

Risque de ré-identification : deux questions pratiques relatives au critère de la l -diversité

Séminaire de méthodologie statistique – INSEE – 24 juin 2019

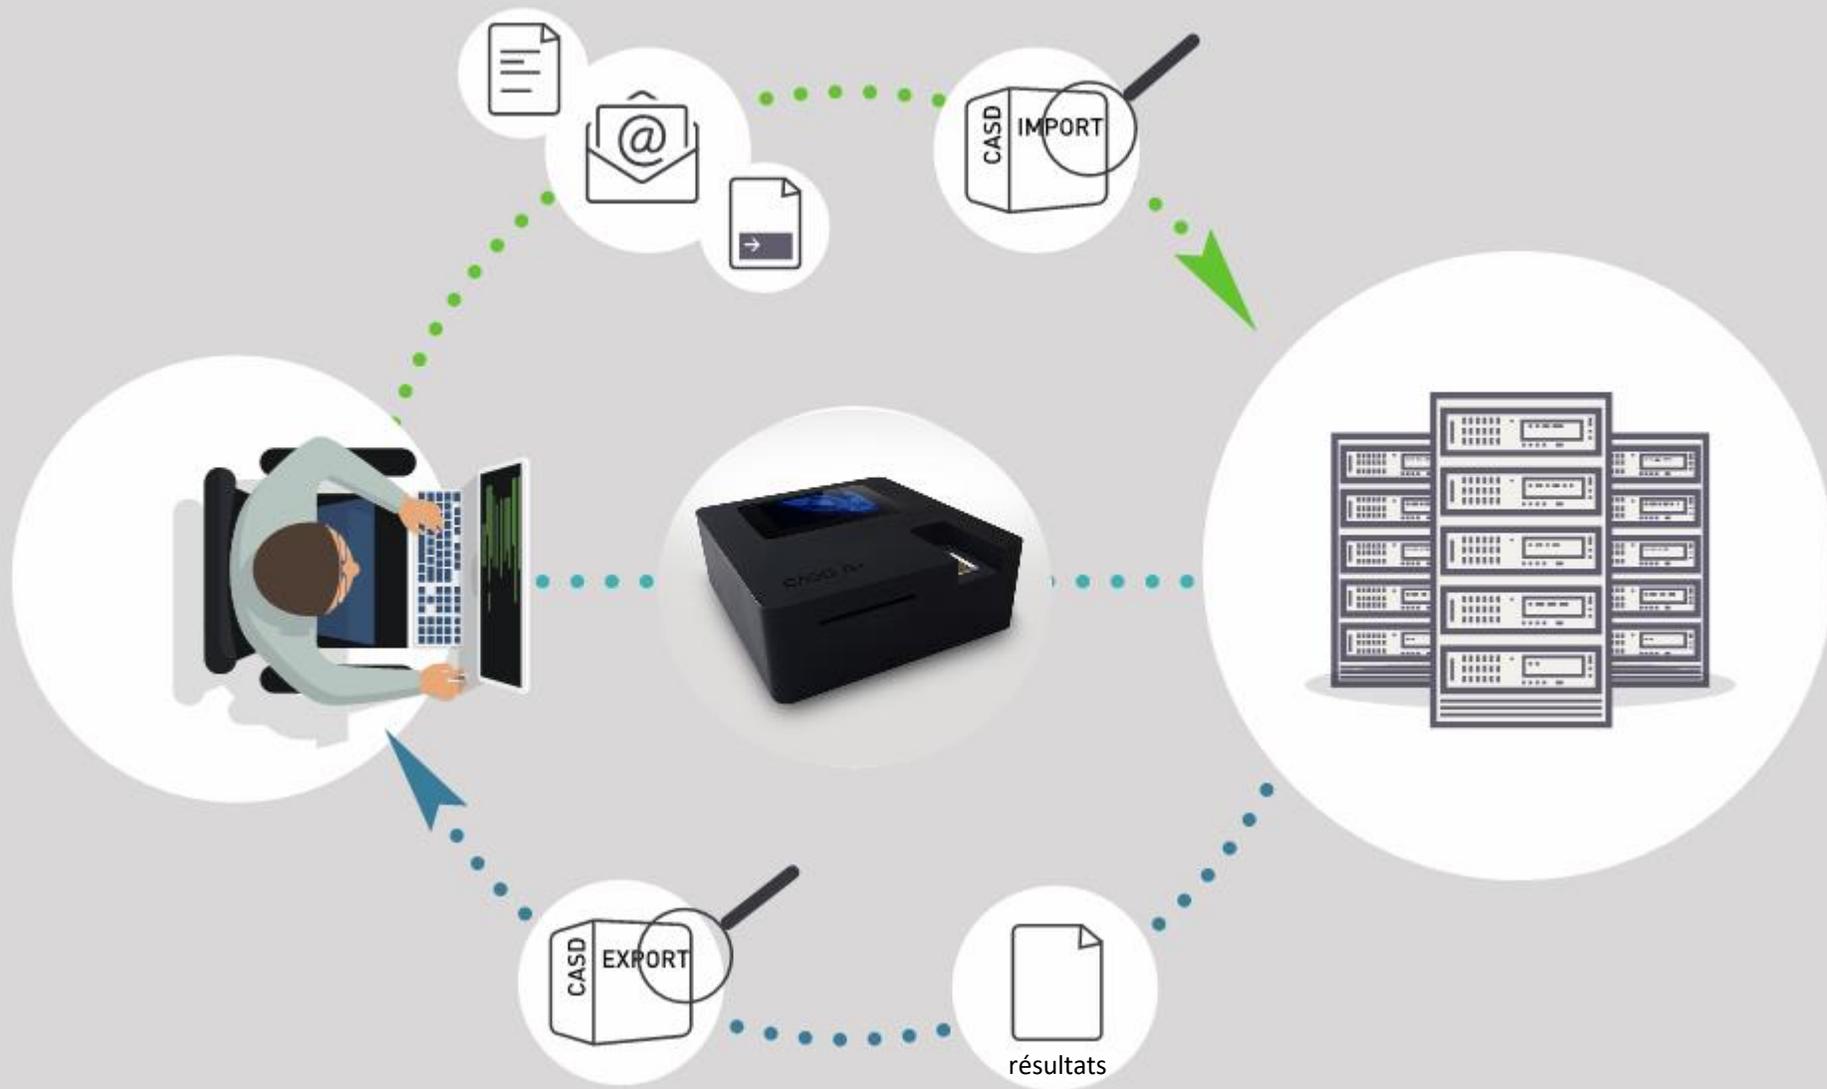
Kamel Gadouche, CASD – Dominique Blum, CASD – Caroline Boucly, DESE Insee



Le contexte

Le CASD en quelques mots

- Le CASD est un équipement qui permet à des utilisateurs, principalement des chercheurs, de pouvoir travailler à distance sur des données très détaillées : qui ne respectent donc pas le secret statistique
- Avant de pouvoir travailler au CASD, les utilisateurs doivent soumettre un dossier au comité du secret statistique
 - afin de lever le secret statistique pour leur permettre d'avoir accès aux données détaillées tout en les soumettant à leur tour à l'obligation de respecter le secret statistique, comme c'est le cas pour les statisticiens du service statistique publique.
- Comment travaillent les chercheurs au sein du CASD ?



