

**Analyse de données
compositionnelles par recherche
de sous-graphes disjoints**

Emmanuel CURIS, Bruno SAUBAMÉA, Cynthia MARIE-CLAIRE

Introduction — Données compositionnelles

- ★ Données sur la composition d'un système
 - ➔ K constituants, 1 à K — q_i : quantité du i -ème
- ★ Exprimées en fraction d'un tout
 - ➔ Elles sont corrélées : somme imposée !
 - ➔ Changer l'une modifie toutes les autres

Applications en chimie, biologie...

- ★ Composition d'un mélange : fractions molaires, massiques
 - ➔ Composition des minéraux en oxydes (20 % de SiO_2 ...)
 - ➔ Composition des huiles en acides gras
- ➔ Composition en A. R. N. d'une cellule

Introduction — Origine de ces données

Contrainte intrinsèque du système...

- ★ Une quantité prédéfinie de matière se répartit entre diverses possibilités
 - ➔ Spéciation d'un élément en quantité totale imposée
 - ➔ Traceur entre divers organes, tissus...

Contrainte expérimentale « externe »

- ★ Chaque constituant est libre de varier
- ★ Le dosage utilise une quantité imposée du mélange
 - ➔ Dosage de fractions, plus de quantités
 - ➔ A. R. N., protéines...
 - ➔ Populations lymphocytaires

Introduction — Exemple des données d'expression

★ Des cellules sont isolées, mise en culture...

➔ K A. R. N. différents, $[ARN\ i] = q_i$

★ Les A. R. N. sont extraits de la culture

➔ K A. R. N. différents, $[ARN\ i] = q_i$

★ On isole une masse totale M d'A. R. N. pour quantification

➔ K A. R. N. différents, $[RNA\ i] = x_i = M \frac{q_i}{\sum_{j=1}^K q_j}$



★ $K^* < K$ A. R. N. différents sont quantifiés

➔ K^* A. R. N. différents, $[ARN\ i] = d_i = \lambda_i x_i = \lambda_i M \frac{q_i}{\sum_{j=1}^K q_j}$

Illustration des données compositionnelles ①

★ K = 4 composants différents, 2 conditions A & B

Réalité



Quantifié

Avec $M = 4$







Illustration des données compositionnelles ②



★ $K = 4$ composants différents, 2 conditions A & B

Réalité



Quantifié

Avec $M = 4$



Méthodes classiques — « alr »

- ★ Données brutes non-analysables Aitchison, 1982 ; 1984...
Egozcue, 2003
Filzmoser, 2009
...
 - ➔ Corrélées, sens de variation fortuit...
- ★ On choisit un constituant « de référence » (p. ex. le 1)
- ★ On calcule $r_{i,1} = q_i/q_1$ pour les $K - 1$ autres constituants
- ★ On travaille sur $\ln r_{i,1}$
 - ➔ Méthode du log des rapport : « alr »
- ★ Les résultats dépendent de la référence choisie
 - ➔ Comment choisir la référence ?
- ★ Le nombre de tests augmente avec K : perte de puissance !

Méthodes classiques — « clr »

- ★ On pose m_g la moyenne géométrique des K q_i
- ★ On calcule $r_{i,c}^c = q_i / m_g$ pour les K constituants
- ★ On travaille sur $\ln r_{i,c}^c$
 - ➔ Méthode du log des rapport centrés : « clr »
- ★ Les $r_{i,c}^c$ sont toujours compositionnels !
- ★ $r_{i,c}^c$ dépend de tous les constituants : s'il change, pourquoi ? est-ce dû au constituant i ?
- ★ Donne une information globale : « la composition a changé »

Méthodes classiques — « ilr »

- ★ On pose $m_{g,k}$ la moyenne géométrique des k derniers q_i
- ★ On calcule $r_i^i = q_i / m_{g,i+1}$ pour les $K - 1$ premiers constituants
- ★ On travaille sur $[(K - i)/(K - i + 1)]^{0,5} \ln r_i^i$
 - ➔ Méthode du log des rapport isométrique : « ilr »
- ★ Transformation complexe qui assure l'indépendance
- ★ r_i^i dépend des $K - i$ constituants suivants : s'il change, pourquoi ? est-ce dû au constituant i ?
 - ➔ Information globale : « la composition a changé »

Rationnel : les rapports ne sont pas faussés

★ Soient deux composants, i (q_i) et j (q_j)

$$x_i = \frac{q_i}{\sum_{k=1}^K q_k}$$

★ Rapport dans l'échantillon père : $r_{i,j} = \frac{q_i}{q_j}$

★ Rapport dans l'échantillon quantifié : $r_{i,j}^* = \frac{x_i}{x_j} = \frac{q_i}{q_j} = r_{i,j}$

★ Rapport quantifié : $r_{i,j}^Q = \frac{\lambda_i x_i}{\lambda_j x_j} = \frac{\lambda_i}{\lambda_j} r_{i,j}$

Conclusion

★ L'information sur les quantités relatives persiste

➔ Peut être celle cherchée (équilibre chimique..)

