

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

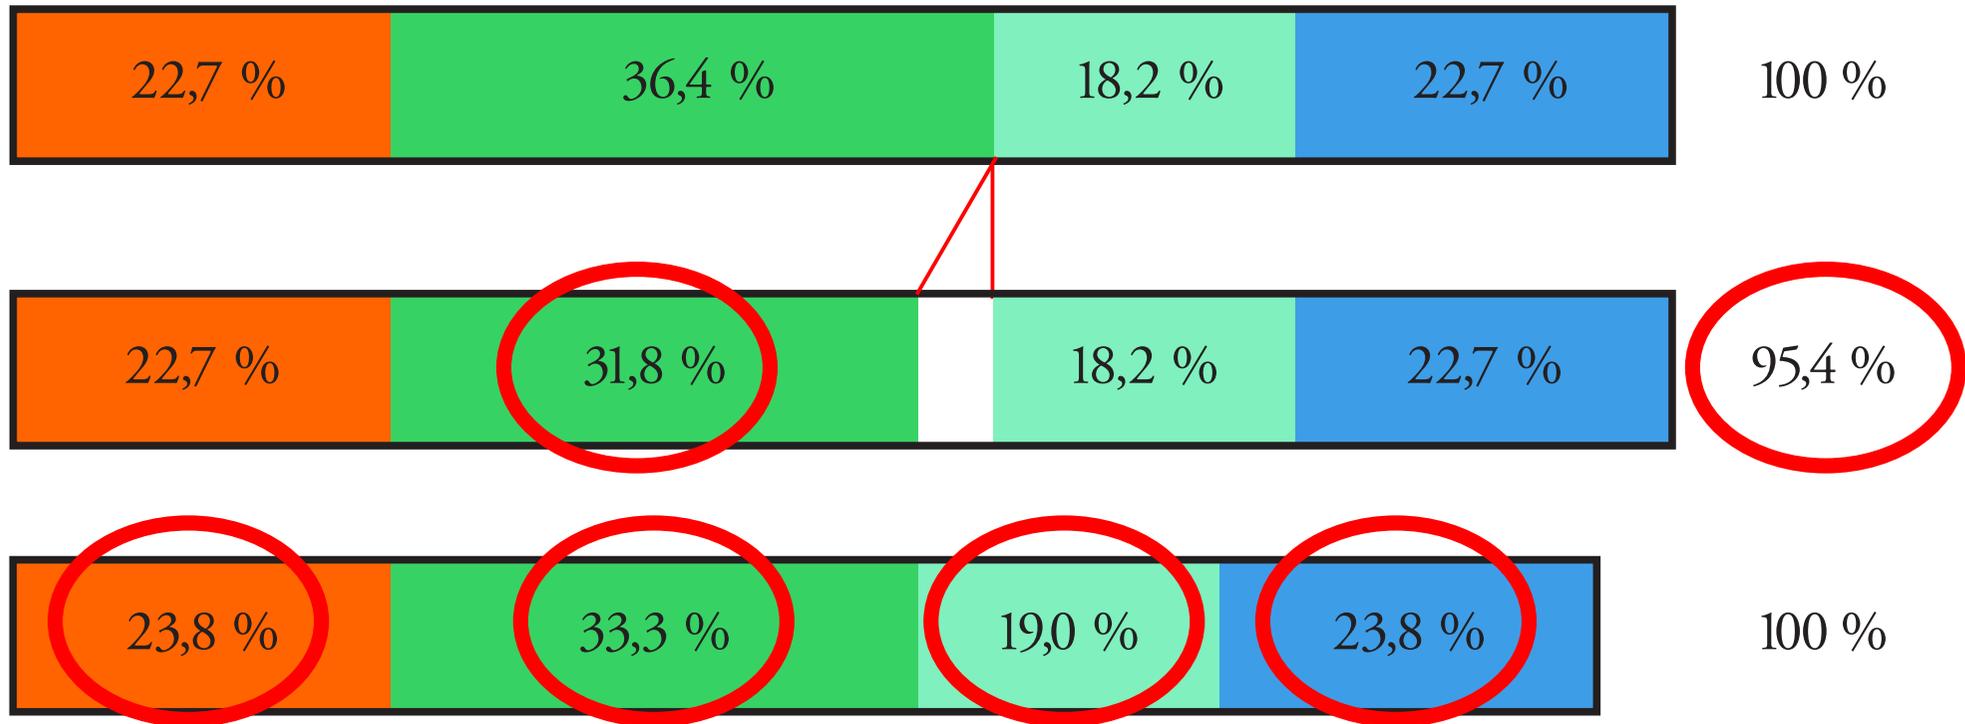
Emmanuel CURIS, Cynthia MARIE-CLAIRE

Introduction — Données compositionnelles ①

★ 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

Introduction — Données compositionnelles ②

Applications en chimie, géologie, archéologie...

- ★ Composition d'un mélange : fractions molaires, massiques
 - ⇒ Composition des minéraux en oxydes (20 % de SiO_2 ...)

Applications en biologie...

- ★ Des situations « évidentes »...
 - ⇒ pourcentage de leukocytes de chaque type
 - ⇒ pourcentage de temps passé dans chaque branche
- ★ ... et d'autres plus inattendues !
 - ⇒ Données d'expression (quantification des A. R. N.)
 - ⇒ Données de métabolomique
 - ⇒ Histologie des champs microscopiques...

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

Les notations...

★ K : nombre total de constituant

⇒ i, j : indice identifiant le constituant

★ q_i : quantité (absolue) du constituant i

⇒ masse (g), quantité de matière (mol)...

★ x_i : proportion du constituant i dans le total

⇒ fraction molaire, fraction massique...

⇒
$$x_i = \frac{q_i}{\sum_{j=1}^K q_j}$$

★ On utilisera aussi (souvent) $\ln x_i$

Le Cas particulier $K = 2$

Cas particulier : $K = 2$

★ En théorie, on peut analyser au choix l'une des deux composantes (x_1 ou x_2)

➔ l'autre varie nécessairement dans l'autre sens

➔ laquelle choisir ?

➔ puisque contraint entre 0 et 100 %, problèmes sur les bords

★ Transformation classique :

$$z = \ln \frac{x_1}{x_2} = \ln \frac{x_1}{1 - x_1} = -\ln \frac{x_2}{1 - x_2}$$

➔ Une seule analyse à réaliser incluant toutes les données

➔ Transformation (régression) logistique...

Cas particulier : $K = 2$

Exemple applicatif : test d'anhédonie

- ★ Dans leur cage, les souris ont le choix entre deux boissons
 - ➔ une bouteille d'eau plate ;
 - ➔ une bouteille d'eau sucrée (saccharose).

- ★ On mesure le volume consommé de chaque boisson par la souris pendant une période donnée
 - ➔ Q_1 : volume d'eau plate ; Q_2 : volume d'eau sucrée.
 - ➔ Normalement, la souris consomme davantage d'eau sucrée ($Q_2 > Q_1$)

- ★ Souvent exprimé en proportion : $P = Q_2 / (Q_1 + Q_2)$
 - ➔ Un traitement a-t-il un effet sur cette proportion ?

Cas particulier : $K = 2$ — Exemple ①

★ Représentation sous forme de graphe

- ➔ 2 composants : 2 nœuds (sommets), au plus une arête
- ➔ Les nœuds sont reliés s'ils se comportent « pareil »


Avant traitement



Volume total de boisson
 $Q_1 + Q_2$ (libre)

Après traitement...

... sans effet



... ayant un effet



Cas particulier : $K = 2$ — Exemple ②

Expériences d'Anne-Sophie HANNAK, UMR-S 1144

★ Effet du lithium sur l'état hédonique des rats

➡ Trois groupes : NaCl, NaHCO₃ et Li₂CO₃

➡ Deux temps : 24 et 48 h — pour les mêmes rats

➡ 8 rats par groupe

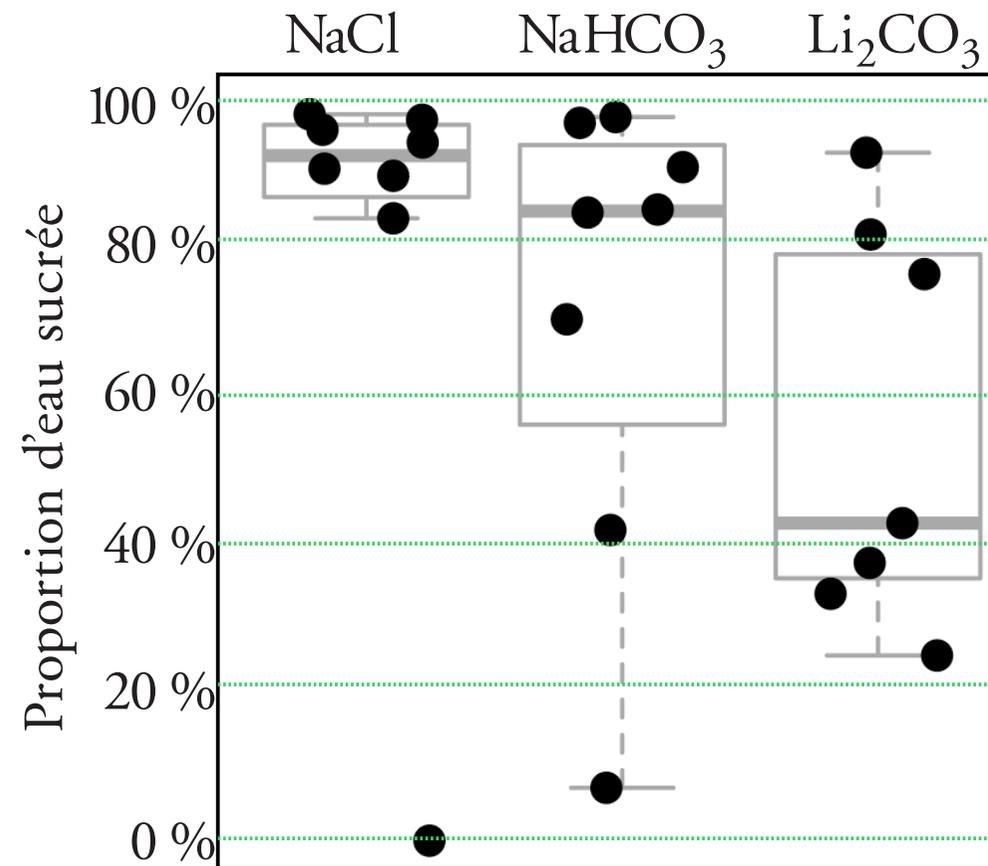
★ Données à 24 h utilisées ici

★ Résultats évidents

➡ Un rat atypique (NaCl)

➡ Effet anhédonique du carbonate

★ Et le lithium ?



Cas particulier : $K = 2$ — Exemple ③

Test global

★ Analyse de variance à un facteur

➔ Sur les proportions : $p = 0,0366$

➔ Sur les $\ln(X_2 / X_1) = \ln(Q_2 / Q_1)$: $p = 0,0273$

➔ Q_1 et Q_2 se comportent différemment



Test pour le lithium

★ Test de Student

➔ Sur les proportions : $p = 0,3131$

➔ Sur les $\ln(X_2 / X_1)$: $p = 0,3027$

➔ Échec à montrer que Q_1 et Q_2 se comportent différemment



Le Cas général ($K > 2$)

Méthodes classiques ($K > 2$) — « 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 ($K > 2$) — « 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 ($K > 2$) — « 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, x_i) et j (q_j, x_j)

★ Rapport des quantités réelles : $r_{i,j} = \frac{q_i}{q_j}$

★ Rapport des quantités relatives :

$$r_{i,j}^* = \frac{x_i}{x_j} = \frac{q_i}{\sum_{k=1}^K q_k} \bigg/ \frac{q_j}{\sum_{k=1}^K q_k} = \frac{q_i}{q_j} = r_{i,j}$$

★ 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>Doublé</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>Doublé</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...

