

RESEARCH OUTPUTS / RÉSULTATS DE RECHERCHE

Big Data: de nouveaux outils à combiner aux savoirs établis et à encadrer par la délibération publique

Rouvroy, Antoinette

Published in:
Statistique et Société

Publication date:
2014

Document Version
le PDF de l'éditeur

[Link to publication](#)

Citation for published version (HARVARD):

Rouvroy, A 2014, 'Big Data: de nouveaux outils à combiner aux savoirs établis et à encadrer par la délibération publique', *Statistique et Société*, vol. 2, numéro 4, pp. 33-41. <http://publications-sfds.fr/index.php/stat_soc/article/view/397/376>

General rights


Copyright and moral rights for the publications made accessible in the public portal are retained by the authors and/or other copyright owners and it is a condition of accessing publications that users recognise and abide by the legal requirements associated with these rights.

- Users may download and print one copy of any publication from the public portal for the purpose of private study or research.
- You may not further distribute the material or use it for any profit-making activity or commercial gain
- You may freely distribute the URL identifying the publication in the public portal ?

Take down policy

If you believe that this document breaches copyright please contact us providing details, and we will remove access to the work immediately and investigate your claim.

BigData : de nouveaux outils à combiner aux savoirs établis et à encadrer par la délibération publique



Entretien avec Antoinette ROUVROY

Chercheuse en Philosophie du Droit au Fonds National de la Recherche Scientifique (Belgique), rattachée au Centre de recherche Droit, Information, Société, Université de Namur

A la différence de la statistique classique qui repose sur des conventions et sur des hypothèses, les algorithmes qui fouillent les mégadonnées en font surgir sans médiation apparente des corrélations qui suggèrent en « temps réel » (sur le mode de l'alerte, de la recommandation, de l'aide à la décision), des actions immédiatement exécutables. Ces algorithmes sont la source de multiples profilages, qui délimitent les opportunités de chacun, à la place de normes communes. Porteuse de services étendus et personnalisés, aussi bien que de découvertes scientifiques, la révolution numérique est aussi un risque pour tout ce qui ne se laisse pas réduire à la rationalité économique, et notamment pour la justice sociale et pour la délibération collective. Les individus entrent presque tous dans le jeu, en permettant l'exploitation de leurs « traces », parce que les architectures de choix ne leur laissent voir que les côtés positifs de leur consentement. Plutôt que vers un renforcement de leur pouvoir sur leurs données personnelles, c'est vers un contrôle public des systèmes de décision susceptibles d'affecter les personnes qu'il faudrait se diriger, à travers la loi ou grâce à des codes de déontologie professionnelle

Statistique & Société : Votre réflexion envisage les BigData à la fois comme une nouvelle source de savoir et comme une nouvelle source de pouvoir – la fameuse « gouvernamentalité algorithmique ». Nous allons aborder ces deux aspects successivement, si vous le voulez bien. D'abord, en quoi l'exploitation des mégadonnées est-elle pour vous différente de la mise en œuvre traditionnelle des outils de la statistique ?

Antoinette Rouvroy : Pour moi, *BigData* signifie surtout le franchissement d'un seuil à partir duquel nous serions contraints (par la quantité, la complexité, la rapidité de prolifération des données) d'adopter une rationalité purement statistique, inductive, se bornant à repérer des patterns, c'est-à-dire des *motifs* formés par les corrélations observées entre des données numériques, indépendamment de toute explication causale. La répétition de ces « motifs » au sein de grandes quantités de données leur conférerait une valeur prédictive. Ainsi voit-on apparaître, grâce à la *visualisation* algorithmique des relations subtiles entre les données, un tout nouveau type de « savoir », exploitable dans une multitude de domaines. L'« intelligence » des algorithmes consiste en leur capacité à traiter statistiquement ces quantités massives,

complexes (textes, images, sons, localisations, trajectoires,...), relativement peu structurées, de données dans un temps record, pour en faire surgir non pas des relations causales explicatives mais des corrélations statistiquement significatives entre des éléments *a priori* sans rapport.

S&S : C'est donc très différent de la démarche classique adoptée par la statistique publique ?

