## Table des matières

I Bases théoriques ..... 1
1 Bases probabilistes utiles ..... 3
1.1 Introduction ..... 3
1.2 L'incertitude ..... 5
1.2.1 Aléa et variabilité naturelle ..... 5
1.2.2 Incertitude par ignorance ..... 7
1.2.3 Compléments ..... 8
1.2.4 Événements incertains ..... 10
1.3 Qu'est-ce qu'une probabilité? ..... 13
1.3.1 La probabilité par l'exemple ..... 13
1.3.2 Définition axiomatique et propriétés ..... 15
1.3.3 Extension au cas où l'univers est infini dénombrable ou continu ..... 16
1.3.4 La probabilité : une propriété de l'objet ..... 17
1.3.5 La probabilité : une propriété du sujet ..... 18
1.4 Probabilité conditionnelle et indépendance ..... 19
1.4.1 Probabilité conditionnelle et statistique bayésienne ..... 19
1.4.2 La probabilité conditionnelle par l'exemple ..... 20
1.4.3 Définition, propriétés et applications ..... 21
1.4.4 Indépendance stochastique ..... 23
1.4.5 La clé de voûte de la statistique bayésienne : la formule de Bayes ..... 25
1.4.6 Casse-têtes résolus par les probabilités conditionnelles ..... 29
1.5 Variable aléatoire et loi de probabilité ..... 35
1.5.1 Qu'est-ce qu'une variable aléatoire? ..... 35
1.5.2 Variables aléatoires discrètes ..... 38
1.5.3 Variables aléatoires continues ..... 46
1.5.4 Comment simuler une variable aléatoire? ..... 55
1.6 Couple de variables aléatoires ..... 55
1.6.1 Qu'est-ce qu'un couple de v.a.? Définition et exemples ..... 56
1.6.2 Couple de v.a. discrètes ..... 58
1.6.3 Couple de v.a. continues ..... 65
1.6.4 Modélisation d'un couple de v.a. ..... 67
2 Modélisation probabiliste ..... 71
2.1 Introduction ..... 71
2.1.1 La construction d'un modèle ..... 72
2.1.2 Les différents ingrédients d'un modèle probabiliste ..... 73
2.2 Lois de probabilité usuelles ..... 77
2.2.1 Loi de Bernoulli (et modèle d'urne) ..... 77
2.2.2 Loi binomiale ..... 78
2.2.3 Loi de Poisson ..... 79
2.2.4 Lois géométrique et exponentielle ..... 80
2.2.5 Loi normale ..... 82
2.2.6 Loi bêta ..... 84
2.2.7 Loi gamma ..... 85
2.2.8 Loi binormale ..... 87
3 Du classique au bayésien ..... 89
3.1 Introduction ..... 89
3.1.1 Propos ..... 89
3.1.2 Exemple discret : un modèle binomial ..... 90
3.1.3 Exemple continu : un modèle normal ..... 90
3.1.4 Modèle probabiliste versus inférence statistique ..... 91
3.2 Inférence statistique classique ..... 92
3.2.1 Estimation ..... 92
3.2.2 Propriétés des estimateurs ..... 95
3.2.3 Tests et intervalles de confiance ..... 95
3.3 Inférence statistique bayésienne ..... 102
3.3.1 Généralités ..... 102
3.3.2 Lois a priori et a posteriori ..... 103
3.3.3 Démarche ..... 110
3.3.4 Influence de la loi a priori et des données sur la loi a posteriori ..... 111
3.3.5 Estimation et intervalle de confiance en bayésien? ..... 113
3.4 Conclusion ..... 114
3.4.1 Récapitulatif de la démarche bayésienne ..... 115
3.4.2 Recommandations ..... 115
3.4.3 Pourquoi préférer le bayésien? ..... 116
4 La modélisation graphique ..... 121
4.1 Introduction ..... 121
4.2 Graphes et dépendances ..... 121
4.2.1 Graphes et graphes orientés ..... 121
4.2.2 Graphes acycliques orientés ou DAG ..... 123
4.2.3 Indépendance conditionnelle ..... 125