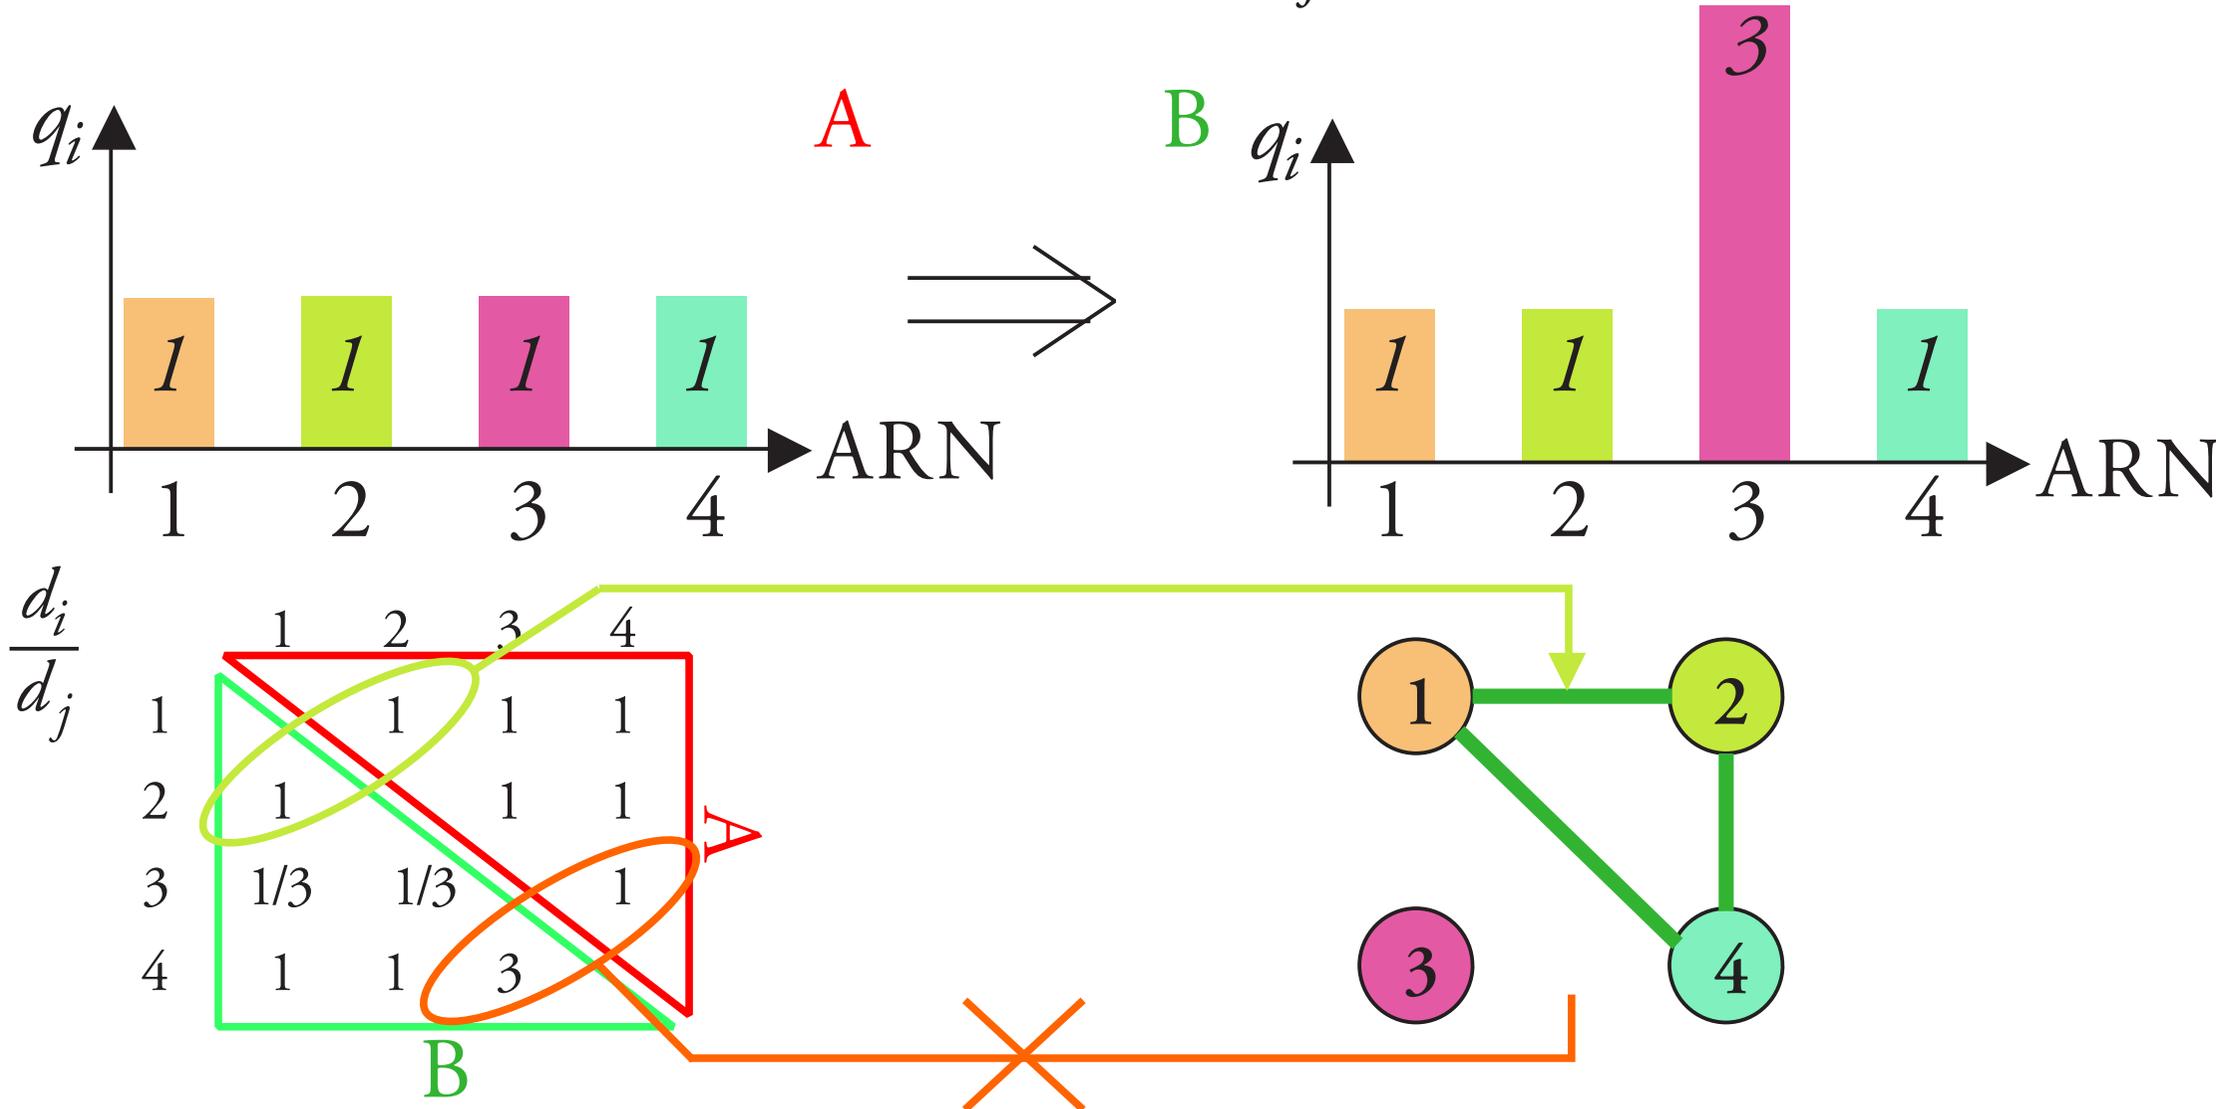
★ ... ou les deux ont été modifiées par le même facteur.

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 »

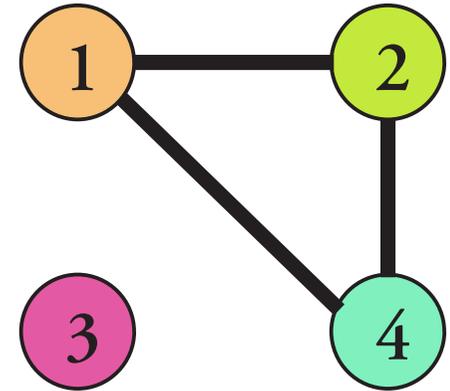
➔ Mais impossible de savoir lequel...

Limitation des données compositionnelles

★ En pratique, les résultats ne seront pas aussi tranchés

➔ Connexions indues entre les nœuds...

➔ Connexions absentes entre les nœuds...



Comment construire le graphe empirique ? ①

- ★ Les nœuds sont connus : composants quantifiés
- ★ En revanche, les arêtes ne le sont pas
 - ➔ Il faut une règle pour mettre ou pas les arêtes
 - ➔ Deux approches possibles : constructive et destructive
 - ➔ Dans les deux cas, il faut tester toutes les arêtes...

Approche constructive

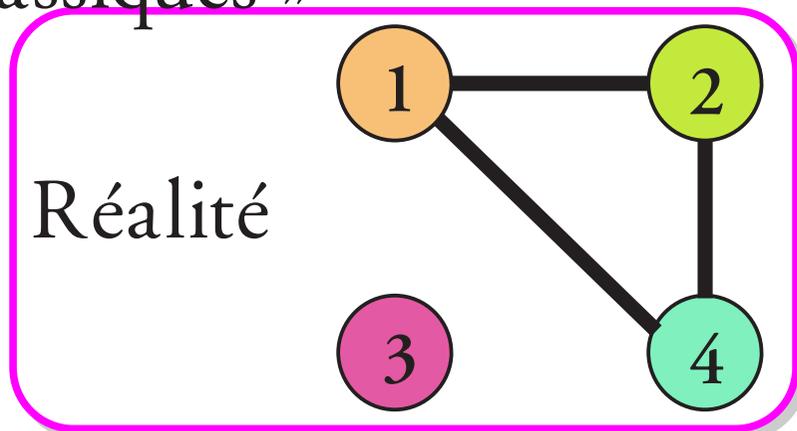
- ★ On part d'un graphe sans aucune arête
- ★ On ajoute une arête entre deux constituants si l'on prouve qu'ils se comportent (suffisamment) pareil
 - ➔ Utilisation de tests d'équivalence

Comment construire le graphe empirique ? ②

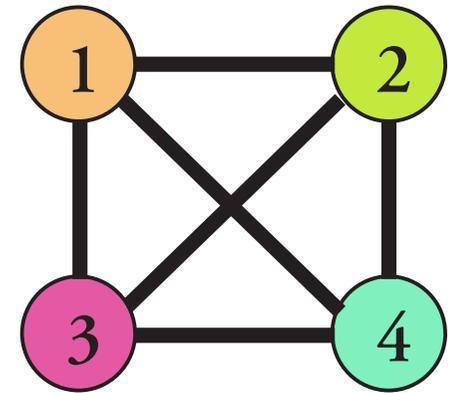
- ★ Approche « destructive »
 - ➔ On suppose le graphe complet (toutes les arêtes sont présentes)

- ★ On supprime l'arête entre deux constituants si l'on prouve qu'ils se comportent différemment

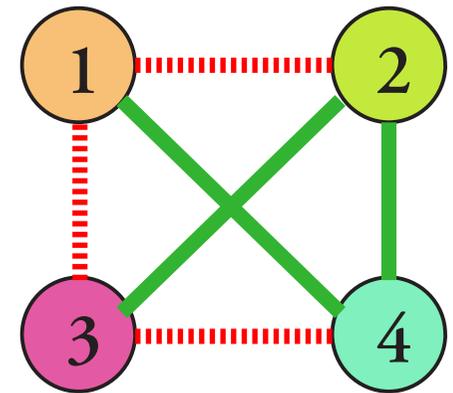
- ➔ Utilisation de tests de différence, « classiques »



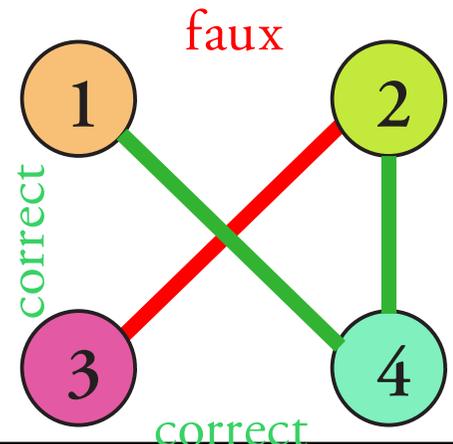
Départ



$p < \alpha$
 $p > \alpha$



Résultat
Incorrect
Correct



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 ?

Exemple 2 : Perfusion d'un traceur ①

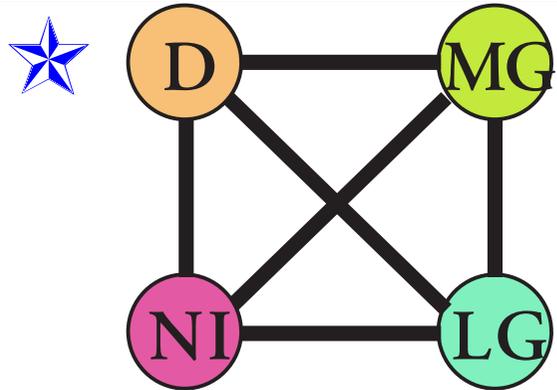
Données de Charles-Henry COTTART

- ★ Modèle murin d'ischémie-reperfusion du foie
 - ➔ Trois lobes ischémiés puis reperfusés (LMD, LMG, LLG)
 - ➔ Deux lobes non-ischémiés (groupés en NI)
- ★ Injection de micro-particules luminescentes (traceur)
- ★ Quatre groupes de souris
 - ➔ groupe témoin
 - ➔ groupe ischémié, non-reperfusé
 - ➔ groupes ischémiés et reperfusés, avec particules injectés après 20 s et 5 min de reperfusion

Exemple 2 : Perfusion d'un traceur ②

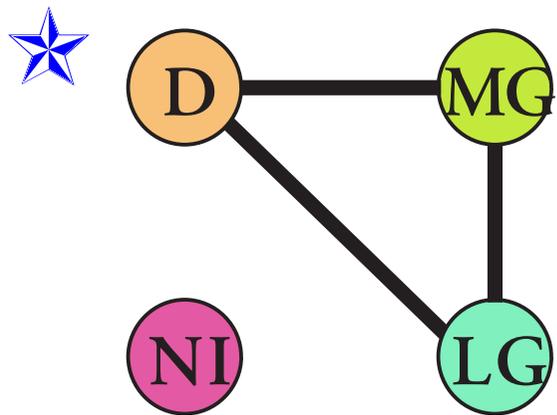
- ★ Pour cet exemple, on se limite aux groupes « témoin » et « ischémié, non-reperfusé »
 - ➔ Contrôle positif : l'ischémie modifie-t-elle la perfusion des lobes ? Normalement oui...
- ★ Quantification par fluorescence des particules dans chaque lobe hépatique
 - ➔ La quantité totale injectée est répartie entre ces lobes
 - ➔ Données compositionnelles par nature !
- ★ $K = 4$ « composants » — LMD, LMG, LLG et NI
 - ➔ Quels graphes sont possibles ?

