

Pourquoi l'analyse de classification...

- On peut rechercher des différences (et non seulement des similitudes)
- Pas de restrictions relativement au nombre de cas par variable
- Permet de sauvegarder une variable d'appartenance à une classe que l'on peut réutiliser dans d'autres analyses
- Tient compte des profils de réponse
- Permet de "visualiser" les profils de réponse
- Multiples mesures de distance disponibles
- Multiples algorithmes de regroupement
- Sert à construire/valider des typologies

4

Les étapes (selon Rapkin et Luke, 1993)

- 1. Identifier les "cas": de quel type de cas s'agit-il? Est-ce qu'on les conserve tous?
- 2. Choisir, réduire, standardiser/pondérer les variables.
- 3. Décider de la mesure de distance entre les cas et entre les groupes de cas.
- 4. Choisir l'algorithme de regroupement
- 5. Déterminer le nombre de classes
- 6. Choisir le logiciel statistique et procéder à l'analyse

5

Les étapes (selon Rapkin et Luke, 1993)

Suite

- 7. Interpréter les profils de chaque classe
- 8. Vérifier la stabilité de la solution
- 9. Vérifier la validité de la solution
- 10. Présenter les résultats.

6

5. Déterminer le nombre de classes

Les critères

- La soudaine augmentation de la distance entre les classes (test de l'éboulis ou du "coude de Cattell").
- Le nombre de cas par classe.
- La capacité de la solution à différencier entre les profils.
- L'homogénéité des profils internes des classes.
- L'ajout de variance expliquée par les classes.
- La stabilité des solutions.
- L'interprétation

13

6. Quel logiciel utiliser?

- SPSS ou STATA :
 - a. Facile
 - b. Multiples méthodes pour standardiser (SPSS)
 - c. Multiples mesures de distance
 - d. Multiples méthodes d'agglomération (Stata: Kmedian)
 - e. SPSS a maintenant une two-step method qui permet de faire la classification avec des variables nominales et continues.
- SPAD, DTM-VIC, TRI-DEUX:
 - a. Possibilité de faire l'analyse en combinaison avec l'analyse factorielle des correspondances; la distance est déterminée par le positionnement des cas sur les facteurs (axes).
 - b. Représentation visuelle très intéressante

14

7. Interpréter les profils

- Demande l'utilisation de procédures complémentaires:
 - a. Anova, manova pour voir les différences de moyennes.
 - b. Graphiques représentant le processus d'agglomération (à utiliser quand il y a peu de cas: villes, pays, etc.).
 - c. Graphiques de moyennes pour visualiser les profils.
 - d. Dans SPAD: représentation visuelle des classes.
- Est-ce que les profils qu'on en dégage ont un sens dans le cadre de nos recherches, de la théorie, etc. Peut-on "mettre un nom" sur chaque type?

15
