

Statistique et société
décembre 2018

Volume 6, Numéro 3

À propos de l'Intelligence Artificielle

Sommaire

Statistique et société

Volume 6, Numéro 3

7 **Éditorial**

Emmanuel DIDIER

Rédacteur en chef de Statistique et société

Dossier : A propos de l'intelligence artificielle

9 **L'IA du Quotidien peut elle être Éthique ?**

Philippe BESSE

Professeur de Statistique, Université de Toulouse et INSA, Institut de Mathématiques

Céline CASTETS-RENARD

Professeure de Droit, Université Toulouse Capitole, Institut de Recherche en Droit Européen, International et Comparé, Membre de l'Institut Universitaire de France

Aurélien GARIVIER

Professeur de Statistique, Ecole Normale Supérieure de Lyon, Unité de Mathématiques pures et appliquées

Jean-Michel LOUBES

Professeur de Statistique, Université de Toulouse Paul Sabatier, Institut de Mathématiques

33 **Recension**

Les Big Data à découvert

Ouvrage collaboratif pluridisciplinaire

Recension de l'ouvrage réalisée par

Jean-Christophe Thalabard, Univ. Paris-Descartes

39 **La politique des petits nombres : Comment appréhender l'histoire de la statistique vaccinale et de ses effets ?**

Gaëtan THOMAS

Docteur de l'EHESS

Sommaire

Statistique et société

Volume 6, Numéro 3

- 45 **Fichiers de population sous l'Occupation**
Gerard LANG
Statisticien retraité, SFdS

Statistique et société

Magazine quadrimestriel publié par la Société française de statistique. Le but de Statistique et société est de montrer d'une manière attrayante et qui invite à la réflexion l'utilisation pratique de la statistique dans tous les domaines de la vie, et de montrer comment l'usage de la statistique intervient dans la société pour y jouer un rôle souvent inaperçu de transformation, et est en retour influencé par elle. Un autre dessein de Statistique et société est d'informer ses lecteurs avec un souci pédagogique à propos d'applications innovantes, de développements théoriques importants, de problèmes actuels affectant les statisticiens, et d'évolutions dans les rôles joués par les statisticiens et l'usage de statistiques dans la vie de la société.

Rédaction

Rédacteur en chef : **Emmanuel Didier**, CNRS, France

Rédacteurs en chef adjoints :

Jean-Jacques Droesbeke, Université Libre de Bruxelles, Belgique

Chloé Friguet, Université de Bretagne-Sud, France

Jean-Christophe Thalabard, Université Paris-Descartes, pôle de recherche et d'enseignement supérieur Sorbonne Paris Cité, France

Comité éditorial

Représentants des groupes spécialisés de la SFdS :

Ahmadou Alioum, groupe Biopharmacie et santé

Alain Godinot, groupe Statistique et enjeux publics

Delphine Grancher, groupe Environnement et Statistique

Marthe-Aline Jutand, groupe Enseignement de la Statistique

Elisabeth Morand, groupe Enquêtes, Modèles et Applications

Alberto Pasanisi, groupe Agro-Industrie

Autres membres :

Jean Pierre Beaud, Département de Science politique, UQAM, Canada

Corine Eyraud, Département de sociologie, Université d'Aix en Provence, France

Michael Greenacre, Department of Economics and Business, Pompeu Fabra
Université de Barcelone, Espagne

François Heinderyckx, Département des sciences de l'information, Université
Libre de Bruxelles, Belgique

Dirk Jacobs, Département de sociologie, Université Libre de Bruxelles, Belgique

Gaël de Peretti, INSEE, France

Theodore Porter, Département d'histoire, UCLA, États-Unis

Carla Saglietti, INSEE, France

Patrick Simon, INED, France

Design graphique
fastboil.net

ISSN 2269-0271



Emmanuel DIDIER

Rédacteur en chef de Statistique et Société

Cher Lecteur,

Voici, avec un peu de retard, la dernière livraison de l'année 2018 de notre revue. Elle comprend pour commencer une contribution fouillée dont le premier auteur est Philippe Besse portant sur le cadre éthique de l'Intelligence artificielle et aboutissant à une série de propositions. Cet article fait suite à une intervention qui a eu lieu dans le cadre d'une journée thématique de la SFdS de mars 2018. Il vient particulièrement à point dans un monde où, face à des usages parfois décriés, de plus en plus d'utilisateurs se penchent sur les limites juridiques et éthiques de l'intelligence artificielle. Vient ensuite la recension, écrite par Jean-Christophe Thalabard, d'un livre ayant pour ambition de cartographier les divers utilisateurs et utilisations des Big Data – et donc de l'IA – en France.

Ensuite, nous nous réjouissons de publier une contribution de Gaëtan Thomas, lauréat du Prix Alain Desrosières pour l'année 2018, récompensé pour un chapitre de sa thèse portant sur l'histoire de la vaccination en France. Son texte montre l'importance des travaux de son auguste prédécesseur et de la prise en compte de la quantification comme acteur social pour la compréhension du développement de la vaccination dans notre pays. Pour finir, nous présentons la deuxième partie de la réflexion de Gérard Lang, ancien administrateur de l'INSEE, commencée dans un numéro précédent sur l'histoire du « numéro de sécu ». Il approfondit ici, avec une précision d'orfèvre et qui contredit certains préjugés, l'histoire du fameux « fichier juif », pendant la Seconde Guerre mondiale.

Bonne lecture,

Emmanuel Didier

ARTICLE DU DOSSIER

L'IA du quotidien peut-elle être éthique ?

Loyauté des Algorithmes
d'Apprentissage Automatique



Philippe BESSE

Professeur de Statistique,
Université de Toulouse et INSA,
Institut de Mathématiques

Céline CASTETS-RENARD

Professeure de Droit, Université Toulouse Capitole, Institut de Recherche en Droit
Européen, International et Comparé, Membre de l'Institut Universitaire de France

Aurélien GARIVIER

Professeur de Statistique, Ecole Normale Supérieure de Lyon,
Unité de Mathématiques pures et appliquées

Jean-Michel LOUBES

Professeur de Statistique, Université de Toulouse Paul Sabatier,
Institut de Mathématiques

Associant données massives (*big data*) et algorithmes d'apprentissage automatique (*machine learning*), la puissance des outils de décision automatique suscite autant d'espoir que de craintes. De nombreux textes législatifs européens (RGPD) et français récemment promulgués tentent d'encadrer les usages de ces outils. Laissant de côté les problèmes bien identifiés de confidentialité des données et ceux d'entrave à la concurrence, nous nous focalisons sur les risques de discrimination, les problèmes de transparence et ceux de qualité des décisions algorithmiques. La mise en perspective détaillée des textes juridiques, face à la complexité et l'opacité des algorithmes d'apprentissage, révèle la nécessité d'importantes disruptions technologiques que ce soit pour détecter ou réduire le risque de discrimination ou pour répondre au droit à l'explication. La confiance des développeurs et surtout des usagers (citoyens, justiciables, clients) étant indispensable, les algorithmes exploitant des données personnelles se doivent d'être déployés dans un cadre éthique strict. En conclusion nous listons, pour répondre à cette nécessité, quelques possibilités de contrôle à développer : institutionnel, charte éthique, audit externe attaché à la délivrance d'un label.

1. Introduction

En 2017, la CNIL a initié un débat national sur le thème : « *Éthique numérique : les algorithmes en débats* » qui a donné lieu à la publication d'un rapport. Besse et al. (2017) y avait apporté leur

contribution dont cet article reprend et développe la section 4 pour continuer à faire avancer la réflexion sur le thème de la *loyauté des décisions algorithmiques*.

Mandatée par le gouvernement, une commission présidée par Cédric Villani a elle aussi publié un rapport dans l'objectif de « donner du sens à l'Intelligence artificielle » (IA). Comme le rapport de la CNIL, le rapport de la commission Villani consacre une large place aux questions éthiques soulevées par la généralisation de l'usage, au quotidien, d'algorithmes d'Intelligence Artificielle. La France n'est évidemment pas seule à se mobiliser sur cette question et les initiatives sont nombreuses dont celle du gouvernement britannique qui a publié un *cadre éthique des données*.

Il n'est pas question d'aborder l'ensemble des algorithmes du vaste champ disciplinaire de l'IA mais de se focaliser sur ceux conduisant à des décisions impactant les personnes au quotidien : accès à la banque, l'assurance, la santé, l'emploi, les applications en matière judiciaire ou de police... Plus précisément cela concerne les algorithmes dits d'apprentissage automatique (*machine learning*) entraînés sur de vastes ensembles de données à minimiser certains critères mathématiques ou plus précisément statistique comme un taux d'erreur moyen afin d'automatiser la production de décisions.

Schématiquement, les questions éthiques concernent principalement les problèmes de confidentialité des données à la base de l'apprentissage, d'entrave à la concurrence, de transparence ou *explicabilité* des décisions, de leurs risques de biais discriminatoires envers des individus ou groupes sensibles.

Avec le déploiement du RGPD (Règlement Général européen sur la Protection des Données n°2016/679/UE), la CNIL focalise son action sur son cœur de métier, c'est-à-dire plus précisément sur la protection des données personnelles en proposant aux entreprises concernées des outils de mesure à même d'évaluer les risques encourus en matière de confidentialité : le DPIA ou *data protection impact assessment*. Il appartient en effet aux entreprises d'être proactives sur ce sujet pour être en mesure de montrer, en cas de contrôle, qu'elles maîtrisent la sécurité des données personnelles dans toute la chaîne de traitement, de l'acquisition à la décision. La constatation de défaillances sera l'occasion de très lourdes sanctions financières : jusqu'à 20M€ et majorée pour une entreprise à 4 % du chiffre d'affaire annuel mondial (le plus élevé des deux chiffres devant être retenu).

De son côté, suite à l'adoption de la loi n° 1321-2016 pour une République numérique, qui tient notamment compte de quelques dispositions du RGPD, l'INRIA a proposé un projet de plateforme collaborative (*TransAlgo*) qui permettrait d'archiver des outils automatiques produits par cinq groupes de travail :

1. Moteurs de classement de l'information et systèmes de recommandation ;
2. Apprentissage : robustesse aux biais des données et des algorithmes, reproductibilité, explication et intelligibilité ;
3. Protection des données et contrôle d'usage des données ;
4. Métrologie des réseaux de communication ;
5. Influence, désinformation, impersonification (photos, voix, agent conversationnel), *nudging*, *fact-checking*.

Nous proposons dans cet article des éléments de réflexion et outils pour faire avancer le point 2 sur les risques de discrimination, ainsi que l'explicabilité, la répétabilité ou la qualité des décisions algorithmiques ou automatiques.

- *Discrimination* : La loi protège les individus et les groupes contre des pratiques discriminatoires, mais comment peut-elle être opposée à des algorithmes ? Comment

répondre à la demande du rapport Villani de création d'un DIA (*discrimination impact assessment*) pour caractériser la discrimination indirecte ou envers un groupe ?

- *Explicabilité* : L'analyse fine des textes juridiques montre que les obligations légales sont relativement peu contraignantes en matière de transparence des algorithmes. Néanmoins, l'acceptation de l'IA et de décisions automatiques impactant des personnes, requiert impérativement des éléments de transparence ; c'est dans ce cas le droit à *l'explication* d'une décision algorithmique. Quels peuvent en être les termes ?
- *Qualité* : la loi française, comme le RGPD, n'évoquent à aucun moment des notions de qualité ou risque d'erreur d'une décision automatique. Comme pour les sondages, il serait pertinent que la loi oblige à informer l'utilisateur des risques associés à l'exécution d'un algorithme d'apprentissage automatique. Quel en est le contexte ?

Comme le rappelle le rapport Villani, les thèmes de l'éthique ont investi l'espace entre ce que permettent les nouvelles technologies issues de l'IA et ce qui est permis par la loi ; il insiste en notant que le « temps du droit est bien plus long que celui du code ». Aussi, en l'absence de textes législatifs plus précis, alors que la notion de loyauté d'une plateforme est présente dans la loi pour une République numérique, les principes de loyauté des algorithmes deviennent des questions éthiques et juridiques, pas simplement par altruisme de la part des entreprises commerciales, mais pour le développement d'une confiance indispensable du grand public envers le déploiement de ces technologies. Appréhender les problèmes soulevés par la généralisation du compteur Linky, ceux liés à la mise en place de ParcoursSup ou encore les déboires en bourse de Facebook à la suite de l'affaire *Cambridge Analytica* en sont de bons exemples.

Il importe, en premier lieu, de pouvoir mieux définir comment des notions d'éthique peuvent se traduire en termes techniques. La section 2 suivante décrit plus précisément les algorithmes d'apprentissage statistique, branche de l'IA, concernés par cet article. La section 3 décrit le contexte juridique et les moyens disponibles pour un individu ou un groupe de se protéger en basant la définition d'une mesure d'impact disproportionné (*disparate impact*) de discrimination sur celle de la littérature et ses récents développements, notamment pour corriger un biais d'apprentissage. La section 4 aborde le droit à l'explication au regard des capacités techniques des modèles statistiques et algorithmes d'apprentissage très généralement utilisés. La section 5 rappelle comment sont estimés et minimisés des risques d'erreur ; les conséquences d'une erreur de 30 % ne sont pas les mêmes lorsqu'il s'agit de l'évaluation du risque de récidive d'un détenu ou de celle de l'intérêt d'un client de *Netflix* pour un film. Enfin, après avoir tenté de résumer une situation pour le moins complexe, nous concluons en évoquant les quelques possibilités de contrôle institutionnel, d'autocontrôle (charte éthique) ou encore de contrôle externe (audit) attaché à la délivrance d'un label.

2. Quelle IA ? Quels algorithmes ?

L'IA couvre un vaste champ disciplinaire et concernent donc de nombreux types d'algorithmes. Nous nous intéresserons plus particulièrement à ceux couramment mis en œuvre dans notre quotidien, conduisant à des décisions à fort impact et construites à partir de données personnelles. Il s'agit donc d'algorithmes dits d'*apprentissage automatique* (*machine learning*) d'une décision à partir d'un historique de situations connues ou observées sur un plus ou moins grand échantillon dit d'apprentissage ou d'entraînement. Parmi ceux-ci, laissons de côté les algorithmes par renforcement (cf. AlphaGo) ou séquentiels dont les applications concernent plus particulièrement le commerce en ligne (algorithmes de bandits) aux conséquences moins critiques. Nous allons donc nous focaliser sur un sous-ensemble, nommé *apprentissage statistique* des algorithmes d'apprentissage automatique.

2.1 Exemples d'utilisation

Le choix d'un traitement médical, d'une action commerciale, d'une action de maintenance préventive, d'accorder ou non un crédit, de surveiller plus particulièrement un individu... toutes les décisions qui en découlent sont la conséquence d'une prévision. La prévision du risque ou de la probabilité de diagnostic d'une maladie, le risque de rupture d'un contrat par un client qui est le score d'attrition (*churn*), le risque de défaillance d'un système mécanique, de défaut de paiement d'un client ou encore de radicalisation d'un individu... Les exemples sont très nombreux et envahissent notre quotidien. Ces prévisions de risques ou scores, par exemple de crédit, sont produits par des algorithmes d'*apprentissage statistique*, après entraînement sur une base de données.

2.2 Algorithmes d'apprentissage statistique

Dans les années 30 et notamment à la suite des travaux de Ronald Fisher, la Statistique a été développée avec une finalité principalement explicative pour un objectif d'aide à la décision. Par exemple : tester l'efficacité d'une molécule et donc d'un médicament, comparer le rendement de semences ou optimiser le choix d'un engrais, montrer l'influence d'un facteur (consommation de tabac, de sucre) sur des objectifs de santé publique. La prise de décision est alors la conséquence d'un test statistique permettant de contrôler le risque d'erreur encouru. Mais il se trouve que les mêmes modèles statistiques peuvent aussi être utilisés avec une finalité seulement prédictive : prévoir la concentration en ozone du lendemain, le risque de défaut de paiement d'une entreprise... De plus, ces modèles statistiques peuvent être suffisamment simples, (typiquement linéaires) pour être facilement *interprétables*.

