

STATISTIQUE ET ANALYSE DES DONNÉES

GUY BERNARD

Quelques réflexions sur des logiciels pour l'analyse statistique - Comparaison de GENSTAT, BMPDP et SPSS

Statistique et analyse des données, tome 3, n° 1 (1978), p. 53-62

http://www.numdam.org/item?id=SAD_1978__3_1_53_0

© Association pour la statistique et ses utilisations, 1978, tous droits réservés.

L'accès aux archives de la revue « Statistique et analyse des données » implique l'accord avec les conditions générales d'utilisation (<http://www.numdam.org/conditions>). Toute utilisation commerciale ou impression systématique est constitutive d'une infraction pénale. Toute copie ou impression de ce fichier doit contenir la présente mention de copyright.

NUMDAM

Article numérisé dans le cadre du programme
Numérisation de documents anciens mathématiques
<http://www.numdam.org/>

Statistique et Analyse des Données

1 - 1978

QUELQUES REFLEXIONS SUR DES LOGICIELS POUR L'ANALYSE STATISTIQUE -
COMPARAISON DE GENSTAT, BMDP ET SPSS

BERNARD Guy

Université de PARIS XIII

Institut Universitaire de Technologie

2 rue de la Liberté

93200 SAINT-DENIS

1 - INTRODUCTION

Le but de cette étude comparative est de contribuer à aider l'utilisateur de logiciels statistiques (qu'il soit statisticien ou non) à choisir parmi le grand nombre de logiciels aujourd'hui diffusés, sinon le logiciel particulier, du moins le type de logiciel le mieux adapté aux problèmes à résoudre et à la formation de l'utilisateur. Bien souvent, le critère de choix est la disponibilité d'un logiciel au centre de calcul de l'utilisateur; encore faut-il connaître les possibilités de ce logiciel, l'audience à laquelle il s'adresse, l'usage qui peut en être fait.

2 - CRITERES DE COMPARAISON RETENUS

Ils ont été regroupés en quatre groupes:

1. Influence du système sur l'exploitation et l'utilisation des logiciels (type de matériel nécessaire - langage source - portabilité et matériel fourni par le distributeur - difficulté d'implémentation - extensibilité et mise à jour - utilisation interactive)
2. Comparaison technique (comparaison méthodologique: organisation et enregistrement des données - méthodes d'analyse disponibles - sortie des résultats - comparaison numérique - possibilité d'enchaînement de plusieurs analyses - volume des données qui peuvent être analysées - coûts de mise en service et d'utilisation)
3. Possibilités de liaison avec d'autres logiciels (langages généraux ou autres logiciels spécialisés)

4. Aides fournies à l'utilisateur (facilité d'apprentissage des langages - facilité d'écriture des modèles - documentation - aide à la correction d'erreurs - aide à une meilleure connaissance des structures statistiques - "intelligence" des logiciels)

Les critères retenus sont ceux du Comité d'Evaluation des ensembles de programmes statistiques créé par la section de calcul statistique de l'American Statistical Association (FRANCIS et al., 1975); toutefois, on a ajouté le troisième groupe de critères (liaison avec d'autres logiciels) car aucun logiciel, aussi complet soit-il, ne peut prétendre à l'universalité et il peut donc être intéressant de lier un logiciel donné, en amont ou en aval, à un autre logiciel (en particulier à un langage général de programmation); de plus, le quatrième groupe de critères (aides fournies à l'utilisateur) a été élargi, par inclusion notamment de la facilité d'apprentissage et de mise en oeuvre et de l'"intelligence" des logiciels.

3 - CHOIX DES LOGICIELS

Les moyens logiciels à la disposition de l'utilisateur peuvent être divisés en plusieurs catégories (BETUING et al., 1972; SCHUCANY et MINTON, 1972; NELDER, 1974): les programmes écrits par l'utilisateur lui-même - les ensembles de programmes - les ensembles de sous-programmes - les programmes avec traducteur - les programmes à langage interpréteur. Pour la dernière catégorie, l'utilisateur dispose d'un langage spécialisé pour écrire ses instructions; lorsque le programme (sous forme de module chargeable) est appelé, il interprète les instructions et les exécute. Parmi les cinq catégories mentionnées, c'est la dernière qui soulage le plus l'utilisateur des contraintes de la programmation, tout en présentant l'avantage de ne nécessiter qu'une seule étape. Il n'est donc pas étonnant que ce soit elle qui se développe le plus depuis quelques années. Les logiciels à comparer ont été choisis dans cette catégorie.