4.2.4 DAGs équivalents ..... 127
4.2.5 Réseau bayésien ..... 129
4.3 Corrélation n'est pas causalité ..... 130
4.4 Vers les structures hiérarchiques ..... 131
4.4.1 Un premier exemple simple ..... 131
4.4.2 Un second exemple ..... 133
4.4.3 Généralisation : la modélisation hiérarchique bayésienne ..... 137
4.5 Propriétés mathématiques des DAGs ..... 138
4.5.1 La factorisation de la loi jointe ..... 138
4.5.2 L'inférence bayésienne ..... 138
4.5.3 Loi conditionnelle complète dans un DAG ..... 140
4.6 Modèles multidimensionnels traditionnels ..... 142
4.6.1 Lois normales multidimensionnelles et GMRF ..... 142
4.6.2 Loi a posteriori de la moyenne ..... 143
4.6.3 Modèles normaux-Wishart ..... 144
4.6.4 Modèles Dirichlet-multinomiaux ou Polya ..... 146
4.7 Les logiciels ..... 148
4.8 Conclusions ..... 149
5 Méthodes numériques ..... 151
5.1 Introduction : pourquoi utiliser des méthodes numériques? ..... 151
5.2 Exemple d'illustration en épidémiologie spatiale ..... 153
5.2.1 Modèle dynamique ..... 154
5.2.2 Données et évaluation des lois a posteriori ..... 156
5.2.3 Lois a priori ..... 157
5.3 Méthode du ré-échantillonnage par importance ..... 158
5.3.1 Principe ..... 158
5.3.2 Application ..... 159
5.3.3 Limites ..... 160
5.3.4 Pour aller plus loin : échantillonnage séquentiel par importance ..... 161
5.4 Algorithme de Monte Carlo par chaînes de Markov ..... 163
5.4.1 Principe ..... 163
5.4.2 Echantillonneur de Gibbs ..... 164
5.4.3 Échantillonneur de Metropolis-Hastings ..... 165
5.4.4 Application 1 : échantillonnage complet ..... 165
5.4.5 Application 2 : échantillonnage incomplet temporellement ..... 168
5.4.6 Application 3 : échantillonnage incomplet spatialement et tem- porellement ..... 169
5.4.7 Limites ..... 171
5.4.8 Pour aller plus loin : algorithmes MCMC en interaction ..... 171
5.5 Calcul bayésien approché ou ABC ..... 173
5.5.1 Principe ..... 173
5.5.2 Limites ..... 174
5.6 Conclusion ..... 175
5.7 Annexe ..... 176
6 Évaluation de modèles ..... 179
6.1 Introduction ..... 179
6.2 Prédiction de la teneur en protéines du blé ..... 180
6.3 Analyse de sensibilité ..... 181
6.4 Qualité des prédictions a posteriori ..... 182
6.5 Validation croisée ..... 185
6.6 Facteur de Bayes ..... 187
6.7 Paradoxe de Lindley-Bartlett ..... 189
6.7.1 Test classique d'une hypothèse nulle ..... 189
6.7.2 Paradoxe de Lindley ..... 190
6.7.3 Paradoxe de Bartlett ..... 191
6.7.4 Mises en garde ..... 191
6.8 Critères de vraisemblance pénalisée ..... 192
6.9 Combinaison de modèles ..... 193
6.10 Conclusion ..... 195
7 Distributions a priori et élicitation ..... 197
7.1 Introduction ..... 197
7.2 Lois a priori conjuguées ..... 198
7.3 Lois a priori non informatives ..... 201
7.3.1 Lois a priori dispersées ..... 204
7.3.2 Lois a priori de Jeffreys ..... 207
7.3.3 Lois a priori de référence ..... 210
7.4 Élicitation de dires d'expert ..... 213
7.4.1 Introduction ..... 213
7.4.2 Le questionnement de l'expert ..... 214
7.4.3 La traduction des réponses en loi a priori ..... 223
II Cas d'études ..... 229
8 Modèle binomial et Listeria ..... 231
8.1 Études complètement comparables ..... 232