Néanmoins, certaines situations, certains phénomènes, nécessitent des modèles, ou plus généralement des algorithmes, plus complexes pour être correctement approchés afin de conduire à des prévisions suffisamment fiables. Toutes les disciplines scientifiques : Statistique et aussi Mathématiques, Informatique, ont été mise à contribution depuis la fin des années 90 pour développer une farandole d'algorithmes avec une *finalité* essentiellement *prédictive* : arbres binaires de décision, k plus proches voisins, machines à vecteurs supports, réseaux de neurones puis apprentissage profond (*deep learning*), forêts aléatoires, *gradient boosting machine*... en sont quelques exemples. Il n'est plus question de tester l'influence d'un facteur ou l'efficacité d'un traitement ; seule compte la *qualité de la prévision*. La littérature est très vaste à ce sujet, consulter par exemple James et al. (2017) ou les vignettes pédagogiques du site wikistat.fr.

2.3 Principe de l'apprentissage statistique

Le principe des algorithmes d'apprentissage statistique repose sur le fait de pouvoir élaborer, à partir d'un ensemble d'exemples appelé échantillon d'apprentissage, une règle de décision qui va s'appliquer à tous les nouveaux cas rencontrés. A partir d'un grand nombre de données recueillies, contenant principalement des décisions qui ont déjà été prises et les variables qui expliquent ses décisions, les principes mathématiques permettent non seulement de comprendre comment ces décisions ont été prises mais également de dégager les règles qui président à ces choix.

La découverte de ces règles consiste concrètement à trouver des tendances (*patterns* ou *features*) dans les observations. Pour cet apprentissage il faut trouver, donc détecter dans les données, des comportements caractéristiques qui permettent de segmenter les individus en des groupes homogènes. Ainsi donc, en fonction de nos caractéristiques, notre profil type peut être défini par rapport aux autres individus déjà analysés et l'algorithme émettra une règle fixe en fonction de notre groupe d'appartenance ou par rapport à des similarités (ressemblances)

vis-à-vis des individus déjà étudiés. Le processus de découverte des comportements type est automatisé, sans contrôle *a posteriori*. Or c'est à partir de ces comportements types que se créent les modèles, se prennent les décisions et que sont prédits les événements à venir.

Plus précisément, les paramètres de modèles sont estimés ou des algorithmes sont *entraînés* sur des ensembles de données d'apprentissage (*training data sets*) et optimisés de sorte qu'ils minimisent une erreur de prévision ou erreur de généralisation. Cette erreur est très généralement estimée par le calcul d'une *moyenne statistique* c'est-à-dire par la moyenne, ou le taux moyen d'erreur, commis sur un *échantillon* test indépendant de l'échantillon d'apprentissage. Un algorithme d'apprentissage statistique s'adapte au mieux à des données historiques afin d'identifier les spécificités de données actuelles ou en cours d'acquisition ; il en déduit la prévision la plus adaptée sans possibilité de créativité : schématiquement, chercher la situation passée la plus ressemblante à la situation actuelle pour en déduire la prévision la plus fidèle.

2.4 Risques de l'apprentissage statistique

Il est important de noter que l'échantillon d'apprentissage doit être d'autant plus volumineux que l'algorithme est complexe au sens du nombre de paramètres à estimer et participant à sa définition. Corrélativement, l'accroissement spectaculaire des capacités de calcul et d'archivage associé à l'explosion des volumes de données disponibles ont permis des avancées très significatives, dont celle de l'apprentissage profond (*deep learning*) depuis 2012, dans la qualité des algorithmes d'apprentissage et donc des décisions qui en découlent. En ce sens, le succès actuel et le battage médiatique de l'apprentissage statistique et donc plus généralement de l'IA sont une conséquence directe de la *datafication* de notre quotidien qui vise à l'enregistrement et l'exploitation systématique de tous nos messages, recherches, achats, déplacements...

Ceci éclaire l'avènement du paradigme de l'ère du *Big Data*. Dans un raisonnement traditionnel cartésien, une théorie permet d'élaborer un modèle fruit d'une réflexion humaine. Puis ce modèle est confronté à la réalité au travers de données recueillies au cours d'expériences prévues pour confronter les données au modèle. Ainsi la théorie peut être clairement réfutée ou acceptée sur la base de faits. Le modèle peut alors être analysé d'un point de vue éthique ou moral, discuté même. Mais en apprentissage la création du modèle provient de l'étude des données, sans analyse *a posteriori*. On comprend dès lors qu'à partir du moment où nous décidons de confier à l'algorithme un pouvoir décisionnel, il peut façonner la réalité pour être conforme à son modèle. Il fige pour ainsi dire la réalité sur la base de ce qu'il en a vu à travers le prisme de l'échantillon fourni à l'apprentissage, puis il reproduit le modèle à l'infini. Naturellement, le modèle n'évolue plus et vient ajuster la réalité à sa propre prédiction. Le comportement étant appris, la règle de prédiction peut alors clairement être exprimée : terminée la place du hasard ou celle de la créativité, place à la répétabilité.

Souvent la confrontation des idées permet à chacun de préciser sa propre Vérité en prenant conscience de ses erreurs même si nous décidons de faire sciemment un mauvais choix. L'IA est autrement catégorique : la matrice algorithmique a pour but d'optimiser les décisions « justement ou froidement ». Naturellement la morale ou l'équité de ce jugement n'est pas prédéfinie mais dépend d'une part, de la manière avec laquelle sont apprises les règles (le critère objectif qui a été choisi) et d'autre part, de la manière avec laquelle a été constitué l'échantillon d'apprentissage. Le choix des règles mathématiques permettant de créer le modèle est primordial.

Se pose alors une question délicate : Comment définir ou par quelles caractéristiques « mesurables » traduire des notions de loyauté, confiance, responsabilité (*fairness, trustworthiness, accountability*), appliquées à de telles décisions algorithmiques lorsqu'elles sont la conséquence

ou le résultat d'une prévision ?

La réponse se décline en trois points.

- elle doit éviter tout biais *discriminatoire* vis-à-vis de minorités et groupes sensibles protégés par la loi.
- Même statistique ou probabiliste, cette décision doit pouvoir être *attribuée* à un humain qui en assume la responsabilité. Il doit pouvoir en *rendre compte* et donc, pouvoir *l'expliquer* de façon compréhensible (e.g. médecin à son patient).
- Elle doit être la plus *juste* au sens de l'intérêt de la personne concernée et / ou globalement de la communauté, donc issue d'une *meilleure prévision*.

Reprenons et détaillons ces trois points.

3. Biais et discrimination

La [partie 5 du rapport Villani](#) consacrée aux questions éthiques laisse une large place aux risques annoncés de pratiques discriminatoires des algorithmes reproduisant, voire renforçant, les biais de société. Cette section va s'attacher à rappeler les notions de discrimination, individuelle et collectives dans le but de poser les bases successives de :

- la mesure de biais discriminatoire afin
- de construire les outils de leur détection,
- et même de leur possible correction.

3.1 Cadre juridique

Selon l'article 225-1 du code pénal : « Constitue une discrimination toute distinction opérée entre les personnes physiques sur le fondement de leur origine, de leur sexe, de leur situation de famille, de leur grossesse, de leur apparence physique, de la particulière vulnérabilité résultant de leur situation économique, apparente ou connue de son auteur, de leur patronyme, de leur lieu de résidence, de leur état de santé, de leur perte d'autonomie, de leur handicap, de leurs caractéristiques génétiques, de leurs mœurs, de leur orientation sexuelle, de leur identité de genre, de leur âge, de leurs opinions politiques, de leurs activités syndicales, de leur capacité à s'exprimer dans une langue autre que le français, de leur appartenance ou de leur non-appartenance, vraie ou supposée, à une ethnie, une Nation, une prétendue race ou une religion déterminée. »

Concernant les groupes, l'alinéa 2, art. 1^{er} de la loi n°2008-496 du 27 mai 2008 portant diverses dispositions d'adaptation au droit communautaire dans le domaine de la lutte contre les discriminations prévoit : "Constitue une discrimination indirecte une disposition, un critère ou une pratique neutre en apparence, mais susceptible d'entraîner, pour l'un des motifs mentionnés au premier alinéa (critères de la discrimination que l'on retrouve aussi dans le code pénal), un désavantage particulier pour des personnes par rapport à d'autres personnes, à moins que cette disposition, ce critère ou cette pratique ne soit objectivement justifié par un but légitime et que les moyens pour réaliser ce but ne soient nécessaires et appropriés.

Apparaît aussi la notion de discrimination systémique¹ qui serait : un processus qui met en jeu un système d'acteurs dans lequel personne ne manifeste pas directement d'intention discriminatoire, mais dont le résultat sera de produire une situation de discrimination. Les discriminations systémiques ne sont pas intentionnelles, elles proviennent de la somme de plusieurs représentations qui, cumulées, forment un contexte discriminant. Ce concept découle de la reconnaissance de l'existence de déséquilibres socioéconomiques ou d'inégalités sociales qui sont historiquement constitués : Les discriminations systémiques sont donc constituées

1. Au sens du Dictionnaire des Dominations (collectif dressehian, 2012).

par les processus qui produisent et reproduisent les places sociales inégalitaires en fonction de l'appartenance à une « classe », une « race » ou un « sexe », cette appartenance pouvant être réelle ou supposée.

L'article 225-2 ajoute que : « La discrimination définie aux articles 225-1 à 225-1-2, commise à l'égard d'une personne physique ou morale, est punie de trois ans d'emprisonnement et de 45 000 euros d'amende lorsqu'elle consiste à :

1. refuser la fourniture d'un bien ou d'un service ;
2. entraver l'exercice normal d'une activité économique quelconque ;
3. refuser d'embaucher, à sanctionner ou à licencier une personne ».

La loi française insiste plus particulièrement sur une approche individuelle de la notion du risque de discrimination même si la notion de discrimination envers un groupe ou *discrimination indirecte* y est citée. La définition ou caractérisation de cette dernière n'est pas explicitée dans la loi tandis que le rapport Villani insiste sur la nécessité de définir un outil d'évaluation afin d'en faciliter la preuve et en permettre la sanction. Il évoque le *Discrimination Impact Assessment* (DIA) en complément du *Data Protection Impact Assessment* (DPIA) prévu par le RGPD et qui protège les données personnelles des individus et non des groupes. Ce n'est pas du tout évoqué dans le rapport Villani mais il existe une littérature abondante sur ce sujet sous l'appellation de *disparate impact* (impact disproportionné) depuis les années soixante-dix aux USA.

De son côté, le règlement européen encadre strictement la collecte de données personnelles sensibles (orientation religieuse, politique, sexuelle, origine ethnique, ...) et interdit aux responsables de décisions algorithmiques de les prendre en compte dans les traitements automatisés (art. 22§4), sous réserve du consentement explicite de la personne ou d'un intérêt public substantiel. Par opposition à discriminatoire, une décision est dite loyale si elle ne se base pas sur l'appartenance d'une personne à une minorité protégée ou la connaissance explicite ou implicite d'une donnée personnelle sensible.

Ce point est sans doute le plus difficile à clarifier. En effet, il ne suffit pas que la variable « sensible » soit inconnue ou supprimée des données d'apprentissage pour que la décision soit sans biais vis-à-vis de ses modalités. L'information sensible peut être contenue implicitement, même sans intention de la rechercher, dans les informations non sensibles et ainsi participer au biais de la décision. Des habitudes de consommation, des avis sur les réseaux sociaux, des données de géolocalisation... renseignent sur les orientations de la personne et peuvent permettre de reconstituer implicitement des données sensibles.

Les questions posées et difficultés rencontrées lors de la construction d'algorithmes avec un objectif de loyauté sont directement liées aux conditions d'apprentissage des décisions. En effet, comme il a été vu dans la section 2 précédente, l'apprentissage est le reflet de la base des données d'entraînement. En conséquence :

- si les données sont elles-mêmes biaisées, pas représentatives de la population,
- si un biais structurel est de toute façon présent dans la population,

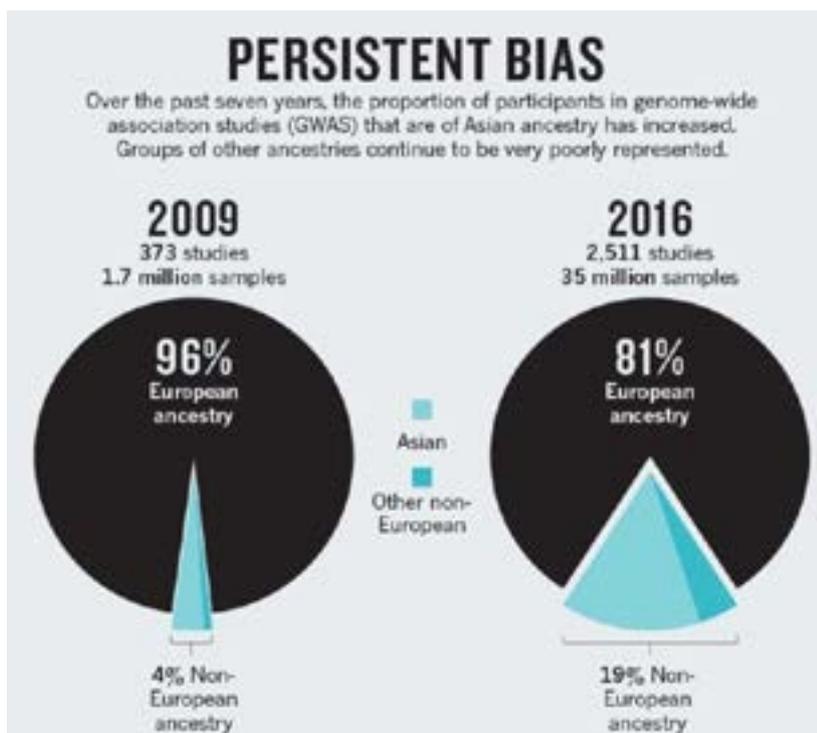
alors ceci est la source d'une *rupture d'équité*.

La décision reproduit voire même peut renforcer le biais, donc la discrimination. Plus dangereux encore, la décision devient une prévision auto-révélatrice. Une estimation (trop) élevée d'un risque de crédit génère un taux, donc des remboursements, plus élevés qui renforcent le risque de défaut de paiement. Un risque trop élevé de récidive retarde une mise en liberté, accroît la désocialisation et renforce *in fine* le risque de récidive. O'Neil (2016) développe en détail la perversité des effets de bord de ce type d'outils. Il faut noter que les algorithmes de classification ont pour objectif de séparer la population en sous-groupes. Ainsi si cette séparation pré-existe dans les données, l'algorithme apprendra et amplifiera cette dissimilitude et peut dès lors

introduire une discrimination de traitement dans les données.

La figure 1 illustre un exemple sévère de biais des bases de données pangénomiques (*genome-wide association study, GWA study, ou GWAS*). Ces bases archivent les analyses des variations génétiques (*singular nucleotid polymorphisms* ou SNPs) chez de nombreux individus, afin d'étudier leurs corrélations avec des traits phénotypiques, par exemple des maladies. Elles sont la première brique pour la recherche de thérapies personnalisées.

Figure 1 : Panpejoy et Fullerton (2016) : Biais de composition des échantillons des études d'associations pangénomiques (GWAS).



D'un point de vue ethnique, le problème est que la grande majorité des bases GWAS ont été constituées sur des populations d'ascendance blanche/européenne (cf. Figure 1, Popejoy et Fullerton, 2016). Les facteurs de risque estimés par des modèles statistiques classiques (régression logistique) ou par des algorithmes d'apprentissage automatique seront donc très probablement beaucoup moins précis pour un patient d'ascendance africaine ou asiatique. Autrement dit, ceux-ci n'ont actuellement rien à attendre d'une médecine personnalisée basée sur des considérations génomiques.

