

# **Cours d'Analyse Multivariée Approfondie**

## **STA 201**

### **2011-2012**

## **Projet**

**Au choix :** un commentaire d'article ou une étude de logiciel.

### **1. Cas d'un article**

Le travail personnel, de l'ordre de 15 pages dactylographiées, consiste à analyser un article scientifique : il ne s'agit ni de le traduire ni de le paraphraser mais d'en faire un exposé synthétique destiné à un statisticien qui ne l'a pas lu et veut savoir de quoi il retourne. Certains articles peuvent nécessiter une recherche de documents complémentaires. Une application sur des données personnelles des méthodes exposées dans l'article sera grandement appréciée. Lorsque les notations utilisées diffèrent trop de celles du cours, il convient de les reformuler.

### **2. Cas d'une étude de logiciel**

Le travail pourra être fait à deux. Il consistera en une présentation de la méthode et du programme (ou de la procédure analysée) avec un « manuel » simple d'utilisation et une application à des données réelles (autres que les jeux d'essais fournis avec le logiciel).

## **Procédure de choix**

Chaque élève (ou binôme éventuellement pour les logiciels) régulièrement inscrit au cours propose par courrier électronique 3 sujets classés par ordre de préférence. Les premiers arrivés sont les premiers servis avec priorité pour les élèves qui assistent au cours (!). La liste est mise à jour au fur et à mesure : les sujets **surlignés en jaune** ne peuvent plus être choisis. Si les 3 choix sont déjà pris, on recommence. Conseil : regardez les articles avant de choisir...

## **Remise du travail :**

Au plus tard le 15 septembre 2012. Aucun report ne sera accepté. Dans le cas d'une note de lecture d'un article, il est **impératif** d'y joindre une copie de l'article analysé. Les rapports seront envoyés exclusivement par courrier électronique sous forme d'un **fichier unique** au format PDF à [gilbert.saporta@cnam.fr](mailto:gilbert.saporta@cnam.fr).

## Articles

La plupart des articles sont téléchargeables depuis les postes informatique du CNAM, sinon par accès à distance aux ressources électroniques : <http://bibliotheque.cnam.fr/ressources-electroniques/comment-se-connecter-a-distance/>

Pour la Revue de Statistique Appliquée, le site est <http://www.numdam.org/numdam-bin/feilleter?j=RSA&sl=0>

1. Donald R. Jensen and Donald E. Ramirez: Anomalies in the Foundations of Ridge Regression, *International Statistical Review*, Volume 76, Issue 1, April 2008, pages 89–105 suivi de Prasenjit Kapat, Prem K. Goel : Anomalies in the Foundations of Ridge Regression: Some Clarifications, *International Statistical Review*, Volume 78, Issue 2, pages 209–215, August 2010 et Donald R. Jensen, Donald E. Ramirez : Anomalies in Ridge Regression: Rejoinder, *International Statistical Review*, Volume 78, Issue 2, pages 215–217, August 2010 Exceptionnellement cet ensemble de 3 articles peut faire l'objet d'un rapport rédigé à deux. Attribué à Hervé Galicher
2. P. CAZES, A. CHOUAKRIA, E. DIDAY, Y. SCHEKTMAN - Extension de l'Analyse en Composantes Principales à des données de type intervalle, Revue de Statistique Appliquée. Vol. XLV, N° 3, 1997 attribué à Anas LAAOUINI
3. F. FERRATY. - Estimation de transformations optimales en ACP curvilinéaire, Revue de Statistique Appliquée, Vol. XLV, N° 1, 1997 attribué à Marie-Hélène Jean-Elie
4. J. PAGES. Eléments de comparaison entre l'Analyse Factorielle Multiple et la méthode STATIS, Revue de Statistique Appliquée, Vol. XLIV, N° 4, 1996 attribué à Thierry Hossin
5. J.PAGES , Analyse factorielle de données mixtes, Revue de Statistique Appliquée, 52, n°4, 2004 attribué à Jérôme Ballanger
6. A.HYVARINEN, E.OJA – Independent component analysis: algorithms and applications, Neural networks, vol 13, 411-430, 2000, [http://www.cis.hut.fi/aapo/papers/ICNN99\\_tutorialweb/](http://www.cis.hut.fi/aapo/papers/ICNN99_tutorialweb/) attribué à Abdelbasset KHALIFI
7. B.SCHOLKOPF, A.SMOLA, K.R. MULLER- Nonlinear Component Analysis as a Kernel Eigenvalue Problem, Neural Computation, 10:1299-1319, 1998. Technical Report No. 44, 1996, Max Planck Institut für biologische Kybernetik, Tübingen. <http://www.kernel-machines.org/papers/nlpca.ps.gz>
8. N. Louw and S.J. Steel: variable selection in kernel Fisher discriminant analysis by means of recursive feature elimination Computational Statistics & Data Analysis, Volume 51, Issue 3, December 2006, Pages 2043-2055
9. M.Tenenhaus : La régression logistique PLS, in Analyse des données qualitatives, (J. Drosbeke, M. Lejeune & G. Saporta, Eds), Technip, Paris, 2005, p. 263-275, attribué à Thomas Besançon