AR : Lorsqu'on compare les pratiques statistiques nourries par les BigData aux statistiques classiques, on constate une série de glissements, tant du point de vue des finalités que du point de vue des pratiques et techniques impliquées.

L'une des finalités classiques des statistiques est l'*objectivation*, la confirmation d'hypothèses posées *a priori*, alors que les nouvelles pratiques statistiques impliquées dans le traitement des BigData visent précisément à dispenser d'avoir à poser des hypothèses *a priori*, et de *découvrir* celles-ci directement dans les mégadonnées par la grâce d'algorithmes capables d'y détecter des corrélations statistiquement significatives. Une autre des finalités classiques des statistiques est la *quantification* : elle consiste à rendre commensurables ou comparables entre eux, en les exprimant sous une forme chiffrée, des éléments de réalité hétérogènes. Ainsi, le *benchmarking des chercheurs* permet-il de comparer entre elles les performances de chercheurs spécialisés dans des domaines de recherche très différents. De telles opérations de *benchmarking* présupposent une série de conventions d'équivalence – toujours imparfaites, controversées -, établies à l'issue de discussions parfois longues entre représentants des disciplines concernées. En aval, elles permettent, ou obligent, suivant l'évaluation positive ou négative que l'on peut faire de ces systèmes, à utiliser, pour évaluer les mérites des uns et des autres, un langage commun, qui est celui des chiffres. Les pratiques statistiques nourries par les BigData s'écartent également de cette finalité d'organisation de la commensurabilité : le *datamining* ne vise pas à établir de commensurabilité qui permette la discussion, mais, prenant au sérieux l'incommensurabilité irréductible des situations, dispense d'avoir à discuter en faisant surgir des mégadonnées elles-mêmes, automatiquement et si possible en temps réel, les patterns, profils ou catégories les plus opérationnels en fonction des finalités (de gestion des ressources humaines, de sécurité, de marketing, etc.). Avec les BigData, nous ne sommes plus dans le monde un peu lent et conflictuel des conventions de quantification ouvertes sur l'espace public : le *datamining* s'inscrit dans un système d'immanence totale, dans lequel la collecte des données n'est plus orientée ni limitée par aucun système de catégories conventionnelles antécédentes ; on a supprimé la couche d'intermédiation que constituait la catégorie statistique et instauré, du même coup, un régime d'indistinction entre la réalité et sa représentation.

Enfin, dans la statistique classique, l'idée que l'on ne prend pas en compte la totalité des données disponibles est très importante. On *sélectionne* les données sur lesquelles on veut travailler, alors que les ambitions dominantes des promoteurs d'applications nourries par les BigData reposent sur l'idéal d'une coextension de la base statistique au réel (numérisé) lui-même. Dans le contexte des pratiques statistiques classiques la sélection consiste aussi à ne pas tenir compte des points trop éloignés de la « moyenne » ou de la « normale », à les considérer comme sources d'erreurs et de perturbations, à les considérer comme du « bruit » à exclure de la base statistique. L'ambition des applications nourries par les BigData est d'éviter cette sélectivité et ainsi, véritablement, *d'épuiser tout le possible* en tenant compte des cas les plus singuliers, les plus éloignés de la « moyenne » ou de la « normale ». A la différence des objets statistiques plus classiques à propos desquels on peut toujours argumenter qu'ils ne sont pas *représentatifs* de la réalité, qu'ils accordent trop ou pas assez d'importance aux situations singulières, les modélisations algorithmiques nourries par les *BigData* ont l'air d'absorber tout ce qui n'était pas pris en compte par les statistiques classiques : les points trop éloignés de la moyenne (qui pouvaient faire dire que les statistiques, ça ne vaut que pour les grands nombres, pas pour les cas individuels), ce qui n'entrait pas « dans les cases », c'est-à-dire dans les catégories statistiques établies par convention... Dans le monde des BigData, on peut prendre en compte

tous les points, y compris les plus atypiques, et on peut justement chercher à analyser les comportements les plus rares : on s'émancipe de tout rapport à la moyenne et à la « normale ». Dès lors, la personnalisation automatique des interactions administratives, sécuritaires, commerciales etc. à l'échelle industrielle n'est plus un oxymore.