3.2 Discrimination individuelle

Apporter la preuve d'une discrimination individuelle est particulièrement difficile pour la personne concernée, à moins d'accepter l'utilisation de procédés probatoires en principe interdits car considérés comme déloyaux. Il s'agit de dispositifs de type « *testing* » : *test de situation* ou *test de discrimination*, qui sont à la fois des moyens d'investigation et une forme d'expérimentation sociale en situation réelle, destinés à déceler une situation de discrimination. Cette dernière peut notamment porter sur des données sensibles comme l'origine ethnique, le handicap, le sexe, l'orientation sexuelle, la religion, l'adhésion syndicale. Ce type de test ne respecte pas le principe de la loyauté de la preuve, mais il est le moyen le plus efficace, voire souvent le seul, de prouver la discrimination. Dans le cas le plus simple, il s'agit de comparer le comportement d'un tiers envers deux personnes ayant exactement le même profil pour toutes les caractéristiques pertinentes, à l'exception de celle que l'on soupçonne de donner

lieu à discrimination. Naturellement, lorsque la discrimination ne repose pas sur une seule ou même plusieurs données sensibles, mais est le résultat de croisement de données permettant indirectement la discrimination, il faut pouvoir appréhender les résultats avec toute leur complexité.

Cette méthode, utilisée par les associations comme SOS racisme, est reconnue par les juridictions françaises, dans la mesure où, bien que considérée comme une pratique déloyale, elle ne peut être écartée comme moyen de recherche de la preuve depuis un arrêt de la Cour de Cassation rendu en juin 2002 dans l'affaire du Pym's de Tours. La solution a été par la suite consacrée à l'article 225-3-1 du code pénal selon lequel : « *Les délits prévus par la présente section sont constitués même s'ils sont commis à l'encontre d'une ou plusieurs personnes ayant sollicité l'un des biens, actes, services ou contrats mentionnés à l'article 225-2 dans le but de démontrer l'existence du comportement discriminatoire, dès lors que la preuve de ce comportement est établie* ».

Le principe est donc simple. Dans le cas par exemple d'une procédure d'embauche, il suffit d'adresser deux CV identiques à des moments différents pour répondre à des offres d'emploi. Les CV qui ne diffèrent alors que par le nom, révélateur de l'origine des candidats potentiels, ou le genre, l'âge. Pour être valide, le CV et la candidature doivent être sincères, seul le CV concurrent est modifié en conséquence. Plusieurs organismes ou laboratoires pratiquent ces opérations : citons l'[Observatoire des Discriminations](#), le laboratoire TEPP de l'Université Marne la Vallée (L'Horty et al., 2017) ou encore la [DARES](#) (Direction de l'Animation, des Études, de la Recherche et des Statistiques) du Ministère du travail en lien avec l'association [ISM Corum](#).

Dans un autre ordre d'idée, Galhotra et al. (2017) définissent le biais d'une décision en incluant une notion de causalité. Le logiciel afférent ([Themis](#)) opère un test automatique de la possible discrimination opérée par des logiciels. Cette dernière idée peut être reprise ou plutôt simplifiée pour être appliquée aux décisions d'un algorithme pour en évaluer les risques de discriminations individuelles. Il suffit de reconsidérer un échantillon test en échangeant les deux modalités de la variable sensible ; par exemple le genre ou l'origine ethnique. L'algorithme est alors à nouveau appliqué à cet échantillon test modifié, afin d'identifier les individus pour lesquels la décision à changer, par exemple devenu plus favorable, à l'issue du seul changement de genre, d'âge ou d'origine ethnique. Même si le nombre trouvé est faible, pas statistiquement significatif, ces personnes sont clairement discriminées ; l'algorithme est source d'une sur-discrimination déloyale par rapport à des biais possibles sur l'échantillon. Ils sont potentiellement des risques de conflits juridiques coûteux pour l'entreprise.

Attention, la variable sensible doit être connue. Ce n'est évidemment pas toujours le cas et c'est un problème car supprimer la variable sensible d'un modèle n'évite pas nécessairement une décision discriminatoire mais empêche d'en identifier simplement le biais. L'autre difficulté est qu'il s'agit en plus d'apporter la preuve de *l'intention discriminatoire*. Or, s'agissant d'une discrimination par un traitement algorithmique, la discrimination n'est pas forcément le fruit d'une intentionnalité.

3.3 Discrimination de groupe

La première difficulté repose dans le choix d'une mesure de discrimination, alors que la littérature propose beaucoup d'indicateurs statistiques pour mesurer le biais d'une décision (positive ou négative), vis-à-vis de personnes appartenant ou non à un groupe, généralement une minorité protégée par la loi. Un type de mesure individuelle s'intéresse au voisinage au sens des k plus proches voisins d'un individu afin de détecter une situation atypique. Néanmoins, cet individu peut être entouré de ceux appartenant au même groupe protégé et tous ne bénéficiant pas à tort d'une décision positive. Il est plus informatif de considérer une mesure collective ou statistique de la discrimination basée sur une table de contingence (tableau 1) croisant deux

variables : la *variable sensible* d'appartenance à un groupe protégé (Oui ou Non) par la loi, et l'obtention d'une décision Positive (crédit, emploi, bourse...) ou Négative.

Tableau 1. Table de contingence entre appartenance au groupe et nature de la décision.
Proportions associées : $p_1=a/n_1$, $p_2=c/n_2$, $p=m_1/n$

Groupe protégé	Décision		Marge
	Positive	Négative	
Oui	a	b	$n_1=a+b$
Non	c	d	$n_2=c+d$
Marge	m_1	m_2	$n=n_1+n_2$

Des mesures simples de discrimination sont définies à partir de cette table (Pedreschi et al., 2012) :

- Différence de risque : $DR=p_1-p_2$,
- Risque relatif : $RR=p_1/p_2$,
- Chance relative : $CR=(1-p_1)/(1-p_2)$,
- Rapport de cote (*odds ratio*) : RR/CR .

Mais beaucoup d'autres mesures sont proposées. Consulter par exemple Žliobaitė (2015) : différences de moyennes, de coefficients de régression, tests de rangs, information mutuelle, comparaison de prévisions. Le problème est qu'il y a finalement beaucoup (trop) de définitions techniques ou statistiques possibles de la discrimination mais sans aucune base légale connue à ce jour pour en justifier le choix.

3.4 Impact disproportionné

Nous choisissons par la suite de nous intéresser plus particulièrement à la définition usuelle largement répandue de disparate impact. Celui-ci est défini comme le rapport de deux probabilités :

$$DI = \frac{P(Y=1|S=0)}{P(Y=1|S=1)}$$

C'est le rapport de la probabilité que la décision soit positive ($Y=1$) sachant que le groupe est protégé ($S=0$) sur la probabilité que la décision soit positive ($Y=1$) sachant que le groupe n'est pas celui protégé ($S=1$). Il est estimé par le risque relatif (RR) défini à l'aide de la table de contingence (tableau 1 ci-dessus).

Feldman et al. (2015) fournissent quelques éléments historiques² de la première utilisation de ce critère par la justice de l'état de Californie et qui date de 1971. Utilisation qui a motivé de très nombreux articles dans les revues juridiques notamment à propos du mode opératoire qui consiste à comparer la valeur obtenue à un seuil fixé empiriquement à 0,8. En deçà de 0,8, l'impact est jugé suffisamment disproportionné pour être révélateur d'une discrimination. Néanmoins, si l'entreprise apporte la preuve que les choix de recrutement sont basés sur des critères nécessaires aux intérêts économiques de l'entreprise, la discrimination n'est pas attestée.

En résumé, une évaluation du DI permet, aux USA, de révéler des situations trop

2. Consulter également la [page afférente](#) du site Wikipedia en anglais.

disproportionnées au détriment d'un groupe sensible ou protégé. Cela ouvre la possibilité de détecter voire condamner une situation de discrimination de groupe.

L'estimation du DI soulève une autre question d'ordre statistique comme soulignée par Peresie (2009). Faut-il comparer par un test statistique l'égalité des termes du DI afin d'introduire une part d'incertitude ou simplement comparer le DI à la valeur seuil de 0,8 ? Ces deux stratégies pouvant conduire à des résultats contradictoires. De plus, le test d'égalité est basé sur une hypothèse de normalité peu judicieuse. Pour éviter ces difficultés, Besse et al. (2018) proposent une estimation du DI par intervalle de confiance incluant un contrôle statistique du risque d'erreur mais sans faire appel à une hypothèse de normalité. La distribution asymptotique exacte est obtenue en application du théorème de la limite centrale et de la linéarisation des critères de loyauté.

Malheureusement l'évaluation ou la caractérisation d'une discrimination envers un groupe ne peut se limiter à la seule évaluation du DI. Ainsi, les algorithmes de reconnaissance faciales sont régulièrement accusés de racisme mais sur le fondement d'un autre critère, celui de l'erreur de reconnaissance. Vraisemblablement à cause de bases d'apprentissage elle-même biaisées c'est-à-dire dans lesquelles certaines catégories, notamment les femmes d'ascendance africaine, sont largement sous-représentées. En conséquence, les taux d'erreur sont de l'ordre de 30 % au lieu de 1 % pour un homme d'ascendance européenne.

De plus même si le DI est limité et les taux d'erreur identiques pour les catégories de la variable sensible, une autre source de discrimination peut se dissimuler dans les dissymétries des matrices de confusion d'un algorithme ou prédicateur. C'est le point de vue de l'outil utilisé par Google et rendu accessible sur la plateforme [What-If Tool](#). La mesure de discrimination adoptée est alors l'*égalité d'opportunité* d'un algorithme d'apprentissage décrite par Hardt et al. (2016). Besse et al. (2018) proposent également une estimation par intervalle de confiance de cette mesure de discrimination nommée dans d'autres références : *égalité des précisions conditionnelles*.

3.5 Exemple : le risque de récidive COMPAS

Cette approche est très bien illustrée par la controverse entre le site *ProPublica* (prix Pulitzer 2011) et l'ex-société *Northpointe*, maintenant *Equivant*. Cette société, dans une démarche de « justice prédictive » commercialise l'application *COMPAS* (*Correctional Offender Management Profile for Alternative Sanction*) qui produit un score ou risque de récidive pour les détenus ou accusés lors d'un procès. *ProPublica* accuse ce score d'être biaisé et donc raciste. Cette controverse a suscité de très nombreux articles venant renforcer une bibliographie déjà présente sur le sujet depuis une vingtaine d'années. Ces études mettent en évidence des contradictions rédhibitoires entre les critères proposés. Résumons la controverse.

Le score est estimé sur la base d'un questionnaire détaillé et à partir d'un modèle de durée de vie (modèle de Cox). La qualité de ce score est optimisée, mesurée, par le coefficient AUC (aire sous la courbe ROC) approximativement autour de 0.7, valeur plutôt faible correspondant aux taux d'erreurs élevés observés, de 30 à 40 %. La société *Northpointe* défend la loyauté de ce score en assurant que

- les distributions de ses valeurs (donc les taux de sélection) sont analogues selon l'origine (afro-américaine vs. caucasienne) des accusés ; le DI n'est pas significatif.
- le taux d'erreur sur la prévision d'une récidive (matrice de confusion) qui en découle est analogue selon l'origine, autour de 30 ou 40 % ; l'argumentaire retenu pour la reconnaissance faciale n'est pas recevable.

De leur côté Angwin et al. (2016) du site *ProPublica* dénoncent un biais du score *COMPAS* en

étudiant une cohorte de détenus libérés pour lesquels sont connus le score de récidive selon *COMPAS*, ainsi que l'observation, ou non, d'une arrestation sur une période de deux ans. Ils montrent alors que le *taux de faux positifs* : score *COMPAS* élevé mais sans récidive observée, est *beaucoup plus importants* pour les libérés d'origine afro-américaine que pour ceux d'origine caucasienne. Comme ce score *COMPAS* est utilisé pour éventuellement des remises en liberté conditionnelles, un détenu d'origine africaine a plus de malchance de rester plus longtemps emprisonné avec le risque de renforcer sa désocialisation donc finalement son risque de récidive.

Pour expliquer l'impasse de cette controverse, Chouldechova (2017) montre que, sous les contraintes de « loyauté » contrôlées par *Northpointe* et sachant que le taux de récidive des afro-américains est effectivement plus élevé, alors, nécessairement, les taux de faux positifs / négatifs ne peuvent être que déséquilibrés au détriment des afro-américains et c'est d'autant plus manifeste que le taux d'erreur (40 %) est élevé.

La question qui se pose ou qui aurait dû être posée en préalable concerne la qualité de cette prévision. Sous l'apparente objectivité d'un algorithme se cache un taux d'erreur qui discrédite largement le produit *COMPAS*. Dressel et Farid (2018) ont par ailleurs montré qu'un ensemble de personnes sans expertise judiciaire et interrogées sur le web aboutissent à des prévisions aussi (peu) fiables, de même qu'un simple modèle linéaire impliquant seulement deux variables.

3.6 Réparation des données pour favoriser des algorithmes loyaux.

Pour détecter la non loyauté des algorithmes, nous avons vu qu'il est possible de calculer de nombreux critères, chacun mettant en évidence un type de différence de traitement entre divers sous-groupes de la population. Il peut s'agir d'un déséquilibre entre la proportion de bonnes prédictions en fonction de chaque sous-groupe ou d'une différence de répartition d'erreur ou d'autres critères qui témoignent d'une relation de dépendance entre la décision apprise et la variable qui caractérise la variable sensible et qui divise la population en deux sous-groupes. Ainsi la notion de loyauté totale doit être caractérisée par l'indépendance entre ces deux lois de probabilités (del Barrio et al., 2018b). Plus la liaison est importante, plus l'effet discriminant sera marqué. Ce formalisme a amené différents auteurs à proposer plusieurs manières de remédier à cette rupture d'équité soit en changeant la règle de décision, soit en changeant l'échantillon d'apprentissage. Modifier la règle revient à imposer à l'algorithme de ne pas sur apprendre cette liaison en imposant un terme favorisant l'absence de lien entre la prédiction et la variable dite sensible (Zafar et al., 2017). Modifier l'échantillon revient à favoriser l'indépendance entre les données et la variable sensible afin de garantir que tout algorithme utilisant ces données comme base d'apprentissage ne puisse pas reproduire un biais par rapport à la variable sensible. Pour cela, il est nécessaire de modifier les lois conditionnelles par rapport à la variable sensible et de les rendre les plus similaires possible sans perdre trop d'information qui pourrait nuire au pouvoir prédictif du modèle. Cette solution décrite dans Feldman et al. (2015), a été étudiée par del Barrio et al. (2018a). Obtenir la non-discrimination représente néanmoins un prix à payer : construire une règle moins prédictive par rapport à l'échantillon d'apprentissage. Le statisticien doit donc contrôler à la fois l'erreur commise par la règle de prédiction ainsi que la non-discrimination souhaitée.

4. Explicabilité d'une décision

4.1 Lois et enjeux du droit à l'explication

Le rapport Villani appelle à « ouvrir les boîtes noires » de l'IA car une grande partie des questions éthiques soulevées tiennent de l'opacité de ces technologies. Compte tenu de leur

place grandissante, pour ne pas dire envahissante, le rapport considère qu'il s'agit d'un enjeu démocratique.

L'article 10 de la loi n° 78-17 relative à l'informatique, aux fichiers et aux libertés du 6 janvier 1978 prévoyait à l'origine que « Aucune décision produisant des effets juridiques à l'égard d'une personne ne peut être prise sur le seul fondement d'un traitement automatisé de données destiné à définir le profil de l'intéressé ou à évaluer certains aspects de sa personnalité ». Autrement dit, une évaluation automatisée des caractéristiques d'une personne conduisant à une prise de décision ne peut être réalisée sur la seule base du traitement automatisé. Cela suppose donc que d'autres critères soient pris en compte ou encore que d'autres moyens soient utilisés. En particulier, les personnes concernées par la décision peuvent attendre que l'évaluation puisse être vérifiée par une intervention humaine. Si ce principe qui tend à contrôler les effets négatifs du profilage est consacré depuis longtemps, son énoncé n'a pu empêcher l'explosion de cette technique, parallèlement à l'émergence de la collecte massive des données sur internet. Beaucoup de techniques de profilage ont été développées, sans nécessairement prévoir des garde-fous techniques ou humains. Cette règle est donc peu respectée et sa violation n'a pour l'instant pas donné lieu à sanction.

