

# Mathématiques et sciences humaines

Mathematics and social sciences

160 | Hiver 2002 Varia

# Évolution ou révolutions dans la pensée démographique ?

Evolution or revolutions in demographic thinking?

# **Daniel Courgeau**



#### Édition électronique

URL: http://journals.openedition.org/msh/2884

DOI: 10.4000/msh.2884 ISSN: 1950-6821

#### Éditeur

Centre d'analyse et de mathématique sociales de l'EHESS

#### Édition imprimée

Date de publication : 1 décembre 2002

ISSN: 0987-6936

# Référence électronique

Daniel Courgeau, « Évolution ou révolutions dans la pensée démographique ? », *Mathématiques et sciences humaines* [En ligne], 160 | Hiver 2002, mis en ligne le 10 février 2006, consulté le 19 avril 2019. URL: http://journals.openedition.org/msh/2884; DOI: 10.4000/msh.2884

© École des hautes études en sciences sociales

# ÉVOLUTION OU RÉVOLUTIONS DANS LA PENSÉE DÉMOGRAPHIQUE ?

# Daniel COURGEAU<sup>1</sup>

RÉSUMÉ – Cet article montre comment la démographie a pu dépasser les différents clivages apparus tout au long de son histoire et dégage les principaux paradigmes qui se sont succédé, en montrant leurs forces et leurs faiblesses. D'une approche transversale à une approche longitudinale, elle est au départ un holisme. L'approche biographique, qui les suit, va au contraire développer un individualisme méthodologique. L'approche multiniveau libère enfin la démographie de l'opposition entre holisme et individualisme □elle introduit des niveaux d'agrégation multiples à considérer simultanément et permet une synthèse des approches précédentes, tout en les dépassant.

MOTS-CLÉS – Analyse biographique, Analyse longitudinale, Analyse multiniveau, Analyse transversale, Démographie, Holisme méthodologique, Individualisme méthodologique, Niveaux d'agrégation.

#### SUMMARY – Evolution or Revolutions in Demographic Thinking?

This paper displays the way demography overrun different pathbreaking issues encountered during its history, draws the main paradigms followed and shows their strengths and weaknesses. From a cross-sectional to a cohort approach demography, from its origins, was a holism. However, these methods were followed by an event history approach, which introduced methodological individualism. Finally, a multilevel approach released demography from the opposition between holism and individualism: it introduces different aggregation levels, to be simultaneously considered, and permits a synthesis of the previous approaches, while going beyond their initial purpose.

KEYWORDS – Event history analysis, Cohort analysis, Multilevel analysis, Cross-sectional analysis, Demography, Methodological holism, Methodological individualism, Aggregation levels.

L'objectif de cet article est de montrer comment la démographie est parvenue à dépasser les différents clivages apparus tout au long de son développement du XVII<sup>e</sup> siècle à nos jours. Nous verrons en particulier s'il est possible de relier entre elles les diverses approches suivies, dont l'observation et l'analyse se situaient à des niveaux différents ou, au contraire, s'il est nécessaire de considérer ces approches comme incompatibles entre elles.

<sup>&</sup>lt;sup>1</sup> Institut national d'études démographiques, 133 boulevard Davout, Paris, 75980 cedex 20, e-mail⊡courgeau@ined.fr

En premier lieu, les sciences de l'homme partent de l'observation d'un vécu, pour chercher ensuite à le structurer selon différents domaines, qui vont constituer les objets propres à chacune d'entre elles. Ces objets sont généralement définis de façon indépendante de l'échelle et des niveaux d'agrégation auxquels on peut se situer pour les observer. Par exemple, la démographie a pour objet l'étude quantitative des populations humaines, de leurs variations et de leur état, sans que l'on indique si l'on se place au niveau d'un individu, d'une famille, de la population d'une commune ou de celle d'un pays. Ainsi, cette distinction entre niveaux se situe en deçà de l'objet de chacune de ces sciences et nous verrons qu'elles y sont toutes soumises.

C'est seulement lorsque le chercheur va tenter d'observer les comportements et d'objectiver le milieu où ils se produisent, ainsi que la façon dont ils opèrent, qu'il sera confronté au problème du niveau d'agrégation, dans un espace tant physique que social, et à celui de la temporalité, qu'il va considérer. De nombreuses questions se posent alors pour le choix du niveau d'agrégation auquel se situer lui faudra-t-il observer des comportements agrégés ou individuels ; les méthodes utilisées pour mettre en évidence les relations entre les grandeurs mesurées seront-elles les mêmes ou totalement différentes selon le niveau auquel il se situe ; est-il possible de faire intervenir simultanément plusieurs niveaux d'agrégation, etc.

Il sera simultanément confronté à la prise en compte du temps à agira-t-il du temps historique dans lequel se déroulent les événements étudiés ou au contraire du temps vécu par l'individu qui connaît ces événements ; ou bien va-t-il se situer à un moment précis de ce temps, pour expliquer les comportements qui s'y produisent par les conditions qui prévalaient juste avant, ou au contraire tout au long de la vie d'un individu, faisant intervenir des conditions qui vont à chaque moment varier, mais qui peuvent également se situer dans un passé lointain [2]

C'est l'ensemble de ces problèmes que nous tenterons d'étudier tout au long de cet article et nous essayerons de leur trouver des solutions satisfaisantes.

# 1. UNE APPROCHE TRANSVERSALE AGRÉGÉE

Même si dans les débuts de l'*Arithmétique politique*, qui a précédé la démographie, la distinction entre approche transversale, qui considère les événements se produisant à un moment précis, et approche longitudinale, qui considère les événements se produisant tout au long de la vie des individus, n'est pas toujours tranchée, au cours du XVIII<sup>e</sup> et du XIX<sup>e</sup> siècles l'approche transversale va l'emporter.

Ainsi Graunt [1662], l'initiateur de la démographie, considère les «Bulletins de Mortalité et les «Bulletins de Baptêmes annuels pour en tirer une vue transversale des populations de Londres ou de la Province anglaise. De même Halley [1693], travaillant sur des données annuelles, de 1697 à 1691, de la ville de Breslau en tire une table de mortalité convenable, pour une population qu'il pouvait considérer comme stationnaire. À l'inverse, les liens entre la valeur des rentes viagères et la mortalité de la population, conduisit

certains auteurs à prendre un point de vue, non plus transversal, mais longitudinal sur la mortalité. Deparcieux [1746] construisit des tables de mortalité des rentiers des tontines de 1689 et de 1696, observés jusqu'au commencement de 1742, selon l'âge à la constitution de cette rente. Cette utilisation d'une approche longitudinale n'était pas alors contradictoire avec l'approche du moment, car l'hypothèse sous-jacente était celle d'une population stationnaire.

Dès la fin du XVIII<sup>e</sup> siècle la mise en place de recensements dans de nombreux pays, vient conforter l'approche transversale. En effet, les recensements, en énumérant la population d'un pays à un instant précis, conduisent également à considérer les données de l'état civil à ce même instant, pour calculer les indices démographiques du moment. La création du terme *démographie*, dans le sens de «III connaissance mathématique des populations , par Achille Guillard (1855) vient remplacer l'arithmétique politique. Une telle approche transversale va se prolonger jusqu'à la fin de la Seconde Guerre mondiale.

Voyons d'abord comment cette analyse s'est mise en place et sa façon d'opérer, avant d'en dégager les principes plus fondamentaux, que l'on peut désigner sous le terme de paradigme, et que l'on discutera alors de façon plus précise.

# 1.1 D'UNE APPROCHE DESCRIPTIVE À UNE ANALYSE STATISTIQUE DU MOMENT

Comme nous l'avons indiqué la démographie a d'abord essayé de mettre en place une description transversale des phénomènes démographiques, en élaborant des pyramides des âges, des taux bruts, des taux par âge et des indices synthétiques qui permettent de résumer ces taux. Il ne peut être question de présenter ici cette approche de façon détaillée, mais seulement d'en donner les principes. Ainsi, les outils pour décrire ces statistiques du moment, pour une part déjà proposés par l'arithmétique politique, se précisent tout au long du XIX<sup>e</sup> et de la première moitié du XX<sup>e</sup> siècles. Par exemple, des indices synthétiques, comme la somme des naissances réduites, la somme des premiers mariages réduits, etc., sont alors mis en place et nous verrons plus loin les problèmes auxquels ils peuvent conduire. Le *Traité de démographie* de Landry [1945], en fournit une excellente synthèse.

Dès que le démographe cherche à dépasser la simple description des phénomènes, il va chercher à vérifier si un certain facteur influe ou non sur le phénomène étudié. Il va devoir définir et mesurer plus précisément ce facteur et voir comment mettre en évidence à l'aide d'un modèle les liens qu'il cherche à déceler. Voyons d'abord les problèmes de mesure avant de nous attaquer à ceux de la modélisation.

L'optique prise ici nécessite une agrégation des mesures pour estimer les probabilités de divers événements. Ainsi, pour pouvoir approcher la probabilité d'un événement donné, il est nécessaire de considérer soit une population dans son ensemble, soit des sous-populations suffisamment nombreuses. Mais si l'on veut ensuite relier cet événement à un autre événement ou à une autre caractéristique, le travail sur la population d'ensemble ne le permet pas disposer de deux probabilités marginales ne fournit aucune information sur le lien qui peut exister entre elles. Il devient indispensable dans ce cas de travailler sur des sous-populations, pour pouvoir mettre en évidence cette liaison.

Pour prendre un exemple simple, que nous utiliserons tout au long de cette présentation, si nous ne disposons que de la probabilité de mobilité de l'ensemble de la population et de son pourcentage d'agriculteurs, il ne sera pas possible de mettre en évidence un lien entre ces deux quantités. Pour ce faire, une solution possible sera de décomposer cette population en un grand nombre de sous-populations et d'estimer ces mêmes quantités dans chacune. On pourra alors mettre en évidence les liens entre probabilités de migrer des agriculteurs et du reste de la population, sous certaines hypothèses qui, on le verra plus loin, pourront être discutées.