10. P.BASTIEN, M.TENENHAUS, V.ESPOSITO-VINZI : PLS Generalized linear regression , Computational Statistics and Data Analysis, 48, 17-46, (2005) attribué à Elisabeth Mineau
11. Abba M. KRIEGER, Paul E. GREEN - A Generalized Rand-Index Method for Consensus Clustering of Separate Partitions of the Same Data Base, J. of Classification 16:63-89 (1999). Attribué à Richard Tran
12. A.D. GORDON, M. VICHI - Partitions of Partitions, J. of Classification 15:265-285 (1998) attribué à Alexis Lautrette
- 13.G.DIANA, C.TOMMASI – Cross validation methods in principal component analysis: a comparison., Statistical Methods and Applications, vol 11, n°1,71-82 (2002) attribué à Vivien El Jalti
14. A.BEN-HUR, D.HORN, H.T. SIEGELMANN, V. VAPNIK, Support Vector Clustering, Journal of Machine Learning Research, 2:125-137, 2001.  
<http://www.ai.mit.edu/projects/jmlr/papers/volume2/horn01a/rev1/abstract.html>  
attribué à Ambroise Decilap
15. Sugnet Gardner and Niël J. le Roux, Extensions of Biplot Methodology to Discriminant Analysis, Journal of Classification, 22, n°1,pp 59 – 86, (2005)
16. Cathy W.S. Chen ,Jennifer S.K. Chan , Mike K.P. So and Kevin K.M. Lee: Classification in segmented regression problems, Computational Statistics & Data Analysis Volume 55, Issue 7, 1 July 2011, Pages 2276-2287 attribué à Philippe Le Bozec
17. Van Gesteel, and al. A support vector machine approach to credit scoring,  
<http://www.geocities.com/joaoagarcia18/BANKFINVer4.pdf> attribué à Quentin AFFAGARD
18. Thaddeus Tarpey, Kimberly K. J. Kinateder : Clustering Functional Data , Journal of Classification, 20, n°1 pp. 93 - 114 (2003)
19. Eric J. Beh and Luigi D'Ambra :Some Interpretative Tools for Non-Symmetrical Correspondence Analysis, Journal of Classification, Volume 26, Number 1 / avril 2009, 55-76
20. Joost van Rosmalen, Patrick J. F. Groenen, Javier Trejos and William Castillo: Optimization Strategies for Two-Mode Partitioning, Journal of Classification, Volume 26, Number 2 / août 2009, 155-181
21. Roman Rosipal, Leonard J. Trejo: Kernel Partial Least Squares Regression in Reproducing Kernel Hilbert Space , JMLR Special Issue on Kernel Methods, 2001  
<http://www.jmlr.org/papers/v2/rosipal01a.html>
22. Donatella Vicari and Maurizio Vichi :Structural Classification Analysis of Three-Way Dissimilarity Data, Journal of Classification, Volume 26, Number 2 / août 2009, 121-154
23. A.Buja, D.Swayne: Visualization Methodology for Multidimensional Scaling, Journal of Classification, Volume 19, Number 1, 2002, Pages: 7 – 43 attribué à Selma Obretin