Parallèlement, le RGPD, et avant lui la directive 95/46/CE, consacre un certain nombre de droits en cas de décision individuelle prise sur le fondement d'un traitement automatisé de données :

1. Le droit d'accès et d'être informé de l'existence d'une prise de décision automatisée (RGDP, art. 13-15h) ;
2. Le droit de ne pas faire l'objet d'un traitement automatisé produisant des effets juridiques ou affectant la personne concernée de manière significative (RGDP, art. 22§1) ;
3. Le droit d'obtenir une intervention humaine de la part du responsable du traitement (RGDP, art. 22§3) ;
4. Le droit d'exprimer son point de vue et de contester la décision (RGDP, art. 22§3) ;

Les données sensibles doivent en principe être exclues des traitements exclusivement automatisés (art. 22§4), sauf en cas de consentement explicite ou pour des raisons d'intérêt public.

Cependant, des exceptions sont aussi prévues (art. 22§2), lorsque la décision :

1. est nécessaire à la conclusion ou à l'exécution d'un contrat entre la personne concernée et un responsable du traitement ;
2. est autorisée par le droit de l'Union ou le droit de L'État membre auquel le responsable du traitement est soumis et qui prévoit également des mesures appropriées pour la sauvegarde des droits et libertés et des intérêts légitimes de la personne concernée ;
3. est fondée sur le consentement explicite de la personne concernée.

Cette série d'exceptions est loin d'être anodine et appauvrit substantiellement la règle. S'agissant des activités économiques du numérique, de nombreux traitements automatisés peuvent en effet se prévaloir d'un fondement contractuel, dès lors que l'utilisation par les internautes des services des sites de e-commerce ou plateformes de mise en relation, telles celles des réseaux sociaux, est de fait considérée comme une acceptation des conditions générales d'utilisation et manifestant l'acceptation de l'offre contractuelle. Par ailleurs, en dehors des activités du numériques, les hypothèses précédemment citées d'accès à un crédit, un logement, à des biens ou services, reposent le plus souvent sur la conclusion d'un contrat.

En outre, le point c) du paragraphe précédent prévoit l'hypothèse d'un consentement explicite de la personne concernée. Si un consentement peut effectivement être assez aisément recueilli en sa forme, on peut toutefois douter au fond de son caractère éclairé, tant

l'accessibilité intellectuelle aux procédés de traitement automatisé est douteuse à l'endroit des profanes composant la grande majorité des personnes concernées, spécialement lorsque ce consentement est recueilli en ligne.

Ces dispositions ont été intégrées au droit français avec l'adoption récente de la loi n° 2018-493 du 20 juin 2018 qui vient modifier la loi n° 78-17 dite informatique et libertés du 6 janvier 1978. L'article 21 modifie l'article 10 de la loi du 6 janvier 1978 afin d'étendre les cas dans lesquels, par exception, une décision produisant des effets juridiques à l'égard d'une personne ou l'affectant de manière significative peut être prise sur le seul fondement d'un traitement automatisé de données à caractère personnel. L'article 10 alinéa 1^{er} de la loi n° 78-17 dispose désormais que « *Aucune décision de justice impliquant une appréciation sur le comportement d'une personne ne peut avoir pour fondement un traitement automatisé de données à caractère personnel destiné à évaluer certains aspects de la personnalité de cette personne* ».

L'alinéa 2 ajoute que « *Aucune décision produisant des effets juridiques à l'égard d'une personne ou l'affectant de manière significative ne peut être prise sur le seul fondement d'un traitement automatisé de données à caractère personnel, y compris le profilage* ». À ce principe, deux exceptions sont prévues.

La première se réfère aux exceptions du RGPD, c'est-à-dire « *les cas mentionnés aux a et c du 2 de l'article 22 précité, sous les réserves mentionnées au 3 de ce même article et à condition que les règles définissant le traitement ainsi que les principales caractéristiques de sa mise en œuvre soient communiquées, à l'exception des secrets protégés par la loi, par le responsable de traitement à l'intéressé s'il en fait la demande* ». Outre les garanties prévues par le texte européen à l'article 22§3 (droit d'obtenir une intervention humaine de la part du responsable du traitement, droit d'exprimer son point de vue et de contester la décision), le législateur français a ajouté l'obligation de communiquer les règles définissant le traitement, ainsi que les principales caractéristiques de sa mise en œuvre à la demande de la personne concernée. Cette garantie n'a plus cours si ces règles font l'objet de secrets protégés par la loi. Cette réserve vient ici aussi substantiellement affaiblir le principe, alors même qu'une communication des règles préservant le respect des secrets pourrait aisément s'envisager.

Quant à la deuxième exception prévue à l'article 10 al. 2 de la loi n° 78-17 modifiée, elle s'appuie sur le point b) de l'article 22§2 du RGPD, selon lequel chaque État membre peut prévoir librement des exceptions, dès lors qu'elles sont légalement prévues et respectent certaines garanties. Le législateur français a posé une exception pour les décisions administratives individuelles, à condition que le traitement ne porte pas sur des données sensibles, que des recours administratifs sont possibles et qu'une information est délivrée sur l'usage de l'algorithme. Cette exception ici précisée était déjà consacrée à l'article 4 de la loi n° 2016-1321 pour une république numérique du 7 octobre 2016, codifiée à l'article L. 311-3-1 du CRPA, selon lequel une décision administrative individuelle prise sur le fondement d'un traitement algorithmique doit comporter une mention explicite en informant l'intéressé. L'article 1^{er} du décret n° 2017-330 du 14 mars 2017, codifiée à l'article R. 311-3-1-1 CRPA, précise que la mention explicite doit indiquer la finalité poursuivie par le traitement algorithmique. Elle rappelle le droit d'obtenir la communication des règles définissant ce traitement et des principales caractéristiques de sa mise en œuvre, ainsi que les modalités d'exercice de ce droit à communication et de saisine, le cas échéant, de la commission d'accès aux documents administratifs. La loi n° 2018-493 du 20 juin 2018 est venue préciser que la mention explicite précitée est exigée à peine de nullité. La sanction de la violation de cette obligation d'information est donc explicitement prévue.

Depuis l'adoption de la loi pour une république numérique le 7 octobre 2016, l'article L. 311-3-1 prévoit par ailleurs que « *les règles définissant ce traitement ainsi que les principales caractéristiques de sa mise en œuvre sont communiquées par l'administration à l'intéressé s'il en fait la demande* ».

Le décret n° 2017-330, codifié à l'article R. 311-3-1-2, précise les informations à fournir sous une forme intelligible et sous réserve de ne pas porter atteinte à des secrets protégés par la loi : 1° Le degré et le mode de contribution du traitement algorithmique à la prise de décision ; 2° Les données traitées et leurs sources ; 3° Les paramètres de traitement et, le cas échéant, leur pondération, appliqués à la situation de l'intéressé ; 4° Les opérations effectuées par le traitement. On constate qu'est maintenue la dérogation en cas de secrets protégés par la loi.

La loi n° 2018-493 va plus loin quant à l'utilisation d'un système de traitement automatisé pour la prise de décision administrative et prévoit désormais une obligation d'explication. Elle dispose ainsi que « le responsable de traitement s'assure de la maîtrise du traitement algorithmique et de ses évolutions afin de pouvoir expliquer, en détail et sous une forme intelligible, à la personne concernée la manière dont le traitement a été mis en œuvre à son égard ». Un fameux « droit à explication » est explicitement consacré par la loi française, alors que le RGPD n'y fait clairement référence que dans le considérant 71. Les articles 13 à 15 se contentent de prévoir un droit d'information et d'accès sur l'utilisation d'un dispositif automatisé et la « logique sous-jacente », ce qui constitue une approche très générale, déconnectée des situations individuelles des personnes concernées.

Par dérogation à cette exception en faveur de l'administration, aucune décision par laquelle l'administration se prononce sur un recours administratif ne peut être prise sur le seul fondement d'un traitement automatisé de données à caractère personnel.

La loi n° 2018-493 a fait l'objet d'une décision du Conseil constitutionnel n° 2018-765 DC le 12 juin 2018, notamment sur les aspects concernant les décisions individuelles automatisées prises par l'administration (points 66 et suivants). Le Conseil constitutionnel estime que les dispositions de la loi se bornent à autoriser l'administration à procéder à l'appréciation individuelle de la situation de l'administré, par le seul truchement d'un algorithme, en fonction des règles et critères définis à l'avance par le responsable du traitement. Elles n'ont ni pour objet ni pour effet d'autoriser l'administration à adopter des décisions sans base légale, ni à appliquer d'autres règles que celles du droit en vigueur. Il n'en résulte dès lors aucun abandon de compétence du pouvoir réglementaire (pt 69).

En deuxième lieu, le seul recours à un algorithme pour fonder une décision administrative individuelle est subordonné au respect de plusieurs conditions. D'une part, la décision administrative individuelle doit mentionner explicitement qu'elle a été adoptée sur le fondement d'un algorithme et les principales caractéristiques de mise en œuvre de ce dernier doivent être communiquées à la personne intéressée, à sa demande. Il en résulte que, lorsque les principes de fonctionnement d'un algorithme ne peuvent être communiqués sans porter atteinte à l'un des secrets protégés par la loi, aucune décision individuelle ne peut être prise sur le fondement exclusif de cet algorithme (pt 70).

En outre, la décision administrative individuelle doit pouvoir faire l'objet de recours administratifs. L'administration sollicitée à l'occasion de ces recours est alors tenue de se prononcer sans pouvoir se fonder exclusivement sur l'algorithme. La décision administrative est, en cas de recours contentieux, placée sous le contrôle du juge, qui est susceptible d'exiger de l'administration la communication des caractéristiques de l'algorithme. Enfin, le recours exclusif à un algorithme est exclu si ce traitement porte sur l'une des données sensibles mentionnées au paragraphe I de l'article 8 de la loi du 6 janvier 1978, c'est-à-dire des données à caractère personnel « qui révèlent la prétendue origine raciale ou l'origine ethnique, les opinions politiques, les convictions religieuses ou philosophiques ou l'appartenance syndicale d'une personne physique », des données génétiques, des données biométriques, des données de santé ou des données relatives à la vie ou l'orientation sexuelle d'une personne physique (pt 70).

En dernier lieu, le responsable du traitement doit s'assurer de la maîtrise du traitement algorithmique et de ses évolutions afin de pouvoir expliquer, en détail et sous une forme intelligible, à la personne concernée la manière dont le traitement a été mis en œuvre à son égard. Il en résulte que ne peuvent être utilisés, comme fondement exclusif d'une décision administrative individuelle, des algorithmes susceptibles de réviser eux-mêmes les règles qu'ils appliquent, sans le contrôle et la validation du responsable du traitement (pt 71).

Le Conseil constitutionnel estime que le législateur a défini des garanties appropriées pour la sauvegarde des droits et libertés des personnes soumises aux décisions administratives individuelles prises sur le fondement exclusif d'un algorithme. Le 2° de l'article 10 de la loi du 6 janvier 1978 est conforme à la Constitution (pt 72).

Différentes situations peuvent être schématiquement considérées pour l'application de ces règles. Dans le cas d'un algorithme procédural de type *ParcoursSup*, les règles de fonctionnement doivent être clairement explicitées ; le Ministère concerné s'y est préparé à la suite des difficultés rencontrées par le prédécesseur APB. En effet, le code de l'algorithme *Parcoursup* est certes rendu public mais, source d'un débat ou controverse car les règles de délibérations locales à un établissement peuvent rester confidentielles rendant finalement opaque et éventuellement discriminatoire le processus.

Enfin, la loi n° 2018-493 prévoit que, s'agissant plus particulièrement des décisions prises en matière éducative dans le cadre de *ParcoursSup*, « le comité éthique et scientifique mentionné à l'article L.612-3 du code de l'éducation remet chaque année, à l'issue de la procédure nationale de préinscription et avant le 1^{er} décembre, un rapport au Parlement portant sur le déroulement de cette procédure et sur les modalités d'examen des candidatures par les établissements d'enseignement supérieur. Le comité peut formuler à cette occasion toute proposition afin d'améliorer la transparence de cette procédure ».

4.2 Quelle transparence ?

Si les dispositions du RGPD ont pour objectif de renforcer les droits des personnes concernées, des lacunes sont constatables, liées, d'une part, aux exceptions et, d'autre part, au fait que l'énoncé de ces droits n'obligent en aucun cas à une forme de transparence. La seule référence à un « droit à explication » prévoit que la personne concernée a le droit d'obtenir du responsable de traitement des informations sur l'existence d'une prise de décision automatisée, y compris un profilage, visée à l'article 22, paragraphes 1 et 4, mais aussi « au moins en pareils cas, des informations utiles concernant la logique sous-jacente, ainsi que l'importance et les conséquences prévues de ce traitement pour la personne concernée ». On peut donc dire que le règlement général sur la protection des données ne concerne pas directement ni véritablement indirectement le principe de transparence algorithmique.

La loi pour une république numérique a essentiellement pour objet d'imposer une obligation d'information (loyauté) sur les modalités de référencement des algorithmes, laquelle s'ajoute aux autres obligations d'information du code de la consommation. Surtout, cette obligation est utilement complétée par les dispositions préexistantes dans le code de consommation relatives aux pratiques commerciales trompeuses dont les énoncés sont suffisamment larges pour viser et sanctionner les comportements déviants qui pourraient être fondés sur des traitements algorithmiques déloyaux ou faussés ; le droit à l'explication ne concerne explicitement que l'administration.

En revanche, la loi n° 2018-493 du 20 juin 2018 pose davantage d'exigences de transparence et explication. Il est encore tôt pour savoir quelle effectivité ces mesures auront à l'avenir sur

la transparence algorithmique et l'IA mais le législateur français se montre particulièrement ambitieux, en comparaison du législateur européen et des autres États membres de l'UE.

4.3 Quelle explication ?

Dans la suite, nous dirons qu'une décision algorithmique est *interprétable* s'il est possible d'en rendre compte explicitement à partir de données et caractéristiques connues de la situation. Autrement dit, s'il est possible de mettre en relation les valeurs prises par certaines variables (les caractéristiques) et leurs conséquences sur la prévision, par exemple d'un score, et ainsi sur la décision. En revanche, une décision algorithmique est dite *explicable* s'il est seulement possible d'identifier les caractéristiques ou variables qui participent le plus à la décision, voire même d'en quantifier l'importance.

Dans le cas d'un algorithme opaque, il est impossible de mettre simplement en relation des valeurs ou des caractéristiques avec le résultat de la décision, notamment en cas de modèle non linéaire ou avec de nombreuses interactions. Telle valeur élevée d'une variable peut conduire à une décision dans un sens ou dans un autre selon la valeur prise par une autre variable non identifiable, voire même une combinaison complexe d'autres variables. Un modèle opaque qui ne permet pas de s'expliquer facilement, par exemple face un candidat à l'embauche, aboutit à une forme de déresponsabilisation du décideur lui permettant de se cacher derrière l'algorithme. Ce n'est plus la faute de l'ordinateur mais celle de l'algorithme.

Chaque acteur, public ou privé, chaque domaine, santé, justice, emploi, banque, assurance, police... nécessite une lecture spécifique de ce que peut être une forme de transparence algorithmique en lien avec le droit à l'explication. Un comportement éthique *a minima* est indispensable à l'acceptabilité de ces technologies mais, dans ce cadre, la formulation d'une explication dépend de bien des facteurs. Expliquer un diagnostic automatique et les risques relatifs encourus lors d'une intervention chirurgicale, motiver une mesure de détention dépendant d'une estimation algorithmique d'un risque de récidive, justifier le refus d'un prêt sur la base d'un score... nécessitent une double compétence : compétence métier et connaissance des limites, propriétés, de l'algorithme qui a conduit à la décision.