★ Comment interpréter cette information sinon ?

➔ Que signifie un changement du rapport moyen ?

Interpréter les modifications des rapports ①

★ Exemple : 2 composants, 3 changements possibles chacun

		composant i		
		<i>Inchangé</i>	<i>Double</i>	<i>Divisé par 2</i>
composant j	<i>Inchangé</i>	$r_{i,j}$ inchangé	$r_{i,j}$ doublé	$r_{i,j}$ divisé par 2
	<i>Double</i>	$r_{i,j}$ divisé par 2	$r_{i,j}$ inchangé	$r_{i,j} \times 1/4$
	$\times 1/2$	$r_{i,j}$ doublé	$r_{i,j} \times 4$	$r_{i,j}$ inchangé

Le rapport est inchangé

★ Les quantités des deux composants sont inchangées...


★ ... ou les deux ont été modifiées par le même facteur.

Si le passage de A à B ne modifie pas $r_{i,j}$, alors il a le même effet sur les quantités des composants i et j .

Construire un graphe des composants quantifiés

★ Nœuds du graphe : les K^* composants quantifiés

★ Les nœuds i et j sont reliés ssi $r_{i,j}$ est inchangé




Interpréter les changements des rapports ②

- ★ Plusieurs sous-graphes disjoints
 - ➔ Chacun est complètement connexe
- ★ Chaque sous-graphe correspond à une variation différente
 - ➔ Au plus un pour « pas de changement »
 - ➔ Mais impossible de savoir lequel...


Limitation des données compositionnelles

- ★ En pratique, les résultats ne sont pas aussi tranchés
 - ➔ Connexions indues entre les nœuds...
 - ➔ Connexions absentes entre les nœuds...

Exemple 1



Exemple 2



Déterminer des groupes de composants

Comment gérer les fausses connexions ?

- ★ Ne considérer que les sous-graphes disjoints
 - ➔ même s'il manque des connexions dedans
 - ➔ très sensible aux variations non-détectées
- ★ Ne considérer que les ensembles connexes de nœuds
 - ➔ cliques et cliques maximales
 - ➔ très sensible aux fausses variations
 - ➔ calculs longs pour les grands graphes (RNAseq..)
- ★ Recherche de communautés
 - ➔ Plusieurs définitions & algorithmes...

Déterminer si un rapport a été modifié

★ *Étape clef de la méthode*

➔ Détermine la structure du graphe !

★ Estimer la variation du rapport

➔ Modèle statistique adapté au plan expérimental

➔ Variation cherchée : l'un des paramètres du modèle, θ

➔ Typiquement : modèle log-linéaire

★ Les nœuds i et j sont déliés si $r_{i,j}^B / r_{i,j}^A$ est significativement différent de 1

➔ Dans le modèle, si le test de θ est significatif

★ Quel niveau (« seuil de p ») utiliser pour ce test ?



Choix du niveau du test — sous-graphes disjoints ①

- ★ Observation : « Au moins deux graphes disjoints »
 - ➔ Si aucun changement, doit arriver avec prob. $< \alpha$ (H_0)
 - ➔ Quel niveau α_0 utiliser dans le test du rapport ?
- ★ Se produit si un nœud (le 1) n'a aucune connexion
 - ➔ Si *tous* les rapports $r_{1, j}$ sont significativement modifiés
 - ➔ Aucune correction de multiplicité nécessaire
- ★ Si les tests étaient indépendants, $\Pr(\text{TSM}|H_0) = \alpha = \alpha_0^{K^* - 1}$
 - ➔ α_0 doit être (bien) plus grand que α
- ★ Les tests ne sont **pas** indépendants. Et doit être vrai pour tous les nœuds...

Choix du niveau du test — graphes disjoints (2)

Résultats de simulation

- ★ Valeurs log-normales, sous H_0 , somme valant 1
- ★ 10 000 simulations, avec $K = 200$ composants






Et pour la puissance ?