Exemple 2 : Les Principaux Graphes possibles



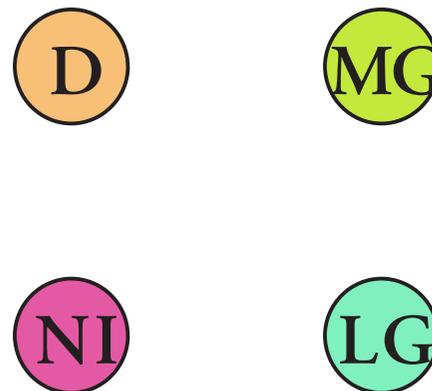
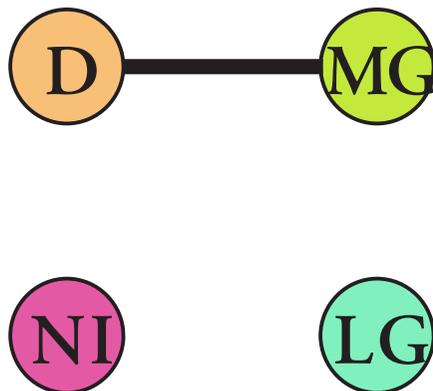
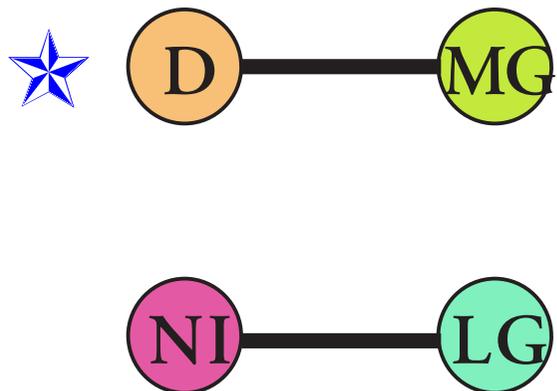
Aucune
différence

L'ischémie n'a pas eu
lieu ou est totale
Expérience ratée...



3 lobes similaires
1 lobe différent

Lobes NI : perfusion
augmentée ou inchangée
Autres lobes : perfusion
diminuée voire nulle
Expérience réussie...



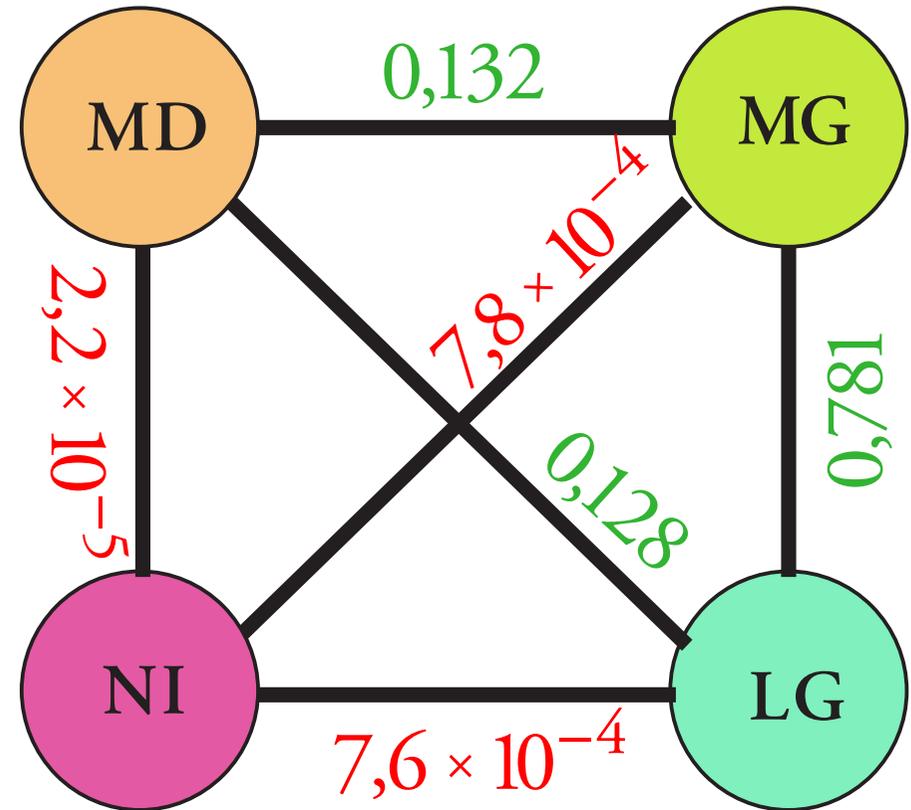
Et variantes...

Ischémie partielle, différente entre les lobes

Exemple 2 : Le Graphe expérimental

- ★ Effectif : $n = 5$ par groupe
 - ★ $K = 4$ donc 6 arêtes à tester
 - ★ Chaque arête correspond au rapport entre les deux lobes
 - ★ Pour chaque rapport, on teste s'il diffère entre les deux groupes
- ➔ Test de Student sur le ln du rapport

Résultats des tests



*Résultats condensés :
matrice de p*

Exemple 2 : Conclusions... et questions !

★ Graphe expérimental obtenu : celui ci-contre

➔ L'expérience semble avoir réussi

★ Ici, cas facile : contrôle positif...

➔ La coupure ou non des arêtes est « facile »

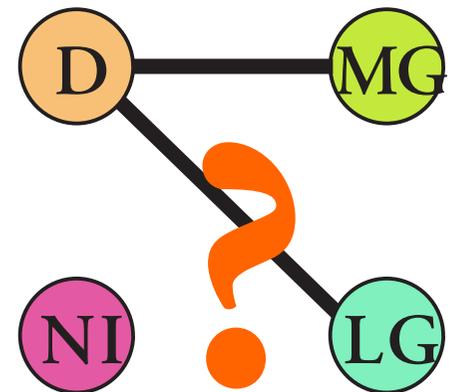
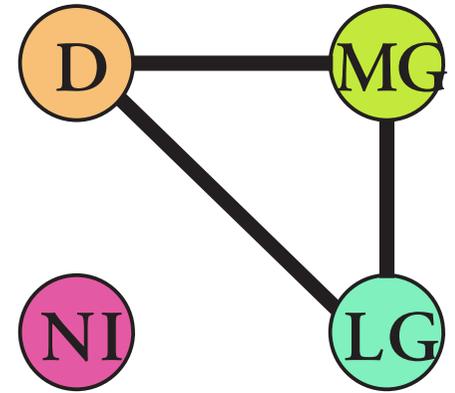
➔ Le graphe obtenu est cohérent

★ Sur des cas moins clair, comment faire ?

➔ Comment interpréter un graphe
« impossible » ?

➔ À partir de quand couper une arête ?

➔ Quel est le risque de voir quelque chose
qui n'existe pas ?



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...

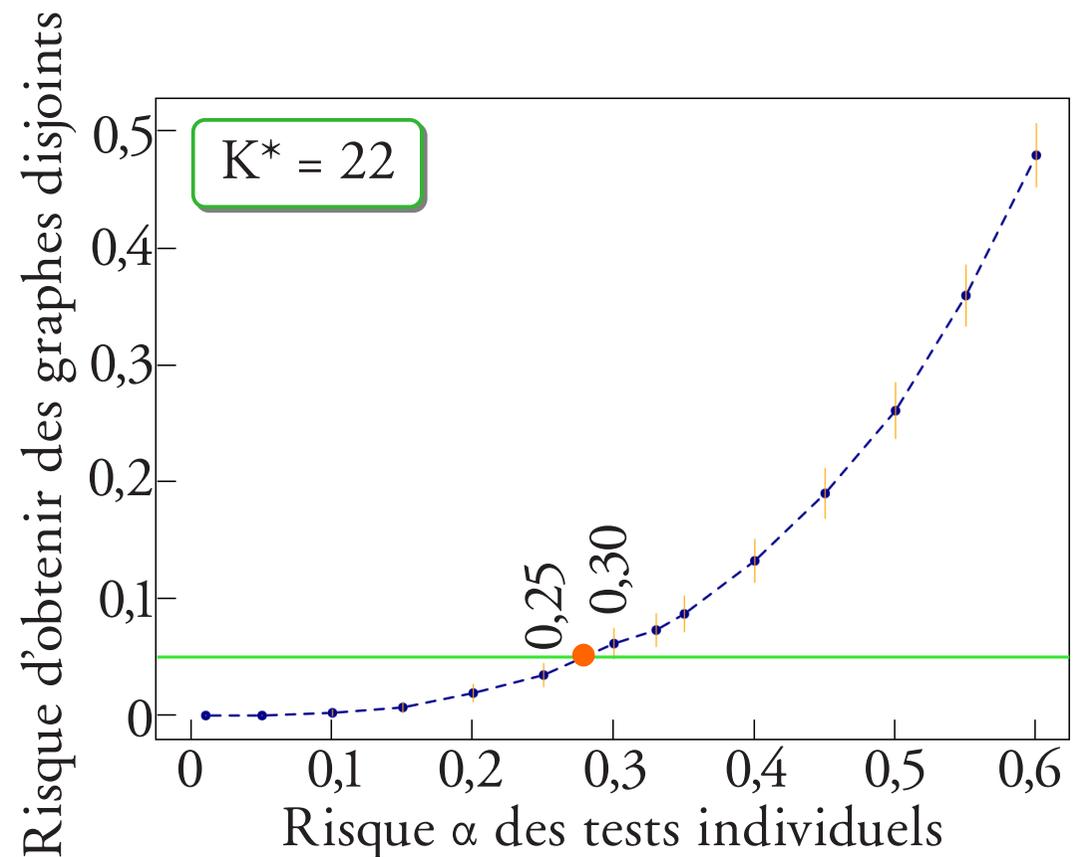
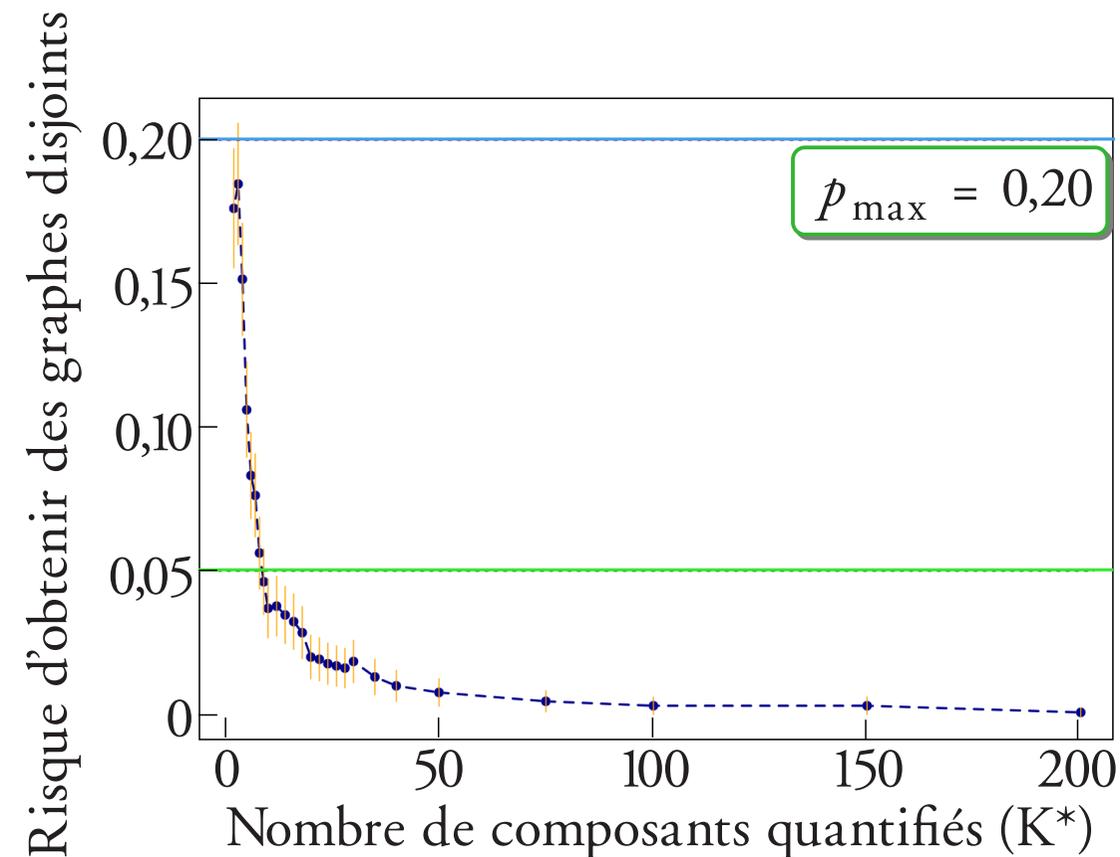
Choix du niveau du test — sous-graphes disjoints ①

- ★ 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, 2 groupes



Exemple 3 : Composition tissulaire ①

Données d'Anne-Gaëlle CORDIER

- ★ Étude microscopique de placentas humains
 - ➔ Six types de structures repérés sur les champs
 - ➔ Ces 6 types recouvrent tout le champ
 - ➔ Pour chaque placenta, 5 champs sont étudiés
- ★ Influence de la drépanocytose sur l'importance de ces structures
 - ➔ groupe de placentas de femmes témoin
 - ➔ groupe de placentas de femmes drépanocytaires
 - ➔ groupes équilibrés, $n = 7$ femmes par groupe

Exemple 3 : Composition tissulaire ②

- ★ Quantification : surface occupée par le tissu dans le champ
- ★ Le champ est (beaucoup) plus petit que le placenta
 - ➔ la somme des surfaces mesurées vaut forcément la surface du champ observé
 - ➔ données compositionnelles par contrainte expérimentale !
- ★ $K = 6$ « composants » — T, VF, M, SK, F et CI
 - ➔ D'après les simulations précédentes, avec $n = 7$, le seuil de coupure est à $p < 0,167$
 - ➔ Intervalle de confiance de ce seuil : $[0,159 ; 0,175]$
 - ➔ $6 \times 5 / 2 = 15$ arêtes à tester

Exemple 3 : Composition tissulaire — approche naïve

★ Chaque tissu est testé isolément

➔ Néglige le côté compositionnel...

