

A Multinomial–Dirichlet Mixture Approach to Rethinking Conditional Dependence Modelling in Latent Class Models

Thibaut Lurier; Pierre Latouche, Pierre Druilhet, Myriam Garrido

UMR EpiA, VetAgro Sup; LMBP, CNRS, UCA



Evaluation de méthodes diagnostiques

- Considérons une maladie M et un test diagnostique T
- On cherche à estimer la Sensibilité (Se) et la spécificité (Sp) du test :

$$Se = P(T^+ | M^+) \quad Sp = P(T^- | M^-)$$

- Par rapport à un Gold Standard de Se et Sp = 100%

$$\hat{Se} = \frac{n_{T^+}}{n_{M^+}} \quad \hat{Sp} = \frac{n_{T^-}}{n_{M^-}}$$

Gold Standard?

- Généralement :
 - le Gold Standard **n'existe pas!**
 - Il est trop cher ou trop invasif
- Autres possibilités :
 - Utiliser un **test de référence de Se et Sp connues**
⇒ Assez rare en médecine vétérinaire
 - Utiliser un **Gold standard imparfait** en tant que Gold standard
⇒ Estimations biaisées
 - Utiliser des **patients de statuts connus** et souvent caricaturaux
⇒ Estimations biaisées (surestimation des Se et Sp)

Modèle à classe latente (*Hui and Walter, 1980*)

- Estimation des caractéristiques de **plusieurs tests binaires** :
 - Considérons 2 tests appliqués à une population dont la prévalence de la maladie est P

	Test 2 positif	Test 2 négatif
Test 1 positif	$p_{11} = Se_1 \times Se_2 \times P + (1 - Sp_1) \times (1 - Sp_2) \times (1 - P)$	$p_{10} = Se_1 \times (1 - Se_2) \times P + (1 - Sp_1) \times Sp_2 \times (1 - P)$
Test 1 négatif	$p_{01} = (1 - Se_1) \times Se_2 \times P + Sp_1 \times (1 - Sp_2) \times (1 - P)$	$p_{00} = (1 - Se_1) \times (1 - Se_2) \times P + Sp_1 \times Sp_2 \times (1 - P)$

- 3 degrés de liberté pour 5 paramètres à estimer ($P, Se_1, Sp_1, Se_2, Sp_2$)
- En revanche, si on se place dans deux populations de prévalences différentes
⇒ **6 DL pour 6 paramètres** à estimer ($P_1, P_2, Se_1, Sp_1, Se_2, Sp_2$)
- Variantes possibles avec 3 tests et une population (8DL pour 7 paramètres)...

Modèle général

- Si on considère 2 tests appliqués à S populations de tailles respectives N_s et de prévalences P_s alors :

$$n_s \sim \text{multinomiale}(N_s, p_{s11}, p_{s10}, p_{s01}, p_{s00})$$

$$p_{s11} = \pi_s \times Se_1 \times Se_2 + (1 - \pi_s) \times (1 - Sp_1) \times (1 - Sp_2)$$

$$p_{s10} = \pi_s \times Se_1 \times (1 - Se_2) + (1 - \pi_s) \times (1 - Sp_1) \times Sp_2$$

$$p_{s01} = \pi_s \times (1 - Se_1) \times Se_2 + (1 - \pi_s) \times Sp_1 \times (1 - Sp_2)$$

$$p_{s00} = \pi_s \times (1 - Se_1) \times (1 - Se_2) + (1 - \pi_s) \times Sp_1 \times Sp_2$$

- Inférence possible par maximum de vraisemblance ou par inférence bayésienne mais deux solutions sans priors informatifs
- Convergence du modèle vers un statut latent \Leftrightarrow consensus entre les deux tests

Hypothèses du modèle

- **Se et Sp constantes** dans chacune des sous populations
 - Les Se et Sp identiques dans les populations à prévalences différentes?
- **Indépendance conditionnelle** au statut vis-à-vis de la maladie
$$P(T_2^+ | T_1^+, M^+) = P(T_2^+ | M^+)$$
 - On considère que l'hypothèse est vérifiée quand les tests reposent sur des principes biologiques différents (PCR qualitative et bactériologie)
 - Possibilité de prendre en compte la dépendance conditionnelle mais alors avec plus de paramètres... (*Hadgu and Qu, 1998; Dendukuri and Joseph, 2001*)
- Le **statut latent est biologiquement similaire** pour les deux tests
 - Immunité pour des sérologies// présence du pathogène pour bactériologie et PCR
 - Possibilité de modéliser plus de 2 statuts latents (*Dendukuri et al. 2009*)

Données d'application

- Données issues du projet KitEval4500
 - Sous-échantillon d'une enquête épidémiologique (*Gache et al. 2017*)
1500x3 sérums bovins, ovins et caprins issus d'environ **150x3 élevages** dans **10** départements français
- Sérums analysés par le LNR fièvre Q avec les 3 tests sérologiques commercialisés en France
- Performances diagnostiques?
 - Pas estimées pour tous les tests dans toutes les espèces
⇒Globalement, en fonction des espèces et des études :
 - Se variant entre 70 et 100%
 - Sp variant entre 90 et 100%
- Des **biais méthodologiques** potentiellement importants
- Aucun d'entre eux ne peut être considéré comme **un Gold standard** à Se et Sp = 100%

Dépendance conditionnelle au statut vis-à-vis de la maladie

- Est-ce que les tests ont tendance à **se tromper en même temps** chez les vrais séropositifs et séronégatifs ?
- Chez les **vrais « séropositifs » : oui ? (probablement)**
 - Si le taux d'anticorps est bas, les DO seront probablement basses pour les trois tests
 - Si souches « particulières » : anticorps spécifiques détectés par certains tests (ex : deux réactifs donnant des résultats concordants et l'autre non)
- Chez les **vrais « séronégatifs » : non ? (moins évident)**
 - Seulement si réaction croisée commune entre les trois tests avec un autre agent infectieux
 - Sinon plutôt erreurs indépendantes d'un test à l'autre

Prise en compte de la dépendance conditionnelle

- Ajout de **termes correcteurs** sur les probabilités

	Réactif 2 positif	Réactif 2 négatif
Réactif 1 positif	$p_{11} = (Se_1 \times Se_2 + \gamma_{Se}) \times P + ((1 - Sp_1) \times (1 - Sp_2) + \gamma_{Sp}) \times (1 - P)$	$p_{10} = (Se_1 \times (1 - Se_2) - \gamma_{Se}) \times P + ((1 - Sp_1) \times Sp_2 - \gamma_{Sp}) \times (1 - P)$
Réactif 1 négatif	$p_{01} = ((1 - Se_1) \times Se_2 - \gamma_{Se}) \times P + (Sp_1 \times (1 - Sp_2) - \gamma_{Sp}) \times (1 - P)$	$p_{00} = ((1 - Se_1) \times (1 - Se_2) + \gamma_{Se}) \times P + (Sp_1 \times Sp_2 + \gamma_{Sp}) \times (1 - P)$

- **Plus de paramètres** donc le modèle est **moins facilement identifiable**
- Potentiellement **non identifiable** en fonction du niveau de dépendance et du **statut latent mesuré**

Dépendance conditionnelle et statut latent

- Face à deux tests très concordants réalisés sur des individus de statuts inconnu
 - Les deux tests identifient très bien les individus vrai positifs et vrai négatifs → Se et Sp élevées, dépendance conditionnelle faible
 - Les deux tests se trompent en même temps → Se et Sp faibles, dépendance conditionnelle élevée
- ⇒ « Statut latent » ajusté = consensus entre les deux tests donc plutôt Se et Sp élevées

Dépendance conditionnelle et statut latent

- Face à deux tests très concordants réalisés sur des individus de statuts inconnus
 - Les deux tests identifient très bien les individus vrai positifs et vrai négatifs
→ Se et Sp élevées, dépendance conditionnelle faible
 - Les deux tests se trompent en même temps → Se et Sp faibles, dépendance conditionnelle élevée
⇒ « Statut latent » ajusté = consensus entre les deux tests donc plutôt Se et Sp élevées
- Et si on ajoute un troisième test indépendant?
 - Identification de la dépendance conditionnelle entre les deux premiers tests?
⇒ Changement de statut latent vers le test 3 et Se et Sp des tests 1 et 2 plus faible
⇒ Pas de changement du statut latent et potentiels biais des Se et Sp du test 3

Contraintes sur les paramètres de dépendance conditionnelle

	Réactif 2 positif	Réactif 2 négatif
Réactif 1 positif	$p_{11} = (Se_1 \times Se_2 + \gamma_{Se}) \times P + ((1 - Sp_1) \times (1 - Sp_2) + \gamma_{Sp}) \times (1 - P)$	$p_{10} = (Se_1 \times (1 - Se_2) - \gamma_{Se}) \times P + ((1 - Sp_1) \times Sp_2 - \gamma_{Sp}) \times (1 - P)$
Réactif 1 négatif	$p_{01} = ((1 - Se_1) \times Se_2 - \gamma_{Se}) \times P + (Sp_1 \times (1 - Sp_2) - \gamma_{Sp}) \times (1 - P)$	$p_{00} = ((1 - Se_1) \times (1 - Se_2) + \gamma_{Se}) \times P + (Sp_1 \times Sp_2 + \gamma_{Sp}) \times (1 - P)$

$$p_{11} \in [0;1]$$

$$(Se_1 \times Se_2 + \gamma_{Se}) \in [0;1]$$

$$((1 - Se_1) \times (1 - Se_2) + \gamma_{Se}) \in [0;1]$$

...

$$\gamma_{Se} \in [-Se_1 \times Se_2 + \max(0, Se_1 + Se_2 - 1); \min(Se_1, Se_2) - Se_1 \times Se_2]$$

$$\gamma_{Sp} \in [-Sp_1 \times Sp_2 + \max(0, Sp_1 + Sp_2 - 1), \min(Sp_1, Sp_2) - Sp_1 \times Sp_2]$$

Pour 3 tests (Wang et al. 2017)!

Catégorie	Probabilité
$T_1^-T_2^-T_3^-$	$P \times ((1 - Se_1) \times (1 - Se_2) \times (1 - Se_3) + \gamma_{Se000}) + (1 - P) \times (Sp_1 \times Sp_2 \times Sp_3 + \gamma_{Sp000})$
$T_1^-T_2^+T_3^-$	$P \times ((1 - Se_1) \times Se_2 \times (1 - Se_3) + \gamma_{Se010}) + (1 - P) \times (Sp_1 \times (1 - Sp_2) \times Sp_3 + \gamma_{Sp010})$
$T_1^-T_2^-T_3^+$	$P \times ((1 - Se_1) \times (1 - Se_2) \times Se_3 + \gamma_{Se001}) + (1 - P) \times (Sp_1 \times Sp_2 \times (1 - Sp_3) + \gamma_{Sp001})$
$T_1^-T_2^+T_3^+$	$P \times ((1 - Se_1) \times Se_2 \times Se_3 + \gamma_{Se011}) + (1 - P) \times (Sp_1 \times (1 - Sp_2) \times (1 - Sp_3) + \gamma_{Sp011})$
$T_1^+T_2^-T_3^-$	$P \times (Se_1 \times (1 - Se_2) \times (1 - Se_3) + \gamma_{Se100}) + (1 - P) \times ((1 - Sp_1) \times Sp_2 \times Sp_3 + \gamma_{Sp100})$
$T_1^+T_2^+T_3^-$	$P \times (Se_1 \times Se_2 \times (1 - Se_3) + \gamma_{Se110}) + (1 - P) \times ((1 - Sp_1) \times (1 - Sp_2) \times Sp_3 + \gamma_{Sp110})$
$T_1^+T_2^-T_3^+$	$P \times (Se_1 \times (1 - Se_2) \times Se_3 + \gamma_{Se101}) + (1 - P) \times ((1 - Sp_1) \times Sp_2 \times (1 - Sp_3) + \gamma_{Sp101})$
$T_1^+T_2^+T_3^+$	$P \times (Se_1 \times Se_2 \times Se_3 + \gamma_{Se111}) + (1 - P) \times ((1 - Sp_1) \times (1 - Sp_2) \times (1 - Sp_3) + \gamma_{Sp111})$

- 8 catégories de résultats croisées des trois tests

⇒ 7 DL

- Minimum 7 paramètres (P, Se, Sp)
- Dépendance conditionnelle

- En théorie 8 + 8 mais :

$$\gamma_{Se100} = \gamma_{Se011} + \gamma_{Se111} - \gamma_{Se000}$$

$$\gamma_{Sp100} = \gamma_{Sp011} + \gamma_{Sp111} - \gamma_{Sp000}$$

$$\gamma_{Se101} = -(\gamma_{Se001} + \gamma_{Se011} + \gamma_{Se111})$$

$$\gamma_{Sp101} = -(\gamma_{Sp001} + \gamma_{Sp011} + \gamma_{Sp111})$$

$$\gamma_{Se110} = \gamma_{Se000} + \gamma_{Se001} - \gamma_{Se111}$$

$$\gamma_{Sp110} = \gamma_{Sp000} + \gamma_{Sp001} - \gamma_{Sp111}$$

$$\gamma_{Se010} = -(\gamma_{Se000} + \gamma_{Se001} + \gamma_{Se011})$$

$$\gamma_{Sp010} = -(\gamma_{Sp000} + \gamma_{Sp001} + \gamma_{Sp011})$$

- Donc 8 paramètres supplémentaires

Back to data : 3 tests (Wang et al. 2017)!

$$\begin{aligned} & -Se_1 \times Se_2 \times Se_3 < \gamma_{Se111} < \min(Se_1, \min(Se_2, Se_3)) - Se_1 \times Se_2 \times Se_3 \\ & -(1 - Se_1) \times Se_2 \times Se_3 < \gamma_{Se011} < \min((1 - Se_1), \min(Se_2, Se_3)) - (1 - Se_1) \times Se_2 \times Se_3 \\ & -(1 - Se_1) \times (1 - Se_2) \times Se_3 < \gamma_{Se001} < \min((1 - Se_1), \min((1 - Se_2), Se_3)) - (1 - Se_1) \times (1 - Se_2) \times Se_3 \\ & -(1 - Se_1) \times (1 - Se_2) \times (1 - Se_3) < \gamma_{Se000} < \min((1 - Se_1), \min((1 - Se_2), (1 - Se_3))) - (1 - Se_1) \times (1 - Se_2) \times (1 - Se_3) \\ & -Se_1 \times (1 - Se_2) \times (1 - Se_3) < \gamma_{Se100} < \min(Se_1, \min((1 - Se_2), (1 - Se_3))) - Se_1 \times (1 - Se_2) \times (1 - Se_3) \\ & -Se_1 \times (1 - Se_2) \times Se_3 < \gamma_{Se101} < \min(Se_1, \min((1 - Se_2), Se_3)) - Se_1 \times (1 - Se_2) \times Se_3 \\ & -Se_1 \times Se_2 \times (1 - Se_3) < \gamma_{Se110} < \min(Se_1, \min(Se_2, (1 - Se_3))) - Se_1 \times Se_2 \times (1 - Se_3) \\ & -(1 - Se_1) \times Se_2 \times (1 - Se_3) < \gamma_{Se010} < \min((1 - Se_1), \min(Se_2, (1 - Se_3))) - (1 - Se_1) \times Se_2 \times (1 - Se_3) \end{aligned}$$

Back to data : Kiteval4500

- 1500x3 sérum bovins, ovins et caprins issus d'environ 150x3 élevages dans 10 départements français = **10 population?**

Nombre de positifs/négatifs aux seuils constructeurs dans chaque département

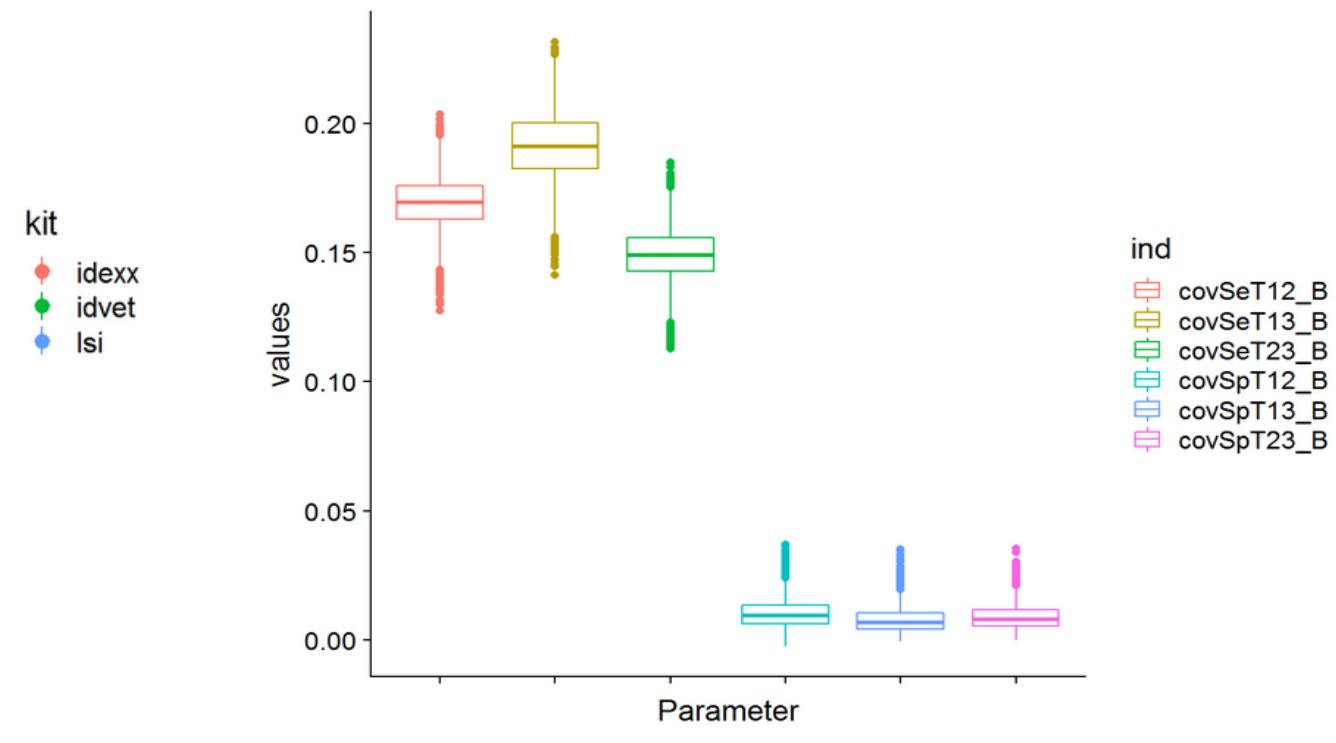
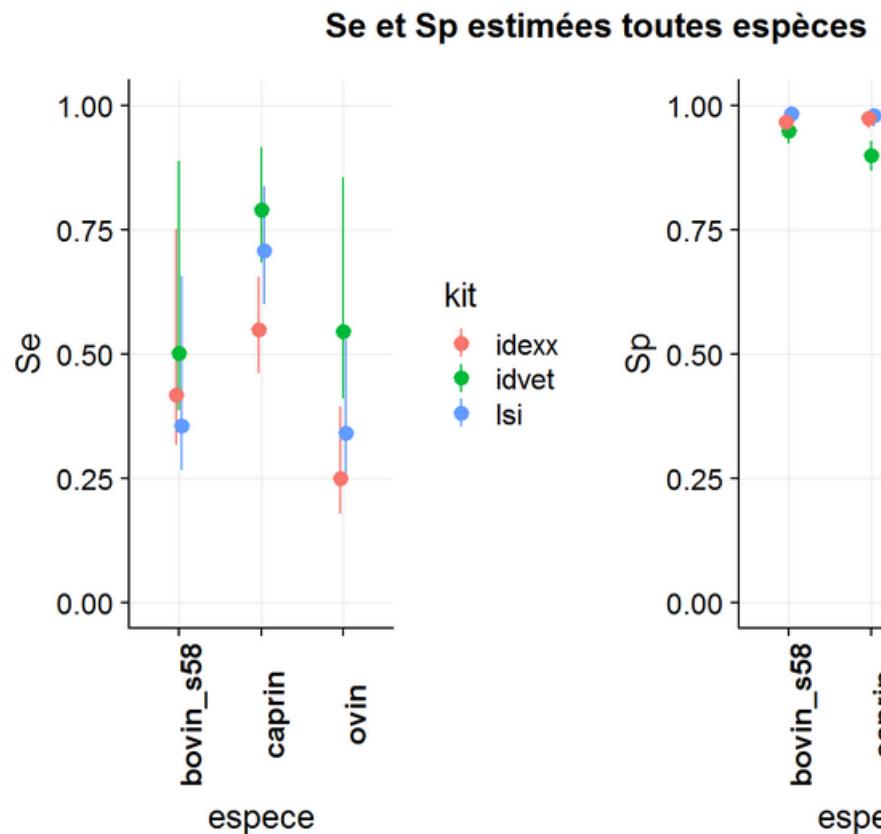
dpt	$T_1^-T_2^-T_3^-$	$T_1^-T_2^-T_3^+$	$T_1^-T_2^+T_3^-$	$T_1^-T_2^+T_3^+$	$T_1^+T_2^-T_3^-$	$T_1^+T_2^-T_3^+$	$T_1^+T_2^+T_3^-$	$T_1^+T_2^+T_3^+$	Total
A	91	27	0	10	2	0	0	35	165
B	94	28	5	11	0	0	2	22	162
C	145	3	0	0	1	0	0	0	149
D	124	2	8	4	0	0	0	7	145
E	142	10	0	0	0	0	0	3	155
F	154	1	1	0	1	0	0	0	157
G	161	0	0	0	0	0	0	0	161
H	91	25	3	4	3	2	0	18	146
I	124	15	9	3	2	1	0	2	156
J	24	2	1	0	0	0	0	9	36

3 départements avec très peu de séropositifs
 ⇒ Les trois tests semblent spécifiques