Un des pôles de la comparaison a été GENSTAT (NELDER, 1975). En effet, ce logiciel encore peu répandu offre à l'utilisateur un langage interpréteur qui est à la fois un langage d'appel de procédures d'analyse statistique et un langage permettant l'écriture de véritables algorithmes. GENSTAT (de même que certains autres logiciels de même conception) se différencie donc des "paquets" les plus répandus, et il est intéressant de le comparer à ceux-ci.

Le choix des logiciels à langage interpréteur autres que GENSTAT a été déterminé par plusieurs considérations:

- il doit être possible d'enchaîner facilement plusieurs analyses statistiques sur le même corpus de données (condition indispensable à la mise en oeuvre d'une étude statistique sérieuse);
- les logiciels retenus doivent être largement répandus;
- il doit être possible de les utiliser au Centre Inter-Régional de Calcul Electronique (Université de Paris XI) doté de deux ordinateurs IBM 370/168, où tous nos calculs sont effectués, afin de pouvoir comparer sur des problèmes-tests les résultats fournis, pour chacune des procédures d'analyse statistique disponibles, par les différents logiciels (une confrontation uniquement livresque ne permet pas d'apprécier la facilité de mise en oeuvre d'un logiciel ni la fiabilité des résultats).

En définitive, BMDP (DIXON, 1975) et SPSS (NIE et al., 1975) ont été retenus. Ce choix n'a pas, bien sûr, la prétention d'être le meilleur possible - on aurait pu en particulier songer à SAS (SERVICE, 1972) -; il présente cependant l'avantage de confronter trois logiciels nettement différenciés: un langage puissant (GENSTAT), un "paquet" classique (SPSS), un ensemble cohérent de programmes indépendants (BMDP). Ainsi, les résultats de la comparaison ne s'appliquent pas uniquement aux trois logiciels particuliers étudiés, mais concernent dans une large mesure les types de logiciels qu'ils représentent.

4 - PRESENTATION DES LOGICIELS

GENSTAT a été développé par l'équipe de la Rothamsted Experimental Station, Harpenden, Herts., Grande-Bretagne, sous la direction de J.A. NELDER. C'est un logiciel à vocation générale mais il porte cependant une coloration "analyse des données expérimentales" assez marquée, due au domaine d'activité de l'équipe de Rothamsted. Il s'agit d'un ensemble constitué d'un programme unique et de 300 sous-programmes environ. C'est la version 3.08 qui a été étudiée.

L'ensemble BMDP ("Biomedical Computer Programs - Serie P") est la nouvelle série des programmes BMD conçus par W.J. DIXON et son équipe de l'Université de Californie. La version de juillet 1975, que nous avons utilisée, comprend 26 programmes utilisant 72 sous-programmes. Ces 26 programmes forment un ensemble cohérent utilisant un langage interpréteur unique; ils offrent la possibilité d'enchaîner l'exécution de plusieurs d'entre eux dans un même job, grâce à un fichier auto-descriptif permettant la conservation et l'utilisation des résultats, sans que l'utilisateur ait à redéfinir à chaque fois tous les paramètres du problème. Du point de vue de l'utilisateur, BMDP peut donc être utilisé comme un ensemble de sous-programmes à langage interpréteur, la seule particularité étant que quelques cartes de JCL (définition des fichiers de résultats à transmettre, appel d'un nouveau programme) doivent être insérées entre les spécifications des modules d'analyse successifs. BMDP est un logiciel à vocation générale, plutôt orienté vers l'analyse des résultats d'enquête cependant.

SPSS ("Statistical Package for the Social Sciences") est développé par le "National Opinion Research Center" de l'Université de Chicago. Il s'agit comme pour GENSTAT, d'un programme unique utilisant quelques centaines de sous-programmes. C'est la version 6.02 (1975) qui a été utilisée. SPSS est un logiciel orienté vers la résolution des problèmes statistiques rencontrés en sciences humaines (manipulation de fichiers comportant un grand nombre d'observations).