➔ 6 tests : travail avec $\alpha < 0,0083$ (Bonferroni)

Tissu	p	Sens
SK	0,0614	▲
F	0,0002	▲
T	0,0458	▼
VF	0,2066	▼
M	0,0952	▼
CI	0,0796	▼

★ Conclusion : la fibrine (F) augmente

Exemple 3 : Composition tissulaire ③

★ Coupure : $p < 0,16$

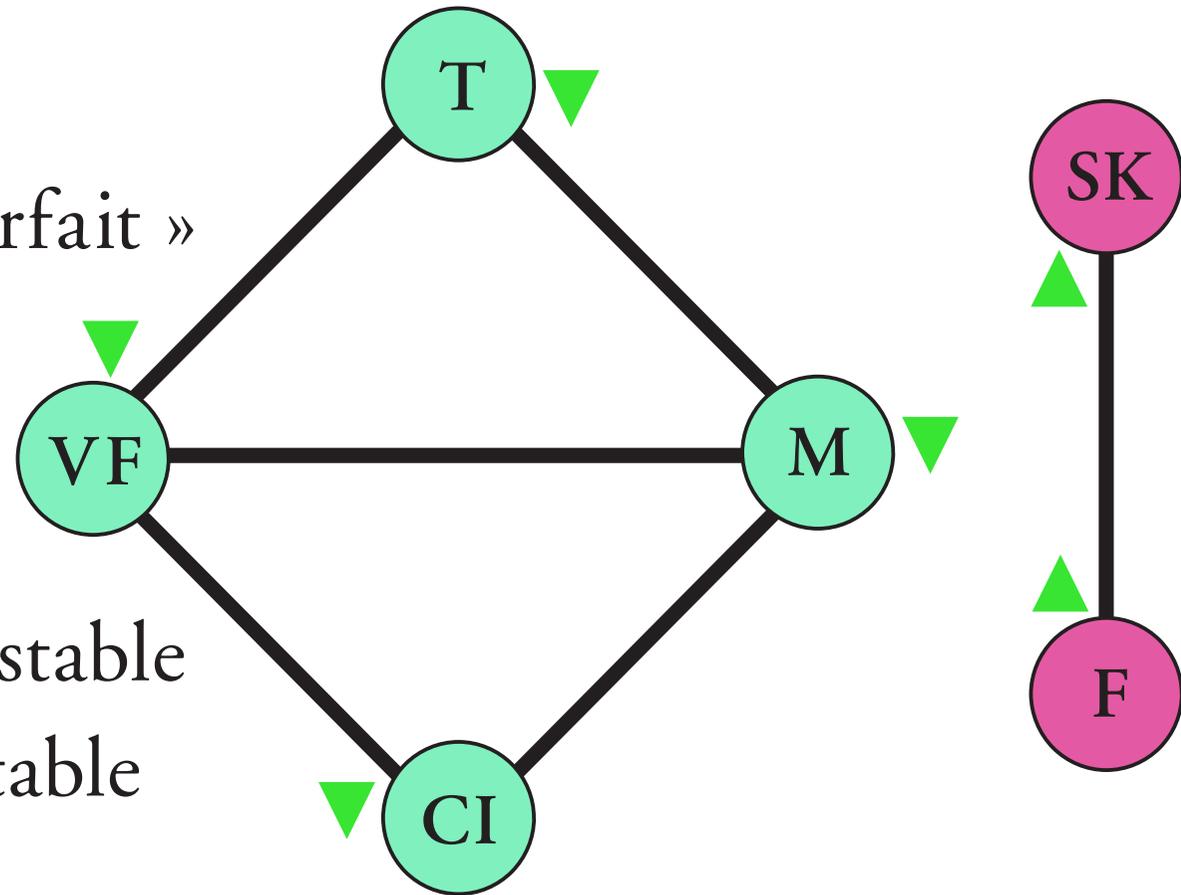
★ Graphe obtenu « quasi-parfait »

➡ Une arête manque...

★ Deux groupes nets

➡ Un augmente ou reste stable

➡ Un diminue ou reste stable



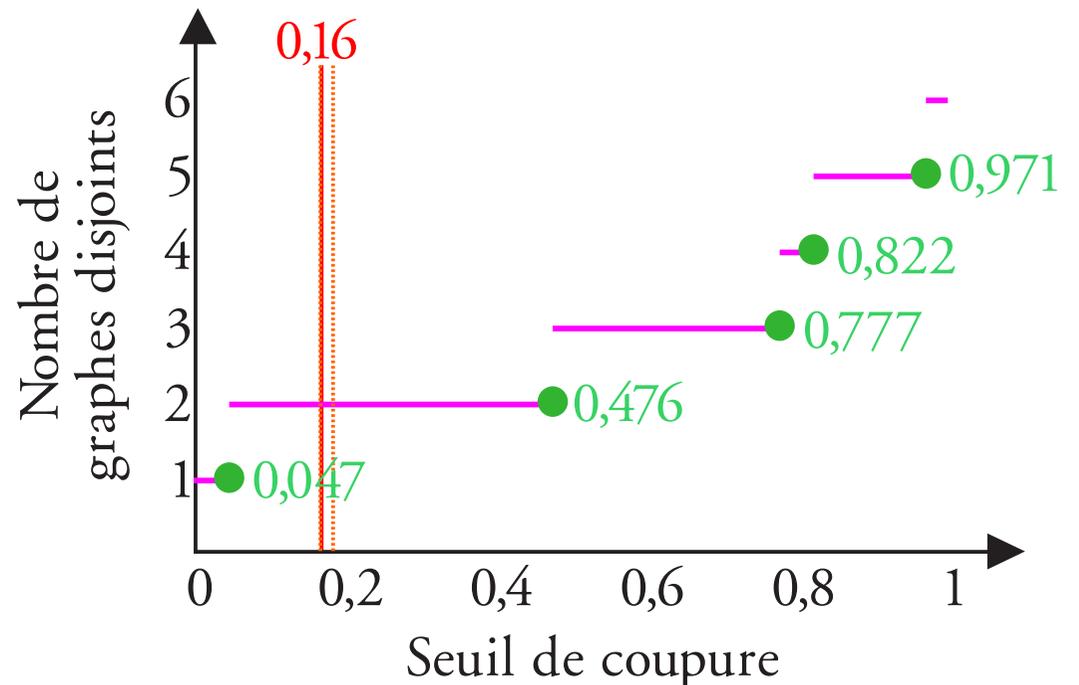
*Quelle est la sensibilité du « découpage »
au choix du seuil de coupure ?*

Sensibilité au seuil de coupure ①

- ★ Plus on augmente le seuil de coupure, plus on ôte d'arêtes
 - ➔ Plus on a de chance d'avoir des graphes disjoints
 - ➔ De combien faut-il bouger le seuil pour reconnecter les deux graphes ? ou les dissocier ?

★ Il suffit d'essayer pour les p de la matrice, triés par ordre croissant

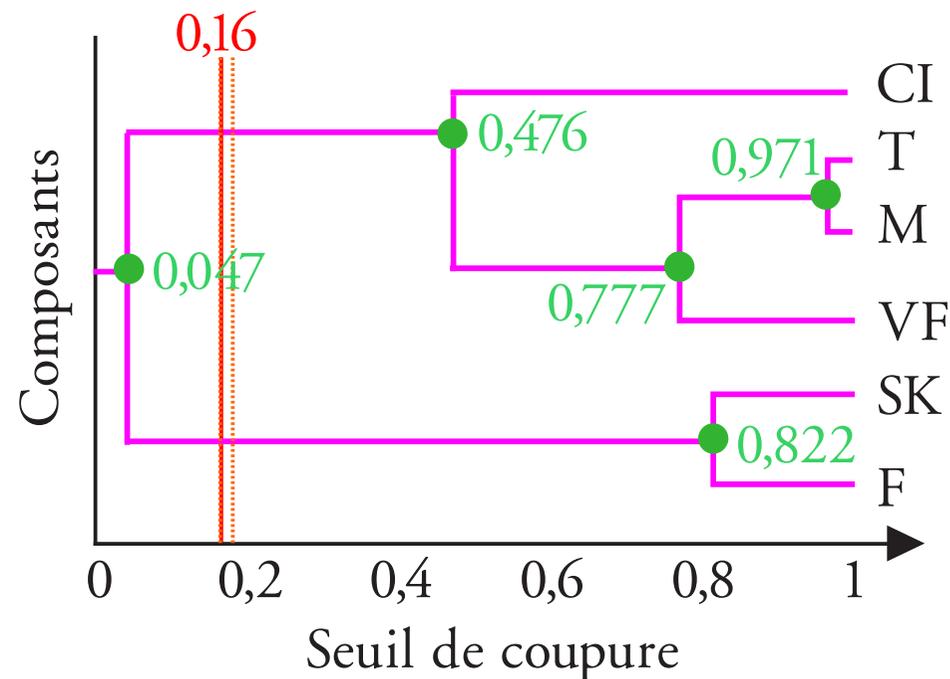
➔ Nombre de graphes disjoints en fonction du p seuil



Sensibilité au seuil de coupure ②

★ À partir de ces coupures, on peut aussi proposer un arbre de classification des composants

- ➔ Arbre hiérarchique de séparation des groupes en fonction du seuil
- ➔ Plus deux composants se regroupent difficilement et plus ils se comportent différemment



Application en qRT-PCR

Pourquoi des données compositionnelles ?

★ 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, $[ARN\ i] = x_i = M \frac{q_i}{\sum_{j=1}^K q_j}$

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

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

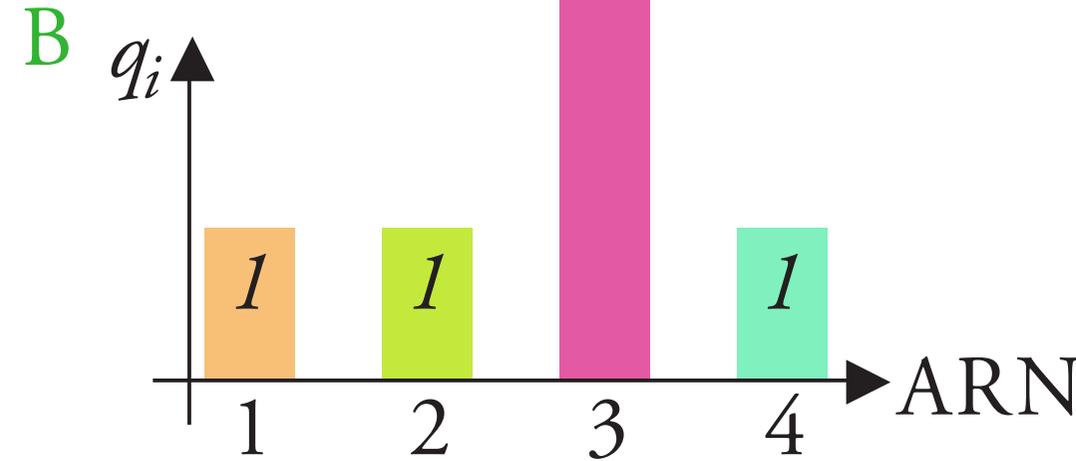
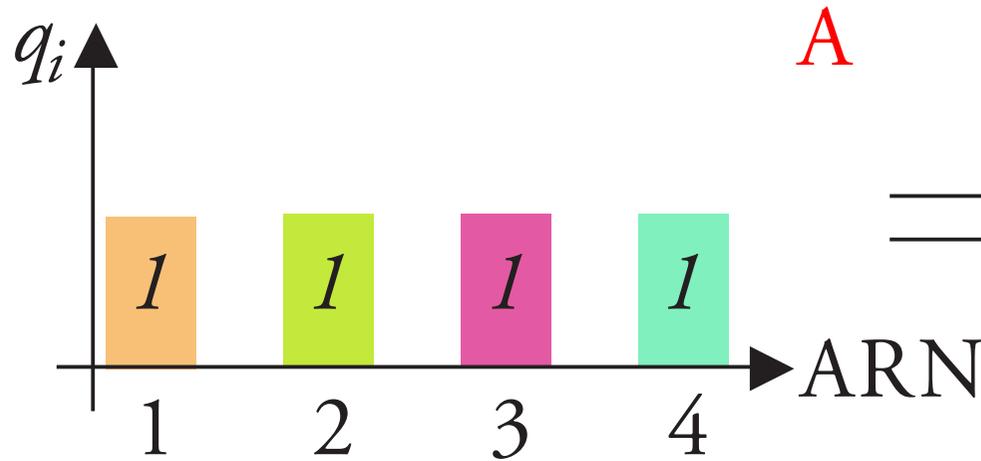
Méthodes classiques ①