Environnement de travail du CASD

The screenshot displays two software windows: SAS and Stata. The SAS window is active, showing a file explorer on the left and a journal window on the right. The journal window contains the following text:

```
Journal - (Untitled)
NOTE: Copyright (c) 2002-2008 by SAS Institute Inc.
NOTE: SAS (r) Proprietary Software Licensed to LICENCE CAMPUS G
NOTE: La session est exécutée sur

NOTE: L'initialisation de SAS a ut
temps réel 1.03 sec
temps UC 0.74 sec
```

The Stata window shows the Stata logo and the text "MP - Parallel Edition". The taskbar at the bottom includes icons for Démarrer, Biblio..., SAS, Micro..., WinEdt, Stat..., RGui, Gest..., Inter..., desk..., and system tray with date 11/05/2010 and time 16:27.

Nom	Modifié le	Type	Taille
Sortie	12/04/2018 14:52	Dossier de fichiers	
Sortie.zip	28/05/2010 16:26	Document	8 Ko

Context menu for 'Sortie.zip':

- Ouvrir
- Sortie CASD
- Ouvrir dans une nouvelle fenêtre
- Extraire tout...
- 7-Zip
- Épingler à l'écran d'accueil
- Edit with Notepad++
- Ouvrir avec...
- Partager avec
- Restaurer les versions précédentes
- Envoyer vers
- Couper
- Copier
- Créer un raccourci
- Supprimer
- Renommer
- Propriétés

Les sorties de résultats

- Les chercheurs ont besoin de récupérer des fichiers de résultats mais ils doivent s'assurer qu'ils ne contiennent pas de données ré-identifiantes.
- Le personnel du service data management fait une vérification manuelle :
 - Qui demande du temps et donc un certain délai pour les chercheurs
 - De nombreux logiciels sont disponibles sur le CASD, de ce fait les sorties de résultats sont de formats et de formes très diverses : tableaux, graphiques (dans ce cas on demande les données sources), des régressions

Type:

Tableaux de résultats Régressions/modèles économétriques Autres Cartes Graphiques

Documentation Tables de données Codes/programmes

Les sorties de résultats

- On souhaite fournir un outil aux chercheurs pour automatiser le contrôle des sorties :
 - L'outil doit être maîtrisé par le CASD pour des raisons de sécurité et de traçabilité
 - Il doit parfaitement s'intégrer à l'architecture CASD
 - Compte tenu de la diversité des types de sorties, nous souhaitons nous concentrer sur les données individuelles
- Les logiciels existants (*mu-argus*, *arx par exemple*) sont complexes à intégrer dans l'architecture du CASD et de prise en main compliquée
- L'idée est de construire à partir de notre base de connaissance des sorties et en partenariat avec les chercheurs un dispositif d'anonymisation robuste pour les données individuelles (avec en entrée un format prédéfini)



Le k-anonymat

Estimation traditionnelle du risque de ré-identification

- Travaux de Latanya Sweeney – 1998 : k -anonymat
 - toute cellule (= classe d'équivalence) constituée par une combinaison déterminée de QIDs doit comporter au moins k individus
 - même en connaissant les QIDs d'un individu déterminé, un attaquant ne pourra pas le distinguer des $k-1$ autres individus (au minimum) présentant les mêmes QIDs
- Seuil utilisé couramment
 - k -anonymat supérieur ou égal à 10

Exemple avec trois QIDs : âge, sexe, département

Nom	Age	Sexe	Région	Code postal	Diagnostic
*	$20 < \text{Age} \leq 30$	Féminin	Normandie	*	Cancer
*	$20 < \text{Age} \leq 30$	Féminin	Île de France	*	Infection virale
*	$20 < \text{Age} \leq 30$	Féminin	Normandie	*	Tuberculose
*	$20 < \text{Age} \leq 30$	Masculin	Grand Est	*	Problème cardiaque
*	$20 < \text{Age} \leq 30$	Féminin	Île de France	*	Appendicite
*	$20 < \text{Age} \leq 30$	Masculin	Grand Est	*	Problème cardiaque
*	$\text{Age} \leq 20$	Masculin	Île de France	*	Cancer
*	$20 < \text{Age} \leq 30$	Masculin	Grand Est	*	Problème cardiaque
*	$\text{Age} \leq 20$	Masculin	Île de France	*	Tuberculose
*	$\text{Age} \leq 20$	Masculin	Île de France	*	Infection virale

Exemple avec trois QIDs : âge, sexe, département dans cet exemple, k -anonymat = 2

Nom	Age	Sexe	Région	Code postal	Diagnostic
*	20 < Age ≤ 30	Féminin	Normandie	*	Cancer
*	20 < Age ≤ 30	Féminin	Île de France	*	Infection virale
*	20 < Age ≤ 30	Féminin	Normandie	*	Tuberculose
*	20 < Age ≤ 30	Masculin	Grand Est	*	Problème cardiaque
*	20 < Age ≤ 30	Féminin	Île de France	*	Appendicite
*	20 < Age ≤ 30	Masculin	Grand Est	*	Problème cardiaque
*	Age ≤ 20	Masculin	Île de France	*	Cancer
*	20 < Age ≤ 30	Masculin	Grand Est	*	Problème cardiaque
*	Age ≤ 20	Masculin	Île de France	*	Tuberculose
*	Age ≤ 20	Masculin	Île de France	*	Infection virale



La l -diversité

Il subsiste un risque : l'attaque par homogénéité

Nom	Age	Sexe	Région	Code postal	Diagnostic
*	20 < Age ≤ 30	Féminin	Normandie	*	Cancer
*	20 < Age ≤ 30	Féminin	Île de France	*	Infection virale
*	20 < Age ≤ 30	Féminin	Normandie	*	Tuberculose
*	20 < Age ≤ 30	Masculin	Grand Est	*	Problème cardiaque
*	20 < Age ≤ 30	Féminin	Île de France	*	Appendicite
*	20 < Age ≤ 30	Masculin	Grand Est	*	Problème cardiaque
*	Age ≤ 20	Masculin	Île de France	*	Cancer
*	20 < Age ≤ 30	Masculin	Grand Est	*	Problème cardiaque
*	Age ≤ 20	Masculin	Île de France	*	Tuberculose
*	Age ≤ 20	Masculin	Île de France	*	Infection virale