5 - COMPARAISON

5.1 - influence des choix fondamentaux

Les choix réalisés par les auteurs des logiciels et concernant les structures que l'utilisateur peut manipuler, conserver, nommer, déterminent dans une large mesure les possibilités des logiciels. En particulier, le choix de la structure de base de la matrice de données, la possibilité de nommer d'autres structures que les variables et la possibilité de conserver les instructions en mémoire ont des conséquences importantes.

- pour la matrice de données (tableau rectangulaire indexé par les variables et les unités statistiques), c'est la variable ou l'unité qui peuvent être choisies comme structure de base. Le choix de la variable (c'est l'option retenue pour GENSTAT) présente l'avantage de permettre l'addition de nouvelles variables (telles que prédictions, scores et résidus) facilement; par contre, toutes les valeurs des variables doivent être présentes simultanément en mémoire, d'où de sévères limitations de taille. Le choix de la variable comme structure de base est tout à fait naturel pour GENSTAT, particulièrement tourné vers l'analyse des données expérimentales, où le nombre d'unités est rarement très élevé et où il est important de pouvoir travailler sur d'autres variables que les variables initiales. Le choix de l'unité (BMDP, SPSS) permet le traitement de fichiers comportant un grand nombre d'observations, puisque certaines structures (tables, matrices des sommes des carrés et produits) peuvent être constituées - et la plupart des procédures d'analyse statistique réalisées - séquentiellement, sans que l'ensemble des unités soit présent en mémoire centrale ; de plus, il facilite la spécification de sous-ensembles d'unités et l'addition de nouvelles unités aux unités initiales. Par contre, il devient difficile d'ajouter de nouvelles variables, puisque les valeurs de la matrice de données sont conservées en mémoire unité par unité (sauf si les nouvelles variables sont créées à partir des variables initiales par des transformations au niveau de l'unité - il suffit alors de réserver au début du programme l'espace devant contenir les nouvelles valeurs et de conserver, en même temps que les valeurs lues pour une unité déterminée, les valeurs créées pour la même unité). Le choix de l'unité comme structure de base pour BMDP et SPSS orientés vers l'analyse des résultats d'enquête, où le nombre d'unités peut être élevé, est tout à fait naturel.

Quelles sont, pour l'utilisateur, les conséquences de ces choix différents?

- le nombre d'unités est théoriquement illimité pour BMDP et SPSS (sauf pour certains modules, comme la statistique non paramétrique et les graphes), alors que pour GENSTAT l'espace occupé en mémoire est fonction du nombre d'unités ;

- l'addition de nouvelles variables à l'ensemble initial peut être réalisé à tout moment d'un programme GENSTAT, alors que pour BMDP et SPSS elle ne peut être effectuée qu'au début d'un nouveau programme ;

- les seuls calculs possibles sur les variables, pour BMDP et SPSS, sont des opérations au niveau de l'unité, alors que GENSTAT permet des opérations plus élaborées, comme la concaténation de deux variables en une troisième.

- si l'utilisateur a la faculté de nommer d'autres types de structures que les variables (ce n'est le cas que pour GENSTAT), il peut réaliser des opérations sur ces structures (par exemple, addition de deux matrices de sommes des carrés et produits, quotient de deux tableaux) ; il peut nommer un résultat et spécifier une structure donnée comme entrée d'un module d'analyse statistique, et par suite enchaîner facilement plusieurs analyses sur le même corpus de données ; le contrôle de la sortie des résultats (par impression et/ou conservation en mémoire auxiliaire) devient très souple ; si enfin les textes sont des structures que l'on peut nommer et conserver, il est possible d'élaborer des macros (ensembles d'instructions écrites en langage interpréteur, permettant par exemple la programmation de nouveaux algorithmes (BERNARD, 1977a)) et de les conserver en mémoire auxiliaire au même titre que les ensembles de données: l'utilisateur de GENSTAT peut ainsi disposer d'une bibliothèque de macros.

En contre-partie, ces facilités entraînent une augmentation de l'espace mémoire utilisé, et surtout un alourdissement de la programmation puisque l'utilisateur doit spécifier la nature et les différents attributs (dimensions des matrices, nombre des niveaux des facteurs...) des structures qu'il désire manipuler. L'apprentissage d'un logiciel permettant, comme GENSTAT, de nommer et utiliser de nombreux types de structures est nécessairement plus long que celui d'un logiciel permettant seulement de nommer les variables, comme BMDP et SPSS.