4.4 Aides à l'explication

Que peut faire un individu, qu'il soit responsable d'une décision ou simple citoyen, client, concerné par celle-ci, confronté à un ensemble de quelques centaines d'arbre de décision, d'un réseau de neurones définis par des milliers voire des millions de paramètres appris sur un gros volume de données ?

Dans beaucoup de domaines d'application et notamment en médecine, un modèle opaque qui ne permet pas de s'expliquer facilement, par exemple face un patient, et qui aboutirait à une forme de déresponsabilisation du décideur, ne serait que difficilement acceptable, à moins d'apporter une qualité de prévision nettement supérieure dans la recherche d'un meilleur *compromis entre qualité et explicabilité*. En d'autre terme faut-il privilégier un modèle élémentaire interprétable mais éventuellement moins précis à un modèle complexe, faisant intervenir de très nombreux paramètres et possédant de meilleures qualités prédictives mais opaque à toute interprétation.

Une approche graduée pourrait s'envisager, suivant la priorité donnée à l'explication ou la qualité de la prévision, à supposer qu'un algorithme plus opaque permette a contrario de meilleurs résultats. La réponse serait alors potentiellement différente selon les activités concernées car il n'est pas pertinent de traiter de la même façon un algorithme utilisé en médecine ou en techniques de commercialisation. Cela conduirait alors à encourager une réglementation

sectorielle. En tout état de cause, il paraît indispensable de pouvoir faire un choix social sur ce qui est préférable dans une balance d'intérêts circonstanciés entre la qualité de l'explication et la qualité de la prévision, au moins dans les hypothèses où les caractéristiques des algorithmes sont réductibles à ces deux principales qualités.

Notons par ailleurs que le « droit à explication » peut faire l'objet de deux approches différentes (Watcher et al. 2017 p5) :

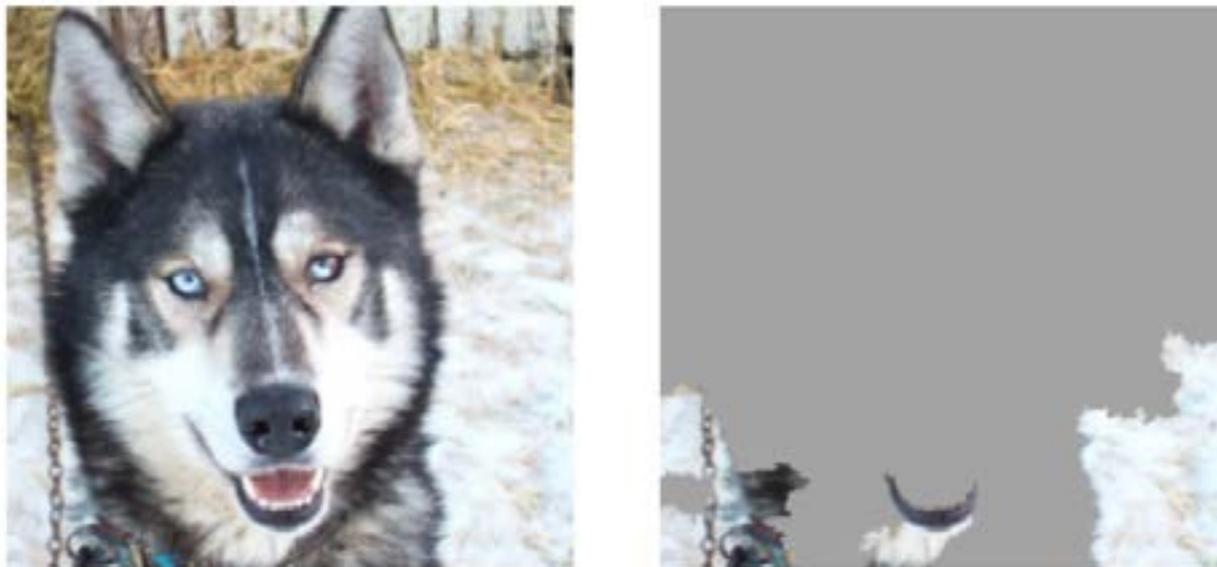
- le droit d'avoir une explication sur le fonctionnement général du système mettant en œuvre des décisions algorithmiques ;
- le droit d'avoir une explication sur une décision spécifique.

Au demeurant, l'explication peut être *ex ante* ou *ex post* (Watcher et al., 2017 p6). S'il s'agit de donner une explication spécifique sur une décision individuelle, l'explication ne pourra être donnée que *ex post*, alors que si elle porte sur le fonctionnement général, elle pourra l'être *ex ante* ou *ex post*.

Dans le cas d'un algorithme d'apprentissage interprétable, les coefficients d'un modèle linéaire ou logistique peuvent et doivent être explicités pour l'individu concerné de même que la séquence de règles définissant un arbre de décision. Le dernier cas d'un algorithme opaque ou seulement explicable semble difficilement concerné ou pris en compte par la loi.

Compte tenu de l'importance des enjeux sur l'explicabilité (ouvrir les boîtes noires de l'IA), la recherche est très active en ce domaine. Citons quelques exemples illustratifs selon qu'une compréhension globale d'un algorithme complexe ou qu'une explication individuelle est visée. Dans le premier cas, des aides visent à identifier les facteurs, variables (*features*) les plus importants c'est-à-dire ceux participant généralement le plus à une décision. Indépendamment de toute question éthique, cela est fondamental pour analyser la fiabilité ou la robustesse de décisions et identifier les possibles artefacts généralement dus aux insuffisances de la base d'apprentissage. Différentes stratégies sont proposées ; ainsi, pour les algorithmes d'agrégation d'arbres (*random forest, gradient boosting*) il est d'usage de chercher les variables dont une permutation circulaire des valeurs (*mean decrease accuracy*) dégrade le plus une estimation de la qualité de prévision. Une méthode plus générale consiste à approcher localement les décisions non interprétables obtenues par un algorithme au moyen d'une règle de décision interprétable de type régression. En effet, pour une régression ou un modèle de régression logistique, le rôle joué par chaque variable est clairement exprimé au moyen d'une combinaison linéaire. Chaque coefficient correspond au poids de chaque variable dans la prédiction et permet ainsi de déterminer non seulement l'importance de chaque variable mais également si sa contribution est positive ou négative dans le résultat final. La règle de décision pouvant être beaucoup plus complexe qu'une règle linéaire, cette approximation n'a pas de sens globalement mais seulement localement. Cette méthodologie est développée dans le package LIME (Ribeiro et al, 2016). Une idée similaire consiste à tester l'algorithme sur un algorithme présentant un biais pour chaque variable. Ainsi si l'on parvient à créer un échantillon de test de loi presque similaire mais pour lequel une variable présente une déviation de sa moyenne (positive ou négative), on peut étudier l'évolution de la règle de décision de manière globale puisque l'on considère les lois de l'échantillon des sorties de l'algorithme avec pour entrées l'échantillon de test modifié. Cette méthodologie permet de répondre à la question : comment peut-on influencer en moyenne sur une décision prise par un algorithme en augmentant ou en diminuant certaines de ses caractéristiques. Ce travail est détaillé dans Bachoc et al. (2018).

Figure 2. Un husky (à gauche) est confondu avec un loup car les pixels (à droite) caractéristiques de ces derniers sont ceux du fond de neige. Cet artefact est dû à une base d'apprentissage pas suffisamment représentative.



Cette approche est encore valide pour les algorithmes même très complexes, apprentissage profond (*deep learning*), utilisés en reconnaissance d'images. Un exemple souvent repris (Ribeiro et al., 2016) met en évidence une coquille de la base d'apprentissage. Comme des loups ont systématiquement été photographiés sur un fond de neige, c'est le fond qui permet de les identifier le plus sûrement. Un husky lui aussi photographié devant de la neige est alors confondu avec un loup (figure 2).

Le problème se pose différemment pour l'explication d'une décision individuelle. Il s'agit encore d'identifier les ou plutôt la variable la plus représentative au sens qu'une modification de celle-ci permettrait de faire basculer la décision. Par exemple, quel revenu serait nécessaire à l'obtention d'un prêt, ou quelle variable comportementale impacte le plus favorablement l'évaluation d'un score de récidive. Cet objectif pourrait être atteint par une approximation locale interprétable de la règle de l'algorithme complexe ; approximation par un modèle linéaire simple ou un arbre binaire de décision élémentaire.

En conclusion, le règlement européen et la loi française, principalement axée sur l'administration, laissent un large espace de manœuvre en matière de transparence. Espace vide qui, sans progrès significatif de la recherche fondamentale sur ce sujet, doit être occupé par des actions éthiques au risque de provoquer un rejet massif des technologies de l'IA. Ainsi, le partenariat (*Partnership on IA*) entre les principaux acteurs (Google, Facebook, Microsoft, IBM, Apple...) pour une IA au service de l'homme est très sensible à ce besoin d'interprétation. Un article de leur charte précise :

7. We believe that it is important for the operation of AI systems to be understandable and interpretable by people, for purposes of explaining the technology.

5. Qualité de décision et erreur de prévision

5.1 Mesurer une qualité de décision

En apprentissage statistique, la *justesse* de la décision dépend de la qualité d'une prévision et donc de la qualité d'un modèle ou d'un algorithme. Cette dernière dépend de la *représentativité*

ou biais des données initiales, de l'adéquation du modèle au problème posé et à la quantité (variance) de bruit résiduel. Elle est évaluée sur un échantillon test indépendant ou par validation croisée (*Monte Carlo*) mais reste indicative sous la forme d'un *risque probabiliste d'erreur*.

Les méthodes de prévisions sont entraînées sur les données d'apprentissage, c'est donc la *qualité* de celle-ci qui est en premier lieu déterminante ; rappelons le vieil adage : *garbage in, garbage out*. Leur volume peut être un facteur utile de qualité mais seulement si les données sont bien représentatives de l'objectif et pas biaisées. Dans le cas contraire des téraoctets n'y font rien. C'est l'exemple de Google Flu Trend (Butler, 2013) qui visait à suivre en temps réel et prédire le déroulement d'une épidémie de grippe à partir du nombre de recherches de certains mots clefs associés et connaissant la localisation (adresse IP) du questionneur. L'outil a été abandonné par Google (2015) car source de lourdes erreurs de prévision. C'était le battage médiatique de la grippe qui était suivi, pas l'épidémie elle-même. Les données ont été reprises avec de meilleurs résultats par une équipe de Boston (Yanga et al, 2015) en estimant un modèle auto-régressif intégrant une chaîne de Markov cachée et corrigée sur la base des tendances des recherches sur Google.

La littérature sur l'apprentissage automatique est excessivement prolifique sur les façons de mesurer et estimer les erreurs. Il faut distinguer en premier lieu l'erreur d'ajustement ou d'apprentissage qui qualifie le bon respect des données et celle à proprement parler de prévision ou de généralisation. Le type de mesure ou fonction perte est adapté au type de la variable cible ou à prévoir ; celle-ci peut être réelle, quantitative (problème de régression) ou discrète, qualitative (classification supervisée). Dans le cas quantitatif, la fonction perte peut être quadratique (erreur quadratique moyenne) ou basée sur une valeur absolue, plus robuste aux valeurs atypiques mais aussi plus complexe à optimiser. Dans le cas qualitatif, il peut s'agir d'un simple taux d'erreur ou d'une mesure d'entropie ou, notamment dans le cas de classes déséquilibrées, de mesure plus complexes. L'erreur d'apprentissage ajoute généralement une pénalisation à la fonction perte afin de contrôler, par la valeur d'un paramètre à optimiser, la complexité du modèle dans l'objectif d'atteindre un meilleur compromis biais vs. variance pour échapper au sur-apprentissage. En définitif, une fois l'algorithme entraîné et optimisé sur l'échantillon d'apprentissage, c'est l'estimation de l'erreur de prévision sur un échantillon test indépendant et de taille suffisante qui donne une indication de la qualité d'une décision algorithmique.

5.2 Enjeu de la qualité d'une décision algorithmique

Il est notable que l'erreur de prévision impacte le biais ou caractère discriminatoire d'une décision (cf. section 3.5 de l'exemple du score de récidive) et influence le choix d'une méthode ou d'un algorithme dans la recherche d'un meilleur compromis entre précision et interprétabilité. Bien que fondamentale à bien des égards, notamment pour être en mesure de discuter de l'opportunité d'une décision (*ex* : conséquence d'un diagnostic médical), la loi comme le RGPD n'en font absolument aucune mention. Il semblerait en effet très pertinent qu'une décision algorithmique soit accompagnée d'une évaluation du risque d'erreur encouru comme la loi oblige les instituts de sondage à produire des marges d'incertitude.

Les principaux fournisseurs ou vendeurs d'Intelligence Artificielle (Google, Facebook, IBM, Microsoft...) ont intérêt à mettre en évidence, amplifiés par les médias, les résultats les plus spectaculaires de l'IA (reconnaissance d'images, traduction automatique, compétition de jeu de go...) avec des taux de succès exceptionnels, meilleurs que l'expert humain. Mais ces succès portent principalement sur des prototypes, ou sur des applications sans enjeux risqués. Malheureusement (quoique ?) les taux d'erreurs attachés à la prévision de comportements humains (score de récidive d'un détenu, détection de commentaires injurieux, de fausses nouvelles, d'un comportement à risque, etc.) sont nettement plus, voire tristement, pessimistes.

La loi ne codifie pas une obligation de résultat mais une pratique éthique ou un manuel de bonne pratique de conception impose au concepteur, comme au médecin, une obligation de moyens : tout mettre en œuvre afin d'assurer au citoyen, client, patient... la meilleure décision possible en l'état des connaissances. Par ailleurs, l'évaluation de l'erreur, la répartition de ses causes contribueraient efficacement à la réflexion sur le partage des responsabilités. L'obligation de publication ou de notification de la qualité de l'algorithme utilisé serait, comme pour les sondages, un facteur important de responsabilisation de l'utilisateur.

Conclusion

La prise de conscience progressive de la puissance que peuvent avoir des systèmes de décision automatiques utilisant des techniques d'apprentissage statistique pour exploiter les masses de données désormais omniprésentes dans tous les secteurs d'activité (commerciales, administratives, économiques, industrielles, médicales, etc.) suscite autant d'espoirs que de craintes légitimes. On ne peut compter exclusivement sur la responsabilité des acteurs de ces changements, ni sur la dynamique propre du front de recherche en apprentissage automatique, pour éviter les dérapages, voire la banalisation d'usages abusifs de ces techniques. Les risques portent notamment sur les discriminations, sur l'arbitraire de décisions dont on ne connaît guère la pertinence et dont on ne sait trop qui est responsable, sur les dérives d'un développement purement guidé par les possibilités techniques, et sur les biais, même involontaires, induits par le processus de récolte des données qui conditionne le comportement des algorithmes. Ils portent également sur des points non abordés dans ce court article : confidentialité des données et risques de ré-identification, entrave à la concurrence.

La principale difficulté vient de ce qu'aborder sérieusement ces questions nécessite à la fois de sérieuses compétences techniques, afin de comprendre finement le fonctionnement des algorithmes et de garder un regard critique sur le discours qui les entoure, et une expertise juridique, sociétale ou sociologique, voire politique ou philosophique. La teneur des débats sur le sujet, et l'analyse des textes juridiques même récents, montrent que le défi est grand.

- Une pratique discriminatoire envers une personne ou un groupe est punie par la loi mais il revient à la ou les victimes d'en apporter la preuve alors que, contrairement aux USA, aucune caractérisation ou mesure de discrimination indirecte n'est rentrée dans la jurisprudence.
- L'obligation de transparence ou d'explicabilité, impose au mieux une intervention humaine pour assumer une décision et n'est contraignante que pour les décisions administratives françaises, interdisant ainsi l'usage d'algorithmes auto-apprenants sans contrôle ou validation humaine, comme ce peut être le cas de ventes de publicités en ligne.
- Aucun texte n'oblige à publier ou renseigner la qualité de prévision ou le taux d'erreur associé à l'utilisation d'un algorithme d'apprentissage.