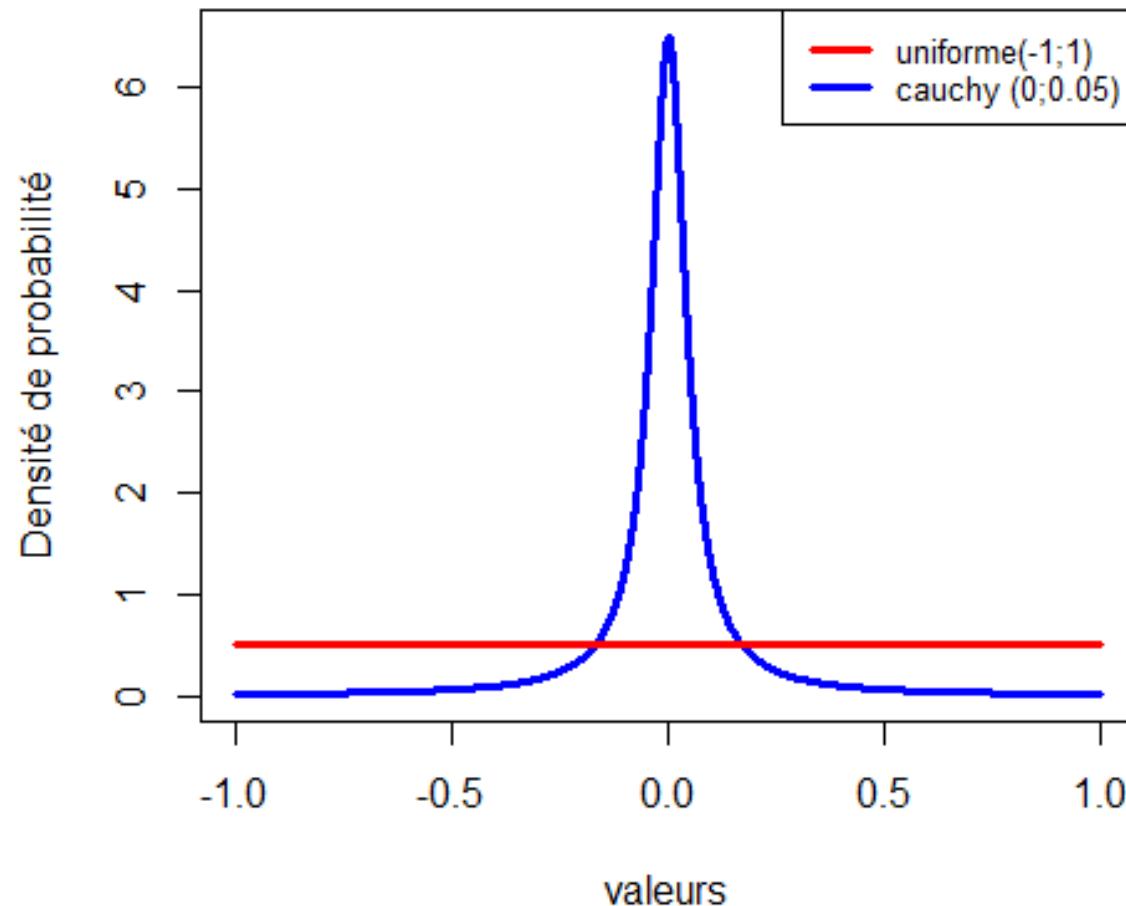
La plupart des positifs sont positifs avec le test 3 ou avec les trois tests
 ⇒ Le test 3 semble plus sensible que les deux autres

Première inférence sous JAGS

- Priors
 - Loi beta (0.5,0.5) sur les Se, Sp et P
 - Loi uniforme [-0.5;0.5] pour les dépendances conditionnelles

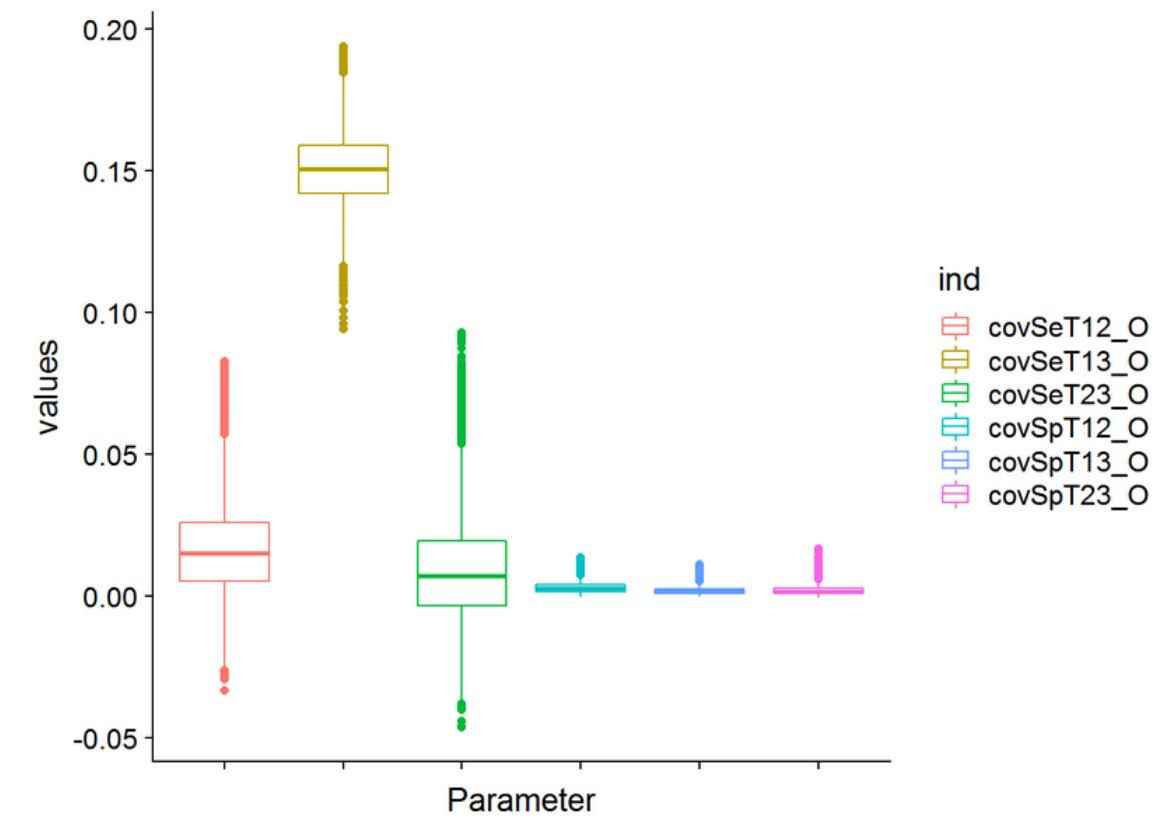
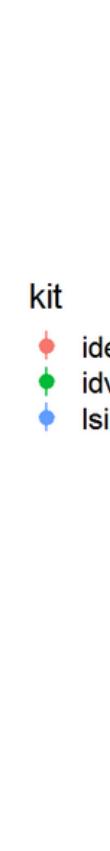
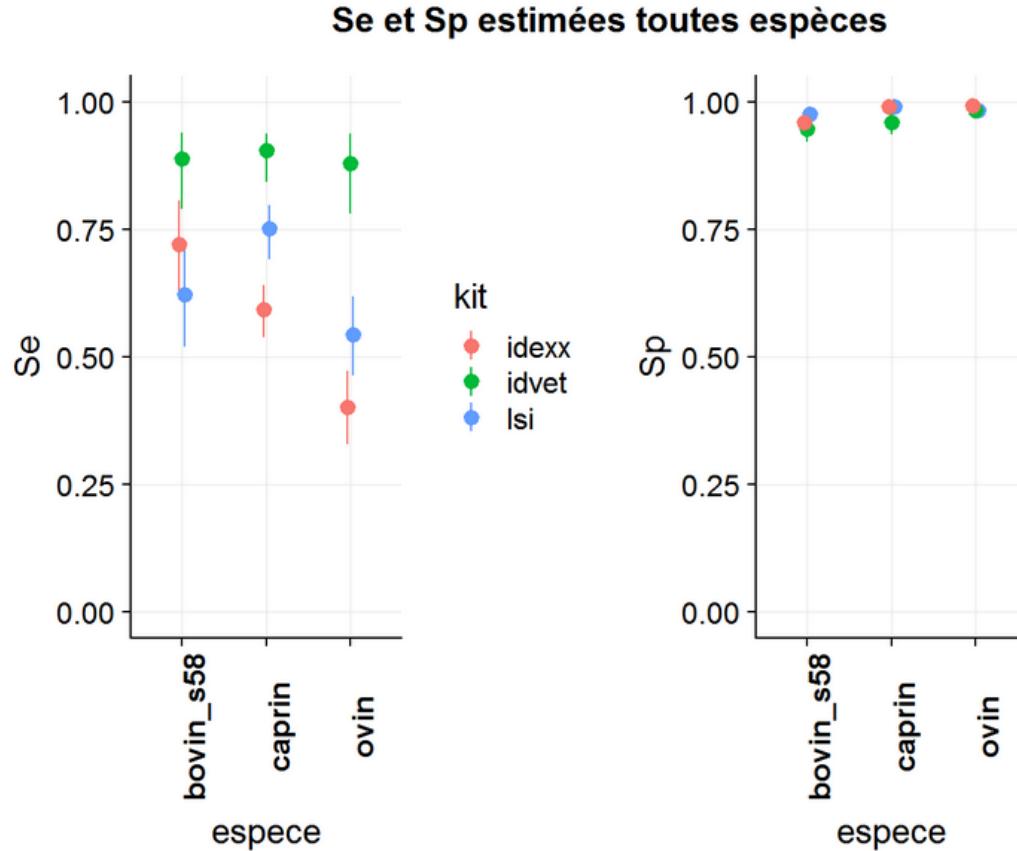


Priors **cauchy** vs loi uniforme???



Deuxième inférence sous JAGS

- Priors
 - Loi cauchy (0, 0.039) pour les dépendances conditionnelles



Back to data

- 1500x3 sérumms bovins, ovins et caprins issus d'environ 150x3 élevages
= **150 population?** dans 10 départements français
 - 150 prévalences par modèle à estimer?
 - Modélisation de distribution des prévalences dans chaque élevage (WHP)
 - Avec possibilité que certains élevages soit indemne
- ⇒Modélisation de la proportion d'élevage non indemne dans chaque élevage (BHP)

Modèle à classes latentes

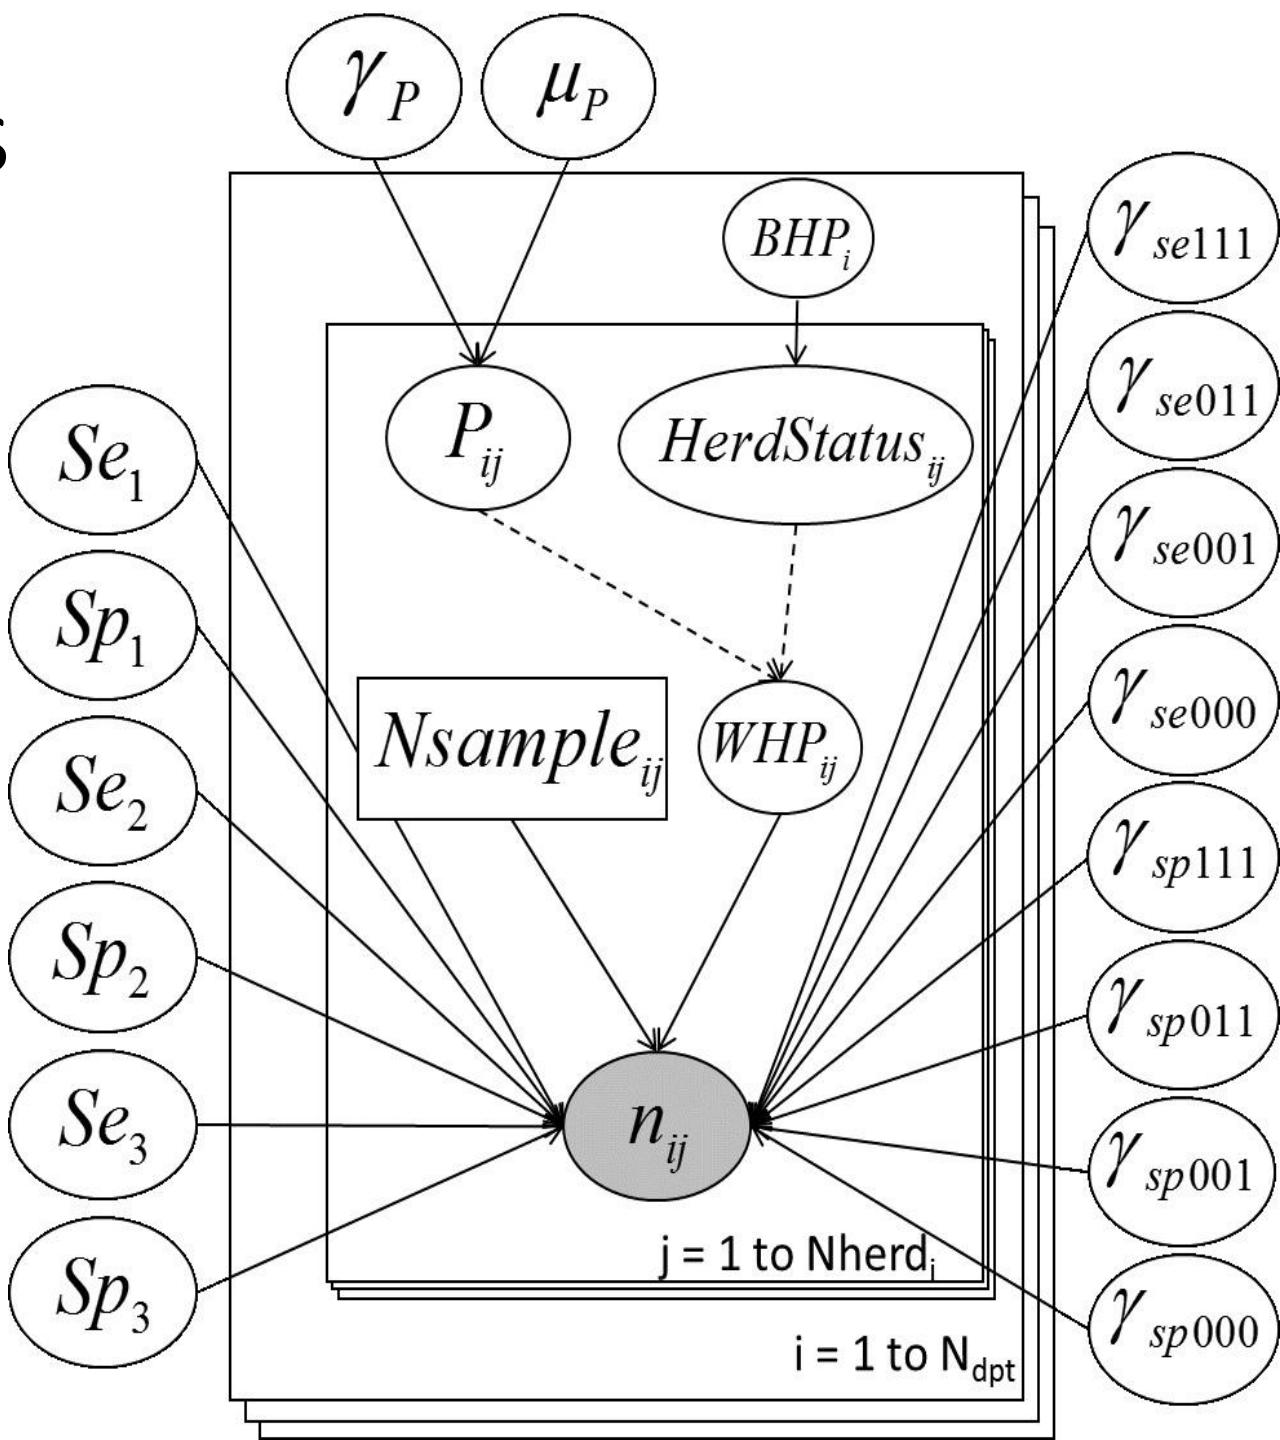
- Une population par élevage
- Modélisation de la prévalence inter-élevage par département
 - Avec possibilité que certains élevages soient indemnes
- Modélisation de la distribution des prévalences intra-élevages dans les élevages séropositifs

Modèle beta-binomiale hiérarchique sur les prévalence

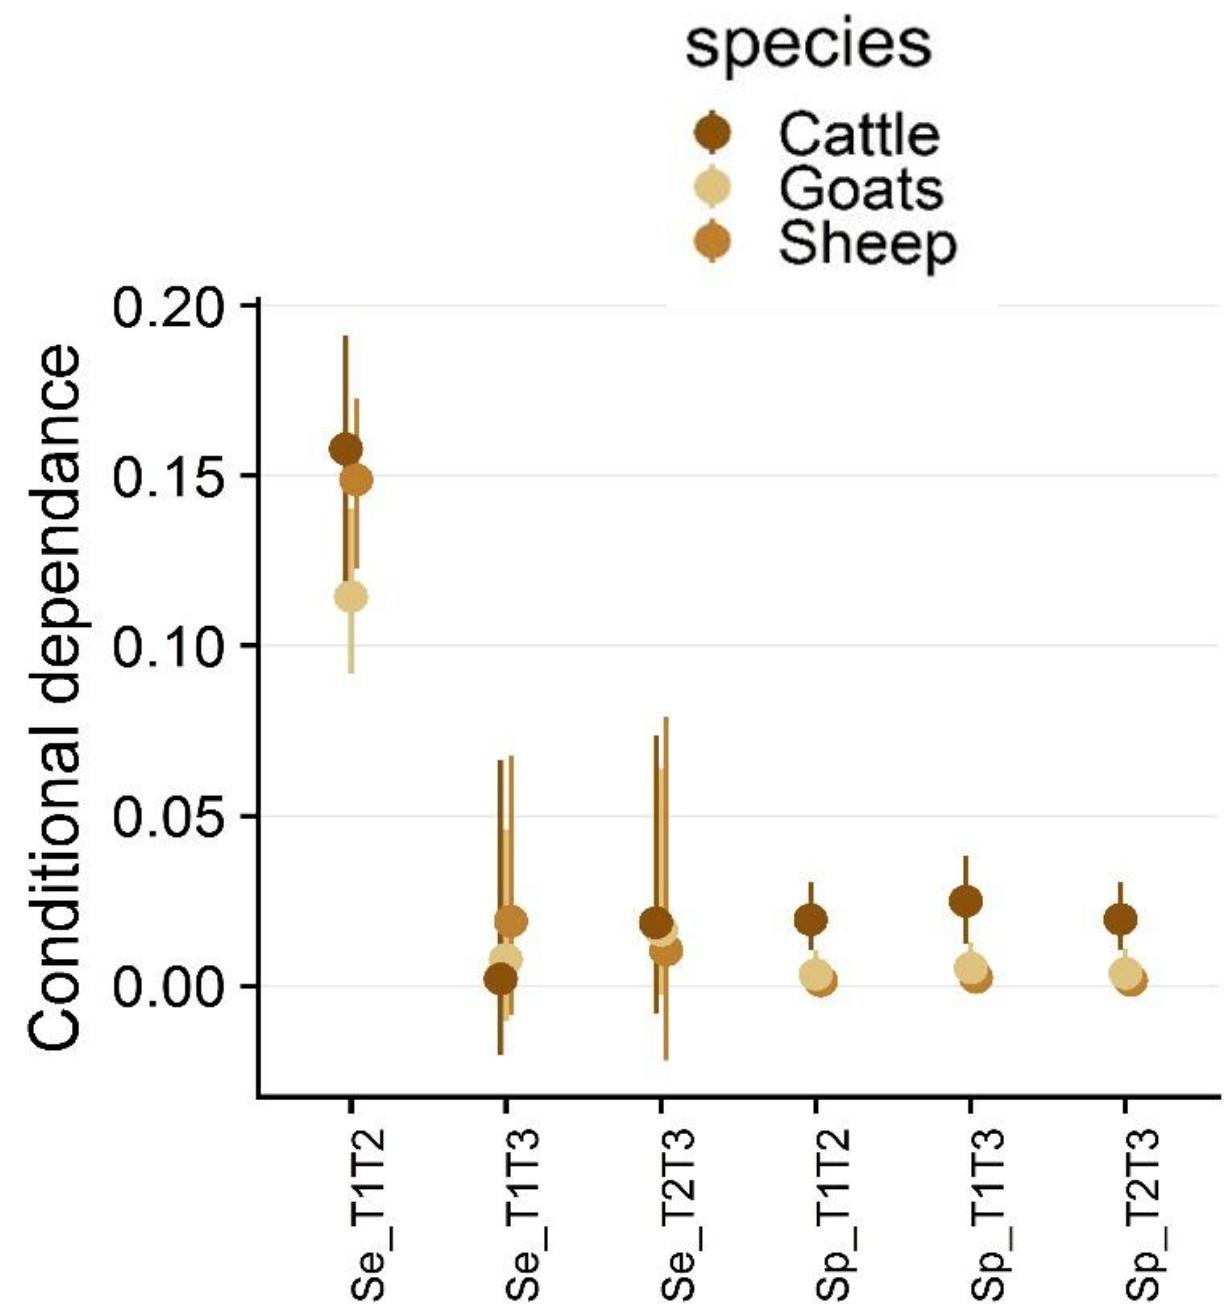
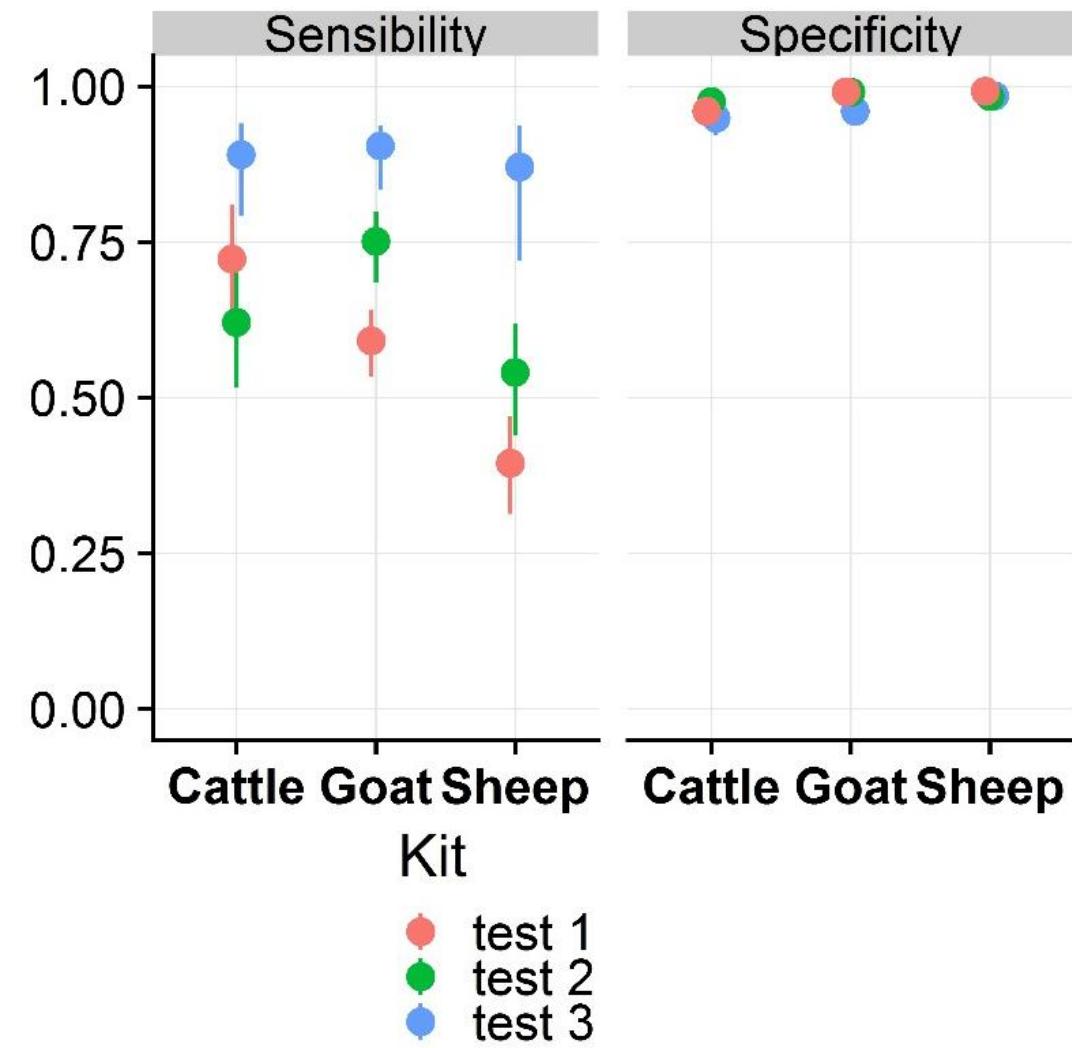
$$HerdStatus_{ij} \sim Bern(BHP_i)$$