- les instructions composant le programme écrit par l'utilisateur peuvent être interprétées une par une et exécutées aussitôt, sans être mises en mémoire (BMDP, SPSS) ; une possibilité alternative consiste à interpréter à la suite toutes les instructions d'un "bloc", à mettre en mémoire le code pseudo-objet résultant et à exécuter ensuite l'ensemble des instructions du "bloc" (c'est le mode de traitement d'un programme GENSTAT). L'avantage de la deuxième démarche est de permettre les instructions de branchement conditionnel, nécessaires à une analyse statistique sérieuse, et les boucles ; en outre, en spécifiant la fin de chaque "bloc" d'instructions, l'utilisateur maîtrise l'alternance de la "compilation" et de l'exécution ; enfin, si la possibilité de nommer les structures utilisées est offerte et si quelques modules de calcul (inversion de matrice, diagonalisation) sont disponibles, le logiciel devient un langage puissant permettant l'écriture d'un algorithme. C'est ainsi que des macros d'analyse factorielle des correspondances et d'analyse des corrélations canoniques ont pu être écrites en GENSTAT (ces méthodes d'analyse n'ont pas été programmées par les auteurs de GENSTAT) (BERNARD, 1977a, 1977b).

La faculté de conserver les instructions en mémoire et les possibilités qui en résultent entraînent une diminution de l'espace disponible pour les calculs, et supposent que l'utilisateur soit familiarisé avec les notions de test, branchement, boucle, compilation, exécution : l'apprentissage d'un logiciel du type de GENSTAT est facilité par la connaissance préalable d'un langage général de programmation ; le bénéfice est beaucoup moins important pour des logiciels comme BMDP et SPSS.

5.2 - résultats

Le premier groupe de critères n'a pas fait apparaître de différences importantes entre les trois logiciels. Ils sont faciles à implémenter (les distributeurs fournissent des modules chargeables accompagnés d'une notice satisfaisante) ; comme ils sont composés principalement de programmes et de sous-programmes écrits en FORTRAN standard, on peut assez facilement les transporter d'un matériel à l'autre (quelques routines en assembleur, en particulier pour la lecture des données, doivent cependant être réécrites) ; il est enfin difficile pour un utilisateur d'étendre lui-même le logiciel, car cette opération suppose une connaissance approfondie du système, que ne procure pas la documentation (pour les mises à jour, les distributeurs préfèrent diffuser l'intégralité de la nouvelle version plutôt que la procédure à suivre pour modifier l'ancienne version).

La confrontation des trois logiciels a comporté la réalisation de problèmes-tests pour la plupart des modules d'analyse statistique. Ces problèmes-tests ont permis l'appréciation

des performances des logiciels dans le domaine de l'analyse statistique proprement dite, mais également dans les domaines correspondant aux trois derniers groupes de critères de comparaison. Les résultats obtenus sont relatifs aux versions utilisées, mais les versions ou mises à jour diffusées depuis lors n'ont pas apporté de changement fondamental aux logiciels, et les conclusions tirées sont, pour l'essentiel, toujours valables.

Les supériorités ponctuelles des logiciels ont pu être mises en évidence : ainsi, GENSTAT possède le programme d'analyse de variance le plus souple, BMDP fournit le programme d'analyse factorielle le plus complet, les manuels de SPSS sont les plus clairs, etc.

Mais on s'est bien gardé, par un jeu de coefficients, d'attribuer une note moyenne à chaque logiciel et d'établir ainsi un classement global. Car quel poids faut-il accorder aux différents critères? Certains d'entre eux sont contradictoires (coût d'utilisation et souplesse, par exemple) ; en outre, l'importance des différents critères varie à la fois selon le type d'utilisateur et le type d'utilisation des logiciels.