Il subsiste un risque : l'attaque par homogénéité
car dans cet exemple, l -diversité = 1

Nom	Age	Sexe	Région	Code postal	Diagnostic
*	$20 < \text{Age} \leq 30$	Féminin	Normandie	*	Cancer
*	$20 < \text{Age} \leq 30$	Féminin	Île de France	*	Infection virale
*	$20 < \text{Age} \leq 30$	Féminin	Normandie	*	Tuberculose
*	$20 < \text{Age} \leq 30$	Masculin	Grand Est	*	Problème cardiaque
*	$20 < \text{Age} \leq 30$	Féminin	Île de France	*	Appendicite
*	$20 < \text{Age} \leq 30$	Masculin	Grand Est	*	Problème cardiaque
*	$\text{Age} \leq 20$	Masculin	Île de France	*	Cancer
*	$20 < \text{Age} \leq 30$	Masculin	Grand Est	*	Problème cardiaque
*	$\text{Age} \leq 20$	Masculin	Île de France	*	Tuberculose
*	$\text{Age} \leq 20$	Masculin	Île de France	*	Infection virale

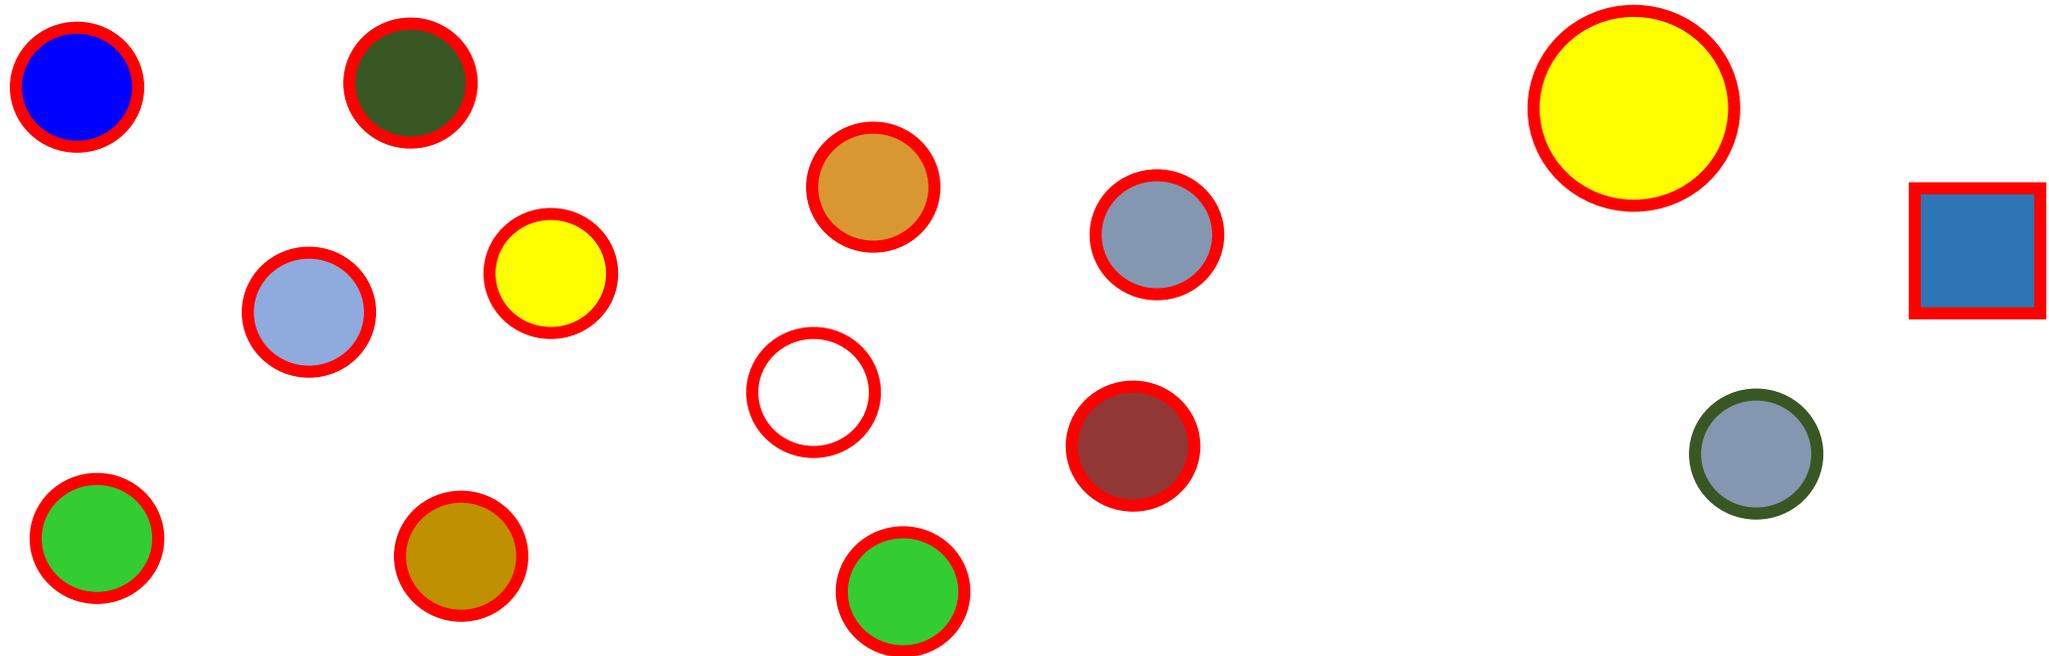
Extension du modèle : la l -diversité

- au moins l modalités de la « variable sensible » doivent être « suffisamment bien représentées » dans chaque cellule (= classe d'équivalence) constituée par une combinaison déterminée de QIDs
- même en connaissant les QIDs d'un individu déterminé, un attaquant ne pourra pas inférer la modalité qui lui correspond parmi les l modalités (au minimum) de la variable sensible représentées par l'ensemble des individus présentant les mêmes QIDs
- seuil utilisé couramment
 - l -diversité égale ou supérieure à 3