$$P_{ij} \sim beta\left(\mu_P \times \frac{(1-\gamma_P)}{\gamma_P}, (1-\mu_P) \times \frac{(1-\gamma_P)}{\gamma_P}\right)$$

$$WHP_{ij} = HerdStatus_{ij} \times P_{ij}$$

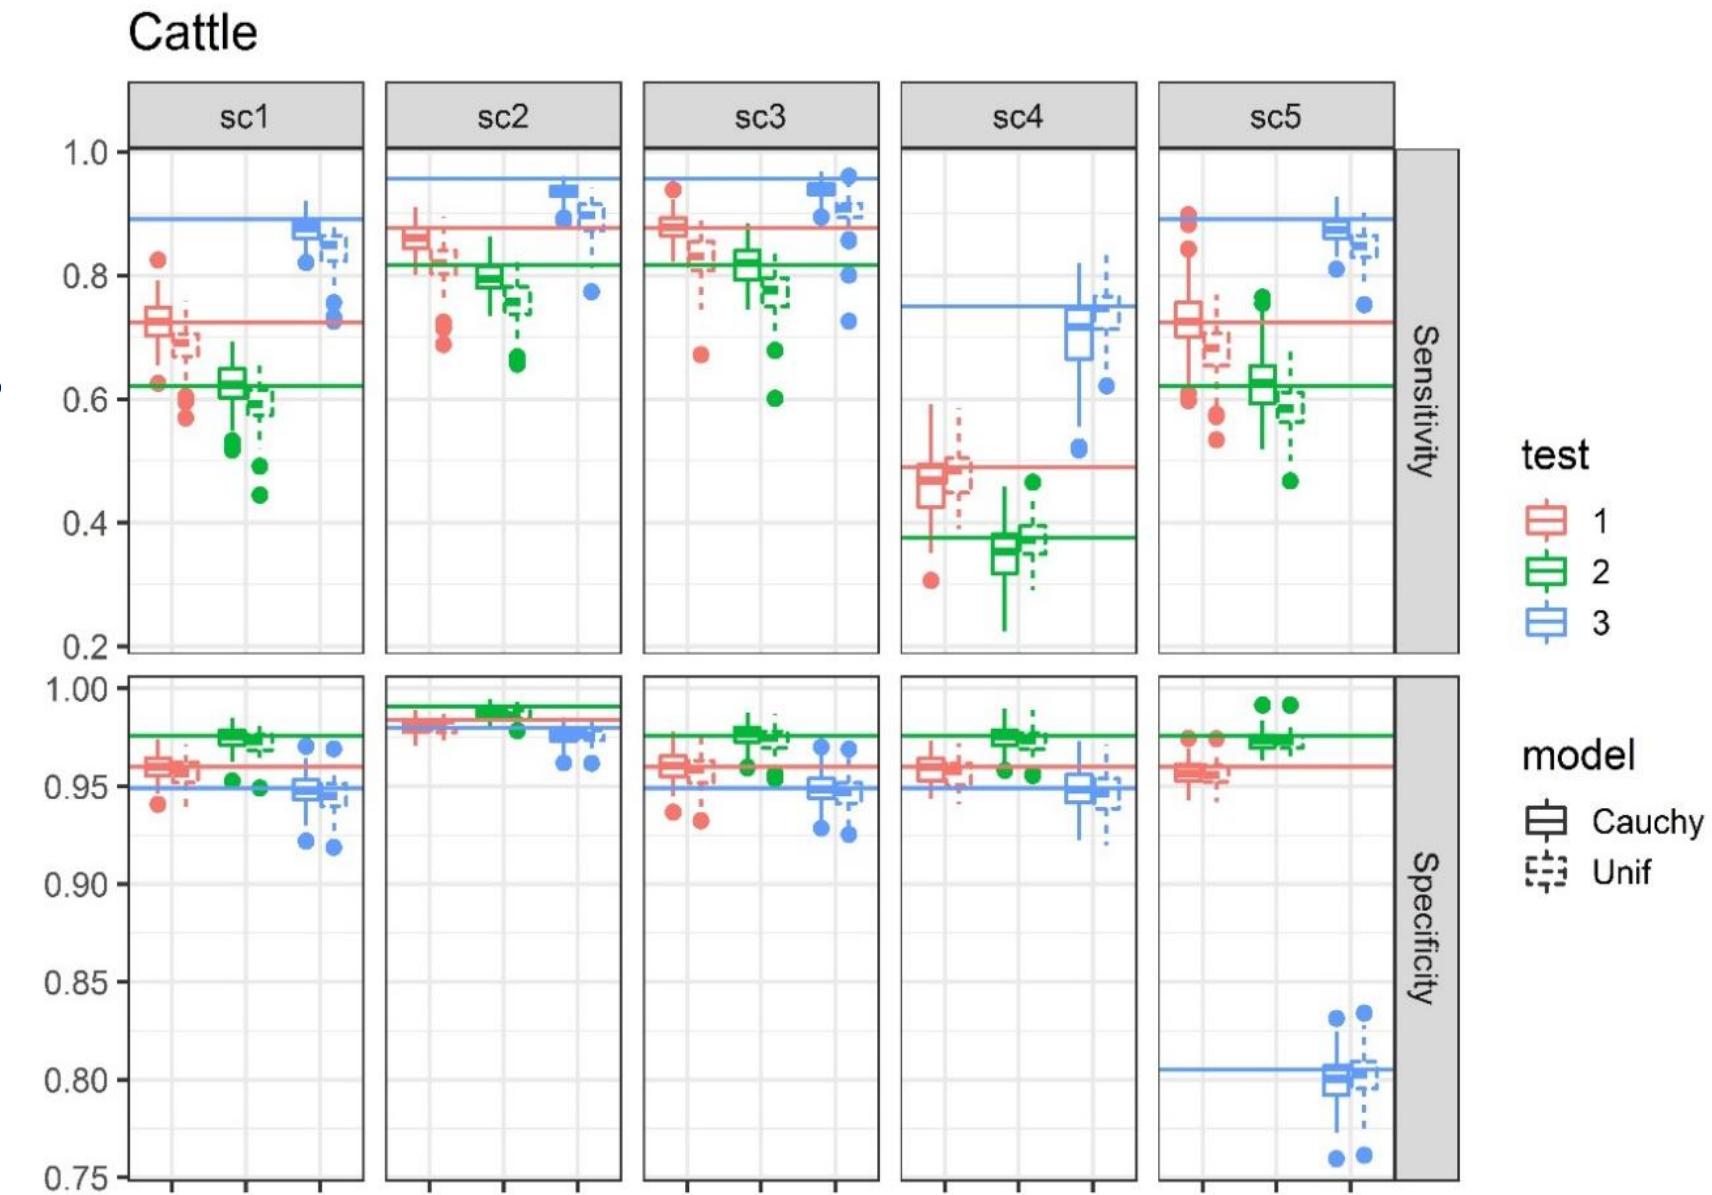


Résultats



Résultat de l'étude de simulation

- Distribution *a priori*
Cauchy moins biaisée
- **Performances élevées chez les caprins et bovins**
 - Biais moyens < -2%
 - Probabilité de couverture > 80%
- **Tendance à sous-estimer les Se et Sp chez les ovins (-3 à -7%)**
- Mais probabilité de couverture acceptable (de 79 à 92%)



Discussion

- Impact potentiellement important du **prior sur les paramètres de dépendance** conditionnelle
- Dans notre cas
 - Possibilité d'identification du problème car « évident »
 - Amélioration de la robustesse du modèle grâce à la prise en compte de la structuration des données
- Pas trivial en l'absence de sous population identifiable...
 - Identification des différentes « solutions » possible?
 - Inclusion des « biologistes » pour choisir entre les différentes solutions possible?

Mélange de dirichlet?



Myriam Garrido



Pierre Latouche



Pierre Druilhet

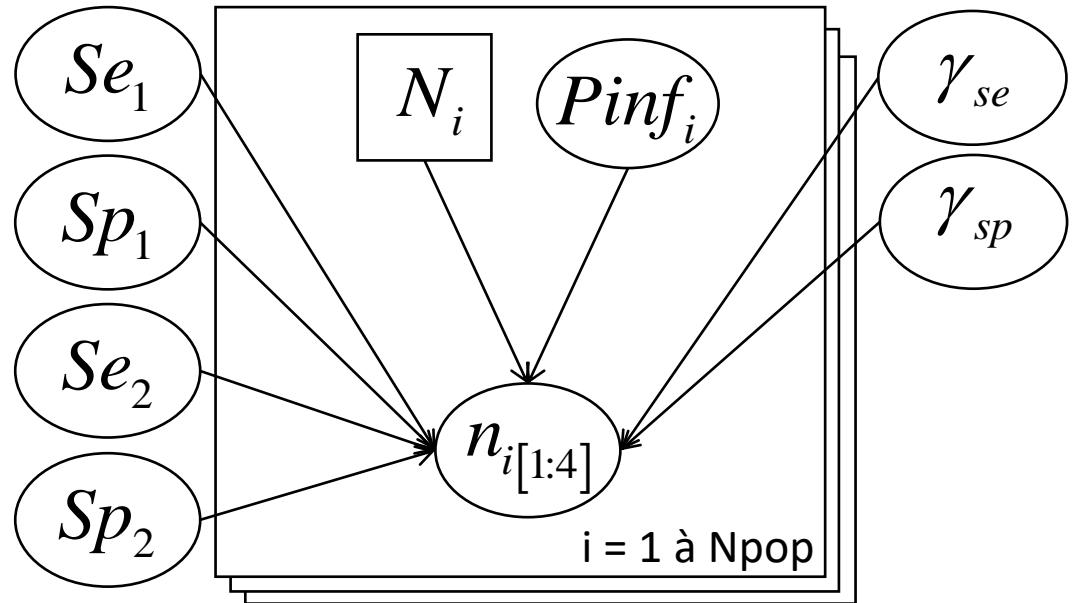
Prise en compte de la dépendance conditionnelle

- Ajout de **termes correcteurs** sur les probabilités

	Réactif 2 positif	Réactif 2 négatif
Réactif 1 positif	$p_{11} = (Se_1 \times Se_2 + \gamma_{Se}) \times P + ((1 - Sp_1) \times (1 - Sp_2) + \gamma_{Sp}) \times (1 - P)$	$p_{10} = (Se_1 \times (1 - Se_2) - \gamma_{Se}) \times P + ((1 - Sp_1) \times Sp_2 - \gamma_{Sp}) \times (1 - P)$
Réactif 1 négatif	$p_{01} = ((1 - Se_1) \times Se_2 - \gamma_{Se}) \times P + (Sp_1 \times (1 - Sp_2) - \gamma_{Sp}) \times (1 - P)$	$p_{00} = ((1 - Se_1) \times (1 - Se_2) + \gamma_{Se}) \times P + (Sp_1 \times Sp_2 + \gamma_{Sp}) \times (1 - P)$

- Nouvelle paramétrisation du modèle proposée sous la forme d'un **mélange de dirichlet**

Traditional LCM



$$n_{i[1:4]} \sim \text{multinomial}\left(N_i, p_{i[1:4]}\right)$$

$$p_{i[1]} = Pinf_i \times ((1 - Se_1) \times (1 - Se_2) + \gamma_{se}) + (1 - Pinf_i) \times (Sp_1 \times Sp_2 + \gamma_{sp})$$

$$p_{i[2]} = Pinf_i \times ((1 - Se_1) \times Se_2 - \gamma_{se}) + (1 - Pinf_i) \times (Sp_1 \times (1 - Sp_2) - \gamma_{sp})$$

$$p_{i[3]} = Pinf_i \times (Se_1 \times (1 - Se_2) - \gamma_{se}) + (1 - Pinf_i) \times ((1 - Sp_1) \times Sp_2 - \gamma_{sp})$$

$$p_{i[4]} = Pinf_i \times (Se_1 \times Se_2 + \gamma_{se}) + (1 - Pinf_i) \times ((1 - Sp_1) \times (1 - Sp_2) + \gamma_{sp})$$

$$Se_1 \sim \text{beta}(1,1)$$

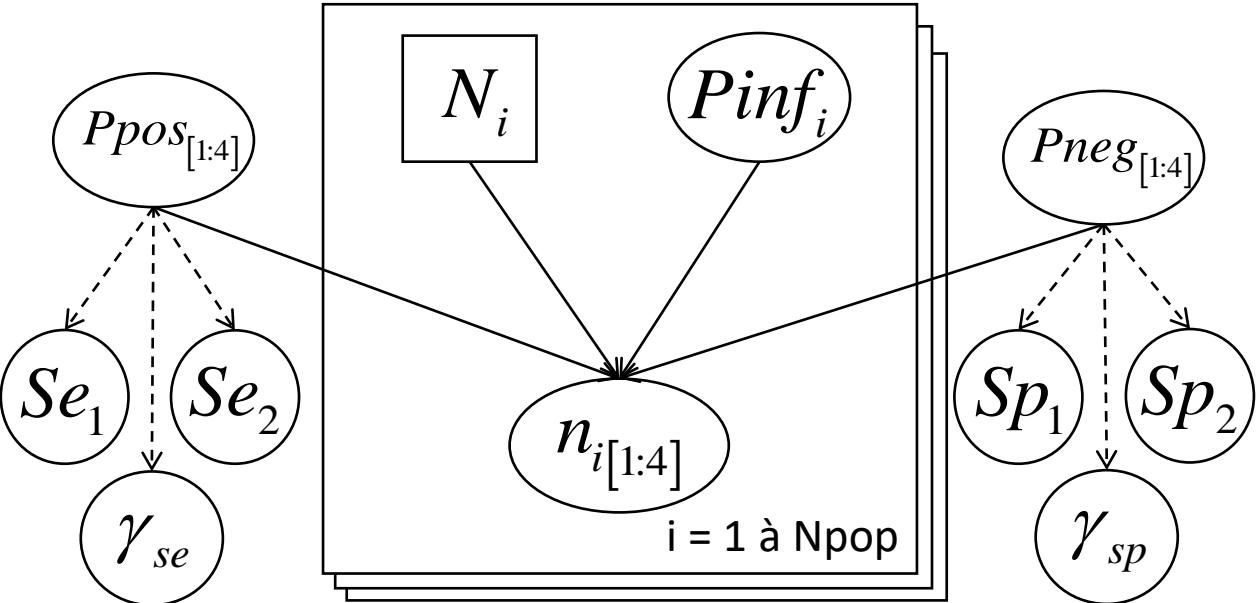
$$Sp_1 \sim \text{beta}(1,1)$$

$$Se_2 \sim \text{beta}(1,1)$$

$$Sp_2 \sim \text{beta}(1,1)$$

$$\gamma_{se} \sim \text{uniform}(-1,1) \quad \gamma_{sp} \sim \text{uniform}(-1,1)$$

Dirichlet mixture LCM



$$n_{i[1:4]} \sim \text{multinomial}\left(N_i, p_{i[1:4]}\right)$$

$$p_{i[1:4]} = Pinf_i \times Ppos_{[1:4]} + (1 - Pinf_i) \times Pneg_{[1:4]}$$

$$Se_1 = Ppos[3] + Ppos[4] \quad Sp_1 = Pneg[1] + Pneg[2]$$

$$Se_2 = Ppos[2] + Ppos[4] \quad Sp_2 = Pneg[1] + Pneg[3]$$

$$\gamma_{se} = Ppos[4] - Se_1 \times Se_2 \quad \gamma_{sp} = Pneg[1] - Sp_1 \times Sp_2$$