C'est, à notre avis, Durkheim [1895, 1897] qui présenta de façon la plus claire les objectifs de cette science sociale et les moyens d'y parvenir. En premier lieu il constate que les faits sociaux sont indépendants de la fonction qu'ils remplissent dans la société et que, tout en restant les mêmes, ils peuvent servir à des fins différentes. C'est cette fonction, qui est importante à mettre en évidence, alors que montrer à quoi un fait est utile devient secondaire. Mais cette fonction ne peut être considérée sans faire intervenir les différentes parties constituantes de la société, sur laquelle il travaille les groupes religieux, domestiques, politiques, etc., qui y sont associés. Les phénomènes sociaux doivent donc varier avec les formes de cette association et avec la façon dont sont groupées ces parties constituantes de la société. Il peut ainsi mettre en évidence la fonction d'un fait social en le reliant à d'autres faits sociaux, mais c'est le système social qui est le fondement de cette explication.

Dès lors comment prouver qu'un phénomène est cause d'un autre ? L'approche expérimentale proprement dite n'est guère utilisable dans la plupart des sciences sociales, notamment pour des raisons d'éthique. Il est dès lors nécessaire d'utiliser une méthode comparative. Parmi celles-ci la plus pertinente est la méthode des variations concomitantes, telle que Durkheim [1895] la propose. Il s'agit dans ce cas de montrer si les variations, que ces phénomènes présentent dans un nombre suffisant de cas, témoignent que l'un dépend de l'autre. Ainsi, lorsqu'il constate que la proportion de suicides dans diverses provinces de Prusse varie de façon proportionnelle au pourcentage de protestants il en conclut que le suicide varie en raison inverse du degré d'intégration de la société religieuse, car, pour lui, l'Église protestante est une Église moins fortement intégrée que l'Église catholique.

Cette méthode est la même que celle proposée dans Landry [1945] qui indique que, si l'on veut comprendre une variation dans le temps ou dans l'espace, il faudra mettre en évidence un rapport de concomitance entre les phénomènes étudiés. Elle revient finalement à une analyse de régression, si l'on utilise le vocabulaire d'aujourd'hui, entre les pourcentages de suicides et les pourcentages de protestants vivant dans diverses régions.

Montrons comment il est possible de formuler plus précisément un tel modèle, dans le cas où l'on observe les pourcentages d'individus ayant connu un phénomène donné en fonction de leur appartenance ou non à une catégorie de population donnée et situés dans diverses aires d'un pays donné. Ainsi, supposons que les membres de la catégorie de population étudiée ont tous la même probabilité de connaître le phénomène, quelle que soit leur position sur le territoire⊡ils sont donc homogènes vis-à-vis du phénomène étudié et

ce phénomène est indépendant des autres événements de la vie des individus. Cela constitue une hypothèse de départ, identique à celle de Durkheim, qui considérait que les membres d'un même groupe avaient la même propension à connaître un événement donné, le suicide par exemple, quelle que soit leur province de résidence, cette propension étant indépendante des autres phénomènes sociaux.

Comme nous l'avons précédemment indiqué, nous allons considérer ici les migrations entre régions norvégiennes observées par le registre de population, données qui furent centralisées et informatisées en 1964<sup>2</sup>. L'histoire résidentielle complète de chacun de ces individus y est enregistrée ainsi que leurs naissances successives. Nous travaillons au niveau régional, la Norvège étant divisée en 19 régions et nous avons éliminé les individus ayant eu au moins un séjour hors de Norvège. De plus, ces données ont été couplées aux données des recensements de 1970 et 1980 elles donnent un certain nombre de caractéristiques des individus à ces dates niveau d'éducation, état matrimonial, profession, etc.

Nous observons ici tous les hommes nés en 1948, résidant en Norvège en 1991 et n'ayant fait aucune migration vers l'étranger, soit un total de 28\(\mathbb{Q}\)62 individus et considérons les changements de région effectués sur une courte période de deux ans suivant le recensement de 1970, en prenant les caractéristiques des individus à cette date. Nous travaillons sur les probabilités de migrer des agriculteurs comparés aux autres membres de la population.

À partir de ces données, il est possible de calculer une régression linéaire entre les taux de migration et les proportions d'agriculteurs de chaque région. En effet, si  $m_a$  et  $m_{\overline{a}}$  sont les probabilités de migrer des agriculteurs et des non-agriculteurs, qui gardent la même intensité dans toutes les régions du pays considéré, si  $N_{aj}$  et  $N_{\overline{a}j}$  sont les effectifs des deux populations dans une région j donnée, alors l'espérance mathématique du nombre de migrations observées de cette région,  $M_j$ , sera  $\square$ 

$$M_j = N_{aj} m_a + N_{\overline{a}j} m_{\overline{a}} = N_{aj} (m_a - m_{\overline{a}}) + N_j m_{\overline{a}}$$

où  $N_j$  est la population totale de la région j. Il en résulte bien que le taux de migration,  $m_j$ , sera fonction linéaire de la proportion d'agriculteurs dans chaque région,  $a_{.j}$ :

$$m_i = a_{.i}(m_a - m_a) + m_a$$

L'observation des résultats sur les données agrégées par région, nous permet de voir quel est l'effet du pourcentage d'agriculteurs sur la probabilité de migrer (Tableau, colonne intitulée *Régression linéaire agrégée*, la seconde colonne intitulée *Régression logistique* sera expliquée plus bas) et d'estimer les probabilités de migrer des agriculteurs et des autres.

<sup>&</sup>lt;sup>2</sup> Nous remercions ici les services statistiques norvégiens qui nous ont permis d'avoir accès à des fichiers créés à partir de ces données et des recensements de population par Kjetil Sørlie et Øjsten Kravdal.

Paramètres	Régression linéaire agrégée	Régression logistique (résultats agrégés)
$m_a$	0,597 (0,197)	0,094 (0,069)
$m_{\overline{a}}$	0,119 (0,014)	0,150 (0,012)
$m_a - m_{\overline{a}}$	0,478 (0,209)	-0,056 (0,070)

Tableau 1. Paramètres estimés et écart-type entre parenthèses, pour les modèles agrégés

La part de variance expliquée est de 0,24 et est significativement différente de zéro au seuil de 5 %. Les résultats de cette régression permettent de conclure que les agriculteurs en Norvège ont une probabilité près de six fois plus forte que les autres professions de migrer. Ce résultat semble surprenant étant donné le coût tant financier que personnel d'un changement de région pour cette profession. Nous verrons plus loin que certaines des hypothèses à la base de cette estimation sont incorrectes, mais qu'un modèle multiniveau permet de réintroduire cette observation de façon plus satisfaisante.

La généralisation des formules précédentes au cas où l'on fait intervenir un nombre plus élevé de caractéristiques est facile à réaliser mais rencontre des difficultés d'interprétation plus grandes que dans le cas de deux caractéristiques. En effet, pour avoir des estimations satisfaisantes des probabilités, on doit alors supposer que les caractéristiques sont indépendantes entre elles, cas qui est rarement vérifié. Nous ne poursuivrons donc pas plus avant cette généralisation.

# 1.2 UN PARADIGME SOUS-JACENT

Ce paradigme, que les auteurs du passé n'ont jamais posé clairement, peut cependant être déduit de la présentation que nous venons de faire. Le paradigme, ou plutôt la matrice disciplinaire d'une science, correspond à l'ensemble des croyances, des valeurs reconnues et des techniques qui sont communes aux membres d'une communauté scientifique donnée [Kuhn, 1983]. Il est donc dans sa nature de résister à une définition précise, mais on peut le cerner par un certain nombre de principes suffisamment généraux. Ainsi, on peut dire que les faits sociaux ont une existence indépendante des individus, qui les vivent. Ils s'expliquent par diverses caractéristiques économiques, politiques, religieuses, sociales, etc., de la société cela définit une forme de causalité qui trouve son origine dans la société elle-même et non dans l'individu et dont les effets se font sentir sur l'ensemble d'une population.

Le mode de recueil des données s'en déduit, avec l'enregistrement le plus complet possible, à des dates régulières, de la population de ses caractéristiques et de celles des lieux où elle vit. Cette approche est donc bien un *holisme*, en ce qu'elle explique l'évolution d'une société à partir de ses finalités globales, sans faire intervenir de volonté individuelle. Le mode de recueil des données le plus satisfaisant est le recensement à des dates précises des informations nécessaires à son application.

On voit ce paradigme se mettre en place pendant la période d'affermissement de l'arithmétique politique, à l'aide des données de registres vues de façon transversale, puis s'affirmer, à partir du début du XIX<sup>e</sup> siècle, avec l'institutionnalisation des services statistiques nationaux et la mise en place des recensements. Ceux-ci fournissent des instantanés de la population, qui permettent une vue exhaustive de celle-ci et enregistrent de nombreuses caractéristiques tant des individus que des ménages. La méthode d'analyse proposée par Durkheim [1895] s'y applique parfaitement et celui-ci d'ailleurs reconnaît que la statistique fournit le moyen d'isoler les faits sociaux ils sont, en effet, figurés, non sans exactitude, par le taux de la natalité, de la nuptialité, des suicides, c'est-à-dire par le nombre que l'on obtient en divisant le total moyen annuel des mariages, des naissances, des morts volontaires par celui des hommes en âge de se marier, de procréer, de se suicider.

#### 1.3 PROBLÈMES MÉTHODOLOGIQUES

C'est d'abord l'utilisation d'indices synthétiques construits à partir de tables du moment, qui entraîna des questions sur cette approche transversale. Ces indices, élaborés en vue de répondre à certaines questions tout à fait légitimes, conduisaient dans certains cas à des résultats d'interprétation difficile et même en contradiction logique avec ce qu'ils étaient censés mesurer.

Ces difficultés apparaissent en particulier dans l'étude de phénomènes, comme la fécondité ou la nuptialité, qui comportent des périodes d'ajournement suivies de périodes de récupération, après une crise économique ou une guerre. Ainsi, comme l'explique Henry [1966], au cours d'une période de récupération, le comportement est influencé par le retard antérieur ; attribuer à une cohorte fictive une série d'indices observés en période de récupération revient alors à postuler l'existence d'une génération qui, d'un bout à l'autre de sa vie, s'emploierait à rattraper un retard qu'elle n'aurait jamais pris. Cela explique pourquoi la somme des quotients de nuptialité (premiers mariages) par âge, qui est censée mesurer l'intensité de la nuptialité et devrait toujours être inférieure à l'unité dans une cohorte réelle, peut avoir des valeurs qui lui sont bien supérieures, dans une cohorte fictive. Ainsi, elle prend des valeurs supérieures à 1,5 en 1946, en France juste après la Seconde Guerre mondiale. Nous verrons comment l'approche longitudinale permet d'éviter de tels raisonnements erronés.