Les statisticiens devraient se tenir fermement aux règles de leur discipline

Souligner ces différences, ce n'est pas nier l'intérêt pour les statisticiens d'investir dans ces nouvelles données et ces nouvelles méthodes, bien au contraire. Il me paraît tout à fait évident que dans de nombreux domaines de la connaissance (génétique, épidémiologie, astronomie, climatologie, etc.), les BigData ont un extraordinaire potentiel de reconfiguration de la perception, avec tout ce que cette révolution de l'accès au "réel" peut ouvrir comme perspectives inédites ne fût-ce que parce qu'elle nous débarrasse partiellement du joug perceptuel imposé aux sens ordinaires (qui nous rend inévitablement "prisonniers" d'un point de vue toujours trop partial et d'une perspective toujours trop partielle).

Mais les dispositifs nourris par les BigData sont un mode particulier de production de « ce qui compte comme réel ».

Il s'agit donc de ne pas se laisser leurrer par les promesses « d'objectivité par la totalité et par l'automatisme » que certains profèrent, et d'être conscients de ce qu'ils risqueraient de perdre s'ils prenaient ces promesses pour argent comptant.

J'insiste particulièrement sur le caractère de convention sociale attaché aux définitions statistiques : selon Alain Desrosières, là résident à la fois la fragilité et la force, des statistiques. Les statisticiens devraient se tenir fermement aux règles de leur discipline, aux modes de vérification qui leur sont propres et qui n'ont pas à céder devant les classifications produites par les algorithmes de *datamining*. Si, en raison de leur origine conventionnelle, les objets statistiques servant de références dans les débats publics sont toujours suspects de répercuter et de « naturaliser » les biais, préjugés et normativités sociales dominantes, l'absence de convention présidant au profilage algorithmique ne garantit qu'une objectivité de façade qui naturalise de manière cette fois absolument invisible, les normativités sociales rendues indiscutables.

S&S : Comment la nouvelle rationalité de l'exploitation des BigData permet-elle de mettre en place de nouveaux moyens de gouverner les personnes ?

AR : En exploitant les *profils* induits par les corrélations, on peut détecter, sans avoir à les rencontrer ni à les interroger personnellement, ni même à les identifier précisément, les risques et opportunités dont sont porteuses les personnes. Les algorithmes produisent des catégorisations impersonnelles, évolutives en continu, en fonction des attitudes, des trajectoires, etc. Être profilé consiste à être appréhendé dans un réseau de formes « percées » qui ne peuvent jamais nous contenir totalement, mais qui tracent, en pointillés mobiles, nos trajectoires à venir. Être « profilé » de telle ou telle manière affecte les opportunités qui nous sont disponibles, et, ainsi, l'espace de possibilités qui nous définit : le gouvernement algorithmique ne s'intéresse pas tant à ce que nous avons fait et faisons, qu'à ce que nous aurions pu faire ou pourrions faire dans l'avenir, c'est à notre dimension « potentielle », « virtuelle » donc, qu'il s'adresse. La spécificité, ou la radicale nouveauté de la gouvernamentalité algorithmique tient notamment en ceci qu'elle affecte les individus en neutralisant (en privant d'effets disruptifs, sans pour autant les supprimer) leurs dimensions inactuelles (la dimension de la spontanéité, de la potentialité), sans pour autant les assujettir à aucune « norme » - à la différence de la discipline - ni mobiliser leurs capacités d'entendement et de volonté - à la différence de la loi.