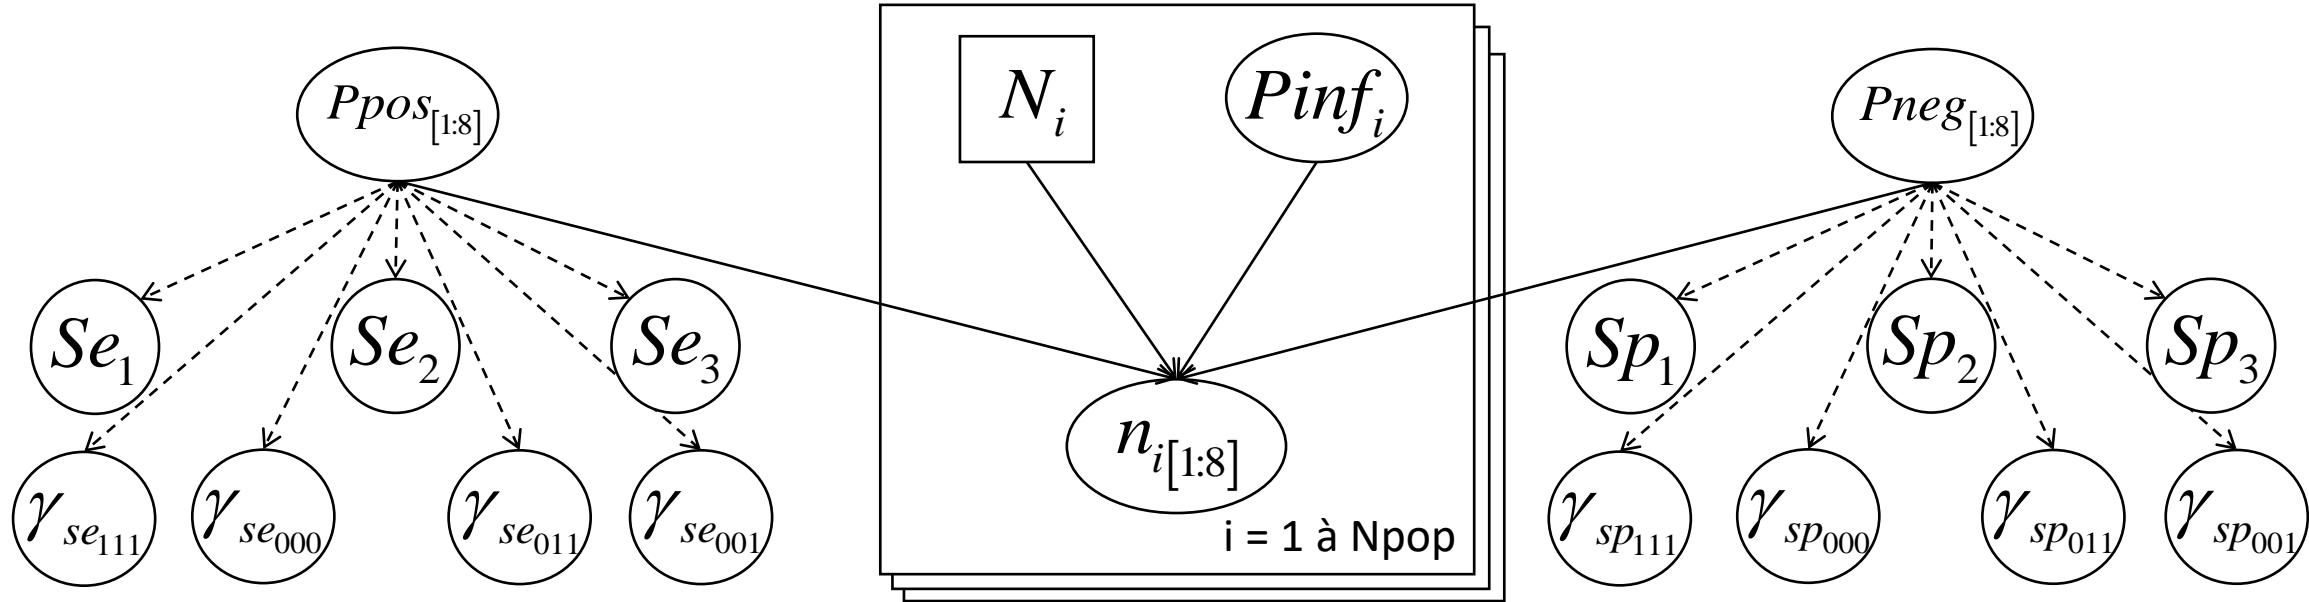
Prior distribution

$$Pinf_i \sim \text{beta}(1,1)$$

$$Ppos_{[1:4]} \sim \text{dirichlet}(\alpha_{pos[1:4]})$$

$$Pneg_{[1:4]} \sim \text{dirichlet}(\alpha_{neg[1:4]})$$

Modèle sous forme dirichlet pour 3 tests



$$Se_1 = Ppos[5] + Ppos[6] + Ppos[7] + Ppos[8]$$

$$Se_2 = Ppos[3] + Ppos[4] + Ppos[7] + Ppos[8]$$

$$Se_3 = Ppos[2] + Ppos[4] + Ppos[6] + Ppos[8]$$

$$\gamma_{se111} = Ppos[8] - Se_1 \times Se_2 \times Se_3$$

$$\gamma_{se011} = Ppos[4] - (1 - Se_1) \times Se_2 \times Se_3$$

$$\gamma_{se001} = Ppos[2] - (1 - Se_1) \times (1 - Se_2) \times Se_3$$

$$\gamma_{se000} = Ppos[1] - (1 - Se_1) \times (1 - Se_2) \times (1 - Se_3)$$

$$n_{i[1:8]} \sim multinomial(N_i, p_{i[1:8]})$$

$$p_{i[1:8]} = Pinf_i \times Ppos_{[1:8]} + (1 - Pinf_i) \times Pneg_{[1:8]}$$

$$Ppos_{[1:8]} \sim dirichlet(\alpha_{pos[1:8]})$$

$$Pneg_{[1:8]} \sim dirichlet(\alpha_{neg[1:8]})$$

$$Sp_1 = Pneg[1] + Pneg[2] + Pneg[3] + Pneg[4]$$

$$Sp_2 = Pneg[1] + Pneg[2] + Pneg[5] + Pneg[6]$$

$$Sp_3 = Pneg[1] + Pneg[3] + Pneg[5] + Pneg[7]$$

$$\gamma_{sp111} = Pneg[8] - (1 - Sp_1) \times (1 - Sp_2) \times (1 - Sp_3)$$

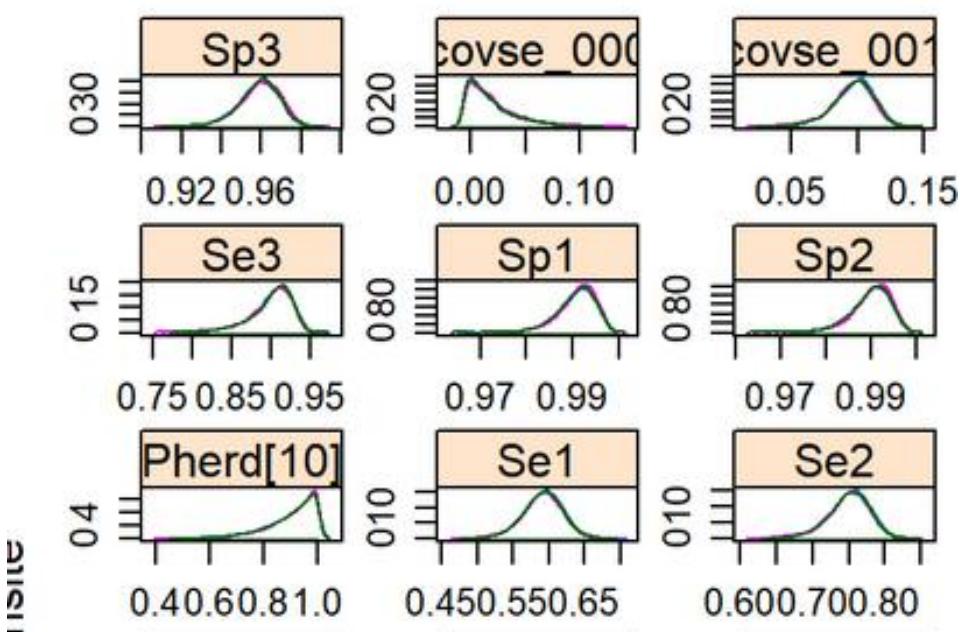
$$\gamma_{se011} = Pneg[4] - Sp_1 \times (1 - Sp_2) \times (1 - Sp_3)$$

$$\gamma_{se001} = Pneg[2] - Sp_1 \times Sp_2 \times (1 - Sp_3)$$

$$\gamma_{se000} = Pneg[1] - Sp_1 \times Sp_2 \times (1 - Sp_3)$$

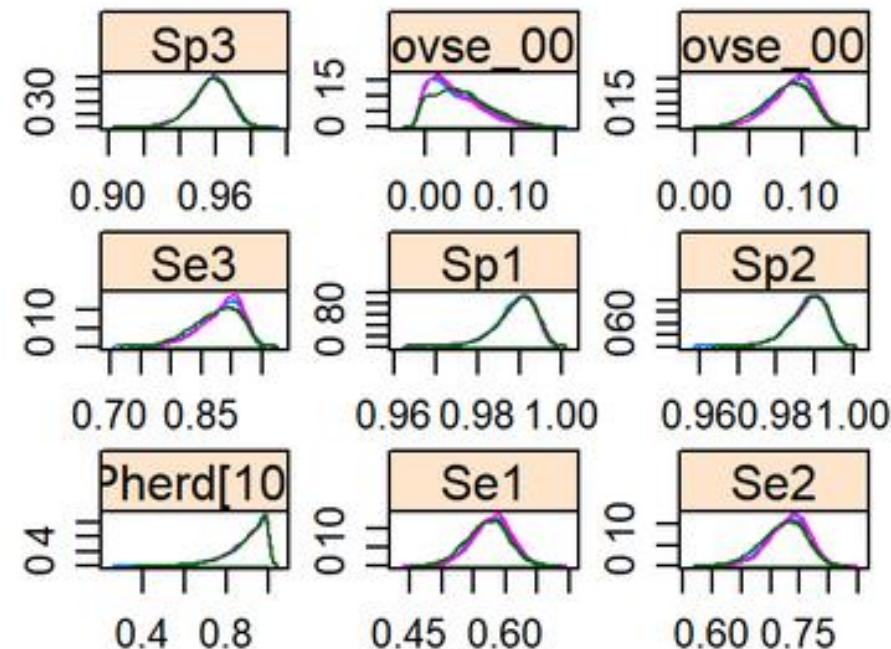
Application sur les données fièvre Q par élevage : 3 tests / 150 populations (1 par élevage)

Modèle « traditionnel »



Temps de calcul = 20,76 minutes

Modèle « Dirichlet »



Temps de calcul = 9,76 minutes

Application sans la structuration en élevage

- Modèle à trois tests et dix populations (1 par département)
 - ⇒ Estimations similaires à celles obtenues avec le prior uniforme
 - ⇒ Biais vers les dépendances conditionnelles fortes?

Perspectives

- Modèle qui tourne plus vite
- A l'air de favoriser les estimations à forte dépendance conditionnelle...
- Essayer d'inclure des distributions a priori informatives sur les deux Dirichlet
 - Actuellement $Dirichlet(\alpha, [0.25, 0.25, 0.25, 0.25])$
 - Potentiellement

$$Dirichlet\left(\alpha, \begin{bmatrix} Se_{1Indep} \times Se_{2Indep}, \\ (1 - Se_{1Indep}) \times Se_{2Indep}, \\ Se_{1Indep} \times (1 - Se_{2Indep}), \\ (1 - Se_{1Indep}) \times (1 - Se_{2Indep}) \end{bmatrix}\right)$$

$$Se_{1Indep} \sim Beta(0.5, 0.5)$$

$$Se_{2Indep} \sim Beta(0.5, 0.5)$$

$$Sp_{1Indep} \sim Beta(0.5, 0.5)$$

$$Sp_{2Indep} \sim Beta(0.5, 0.5)$$

Estimation sur les données FQ par département

- 3 jeux de données environ 1500 ovins/bovins et caprins
- Testés avec 3 tests dans 10 départements
⇒ Modèle à 3 tests et 10 populations

- 3 modèles historiques avec des estimations incohérentes
- « vrai valeurs » estimées dans un modèle plus complexe

⇒ Evaluer le comportement des modèles Dirichlet sur ces jeux de données
⇒ Idéalement dans ce cas, peu biaisée et à large intervalle de crédibilité

Modèle à classes latentes

- Lclass : modèle à classe latente sans dépendance conditionnelle

$$\gamma_{se\ldots} = 0$$

$$\gamma_{sp\ldots} = 0$$

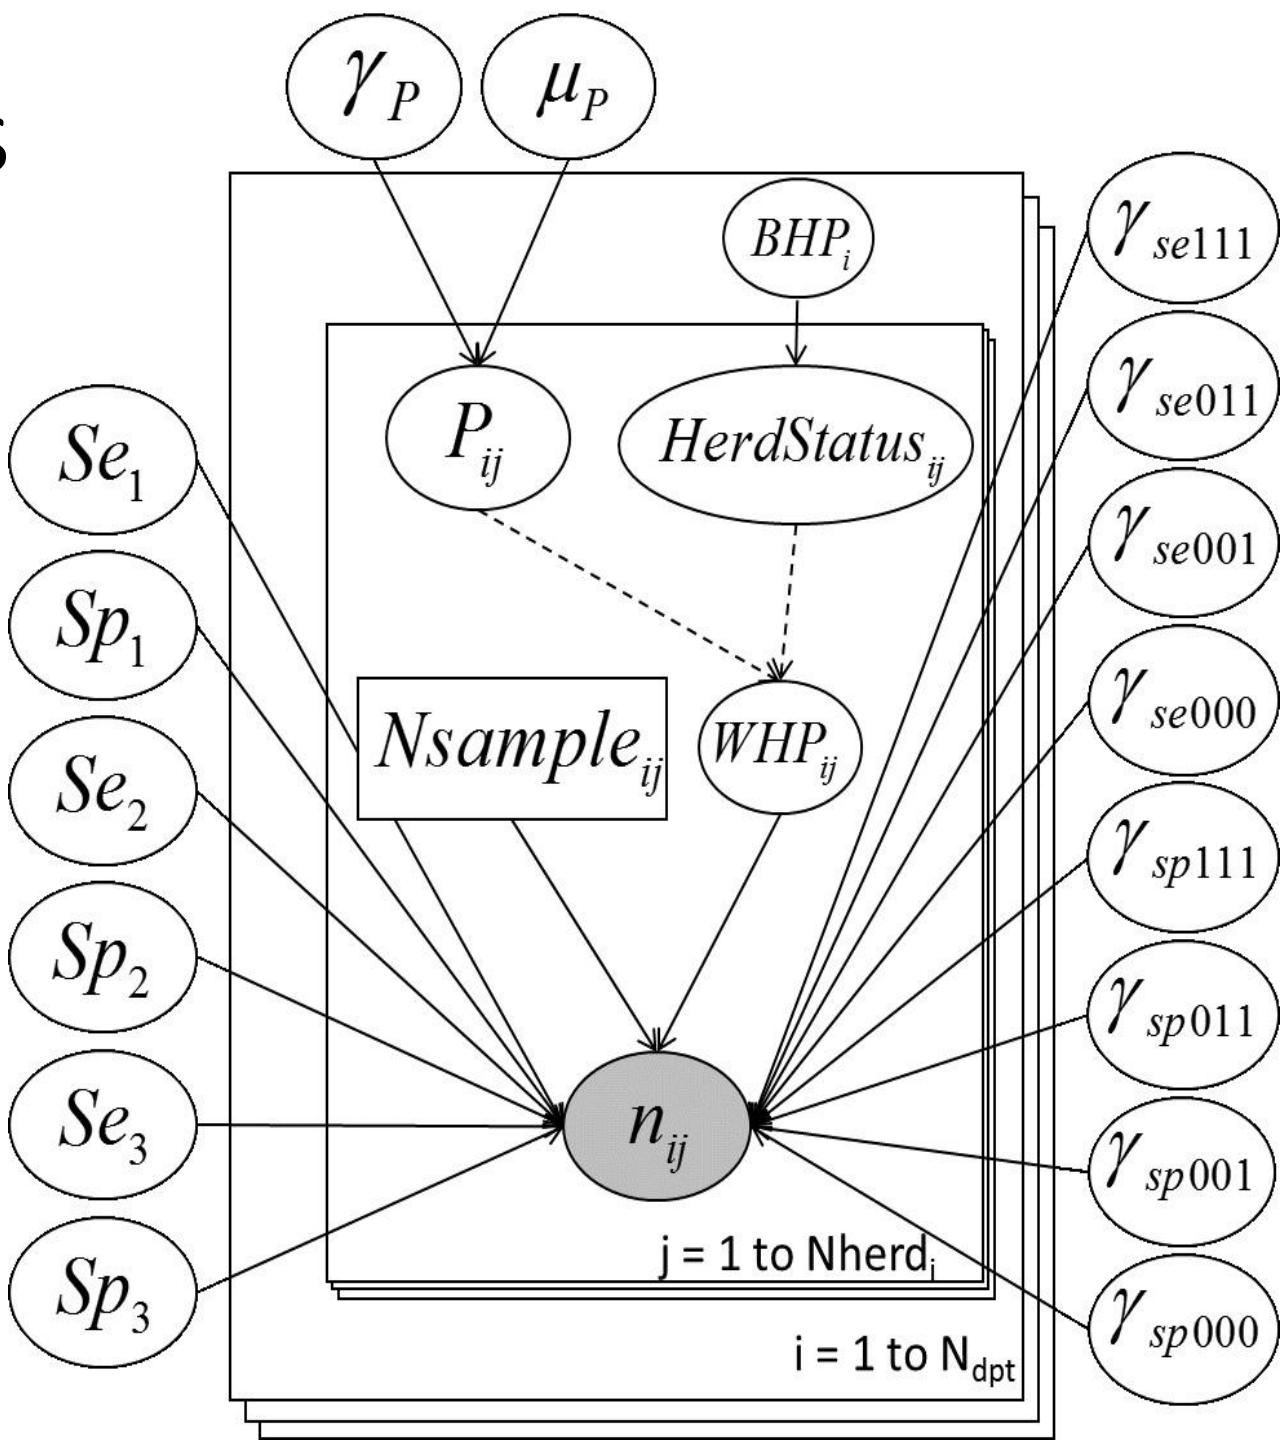
- Unif : modèle à classe latente prior uniform[-0,5;0,5] sur la dep cond

$$\gamma_{se\ldots} \sim unif [0.5, 0.5]$$

$$\gamma_{sp\ldots} \sim unif [0.5, 0.5]$$

- Cauchy : idem mais prior cauchy

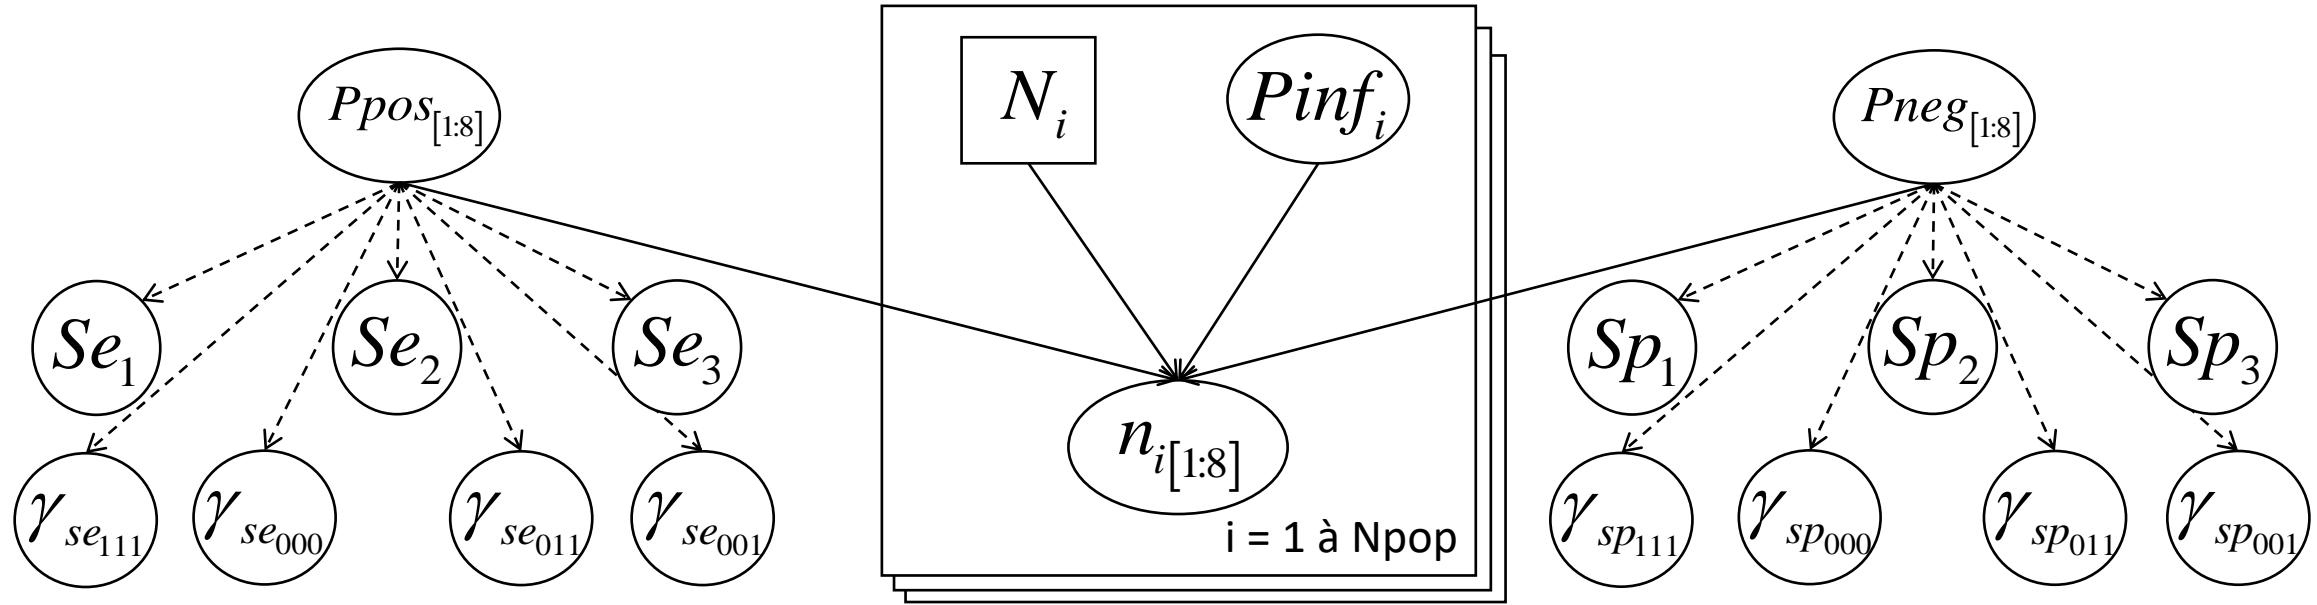
$$\gamma_{se\ldots} \sim cauchy [0, 0.039] \quad \gamma_{sp\ldots} \sim cauchy [0, 0.039]$$



7 Modèles testés

- Lclass : modèle à classe latente sans dépendance conditionnelle
- Unif : modèle à classe latente prior uniform[-0,5;0,5] sur la dep cond
- Cauchy : idem mais prior cauchy
- Dir : modèle à classe latente sous forme dirichlet
- Alpha 1 : modèle dirichlet avec hyperparamétrisation des Se et Sp et une valeur de alpha de 1
- Alpha8 : idem mais alpha 8
- Alpha 100 :idem mais alpha 100

