y)$  plutôt que  $f(\theta|y)$
- ▶ Comment interpréter une probabilité?
  - ▶ incertitude épistémique
  - ▶ incertitude de répétabilité expérimentale
  - ▶ incertitude de variabilité *génétique*
- ▶ En bayésien  $\theta$  est fixe et spécifique au problème
- ▶ Et si vous étiez un bayésien sans le savoir?
  - ▶ Q'avez vous compris du test d'hypothèse, type  $\theta > 0$ ?
  - ▶ la mauvaise interprétation de l'intervalle de confiance

# Paradoxe fréquentiste

- ▶ Le principe de vraisemblance
  - ▶ Si échantillon de  $n = 100$  personnes, et observation  $Y = 23$  alors  $\hat{\theta}_1 = \frac{Y}{n}$  sans *bias* (modèle binomial)
  - ▶ si observation de  $N = n$  personnes interrogées jusqu'à  $y = 23$  alors l'estimateur sans approprié au modèle négatif binomial est  $\hat{\theta}_2 = \frac{Y-1}{n-1}$

Les écoles bayésienne et fréquentiste utilisent cet exemple pour défendre chacune leur *juste* interprétation.

En fait, on observe souvent  $N$  et  $Y$  jusqu'à plus de ressources: difficile à modéliser en fréquentiste, facile en bayésien! Pour l'échantillonnage binomial à  $n = 100$  fixé, l'estimateur fréquentiste  $\hat{\theta}_3 = \frac{Y}{n}$  si  $Y$  est impair et  $\hat{\theta}_3 = \frac{Y}{n+1}$  si  $Y$  est pair, est biaisé, ... mais donne la même valeur à l'estimation que l'estimateur, non biaisé,  $\hat{\theta}_1$ !

## Annexe: Loi binomiale négative

- ▶ tirages avec succès de proba  $\theta$ .
- ▶ Combien de tirages  $N$  jusqu'à obtention de  $y$  succès? ( $y$  fixé)?
- ▶ Appelons  $X$  le nombre d'échecs;  $N = X + y$ .

$$[X = k] = \binom{k + y - 1}{y - 1} \theta^y (1 - \theta)^k$$

- ▶ Il faut tirer obtenir  $y - 1$  parmi  $N - 1$  et terminer par un succès

$$[X = k] = \left( \binom{N - 1}{y - 1} \theta^{y-1} (1 - \theta)^{N - y - (y - 1)} \right) \times \theta$$

- ▶  $\hat{\theta} = \frac{y-1}{N-1}$  est sans biais pour la binomiale négative