- ★ Parmi les K^* A. R. N. quantifiés, K_R « gènes de référence »
 - ➔ Gènes dont l'expression est postulée invariante
 - ➔ Pour simplifier les notations : composants 1 à K_R
- ★ Dans chaque échantillon, on calcule un facteur de normalisation, f_{norm}
 - ➔ Moyenne arithmétique des d_i ($1 \leq i \leq K_R$)
 - ➔ Moyenne géométrique des d_i (arithmétique des C_t)
- ★ On étudie les rapports $r_{i, \text{norm}} = \frac{d_i}{f_{\text{norm}}}$ ($K_R < i \leq K^*$)
 - ➔ Si $K_R = 1$, méthode a. l. r. et « ΔC_t » !
 - ➔ Il faut faire $(K^* - K_R)$ tests distincts

Conséquences sur les conclusions — Exemple ①

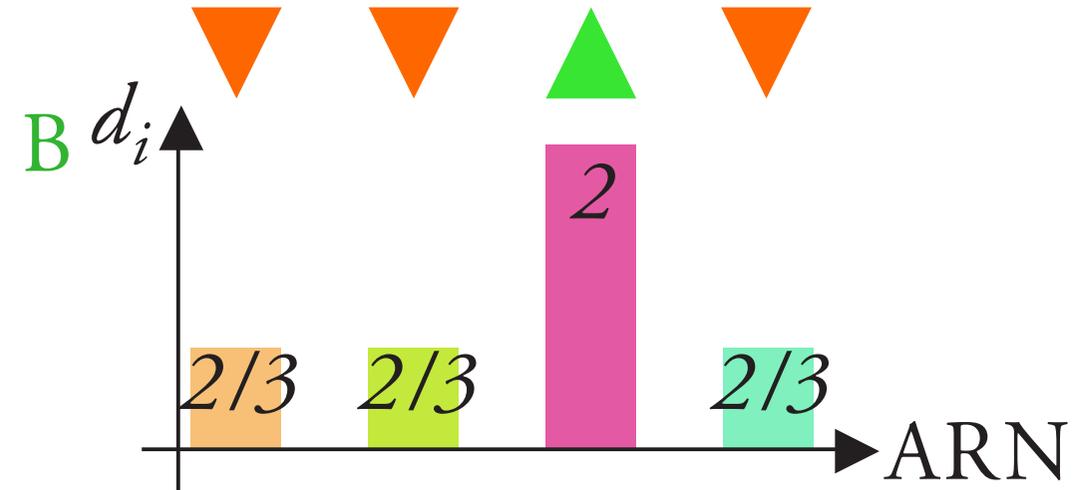
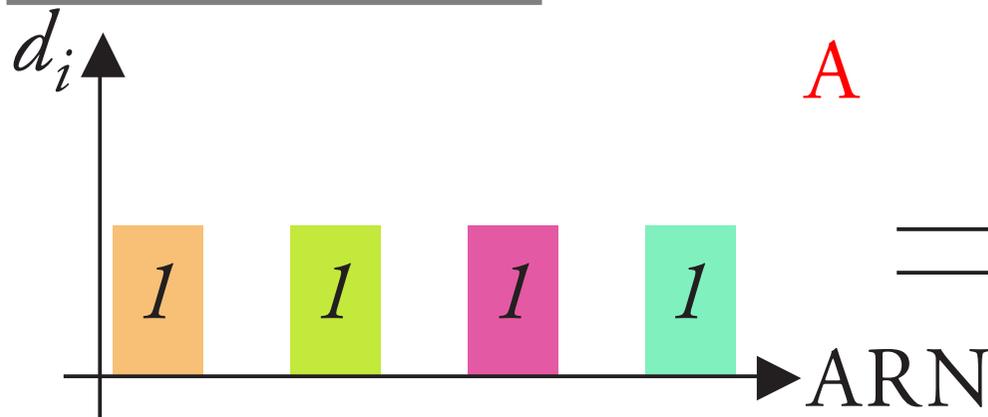
★ $K = 4$ composants différents, 2 conditions A & B

Réalité



Quantifié

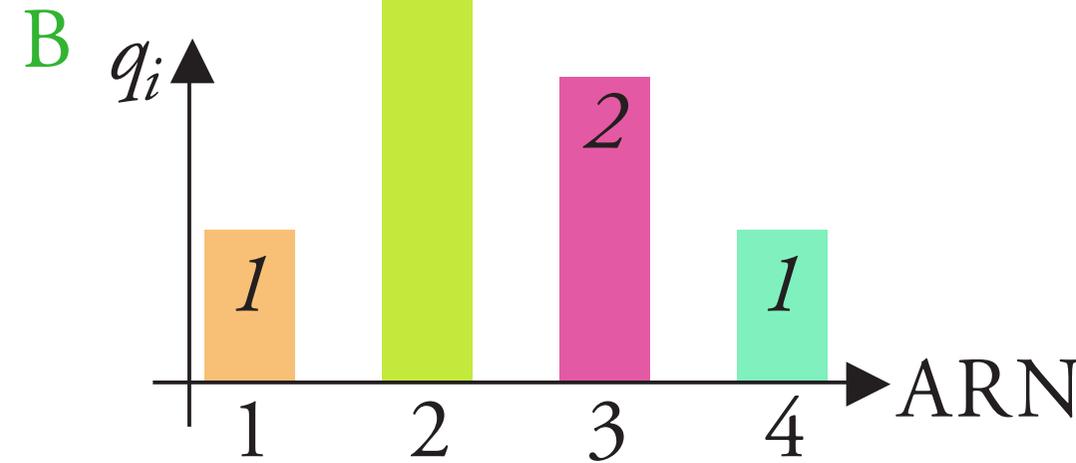
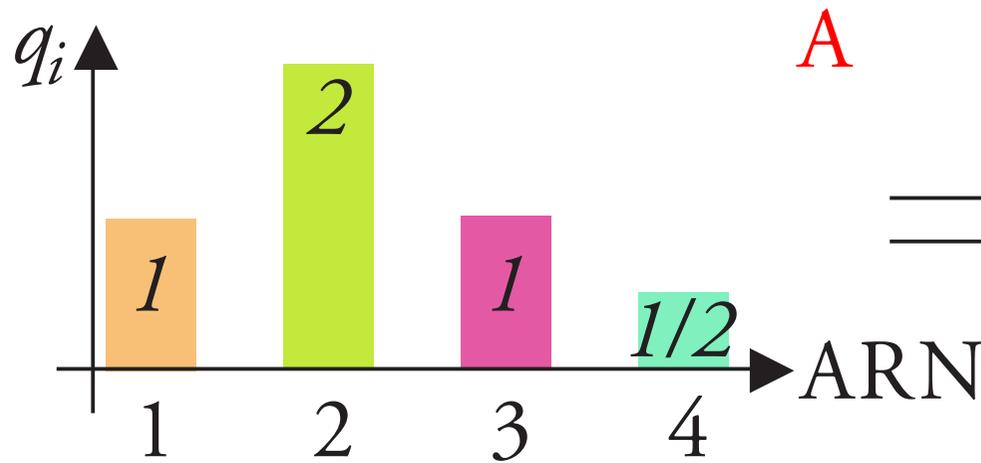
Avec $M = 4$



Conséquences sur les conclusions — Exemple ②

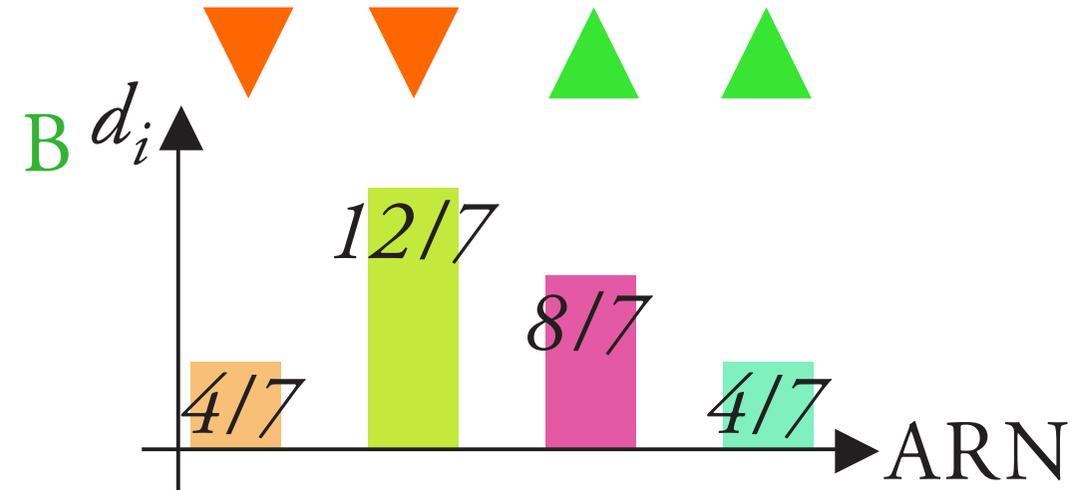
★ $K = 4$ composants différents, 2 conditions A & B

Réalité



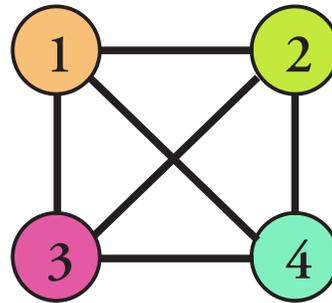
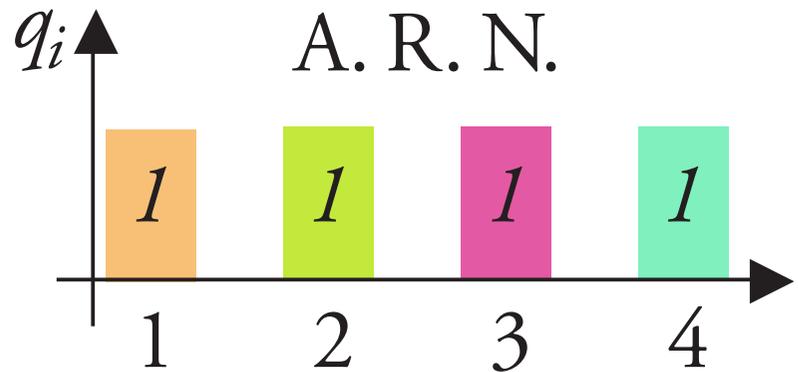
Quantifié

Avec $M = 4$

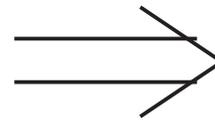


Étude sous H_0 — Principe

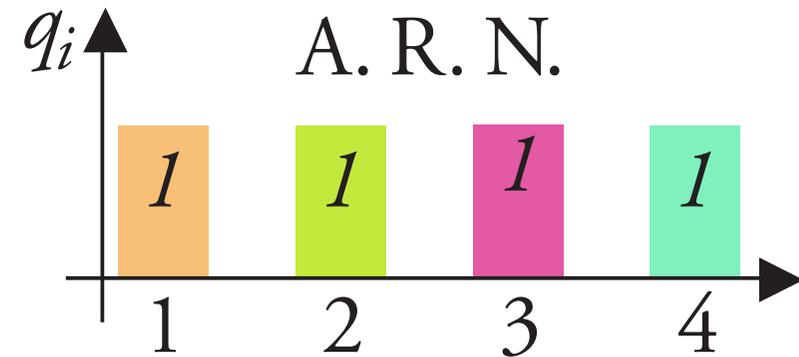
Réalité



A



B



★ Sous H_0 , rien ne se passe entre A et B

➡ On ne doit obtenir qu'un seul graphe

➡ Méthode a. l. r. : on ne doit rien trouver

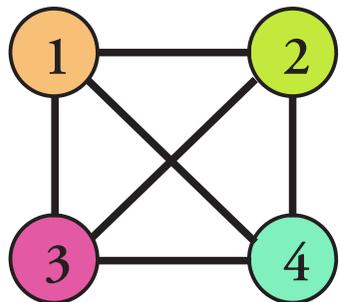
➡ Le pourcentage de simulations se trompant estime α

★ Pour la méthode a. l. r., il faut une référence

➡ Arbitrairement, l'A. R. N. n° 1 sera la référence

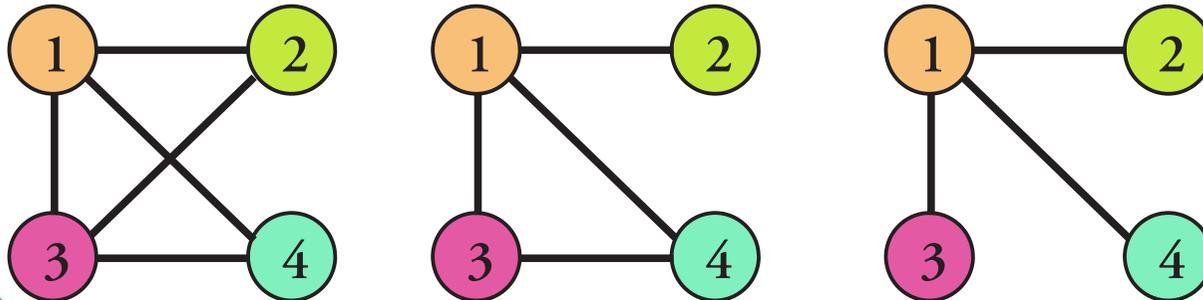
Étude sous H_0 — conditions de simulation

- ★ Distribution log-normale des q_i ; CV = 20 %
 - ➔ Test de Student « classique », en ln, pour chaque arête
- ★ Sous H_0 , la taille des groupes joue peu
 - ➔ Pas du tout pour la méthode ΔC_t
 - ➔ $n = 3$ par condition (raison : patience...)