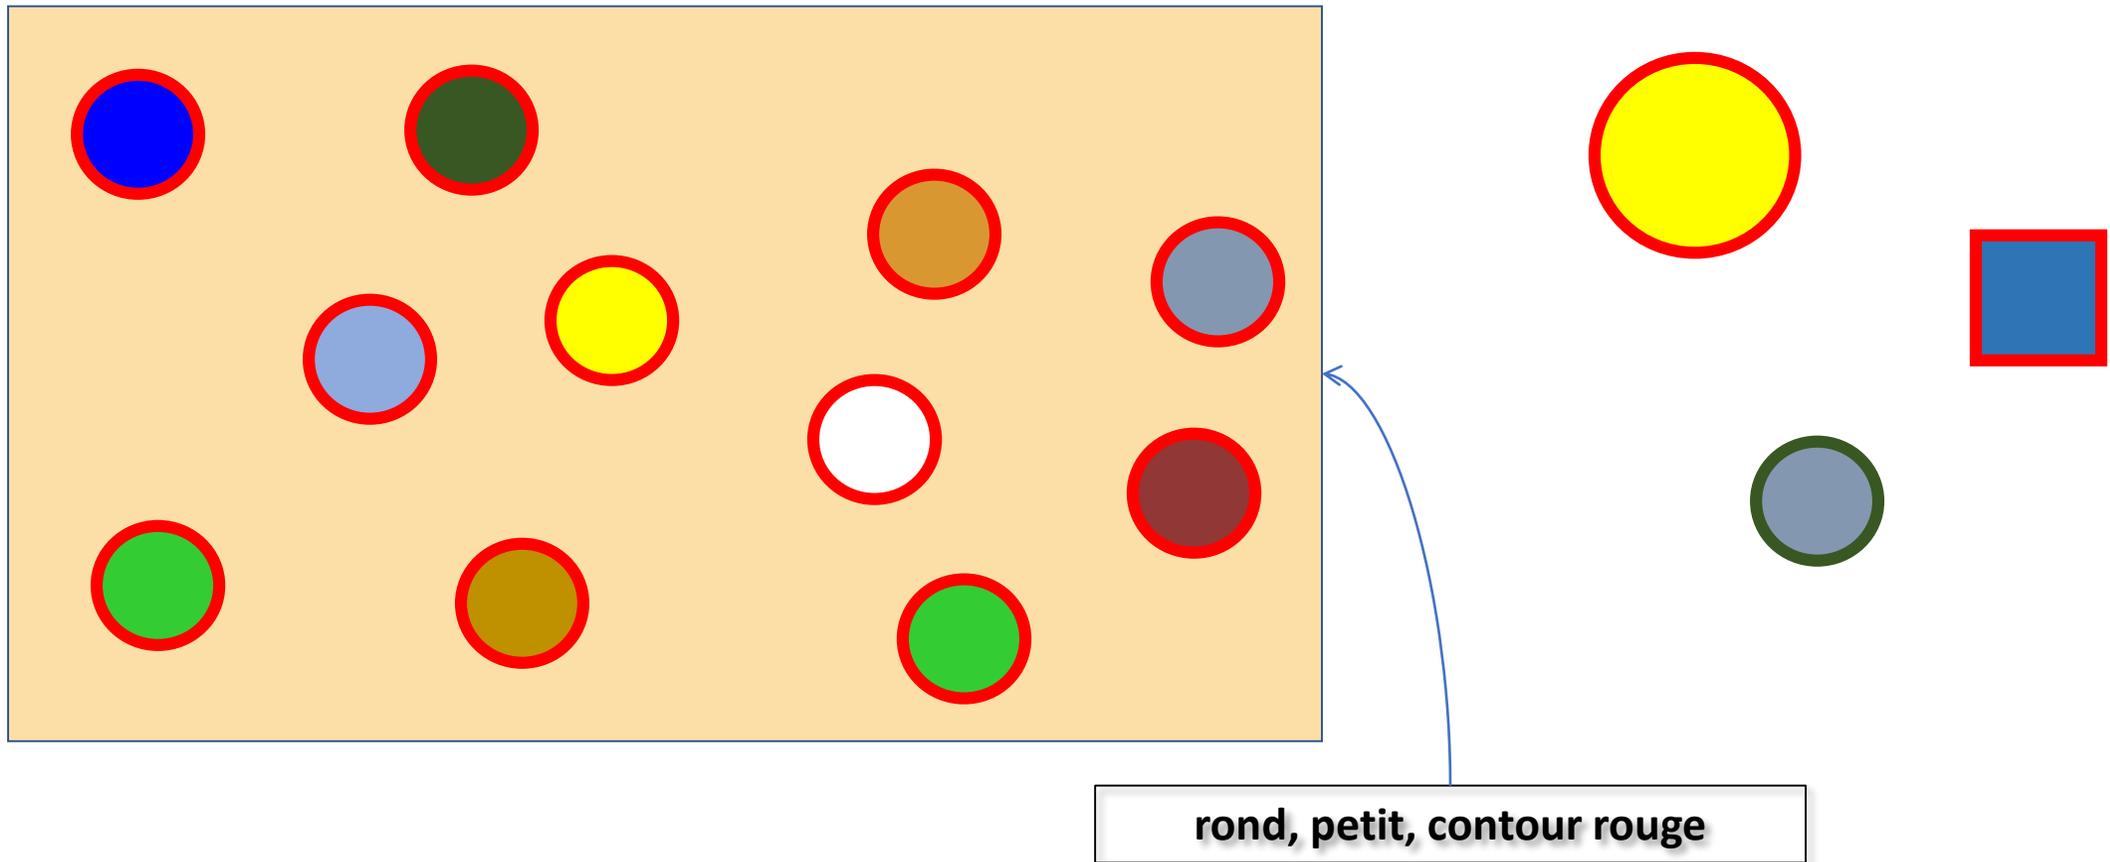


Impact artificiel de la granularité du critère de la l -diversité