L'exemple le plus connu est celui du marketing : si l'on en croit Eric Schmidt, directeur chez Google, bientôt la technologie deviendra tellement efficace qu'il deviendra très difficile pour les personnes de voir ou consommer quelque chose qui n'aurait pas été prévu pour elles. En sens inverse, aucune norme sociale – nous avons vu déjà que le monde des BigData s'était émancipé de tout rapport à la « normale » ou à la « moyenne » - n'impose ni ne suggère de limites à l'exploitation des possibilités de profit : une personne ayant des addictions, « droguée au chocolat » par exemple, se verra inviter à acheter indéfiniment le produit sans aucune autre limite que sa propre satiété. Il risque de devenir de plus en plus difficile de résister à la « manipulation digitale » : d'une part, le « temps réel » est un temps dans lequel les humains n'ont pas la possibilité de prendre du recul relativement à leurs propres pulsions (d'achat, par exemple), un temps dans lequel on fonctionne sur le mode de l'alerte et du réflexe, plutôt que sur le mode de la réflexivité ; d'autre part, chaque consommateur se retrouve seul face à la sollicitation, parce celle-ci est adaptée à ce qu'il a de singulier, excluant de ce fait toute possibilité de résister ensemble. Il en résulte que nous n'avons plus même à former ni à formuler par nous mêmes nos désirs : ceux-ci nous précèdent sous une forme adaptée à la fois à l'offre et à ce que chacun de nous a de plus singulier, de plus éloigné des grands nombres.

Autre exemple : un programme de financement de l'Union Européenne suscite des innovations techniques favorisant le maintien des personnes âgées à leur domicile. Avec les meilleures intentions du monde, les visionnaires du futur qui répondent à cet appel d'offres proposent d'équiper d'un très grand nombre de capteurs les appartements des personnes âgées, pour permettre d'intervenir face à toute forme d'évènement ou de comportement inattendu (une chute, une immobilité prolongée, des déplacements nocturnes, un défaut de prise d'un médicament,...). A aucun moment ces innovateurs, préoccupés de réduire toute incertitude, ne pensent qu'une certaine intimité peut être pour ces personnes indispensable, fût-ce au prix de leur sécurité. Il ne s'agit pas d'un simple pas supplémentaire dans le progrès technique. Ces appareils ne sont pas faits pour faire quelque chose à notre place : ce sont des appareils qui vont nous faire faire des choses, en vertu d'une notion de besoin détecté en temps réel à partir des enregistrements qui seront faits, et donc selon une normativité immanente qui fait l'économie de la volonté des personnes elles-mêmes, et de toute délibération autour de la nature de ces besoins.

S&S : On pourrait arriver à des situations extrêmes avec les objets connectés, comme dans le cas de ce bracelet mis au point par une société américaine, que l'on porterait en permanence pour diminuer le coût de son assurance automobile, si on accepte que soient ainsi mesurés les temps d'exercice physique et de sommeil...

AR : C'est un très bon exemple. En matière d'assurance, le profilage par des algorithmes peut permettre de former des groupes de plus en plus restreints, évolutifs, de manière à ajuster en permanence les primes demandées aux risques de sinistres : la logique actuarielle est alors poussée à l'extrême, au détriment des principes de mutualisation qui fondent l'assurance, et qui supposent qu'on accepte l'existence d'une part irréductible d'incertitude. Toute incertitude est vue comme un résidu à neutraliser par un raffinement de l'algorithme. Les catégories produites par le *datamining* ne sont pas nécessairement « justes » ni « équitables ». Elles le seraient si, par exemple, les notions de justice actuarielle (en fonction de laquelle toute distinction de traitement économiquement rationnelle serait actuariellement juste, chacun ayant à contribuer au fonctionnement de l'assurance en payant des primes ajustées à « son » risque, c'est-à-dire à la probabilité qu'il bénéficie, plus tard, de la compensation d'un dommage qui se serait réalisé) et de justice sociale se recouvraient parfaitement, ce qui n'est bien évidemment pas le cas. Une distinction de traitement qui exclurait par exemple systématiquement les personnes victimes de violences conjugales du bénéfice de l'assurance vie, quels que soient le sexe, l'origine sociale de ces personnes, sur base d'une attribution de profil de risque établi par une méthode inductive de *datamining*, pourrait bien être algorithmiquement et économiquement « rationnelle »,

actuariellement justifiée, et socialement injuste. On perçoit bien, en l'occurrence, le danger associé au déploiement d'un « régime de vérité » numérique impartial et opérationnel mais qui dispenserait de toute discussion politique, de toute décision collective, et de toute contestation relative aux critères de besoin, de mérite, de dangerosité, de capacités qui président aux catégorisations bureaucratique et/ou sécuritaire des individus et comportements. Notons en passant que l'individualisation « parfaite » des risques et opportunités signifierait tout aussi bien la fin de la raison d'être des assurances, dont le rôle premier n'est certainement pas d'individualiser la charge des risques mais au contraire, de constituer des « contrats sociaux » restreints entre des personnes, les assurés, qui, soumis à des risques comparables, s'engagent à prendre en charge collectivement les coups du sort qui s'abattraient sur certains d'entre eux. Le *datamining* permettrait le passage d'une société actuarielle à une société post-actuarielle.