La disruption technologique qui en découle autorise toutes les possibilités de comportements ou de pratiques, éthiques ou pas. Les questions de discrimination sont celles le mieux encadrées par la loi mais aussi celles les plus complexes à appréhender. L'exemple souvent cité de justice prédictive (score de récidive) montre bien que les décisions qui en découlent ne peuvent être que largement statistiquement biaisées donc collectivement discriminatoires, sur certains critères, mais sans pour autant qu'il soit facile, pour une personne, de montrer qu'elle en a été lésée. Cet exemple montre par ailleurs très bien que les données, bases de l'apprentissage des algorithmes, et leurs modes sélectifs de recueil, reflets de nos sociétés, sont la principale source d'erreurs ou de biais.

Cette situation motive en retour la recherche fondamentale pour définir des modèles ou construire des algorithmes répondant à ces critiques. Les investigations en cours consistent à

rechercher des meilleurs compromis entre différentes contraintes : explicabilité et qualité de prévision, réduction du biais et confidentialité des données.

Vérifier l'interprétabilité ou l'explicabilité d'un algorithme ou du modèle sous-jacent, contrôler, par exemple sur un échantillon test, ses qualités prédictives et enfin détecter des biais potentiels, collectifs ou individuels sont des tâches complexes. À l'heure actuelle, aucun acteur ne peut à lui seul prétendre pouvoir contrôler la loyauté algorithmique. Une pluralité de contre-pouvoirs est donc nécessaire. Quels sont les acteurs susceptibles de prendre en charge ces contrôles ? Certains sont les régulateurs publics : CNIL, DGCCRF (répression des fraudes), Autorité de la Concurrence, juges (juridictions françaises et CJUE) mais en ont-ils les moyens ? D'autres sont privés : plateformes collaboratives (Data transparency lab, TransAlgo INRIA, Conseil National du Numérique), Médias (ProPublica aux USA), ONG Data (*Bayes Impact*) mais ne sont que balbutiants et difficilement finançables.

Faut-il aller plus loin que les principes énoncés par la loi pour une république numérique et la loi de 1978 modifiée par la loi n° 2018-493 ? À l'heure actuelle, il convient d'abord de laisser le temps à ces lois de s'appliquer pour en mesurer la portée. Cela peut paraître prématuré, alors même que l'efficacité des dispositifs de contrôle est encore incertaine. En outre, comment formuler plus précisément les conditions d'encadrement dans l'utilisation des différentes méthodes algorithmiques alors que le domaine d'application, commerciale, juridique, médical, administratif... en change considérablement l'environnement et donc les conditions d'utilisation ou les termes d'explication ?

Dans ce contexte encore flou, il paraît peu pertinent de s'en remettre une nouvelle fois et dès à présent au législateur, sauf pour éventuellement réclamer, comme pour les sondages, l'obligation d'affichage d'un taux d'erreur. Les recherches académiques émergent seulement depuis 2-3 ans et il convient de prendre un peu de recul avant d'imposer une règle précise à respecter. D'autres normes commencent à apparaître, simples règles éthiques, bonnes pratiques (*soft law*), qui pourraient aider à mieux cerner les conditions d'une loyauté et transparence algorithmique : O'Neil (2016) évoque la nécessité d'un **serment d'Hippocrate** pour les *data scientists*, idée reprise par de très nombreux groupes ou associations dont celle française *data for good*, tandis qu'un groupe de travail offre de signer un **code de conduite sur l'éthique des pratiques des données**... les initiatives se sont multipliées et il serait difficile d'en établir une liste exhaustive. Notons que les statisticiens **européens** ou **américains** se sont dotés de longue date de chartes ou codes de bonnes pratiques mais ces textes ne peuvent être transposés sans réflexion approfondie comme par exemple sur la notion de *consentement libre et éclairé* lorsque celui-ci est recueilli en ligne.

Enfin, la pratique de l'IA au quotidien ayant besoin de confiance de la part des usagers, confiance qu'il est difficile d'accorder sans contrôle aux fournisseurs et vendeurs de technologies, une autre solution consiste à proposer aux entreprises et principaux acteurs la délivrance d'un label indépendant témoignant, à la suite d'un audit, d'un usage loyal des données (*fair data use*). C'est ce que propose la société **ORCAA** créée par C. O'Neil ou encore la startup **Maathics**.

Références

- Angwin J., Larson J., Mattu S., Kirchner L. (2016). *How we analyzed the compas recidivism algorithm*. ProPublica, en ligne consulté le 28/04/2017.
- Bachoc F., Gamboa F., Loubes J.-M. and Risser L. (2018). Sensitivity Analysis for Explainable & Interpretable Machine Learning Algorithms. work in progress.
- Besse P., Castets-Renard C., Garivier A. (2017). *Loyauté des Décisions Algorithmiques*, Contribution au Débat "Éthique et Numérique" de la CNIL.
- Besse P., del Barrio E., Gordaliza P., Loubes J.-M. (2018). Confidence Intervals for testing Disparate Impact in Fair Learning, arXiv preprint arXiv:1807.06362.
- Butler D. (2013). When Google got flu wrong, Nature 494, 155-156.
- Chouldechova A. (2017). Fair prediction with disparate impact: A study of bias in recidivism prediction instruments, Big Data, Special issue on Social and Technical Trade-offs, arXiv.
- Collectif Manouchian, Cormont J., Bouamana S., Fotia Y. (2012). Dictionnaire des Dominations, Syllepse.
- Dressel J., Farid H. (2018). The accuracy, fairness, and limits of predicting recidivism, Science Advances, Vol. 4, no. 1.
- del Barrio E., Gamboa F., Gordaliza P., Loubes J.-M. (2018a), *Obtaining fairness using optimal transport theory*, arXiv:1806.03195.

- del Barrio E., Gordaliza P., Loubes J.-M. (2018b), A Central Limit Theorem for transportation cost with applications to Fairness Assessment in Machine Learning, arXiv:1807.06796.
- Feldman M., Friedler S., Moeller J., Scheidegger C., Venkatasubramanian S. (2015). Certifying and removing disparate impact, arXiv-preprint.
- Galhotra S., Brun Y., Meliou A. (2017). FairnessTesting: Testing Software for Discrimination. In Proceedings, 11th Joint Meeting of the European Software Engineering Conference and the ACM SIGSOFT Symposium on the Foundations of Software Engineering, 13 pages.
- Hardt M., Price E., Srebro N. (2016). Equality of Opportunity in Supervised Learning, 30th Conference on Neural Information Processing System (NIPS).
- James G., Witten D., Hastie T., Tibshirani R. (2017). *An Introduction to Statistical Learning, with Applications in R*, 8ème édition, Springer.
- L'Horty Y., Bunel M., Mbaye S., Petit P., du Parquet L. (2017). Discriminations dans l'accès à la banque et à l'assurance : Les enseignements de trois testings, TEPP Research Report 2017-08, TEPP.
- O'Neil C. (2016). Weapons of Math Destruction: How Big Data Increases Inequality, Crown Random House.
- Pedreschi D., Ruggieri S., Turini F. (2012). A Study of Top-K Measures for Discrimination Discovery. SAC. Proceedings of the 27th Annual ACM Symposium on Applied Computing, 126-131.
- Peresie, J. L. (2009). Toward a Coherent Test for Disparate Impact Discrimination, Indiana Law Journal, Vol. 84 (3).
- Popejoy A., Fullerton S. (2016). Genomics is failing on diversity, Nature, 538, 161-164.
- Tulio R., M., Singh S., Guestrin C. (2016). Why Should I Trust You?: Explaining the Predictions of Any Classifier, KDD'16 Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 1135-1144.
- Yanga S., Santillanab M., Koua S. (2015). Accurate estimation of influenza epidemics using Google search data via ARGO, PNAS, 112(47), 4473-14478.
- Wachter S., Mittelstadt B., Floridi L. (2017). Why a Right to Explanation of Automated Decision-Making Does Not Exist in the General Data Protection Regulation, *International Data Privacy Law*, à paraître.
- Zafar M., Valera I., Rodriguez M., Gummadi K. (2017). Fairness Constraints: Mechanisms for Fair Classification in International Conference on Artificial Intelligence and Statistics (AISTATS), vol. 5.
- Žliobaitė I. (2015). A survey on measuring indirect discrimination in machine learning. arXiv pre-print.

Recension

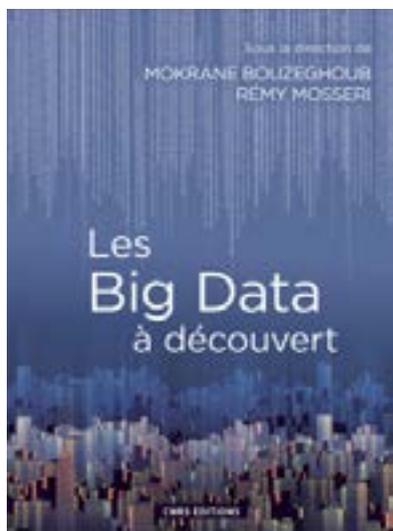
Les Big Data à découvert

Ouvrage collaboratif pluridisciplinaire



Recension de l'ouvrage réalisée par Jean-Christophe Thalabard, Univ. Paris-Descartes

1. Introduction



Sous ce titre, près de 220 chercheurs abordent sous la forme de 150 articles très synthétiques (2 pages), largement illustrés, les formidables potentialités offertes par les nouveaux moyens de stockage des informations et de calcul mais aussi les nouvelles contraintes qui débordent largement le seul domaine scientifique. L'ouvrage, dense (368 pages), est divisé en 9 parties, même s'il existe de larges recoupements des thèmes abordés, s'efforçant d'apporter des points de vue complémentaires, entre les parties. Il convient peut-être de noter ici que ni le titre de l'ouvrage, ni les intitulés des parties successives et encore moins les intitulés des différentes contributions ne renferme directement le terme « intelligence artificielle » (IA), que le grand public associe volontiers à « Big Data ». La porte d'entrée de l'ouvrage est donc la donnée massive, ou plutôt les différentes formes de données massives et leurs traitements et les conséquences sociétales et d'organisation que cela peut

avoir. Ainsi il semblerait que pour les experts des données et de leurs traitements, l'IA ne pourrait se saisir qu'à travers les particularités de chaque domaine, en n'existant qu'à travers la somme, souvent gigantesque, de données amassées, bien loin encore de la souplesse et de l'adaptabilité de l'intelligence humaine multi-objectifs dès les premiers âges.

La première partie « **Big Data : enjeux et défis** » rappelle l'importance prise par les données massives dans des domaines aussi divers que le commerce, l'industrie, la météorologie, la géographie, la santé, sans taire les risques de dérives et les questions concernant l'individu et la société.

La partie 2 « **Données, acquisition, stockage** » indique les particularités des données de différents domaines (vivant, collections muséologique, littérature, multimédias) avant d'interroger la nature des métadonnées et leur rapport aux connaissances. Elle se poursuit par des considérations sur la qualité des données collectées suivies d'une série d'articles sur les capteurs, leurs différentes natures, leurs autonomies et leurs capacités de communication, leurs organisations en réseaux. Elle se termine par les aspects de stockage en lien avec les notions cruciales de préservation et d'archivage, de coûts énergétiques et d'impact écologique.

La troisième partie, « **Traitement des données** », décrit notamment différentes approches de traitement des données : algorithmes, interfaçages et interrogations des bases de données, intégration de données massives, hétérogènes et équidistribuées, compression, sans oublier

les aspects sécurité et d'architecture de traitement préservant la vie privée.

La quatrième partie, « **Analyse de données et apprentissage** » regroupe des thèmes variés allant de modèles de prévision à visées industrielles ou commerciales (transports, énergie), à la fouille de données (textes), aux modèles d'apprentissage (neuroscience, imagerie, reconnaissance de formes).

La cinquième partie, « **Web, réseaux sociaux et recherche d'information** » aborde l'utilisation faite des ressources accessibles via les moteurs de recherche, leurs organisations, l'accès aux données personnelles avec des conséquences sur la vie sociale, la diffusion des opinions et l'apparition de phénomènes extrémistes.

La sixième partie, « **De l'infiniment petit à l'infiniment grand** » rentre dans l'exploitation des données massives dans des domaines d'échelles variées allant de l'astronomie et l'exploration de l'espace, à la climatologie à la physique des particules en passant par le décryptage du vivant (génomique et génomique, biologie), l'étude des écosystèmes (données Tara par exemple pour l'écosystème océan).

La septième partie, « **Santé humaine** », est plus particulièrement consacrée aux enjeux des « Big Data » dans différents champs d'activités et d'instrumentation touchant à la santé humaine : objets connectés, imagerie, oncologie, chirurgie, environnement, sans oublier les aspects éthiques.

La huitième partie, « **Individu et Société** » reprend et développe, sous un angle sciences sociales, les impacts de nouvelles pratiques et modes de vie associés à des collections et échanges de flux de données (tels tweets, Smart Grids, Smarthome). Quels sont les enjeux sociaux ? Quelle(s) place(s) de l'humain pensant par rapport aux approches robotisées ? Quel est le futur de l'entreprise ? Quelle place pour les choix individuels ? Quel droit à la déconnexion ?

Une dernière partie de **conclusions** laisse la parole à des acteurs reconnus de la robotique, des neurosciences, de la physique théorique, du monde technologique, des sciences sociales de dresser quelques perspectives et interrogations à partir de leurs champs respectifs pour rejoindre des préoccupations plus générales.

2. Une tentative d'analyse graphique de l'ouvrage

Qui sont ces acteurs qui, sous la coordination d'un enseignant-chercheur en informatique, Mokrane Bouzeghoub et d'un chercheur du CNRS en physique théorique, Rémy Mosseri, ont apporté leur contribution à cet ouvrage ? Domaine oblige, nous nous sommes amusés à soumettre l'ouvrage à un outil d'analyse des larges bases de données, *linkage.fr*, que nos lecteurs ont pu découvrir lors d'un récent numéro de *Statistique et Société* (sous la plume de leurs auteurs, C. Bouveyron (INRIA/Univ. Nice) et P. Latouche (Univ. Paris Descartes)¹.

Il nous a fallu faire quelques choix. Nous avons choisi de garder des informations factuelles concernant les auteurs, leur appartenance, leur genre, leurs publications telles qu'apparaissant dans la base de données internationale Pubmed (nous nous sommes donc restreints aux liens pouvant exister avec les domaines biologie et/ou santé) nous donnant accès à leurs co-auteurs, leurs appartenances et les titres des journaux concernés.

1. Présidentielle 2017 : l'analyse des tweets renseigne sur les recompositions politiques - Pierre LATOUCHE, Charles BOUVEYRON, Damien MARIE, Guilhem FOUETILLOU. *Statistique et Société*, Vol. 5 No 3 (2017) - Ouvrir les données. Pages 39-44. <http://statistique-et-societe.fr/article/view/660>

Nous ne pouvons qu'insister sur le caractère très parcellaire de notre analyse en ce qui concerne le réseau collaboratif autour du seul domaine, déjà très vaste, des publications concernant les domaines de la biologie et de la santé.