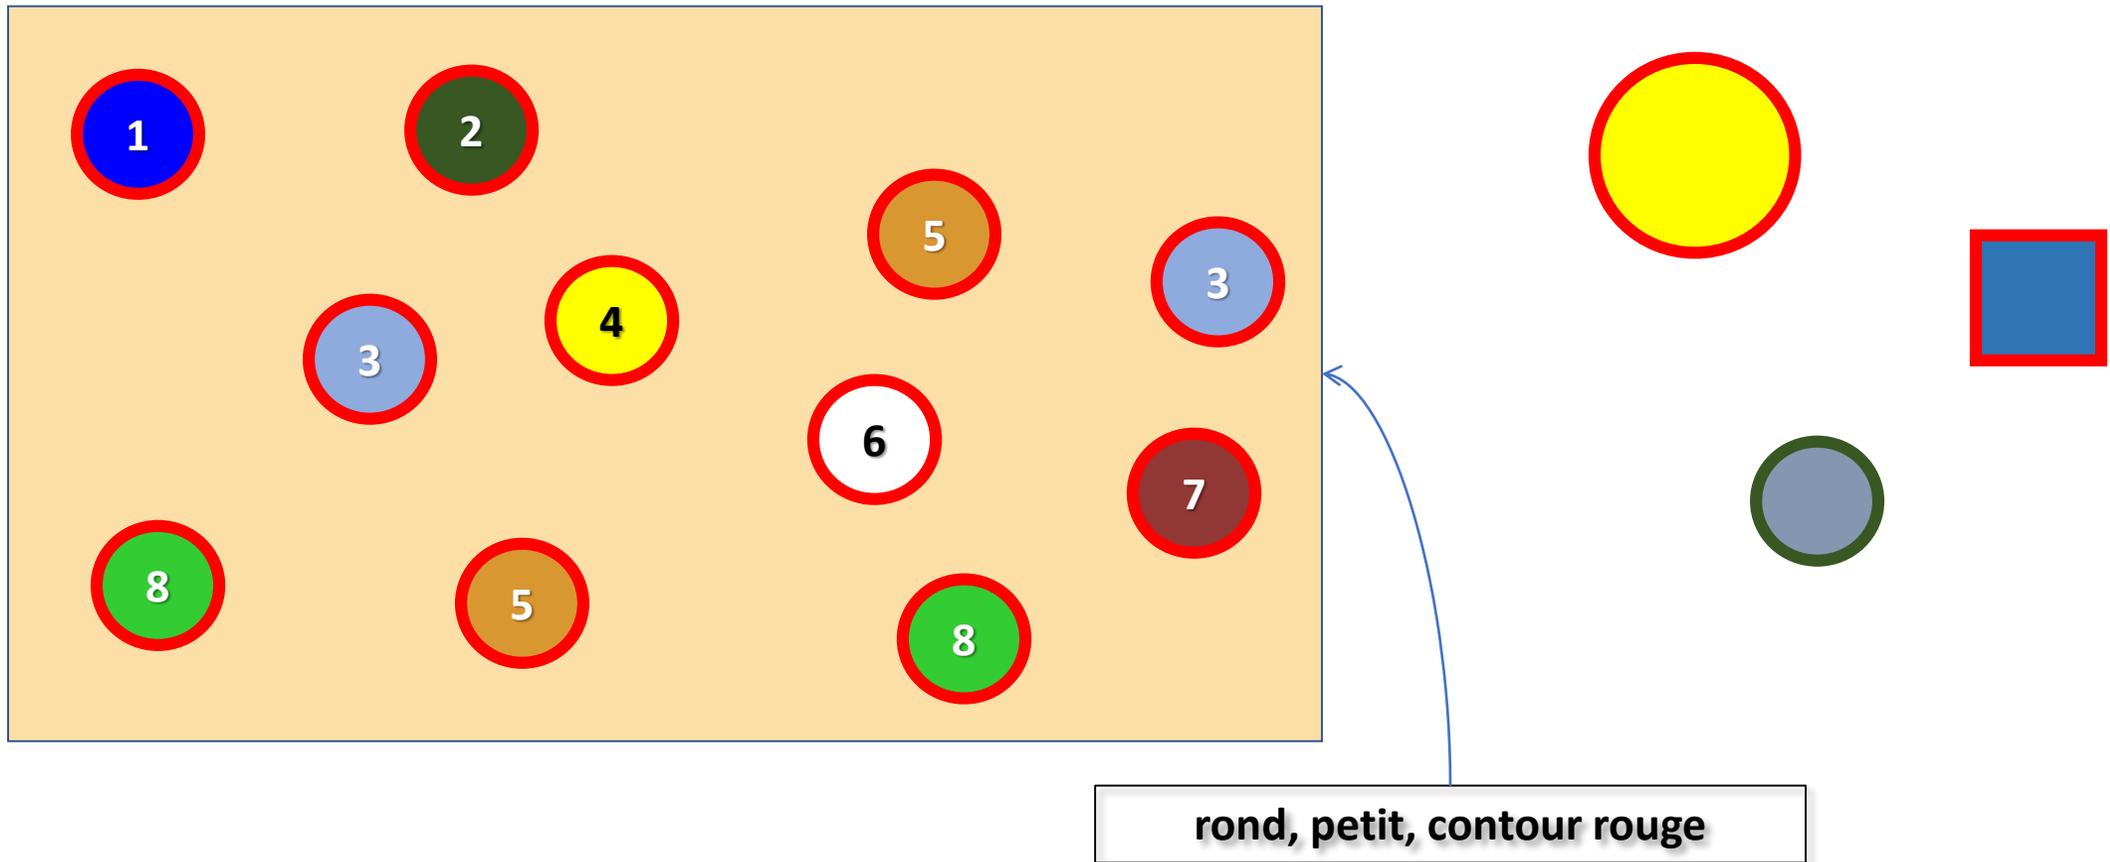
QIDs = forme, taille, contour - donnée sensible = couleur