L'alliance des visionnaires bienveillants et des commerçants intéressés

S&S : C'est donc ce que vous appelez « gouverner au moyen d'algorithmes », en visant spécifiquement les algorithmes qui à partir d'analyses de données comportementales ou autres proposent des actions qui n'ont plus qu'à être exécutées. Mais qui est là-dérrière ? Qui promeut ce genre d'algorithmes ?

AR : Je n'ai pas une théorie du complot, rassurez-vous ! Je constate une curieuse convergence, parmi les « promoteurs » d'une gouvernementalité algorithmique, entre des groupes d'opinions qui a priori semblent très éloignés, mais qui ne le sont pas tant que cela en réalité. D'une part, un courant « anarchiste pro-cybernétique » ou crypto-anarchiste voit dans les applications en réseaux la promesse d'une société sans État ni institutions – on rejoint l'idée de l'im-médiation, d'une sortie de la logique de la représentation. On pourrait penser, naïvement, que ce rêve d'immanence corresponde aux idéaux de la pensée critique héritée des années 1960-1970 (Gilles Deleuze, Félix Guattari, Michel Foucault,...) ; mais alors que cette pensée critique était véritablement une pensée du « virtuel », une pensée de l'ouverture au non numérisable, au non maîtrisable, ce à quoi nous assistons aujourd'hui avec cette modélisation du social à même le social numérisé, c'est à une clôture du numérique sur lui-même, à une neutralisation du possible. D'autre part, la gouvernementalité algorithmique s'inscrit parfaitement dans la continuité de la gouvernementalité néolibérale dont elle n'est en somme qu'un « perfectionnement ». Appuyés sur une forme d'« idéologie technique », ces gens conçoivent l'idéal d'une société qui se gouvernerait toute seule, en temps réel, l'a priori étant que les individus, une fois émancipés du joug des institutions, se trouveraient dans une situation de parfaite égalité en termes de moyens et de bien-être. La possibilité de modéliser le social sans intermédiation, en dehors des conventions imposées par des autorités de toutes natures, rejoint leurs rêves. Ils essaient de faire du « design utile », avec une réelle bienveillance, mais sans prendre garde qu'ils ont un certain point de vue qui n'est pas forcément celui des utilisateurs. Ils auraient intérêt à s'entourer d'anthropologues...ou de philosophes, qui pourraient leur rappeler les limites de l'idéologie technique, qui renvoie dans l'arrière-fond invisible les constructions techniques, et les visions du monde qui les sous-tendent, et qui propose à la place une « interprétation globale du réel censée valoir par elle-même, comme si le réel lui-même parlait... »¹. D'autre part, les promoteurs habituels d'une gouvernance mondiale de type néolibérale se retrouvent très bien dans le projet d'une gouvernementalité algorithmique destituant l'État et l'espace de délibération publique. Très prosaïquement, les grandes sociétés multinationales ont bien vu qu'avec les systèmes fondés sur des algorithmes, toute distinction de traitement des individus qui serait économiquement justifiée devient automatiquement légitime : l'émancipation de toute norme libère de toute contrainte, de tout scrupule, les objectifs de maximisation des profits. Ainsi des enthousiasmes très libertariens s'articulent à des intérêts qui font peu de cas de la liberté !

1. Pierre Macherey, « Idéologie : le mot, l'idée, la chose. Langue, discours, idéologie, sujet, sens : de Thomas Herbert à Michel Pêcheux », 17/01/2007, <http://stl.recherche.univ.lille3.fr/seminaires/philosophie/macherey/macherey20062007/macherey17012007.html>

S&S : Alors, selon vous, il faut rejeter tout en bloc ?