Si l'utilisation de données agrégées est légitime sous le paradigme proposé, il est possible que l'utilisation de données individuelles vienne le mettre en cause. En effet, de nouvelles méthodes telles que les régressions logistiques, permettent maintenant d'estimer des modèles basés sur des caractéristiques individuelles. Et cette estimation peut ne pas conduire à des résultats équivalents à ceux que l'on obtenait avec des données agrégées. Ainsi, la liaison positive entre le pourcentage d'agriculteurs et le pourcentage de migrants, trouvée plus haut, montre seulement que la plus forte probabilité de migrer est liée à une forte proportion d'agriculteurs, sans que l'on puisse dire si ce sont les agriculteurs ou les non-agriculteurs de ces régions qui migrent plus. Il peut être tout à fait possible, qu'un fort pourcentage d'agriculteurs, en limitant les offres d'emploi aux autres professions,

contraignent les non-agriculteurs à migrer pour trouver un meilleur emploi, alors que les agriculteurs eux-mêmes n'ont aucune raison de migrer plus, hors de ces zones.

Un tel problème a été mis en évidence il y a plus de 50 ans maintenant [Robinson, 1950]. Si les données agrégées ne fournissent pas des résultats identiques à ceux obtenus avec des données individuelles, cela conduit à ce que l'on appelle l'*erreur écologique*. Ainsi on observe souvent que les corrélations entre deux caractéristiques mesurées de façon binaire sur des individus et par des proportions sur des régions, ne sont en général pas égales entre elles. Bien plus elles peuvent être parfois de signe opposé, conduisant à des résultats complètement erronés si l'on veut raisonner au niveau individuel.

# 2. UNE APPROCHE LONGITUDINALE AGRÉGÉE

À partir de la fin de la Seconde Guerre mondiale, certaines de ces questions amenèrent des démographes à revoir les bases sur lesquelles ils travaillaient. Si l'approche du moment posait de nombreux problèmes, ceux-ci ne seraient-ils pas résolus par une approche par génération, qui permet de mieux prendre en compte le temps vécu par les individus ?

#### 2.1 L'INTRODUCTION DU TEMPS VÉCU

L'analyse du moment cherchait les relations entre événements et caractéristiques considérés simultanément et ne faisait intervenir le temps qu'à titre secondaire, lorsque l'on passait d'une date à la suivante. Essayons maintenant de mettre le temps vécu par les membres de la population au cœur de l'analyse. On va dans ce cas considérer le devenir au cours du temps d'une génération, née une année donnée dans un pays, ou une cohorte ayant connu un événement origine à un instant précis. Les comportements que l'on observe correspondent aux différents phénomènes démographiques (décès, naissance, mariage, migration, etc.), qui vont survenir tout au long de la vie des membres de cette génération. Pour rendre l'analyse possible le démographe doit cependant prendre une approche simplificatrice en supposant que les divers phénomènes sont indépendants les uns des autres. En effet, il peut ainsi éliminer l'effet des autres phénomènes et isoler le phénomène étudié à l'état pur [Henry, 1972].

Voyons alors comment il va opérer pour obtenir ces événements à l'état pur, par exemple les premiers mariages. Pour cela prenons le raisonnement suivi par Henry [1972] une mort prématurée empêche des célibataires de se marier; d'où la perturbation que la mortalité fait subir à la nuptialité. Pour l'éliminer, il faudrait savoir comment se seraient mariées, si elles avaient vécu les personnes mortes célibataires avant 50 ans. Comme on ne le sait pas on recourt à une hypothèse on admet que ceux qui sont morts célibataires à un certain âge a se seraient mariés, s'ils avaient vécu audelà de l'âge a, comme l'ont fait ceux qui ne sont pas morts à cet âge. C'est donc bien une hypothèse d'indépendance entre mariage et mortalité qui est faite ici et il est nécessaire de faire une hypothèse équivalente pour l'émigration internationale. Une fois ces hypothèses faites, on peut estimer un quotient de nuptialité, à partir des effectifs observés, qui serait le même que celui que l'on calculerait si l'on disposait d'une population non

soumise à la mortalité et aux migrations. La somme des mariages de la table jusqu'à cinquante ans donnera l'intensité de la nuptialité avant 50 ans et leur répartition au cours du temps donnera son calendrier.

Les résultats d'une telle analyse, qui observe une génération ou une cohorte réelle, ne conduisent plus à certaines des objections que nous avions rencontrées en faisant une analyse transversale. Ainsi l'intensité des premiers mariages sera toujours inférieure ou égale à l'unité. On pourra clairement mettre en évidence l'effet d'une guerre ou de tout autre phénomène conjoncturel sur la nuptialité et mesurer comment la récupération s'effectue après celle-ci, selon les âges auxquels cette génération a connu ces événements. Il en est de même pour les naissances ou les migrations considérées par rang.

#### 2.2 PARADIGME DE L'ANALYSE LONGITUDINALE

L'objectif de cette analyse est d'isoler les divers phénomènes démographiques à l'état pur, afin de les débarrasser des phénomènes perturbateurs et de pouvoir effectuer des comparaisons entre pays ou entre régions. On peut dès lors cerner son paradigme par le postulat suivant⊡le démographe ne peut étudier que l'arrivée d'un événement et d'un seul, au cours de la vie d'une génération ou d'une cohorte, dans une sous-population *qui conserve tous ses caractères et les mêmes caractères tant que le phénomène se manifeste* [Blayo, 1995]. Cette population est donc considérée comme homogène, mais de plus les phénomènes perturbateurs doivent être indépendants du phénomène étudié, pour que cette analyse soit correcte [Henry, 1959]. Sous ces hypothèses il est possible d'utiliser les données de l'état civil et des registres de population pour en tirer une information claire sur la démographie des générations ou des cohortes définies à partir d'événements initiaux, tels que le mariage pour étudier la fécondité légitime, une naissance pour étudier la suivante, etc. Les manuels de démographie, qui en sont issus, vont considérer chaque phénomène dans un chapitre séparé, puisqu'ils sont isolés à l'état pur nuptialité, fécondité, mortalité, migrations, etc. [Pressat, 1966 ; Henry, 1972].

Henry [1959] indique cependant données les différences de tous ordres entre les hommes, on peut être assuré qu'aucun groupe humain n'est homogène; l'observation courante et la réflexion nous incitent, d'autre part, à penser qu'il n'y a pas, le plus souvent, indépendance entre les risques. Il indique ensuite qu'en pratique les procédés approchés utilisés pour réaliser une telle analyse sont acceptables la réponse paraît devoir être affirmative pour la fécondité perturbée par la mortalité. Nous avons, d'autre part donné un exemple où il semblait, à première vue, injustifiable de traiter un groupe comme s'il était homogène et où, néanmoins, les résultats ainsi obtenus étaient acceptables.

Ces analyses paraissent ainsi acceptables, même si le paradigme sous-jacent est loin d'être parfaitement vérifié. En fait, il a fallu l'utilisation d'enquêtes plus détaillées que les données de l'état civil ou les recensements, pour remettre vraiment en cause cette approche. Elle rencontre plus généralement certaines difficultés, que nous allons maintenant montrer.

# 2.3 PROBLÈMES RENCONTRÉS DANS L'APPLICATION DE CE PARADIGME

En premier lieu, on peut dire que cette analyse ne porte pas sur des trajectoires individuelles que l'on va suivre au cours du temps, mais sur une population dans laquelle certains individus entrent, tandis que d'autres en sortent. C'est au sein de cette population, qui resterait homogène au cours du temps, que l'on calcule l'intensité et le calendrier d'un phénomène. Un tel point de vue revient à nier toute spécificité à la vie d'un individu, pour ne s'attacher qu'à l'arrivée d'un événement dans une population qui demeure dans son ensemble homogène au cours du temps, car constituée d'unités interchangeables. Cette approche est donc un *holisme*, bien que différent du précédent il va nier l'existence d'entités individuelles, pour ne retenir que des comparaisons entre groupes homogènes.

Les événements qui régissent les entrées et sorties de la population étudiée doivent intervenir sous des conditions précises. Les événements perturbateurs qui, comme la mortalité ou l'émigration, empêchent certains individus de connaître le phénomène étudié, et les événements compétitifs ou concurrents qui, comme la cohabitation, viennent concurrencer le mariage, doivent être indépendants du phénomène étudié, sinon un biais de sélection évident fait disparaître de la population soumise au risque des individus aux caractéristiques particulières. Cela rend certaines études difficiles.

Ainsi, toutes les études de mortalité par cause sont interdites, à moins de supposer l'indépendance entre ces diverses causes. Il est en fait évident que l'éradication d'une cause de mortalité, si elle est possible, changera les quotients de mortalité pour d'autres causes, d'une façon qu'il est pratiquement impossible de prévoir tant que la première cause existe. De la même façon, l'étude de la sortie du célibat par cohabitation ou mariage n'est guère réaliste, car on doit faire l'hypothèse qu'il s'agit de deux phénomènes indépendants. C'est enfin *pour la même raison que l'on doit renoncer à faire l'étude dans une population dans laquelle plusieurs événements permettent d'entrer* [Blayo, 1995]. Voilà un bien grand nombre de cas dans lesquels le postulat empêche toute possibilité d'analyse.

L'hypothèse d'homogénéité de la population va poser d'autres problèmes. Tant que l'on travaillait sur des données de l'état civil, cela ne posait pas de difficultés car on n'avait aucune possibilité de vérifier cette hypothèse. En effet cette source, dont l'intérêt se trouve dans son exhaustivité, ne fournit que peu d'informations sur l'histoire de vie des individus qui permettrait une analyse plus détaillée des phénomènes étudiés. En dépit de cela, il paraît évident que la population sur laquelle on travaille est à bien des égards hétérogène. Ainsi, des études du moment [Roussel, 1971] ont montré que la nuptialité des agriculteurs et des salariés agricoles en 1968, était bien plus basse que celle des autres professions. Il y aurait donc tout intérêt à travailler sur cette sous-population, plus spécifique, qui sera plus homogène que la population initiale d'ensemble. Dans ce cas un nouveau phénomène intervient depart de l'agriculture de célibataires. Ce phénomène va toucher un bien plus grand nombre d'individus que la mortalité ou la migration internationale, et cela aux âges où se produisent la majorité des mariages.