FRANCIS (1975) propose d'établir une classification des utilisateurs par un tableau à double entrée : niveau statistique et niveau informatique, et une classification des utilisations par un tableau à double entrée également : domaine d'utilisation (université, laboratoire de recherche, industrie pharmaceutique...) et activité de l'utilisateur (apprentissage, usage de routine, implémentation...). Pour chaque couple de cases des deux tableaux, l'importance des critères est différente. Ainsi :

- pour des utilisateurs débutants en statistique et en informatique apprenant l'usage d'un logiciel à l'université, la caractéristique la plus importante est la documentation. Vient ensuite le langage de contrôle et enfin les possibilités statistiques (FRANCIS et VALIANT, 1975) ;

- pour des utilisateurs de niveau intermédiaire en statistique et en informatique (connaissance du FORTRAN et de l'assembleur ou du PL1), en enseignement universitaire, les caractéristiques jugées importantes sont la documentation, la qualité des sorties puis les caractéristiques du langage (flexibilité, boucles et branchements souhaités) (GENTLE, 1975) ;

- pour des utilisateurs "experts" tant en statistique qu'en informatique, en ce qui concerne les programmes de régression, les caractéristiques importantes sont les possibilités statistiques et la qualité des sorties, alors que la documentation est secondaire (HEIBERGER, 1975) ;

- pour des utilisateurs spécialistes de classification, l'important est la qualité de la documentation (ce qui se comprend pour une branche aussi anarchiquement développée que la classification : les 53 spécialistes ayant répondu à l'enquête utilisaient 50 programmes différents, et la terminologie n'est pas unifiée), et la souplesse statistique (BLASHFIELD, 1976).

En ce qui concerne le domaine d'utilisation, on a vu plus haut que les options prises par les auteurs déterminent l'orientation générale des logiciels.

En ce qui concerne le type d'utilisateurs, on a déjà mentionné l'intérêt de la connaissance d'un langage général de programmation pour la mise en oeuvre de GENSTAT ; quant au niveau statistique, SPSS dont le manuel comporte une grosse part de rappels statistiques s'adresse plutôt à des débutants, tandis que GENSTAT et BMDP supposent l'utilisateur préalablement rompu à l'usage des méthodes statistiques qu'il désire employer.

Cependant, ceci ne signifie pas qu'un statisticien éprouvé ne puisse pas utiliser avec profit BMDP ou SPSS : l'adéquation d'un logiciel au traitement d'un problème particulier peut être aussi importante que l'adéquation du logiciel à un type d'utilisateur (le très bon programme d'analyse factorielle de BMDP, par exemple, n'est pas qu'un programme pour statisticiens débutants).

Une autre notion qui doit intervenir dans la classification des utilisateurs est la continuité de l'utilisation. Le manuel BMDP est conçu pour pouvoir être utilisé en l'ouvrant à la page d'un programme particulier ; de plus, la facilité d'apprentissage des conventions générales du langage permet à un utilisateur occasionnel de manier BMDP très rapidement. Ceci n'est pas vrai pour SPSS, et encore moins pour GENSTAT, qui nécessitent un apprentissage beaucoup plus long. Or de nombreux utilisateurs de logiciels pour l'analyse statistique sont des utilisateurs occasionnels, et il est impensable de leur imposer des cours de programmation GENSTAT avant qu'ils puissent résoudre leur simple problème de régression linéaire. Cet aspect est rarement pris en compte par les auteurs de comparaisons de logiciels. Il n'y a pourtant pas que des statisticiens qui réalisent des analyses statistiques.

GENSTAT, par sa souplesse (possibilité d'écrire un algorithme) et la richesse de sa gamme de procédures statistiques est un bon outil pour l'enseignement. Il est utilisé depuis trois ans, avec succès, par les étudiants de troisième cycle de statistique à l'Université de Paris-sud (une rapide initiation à la programmation FORTRAN précède l'enseignement de GENSTAT).

On a noté plus haut l'influence des choix effectués par les auteurs des logiciels et relatifs aux structures reconnues, sur les performances des logiciels, et les avantages et inconvénients associés à ces choix. Il n'existe pas de solution idéale. Cependant, quelles que soient les options prises par les bâtisseurs de logiciels, les utilisateurs sont en droit d'attendre :

- l'emploi d'algorithmes fiables (la procédure FACTOR de la version 6.02 de SPSS, qui a été - ou est toujours - utilisée dans plus de mille centres de calcul, donne parfois des résultats erronés pour un simple calcul d'écart-type ou de corrélation^(°) ; le programme de régression orthogonale de BMDP s'accommode fort mal de la multicollinéarité, alors que la méthode de régression orthogonale trouve sa raison d'être dans ce cas^(°°) ;
- une documentation correcte des algorithmes utilisés (SPSS, bien que s'adressant en particulier à des débutants, pourrait - devrait! - indiquer la référence des algorithmes employés) ;
- la possibilité d'imprimer, au moins dans un format rigide, les valeurs des variables ou autres structures qui sont de toute façon calculées, voire conservées ;

 (°) des résultats particulièrement mauvais ont été obtenus avec les données de LONGLEY (1967) ; ainsi, l'écart-type trouvé pour les 16 valeurs 1947, 1948, ..., 1962 a été de 4.50, alors que la valeur exacte est 4.76.