AR : Ce n'est certainement pas ce que je dis. Je vois de nombreux domaines scientifiques comme l'astronomie, l'épidémiologie, la climatologie, la génétique, etc. dans lesquels les BigData vont permettre de faire des découvertes inattendues, et très intéressantes, surtout si on sait les combiner aux savoirs établis et aux théories existantes. Et bien sûr, de multiples applications utiles sont à la portée des BigData en aval de ces découvertes.

En revanche, quand il s'agit d'interventions dans la vie des personnes et dans la vie sociale, j'essaie d'attirer l'attention sur les risques de cette nouvelle forme de « gouvernementalité » pour la justice sociale et pour la délibération publique, les deux étant bien entendu liés.

Le danger d'injustice sociale est démultiplié si les procédures mises en place excluent de fait les espaces de délibération publique. Les conclusions se présentent comme des « vérités numériques » impartiales et opérationnelles, qui dispenseraient de toute discussion politique, de toute décision collective, et de toute contestation relative aux critères de besoin, de mérite, de dangerosité, de capacités qui président aux catégorisations bureaucratique et/ou sécuritaire des individus et comportements.

S&S : En multipliant leurs « traces » numériques, et en permettant l'utilisation de ces données, les individus entrent massivement dans ce jeu. Pourquoi ne sont-ils pas plus méfiants ?

AR : En ce qui concerne les données à caractère personnel (dont on sait qu'elles ne sont pas absolument nécessaires aux opérations de profilage des personnes, qui peuvent très bien être réalisées en n'utilisant que des données anonymes, des métadonnées, etc.), le succès des règles de conservation des données par défaut ou, pour le dire autrement, le manque de succès des options permettant de déroger à cette règle de conservation des données tient, si l'on en croit Cass R. Sunstein, se fondant sur l'économie comportementale, à la combinaison de trois facteurs principaux : 1) Le premier facteur est l'inertie des comportements dès lors qu'effacer « ses traces » demande un effort dont on ne sait au juste s'il vaut vraiment la peine, étant donné que chacune des données émanant de nos activités en ligne nous paraît à nous-mêmes, *a priori* (indépendamment des opérations de recoupement, de croisement, de modélisation auxquelles elles pourraient contribuer), de peu d'importance. La règle par défaut, quand bien même nous avons la possibilité d'y déroger très facilement « en quelques clics » prévaudra toujours lorsque l'enjeu ponctuel, actuel, n'apparaît pas significatif aux yeux de l'internaute. 2) Le second facteur favorisant la règle de conservation par défaut consiste en ceci que, dans une situation d'incertitude quant à la marche à suivre, l'utilisateur moyen aura tendance à considérer que la règle par défaut, puisqu'elle a été pensée par d'autres que lui, réputés plus experts et puisqu'elle est probablement suivie par la plupart des autres personnes, est sans doute la meilleure option pour lui aussi. 3) Enfin, le troisième facteur consiste dans le fait que les individus soient généralement plus sensibles au *risque de perdre* un avantage dont ils ont ou croient avoir la jouissance en se maintenant dans la situation dans laquelle ils se trouvent qu'à *l'opportunité de gagner* quelque chose en changeant. C'est une variante du phénomène d'inertie mais à travers laquelle les concepteurs, les « designers », les « marketeurs » peuvent avoir une prise sur les individus : ils peuvent réduire la probabilité que les utilisateurs s'écartent de la règle par défaut dans l'ajustement des « règles de confidentialité » en évoquant tout ce qu'ils ont à perdre dans la mesure où la rétention des « traces numériques » est ce qui permet de leur offrir un service plus personnalisé, plus adapté à leurs besoins en temps réel en fonction du lieu où ils se trouvent, ou de leurs goûts, un service plus rapide et efficace, et que l'effacement leur fera perdre tous ces avantages suffira généralement à éviter que l'utilisateur ne s'écarte de la règle par défaut.

Superviser les architectures de choix

S&S : Que suggérez-vous ?