Bien plus, il conviendrait de scinder cette sous-population en un nombre toujours croissant de sous-groupes pour chercher à les rendre tous homogènes, vis-à-vis du phénomène étudié. Comme l'indique Henry [1959] [pour savoir, exactement, quelle est la portée pratique de l'hétérogénéité des groupes humains, il faudra pousser les recherches en démographie différentielle jusqu'aux caractéristiques individuelles, physiques et psychologiques, avec le souci d'étudier, à la fois, la dispersion et la corrélation des indices démographiques à l'intérieur des groupes, assez sommaires, considérés jusqu'ici.

Ainsi, ces groupes pourront être distingués selon la région de résidence, car les chances de se marier d'un agriculteur beauceron seront sans doutes différentes de celles d'un Ariégeois, selon le revenu, selon le niveau d'éducation, et ainsi de suite. Mais, dans ce cas, on va se trouver en présence de groupes si restreints, que leur effectif réduit empêchera toute analyse longitudinale. Qui plus est, on n'aura jamais la certitude d'avoir pris en compte tous les facteurs d'hétérogénéité de la population. Il restera toujours une hétérogénéité non observée, dont l'effet sur les quotients sera totalement inconnu, contrairement à ce qui se passe dans une analyse biographique, comme on le verra plus loin. Enfin, la possibilité pour les individus de passer d'un groupe à l'autre, va compliquer l'analyse.

Reprenons l'exemple précédent de la migration des norvégiens influencée par le fait d'être agriculteur. Si l'on essaye d'analyser ce cas à l'aide de l'analyse longitudinale, on voit que l'individu, au cours de sa vie, a la possibilité non seulement de migrer mais aussi de changer de profession. Un individu, qui est agriculteur au début de son séjour, pourra changer de profession, devenir chômeur ou inactif. Etre agriculteur n'est donc pas un état stable au cours du temps, et le registre de population norvégien ne permet pas de saisir cette profession de façon continue. Celle-ci n'est connue qu'à l'aide des recensements, qui n'ont lieu que tous les dix ans. Il n'est donc pas possible dans ce cas de faire une analyse longitudinale de la migration des agriculteurs.

Il semble, dès lors, que l'application en toute rigueur de ce paradigme à des problèmes démographiques concrets, revient à nier toute possibilité d'analyse longitudinale plus poussée des divers événements démographiques. Il nécessite, en effet, des décompositions tellement fines de la population étudiée, qu'il invalide tout calcul sérieux. Il impose également de telles contraintes sur les événements étudiés qu'il interdit tout un pan de l'analyse démographique (analyse d'événements compétitifs, en interaction, analyse d'événements dans une population où il y a des entrées et des sorties).

Devant toutes ces difficultés on peut se demander s'il n'est pas nécessaire de changer les hypothèses à la base de l'analyse pour pouvoir mieux asseoir les raisonnements tenus.

# 3. UNE APPROCHE BIOGRAPHIQUE

#### 3.1 APPROCHE MISE EN PLACE AU DÉBUT DES ANNÉES 1980

Au début des années 1980, soit plus de trente ans après l'introduction de l'analyse longitudinale, une nouvelle approche apparaît en démographie. Celle-ci ne suit pas la proposition d'utiliser plus avant les méthodes de l'analyse longitudinale différentielle, dont nous avons déjà indiqué les difficultés, mais se dirige vers une généralisation des méthodes de régression logistique utilisées d'abord en transversal, puis étendues à l'approche longitudinale. Voyons maintenant ce qui a rendu possible cette analyse des comportements individuels et comment, en introduisant le temps, elle permet de résoudre les difficultés indiquées précédemment.

#### 3.2 DEUX INNOVATIONS

Il nous paraît utile de distinguer ici deux innovations qu'apporte cette approche, car elles sont très différentes l'une de l'autre. La première permet l'analyse des comportements, tandis que la seconde introduit dans cette analyse le temps vécu par l'individu.

# 3.2.1 L'introduction de comportements individuels

En premier lieu, l'analyse des comportements individuels n'était pas de mise, tant avec l'analyse transversale qu'avec l'analyse longitudinale. Les deux approches, nous l'avons vu, considéraient essentiellement la population d'un point de vue agrégé. La première avancée de la nouvelle approche sera de considérer les phénomènes étudiés comme individuels.

Dans l'analyse du moment de données agrégées, considérée plus haut, nous avions relié la probabilité de connaître un événement à celle d'en connaître d'autres ou d'avoir diverses caractéristiques, en travaillant sur un certain nombre de sous-populations. Dans ce cas, il suffit de connaître les distributions marginales des événements étudiés pour pouvoir estimer, sous des hypothèses données, la liaison recherchée. Maintenant, nous allons essayer d'estimer la distribution jointe de toutes les combinaisons de variables, au niveau individuel, et de relier ainsi de façon différente l'arrivée d'un événement aux caractéristiques d'un individu statistique.

Reprenons l'exemple de l'effet de la proportion d'agriculteurs sur les migrations interrégionales en Norvège. Nous avions vu qu'une analyse au niveau agrégé conduit à un effet positif plus une région contient d'agriculteurs plus la probabilité d'en émigrer est importante. Si l'on travaille maintenant sur les données individuelles on a une autre possibilité d'estimer ces probabilités, par un modèle logit, par exemple, qui est équivalent dans ce cas simple à l'estimation séparée des probabilités de migrer des agriculteurs et des autres.

Si l'on suppose qu'un *modèle logit* s'applique correctement à nos données individuelles, on peut écrire la probabilité pour que l'individu *i* présent dans la région *j* 

soit un migrant  $(\mu_{ij} = 1)$  en fonction du fait qu'il soit agriculteur  $(a_{ij} = 1)$  ou non  $(a_{ij} = 0)$ , sous la forme suivante  $\square$ 

$$P(\mu_{ij} = 1 \mid a_{ij}) = (1 + exp - [\alpha_0(1 - a_{ij}) + \alpha_1 a_{ij}])^{-1}$$

Dans ce cas, lorsque l'individu est agriculteur, sa probabilité de migrer s'écrit en fonction des paramètres estimés

$$P(\mu_{ij} = 1 \mid a_{ij} = 1) = (1 + exp[-\alpha_1])^{-1} = m_a$$

et lorsqu'il a une autre profession⊡

$$P(\mu_{ij} = 1 \mid a_{ij} = 0) = (1 + exp[-\alpha_0])^{-1} = m_a$$

Les paramètres estimés à l'aide de ce modèle sont donnés dans la première colonne intitulée *Modèle logit simple* du Tableau 2. Ces paramètres pourront être comparés à ceux des modèles que nous estimerons par la suite.

Paramètres	Modèle logit		
	simple	contextuel	
$\alpha_0$ (non-agriculteur)	-1,736 (0,017)	-1,996 (0,033)	
$\alpha_1$ (agriculteur)	-2,260 (0,084)	-2,155 (0,209)	
α <sub>2</sub> (part d'agriculteurs)		4,469 (0,461)	
$\alpha_3$ (agric. × part agric.)		-5,774 (2,447)	

Tableau 2. Paramètres estimés et leur écart-type entre parenthèses, par les modèles individuels logit

En revanche, pour comparer ces résultats à ceux obtenus par une régression sur données agrégées, il est préférable d'estimer les probabilités individuelles de migrer des agriculteurs et des autres celles-ci sont données dans la deuxième colonne du Tableau 1 (p. 54) intitulée *Régression logistique*. Le comportement individuel, mis ici en évidence, est en contradiction avec les résultats obtenus à l'aide des données agrégées, mais est plus proche de notre intuition initiale les agriculteurs ont une plus faible probabilité de migrer que le reste de la population. Nous pourrons voir en effectuant une analyse multiniveau les raisons de cette divergence. Mais poursuivons d'abord l'examen de cette approche.

Cette analyse peut facilement être généralisée à un nombre quelconque de caractéristiques individuelles, pour expliquer un comportement donné. Dans ce cas le problème de la dépendance entre ces caractéristiques ne se pose plus comme dans l'analyse agrégée. Bien plus il sera toujours possible, si deux caractéristiques ne sont pas indépendantes entre elles, de considérer séparément les individus ayant l'une de ces

caractéristiques sans avoir l'autre et les individus ayant simultanément ces deux caractéristiques.

Cette approche qui considère les événements connus par les individus pendant un court intervalle de temps, pour les expliquer par leurs caractéristiques en début de période, rencontre cependant un certain nombre d'inconvénients. En premier lieu, elle entraîne une perte d'information importante, car on agrège des événements survenus au cours d'une période, ici de deux ans, en laissant de côté leur date exacte de survenue ; on ne tient pas compte non plus de la date d'installation dans la région de résidence en 1970, perdant ainsi un effet de la durée de séjour sur cette probabilité de migrer. Elle ne permet pas non plus d'observer un effet variable avec le temps des caractéristiques initiales.

En second lieu, ces caractéristiques sont fixées au moment de leur mesure en 1970, sans pouvoir varier au cours du temps. A nouveau il n'y a aucune raison qu'un départ de l'agriculture ne change pas la probabilité de migrer des individus. Il n'est malheureusement pas possible de faire intervenir cette variation avec un modèle logit.

# 3.2.2 L'introduction de régressions temporelles

Pour pouvoir aller plus loin, il paraît alors nécessaire de rompre la carapace rigide de ces données administratives. Mais, simultanément, lorsque l'information devient trop lourde et trop détaillée, il faut utiliser un recueil non exhaustif de celle-ci. La solution à cette double contrainte se trouve dans le recueil d'enquêtes qui permettent d'élaborer un questionnaire pour répondre à des questions précises. On pourra alors voir si l'effet des phénomènes, dits perturbateurs, est vraiment indépendant des phénomènes étudiés et, s'il en dépend, de mettre en place de nouvelles méthodes d'analyse pour montrer clairement ces effets.

Ces enquêtes doivent donc enregistrer le maximum d'événements dans la vie des personnes interrogées, avec l'ordre temporel de leur arrivée et les durées qui les séparent pour réussir à mettre en évidence toutes les dépendances qu'il peut y avoir entre eux. Elles doivent également enregistrer le plus grand nombre de caractéristiques des enquêtés et de leur cadre de vie pour pouvoir les faire intervenir dans l'analyse des comportements. Pour saisir tous ces événements et tous ces états, deux types de questionnaires peuvent être utilisés, chacun ayant ses avantages et ses inconvénients.

