

# Les modèles EDD : Une famille de modèles nuls génériques pour les réseaux écologiques

Tâm Le Minh, Sophie Donnet, François Massol, Stéphane Robin

MIA-Paris, INRAE








5 avril 2022

Journées du GdR Écologie Statistique

# Étude des réseaux écologiques

Calcul de métriques globales :

- Connectance, Nestedness, Modularité
- Fréquences de motifs
- etc.



## Test d'hypothèse avec une statistique :

- On décide d'un niveau de significativité  $\alpha$ ,
- On calcule la distribution  $\mathcal{F}_0$  de la statistique associée à l'hypothèse nulle  $\mathcal{H}_0$ ,
- On construit une zone de rejet en fonction de  $\mathcal{F}_0$  et de  $\alpha$ ,
- Si la statistique observée est dans la zone de rejet, alors l'hypothèse  $\mathcal{H}_0$  est rejetée.

Le modèle nul génère des réseaux aléatoires utilisés pour calculer la distribution nulle  $\mathcal{F}_0$  de la statistique.

$\rightsquigarrow \mathcal{H}_0$  est donc déterminée par les hypothèses du modèle nul.

**Hypothèse écologique** : l'hétérogénéité de spécialisation entre espèces crée le patron d'intérêt.

- Contraintes sur les degrés des lignes et des colonnes (Connor et Simberloff, 1979)

↪ Cependant, le support de  $\mathcal{F}_0$  est restreint :

- Pourquoi conserver exactement les degrés ?
- Quelle distribution des réseaux générés ?

- Contraintes sur les espérances des degrés (Gilpin et Diamond, 1982, Gotelli et Graves, 1996)

↪ Par exemple :  $p_{ij} = \lambda \times p_i^{(r)} \times p_j^{(c)}$

Le réseau est organisé par les distributions de degrés (somme des arêtes d'un nœud) attendus.

## Notations

- Matrice d'adjacence du réseau  $Y$  de taille  $m \times n$
- Densité du réseau :  $\lambda$
- "Degré attendu" d'une ligne :  $f(U_i)$ ,  $U_i \sim \mathcal{U}[0, 1]$ ,  $\int f = 1$
- "Degré attendu" d'une colonne :  $g(V_j)$ ,  $V_j \sim \mathcal{U}[0, 1]$ ,  $\int g = 1$


$$U_i, V_j \stackrel{iid}{\sim} \mathcal{U}[0, 1]$$
$$Y_{ij} \mid U_i, V_j \sim \mathcal{P}(\lambda f(U_i)g(V_j))$$

On peut remplacer la loi d'émission par la loi qu'on souhaite (par exemple, une loi de Bernoulli pour les réseaux binaires).


# Les modèles EDD

$$U_i, V_j \stackrel{iid}{\sim} \mathcal{U}[0, 1]$$
$$Y_{ij} \mid U_i, V_j \sim \mathcal{P}(\lambda f(U_i)g(V_j))$$




$g_0(v) =$






$g(v) =$



$f_0(u) =$



$f(u) =$



Le modèle EDD est un modèle échangeable ligne-colonne : la loi jointe de la matrice est invariante par permutation des lignes ou des colonnes.

C'est un modèle raisonnable pour la plupart des problèmes car en général, on omet la taxonomie :

- La plupart des statistiques étudiées donnent des informations sur la topologie globale du réseau (nestedness, modularité, fréquences de motifs).
- Si on permute les lignes ou les colonnes de la matrice d'adjacence, elle représente toujours le même réseau.

Hoeffding (1948) :  $(X_1, \dots, X_n)$  variables i.i.d.


$$U = r! \binom{n}{r}^{-1} \sum_{1 \leq i_1 \neq \dots \neq i_r \leq n} h(X_{i_1}, \dots, X_{i_r}).$$

U-statistique sur une matrice  $m \times n$

$$U = m!n! \left[ \binom{m}{2} \binom{n}{2} \right]^{-1} \sum_{i_1 \neq i_2}^m \sum_{j_1 \neq j_2}^n h(Y_{\{i_1, i_2; j_1, j_2\}})$$

Exemple : fréquences de motifs

$$h(Y_{\{1,2;1,2\}}) = Y_{11} Y_{12} Y_{21} (1 - Y_{22})$$



## Rappel : Modèle EDD Poisson

$$\begin{aligned}U_i, V_j &\stackrel{iid}{\sim} \mathcal{U}[0, 1] \\ Y_{ij} \mid U_i, V_j &\sim \mathcal{P}(\lambda f(U_i)g(V_j))\end{aligned}$$

où :

- $\lambda = \mathbb{E}[Y_{ij}]$
- $\int f = \int g = 1, \int f^k = F_k, \int g^k = G_k.$

Quelques propriétés :

$$\rightarrow \mathbb{E}[Y_{i1j1}^2 - Y_{i1j1}] = \lambda^2 F_2 G_2$$

$$\rightarrow \mathbb{E}[Y_{i1j1} Y_{i1j2}] = \lambda^2 F_2$$

$$\rightarrow \mathbb{E}[Y_{i1j1} Y_{i2j1}] = \lambda^2 G_2$$

Estimateur  $\hat{\theta}_N := U_{cN, (1-c)N}^h \rightsquigarrow \mathbb{E}[\hat{\theta}_N] = \mathbb{E}[h(Y_{\{i_1, i_2; j_1, j_2\}})] = \theta$

TCL pour les modèles échangeables ligne-colonne (LM, 2021)

$$\sqrt{\frac{N}{V}}(\hat{\theta}_N - \theta) \xrightarrow[N \rightarrow \infty]{\mathcal{L}} \mathcal{N}(0, 1).$$


Les U-statistiques permettent de faire de l'inférence statistique avec un minimum d'hypothèses

- Estimation
- Intervalles de confiance
- Tests de comparaison


# Exemple : test sur $f$

$\mathcal{H}_0 : f \equiv 1$  contre  $\mathcal{H}_1 : f \neq 1$   
( $F_2 = 1$  contre  $F_2 > 1$ )




$g_0(v) =$






$g(v) =$



$f_0(u) =$



$f(u) =$



Les modèles EDD sont :

- des modèles nuls probabilistes génératifs  
     $\rightsquigarrow \mathcal{H}_0$  correspond à une hypothèse écologique,
- des modèles échangeables ligne-colonne  
     $\rightsquigarrow$  résultats de convergence des  $U$ -statistiques,
- des modèles semi-paramétriques mais les  $U$ -statistiques ne nécessitent pas de connaître les distributions de degrés  
     $\rightsquigarrow$  possibilité de faire de l'inférence avec le minimum d'hypothèses.

Le Minh, T. (2021). *U*-statistics on bipartite exchangeable networks. *arXiv preprint*, arXiv :2103.12597.

Merci de votre attention !