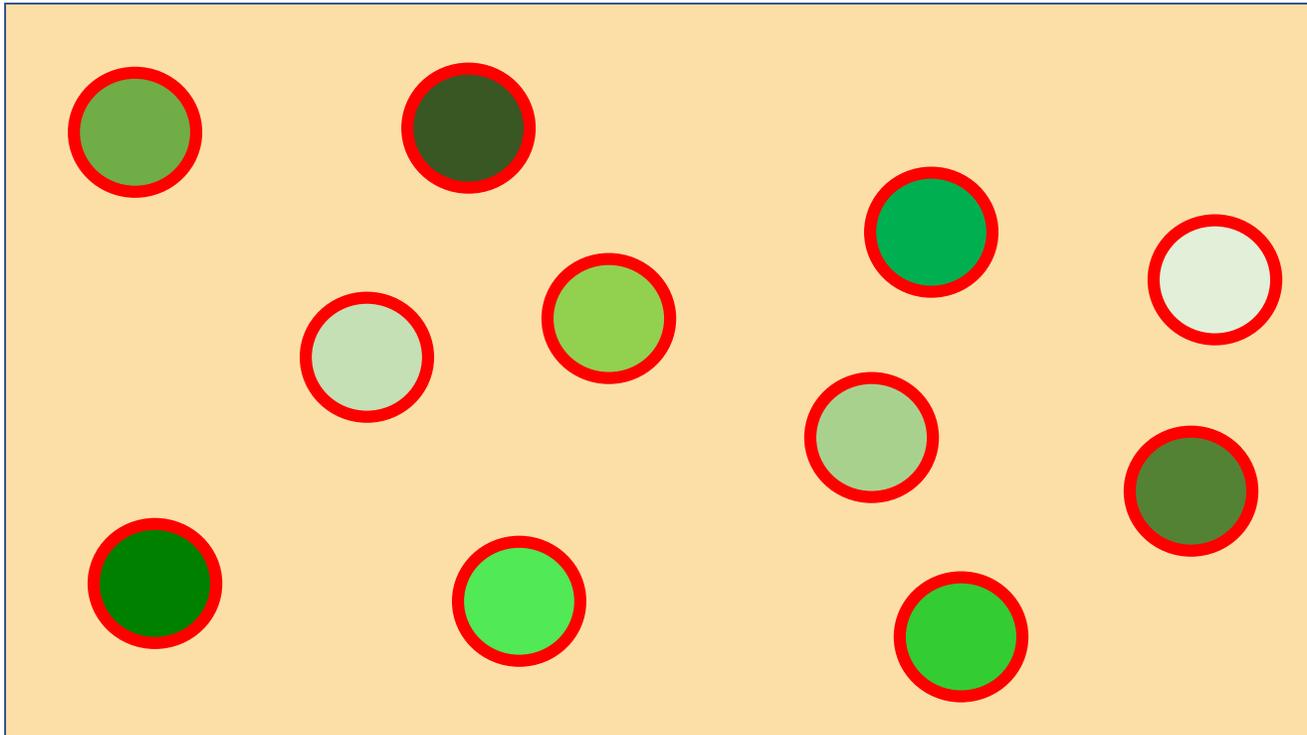
QIDs = forme, taille, contour - donnée sensible = couleur



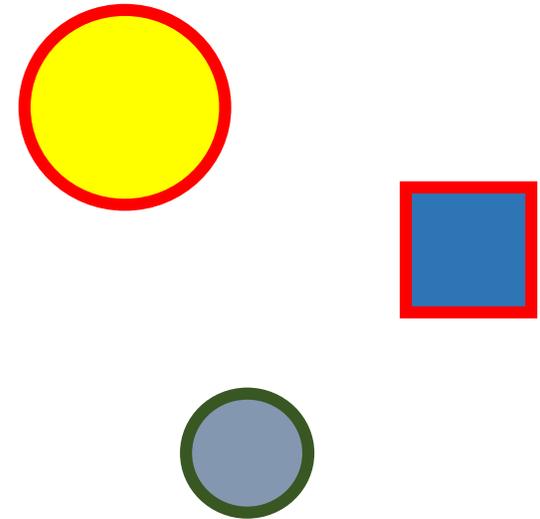
QIDs = forme, taille, contour - donnée sensible = couleur
dans cet exemple, l -diversité = 8



Oui mais... la l -diversité vaut-elle 11 dans cet exemple ?
sûrement pas : la diversité n'est qu'apparente, tous sont verts