Le premier type est l'enquête prospective qui suivra tout au long de leur vie les membres d'un échantillon et ne posera donc pas de problèmes de mémoire. Mais, l'importance du délai d'attente, avant de pouvoir analyser les données d'une telle enquête, conduit le chercheur à préférer plutôt réaliser une enquête rétrospective. Celle-ci enregistre lors d'un seul passage tous les événements passés d'intérêt et les caractéristiques individuelles. L'enquête est alors immédiatement utilisable pour l'analyse et on ne court aucun risque de perdre des individus en cours d'enquête. Elle pose cependant des problèmes de mémoire des enquêtés⊡nous renvoyons les lecteurs intéressés aux travaux réalisés sur ce thème [Poulain et al., 1991, Courgeau, 1991).

Il n'est pas question ici d'entrer dans le détail des méthodes d'analyse, mais d'indiquer seulement qu'elles sont issues des travaux des probabilistes en majeure partie français, qui ont développé les théories des martingales [Dellacherie et Meyer, 1980], de l'intégration stochastique [Dellacherie, 1980] et des processus de comptage [Bremaud et Jacod, 1977]. Divers manuels d'analyse des biographies ont été publiés⊡citons ici pour le lecteur intéressé le manuel de Courgeau et Lelièvre [1989] pour l'application à la démographie, et celui d'Andersen et *al*. [1993] pour une approche statistique plus complète.

Ces méthodes permettent des conclusions mieux assurées que celles obtenues avec l'analyse longitudinale, en particulier sur l'hétérogénéité non observée [Bretagnole et Huber-Carol, 1988]. Elles nous amènent enfin à rechercher quel est le paradigme qui les soutient et quels avantages il présente par rapport aux précédents, aussi bien celui de l'analyse du moment que celui de l'analyse longitudinale. Enfin il nous faudra voir les inconvénients qu'il présente encore par rapport aux enjeux de la démographie.

# 3.3 UN PARADIGME ISSU DE L'INDIVIDUALISME MÉTHODOLOGIQUE

L'intérêt ne va plus se porter maintenant sur l'étude de sous-populations homogènes, mais sur celle d'un ensemble de trajectoires individuelles entre un grand nombre d'états. L'unité d'analyse n'est plus l'événement mais la biographie individuelle, considérée comme un processus stochastique complexe. Il ne s'agit plus de chercher à isoler chaque phénomène à l'état pur, mais au contraire de voir comment un événement d'une existence peut influer sur la suite de la vie de l'individu et comment certaines caractéristiques peuvent pousser un individu à se comporter différemment d'un autre.

Le paradigme, dans ce cas, peut être approché par l'énoncé suivant un individu parcourt, tout au long de sa vie, une trajectoire complexe, qui dépend à un instant donné, de sa trajectoire antérieure et des informations qu'il a pu acquérir dans son passé [Courgeau et Lelièvre, 1996]. Il s'agit alors d'un *individualisme méthodologique*, qui montre que le comportement d'un homme est à rattacher à son histoire de vie passée, sans rechercher dans la société des raisons de ses actes. Il est donc à l'opposé de l'approche agrégée du moment qui est, comme l'approche longitudinale, un holisme méthodologique.

En premier lieu on va suivre, au cours du temps, un ensemble d'individus, faisant partie d'une génération ou d'une cohorte donnée. La principale façon, pour un individu, d'échapper à l'observation est la sortie de l'échantillon à la date de l'enquête ou à la date de l'étude, si l'on travaille de façon prospective. Dans la mesure où ces dates n'ont aucune raison d'être liées à la vie d'un individu, la condition d'indépendance est parfaitement vérifiée l'observation est dite non-informative et l'on sait tenir compte de ces sorties lors de l'estimation des quotients [Hoem, 1985]. On voit ainsi, comment le changement de point de vue résout le problème des phénomènes perturbateurs.

Alors que dans l'analyse longitudinale classique, il n'était pas utile de distinguer les événements perturbateurs des événements compétitifs ou concurrents, il importe maintenant de les considérer séparément. Comme nous venons de l'indiquer, le phénomène perturbateur, que nous préférons appeler ici «Phénomène en interaction (modifie la probabilité de survenue de l'événement étudié. Au contraire, quand on parle de

phénomènes compétitifs ou concurrents, il s'agit des diverses modalités d'un événement qui conduisent au même état final⊡ mortalité distinguée par cause⊡ mise en union distinguée selon qu'elle se produit par mariage ou cohabitation, etc.

Nous sommes ainsi armés pour voir comment un événement familial, économique ou autre, que vit un individu ayant une expérience passée également connue, va modifier les chances d'arrivée des autres événements de son existence. C'est bien là ce que nous avons appelé l'analyse des interactions entre phénomènes démographiques, qui prend bien sa place dans le paradigme proposé. Elle s'oppose à l'hypothèse d'indépendance en longitudinal. Il est évident que, si l'on cherche à comprendre les comportements d'un individu, il faudra faire intervenir ses origines sociales et toute son histoire passée. Nous supposons alors que ces comportements ne sont pas innés, mais se modifient au cours de l'existence individuelle grâce aux expériences personnelles et aux acquis successifs. Nous en arrivons ainsi à l'analyse de l'hétérogénéité des populations, vue sous forme dynamique et non plus statique, comme dans l'analyse du moment. L'analyse de régression, qui cherchait à relier des comportements agrégés à des caractéristiques des populations, agrégées elles aussi, doit maintenant être étendue à l'analyse de caractéristiques individuelles. Elle s'oppose donc à l'hypothèse d'homogénéité de l'analyse longitudinale.

Lorsqu'un individu naît, son existence peut suivre une très grande variété de trajets. En dépit de cela, ces divers trajets sont loin d'être tous également probables. La biographie d'un individu peut dès lors être définie comme le résultat d'un processus stochastique complexe, se déroulant au cours du temps vécu par l'individu. C'est bien l'étude de ce processus qui constitue la base de l'analyse biographique. Il nous faut cependant voir plus en détail les problèmes rencontrés lorsque l'on utilise cette approche.

#### 3.4 PROBLÈMES RENCONTRÉS PAR CETTE APPROCHE

Les diverses raisons d'agir, à la fois internes et externes à la démographie, peuvent maintenant être mises en évidence et leurs effets sur les comportements individuels peuvent être analysés avec un grand détail. Mais le plus souvent ce sont les caractéristiques de l'individu, que l'on fera intervenir pour expliquer ses comportements. On risque de commettre, dans ce cas, ce que l'on appelle l'*erreur atomiste*, car on ignore alors le contexte dans lequel les conduites humaines se produisent. Ce contexte peut être défini comme le milieu familial dans lequel l'individu vit, ou plus généralement comme un entourage plus ou moins étendu autour de l'individu son quartier, sa commune, etc. On peut penser que ce contexte peut jouer sur les comportements individuels et il paraît fallacieux d'isoler l'individu des contraintes imposées par la société et le milieu dans lequel il vit.

Ce risque d'erreur, que l'on peut opposer à l'erreur écologique, avait déjà été reconnu par des sociologues [Lazarsfeld et Menzel, 1961]. Ils montraient la nécessité de définir avec suffisamment de précision divers types de groupes, de communautés, et plus généralement d'ensembles quelconques d'individus. Ce qui apparaît comme un groupe

dans une étude, peut être considéré comme un membre d'un groupement plus général dans une autre étude. Cette propriété est très importante, car elle montre le caractère relatif de l'individu que l'approche biographique considère comme l'unité prépondérante. Nous allons maintenant l'appliquer pour dépasser l'opposition entre individualisme et holisme.

#### 4. UNE APPROCHE CONTEXTUELLE ET MULTINIVEAU

Devant ce risque d'erreur atomiste, le chercheur va essayer de travailler simultanément à divers niveaux d'agrégation. Les premiers travaux démographiques dans ce sens datent de 1983 [Mason et al.]. Diverses possibilités s'offrent dans ce cas au chercheur, que nous allons explorer successivement. Ou bien il essaye de faire intervenir l'effet de caractéristiques agrégées dans le modèle individuel qu'il utilise, ou bien il essaye de prendre en compte les divers niveaux d'agrégation auxquels il peut travailler.

#### 4.1 D'UNE ANALYSE CONTEXTUELLE...

Il est possible de montrer quelles sont les conditions à vérifier pour qu'un modèle estimé sur des données individuelles soit identique au modèle équivalent calculé sur des données agrégées. On montre qu'une fois contrôlé le fait que l'individu a la caractéristique explicative (agriculteur, par exemple), la caractéristique agrégée correspondante (le pourcentage d'agriculteurs, par exemple) ne doit plus influer sur la probabilité de connaître l'événement étudié (migrer, par exemple). Dans ce cas, les modèles agrégé et individuel sont parfaitement équivalents [Courgeau, 2003]. Le problème vient de ce que cela est rarement le cas, comme nous l'avons vérifié sur l'exemple norvégien.

La solution la plus simple à ce problème est de faire intervenir des données mesurées à divers niveaux d'agrégation, pour expliquer un comportement qui est toujours individuel. On voit alors la différence qui existe entre cette approche, qui fait intervenir des caractéristiques agrégées pour expliquer un comportement individuel, et l'approche agrégée qui expliquait un comportement agrégé par des caractéristiques elles-mêmes agrégées.

Cela permet d'éliminer le risque d'erreur écologique, car la caractéristique agrégée va mesurer une construction différente de son équivalent au niveau individuel. Elle n'intervient plus comme un substitut, mais comme une caractéristique de la souspopulation qui va affecter le comportement d'un individu qui en fait partie. Simultanément, l'erreur atomiste disparaît à partir du moment où l'on fait intervenir le contexte dans lequel l'individu vit. On peut cependant se demander si l'intervention des caractéristiques agrégées suffit entièrement pour prendre en compte ce contexte nous verrons plus loin qu'il sera nécessaire d'aller plus avant dans une analyse pleinement multiniveau.

Si l'on reprend l'exemple précédent de la migration des agriculteurs norvégiens l'application d'un modèle contextuel peut faire intervenir à la fois le fait que l'individu soit agriculteur et le pourcentage d'agriculteurs présents dans la région où il vit. Le modèle logit correspondant peut alors s'écrire

$$P(\mu_{ij} = 1 \mid a_{ij}, a_{.j}) = (1 + exp - [\alpha_0(1 - a_{ij}) + \alpha_1 a_{ij} + \alpha_2 a_{.j} + \alpha_3 a_{ij} a_{.j}])^{-1}$$

où  $a_{.j}$  est la proportion d'agriculteurs observée dans la région j. Ainsi le terme  $\alpha_2$  représente l'effet contextuel du pourcentage d'agriculteurs sur la probabilité de migrer, tant des agriculteurs que des autres professions, et le terme  $\alpha_3$  représente un effet d'interaction, qui permet de faire dépendre l'effet contextuel de la profession de l'individu.