(°°) avec les données de LONGLEY on aboutit à des résultats faux ou absurdes (corrélations supérieures à 1, sommes de carrés négatives) selon que l'on travaille sur les corrélations ou les covariances.

- la possibilité de profiter du chargement du programme en mémoire pour réaliser plusieurs analyses indépendantes, portant sur des ensembles de données différents ;
- la possibilité de sortir sur un support autre que l'imprimante tout ou partie des résultats obtenus, ainsi que la possibilité de lire avec un format contrôlé par l'utilisateur toute structure admise en entrée, conditions nécessaires à la liaison entre différents logiciels ;
- l'homogénéité de la présentation des résultats (nombre de chiffres) et du langage (spécification des options).

La qualité de la documentation est extrêmement importante (elle doit être claire et complète). La présentation de la documentation de SPSS est un des facteurs du succès de ce logiciel alors que celle de GENSTAT ne contribue pas à inciter à utiliser ce langage. Le "marketing" du logiciel, et par suite l'ampleur de sa diffusion, est également un facteur d'utilisation.

Cependant, quelle que puisse être la qualité du prochain manuel de GENSTAT, il est certain que ce logiciel sera toujours plus difficile à mettre en oeuvre que SPSS et BMDP, de par sa conception même (langage algorithmique). Pour assurer la diffusion d'un logiciel de ce type, un effort important doit être consenti par les auteurs du logiciel et par les centres de calcul pour sa promotion (enseignement) ; il ne suffirait pas de mettre la documentation à la disposition de l'utilisateur pour qu'il soit adopté.

Parmi les trois logiciels comparés, GENSTAT est le seul à permettre effectivement une analyse statistique en plusieurs étapes, pour les raisons qui ont été évoquées, alors que BMDP et SPSS ne permettent bien souvent la transmission, d'une étape à la suivante, que des données de départ, sans fournir, en outre, de possibilité de branchement. Si tout le monde s'accorde à accepter, sur le plan des principes, l'idée d'une analyse statistique en plusieurs étapes, beaucoup d'utilisateurs emploient cependant des logiciels qui incitent à appliquer le schéma : lecture - analyse - impression - arrêt. Pourquoi de tels logiciels sont-ils si largement utilisés? Peut-être parce qu'une grande partie des utilisateurs considèrent le logiciel comme une "boîte noire" capable de fournir LA méthode d'analyse ; peut-être faut-il invoquer aussi la responsabilité des centres de calcul, puisque peu d'efforts sont faits pour rendre disponibles des logiciels permettant réellement une analyse en plusieurs étapes.

Qu'on le veuille ou non, les logiciels pour l'analyse statistique ne sont pas utilisés que par les statisticiens ; bien souvent, les utilisateurs n'ont qu'une formation statistique limitée et une conception simpliste de l'analyse statistique. Les logiciels ne devraient pas être conçus de façon à conforter l'utilisateur dans ses défauts et à lui permettre de réaliser n'importe quelle analyse dans n'importe quelles conditions : ils devraient au contraire inciter l'utilisateur à réfléchir sur ses données et lui fournir des sécurités, en étant des programmes "intelligents" (NELDER, 1976) ; les trois logiciels comparés sont loin de présenter cette qualité.