AR : Cette question des « architectures de choix » - qui affectent le consentement des personnes à la conservation de « leurs » données, mais aussi leurs propensions à « faire confiance » aux recommandations d'achat automatisées qui leur sont envoyées, ou à se fier aux « rankings » de Google pour évaluer la pertinence et la valeur des contenus informationnels fournis par le moteur de recherche - est très importante : ce sont elles qui conditionnent en partie la capacité des personnes à intervenir de façon réfléchie et non pas de façon réflexe. Une supervision éthique et juridique des architectures de choix spécifiques aux plateformes est à mettre en place, qui soit fondée sur une typologie fine des acteurs et de leurs intérêts, suivant que ces intérêts sont plus ou moins alignés sur les intérêts des « utilisateurs » : un hôpital ne devrait pas être traité de la même façon qu'un commerçant. Il s'agirait de ménager la possibilité de processus de vérification et de justification, donc de mises à l'épreuve des productions des catégorisations émanant des BigData en tenant compte de la nature des intérêts en jeu. Suivant une typologie fine des acteurs et surtout de leurs intérêts, il est possible de distinguer les situations dans lesquelles les acteurs – ceux qui exploitent les données d'une part, et ceux que l'on appelle parfois un peu abusivement les utilisateurs (consommateurs, citoyens,... qui sont aussi, en partie, les producteurs des données) – ont des intérêts alignés et les situations où c'est l'inverse. Exemples : l'hôpital et les patients ont, en principe, même si ce n'est pas toujours complètement le cas, des intérêts alignés, c'est-à-dire convergents vers la guérison, bonne pour le patient, pour la réputation de l'hôpital, etc. alors qu'une compagnie d'aviation et les voyageurs peuvent avoir des intérêts désalignés, la compagnie souhaitant faire payer les voyageurs le plus cher possible tout en restant concurrentiels, et les voyageurs ayant, eux, intérêt à payer le moins cher possible. Le « profilage » peut jouer soit dans l'intérêt des deux parties, soit dans l'intérêt de l'une d'entre elles seulement, au détriment de l'autre. Ainsi la classification des patients dans certains « profils » thérapeutiques est dans l'intérêt tant de l'hôpital que du patient, alors que le profilage des voyageurs dans un certain « profil » en fonction de leur prédisposition à vouloir payer un certain prix pour un certain voyage (la « personnalisation » ou le profilage algorithmique permettent d'ajuster les prix en fonction de la disposition à payer [willingness to pay] de chaque client ; au plus le client aura « besoin » de voyager à telle date rapprochée, au plus cher sera son billet), est le plus souvent défavorable au voyageur (la somme qu'il aura à déboursier pour voyager étant adaptée à l'élasticité de sa disposition à acheter un billet en fonction d'une évolution des prix). En fonction, donc, des applications, et des intérêts en jeu, il importe, afin de protéger la « partie faible » (celle qui subit, généralement, une asymétrie d'information, n'étant pas au courant des logiques de traitement de données qui président aux décisions qui l'affectent et ne se sachant pas « profilée »), de veiller à assurer des possibilités de contester les productions algorithmiques (« catégorisations » ou « profilages »).

En ce qui concerne les algorithmes eux-mêmes, je ne crois absolument pas à la possibilité de les rendre « transparents », comme certains le proposent aujourd'hui. A la technicité des processus algorithmiques et aux perspectives de dispositifs auto-apprenants les rendant difficilement intelligibles pour le commun des mortels s'ajoutent les obstacles juridiques imposés par le secret industriel ou le secret-défense. Mais je crois au recours à la loi, et aux codes de déontologie. Le projet de nouveau règlement européen sur la protection des données contient un article, déjà présent dans la directive de 1995 et dans la loi française de 1978, qui stipule que :

«Toute personne a le droit de ne pas être soumise à une mesure produisant des effets juridiques à son égard ou l'affectant de manière significative prise sur le seul fondement d'un traitement automatisé destiné à évaluer certains aspects

personnels propres à cette personne physique ou à analyser ou prévoir en particulier le rendement professionnel de celle-ci, sa situation économique, sa localisation, son état de santé, ses préférences personnelles, sa fiabilité ou son comportement (...) »