24. Mingan Yang and David B. Dunson : Bayesian Semiparametric Structural Equation Models with Latent Variables, *Psychometrika*, Volume 75, Number 4, 675-693 attribué à César Zinga
25. Michel van de Velden, Optimal Scaling of Paired Comparison Data , *Journal of Classification*, 21, n°1 pp89 – 109, (2004)
26. Jieping Ye, Characterization of a Family of Algorithms for Generalized Discriminant Analysis on Undersampled Problems , *Journal of Machine Learning Research*, 6:483–502, 2005. , <http://jmlr.csail.mit.edu/papers/volume6/ye05a/ye05a.pdf> attribué à François Salamon
27. Ana M. Aguilera, Manuel Escabias and Mariano J. Valderrama , Using principal components for estimating logistic regression with high-dimensional multicollinear data, *Computational Statistics & Data Analysis*, Volume 50, Issue 8, Pages 1905-1924, (2006) attribué à KARAMOKO Vadjawe
28. S. Bougeard, M. Hanafi and E.M. Qannari: Continuum redundancy–PLS regression: A simple continuum approach, *Computational Statistics & Data Analysis*, volume 52, n°7, (2008) pages 3686-3696 attribué à Thouraya Nales
29. Raffaella Piccarreta : Classification trees for ordinal variables, *Computational Statistics*, Volume 23, Number 3 (2008) pages 407-427 attribué à Bassirou Diagne
30. Joaquín Pacheco, Silvia Casado, Laura Núñez and Olga Gómez Analysis of new variable selection methods for discriminant analysis • *Computational Statistics & Data Analysis*, Volume 51, n°3, Pages 1463-1478
31. António Pedro Duarte Silva and Paula Brito , Linear discriminant analysis for interval data, *Computational Statistics*, Volume 21, Number 2 / June, 2006 , 289-308
32. Govaert, G., Classification binaire et modèles. *Revue de Statistique Appliquée*, 38 no. 1 (1990), p. 67-81 attribué à Michel Vivier
33. Celeux, G. Classification et modèles. *Revue de Statistique Appliquée*, 36 no. 4 (1988), p. 43-57 attribué à Abdallah HALIMI
34. Isabella Morlini: A latent variables approach for clustering mixed binary and continuous variables within a Gaussian mixture model *Advances in Data Analysis and Classification* Volume 6, Number 1, 5-28, 2012
35. M. Escabias, A.M. Aguilera, M.J. Valderrama :Functional PLS logit regression model. *Computational Statistics & Data Analysis*, Volume 51, Issue 10, 15 June 2007, Pages 4891-4902
36. Michael J. Brusco, Renu Singh and Douglas Steinley : Variable Neighborhood Search Heuristics for Selecting a Subset of Variables in Principal Component Analysis, *Psychometrika*, Volume 74, Number 4 / décembre 2009, 705-726
37. Heungsun Hwang:Regularized Generalized Structured Component Analysis, *Psychometrika*, Volume 74, Number 3, 517-530 attribué à Ngakue Dany

38. Ke-Hai Yuan: Identifying Variables Responsible for Data not Missing at Random; Psychometrika, Volume 74, Number 2, 233-256 attribué à Elisabeth Champion

39. Douglas Steinley and Michael J. Brusco: Selection of Variables in Cluster Analysis: An Empirical Comparison of Eight Procedures, Psychometrika, Volume 73, Number 1 / mars 2008, 125-144

40. Pier Alda Ferrari and Silvia Salini: Complementary Use of Rasch Models and Nonlinear Principal Components Analysis in the Assessment of the Opinion of Europeans About Utilities, Journal of Classification, DOI: 10.1007/s00357-011-9081-0

41. Rosaria Lombardo and Jacqueline J. Meulman: Multiple Correspondence Analysis via Polynomial Transformations of Ordered Categorical Variables, Journal of Classification Volume 27, Number 2, 191-210

42. Mark Ming-Tso Chiang and Boris Mirkin : Intelligent Choice of the Number of Clusters in K-Means Clustering: An Experimental Study with Different Cluster Spreads Journal of Classification, Volume 27, Number 1, 3-40

43. Kohei Adachi: Constrained principal component analysis of standardized data for biplots with unit-length variable vectors, Advances in Data Analysis and Classification Volume 5, Number 1, 23-36