Modèle sous forme dirichlet pour 3 tests sans hyperparamétrisation



$$Se_1 = Ppos[5] + Ppos[6] + Ppos[7] + Ppos[8]$$

$$Se_2 = Ppos[3] + Ppos[4] + Ppos[7] + Ppos[8]$$

$$Se_3 = Ppos[2] + Ppos[4] + Ppos[6] + Ppos[8]$$

$$\gamma_{se111} = Ppos[8] - Se_1 \times Se_2 \times Se_3$$

$$\gamma_{se011} = Ppos[4] - (1 - Se_1) \times Se_2 \times Se_3$$

$$\gamma_{se001} = Ppos[2] - (1 - Se_1) \times (1 - Se_2) \times Se_3$$

$$\gamma_{se000} = Ppos[1] - (1 - Se_1) \times (1 - Se_2) \times (1 - Se_3)$$

$$n_{i[1:8]} \sim \text{multinomial}(N_i, p_{i[1:8]})$$

$$p_{i[1:8]} = Pinf_i \times Ppos_{[1:8]} + (1 - Pinf_i) \times Pneg_{[1:8]}$$

$$Ppos_{[1:8]} \sim \text{dirichlet}(\alpha_{pos[1:8]})$$

$$Pneg_{[1:8]} \sim \text{dirichlet}(\alpha_{neg[1:8]})$$

$$Sp_1 = Pneg[1] + Pneg[2] + Pneg[3] + Pneg[4]$$

$$Sp_2 = Pneg[1] + Pneg[2] + Pneg[5] + Pneg[6]$$

$$Sp_3 = Pneg[1] + Pneg[3] + Pneg[5] + Pneg[7]$$

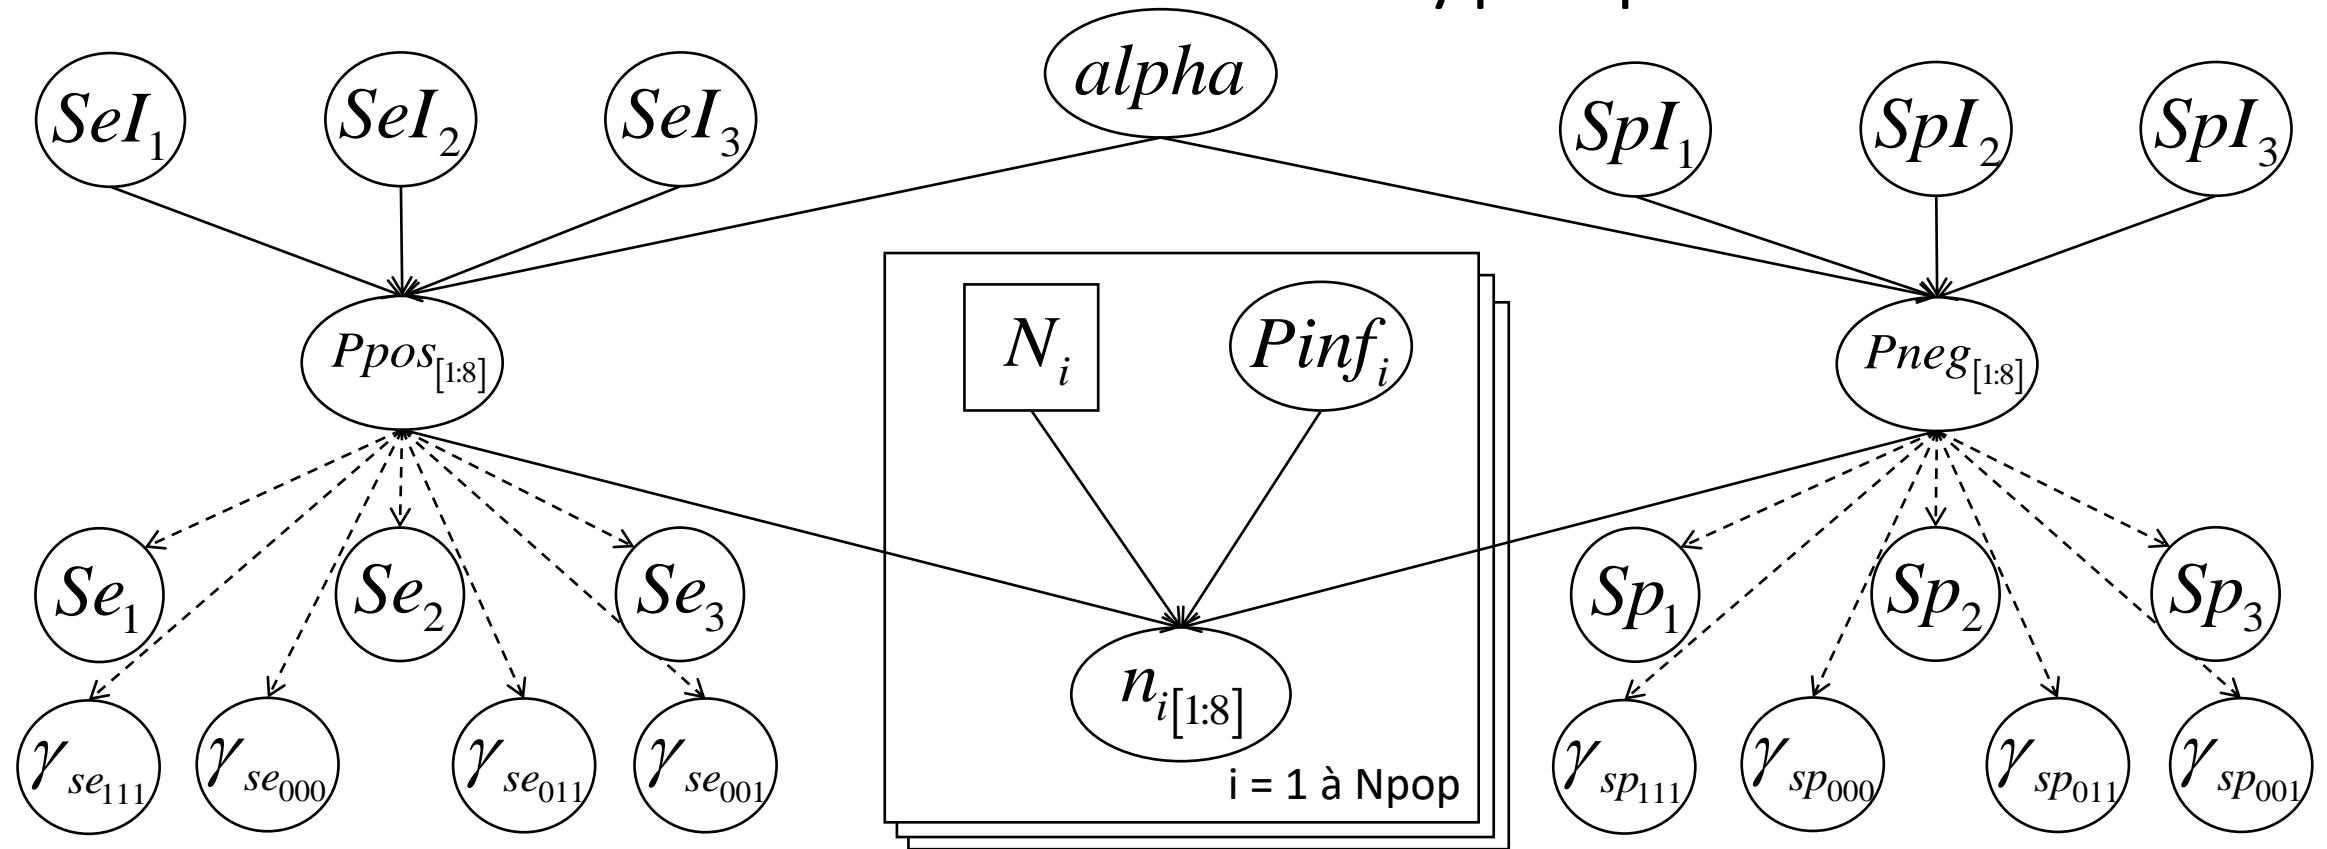
$$\gamma_{sp111} = Pneg[8] - (1 - Sp_1) \times (1 - Sp_2) \times (1 - Sp_3)$$

$$\gamma_{se011} = Pneg[4] - Sp_1 \times (1 - Sp_2) \times (1 - Sp_3)$$

$$\gamma_{se001} = Pneg[2] - Sp_1 \times Sp_2 \times (1 - Sp_3)$$

$$\gamma_{se000} = Pneg[1] - Sp_1 \times Sp_2 \times (1 - Sp_3)$$

Modèle sous forme dirichlet avec hyperparamétrisation



$$Ppos_{[1:8]} \sim Dirichlet \left(\alpha, \begin{bmatrix} (1 - Sel_1) \times (1 - Sel_2) \times (1 - Sel_3), (1 - Sel_1) \times (1 - Sel_2) \times Sel_3, \\ (1 - Sel_1) \times Sel_2 \times (1 - Sel_3), (1 - Sel_1) \times Sel_2 \times Sel_3, \\ Sel_1 \times (1 - Sel_2) \times (1 - Sel_3), Sel_1 \times (1 - Sel_2) \times Sel_3, \\ Sel_1 \times Sel_2 \times (1 - Sel_3), Sel_1 \times Sel_2 \times Sel_3 \end{bmatrix} \right)$$

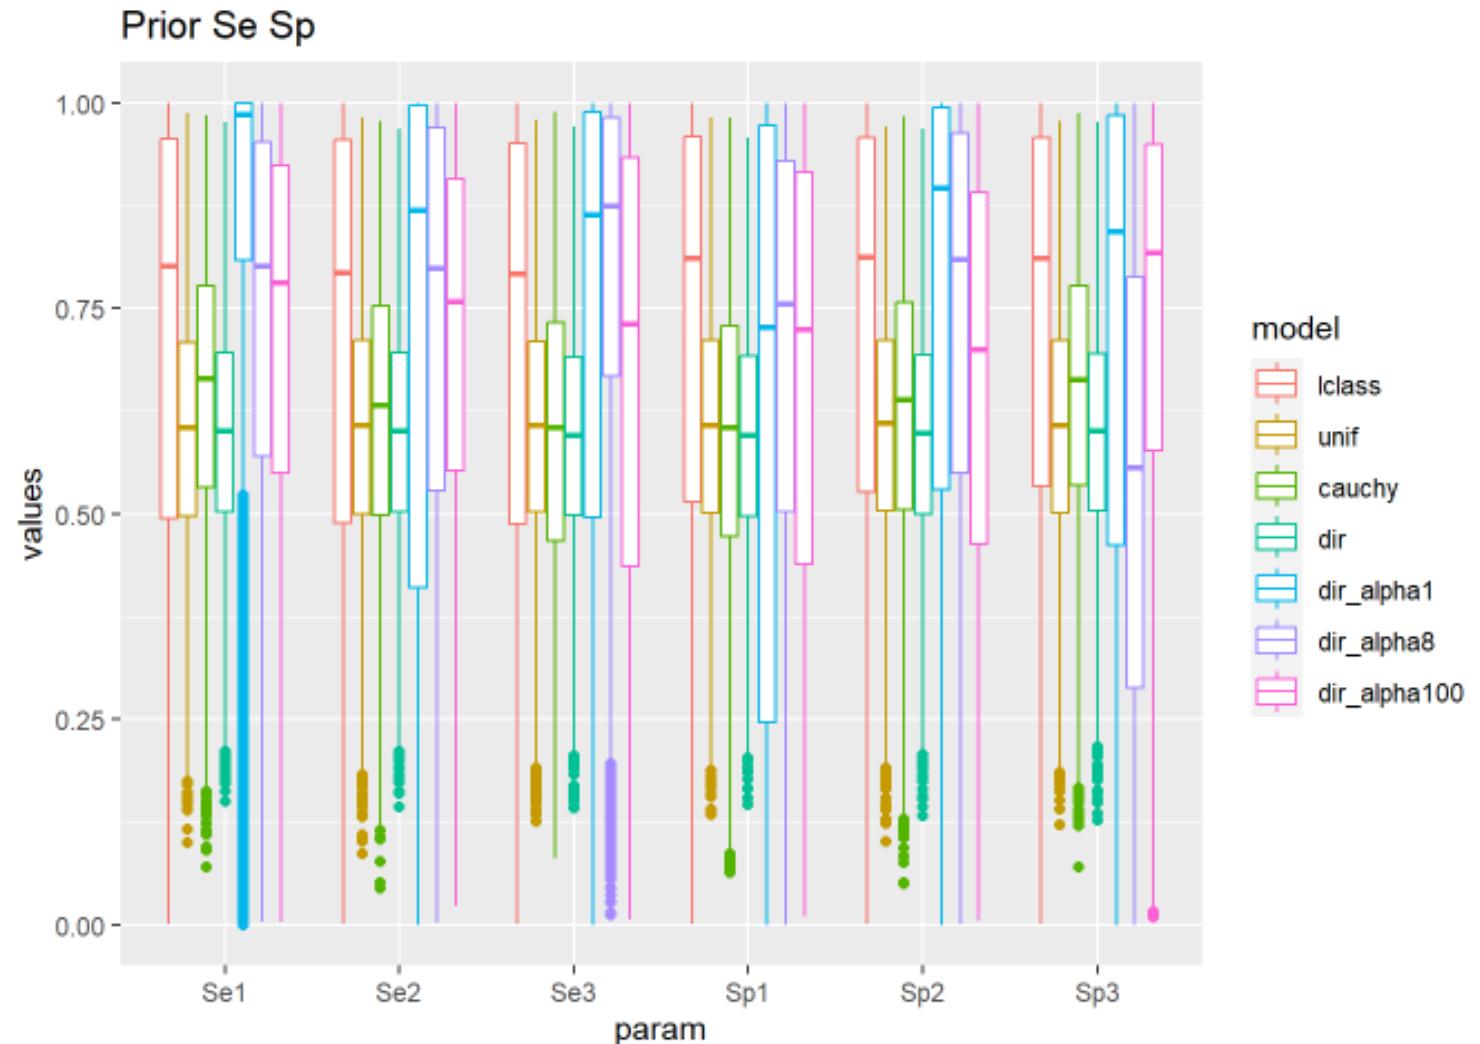
$Sel_i \sim Beta(0.5, 0.5)$

$$Pneg_{[1:8]} \sim Dirichlet(\alpha, [...])$$

$$SpI_i \sim Beta(0.5, 0.5)$$

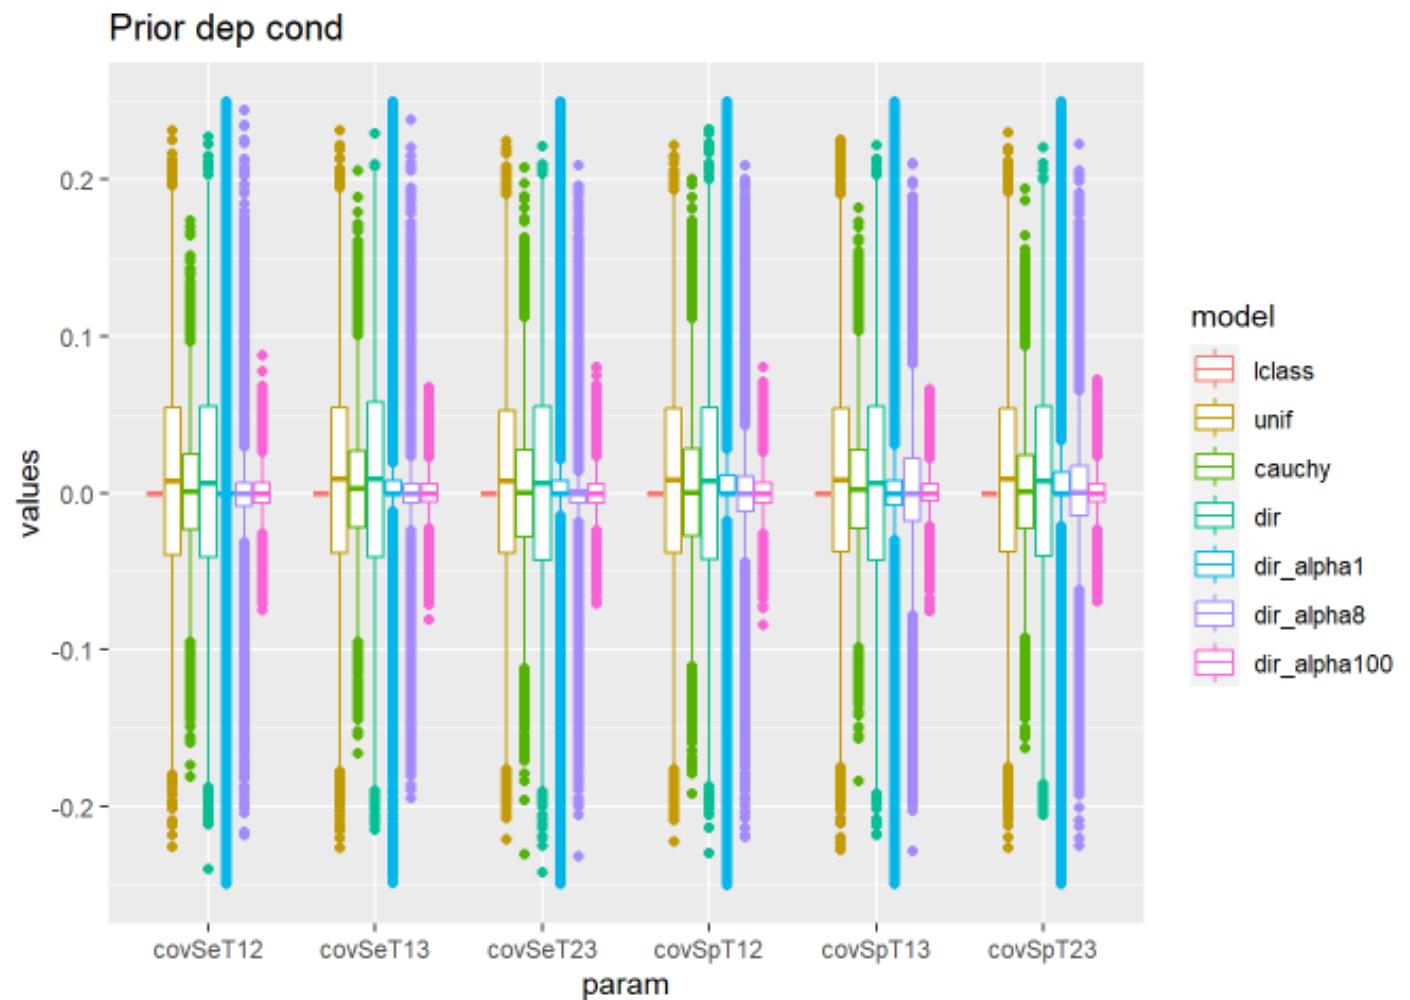
Distribution a priori Se-Sp

- Distribution a priori assez similaire quelques soit le modèle



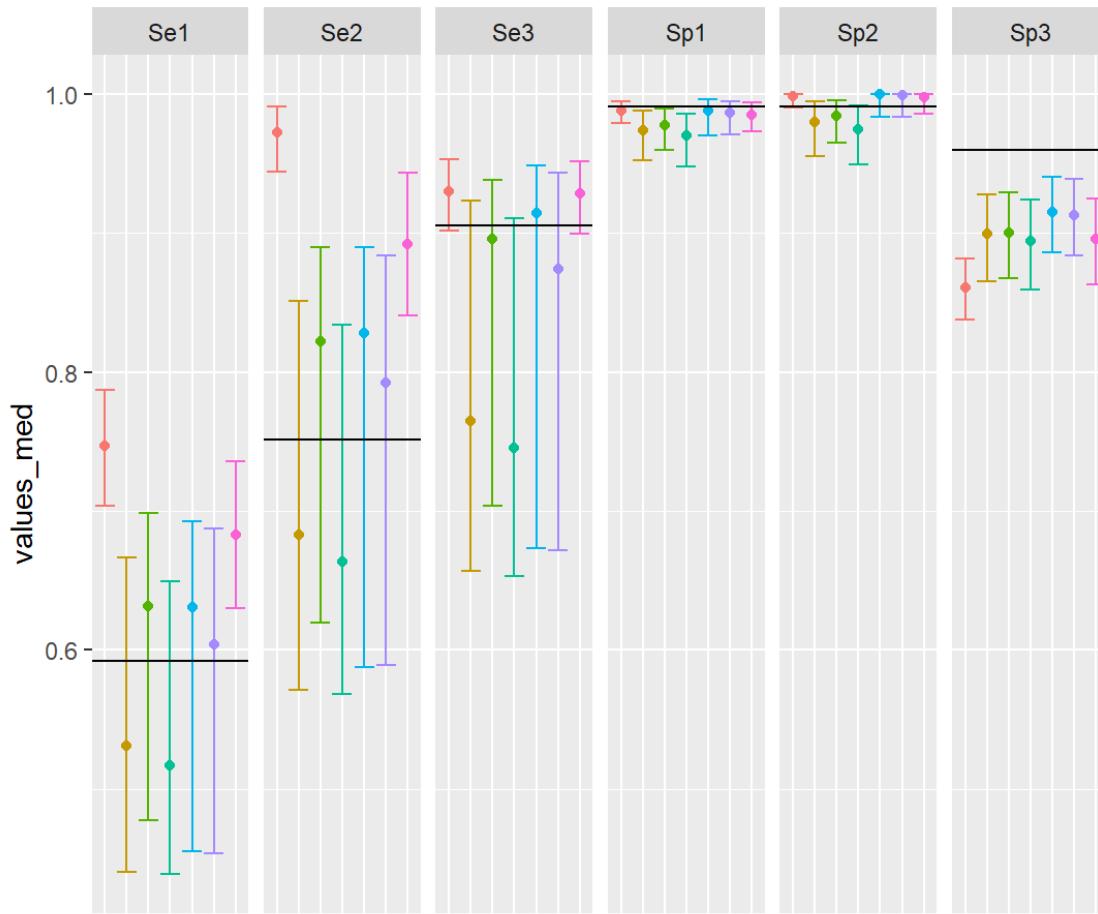
Distribution a priori dep-cond

- Dependance conditionnelle
- Lclass : nulle
- Unif : assez large
- Cauchy : plus étroite
- Dir : idem Unif
- Alpha 1 : centrée en 0 mais queue large
- Alpha8 : idem
- Alpha 100 : proche Lclass