Ces résultats donnés dans le Tableau 2 précédent (colonne intitulée *Modèle logit contextuel*, p.**©**1), sont synthétisés ici par la Figure 1, qui représente pour les agriculteurs et les non-agriculteurs norvégiens les probabilités de migrer, en fonction de la proportion d'agriculteurs présents dans chaque zone.

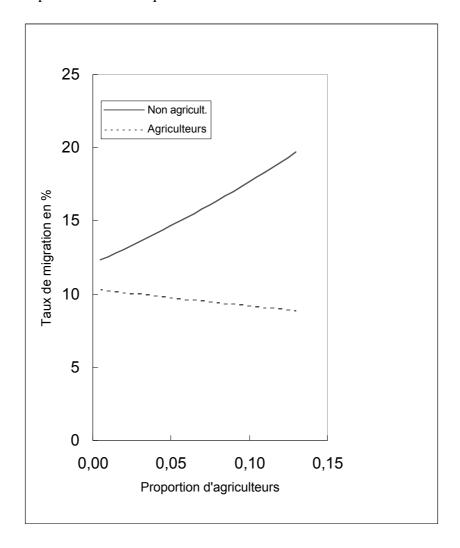


Figure 1. Taux de migration en fonction de la proportion d'agriculteurs (Modèle logit contextuel)

Elle fournit des résultats qui permettent d'harmoniser les contradictions précédentes De fait d'être agriculteur réduit toujours fortement la probabilité de migrer, alors que le fait de vivre dans une région où le pourcentage d'agriculteurs est important va augmenter les chances de migrer. Mais cette fois-ci, l'augmentation des taux d'émigration

avec le pourcentage d'agriculteurs s'explique d'une façon tout à fait différente de la précédente. En effet, dans l'analyse des données agrégées, c'est la constance des probabilités d'émigrer des agriculteurs et des autres (à des valeurs différentes), qui, par le jeu des pourcentages d'agriculteurs, explique que c'est dans les régions où il y a plus d'agriculteurs que les taux d'émigration sont plus élevés. Ici, c'est la variation de ces probabilités d'émigrer selon le pourcentage d'agriculteurs, qui vient expliquer le même résultat. Cela permet de montrer que cette plus forte probabilité de migrer est essentiellement le fait des non-agriculteurs, car les chances de migrer des agriculteurs ne sont pas significativement affectées par le pourcentage d'agriculteurs. Ce modèle vient bien conforter l'hypothèse que nous avions précédemment posée une forte densité d'agriculteurs dans une zone va augmenter les chances de migrer des autres professions. Cela pourrait s'expliquer, dans ces régions, par un manque relatif d'autres emplois qu'agricoles qui va pousser les autres professions à émigrer plus que les agriculteurs, lorsqu'ils recherchent un nouveau travail.

Il est intéressant maintenant de voir que les caractéristiques, qui interviennent peuvent être de types très différents. Les caractéristiques à analyser sont toujours considérées comme individuelles. Elles peuvent être des caractéristiques du moment, donc analysées par un modèle de type logit, mais elles peuvent également être des caractéristiques biographiques et être analysées comme telles. Les caractéristiques explicatives sont en revanche de nature bien plus diverses. On peut d'abord faire intervenir des caractéristiques individuelles, soit mesurées juste avant l'arrivée de l'événement dans le cas d'un modèle logit, soit mesurées au cours du temps dans le cas d'un modèle biographique. Ensuite, pour un niveau d'agrégation donné, on peut agréger certaines de ces caractéristiques individuelles et estimer des pourcentages ou des moyennes pour une région donnée, par exemple, son pourcentage d'agriculteurs, le nombre moyen d'enfants de ses habitants, etc. Des procédures analytiques plus complexes peuvent aussi être utilisées en même temps que le nombre moyen d'enfants, on peut faire intervenir simultanément l'écart-type de ce nombre, ou la corrélation entre ce nombre et le revenu dans chaque niveau d'agrégation.

Les caractéristiques structurelles sont des propriétés de chacune des unités d'un niveau d'agrégation donné. Elles sont obtenues en effectuant des opérations sur les effectifs intervenant dans certaines relations, qui existent entre membres de ces unités. Ainsi considérons un ménage son nombre d'enfants, sa proportion de membres non apparentés au chef de ménage (domestiques, par exemple), etc., en constituent des caractéristiques structurelles. D'autres caractéristiques plus globales distinguent les unités comme un tout nombre de lits d'hôpital, densité de population, etc. Aucune caractéristique individuelle ne leur correspond, mais elles peuvent cependant être agrégées à divers niveaux. Ainsi, le nombre de lits d'hôpital d'une région est la somme des lits de chacun des départements qui la constituent et sa densité est la somme des densités pondérées par les populations de chaque département. Également, d'autres caractéristiques collectives sont bien définies à un niveau d'agrégation donné, mais ne peuvent guère être agrégés à des niveaux plus larges. Ainsi la coloration politique d'une commune, définie par exemple par le parti d'affiliation de son maire, ne peut être agrégée à celle des

communes voisines qui peuvent couvrir un large spectre. Elle n'existe donc pas au niveau individuel, ni au niveau départemental ou régional.

Enfin dans les modèles biographiques contextuels, on a la possibilité d'introduire des périodes historiques, par exemple une guerre, une crise économique, etc., qui surviennent bien à un moment précis du temps historique mais à des instants différents du temps vécu par les individus. Cela permet de combiner une approche transversale à une approche longitudinale de la vie d'un individu, dans un même modèle. Comme on introduit des caractéristiques de divers niveaux d'agrégation, il est simultanément possible d'introduire des temporalités différentes dans le même modèle.

L'utilisation de modèles contextuels impose cependant des conditions très restrictives à la formulation des risques relatifs en fonction des caractéristiques. Ils supposent que les comportements des individus à l'intérieur d'un groupe soient indépendants entre eux. En pratique, il est plus vraisemblable que le risque encouru par un individu d'un groupe donné dépende des risques rencontrés par les individus du même groupe. Ignorer cette dépendance intra-groupe entraîne généralement des estimations biaisées des variances des effets contextuels, conduisant à des intervalles de confiance trop resserrés.

Également ces risques relatifs pour des individus situés dans des groupes différents ne peuvent pas varier librement, mais ont des contraintes restrictives imposées par le modèle utilisé. Ainsi, dans le cas précédent, si l'on relie les probabilités de migrer des non-agriculteurs et des agriculteurs, dans chacune des régions, par ses segments de droite, alors on peut facilement montrer que toutes ces droites vont passer par un point commun, bien qu'a priori elles n'ont aucune raison de vérifier cette condition restrictive [Courgeau, 2001]. Étant données ces différentes contraintes, il devient nécessaire de formuler un tel modèle dans toute sa complexité. Nous arrivons là à de véritables modèles multiniveaux.

#### 4.2 À UNE ANALYSE MULTINIVEAU

Pour montrer plus clairement ce que nous allons faire, il est utile de revenir sur ce que nous avions dit au sujet de l'analyse longitudinale, lorsque nous cherchions à mettre en évidence l'effet de nombreuses caractéristiques sur les comportements démographiques. Nous avions en effet indiqué qu'une décomposition en sous-populations plus homogènes, tant en considérant des régions différentes, que des caractéristiques différentes, conduisait rapidement à des effectifs soumis au risque très faibles les résultats d'une telle analyse devenaient trop fortement instables et ne pouvaient plus révéler de relations significatives. Dans ce cas on se trouvait noyé dans des fluctuations aléatoires (bruit) qui cachaient tout résultat d'intérêt.

Pour résoudre ce problème nous nous sommes alors tournés vers les méthodes de régression logistique, en démographie, qui mettent en évidence des résultats saillants de l'analyse. L'introduction du temps dans des modèles de type Cox, a ouvert la possibilité d'étudier l'hétérogénéité de la population et d'obtenir des résultats tout à fait significatifs, cette fois-ci, même lorsque l'on fait intervenir un grand nombre de caractéristiques. Mais

cette méthode va impliquer de nouvelles hypothèses, dont il faudra tester la validité. Malheureusement la puissance de tels tests est si faible qu'ils ne permettent guère de rejeter le modèle même s'il est très erroné [Greenland, 2001]. Les modèles contextuels, qui généralisent ces méthodes en introduisant des caractéristiques agrégées, n'apportent toujours pas de solution aux difficultés que nous venons d'indiquer.

Il paraît dès lors utile d'essayer de rechercher un compromis entre un modèle n'imposant aucune contrainte à ses estimateurs, mais ne permettant guère une estimation significative, et un modèle avec de trop fortes contraintes dont on ne peut guère tester la validité. La solution à ce double problème se trouve, à notre avis, dans les modèles multiniveaux. Ceux-ci vont introduire des effets aléatoires dans les modèles individuel ou contextuel précédents, qui permettent de généraliser les méthodes de régression considérées [Courgeau, 2001].

Reprenons l'exemple des migrations norvégiennes. Nous avons en premier lieu la possibilité d'estimer un modèle logistique par région, permettant de mesurer l'effet d'une caractéristique, ici être agriculteur, sur la probabilité de migrer. C'est la première étape de l'analyse, qui va estimer des séries de paramètres régionaux. Mais dès que le nombre de régions est élevé ou que le nombre de paramètres est important ces estimations seront entachées d'une très forte erreur et ne permettront guère de conclure. Si l'on pose des contraintes sur ces paramètres pour avoir des résultats plus précis, en supposant par exemple qu'ils sont répartis de façon aléatoire autour de leur valeur moyenne, on peut estimer leur variance.