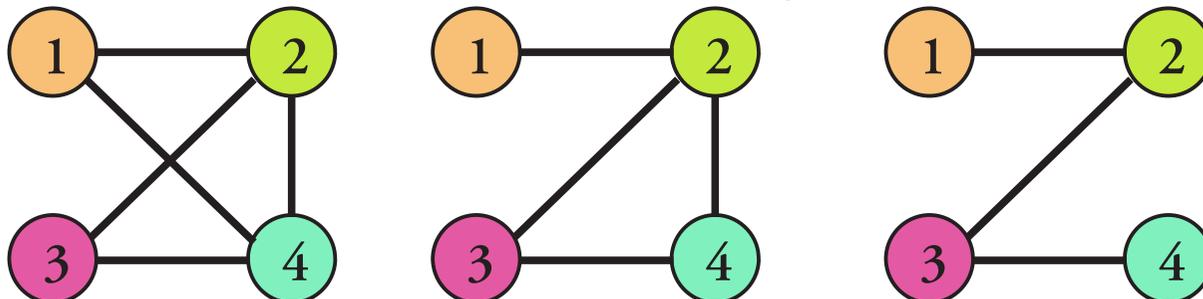


Correct

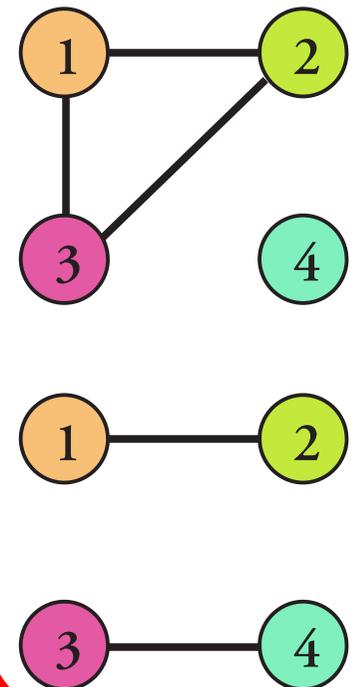
Incorrect, mais conclusion correcte (alr & graphe)



alr se trompe, pas les graphes



Erreur

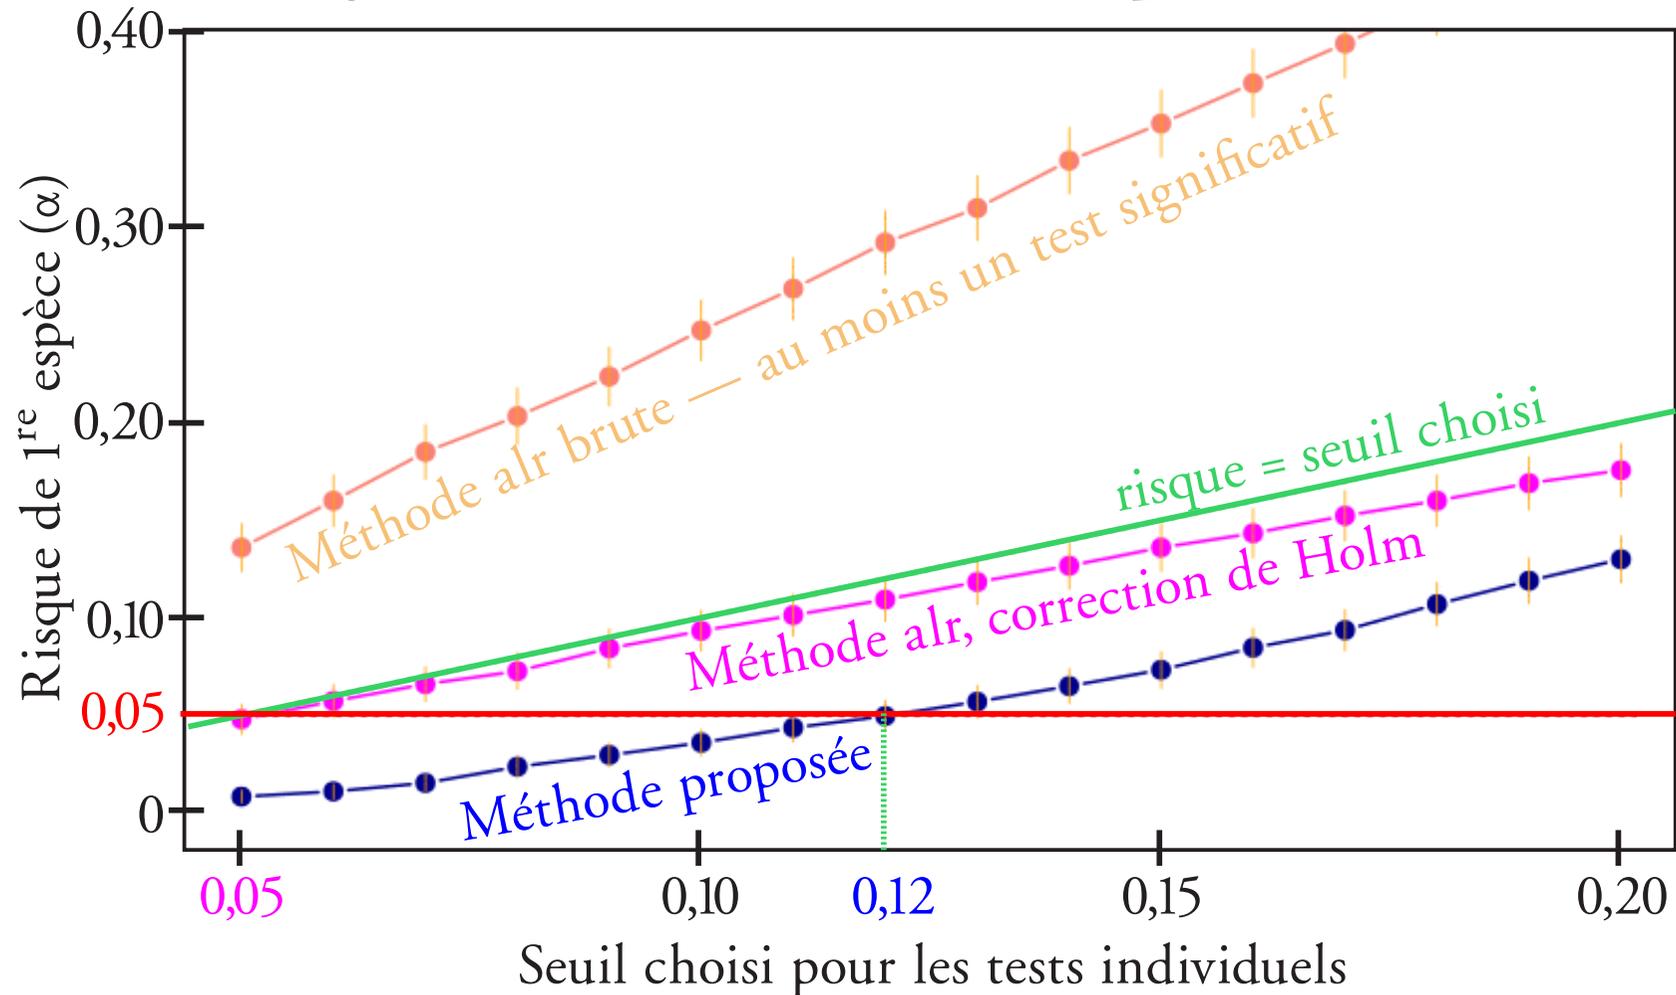


Étude sous H_0 — risque α

★ La méthode alr « brute » ne contrôle pas α

➔ Correction de multiplicité (ici, Holm) indispensable

★ Méthode des graphes : coupure pour $p < 0,12$ ici



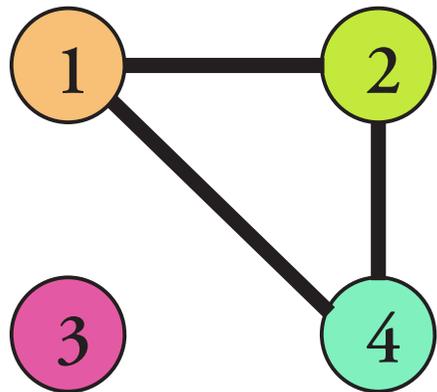
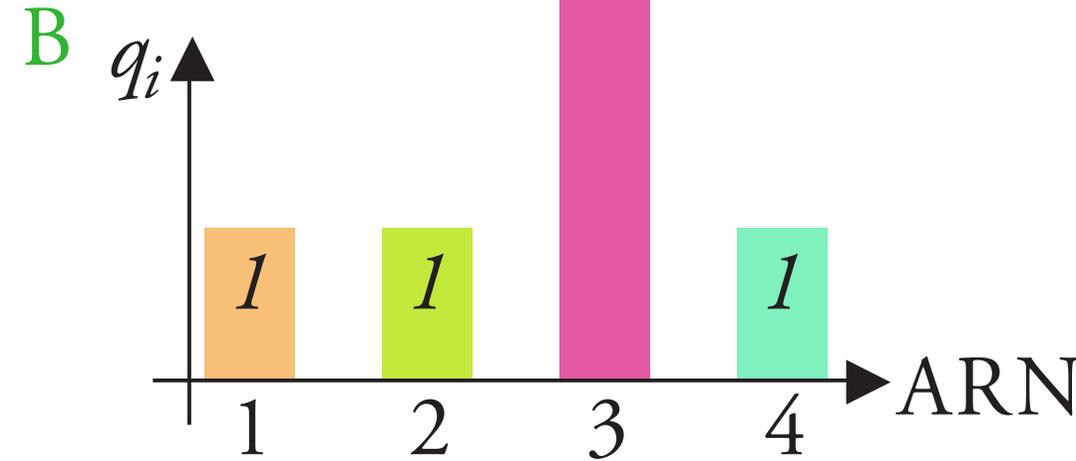
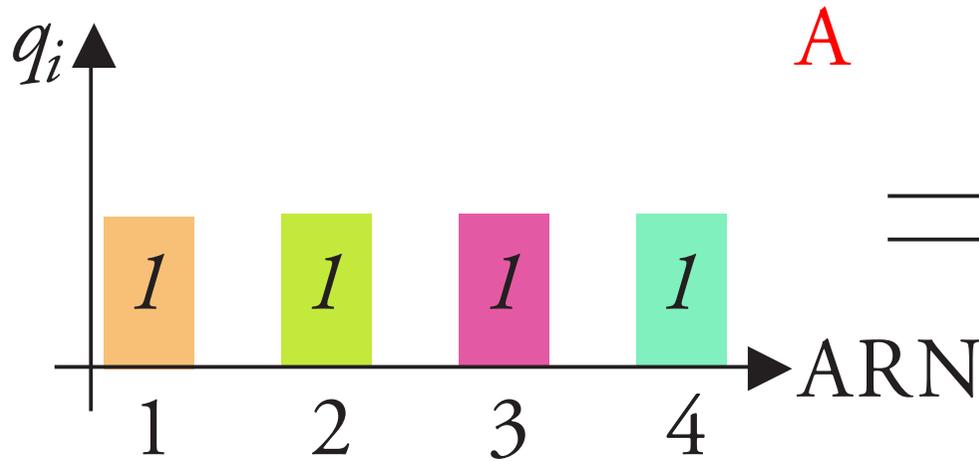
Et pour la puissance ?

- ★ 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 — étude de la puissance totale

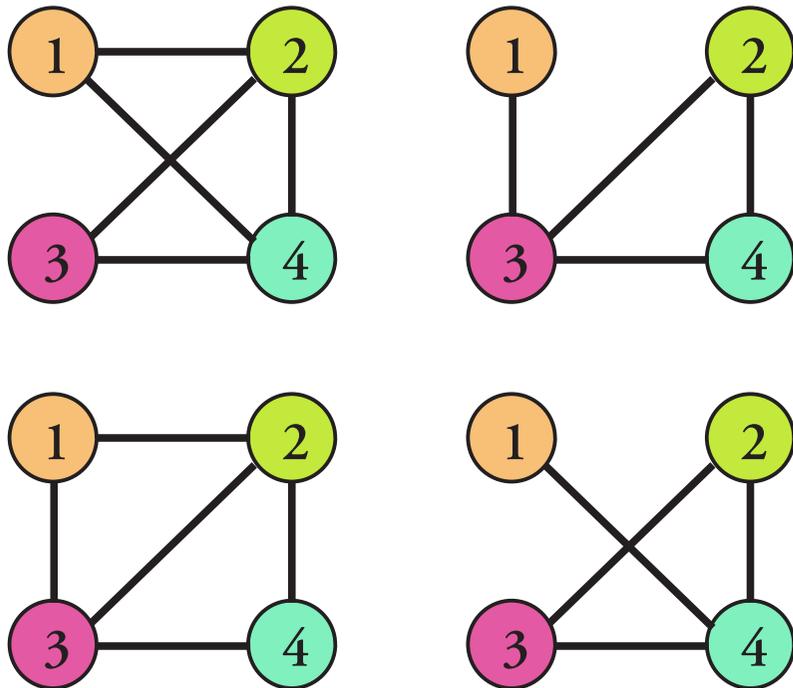
★ On rejette H_0 pour n'importe quelle raison

➔ Il se passe quelque chose (ce qui est observé... ou pas !)