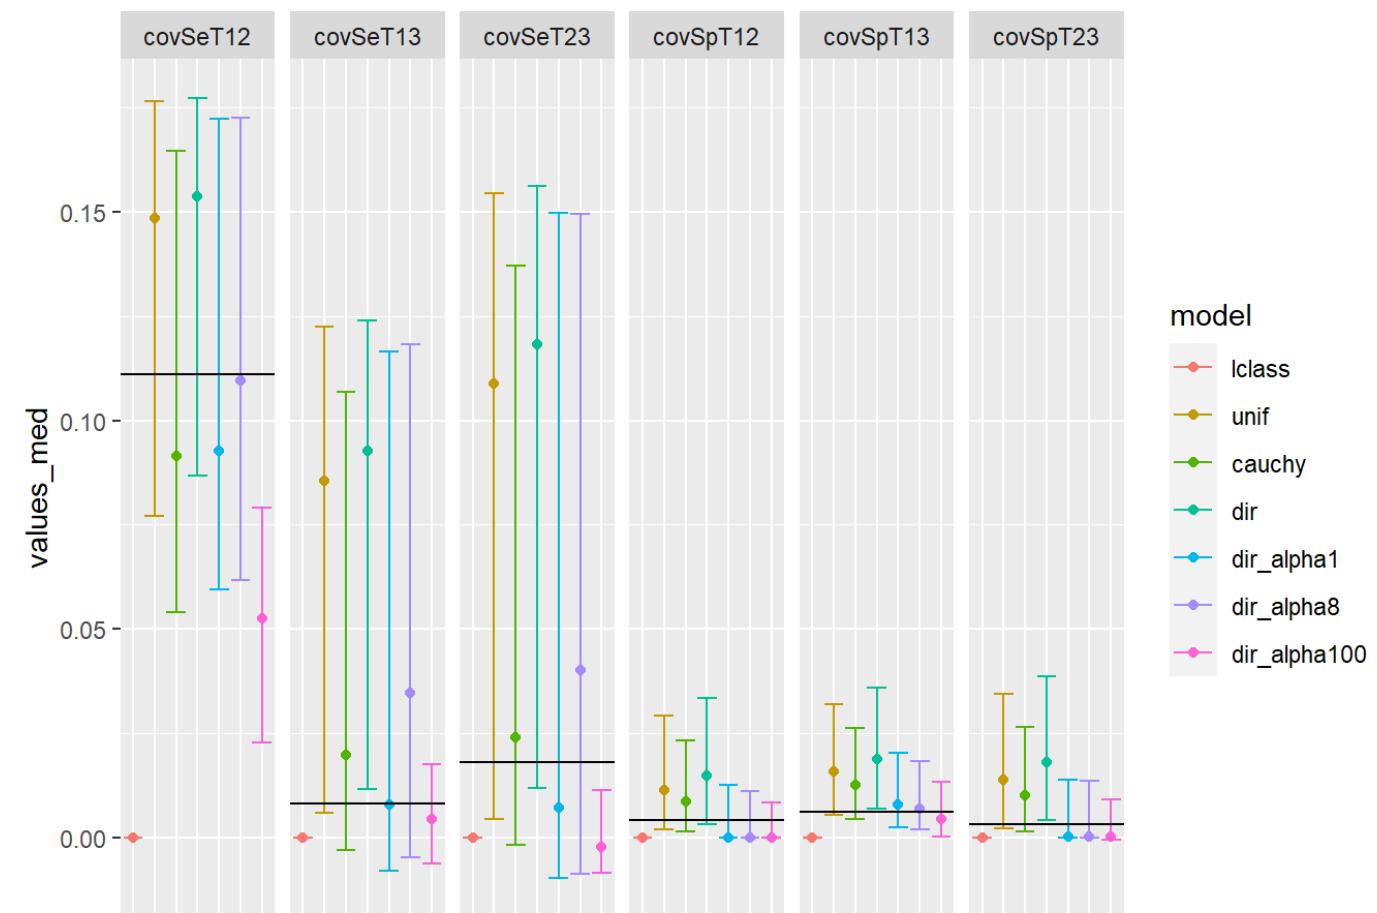


Estimation caprin

Caprin Se Sp



Caprin dep cond

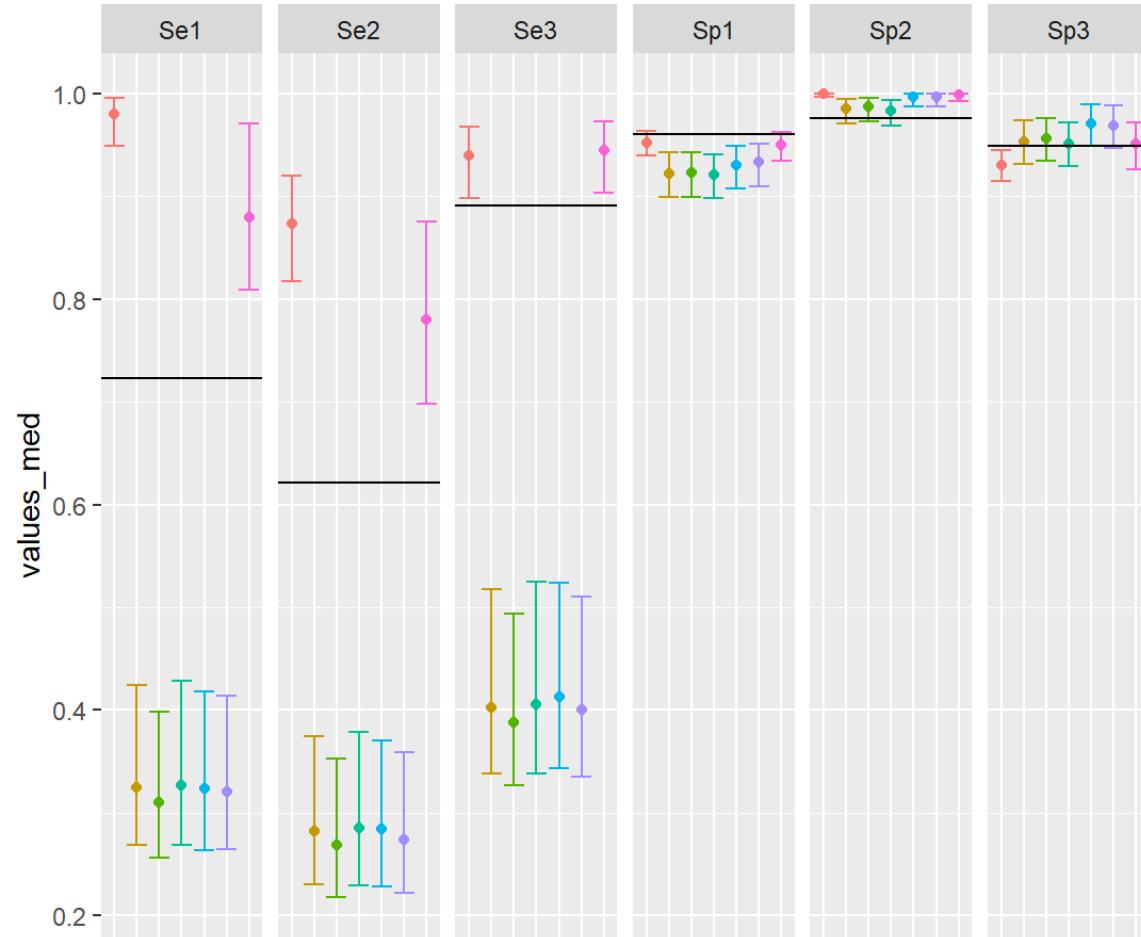


model

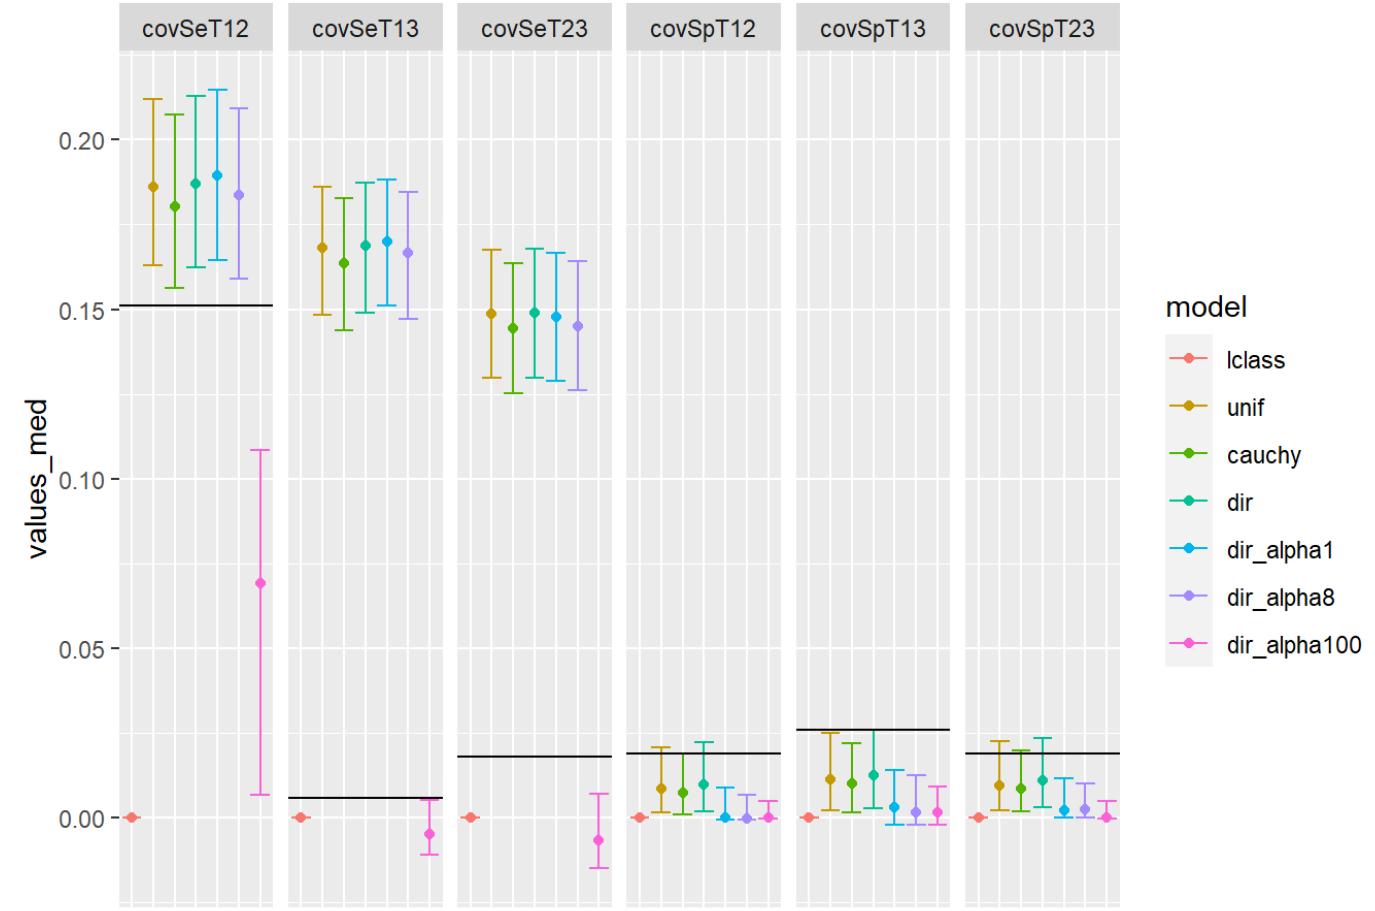
- Iclass
- unif
- cauchy
- dir
- dir_alpha1
- dir_alpha8
- dir_alpha100

Estimation bovin

Bovin Se Sp



Bovin dep cond

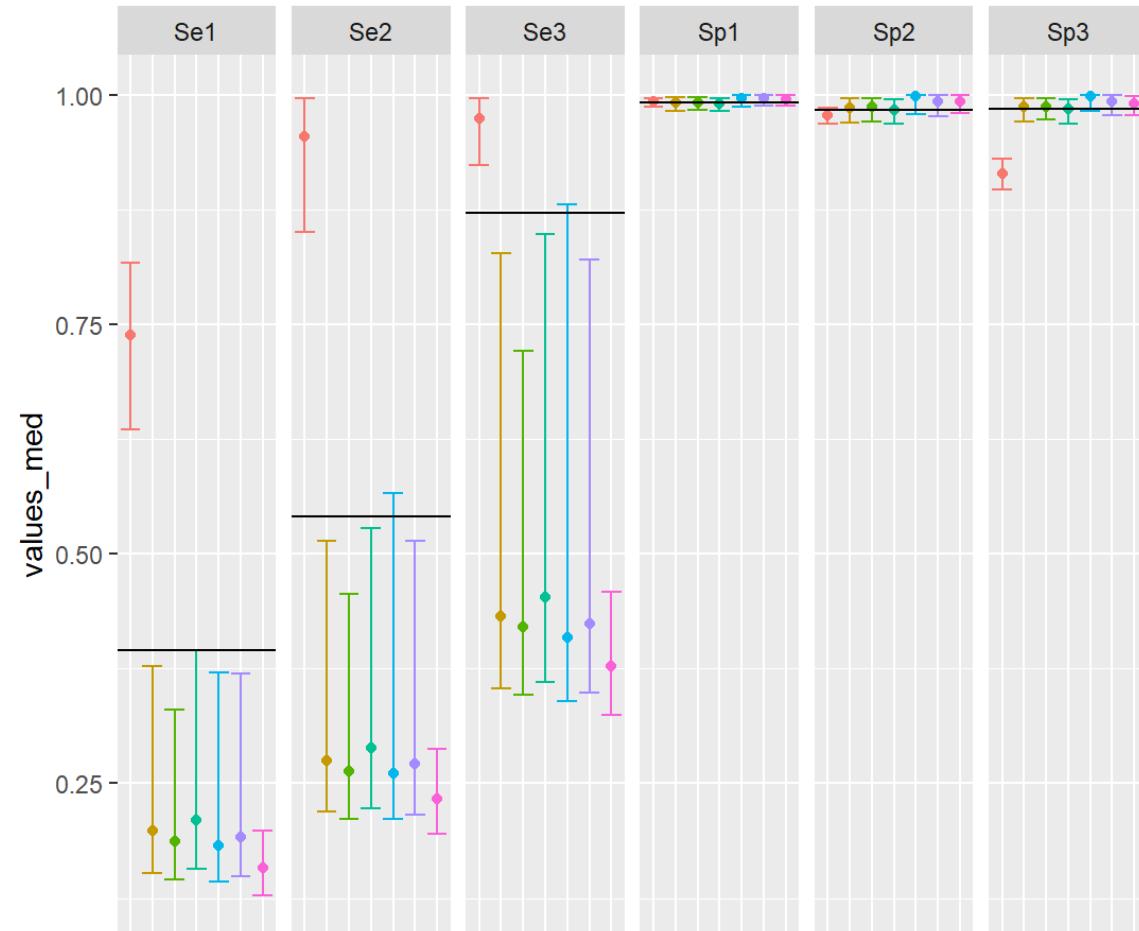


model

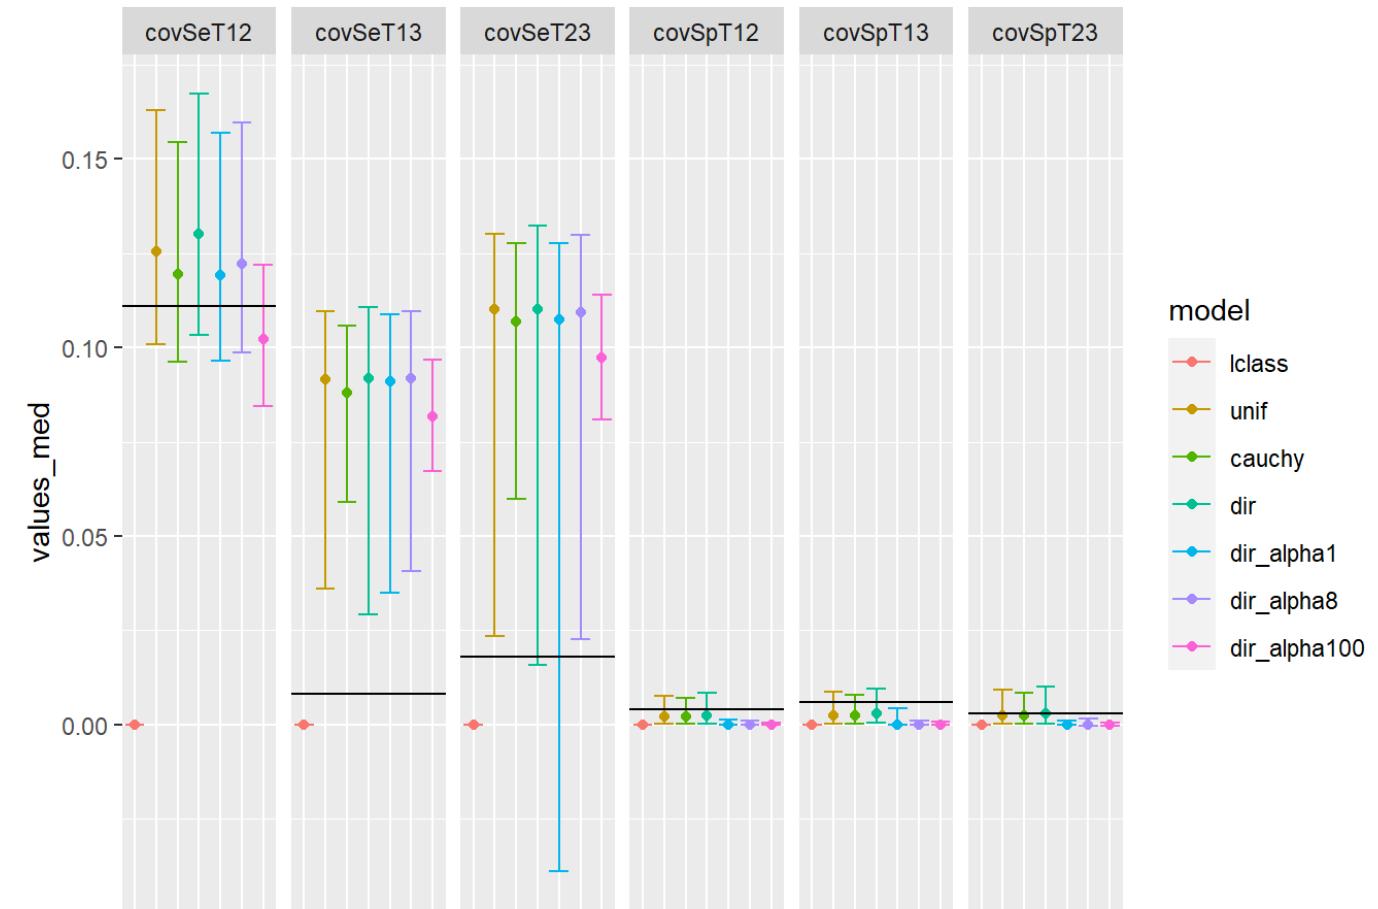
- lclass
- unif
- cauchy
- dir
- dir_alpha1
- dir_alpha8
- dir_alpha100

Estimation ovin

Ovin Se Sp



Ovin dep cond



model

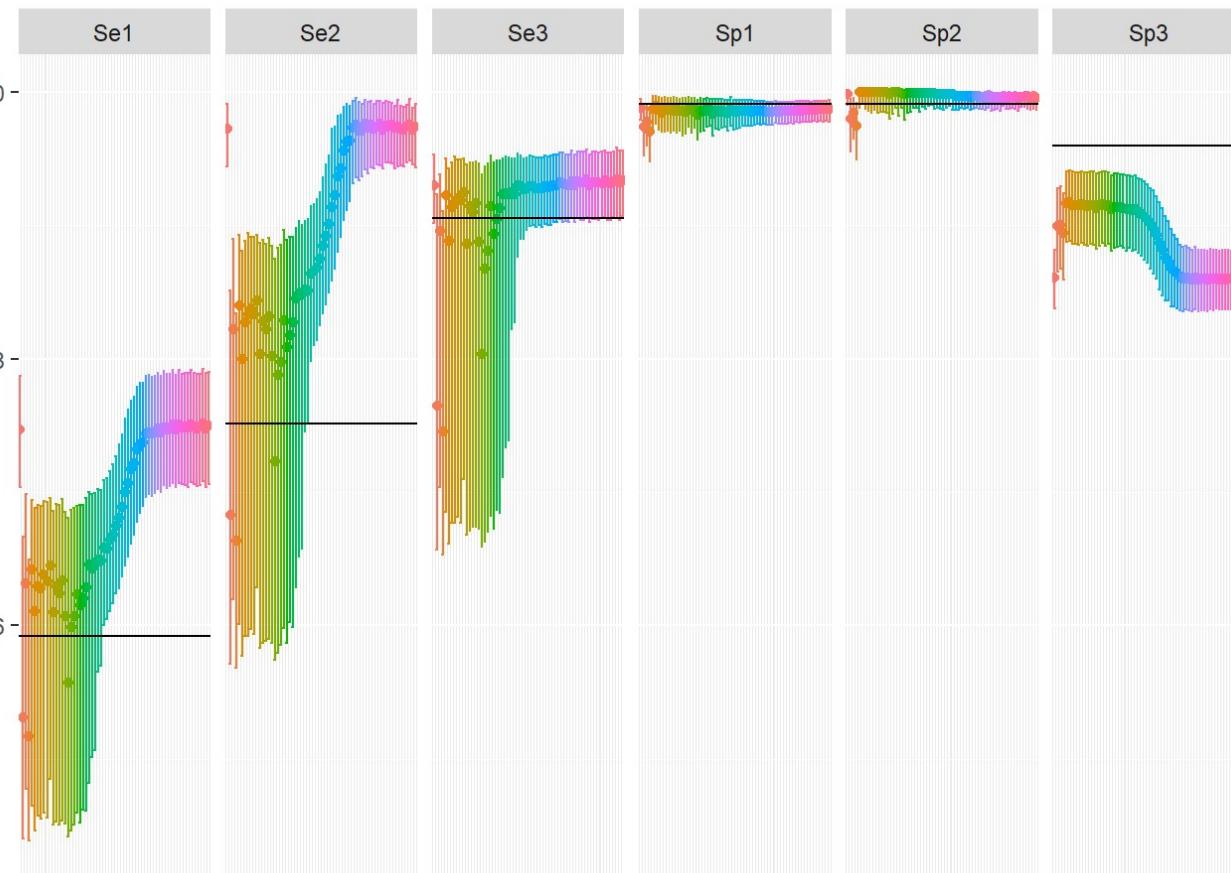
- lclass
- unif
- cauchy
- dir
- dir_alpha1
- dir_alpha8
- dir_alpha100