D'où l'idée de mettre d'abord en évidence cet effet régional avant de faire intervenir des caractéristiques agrégées, comme le pourcentage d'agriculteurs. Nous nous dirigeons alors vers un *modèle multiniveau*, qui permet de faire intervenir des aléas régionaux pour prendre en compte cet effet [Courgeau et Baccaïni, 1997]. Un tel modèle peut s'écrire

$$P(\mu_{ij} = 1 \mid a_{ij}) = p_{ij} = (1 + exp - [(\alpha_0 + u_{0j})(1 - a_{ij}) + (\alpha_1 + u_{ij})a_{ij}])^{-1}$$

où les paramètres  $u_{0j}$  et  $u_{1j}$  sont des aléatoires, de moyenne nulle et dont on va estimer les variances et covariance  $u_{0j} = \sigma_{u_0}^2$ ,  $var(u_{1j}) = \sigma_{u_1}^2$  et  $cov(u_{0j}, u_{1j}) = \sigma_{u_{01}}$ . Il s'ensuit que les réponses  $u_{ij}$  sont distribuées selon une loi binomiale de paramètres  $u_{ij} \approx B(p_{ij}, 1)$ . On a la variance conditionnée  $var(u_{ij} \mid p_{ij}) = p_{ij}(1 - p_{ij})$  et le modèle devient alors un modèle non linéaire  $u_{ij} = v_{ij} + v_{ij} = v_{ij}$  où  $u_{ij} = v_{ij} = v_{ij}$  et où  $u_{ij} = v_{ij} = v_{ij}$  et où  $u_{ij} = v_{ij} = v_{ij}$ 

Dans ce cas la variance est égale à l'unité au niveau individuel, et l'on travaillera essentiellement sur les variances et covariances au niveau régional. Il est cependant possible de libérer la variance individuelle de la contrainte d'égalité à l'unité, pour vérifier qu'un modèle logit s'applique correctement aux données. Ces paramètres et leurs variances-covariances ont été estimés ici à l'aide du logiciel Mln [Goldstein, 1995].

Voyons comment de tels modèles éclairent les comportements migratoires. Le Tableau 3 porte les résultats de l'application de ce modèle aux données norvégiennes.

Paramètres	Modèle multiniveau	
♦ Fixes:	simple	contextuel
$lpha_0$ (non-agriculteur)	-1,710 (0,070)	-2,067 (0,119)
$\alpha_1$ (agriculteur)	-2,306 (0,133)	-2.017 (0,340)
α <sub>2</sub> (part d'agriculteurs)		5,420 (1,209)
$\alpha_3$ (agric. × part agric.)		-8,691 (3.238)
♦ Aléatoires:		
$\sigma_{u_0}^2$ (non-agriculteur)	0,088 (0,032)	0,047 (0,024)
$\sigma_{u_{01}}^2$ (covariance)	0,054 (0,044)	0,085 (0,042)
$\sigma_{u_1}^2$ (agriculteur)	0,167 (0,135)	0,181 (0,119)

Tableau 3. Paramètres estimés et leur écart-type entre parenthèses

Lorsqu'on n'introduit pas les caractéristiques agrégées des régions (première colonne intitulée *Modèle multiniveau simple*), les paramètres au niveau individuel restent pratiquement les mêmes que ceux estimés sans faire intervenir d'effets régionaux, tant pour les agriculteurs que pour les autres professions (cf. Tableau 2, p. 161). En revanche des effets significatifs apparaissent pour les aléatoires régionaux, montrant un comportement très diversifié des habitants des différentes régions. Lorsque l'on introduit les caractéristiques agrégées des régions (deuxième colonne du tableau 3 intitulée *Modèle multiniveau contextuel*), leur effet apparaît tout à fait significatif et identique à ce que l'on observait avec un seul niveau d'agrégation (cf. Tableau 2, p. 161). En revanche au niveau des aléatoires régionaux, on observe une nette réduction de moitié pour les nonagriculteurs, montrant clairement que la prise en compte des pourcentages régionaux d'agriculteurs joue sur cette variance, alors que pour les agriculteurs l'aléa reste toujours aussi élevé. Mais le fait que la variance régionale reste significative montre que l'on n'explique pas tout avec les caractéristiques agrégées. Ce modèle est donc bien plus complet que le modèle contextuel précédent, tout en confirmant ses résultats.

# 4.3 UN PARADIGME DÉPASSANT L'INDIVIDUALISME ET LE HOLISME MÉTHODOLOGIQUE

Cette nouvelle approche ne va pas bouleverser le paradigme utilisé pour l'analyse biographique, car elle se situe toujours au niveau individuel. Mais, en introduisant des effets de groupes ou de régions sur les comportements des individus, elle va permettre de le compléter.

Le nouveau paradigme va donc toujours considérer que le comportement d'un individu dépend de son histoire passée, mais il va falloir ajouter que ce comportement peut également dépendre de contraintes extérieures exercées sur l'individu, que celui-ci en soit conscient ou non. Il sera donc ainsi possible de considérer les « fets pervers d'actions individuelles, dont l'objectif initial était tout à fait différent du résultat obtenu [Boudon, 1977]. Ces effets sont induits par le milieu dans lequel l'individu vit et il est possible de les mettre en évidence à l'aide des méthodes multiniveaux. De même, l'individu peut ne pas être conscient de contraintes que la société lui impose, alors que son comportement pourra en être influencé sans qu'il ne le sache. Enfin, l'individu peut être pleinement conscient de ces contraintes et agir en fonction d'elles, aussi bien pour y résister, que pour les contourner ou les utiliser, si elles peuvent améliorer sa situation.

Cette approche permet de travailler sur les biographies individuelles situées dans un espace multiple. Cet espace ne sera pas seulement l'espace physique habituel, où l'on peut distinguer des régions ou des villes, mais pourra également être un espace plus social, faisant intervenir les réseaux de relations entre individus, plus économique, faisant intervenir les entreprises, les administrations, etc., où ces individus travaillent, ou tout autre espace fonctionnel.

Ce paradigme va également ouvrir vers un point de vue statistique nouveau des comportements humains. En effet, le point de vue «Subjectivistes, mis en place par Bayes en 1763, apporte une dimension plus large à cette approche. Il part d'une probabilité *a priori* d'un événement donné, pour estimer ensuite, à l'aide d'observations, une probabilité *a posteriori* pour ce même événement. L'utilisation d'une telle formulation a été fortement rejetée par les objectivistes, car pour eux la probabilité *a priori* n'a rigoureusement aucun sens, puisque c'est parler de la probabilité d'un événement unique. Tout l'effort des objectivistes a visé à développer des méthodes d'inférence compatibles avec cette conception des probabilités, en évitant l'utilisation du théorème de Bayes. L'approche multiniveau permet le retour en force de la conception bayésienne des probabilités [Courgeau, 2003].

Ainsi, un modèle par régions va nous donner des estimations d'un grand nombre de coefficients, ici 38 pour 19 régions, certains pouvant être estimés sur de faibles effectifs avec en conséquence une variance très élevée. Comme nous l'avions indiqué il n'est guère possible de conclure à partir de cette première étape. Nous pouvons alors nous retourner vers le modèle contextuel, qui cette fois-ci ne nécessite plus que l'estimation de quatre coefficients seulement. La recherche d'une synthèse entre ces deux modèles, va finalement introduire quatre paramètres fixes et deux variables aléatoires dont on ne va estimer que les variances et covariances, soit au total sept quantités.

Cependant l'estimation des résidus est possible et permet de mieux situer les régions les unes par rapport aux autres et d'identifier celles qui sont dans une situation extrême par rapport aux autres, en estimant un intervalle de confiance pour chaque région. C'est là ce que l'on a coutume d'appeler une estimation bayésienne empirique (empirical - Bayes estimator), où la distribution *a priori* est estimée à partir des données de même que la distribution *a posteriori* [Lee, 1997]. Il est bien entendu possible d'aller plus loin et

d'introduire à un troisième niveau une estimation vraiment *a priori*, pour tomber sur un modèle plus pleinement Bayesien (Bayes empirical - Bayes estimator).

#### 4.4 PROBLÈMES RENCONTRÉS PAR CETTE APPROCHE

Si l'intervention de certains découpages paraît claire et sensée (par exemple la famille ou la classe), car on sait par ailleurs combien le comportement individuel peut être influencé par ces groupes, l'utilisation d'autres découpages peut être moins évidente. En premier lieu, si l'on fait intervenir un grand nombre de niveaux d'agrégation, ce qui est en théorie tout à fait possible, on risque d'avoir des redondances entre certains de ces niveaux. Par exemple, si l'on utilise un découpage administratif, on peut se demander si le découpage communal (36000 environ en France) et le découpage cantonal (3000 environ en France) ne risquent pas de faire double emploi. L'utilisation de l'analyse multiniveau devrait apporter une réponse à ces questions, car les aléas correspondant à un niveau d'agrégation peuvent disparaître lorsque l'on en fait intervenir un autre qui prend correctement en compte ces aléas. De plus certains découpages peuvent être parfaitement pertinents pour étudier un phénomène donné et ne plus l'être pour un autre. Ainsi le découpage en régions, que nous avons utilisé en Norvège, est évidemment pertinent pour une analyse des migrations interrégionales. En revanche pour étudier les migrations à un niveau géographique plus fin, il peut se révéler sans intérêt.

Une étude très poussée des divers niveaux d'agrégation utilisables est dès lors nécessaire, pour avancer dans ce domaine, et cela pour chaque type d'étude. Également, il serait utile de voir si des regroupements de zones permettraient sans perte d'information d'obtenir des résultats aussi pertinents qu'avec un plus grand nombre. C'est tout un travail de reconnaissance de la validité des découpages existants, de création de nouveaux découpages plus pertinents, qui reste entièrement à faire.

D'un autre côté, cette analyse, qui cherche à expliquer les comportements individuels à l'aide de caractéristiques à la fois individuelles et agrégées, peut manquer l'explication de l'évolution des règles qui prévalent à des niveaux d'agrégation supérieurs. Il faut bien voir que ces règles sont le résultat d'une transmission entre individus d'un même groupe de comportements voisins, à un moment donné, mais qui peuvent évoluer avec le temps. C'est donc un double problème qu'il faut analyser celui de l'évolution de ces groupes au cours du temps et celui des changements des divers comportements.

Comment se forment les groupes pertinents, qu'est-ce qui permet leur maintien ou qui amène leur disparition et qu'est-ce qui explique leur évolution ? Autant de questions auxquelles il faut apporter une réponse et qui sont encore peu explorées. Bien sûr il existe des études sur la formation et la disparition de grandes cultures du passé, mais l'analyse de la cohésion et de l'évolution de groupes plus restreints est encore peu développée. Cette recherche doit être poursuivie pour pouvoir fonder plus solidement l'analyse multiniveau.