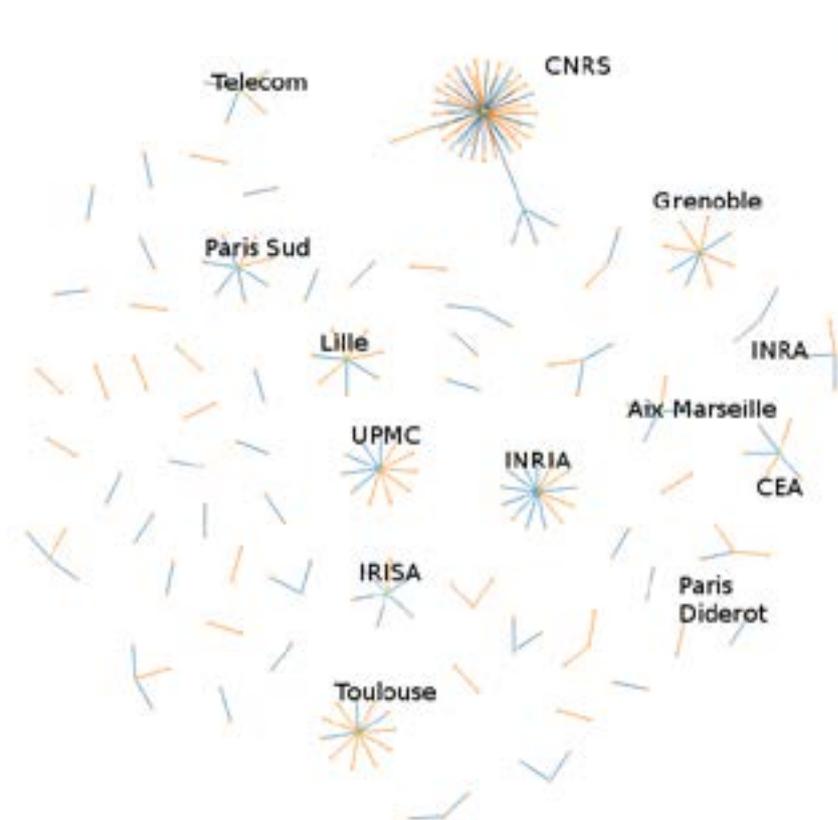
Préparer un tel fichier, qui reste plus que modeste dans le monde des « Big Data » (22°000 lignes x 8 colonnes°!) permet également de voir quelques limites de ces aspirations (via le package easyPubmed de R) d'une base de données comme Medline. En effet, les appartenances, les mots clés, les adresses sont fonctions de l'alimentation de la base qui dépend fortement des contraintes éditoriales de tel ou tel article et de sa présence dans ladite base de données. Le travail qui consiste à combler les lacunes d'un logiciel de reconnaissance automatique d'un pays ou d'une ville reste imparfait, imposant une vérification visuelle et manuelle des données incomplètes que des esprits algorithmiques s'empresseraient de vouloir imputer...

Nous nous contenterons ici de souligner les nombreux pièges qui peuvent apparaître dans toute illusion d'analyse automatique avec des outils facilement disponibles et imposent encore un certain savoir-faire vigilant.

Il convient sans doute de préciser que de tels outils sont essentiellement des moyens de représentation de données complexes, ouvrant la place à des interprétations personnelles, par nature, subjectives. La valeur d'une prédiction ne saurait se substituer à une quelconque preuve de causalité.

2.1 Répartition des auteurs par laboratoires

Figure 1 : représentation de l'ensemble des contributeurs rapportés à leur laboratoire / structure d'appartenance. Pour des questions de lisibilité, nous n'avons labellisé que les nœuds les plus denses, où se retrouvent les acteurs connus du domaine. Il convient cependant de souligner la forte interdépendance entre les grands organismes (CNRS, INRA, INRIA, CEA...), dont l'appréhension ici dépend fortement des appartenances indiquées par les auteurs.



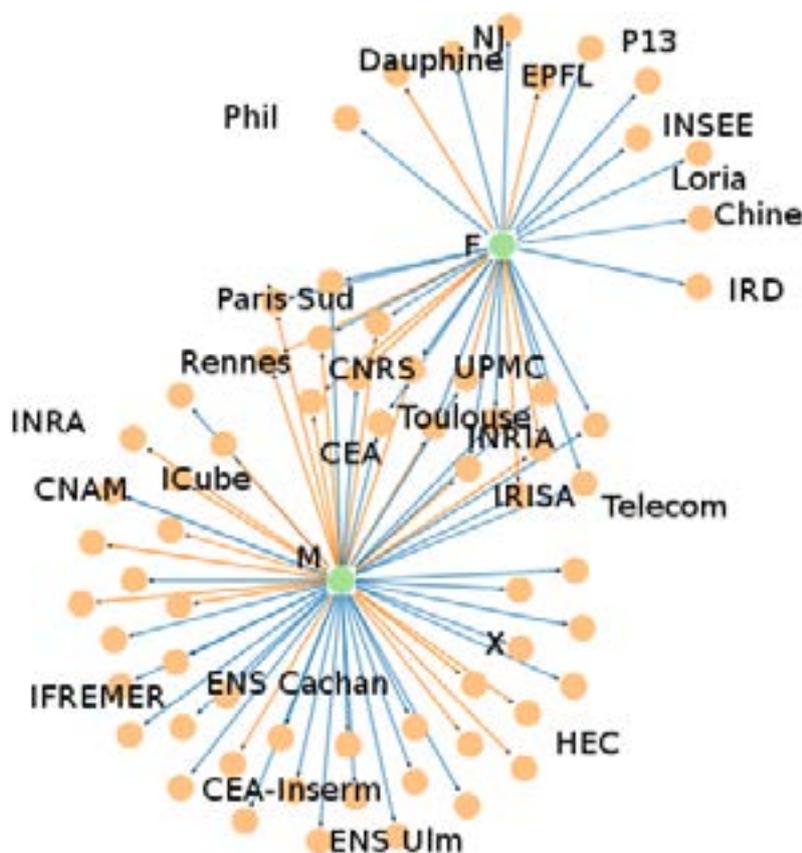
2.2 Répartition des auteurs par genre

Factuellement, parmi les 220 auteurs, 62 sont des femmes (28 %). La répartition selon les 9 parties de l'ouvrage est représentée dans le Tableau 1. Il y apparaît une nette prédominance masculine dans la plupart des parties, à commencer par l'introduction (partie 1) et la conclusion (partie 9), avec une exception pour la partie 3 « Traitement de données ». Dix-neuf de ces articles étaient écrits avec une seule auteure, vingt-cinq étaient écrits avec un ou des co-auteurs masculins. Trois étaient écrits par un binôme d'auteurs et un par un trio. La répartition par appartenance est représentée sur la Figure 2.

Tableau 1 : Répartition des auteurs par genre en fonction des parties thématiques de l'ouvrage

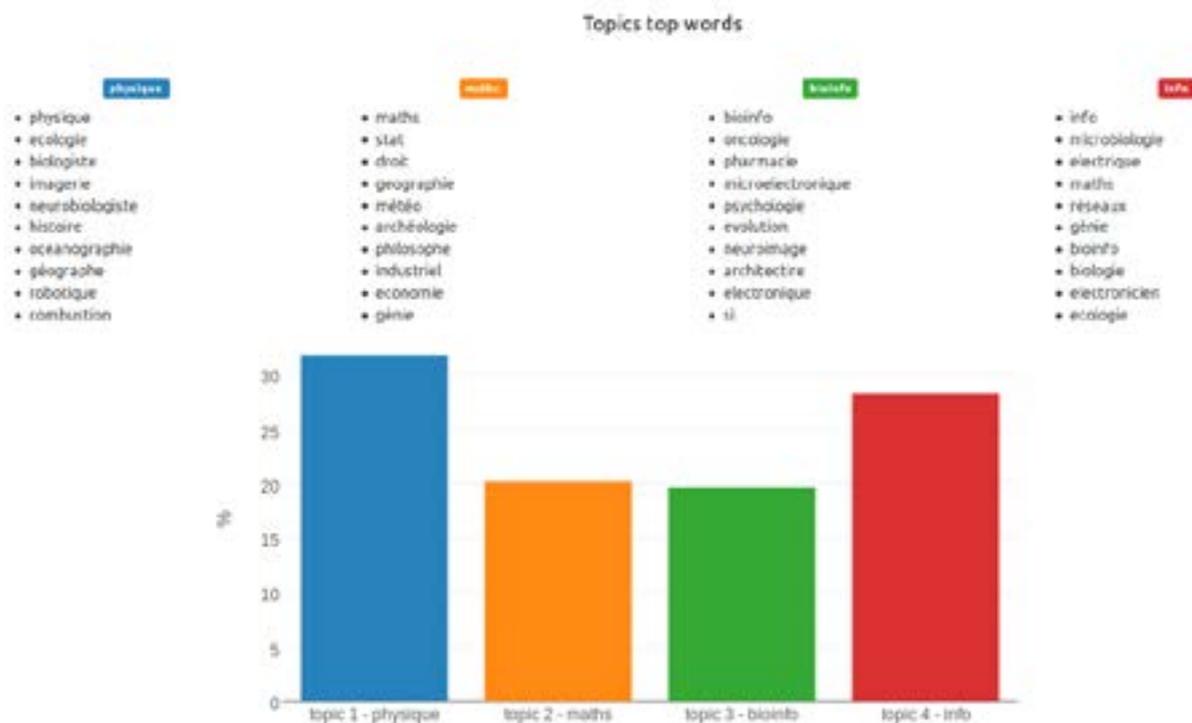
	Parties de l'ouvrage									Total
	1	2	3	4	5	6	7	8	9	
Femme	6	10	14	6	3	9	3	10	2	63
Homme	11	18	13	25	21	28	11	19	11	157
Total	17	28	27	31	24	37	14	29	13	220

Figure 2 : Distribution des contributeurs en fonction de leur genre (F : Féminin ; M : Masculin). La couleur des arêtes indique le champ disciplinaire : bleu pour informatique ; orange pour application aux domaines (biologie/ santé/ écologie...). Quelques institutions représentatives sont indiquées au niveau des nœuds. Le graphe suggère des interactions féminines plus tournées vers le monde universitaire et l'étranger, les acteurs majeurs du domaine (CNRS, INRIA, IRISA, CEA) semblant accueillir indifféremment des acteurs des deux sexes, avec une répartition similaire entre les développements informatiques et leurs applications.



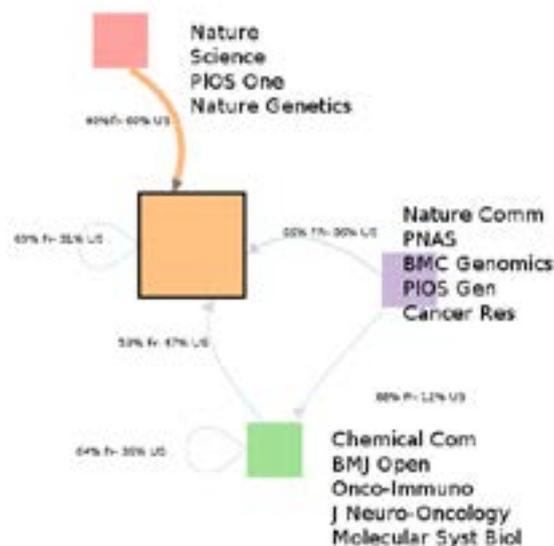
2.3 Regroupements des contributeurs (clusters) et leurs interactions (topics)

Figure 3 : Distribution des thèmes d'échanges (topics) restreints à un maximum de 4 grands thèmes entre les différents auteurs regroupés en 4 « clusters », de tailles relatives très différentes, correspondant aux poids des appartenances des contributeurs de l'ouvrage aux différents organismes et institutions. On notera la position « discrète » de la Statistique dans la colonne « maths »



2.4 Publications

Figure 4 : Étude des liens entre chercheurs à partir des publications communes. Le carré central, orange, représente l'ensemble des contributeurs et leurs co-auteurs tels que retrouvés dans PubMed. Les carrés périphériques correspondent à des grands types de journaux dont les principaux sont indiqués en regard. Les flèches indiquent les natures (en pourcentage) des collaborations franco- françaises versus franco- étrangères, dont la contribution majoritaire apparaît être nord- américaine



3. En guise de conclusion

Si la lecture de l'ouvrage peut inciter le lecteur curieux à s'essayer aux techniques d'analyses et de synthèses automatisées, rien ne peut remplacer encore une lecture plus traditionnelle au hasard des parties et des contributions, faisant découvrir la richesse des multiples points de vue au gré des inclinations du lecteur.

Il convient certainement de saluer les 2 coordinateurs de l'ouvrage, Mokrane Bouzeghoub et Rémy Mosséri, pour avoir réussi une véritable gageure de réunir une large palette d'experts pour produire cette somme d'articles courts, percutants, bien illustrés, toujours accompagnés de quelques références bibliographiques récentes, qui ne peut qu'intéresser l'honnête homme du 21^{ème} siècle soucieux de saisir dans son élaboration l'état des connaissances portées par les multiples acteurs actuels d'un domaine aux contours par nature évolutifs qui bouge les frontières des savoirs traditionnels, tout en questionnant leurs impacts sur les sociétés, leurs économies et leurs régulations.

La politique des petits nombres : comment appréhender l'histoire de la statistique vaccinale et de ses effets ?



Gaëtan THOMAS

Docteur de l'EHESS

Les débats suscités par la diffusion de l'inoculation en Europe, au XVIII^e siècle, ont alimenté des pages glorieuses de l'histoire du calcul de probabilités. Ce procédé ancien, courant en Orient et en Extrême-Orient, qui préfigura l'invention de la vaccine à la fin du XVIII^e siècle, consistait à administrer à un sujet sain de la substance prélevée sur les vésicules d'un malade de la variole. La technique n'était pas sans danger pour la personne inoculée. Des savants européens se mirent à calculer des risques comparés de mourir de la variole ou de l'inoculation. Mais déjà, pour reprendre une distinction proposée par Alain Desrosières, la statistique n'était pas qu'une affaire de preuve, elle relevait du gouvernement de la population. C'est la raison pour laquelle Michel Foucault a fait du contrôle de la variole au XVIII^e siècle un exemple emblématique de ses réflexions sur la biopolitique¹.

1. Les petits nombres de la vaccination

Plusieurs auteurs ont souligné la part d'idéalisation que comportent les analyses sur la biopolitique. Ce rapport entre un savoir statistique élaboré et un pouvoir souverain soucieux de la vigueur de sa population prend une dimension presque idéale quand on le compare à l'histoire postérieure de la vaccination. On ne retrouve pas par la suite, en France, d'alignement aussi clair entre pouvoir, savoir et immunisation. Sans doute la vaccine a-t-elle été associée aux entreprises de quantification des Hygiénistes dans la première partie du XIX^e siècle. Mais les vaccins humains suivants, développés à partir du tournant du XX^e siècle, n'apparaissent à aucun moment marquant de l'histoire de la statistique. Quand ils y figurent, comme le vaccin contre la tuberculose dans les années 1920, c'est pour illustrer le retard français sur les normes méthodologiques édictées par les fondateurs britanniques et américains de l'épidémiologie moderne².

Sur le versant gouvernemental on observe une même coupure, particulièrement nette au XX^e siècle : les maladies infectieuses et la vaccination n'ont pas fait l'objet d'investissement significatif de la part des services statistiques créés ou développés par l'État français. Il y eut bien sûr l'intermédiaire de l'Institut national d'hygiène (1941-1964), qui récupéra les machines

1. Michel Foucault, *Sécurité, territoire, population. Cours au Collège de France, 1977-1978*, Paris, Gallimard Seuil, 2004.

2. Christian Bonah, « The "experimental stable" of the BCG vaccine: safety, efficacy, proof, and standards, 1921-1933 », *Studies in History and Philosophy of Biological and Biomedical Sciences*, 2005, vol. 36, no 4, p. 696-721.

de la Statistique générale de France et investit pour quelques années la statistique de la vaccination, avant de l'exclure du cœur de ses activités. L'intervention reine de santé publique ne se transforma jamais en objet prioritaire de quantification pour l'État, y compris quand les lois d'obligation vaccinale se multiplièrent entre la fin des années 1930 et les années 1950, une période de structuration de la statistique publique.

Les tentatives d'objectivation des politiques vaccinales et des vaccins pâtissaient d'un désintérêt politique. En témoigne le naufrage des fichiers des vaccinations mis en place au niveau des communes dans les années 1940. Ces fichiers furent si peu et si mal remplis que le ministère de la santé le jugea inexistant quarante ans plus tard. Dans les décennies d'après-guerre, les experts rassemblés au Conseil supérieur d'hygiène publique de France, le corps censé défendre la constitution d'un savoir sur la santé publique au bénéfice du politique, considéraient qu'il ne fallait pas assommer les confrères avec des formulaires. Jusqu'à la création d'une instance dédiée à l'édiction des politiques vaccinales en 1986, le Comité technique des vaccinations, aucun groupe d'acteurs institué, directement associé à l'État, ne défendit avec vigueur la mise en place d'une statistique nationale de la vaccination et des maladies infectieuses.