Bilan

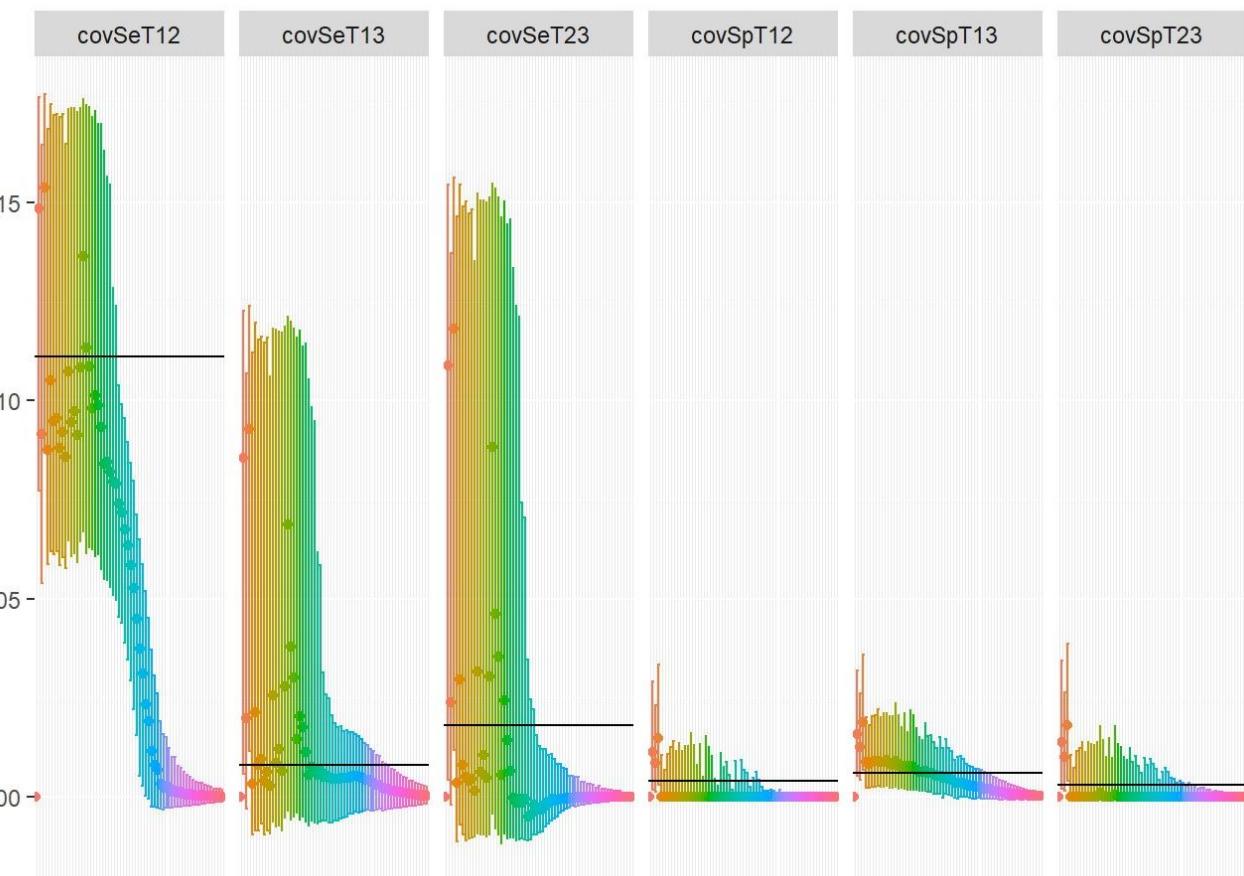
- Dirichlet sans hyperparamétrisation :
 - Comportement proche de modèle unif, forte dépendance conditionnelles à posteriori => biais négatifs potentiellement important
 - Dirichlet avec hyperparamétrisation : alpha 1, alpha 8, alpha 100
 - Plus alpha est grand plus on est proche de Lclass (indépendance)
- ⇒ Est-ce qu'en testant plus de valeur de alpha, on peut identifier les solutions attendues avec le jeu de données sans structuration à l'échelle de l'élevage?