L'autre problème est de voir comment se forment, se modifient et disparaissent certains comportements. Cette genèse des comportements sociaux est encore peu étudiée. Ainsi, dans nos pays développés au cours des années 1960, l'apparition et l'extension de

la cohabitation à la place du mariage n'ont guère encore trouvé d'explication pleinement satisfaisante. Il s'agit sans doute d'un comportement mieux adapté que le mariage traditionnel aux conditions du moment et qui a pu se diffuser dans ces divers pays. Il importerait de voir comment des actions individuelles isolées, dans une communauté donnée, peuvent amener la prise de conscience d'un problème, qui affecte l'ensemble de la collectivité, et y apporter une solution convenable. Ensuite de voir comment ces nouveaux comportements se diffusent et peuvent conduire à des mesures politiques (PACS, par exemple), prises à un niveau plus agrégé. Bien entendu ces mesures vont affecter les conduites individuelles, amener de nouvelles actions pour contrebalancer leurs effets pervers, et ainsi de suite.

Ne faut-il pas, enfin, essayer de tenir mieux compte de la structure sociale des groupes considérés? Les modèles multiniveaux font, en effet, intervenir une corrélation entre comportements des membres d'un groupe donné, mais cette corrélation s'applique indifféremment à chaque couple d'individus de ce groupe. Il serait utile dans certains groupes, généralement d'effectif restreint, de tenir compte des interactions qui peuvent exister entre certains membres, par exemple les conjoints d'une famille. Des «Indoèles de chocs peuvent faire intervenir de telles interactions. Il reste cependant encore de nombreuses difficultés à lever avant que ces modèles soient pleinement utilisables [Lelièvre et al., 1997].

#### 5. CONCLUSION

Au terme de cet article, il est possible de répondre avec plus de précision à la question posée dans son titre évolution ou révolutions dans la pensée démographique? Les diverses étapes distinguées permettent de voir qu'elles sont chacune issues de problèmes rencontrés lors de l'application du paradigme antérieur et qu'elles introduisent bien une remise en cause de l'ensemble des croyances précédentes, sur lesquelles s'appuyaient les chercheurs. Voyons ce qu'il en est pour chacun de ces passages.

Le premier passage d'une analyse transversale à une analyse longitudinale a conduit à repenser la prise en compte du temps en démographie pour passer du temps impersonnel de l'histoire au temps personnel d'une génération. Ces deux temporalités semblent incompatibles l'une avec l'autre et conduisent à deux approches démographiques *a priori* inconciliables entre elles. Cependant il s'agit dans les deux cas d'un holisme, car les événements sont considérés comme des faits sociaux indépendants des êtres humains qui les connaissent. Ceux-ci sont produits par des acteurs sociaux supra-individuels, telles les institutions, les organisations, etc.

Le second passage d'une analyse longitudinale à une analyse biographique, conduit à considérer la démographie non plus comme un holisme mais comme un individualisme méthodologique. Ce sont maintenant les actions, attitudes, relations, etc., des individus qui vont déterminer les comportements démographiques observés. En revanche le temps considéré est comme en analyse longitudinale un temps personnel, mais est débarrassé des conditions d'homogénéité des populations observées et d'indépendance des phénomènes

démographiques qui s'y déroulent. Elle permet dès lors une analyse plus précise des comportements humains.

Le troisième passage d'une analyse biographique à une analyse multiniveau conduit à dépasser l'opposition entre holisme et individualisme, en abandonnant l'opposition entre le tout et les parties et en introduisant une hiérarchie entre les niveaux. Cette nouvelle approche permet une synthèse des trois approches antérieures, tout en les dépassant. Parce qu'elle fait intervenir les caractéristiques agrégées, elle va expliquer les résultats obtenus avec un modèle du moment cependant il ne s'agira plus d'une probabilité constante sur l'ensemble du territoire, mais au contraire d'une probabilité variable avec la région considérée. Parce qu'elle fait intervenir les caractéristiques individuelles, elle va donner des résultats comparables à ce que l'on obtenait avec un modèle biographique. Parce qu'elle permet de prendre mieux en compte la diversité des comportements à divers niveaux d'agrégation, elle fournit une solution aux problèmes posés en analyse longitudinale, où la désagrégation des catégories et des lieux conduit rapidement à une impossibilité d'analyse. Enfin elle permet de faire intervenir des temps multiples dans l'analyse, fournissant une solution au problème des temporalités incompatibles entre elles.

Bien entendu nous avons indiqué qu'il restait encore de nombreux problèmes à résoudre pour rendre cette approche pleinement utilisable. Pour répondre correctement à ces nouvelles questions, il est nécessaire de mettre en place une théorie plus complète des comportements humains ses bases épistémologiques, ses méthodes de mesure et d'analyse restent encore largement à établir. Cette théorie devrait permettre d'aborder simultanément l'étude sur divers niveaux d'agrégation, sans en privilégier certains, et de fournir un cadre explicatif pour l'ensemble des phénomènes étudiés en sciences sociales. L'avenir pourra nous révéler la richesse d'une telle théorie ou la nécessité de la rendre encore plus complexe pour être plus proche de la réalité.

#### **BIBLIOGRAPHIE**

ANDERSEN P., BORGAN O., GILL R., KEIDING N., Statistical models based on counting processes, New York, Springer-Verlag, 1993.

BAYES T.R., « An essay towards solving a problem in the doctrines of chance », *Phil. Trans. Roy. Soc. London*, 53, 1763, p. 370-418.

BLAYO C., « La condition d'homogénéité en analyse démographique et en analyse statistique des biographies », *Population*, 50, n° 6, 1995, p. 1501-1518.

BOUDON R., Effets pervers et ordre social, Paris, Presses Universitaires de France, 1977.

BRÉMAUD P., JACOD J., « Processus ponctuels et martingales⊡résultats récents sur la modélisation et le filtrage », *Advanced Applied Probabilities*, 9, 1977, p. 362-416.

BRETAGNOLE J., HUBER-CAROL C., « Effects of omitting covariates in Cox's model for survival data », *Scandinavian Journal of Statistics*, n° 15, 1988, p. 125-138.

COURGEAU D., « Analyse de données biographiques erronées », *Population*, 46, n°□, 1991, p.□9-104.

COURGEAU D., « Individus et contextes dans l'analyse des comportements selon l'approche multiniveau », *Démographie* analyse et synthèse, Caselli, Vallin, Wunsch (eds.), Éditions de l'INED, 2001, p. 519-536.

COURGEAU D. ed., *Methodology and epistemology of multilevel analysis*, Collection *Methodos*, Dordrecht, Kluwer Academic Publishers, [à paraître en 2003].

COURGEAU D., BACCAÏNI B., « Analyse multi-niveaux en sciences sociales », *Population, Nouvelles approches méthodologiques en sciences sociales*, Courgeau (ed.), 52, n° 4, 1997, p. 831-864.

COURGEAU D., LELIÈVRE E., Analyse démographique des biographies, Paris, Éditions de l'INED, 1989.

COURGEAU D., LELIÈVRE E., « Changement de paradigme en démographie⊠, *Population*, 51, n° 2, 1996, p. 645-654.

DELLACHERIE C., « Un survol de l'intégrale stochastique D., Stochastic Processes Applications, 10, 1980, p. 115-144.

DELLACHERIE C., MEYER P.A., Probabilités et potentiels⊡théorie des martingales, Paris, Hermann, 1980.

DEPARCIEUX A., Essai sur les probabilités de la durée de la vie humaine, Paris, Guérin frères, 1746.

DURKHEIM E., *Le suicide*, 1897, Paris, Nouvelle édition Presses Universitaires de France, 1930.

DURKHEIM E., Les règles de la méthode sociologique, 1895, Paris, Nouvelle édition Presses Universitaires de France, 1937.

GOLDSTEIN H., Multilevel statistical models, London, Arnold, 1995.

GRAUNT J., *Natural and political observations upon the bills of mortality... of the city of London*, London, The Roycroft, 1662. *Observations naturelles et politiques*, translated by Vilquin E., Paris, INED, 1977.

GREENLAND S., « Principles of multilevel modelling », *International Journal of Epidemiology*, 29, 2001, p. 158-167.

HALLEY E., « An estimate of the degrees of the mortality of mankind drawn from curious tables of the births and funerals at the city of Breslaw », *Philosophical Transactions*, XVII, 1693, p. 596-610.

HENRY L., « D'un problème fondamental d'analyse démographique », *Population*, 13, n° 1, 1959, p. 9-32.

HENRY L., « Analyse et mesure des phénomènes démographiques par cohorte », *Population*, 20, n° 3, 1966, p. 465-482.

HENRY L., Démographie⊡Analyse et modèles, Paris, Larousse, 1972.

HOEM J., « Weighting, misclassification and other issues in the analysis of survey samples of life histories », *Longitudinal analysis of labour market data*, Heckman and Singer (eds.), Cambridge, Cambridge University Press, 1985, p. 249-293.

KUHN T.S., La structure des révolutions scientifiques, Paris, Flammarion, 1983.

LANDRY A., Traité de démographie, Paris, Payot, 1945.

LAZARSFELD P.-F., MENZEL H., « On the relation between individual and collective properties », *Complex organizations*, Etzioni (ed.), New York, Holt, Reinhart, and Winston, 1961, p. 422-440.

LEE P.M., Bayesian statistics. An introduction, Second edition, London, Arnold, 1997.

LELIÈVRE E., BONVALET C., BRY X., « Analyse biographique des groupes. Les avancées d'une recherche en cours », *Population, Nouvelles approches méthodologiques en sciences sociales*, Courgeau (ed.), 52, n° 4, 1997, p. 803-830.

MASON W.M., WONG G.W., ENTWISTLE B., « Contextual analysis through the multilevel linear model », *Sociological Methodology 1983-1984*, San Francisco, Leinhart S., Jossey-Bass, 1983, p. 72-103.

POULAIN M., RIANDEY B., FIRDION J.-M., « Enquête biographique et registre belge de population⊡une confrontation des données », *Population*, 46, n° 1, 1991, p. 65-88.

PRESSAT R., Principes d'analyse, Paris, Éditions de l'INED, 1966.

ROBINSON W.S., « Ecological correlations and the behavior of individuals », *American Sociological Review*, 15, 1950, p. 351-357.

ROUSSEL L., « La nuptialité en France. Précocité et intensité suivant les régions et les catégories socio-professionnelles », *Population*, 26, n° 6, 1971, p. 1029-1056.