8.2 Variabilité inter-études ..... 237
8.3 Deux sous-populations? ..... 240
9 Régression pour la processionnaire du pin ..... 247
9.1 Dispositif expérimental ..... 247
9.2 Modèle de régression linéaire multiple ..... 250
9.2.1 Modèle ..... 250
9.2.2 Écriture matricielle et vraisemblance ..... 251
9.2.3 Lois a priori classiques pour l'inférence bayésienne ..... 252
9.2.4 Prendre des lois a priori conjuguées simplifie l'inférence bayé- sienne ..... 252
9.2.5 Loi a priori de Zellner pour le modèle linéaire ..... 254
9.3 Mise en pratique de la régression linéaire multiple ..... 256
9.3.1 Régression linéaire multiple sur la variable sans transformation ..... 257
9.3.2 Régression linéaire multiple sur la variable $\log (N b N i d s)$ ..... 258
9.3.3 Vérifier les hypothèses du modèle linéaire ..... 258
9.3.4 Estimation des paramètres et tests sur les paramètres ..... 263
9.4 Sélection de variables explicatives ..... 264
9.4.1 Contexte ..... 264
9.4.2 Principe de l'algorithme ..... 264
9.4.3 Lois a priori ..... 265
9.4.4 Résultats ..... 267
10 Modèle hiérarchique normal ..... 271
10.1 Introduction ..... 271
10.2 Les données de Potthoff et Roy ..... 272
10.2.1 Des mesures longitudinales entachées d'erreurs ..... 272
10.2.2 Objectifs de l'analyse statistique des données ..... 274
10.3 ANCOVA ..... 274
10.3.1 Modèle normal de vraisemblance ..... 274
10.3.2 Lois a priori ..... 275
10.3.3 Inférence ..... 276
10.3.4 Mise en œuvre sous WinBugs ..... 277
10.4 Modèle à effet aléatoire ..... 279
10.4.1 Construction ..... 279
10.5 Discussion ..... 283
10.5.1 Mise en évidence le dimorphisme sexuel ..... 283
10.5.2 Traiter facilement les données manquantes ..... 283
10.5.3 Borrowing strength ..... 284
10.5.4 Conclusions générales ..... 284
11 ABC et histoire démographique de bovins ..... 287
11.1 Contexte et objectif ..... 287
11.2 Les données microsatellites ..... 288
11.3 Implémentation du calcul bayésien approché ..... 289
11.3.1 Simulation de jeux de données ..... 289
11.3.2 Lois a priori pour les paramètres $\theta$ ..... 292
11.3.3 Choix des statistiques descriptives ..... 292
11.4 Pré-évaluation des lois a priori ..... 292
11.5 Estimation des lois a posteriori approchées ..... 293
11.6 Évaluation du modèle ..... 296
11.7 Conclusions ..... 296
12 Cas d'étude à explorer ..... 299
12.1 La catastrophe de Montroc ..... 299
12.1.1 Rappel des faits ..... 299
12.1.2 Le problème décisionnel ..... 299
12.1.3 Objectif ..... 300
12.1.4 Questions ..... 300
12.1.5 Solution ..... 302
12.2 Invertébrés épibenthiques du Golfe du St Laurent ..... 302
12.2.1 Contexte ..... 302
12.2.2 Objectif ..... 302
12.2.3 Données ..... 303
12.2.4 Questions ..... 304
12.3 Courbes de croissance de poulets ..... 306
12.3.1 Contexte ..... 306
12.3.2 Objectif ..... 306
12.3.3 Données ..... 306
12.3.4 Questions ..... 306
12.4 Risques de pollution de l'eau par les nitrates ..... 308
12.4.1 Contexte ..... 308
12.4.2 Objectif ..... 309
12.4.3 Données ..... 309
12.4.4 Questions ..... 309
12.5 Nombre de copies d'ADN ..... 311
12.5.1 Introduction ..... 311
12.5.2 Données . ..... 311
12.5.3 Questions ..... 313