11 nuances de vert, mais vert quand même

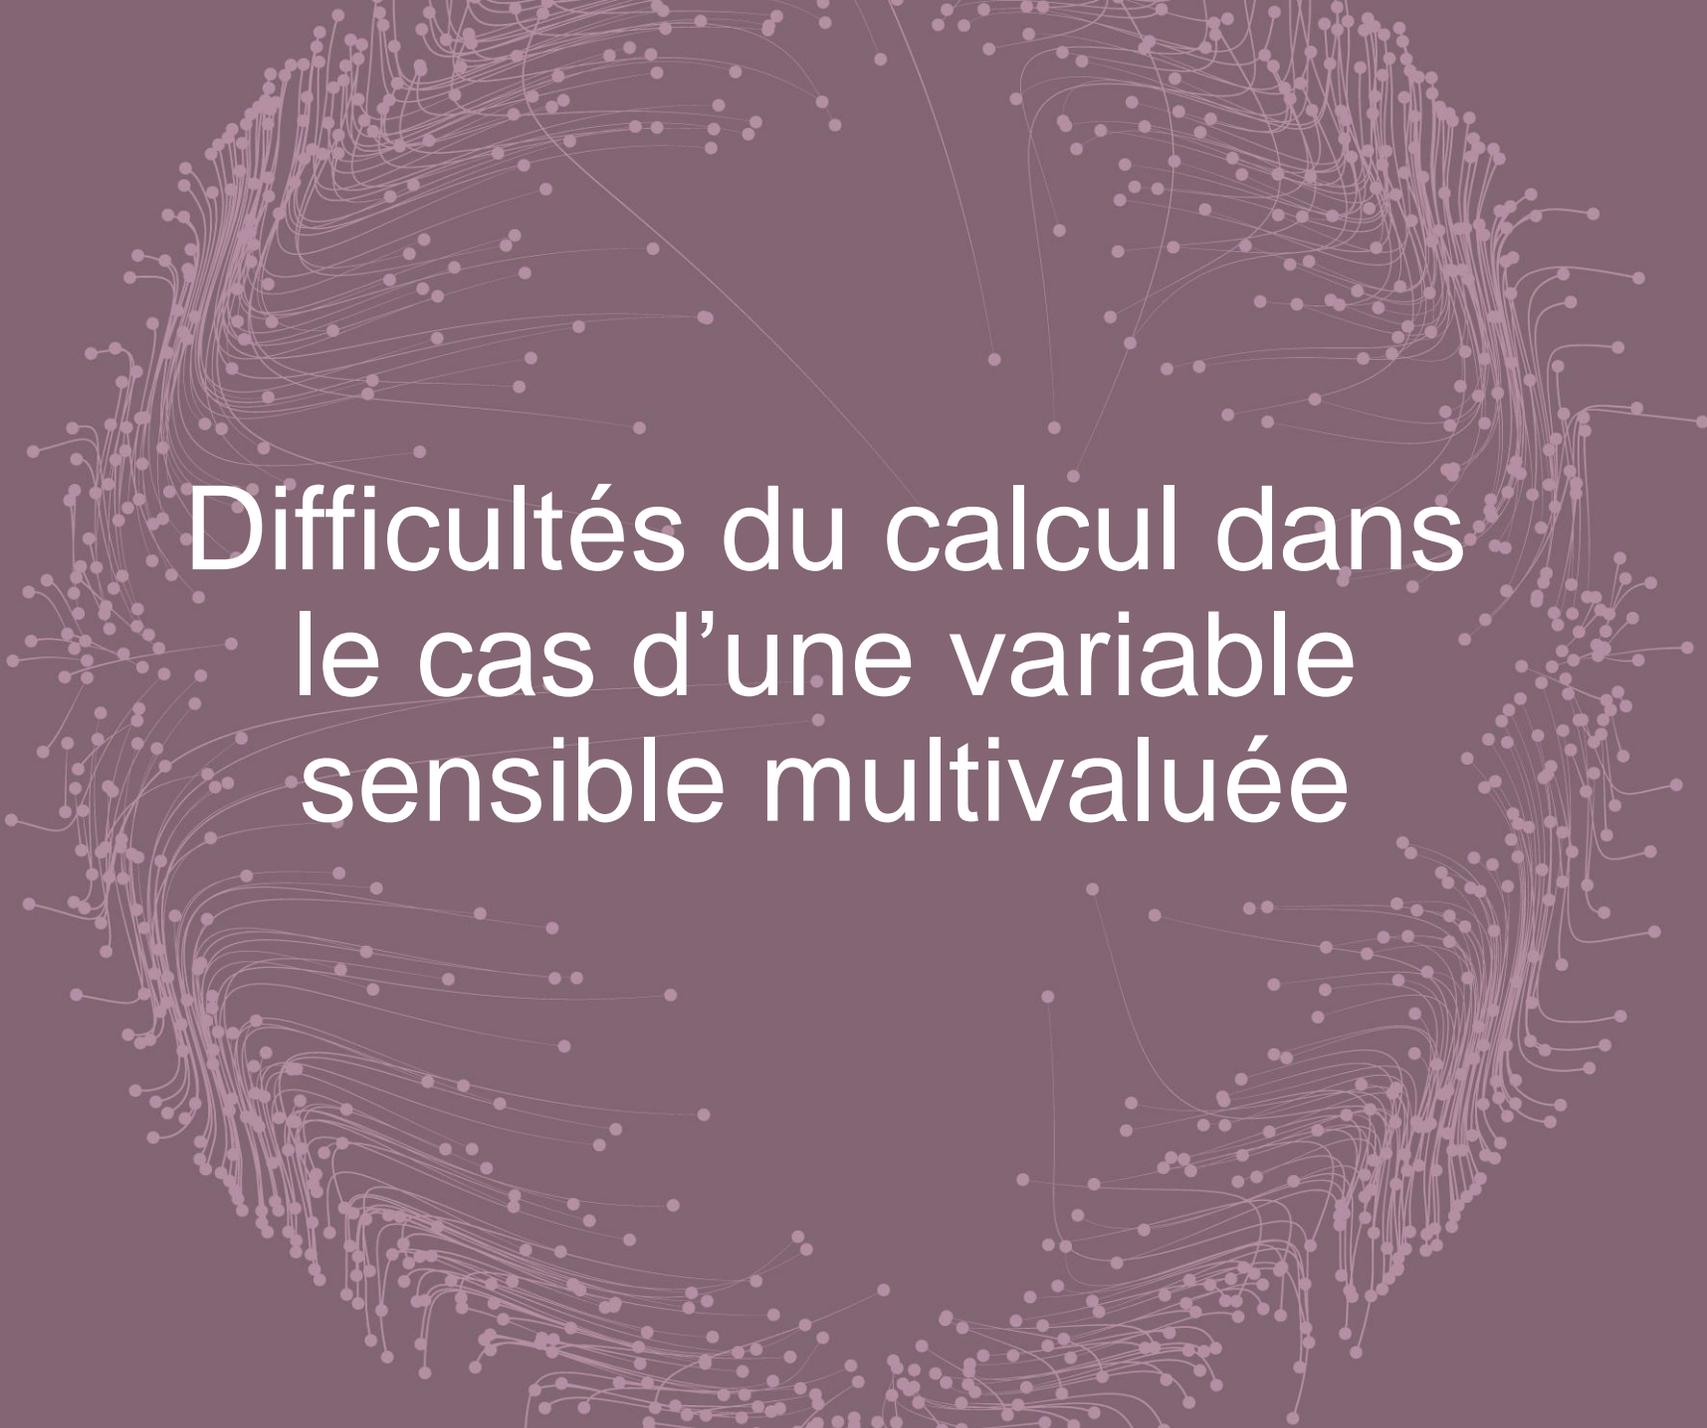


... la l-diversité vaut-elle 11 dans cet exemple ?
sûrement pas : la diversité n'est qu'apparente, tous sont diabétiques

Âge	sexe	région	code	diagnostic
45 à 60 ans	masculin	Hauts de France	E10.7	Diabète sucré de type 1, avec complications multiples
45 à 60 ans	masculin	Hauts de France	E11.0	Diabète sucré de type 2, avec coma
45 à 60 ans	masculin	Hauts de France	E11.00	Diabète sucré de type 2 insulinotraité, avec coma
45 à 60 ans	masculin	Hauts de France	E10.3	Diabète sucré de type 1, avec complications oculaires
45 à 60 ans	masculin	Hauts de France	E11.2	Diabète sucré de type 2, avec complications rénales
45 à 60 ans	masculin	Hauts de France	E10.1	Diabète sucré de type 1, avec acidocétose
45 à 60 ans	masculin	Hauts de France	E11.1	Diabète sucré de type 2, avec acidocétose
45 à 60 ans	masculin	Hauts de France	E10.9	Diabète sucré de type 1, sans complication
45 à 60 ans	masculin	Hauts de France	E10.0	Diabète sucré de type 1, avec coma
45 à 60 ans	masculin	Hauts de France	E10.2	Diabète sucré de type 1, avec complications rénales
45 à 60 ans	masculin	Hauts de France	E11.9	Diabète sucré de type 2, sans complication

Conséquences pratiques

- Une granularité inappropriée de la variable sensible sur laquelle se fonde le calcul de la l -diversité peut aboutir à un résultat faussement rassurant
- La granularité de ce critère doit être adaptée à la finesse descriptive que dévoilent les modalités de cette variable sensible
- En pratique on aura recours au « floutage » de la variable sensible
 - soit en remontant dans son arborescence
 - soit en établissant un mappage *ad hoc* (proxies)



Difficultés du calcul dans
le cas d'une variable
sensible multivaluée

Ce cas de figure est parfait pour la théorie...