44. Hye Won Suk and Heungsun Hwang : Regularized fuzzy clusterwise ridge regression, Advances in Data Analysis and Classification, Volume 4, Number 1, 35-51

45. Véronique Cariou, Stéphane Verdun, Emmanuelle Diaz, El Mostafa Qannari and Evelyne Vigneau: Comparison of three hypothesis testing approaches for the selection of the appropriate number of clusters of variables, :Advances in Data Analysis and Classification Volume 3, Number 3, 227-241 attribué à Wajihah Syed

46. Julie Josse, Jérôme Pagès and François Husson : Multiple imputation in principal component analysis Advances in Data Analysis and Classification Volume 5, Number 3, 231-246, 2011 attribué à Isabelle Attia

47. Michiel Debruyne and Tim Verdonck: Robust kernel principal component analysis and classification. Advances in Data Analysis and Classification Volume 4, Numbers 2-3, 151-167, 2010

48. Olcay Arslan : Weighted LAD-LASSO method for robust parameter estimation and variable selection in regression. Computational Statistics & Data Analysis, Volume 56, Issue 6, June 2012, Pages 1952–1965 attribué à Alexandre Chamboredon

49. Heungsun Hwang, Kwanghee Jung, Yoshio Takane and Todd S. Woodward: Functional Multiple-Set Canonical Correlation Analysis.Psychometrika Volume 77, Number 1, 48-64, 2012

50. Hidetoshi Matsuia, Sadanori Konish: Variable selection for functional regression models via the L1 regularization. Computational Statistics & Data Analysis, Volume 55, Issue 12, 1 December 2011, Pages 3304–3310

51. Julie Josse, Marie Chavent, Benot Liquet and François Husson : Handling Missing Values with Regularized Iterative Multiple Correspondence Analysis. Journal of Classification Volume 29, Number 1, 91-116, 2012 attribué à Fabrice Borel-Mathurin

52. Antonello D'Ambra and Pietro Amenta: Handling Missing Values with Regularized Iterative Multiple Correspondence Analysis, Journal of Classification Volume 28, Number 1, 70-92, 2011

## Logiciels

1. Procédure MODECLUS de SAS attribué à Ahmed CHENNOUFI
2. Procédure ACECLUS de SAS attribué à Baptiste Yon et Kevin Quellec
3. Procédure MDS de SAS attribué à Anatilik et Mada
4. Procédure VARCLUS de SAS attribué à Rida JALAL & Oussama ALAOUI BELGHITI
5. Procédure PLS de SAS attribué à NGOMA MBAMBY LUC
6. Procédure GAM de SAS attribué à Mariam Binaté et Mélina Brichory
7. Procédure FACTOR de SAS attribué à Hasni Aymen et Martinez Emmanuel
8. Procédure LOESS de SAS attribué à Stéphane Mendy et Toan Nguyen-Huu
9. Procédure KDE de SAS attribué à Olivier Chansin
10. Procédures PHREG et TPHREG de SAS attribué à Rhesus Ousmane Lebamba
11. Procédures MI et MIANALYZE de SAS attribué à Léodas Julien
12. Procédure ROBUSTREG de SAS attribué à Hanifa Belhammou et Ilhame Hajji
13. Procédure QUANTREG de SAS attribué à Aurelien Mouenet et Menchu Dieudonné Jim Hero
14. Procédure PRINQUAL de SAS attribué à Guillaume Bourdon et Binh Nguyen
15. Procédure TRANSREG de SAS attribué à Amandine Carriere et Marlène Escarnot

16. Arbres et graphes de décision: SIPINA et TANAGRA <http://eric.univ-lyon2.fr/~ricco/sipina.html> <http://eric.univ-lyon2.fr/~ricco/tanagra> attribué à DRISS ASRARY
17. Classes latentes : logiciel LatentGold version de démo gratuite téléchargeable à l'adresse : <http://www.statisticalinnovations.com/> attribué à François-Marie DIBON
18. Classes latentes : PROC LCA développée à Penn State University : <https://methodology.psu.edu/downloads/proclcalta> attribué à Mustapha AKRID