Au-delà de la loi, je crois possible de persuader les acteurs du domaine de l'intérêt qu'ils ont à se doter de codes professionnels pour encadrer leurs pratiques. Ils ont accès à des possibilités de manipulation de l'intellect des gens ! Certains des « grands principes » formant l'ossature des régimes juridiques de protection des données à caractère personnel pourraient rester très inspirants moyennant une série d'adaptations (dans le contexte des BigData, nous n'avons plus affaire que minimalement à des données à caractère personnel, les données ne servant plus tant à identifier qu'à catégoriser, etc.). Je pense notamment au principe de loyauté de la collecte des données qui pourrait contribuer à discipliner certaines pratiques de « smarter marketing » qui, au lieu de s'appuyer sur les capacités d'entendement et de volonté des consommateurs, capitalisent au contraire sur les faiblesses de leur volonté et de leur entendement, détectées en temps réel, de manière à les faire passer à l'acte d'achat sans qu'ils aient eu l'occasion de même comprendre leurs propres motivations, ou encore à des pratiques de marketing qui n'ont pas pour but de vendre quoi que ce soit mais seulement de recueillir davantage d'informations sur les consommateurs de manière à mieux les profiler. Je parle ici de marketing et cela paraît trivial, mais on peut imaginer que ces mêmes techniques soient utilisées à des fins d'individualisation de la communication électorale, par exemple, ou à des fins de conditionnement des enfants à la surconsommation dès le plus jeune âge. L'enjeu, c'est notre intégrité mentale.

S&S : Si l'on vous suit bien, ce n'est pas la protection des données à caractère personnel qui est le point fondamental ?

AR : Nous n'avons appris à nous méfier que des traitements automatisés de données à caractère personnel : or celles-ci n'interviennent que marginalement dans les phénomènes qui nous intéressent ici. Une sorte de fétichisation de la donnée personnelle – renforcée par le droit positif actuel – nous fait passer à côté de ce qui fait aujourd'hui problème. Les nouvelles formes de pouvoir qui s'exercent sur les individus passent beaucoup moins par les traitements de données à caractère personnel et l'identification des individus que par des catégorisations impersonnelles, évolutives en continu, des opportunités et des risques, c'est-à-dire des formes de vie (attitudes, trajectoires,...). Un profil, ce n'est en réalité personne – personne n'y correspond totalement, et aucun profil ne vise qu'une seule personne, identifiée ou identifiable. Ce n'est pas le risque d'identification qui est le plus dangereux, c'est le risque de catégorisation, sans outil de critique des catégories et de récalcitrance par rapport à elles. Et donc, ce n'est pas « plus de privé » qu'il nous faut, c'est au contraire « plus d'espace public ».

S&S : Finalement, est-ce qu'on n'est pas un peu dans une « Querelle des Anciens et des Modernes » ? Que devrions-nous dire aux jeunes générations, de statisticiens, ou simplement de citoyens ?

AR : Je l'ai déjà dit : je ne suis pas une adversaire des BigData, j'en perçois très bien les avantages en termes d'avancement de la connaissance scientifique et en termes de nouveaux services utiles. Mais j'en perçois les dangers, d'autant plus marqués que nous vivons actuellement dans une sorte de « bulle spéculative » à propos des BigData. J'aimerais faire partager cette vision équilibrée.

Aux statisticiens je dirais : engagez-vous dans ce mouvement, mais conservez vos principes professionnels et la lucidité de vos prédécesseurs sur l'insertion sociale de leur discipline et sur son rôle dans la constitution d'un espace public de délibération.

Pour le reste, j'ai bon espoir, et je me réjouis du débat qui s'instaure en France notamment à propos des possibilités et des risques des BigData. En ces temps de crise de la représentation et

d'assèchement de l'espace public, ces débats sont une occasion pour repenser collectivement des questions essentielles. Quelle partie de nos fonctions cognitives voulons-nous déléguer à des algorithmes ? Dans quel rythme temporel voulons-nous vivre ? Quelle place voulons-nous faire à la mémoire des tentatives, de l'ineffectué (seules les choses effectuées laissent des traces numériques, rejetant dans l'oubli les projets trop tôt abandonnés, les utopies non tentées par nos prédécesseurs, mais qui sont autant de sources d'inspiration pour l'avenir) ? Et surtout, comment ménager encore l'espace de l'événement, de l'imprévisibilité toujours renouvelée, et donc de la liberté ?