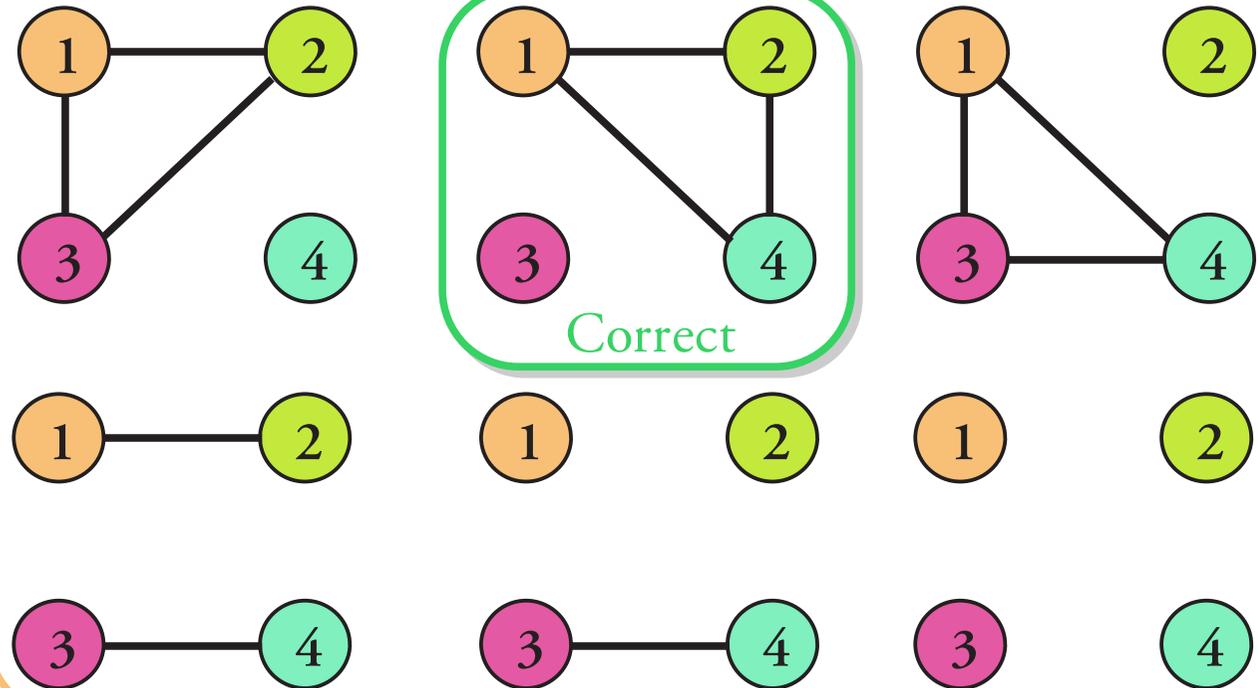
★ Méthode alr : composants 2 ou 3 ou 4 détectés

Méthode proposée : graphe disjoint, quel qu'il soit

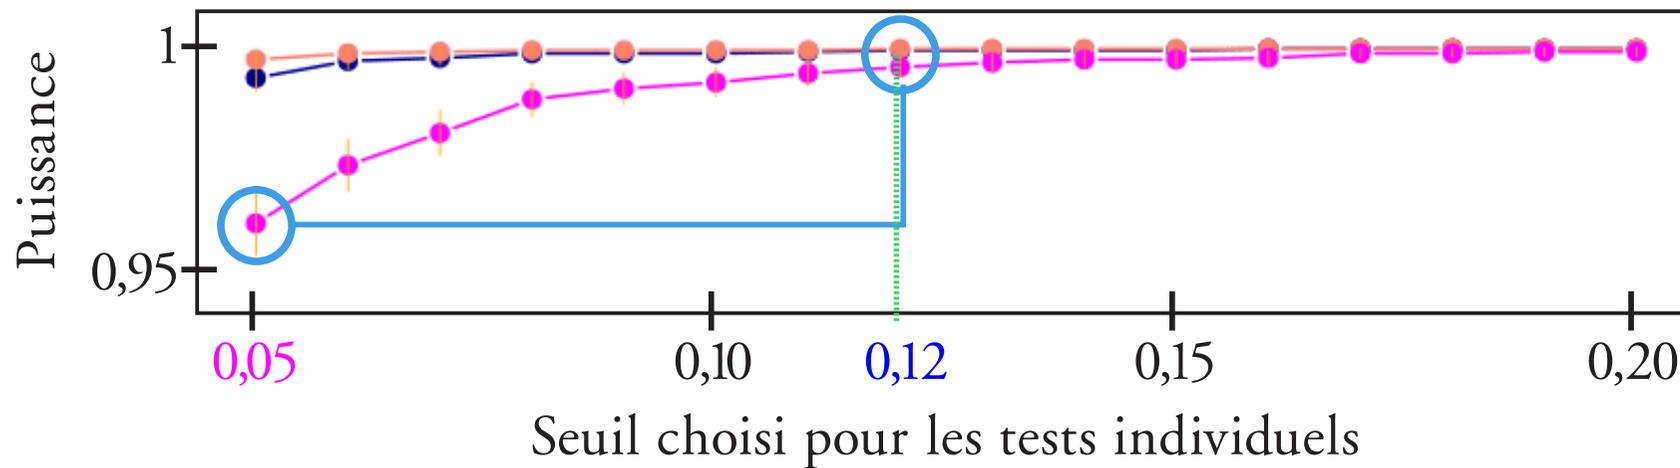
alr seule détecte quelque chose



Les deux détectent quelque chose



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



★ En pratique les deux méthodes sont aussi puissantes

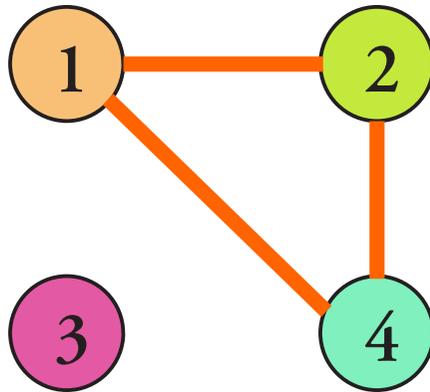
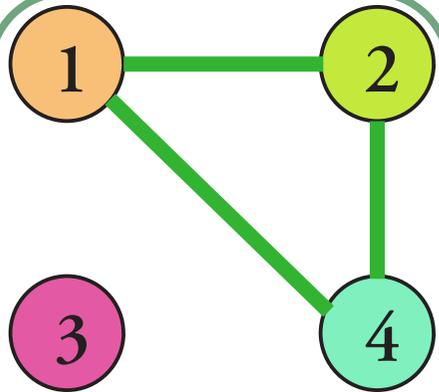
➡ Mais la correction de multiplicité en alr a un prix !

★ Mais est-ce qu'elles détectent bien ce qu'il faut ?

➡ alr : le composant 3 (et seulement lui) est significatif

➡ graphes : deux graphes, un avec le nœud 3 et un second avec les trois autres nœuds

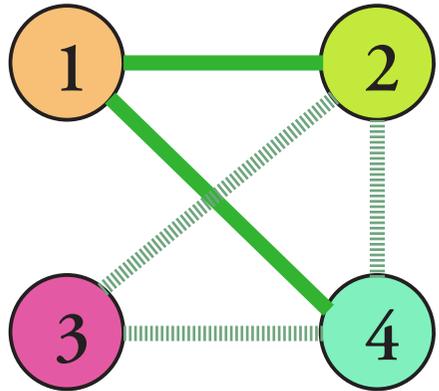
Exemple 1 — trouve-t-on le bon composant ?



Méthode proposée

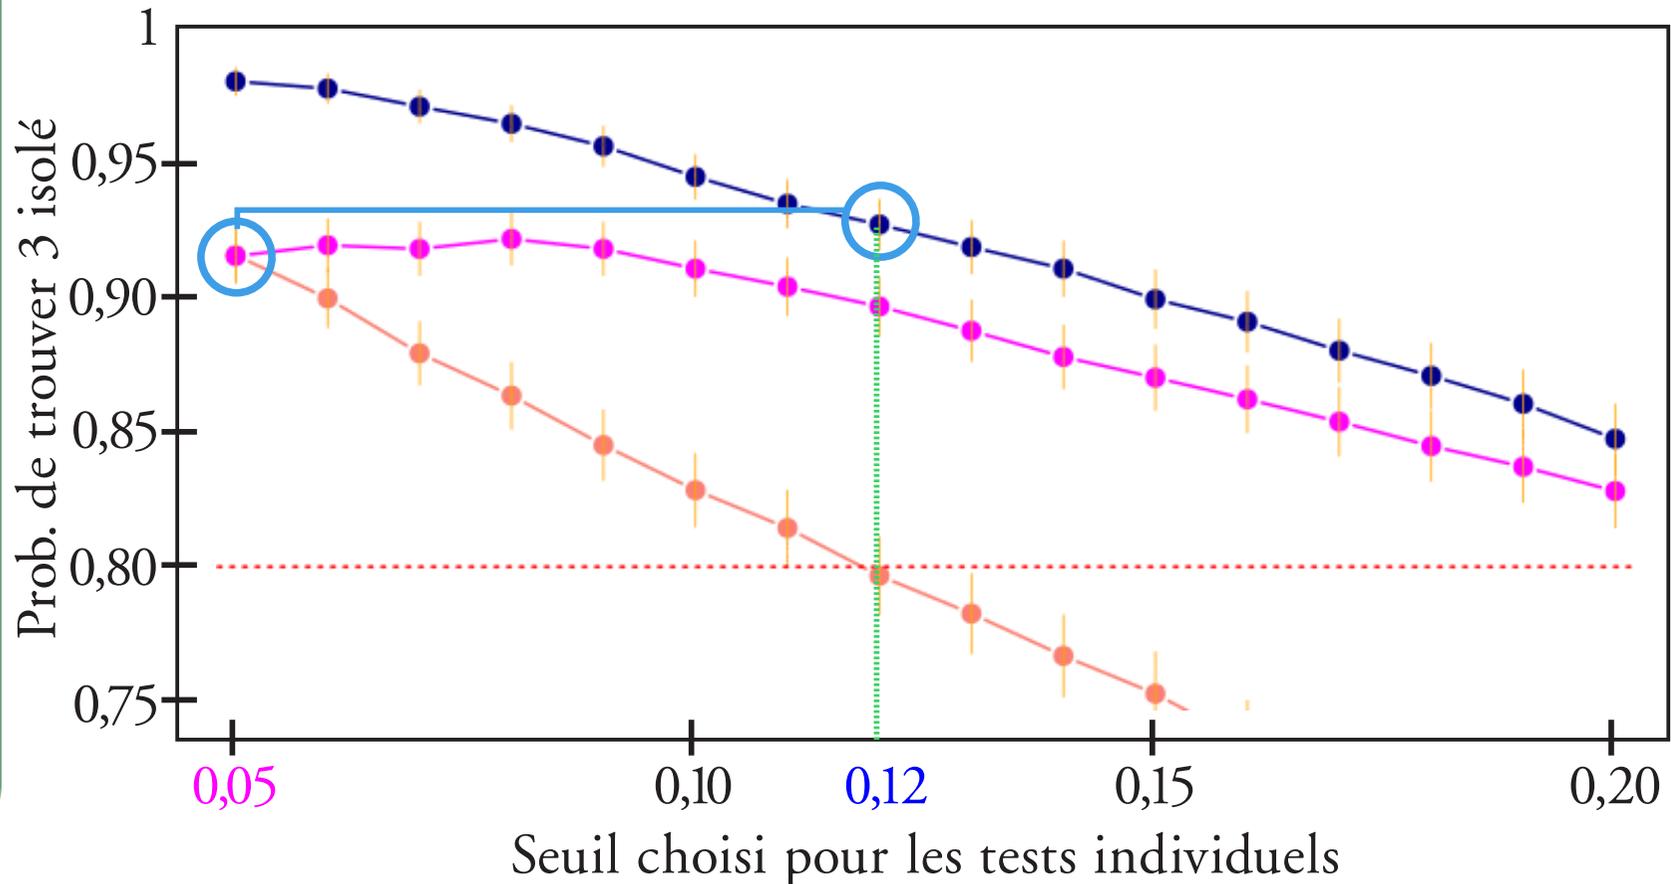
Une seule de ces arêtes peut manquer, au plus, pour conclure correctement

Soit 4 graphes acceptables (sur 2^6 possibles)