6 - CONCLUSIONS

Les logiciels pour l'analyse statistique peuvent avoir des performances fort différentes, essentiellement à cause des choix fondamentaux effectués par leurs auteurs ; par simple examen de ces options, l'utilisateur peut donc savoir ce qu'il est possible de faire, et ce qu'il est impossible d'obtenir, avec un logiciel particulier. Le problème du choix se pose alors. Bien qu'il soit difficile de comparer des produits fort dissemblables, on peut tracer les grandes lignes suivantes :

- pour une utilisation fréquente, par des statisticiens, un logiciel souple et puissant, du type de GENSTAT, est un outil extrêmement précieux ;

- pour une mise en oeuvre occasionnelle, par des utilisateurs familiarisés avec les méthodes statistiques mais désirant obtenir des résultats rapidement pour des analyses simples en consacrant un temps réduit à l'apprentissage d'un outil dont ils n'auront que peu l'usage, un logiciel du type de BMDP est le mieux adapté ;

- pour la manipulation de fichiers comportant un grand nombre d'unités, un logiciel où la structure de base de la matrice de données est l'unité, comme SPSS ou BMDP, doit être retenu ;

- lorsque l'on souhaite mettre en oeuvre une méthode d'analyse particulière pour un problème nécessitant un traitement élaboré, le type de logiciel devient secondaire et on doit exploiter les points forts de chacun (analyse de variance pour GENSTAT, analyse factorielle pour BMDP...).

x
x x

Cette comparaison est le résultat d'un travail commun entre l'Université de Paris XI et le Département de Biométrie du C.N.R.Z. de Jouy-en-Josas. Une équipe de l'Université de Toulouse travaille actuellement à l'élaboration d'un logiciel français adapté en particulier au traitement des problèmes statistiques.

BIBLIOGRAPHIE

- BETUING, M., BILLOT, P. et MULLER, O. (1972). Les systèmes intégrés de traitement statistique. Rev. Stat. Appl., XX, 4, 13-20.
- BERNARD, G. (1977a). Ecriture d'un algorithme en langage GENSTAT - Exemple de l'analyse des correspondances. Premières Journées Internationales Analyse des Données et Informatique, Versailles, 7-9 septembre 1977, 851-856.
- BERNARD, G. (1977b). Comparaison de trois logiciels spécialisés pour l'analyse statistique : GENSTAT, BMDP, SPSS. Thèse 3ème cycle, Université de Paris XI.
- BLASHFIELD, R.K. (1976). A consumer report on the versatility and user manuals of cluster analysis software. Proc. of the Statistical Computing Section, American Statistical Association, 24-30.
- DIXON, W.J. (1975). BMDP : Biomedical Computer Programs. Berkeley : University of California Press.
- FRANCIS, I. (1975). Design for evaluation of statistical program packages. Bull. I.S.I., 46, 2, 573-584.
- FRANCIS, I., HEIBERGER, R.M. et VELLEMAN, P.F. (1975). Criteria and considerations in the evaluation of Statistical Program Packages. Amer. Stat., 29, 1, 52-56.
- FRANCIS, I. et VALIANT, R. (1975). The novice with a statistical package : performance without competence. Proc. of Computer Science and Statistics : Eighth annual symposium on the Interface (J.W. FRANE, ed.). Los Angeles : University of California, 110-114.
- GENTLE, J.E. (1975). Comparisons of Statistical Packages by users having some familiarity with computing and statistics. Proc. of the Statistical Computing Section, American Statistical Association, 114-117.
- HEIBERGER, R.M. (1975). A procedure for the review of statistical packages and its application to the user interface with regression programs. Proc. of Computer Science and Statistics : Eighth Annual Symposium on the Interface (J.W. FRANE, ed.). Los Angeles : University of California, 115-121.
- LONGLEY, J.W. (1967). An appraisal of least squares programs for the electronic computer from the point of view of the user. Amer. Stat. Assoc. Journal, 62, 819-841.
- NELDER, J.A. (1974). A user's guide to the evaluation of statistical packages and systems. Int. Stat. Rev., 42, 3, 291-298.
- NELDER, J.A. (1976). Intelligent programs : the next stage in statistical computing. Congrès Européen des Statisticiens, Grenoble, 143-145.
- NELDER, J.A. et al. (1975). GENSTAT Reference Manual and User's Guides. Statistics Department, Rothamsted Experimental Station, Harpenden, Herts., England.
- NIE, N.H. et al. (1975). Statistical Package for the Social Sciences, 2ème éd. New York : Mac Graw Hill.
- SCHUCANY, W.R. et MINTON, P.D. (1972). A survey of statistical packages. Computing Surveys, 4, 2, 65-79.
- SERVICE, J. (1972). A users guide to the Statistical Analysis System. North Carolina : Carolina State University.