Age	Sexe	Région	Diagnostic
45 à 60 ans	masculin	Hauts de France	Cancer
45 à 60 ans	masculin	Hauts de France	Infection virale
45 à 60 ans	masculin	Hauts de France	Tuberculose
45 à 60 ans	masculin	Hauts de France	Problème cardiaque
45 à 60 ans	masculin	Hauts de France	Appendicite
45 à 60 ans	masculin	Hauts de France	Problème cardiaque
45 à 60 ans	masculin	Hauts de France	Cancer
45 à 60 ans	masculin	Hauts de France	Problème cardiaque
45 à 60 ans	masculin	Hauts de France	Tuberculose
45 à 60 ans	masculin	Hauts de France	Infection virale

... mais dans la vraie vie, voici ce qu'on observe

Age	Sexe	Région	Diagnostics
45 à 60 ans	masculin	Hauts de France	Cancer ; Diabète ; Tuberculose ; Hypertension
45 à 60 ans	masculin	Hauts de France	Infection virale ; Pneumopathie ; Diabète
45 à 60 ans	masculin	Hauts de France	Tuberculose ; Diabète ; Infection virale
45 à 60 ans	masculin	Hauts de France	Problème cardiaque ; Hypertension
45 à 60 ans	masculin	Hauts de France	Appendicite ; Hypertension ; Parkinson
45 à 60 ans	masculin	Hauts de France	Problème cardiaque ; Diabète ; Alzheimer
45 à 60 ans	masculin	Hauts de France	Cancer ; Hypertension ; Infection bactérienne
45 à 60 ans	masculin	Hauts de France	Problème cardiaque ; Alzheimer ; Diabète
45 à 60 ans	masculin	Hauts de France	Tuberculose ; Hypertension
45 à 60 ans	masculin	Hauts de France	Infection virale ; Ostéoporose ; Diabète ; Hypertension ; Potomanie

... mais dans la vraie vie, voici ce qu'on observe

Age	Sexe	Région	Diagnostics
45 à 60 ans	masculin	Hauts de France	Cancer ; Diabète ; Tuberculose ; Hypertension
45 à 60 ans	masculin	Hauts de France	Infection virale ; Pneumopathie ; Diabète
45 à 60 ans	masculin	Hauts de France	Tuberculose ; Diabète ; Infection virale
45 à 60 ans	masculin	Hauts de France	Problème cardiaque ; Hypertension
45 à 60 ans	masculin	Hauts de France	Appendicite ; Hypertension ; Parkinson
45 à 60 ans	masculin	Hauts de France	Problème cardiaque ; Diabète ; Alzheimer
45 à 60 ans	masculin	Hauts de France	Cancer ; Hypertension ; Infection bactérienne
45 à 60 ans	masculin	Hauts de France	Problème cardiaque ; Alzheimer ; Diabète
45 à 60 ans	masculin	Hauts de France	Tuberculose ; Hypertension
45 à 60 ans	masculin	Hauts de France	Infection virale ; Ostéoporose ; Diabète ; Hypertension ; Potomanie

... mais dans la vraie vie, voici ce qu'on observe

Age	Sexe	Région	Diagnostics
45 à 60 ans	masculin	Hauts de France	Cancer ; Diabète ; Tuberculose ; Hypertension
45 à 60 ans	masculin	Hauts de France	Infection virale ; Pneumopathie ; Diabète
45 à 60 ans	masculin	Hauts de France	Tuberculose ; Diabète ; Infection virale
45 à 60 ans	masculin	Hauts de France	Problème cardiaque ; Hypertension
45 à 60 ans	masculin	Hauts de France	Appendicite ; Hypertension ; Parkinson
45 à 60 ans	masculin	Hauts de France	Problème cardiaque ; Diabète ; Alzheimer
45 à 60 ans	masculin	Hauts de France	Cancer ; Hypertension ; Infection bactérienne
45 à 60 ans	masculin	Hauts de France	Problème cardiaque ; Alzheimer ; Diabète
45 à 60 ans	masculin	Hauts de France	Tuberculose ; Hypertension
45 à 60 ans	masculin	Hauts de France	Infection virale ; Ostéoporose ; Diabète ; Hypertension ; Potomanie

Tous ont (au moins) du diabète ou de l'hypertension dans cet exemple, l-diversité = 2

Age	Sexe	Région	Diagnostics
45 à 60 ans	masculin	Hauts de France	Cancer ; Diabète ; Tuberculose ; Hypertension
45 à 60 ans	masculin	Hauts de France	Infection virale ; Pneumopathie ; Diabète
45 à 60 ans	masculin	Hauts de France	Tuberculose ; Diabète ; Infection virale
45 à 60 ans	masculin	Hauts de France	Problème cardiaque ; Hypertension
45 à 60 ans	masculin	Hauts de France	Appendicite ; Hypertension ; Parkinson
45 à 60 ans	masculin	Hauts de France	Problème cardiaque ; Diabète ; Alzheimer
45 à 60 ans	masculin	Hauts de France	Cancer ; Hypertension ; Infection bactérienne
45 à 60 ans	masculin	Hauts de France	Problème cardiaque ; Alzheimer ; Diabète
45 à 60 ans	masculin	Hauts de France	Tuberculose ; Hypertension
45 à 60 ans	masculin	Hauts de France	Infection virale ; Ostéoporose ; Diabète ; Hypertension ; Potomanie

En résumé, dans le cas d'une variable multivaluée

- Le calcul de la l -diversité s'apparente au problème connu en algorithmique sous le nom de « problème de couverture maximale » :
 - dans notre exemple : combien de diagnostics sont nécessaires pour couvrir la totalité des individus de la classe d'équivalence ?
- Ce problème est NP-difficile (théorie de la complexité)
- En raison de la durée des calculs pour le résoudre de manière exacte, on a recours habituellement à un algorithme d'approximation (dit « algorithme glouton ») qui fournit donc des valeurs approchées

En pratique, avec l'exemple des diagnostics...

- Étant donné que le seuil utilisé couramment est
 - l -diversité égale ou supérieure à 3
- nous préconisons une solution alternative pragmatique, en deux étapes :
 1. **un seul diagnostic suffit-il à couvrir tous les individus de la classe ?**
 - l'algorithme est très simple et quasi-immédiat
 - si oui, la l -diversité de cette classe est égale à 1
 - si non, on passe à l'étape suivante
 2. **deux diagnostics suffisent-ils à couvrir tous les individus de la classe ?**
 - l'algorithme est relativement simple et très rapide
 - si oui, la l -diversité de cette classe est égale à 2
 - si non, la l -diversité de cette classe est égale ou supérieure à 3



Travaux à venir

Travaux à venir

- Finaliser l'implémentation expérimentale de la méthode
- Faire évaluer la pertinence des données résultantes anonymisées par des chercheurs
- Réaliser le développement de la méthode :
 - en la rendant générique (sans a priori sur les données),
 - en prenant en compte les contraintes de performance,
 - et en prenant en compte son intégration dans l'architecture sécurisée du CASD, notamment pour les questions de traçabilité.



Merci pour votre
attention

Comme les chimistes le font avec des produits sensibles