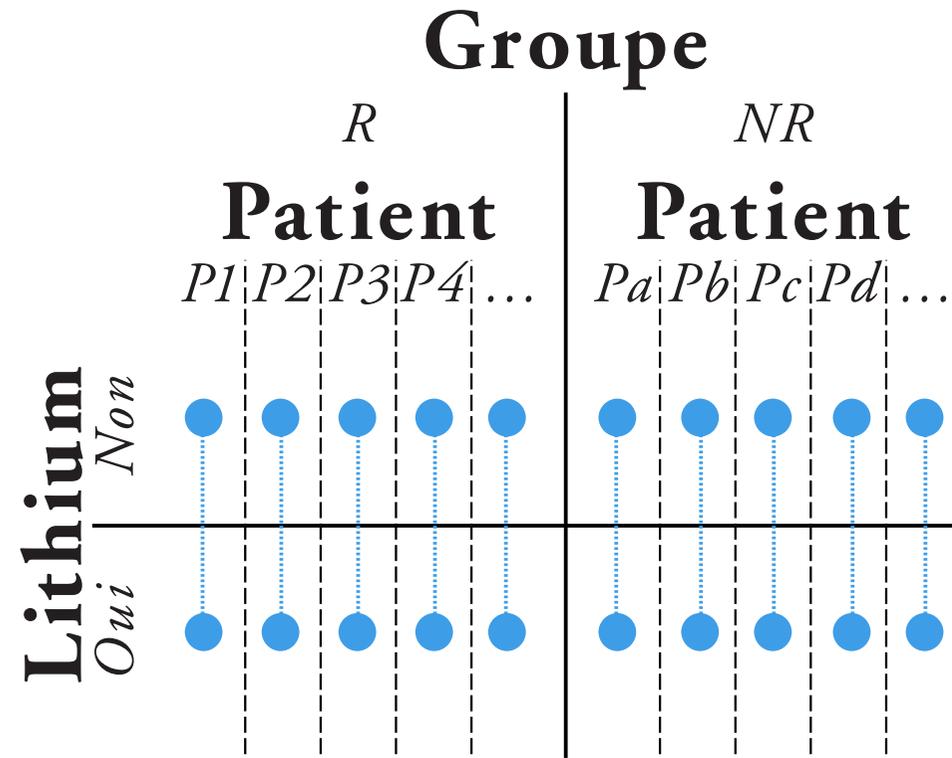
Méthode alr

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)

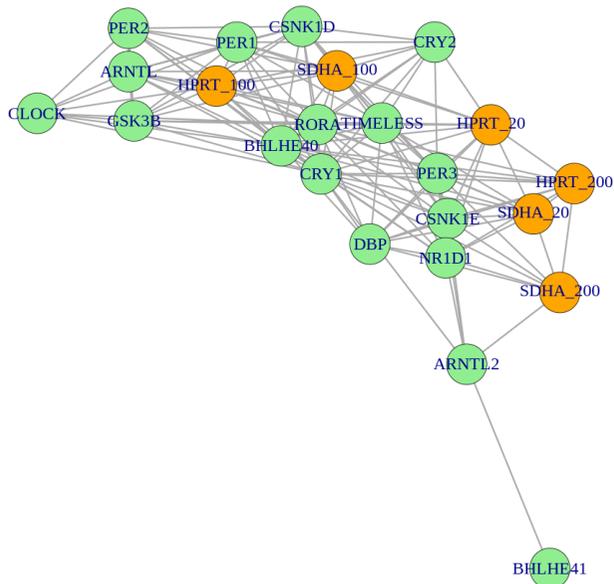
★ Modèle linéaire à effets mixtes, avec lme4 (R)

➡ Coefficients testés par test de Wald asymptotique

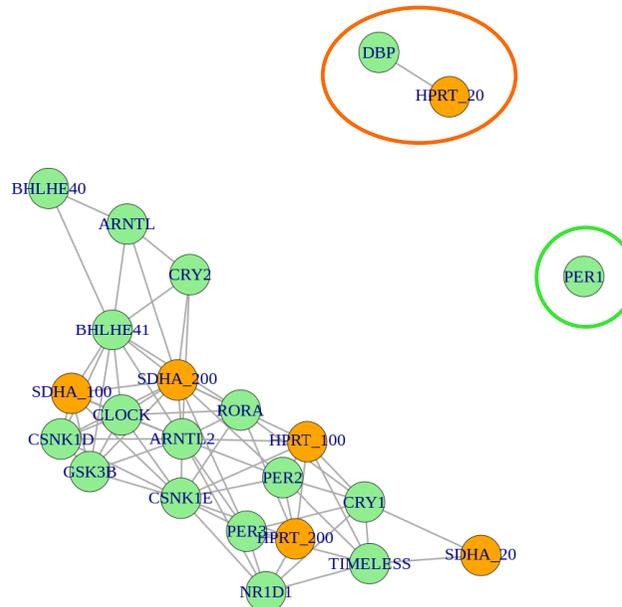
★ Critère : sous-graphes disjoints

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

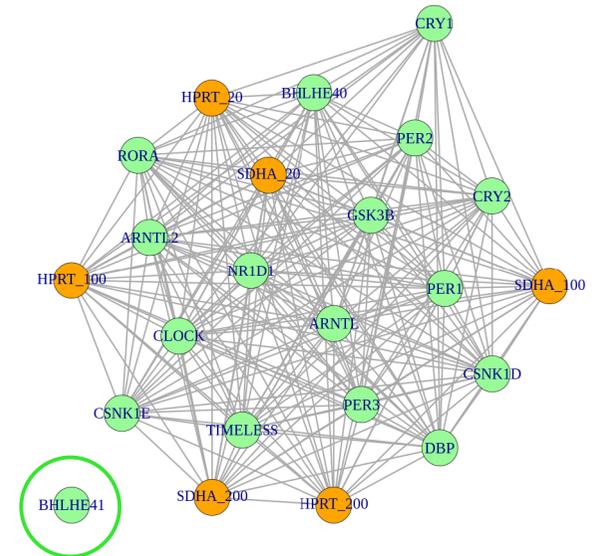
Comparaison
R vs NR, basal



Effet de Li^+
chez les NR



Effet différentiel
de Li^+



Application en métabolomique

Pourquoi des données compositionnelles ?

★ Des échantillons sont prélevés, traités...

⇒ K composés (C) différents, $[C_i] = q_i$

★ Les composés sont séparés puis dosés

⇒ K' composés sont séparés, $[C_i] = \varepsilon_i q_i$

⇒ K* composés sont quantifiés, $d_i = \lambda_i \varepsilon_i q_i$

⇒ Courbes d'étalonnage inconnues : d_i en unité arbitraire

★ On normalise les valeurs entre expériences

⇒ La normalisation rend les données compositionnelles

Exemple d'application ①

Étude de la maladie du greffon contre l'hôte

- ★ 2 groupes de patients, ayant reçu une greffe de moëlle : patients développant ou ne développant pas cette complication
- ★ Chez chaque patient, prélèvement plasmatique
- ★ Quantification « lipidomique » des petites molécules

Modèle

$$\ln r_{i,j} = \underbrace{\mu_{0,i,j}}_{\text{Rapport moyen en l'absence de complication}} + \underbrace{\delta_{D i,j}}_{\text{Variation en présence de complication}} \mathbf{1}_D + \varepsilon$$

Rapport moyen en l'absence de complication

Variation en présence de complication

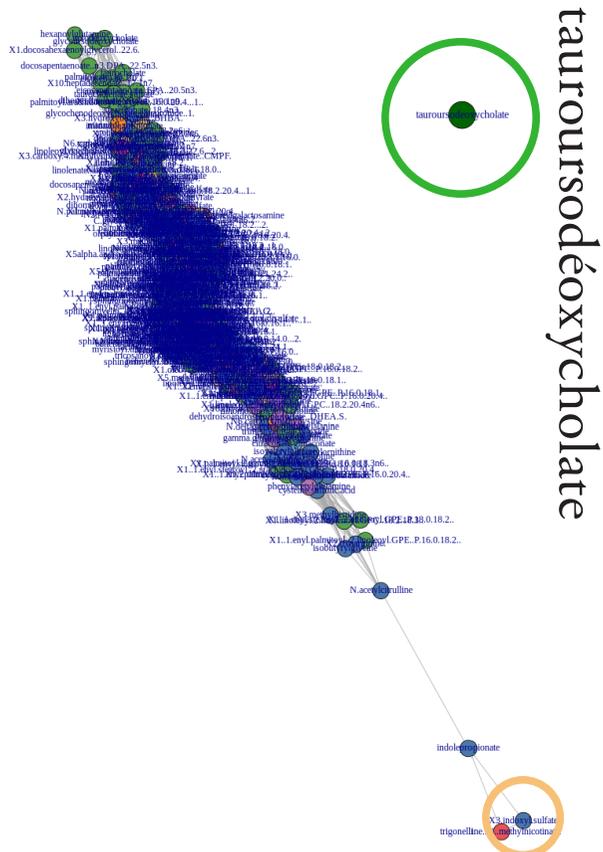
Exemple d'application ③ — Résultats

★ Analyse sur 491 métabolites (communs aux deux cohortes)

➔ Seuil de coupure : $p < 0,44$

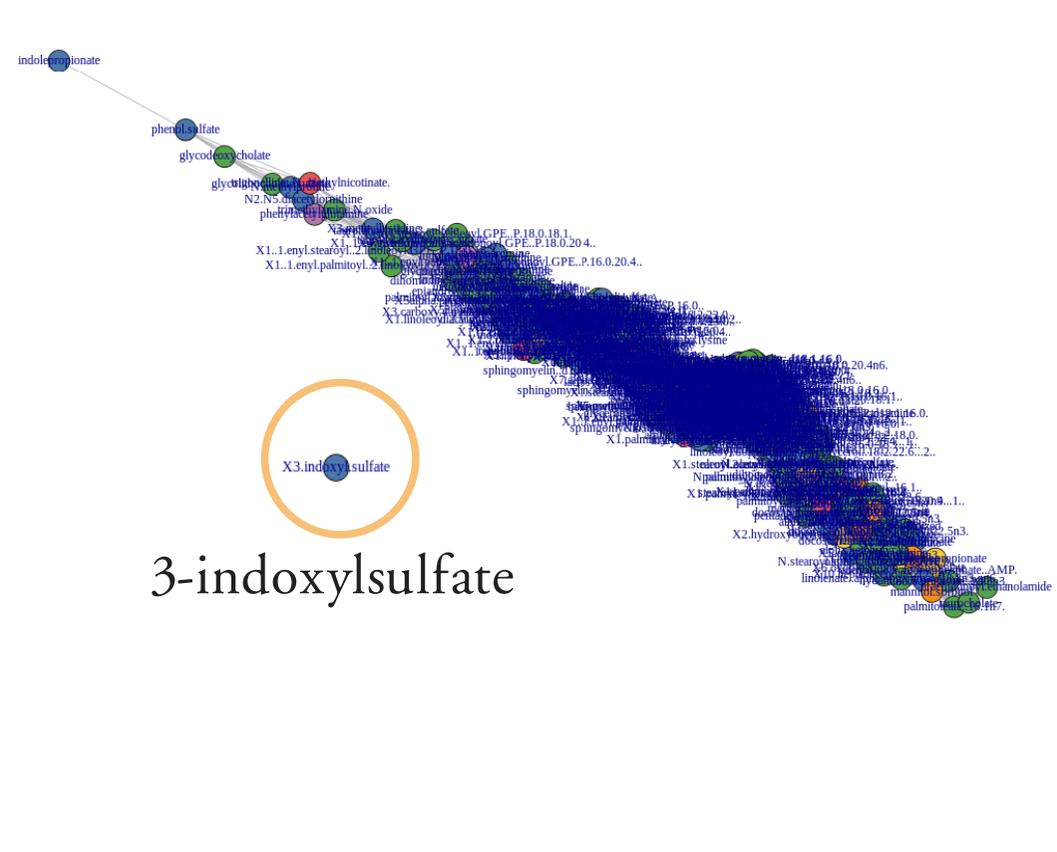
Cohorte 1

12 vs 31 patients



Cohorte 2

26 vs 30 patients



Quelques limitations de la méthode...

- ★ Nombre de tests augmente avec K^* comme K^{*2}
 - ➔ Temps et mémoire nécessaires augmentent « vite »
 - ➔ Temps de calcul pour $K = 800$: 15 minutes
 - ➔ Temps de 1000 simulations, 48 cœurs : 5 heures
 - ➔ 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 composé donné
 - ➔ Limite de la normalisation, pas de la méthode...

... et quelques avantages

- ★ Pas besoin d'hypothèse sur des composés invariants
- ★ Pas de correction de multiplicité
 - ➔ Moins de perte de puissance quand K^* augmente...
- ★ Insensible aux différences d'efficacité de quantification entre composés
 - ➔ tant que ces différences ne dépendent pas des conditions comparées !
- ★ RNASeq : insensible aux profondeurs de séquençage...
- ★ Applicable à tout plan expérimental

Remerciements

- ★ Charles-Henry Cottart — données hépatiques (traceur)
- ★ Anne-Gaelle Cordier — données d'imagerie (placentas)
- ★ Cindie Courtin, Calypso Nepost, Pierre-Alexis Geoffroy — qRT-PCR
- ★ David Michonneau, Gérard Socié — données urinaires
- ★ Bruno Saubaméa — données de RNA-Seq
- ★ Étudiants de l'ENSAI
- ★ Sylvie Chevret, Yves Rozenholc, Chantal Guihenneuc

Merci de votre attention !

Bibliographie

Logiciel

★ *Package R : SARP.compo, disponible sur le C. R. A. N.*

Articles

Théorie

★ E. Curis et coll., *Bioinformatics*, janvier 2019

Application

★ P. A. Geoffroy et coll., *The World Journal of Biological Psychiatry*, 2018