Estimation caprin

Caprin Se Sp

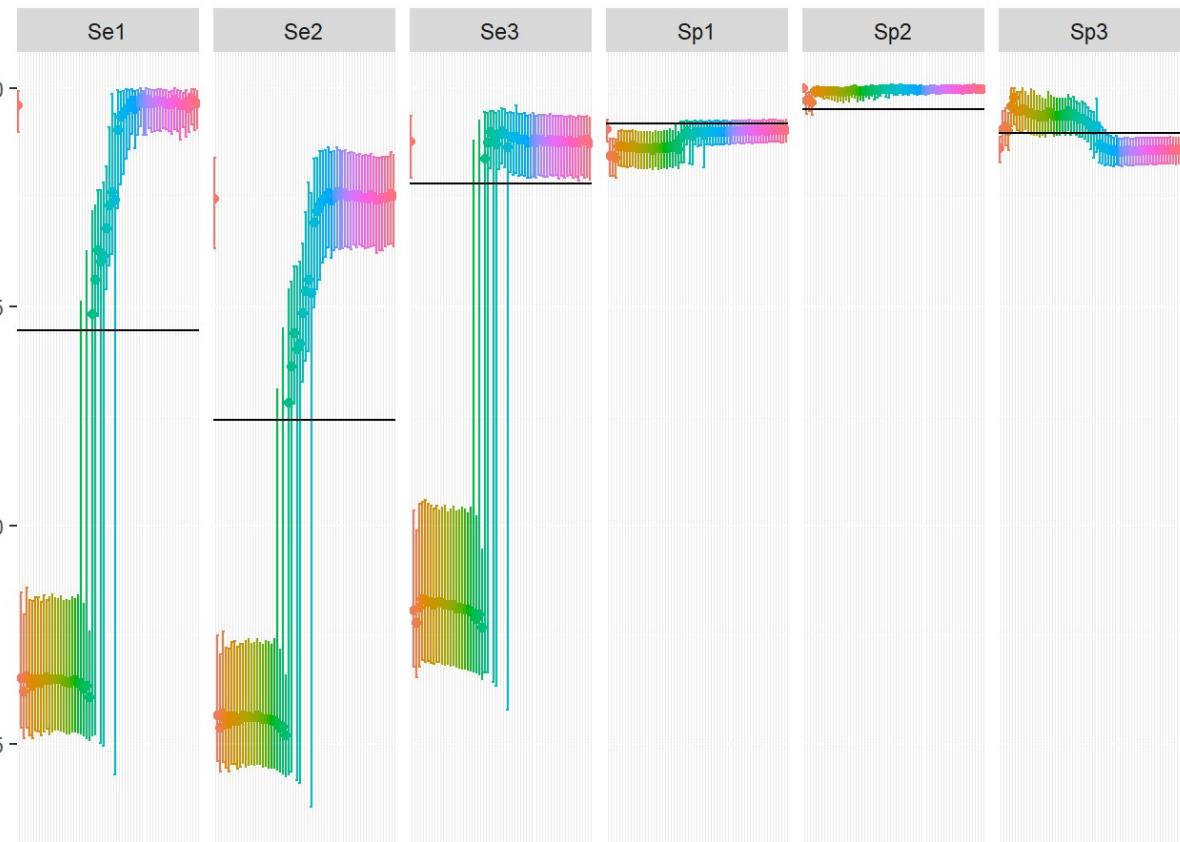


Caprin dep cond

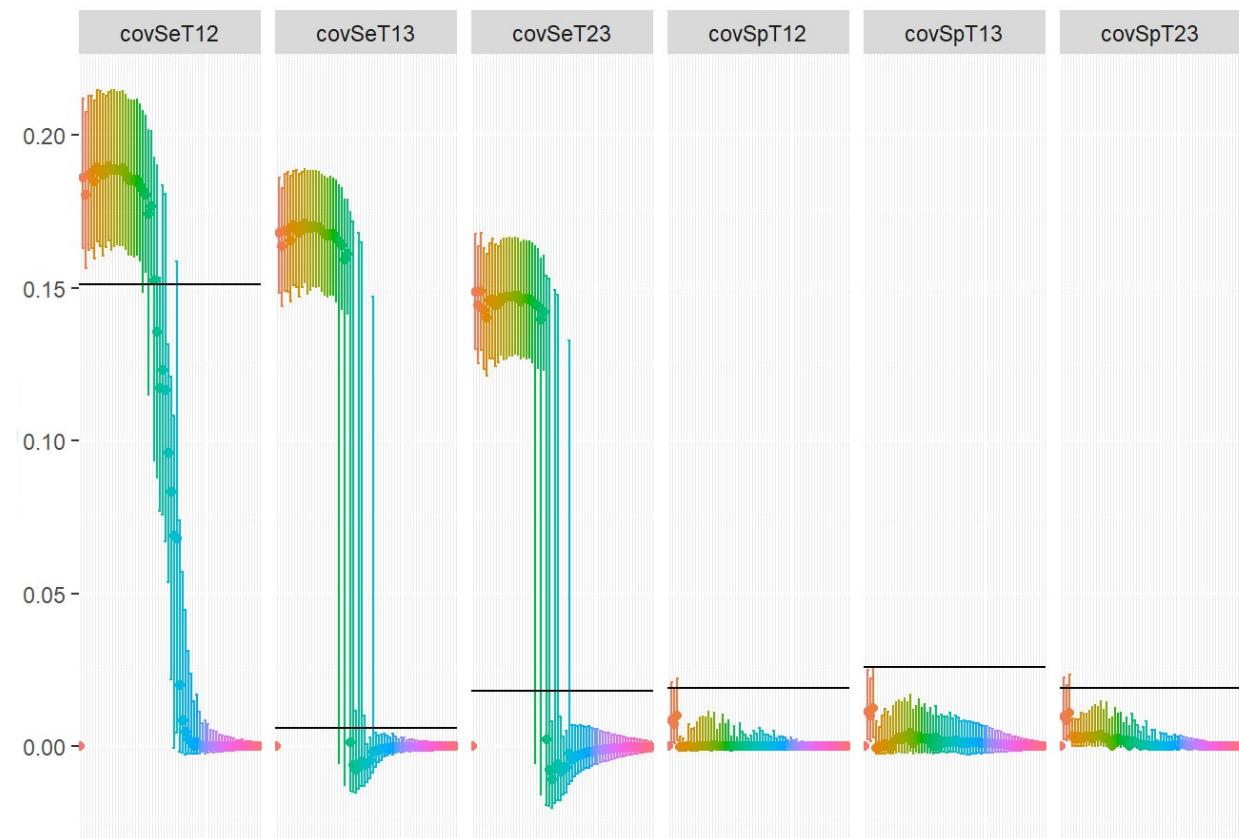


Estimation bovin

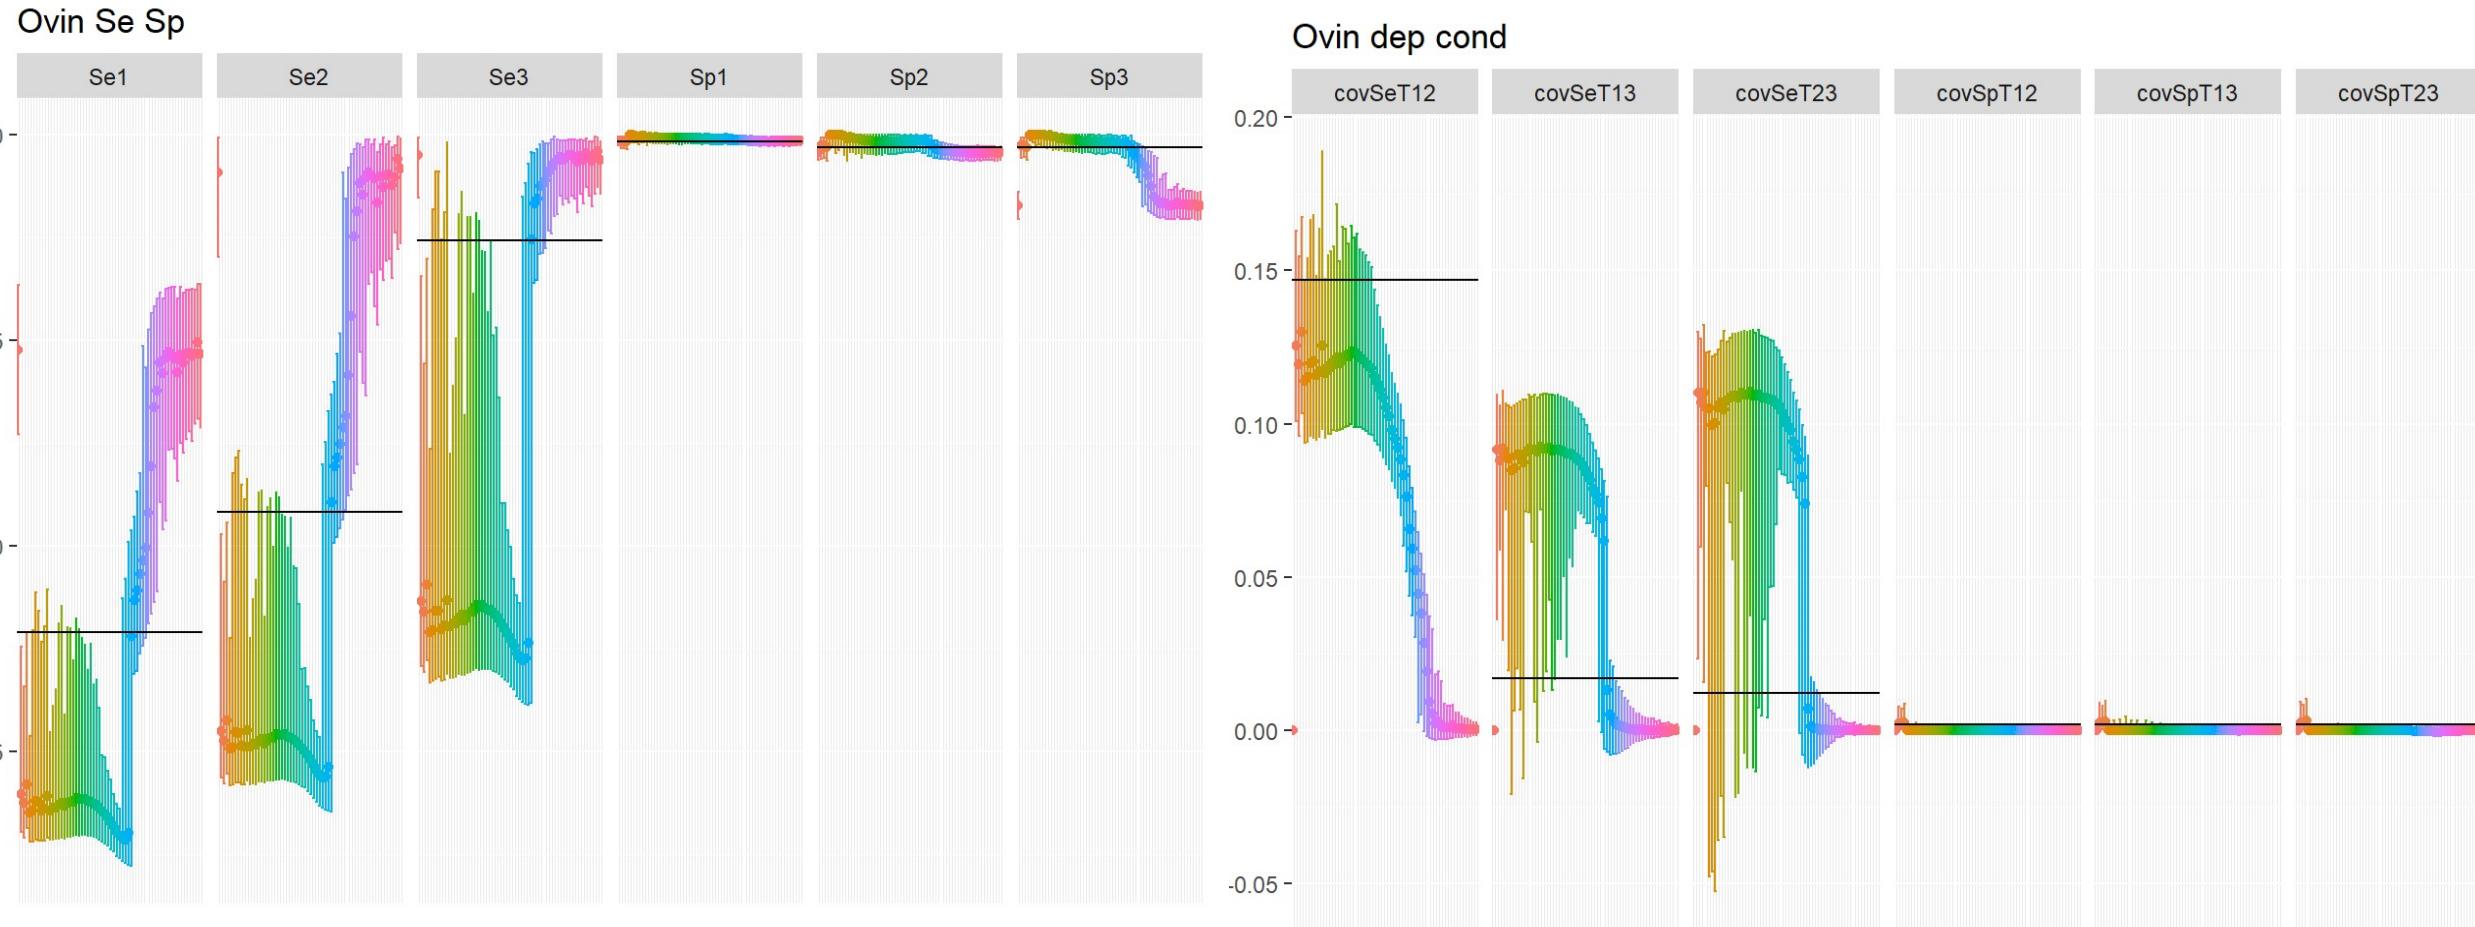
Bovin Se Sp



Bovin dep cond

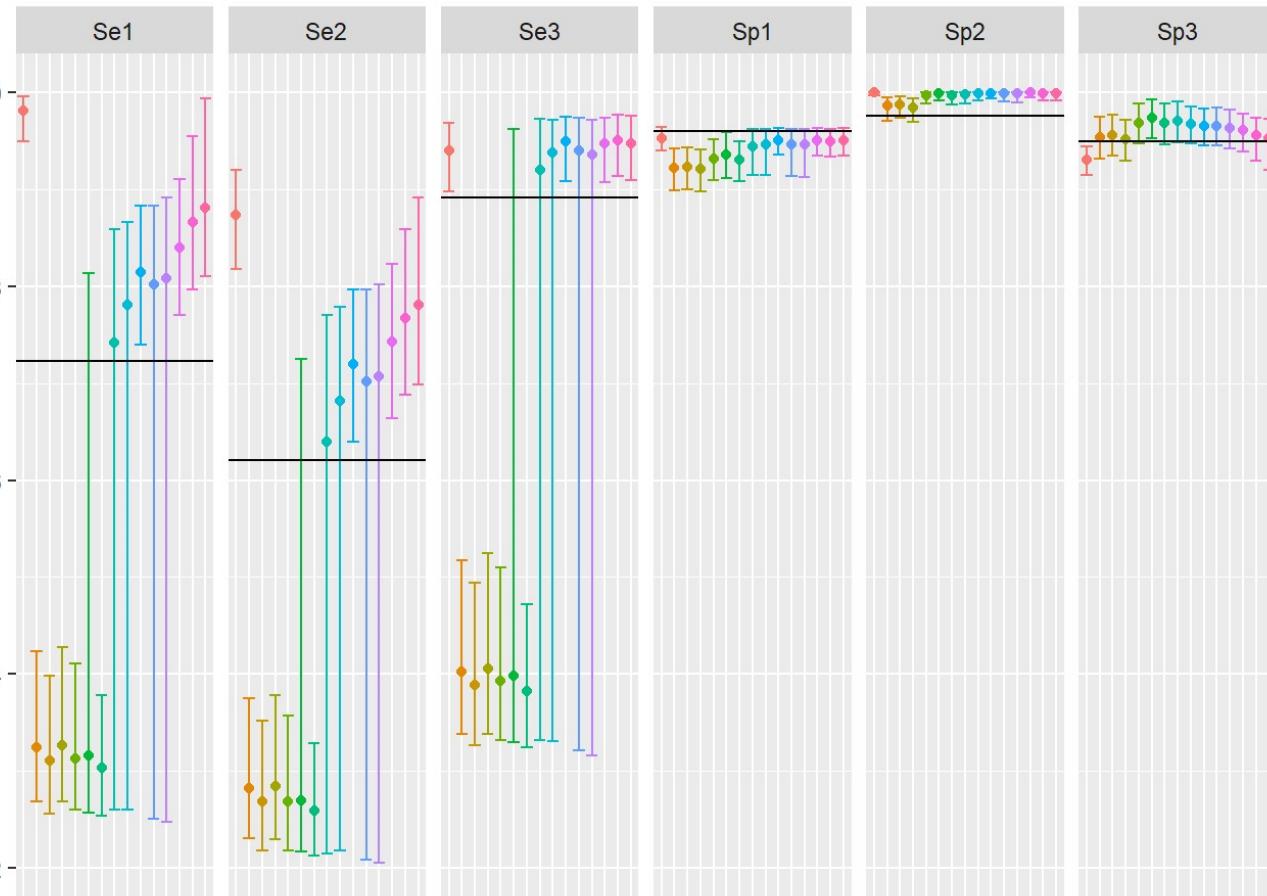


Estimation ovin

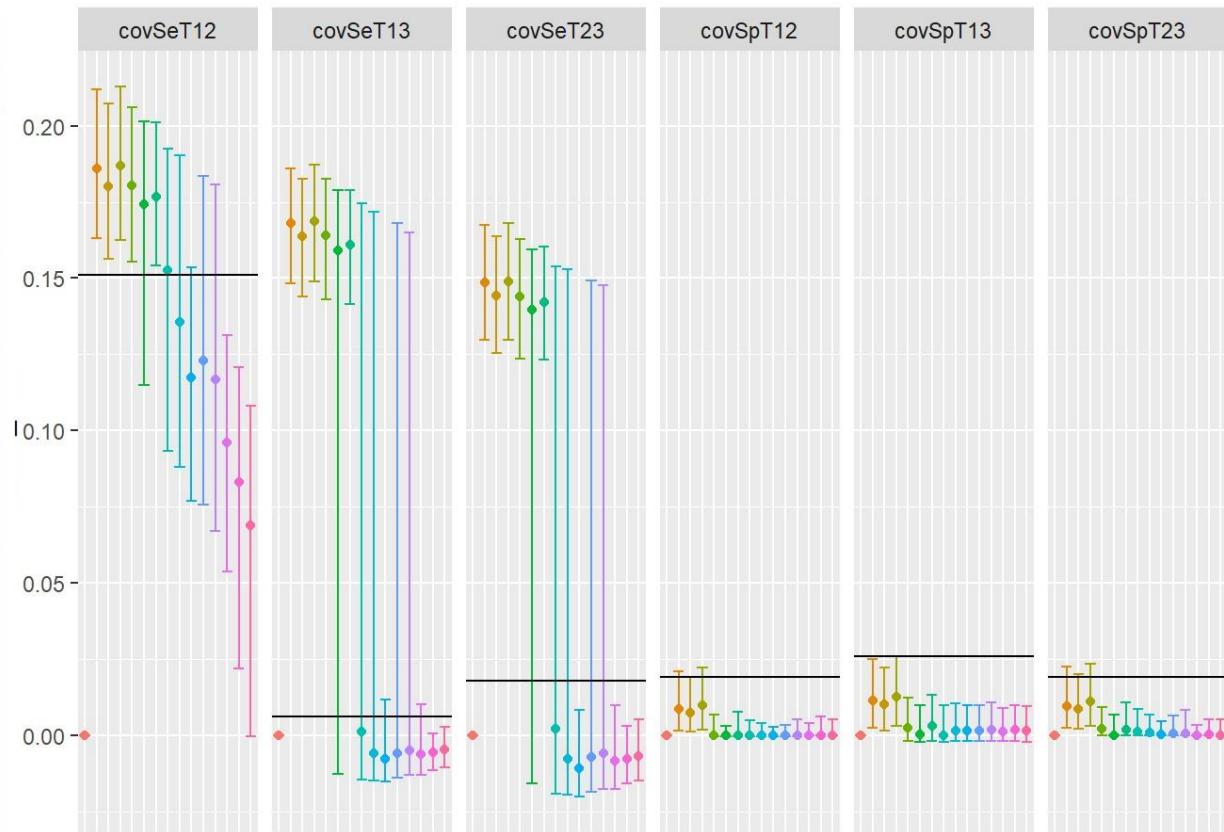


Estimation bovin

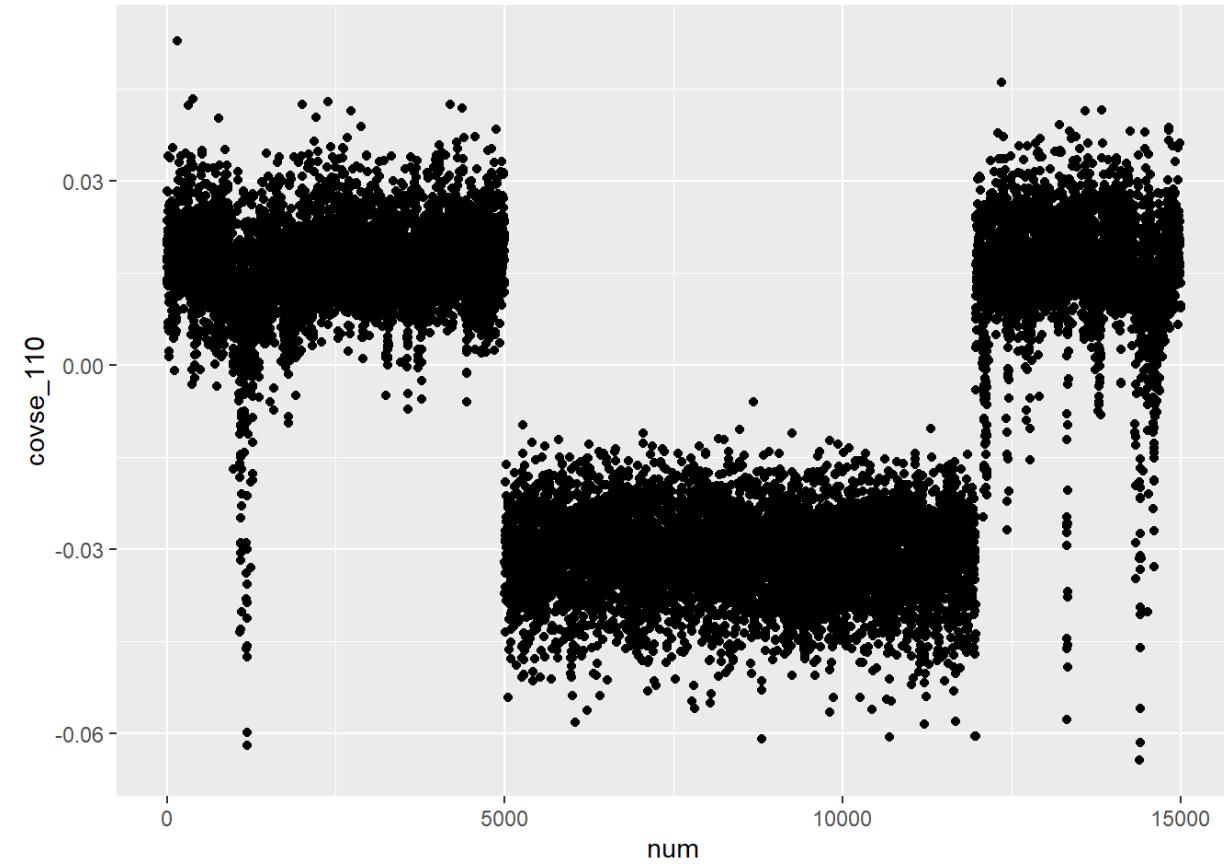
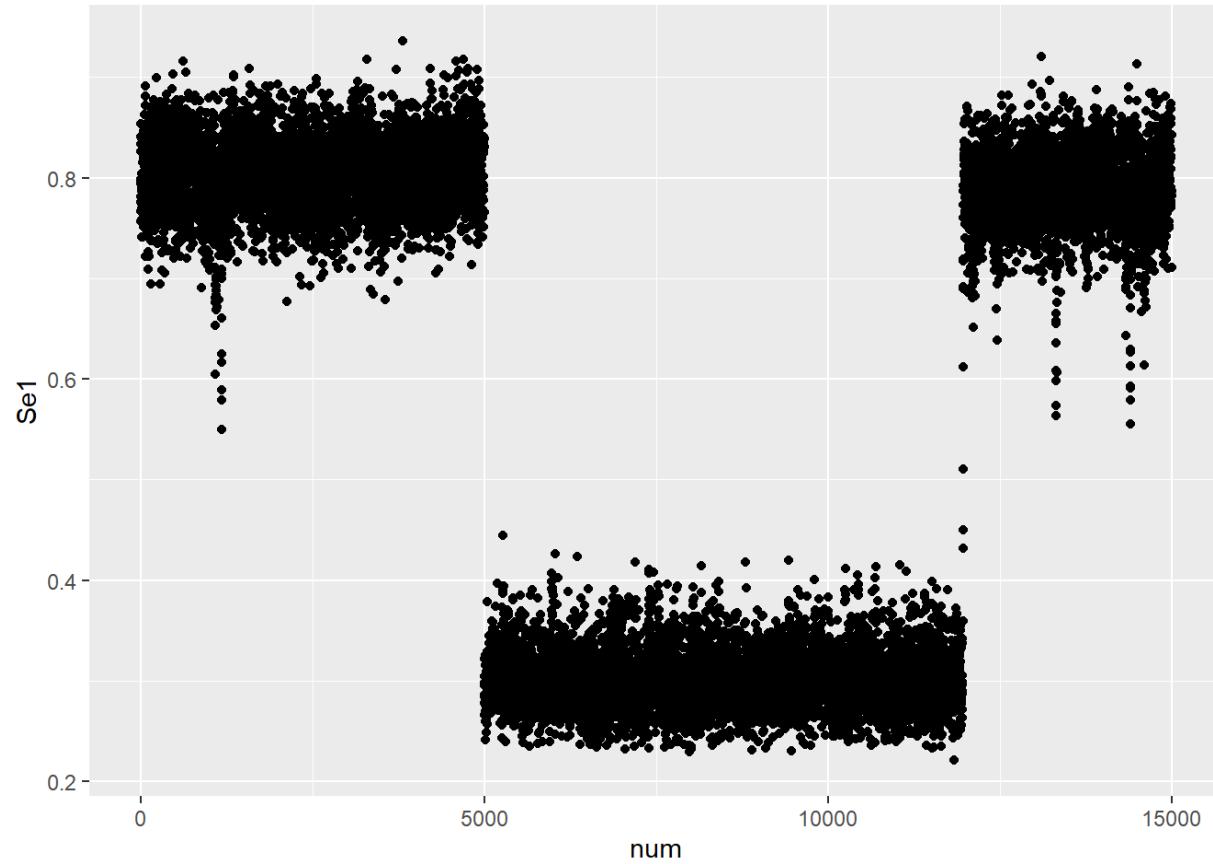
Bovin Se Sp



Bovin dep cond

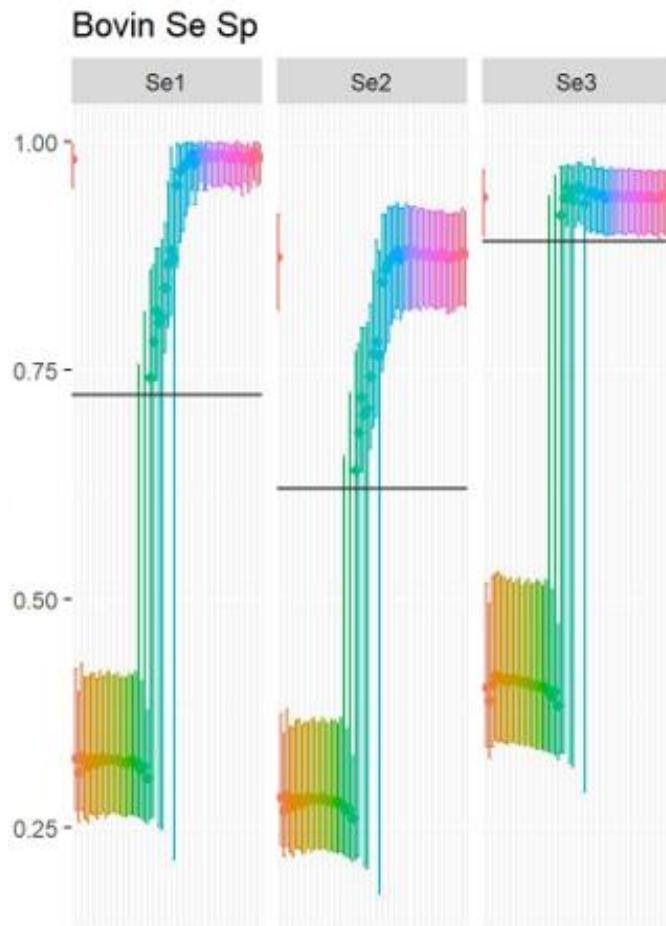


Trace, Se, CovSe, alpha = 22

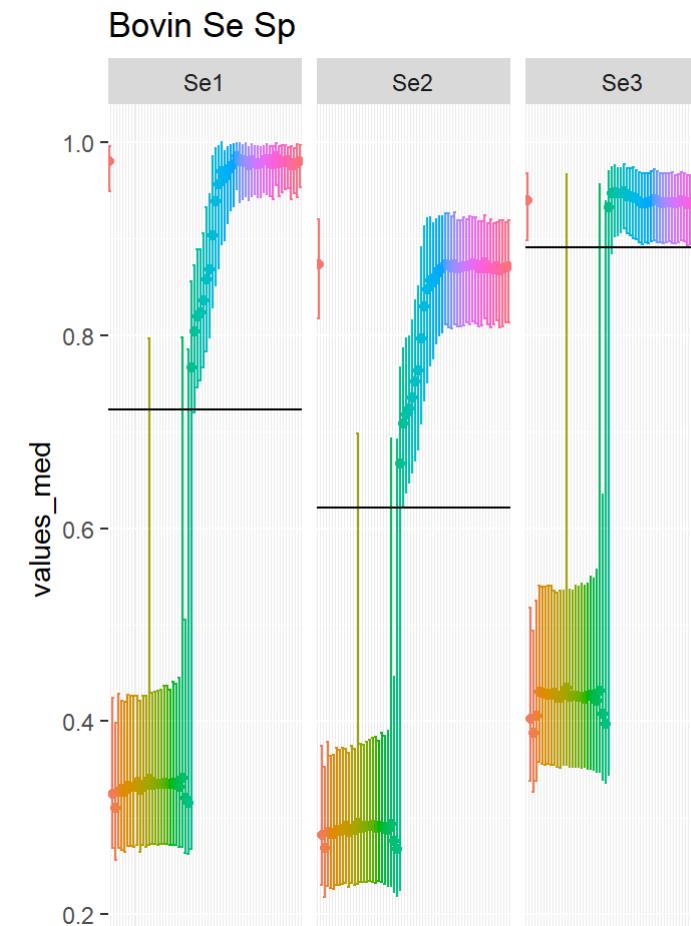


Distribution a priori sur les Se et Sp

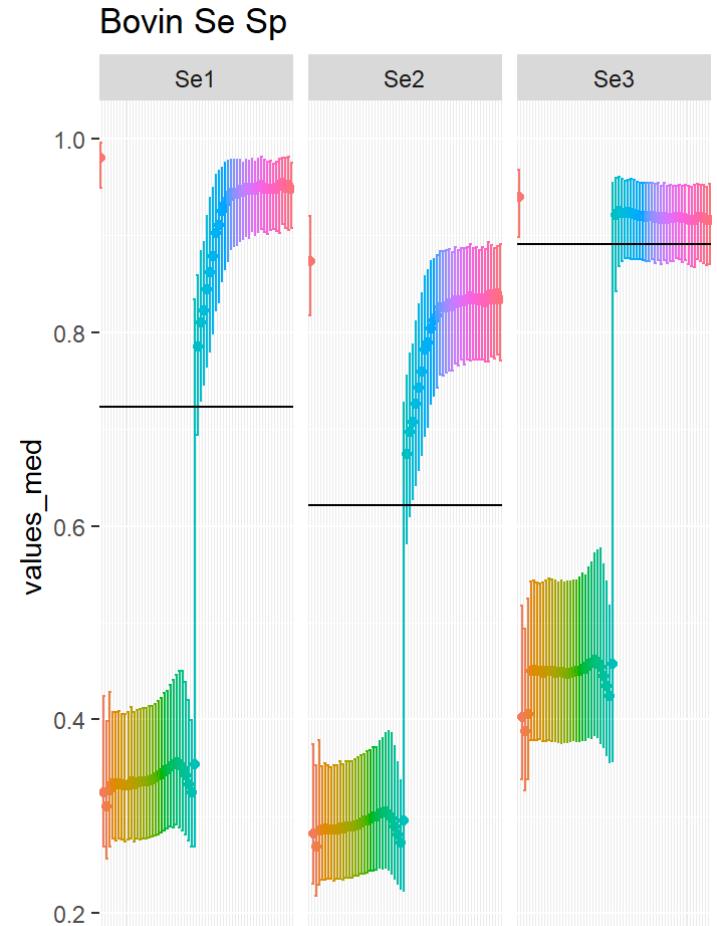
$Beta(0.5, 0.5)$



$Beta(1, 1)$



$Beta(5, 5)$



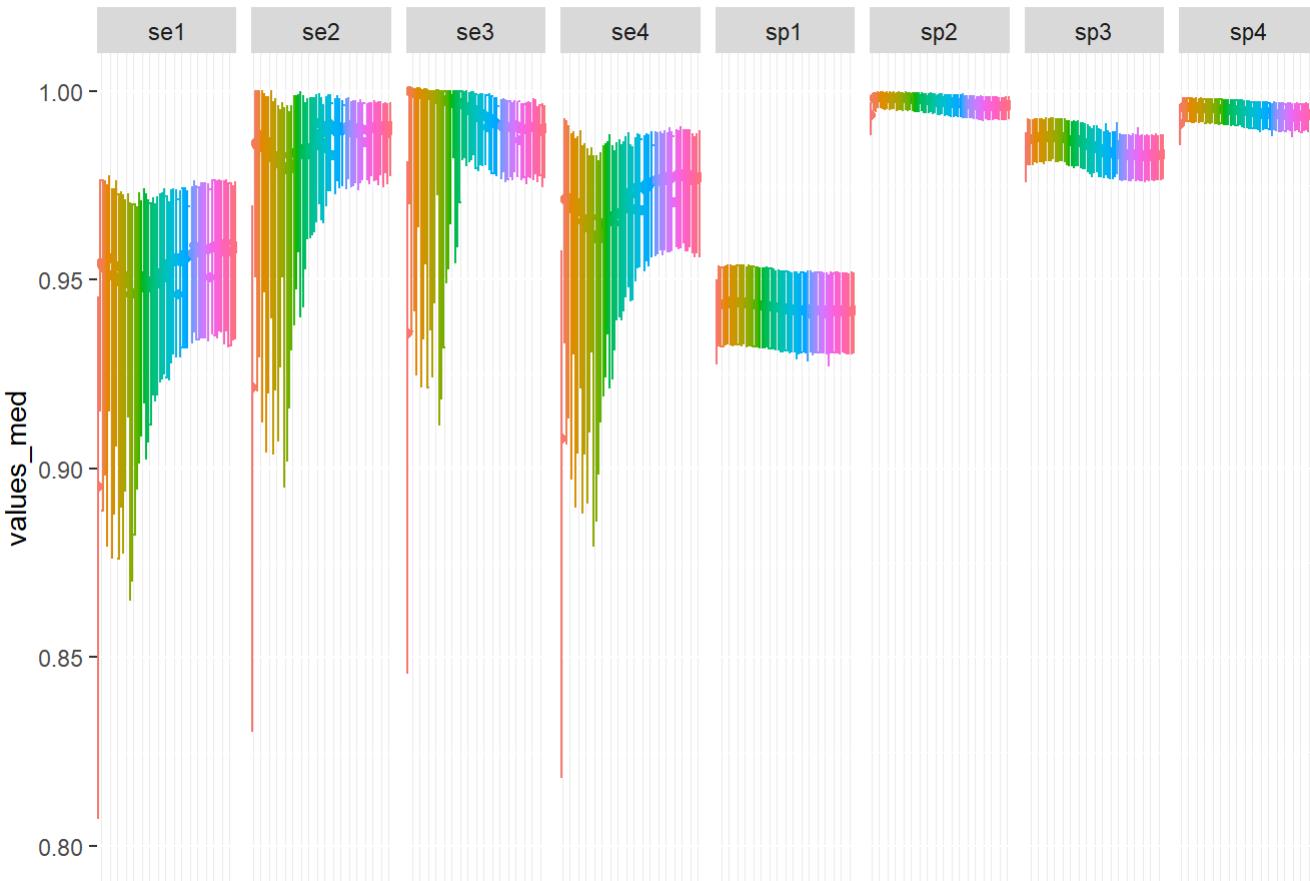
Bilan

- LCM paramétré en mélange de Dirichlet
 - Estimation similaire aux LCM classiques qui tendent à surestimer la dépendance conditionnelle
 - Plus facile à implémenter
 - Pas de contrainte sur les paramètres de dépendance conditionnelle
 - Plus rapide
- Avec hyper-paramétrisation
 - Exploration possible de solution avec moins de dépendance conditionnelle
 - Questionnement systématique de l'hypothèse d'indépendance conditionnelle?

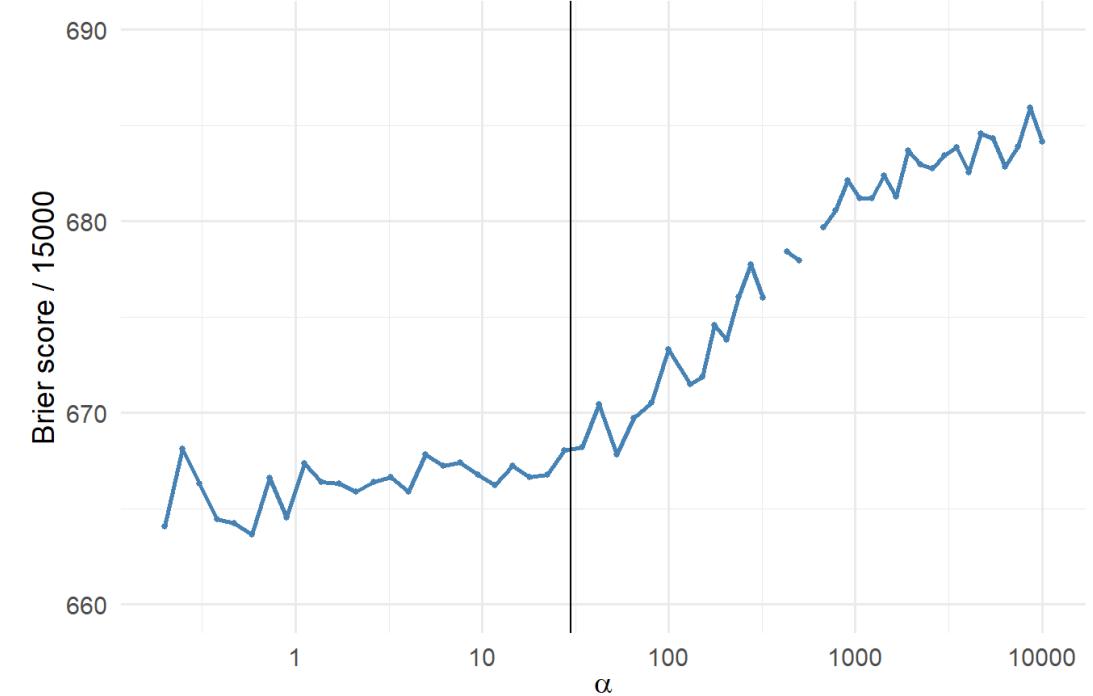
Sélection de la valeur de alpha?

- Scores de prédiction:
 - Pseudo Score de brier pour données multinomiales?

DP se sp



Brier Score vs Alpha (log scale)



Merci de votre attention