- ★ Simulations précédentes : risque de détecter des composants se comportant différemment, quand tous se comportent de façon identique (« rejet de H_0 quand elle est vraie »)
- ★ Comment se comporte la méthode quand certains composants se comportent réellement différemment ?
 - ➔ Détecte-t-elle des graphes disjoints ? (*puissance*)
 - ➔ Détecte-t-elle les bons groupes de composants ?
- ★ Dépend de la puissance de chaque test individuel
- ★ Difficile de comparer à la méthode classique alr
 - ➔ Posent des questions légèrement différentes...

Étude de l'exemple 1 — conditions de simulation

★ K = 4 composants, 2 conditions A & B, 1 composant triple

Réalité



★ Distribution log-normale ; CV = 20 %

★ $n = 3$ par condition (puissance individuelle > 80 %)


★ Méthode alr : référence = composant 1

Graphique théorique

Étude de l'exemple 1 — choix du seuil (risque α)


★ La méthode alr « brute » ne contrôle pas α

➔ Correction de multiplicité (ici, Holm) indispensable





Étude de l'exemple 1 — étude de la puissance totale

- ★ On rejette H_0 pour n'importe quelle raison
 - ➔ Il se passe quelque chose (pas forcément ce qui est observé !)
- ★ Méthode alr : composants 2 ou 3 ou 4 détectés
- ★ Méthode proposée : graphe disjoint, quel qu'il soit
- ★ En pratique les deux méthodes sont aussi puissantes
 - ➔ Mais la correction de multiplicité en alr a un prix !




Exemple 1 — trouve-t-on le bon composant ?



Méthode proposée


Une seule de ces arêtes peut manquer, au plus, pour conclure correctement

Soit 4 graphes acceptables (sur 2^6 possibles)




Méthode alr

Ces arêtes peuvent, ou non, exister — la conclusion est identique



Application en qRT-PCR: un exemple ①

- ★ 2 groupes de patients bipolaires (répond [R, $n = 19$] ou non [NR, $n = 19$] au lithium)
- ★ Leurs lymphocytes sont cultivés avec et sans lithium
- ★ 17 candidats + 2 références



Geoffroy et coll., 2017

Modèle

$$\ln r_{i,j} = \mu_0 + \underbrace{U_P}_{\text{Effet patient}} + \underbrace{\delta_R \mathbf{1}_R}_{\text{Différence basale}} + \underbrace{\delta_{Li} \mathbf{1}_{Li}}_{\text{Effet du lithium chez les patients NR}} + \underbrace{\delta_I \mathbf{1}_R \mathbf{1}_{Li}}_{\text{Effet additionnel du lithium chez les patients R}} + \varepsilon$$

Application en qRT-PCR : un exemple ②


★ Modèle linéaire à effets mixtes, avec lme4 (R)

➡ Coefficients testés par test de Wald asymptotique


★ Critère : sous-graphes disjoints

★ $K^* = 23$ nœuds ➡ $\alpha_0 = 0,25$ pour avoir $\alpha < 0.05$


Comparaison
R vs NR, basal



Effet de Li^+
chez les NR



Effet différentiel
de Li^+



Quelques limitations de la méthode...

- ★ Nombre de tests augmente avec K^* comme K^{*2}
 - ➔ Temps et mémoire nécessaires augmentent « vite »
 - ➔ Peut être problématique en RNAseq ($K^* \approx 2 \times 10^4$)
- ★ Taille du graphe augmente avec K^*
 - ➔ Temps d'analyse du graphe peuvent devenir longs (cliques, communautés...)
- ★ Impossible de savoir comment varie un gène donné
 - ➔ Limite du plan expérimental, pas de la méthode...
- ★ Gestion des valeurs non-quantifiables délicate
 - ➔ Division par 0...

... et quelques avantages

- ★ Pas besoin d'hypothèse sur des gènes de référence invariants
- ★ Pas de correction de multiplicité
 - ➔ Moins de perte de puissance quand K^* augmente...
- ★ Rapports au sein d'une préparation
 - ➔ Insensible aux erreurs sur la masse M prélevée...
- ★ Insensible aux différences d'efficacité de quantification entre A. R. N.
 - ➔ tant qu'elles ne dépendent pas des conditions comparées !
- ★ RNASeq : insensible aux profondeurs de séquençage...

Merci de votre attention !