Toutes les données populationnelles qui reposent sur une machinerie étatique et des relais locaux restèrent inaccessibles aux acteurs de la vaccination. Dans la deuxième partie du XX^e siècle, on n'a jamais su mesurer le taux exact d'enfants immunisés sur l'ensemble du territoire (la couverture vaccinale). Jusqu'aux années 1990, les données sur le nombre d'effets secondaires graves n'avaient aucune valeur, malgré des déclarations contraires des responsables sanitaires. Il n'existait pas de dispositif permettant de dénombrer les accidents vaccinaux ne débouchant pas sur un procès. Pour autant, le travail de quantification se maintint. Il répondait à des besoins réels, dont la régulation d'un nombre grandissant de vaccins, la rationalisation des injections à travers leur ordonnancement dans les premiers mois de la vie et, lorsqu'une série de crises déstabilisa les mondes de la santé publique à la fin du XX^e siècle, la justification politique et économique de la vaccination. Les données statistiques étaient nombreuses, souvent issues d'enquêtes et d'essais cliniques, mais elles n'atteignaient jamais l'échelle du pays et leur production s'effectuait à distance de l'État et des centres de la biomédecine française.

2. Le Centre international de l'enfance

On réalise combien la vaccination constitue un cas de figure original en rappelant qu'Alain Desrosières a lié l'histoire de la statistique à celle de l'État. C'est un rapport qu'il n'a pas cessé d'analyser, des premiers chapitres de *La politique des grands nombres* jusqu'au « gouvernement de la cité libérale ». Conformément à l'idée que « les conventions de quantification sont-elles mêmes le produit de l'histoire de l'État et de ses modes de gouvernement³ », Desrosières a proposé une histoire stylisée des différentes formes d'État et de leurs outils statistiques. Mais alors que la vaccination apparaît dans les discours experts comme une intervention sur la société menée au nom de la communauté nationale, l'État a externalisé le travail d'objectivation statistique de la vaccination pendant des décennies. Il est donc impossible de traquer l'État dans les différentes formes de la statistique vaccinale, sinon pour souligner son désintérêt. Cette distance pourrait expliquer que les médecins producteurs de statistique vaccinale dans la deuxième partie du XX^e siècle, qui n'étaient pas des épidémiologistes professionnels au sens contemporain du terme, mais qui réalisèrent des essais cliniques randomisés, remplirent des registres, s'essayèrent aux méthodes de sondage et enfin rejoignirent une instance gouvernementale où les discussions étaient chiffrées, ne jugeaient pas appartenir aux mondes de la statistique publique.

Ce constat n'en annule pas moins l'intérêt de la grande question de Desrosières, relative aux

3. Alain Desrosières, *Prouver et gouverner. Une analyse politique des statistiques publiques*, Paris, La Découverte, 2014, p. 40.

effets instituants et normalisateurs de la statistique. Il faut simplement redéfinir certains de ses termes pour l'appliquer à la statistique vaccinale. D'abord, cette dernière ne s'appuyait pas sur une chaîne d'enregistrement stable impliquant une grande variété d'acteurs et d'institutions nationales – par contre, la chaîne s'étendait à l'occasion à des acteurs étrangers et des institutions internationales. De l'après-guerre à l'émergence des nouvelles bureaucraties sanitaires dans les années 1990, le milieu français de la vaccination s'est organisé autour du Centre international de l'enfance (CIE, 1949-1999), une institution singulière et, de l'aveu même de ses membres, peu connue durant son existence. Fondé par Robert Debré, le CIE était emblématique des ambiguïtés de la coopération franco-africaine. Debré donna à « son » centre tous les atours d'une institution internationale, à commencer par son nom, alors que le CIE était une institution de droit français avec un personnel essentiellement national. Il avait pour mission de diffuser la discipline fondée par Debré, la pédiatrie sociale, à travers des actions menées dans les possessions coloniales en Afrique. Le CIE était entièrement tourné vers l'Afrique francophone. Il est donc remarquable que le département du CIE spécialisé à l'origine dans le BCG, la Station pilote, soit devenu l'institution de référence pour la vaccination des enfants en métropole. La Station pilote ne disposait d'aucune prise sur le pays. La position très particulière du CIE a façonné l'organisation des réseaux français de la vaccination. Alors que cette intervention est envisagée d'ordinaire sous un angle national, à grand renfort de considérations sur l'exceptionnalité du pays de Pasteur, le dispositif français et son volet statistique se sont construits dans un échange ininterrompu avec des contextes extra-métropolitains, au point de constituer un volet de l'histoire coloniale et de la santé internationale.

3. Routiniser la vaccination par les nombres

Les réseaux étroits de la vaccination en France déterminèrent la nature des données, on l'a vu, mais aussi leur circulation. Des chiffres jugés sensibles étaient retenus au prétexte de ménager l'opinion ; c'est un aspect fascinant mais relativement anecdotique de cette histoire. En réalité, peu de données étaient cachées, cette rétention épisodique exprimait surtout une méfiance des experts à l'égard de l'opinion. La circulation publique de la statistique butait en premier lieu sur un manque de relais en métropole. La vaccination était un sujet jugé ennuyeux, peu traité par les médias et rarement discuté par les médecins avec leurs patients. Pour reprendre l'expression forgée par une sociologue au tournant des années 1980, la vaccination était « inquestionnable » : l'immense majorité des individus se contentait de recevoir les injections sans discuter⁴. L'absence d'une statistique nationale robuste et accessible pourrait expliquer la quasi inexistence d'un débat public sur la vaccination jusqu'à la controverse du vaccin contre l'hépatite B, qui éclata en 1996. On se souvient que Desrosières soutenait, dans la conclusion de la *Politique des grands nombres*, qu'un espace de discussion social, ouvert, se constituait sur la base d'une information statistique accessible. L'histoire française de la vaccination en fournit en creux l'illustration.

Si les chiffres étaient si petits, si confidentiels, circulant davantage dans des espaces extra-métropolitains qu'en France, comment ont-ils pu façonner et stabiliser un monde autrement plus vaste que celui des experts qui les manipulaient ? L'idée selon laquelle le travail statistique a contribué à perpétuer, en France, le calme entourant la vaccination, de l'après-guerre aux années 1990, n'est-elle pas l'expression d'un déterminisme naïf ? De nombreux auteurs ont mis en garde contre les risques d'hypostasier le pouvoir et les outils des bureaucrates, de présenter une vision idéalisée ou exagérée de l'influence des experts⁵. Après avoir passé des années à examiner des protocoles d'essais et des chiffres qui n'intéressaient pas grand monde, l'historien pourrait être enclin à rehausser son objet en lui attribuant un certain pouvoir.

4. Claudine Marenco et Sélimir Govedarica, *La vaccination des enfants en France, 1880-1980*, Paris, DGRST - CNRS, 1980.

5. Céline Plessis, Sezin Topçu et Christophe Bonneuil, « Pour en finir avec les "Trente Glorieuses" » dans Céline Plessis, Sezin Topçu et Christophe Bonneuil (eds.), *Une autre histoire des « Trente Glorieuses »*, Paris, La Découverte, 2016, p. 5-32.

Tout dépend de la façon dont cette normalisation par les chiffres est envisagée. En abordant la question dans sa forme la plus générale, on pourrait avancer que les effets de la quantification touchent à tous les aspects du monde social puisque celle-ci, comme l'expliquait Alain Desrosières, se fonde sur des opérations successives de convention et de mesure. Quantifier, c'est ordonner le monde, pour la simple raison que l'entreprise de quantification impose de stabiliser un objet au moyen de conventions avant de procéder au dénombrement. Cette idée s'avère particulièrement utile pour comprendre le fonctionnement et les effets d'opérations statistiques comme les calculs coût-bénéfice, courants dans le domaine de la vaccination à partir du tournant des années 1980. Typiquement, ces calculs transforment différentes qualités d'apparence inassimilables dans une même métrique – ce que la sociologue Wendy Espeland a appelé un « processus de *commensuration*⁶ ». Mais pour que cet argument exprime toute sa puissance dans le contexte de l'histoire moderne de la vaccination, il aurait fallu que les données soient diffusées largement et que les opérations de mise en équivalence se routinisent elles-mêmes. Or, les études construisaient rarement le coût de la vaccination de la même façon. Au-delà des critiques nombreuses pointant l'inutilité et la cherté de ces calculs, les acteurs reconnaissaient volontiers la précarité des conventions préalables à l'établissement d'un rapport coût-bénéfice. Cette absence de stabilité se traduisait par la production de données contradictoires sur un même vaccin.

Bien que le travail sur les conventions restât inabouti, la catégorie de coût et les valeurs culturelles associées circulèrent avec les premières études impliquant cette variable. La vaccination gagna ainsi une nouvelle propriété : alors que le prix des vaccins explosa dans les années 1980, suite à l'introduction du vaccin contre l'hépatite B et des changements profonds dans l'organisation du marché pharmaceutique⁷, la vaccination, resta grâce aux calculs coût-bénéfice, l'opération de santé la plus rentable dans le domaine concurrentiel de la gestion des maladies infectieuses. Cet exemple indique la façon dont agissait la statistique vaccinale, elle construisait et aidait à maintenir des qualités de la vaccination. Si la statistique publique produite par les instituts nationaux manie plutôt des catégories (qu'est-ce qu'un chômeur, un cadre, un célibataire ?), et les solidifie à travers la répétition des procédures et leur adoption en dehors des cercles experts, le travail d'objectivation de la vaccination agissait davantage sur l'ontologie des produits. Il apportait une réponse à une question simple - qu'est-ce qu'un bon vaccin ? – en dotant cet objet de qualités modelées par les nombres. Routiniser la vaccination revenait à maîtriser différentes qualités afin que celle-ci reste attractive.

4. Les qualités de la vaccination

La myriade de travaux d'histoire des sciences sur la standardisation, traitant de vaccination ou de produits thérapeutiques, se focalise sur les qualités d'innocuité et d'efficacité. Ces études montrent que les pionniers de la vaccination, et plus tard les industriels, se sont investis sans relâche dans la stabilité de leurs produits, au moyen d'essais mobilisant des outils statistiques. Mais le travail statistique sur la vaccination ne se limita pas à la maîtrise de l'efficacité et de l'innocuité. On peut d'ailleurs se demander si l'utilisation très large de la notion de standardisation par les acteurs et dans l'historiographie, un terme initialement associé au tournant du XX^e siècle dans différents domaines des sciences et des techniques⁸, n'obscurcit pas la diversité des opérations et leurs buts.

6. Wendy Nelson Espeland et Mitchell L. Stevens, « Commensuration as a Social Process », *Annual Review of Sociology*, 1998, vol. 24, no 1, p. 313-343.

7. Farah Huzair et Steve Sturdy, « Biotechnology and the transformation of vaccine innovation: The case of the hepatitis B vaccines 1968-2000 », *Studies in History and Philosophy of Science Part C: Studies in History and Philosophy of Biological and Biomedical Sciences*, 2017, vol. 64, p. 11-21.

8. Theodore M. Porter, *Trust in Numbers: The Pursuit of Objectivity in Science and Public Life*, Princeton, N.J., Princeton University Press, 1996. ; Vanessa Ogle, *The Global Transformation of Time, 1870-1950*, Cambridge, Harvard University Press, 2015.

La simplicité des vaccins a ainsi fait l'objet d'un investissement considérable. Le programme de simplification mis en place par le CIE dans les années 1960 avait pour but de construire un calendrier des vaccinations simplifié, c'est-à-dire d'ordonner et de rassembler un nombre croissant d'injections dans un tableau représentant les premiers mois de la vie. Cette entreprise était saturée de statistique, mêlant de la randomisation, des calculs de corrélations, des séries de chiffres définissant des dosages. La définition des modalités d'usage normalisa ainsi un dispositif à la complexité grandissante en le présentant sous sa forme la plus simple. À côté de la simplicité, de l'efficacité et de l'innocuité, le bas coût relatif de la vaccination était l'autre grande qualité travaillée par la statistique dans la deuxième partie du XX^e siècle. Les calculs de coût redéfinirent ce qu'était un bon vaccin : un bon vaccin était un vaccin avec un coût-bénéfice intéressant.

Conclusion

Le travail statistique a normalisé la vaccination en la transformant à différents niveaux, dans sa matérialité, dans son utilisation, dans la construction des prix. Comme l'indiquaient sans détour les acteurs, le but de ces opérations était de rendre acceptable l'administration la plus grande d'injections, recommandées ou obligatoires, par le plus grand nombre d'individus. Les médecins-épidémiologistes accomplirent un rôle fondamental d'intermédiaire entre les concepteurs, les producteurs et l'État d'un côté, les médecins et les patients de l'autre. Mais la crise de la vaccination contre l'hépatite B et les controverses postérieures ont montré que le fruit de ce travail n'était pas garanti. Les controverses ont révélé l'ambiguïté, voire la réversibilité, des qualités visées par la statistique. Les études de coût ne sont pas parvenues à dissimuler l'augmentation du prix net des vaccins. L'argument des profits réalisés sur le dos de l'État et des citoyens, rare jusqu'aux années 1990, a ainsi pu s'imposer et balayer les subtilités des calculs coût-bénéfice. La simplicité de la vaccination a elle aussi été mise à l'épreuve. La simplification de la vaccination a limité le choix des individus, désormais soumis à des assemblages d'injections plutôt qu'à une série de vaccins dissociés. Ce qui devait être un avantage rationnel s'est transformé en un problème, ainsi que le montrent les débats récents sur les vaccins combinés.

Remise du prix Alain Desrosière à Gaétan Thomas (au centre) par Michel Armatte (Maître de conférence, Univ. Paris-Dauphine et Centre Alexandre Koyré (CNRS-EHESS)), président du jury (à gauche) et Gael de Peretti (administrateur de l'INSEE), secrétaire et cheville ouvrière du jury (à droite) lors du séminaire sur l'histoire des enquêtes sociales organisé le 22 novembre 2018 par le groupe Histoire de la statistique, des probabilités et de leurs usages de la Société Française de Statistique



Fichiers de population sous l'Occupation



Gérard LANG

Statisticien retraité, SFdS

Un point soulevé dans les Éléments pour une histoire du « numéro de sécurité sociale », du même auteur qu'ici, publié dans le numéro 2018-1 de Statistique et société, était le rôle crucial qu'avaient joué la mémoire des fichiers de populations aussi bien pendant la guerre qu'après, lors des débats sur l'informatisation du « numéro de Sécu » en 1973, et la peur des usages totalitaires que ces souvenirs avaient causés. En complément au précédent article, voici quelques faits importants et peu connus de ce qui s'est passé au début du régime de Vichy, entre 1940 et 1943.

1. Quelques repères chronologiques sur la statistique publique au début du régime de Vichy

- 10 juillet 1940 : Le maréchal Philippe PETAIN reçoit les pleins pouvoirs.
- 12 juillet 1940 : Pierre LAVAL est nommé vice-président du conseil des ministres présidé par le maréchal PETAIN. Yves BOUTHILLIER est ministre, secrétaire d'État aux finances.
- 18 septembre 1940 : Un décret nomme Henri BUNLE directeur de la Statistique générale de France (SGF) à compter du 1^{er} octobre 1940, en remplacement d'André FOURGEAUD, disparu depuis l'armistice et qui va rejoindre le Rassemblement National Populaire de Marcel DEAT.
- 3 octobre 1940 : Loi portant statut des juifs (1^{er} statut)
- 7 juin 1940 : Arrêté portant délégation de signature pour la SGF à Henri BUNLE, directeur, avec subdélégation à Alfred SAUVY, statisticien faisant fonction de sous-directeur.
- 29 octobre 1940 : Décret rattachant l'Institut de conjoncture et le service d'observation économique à la SGF, sous l'appellation « Service d'observation économique », avec transfert à la SGF du poste de sous-directeur créé par le décret du 12 novembre 1938.
- 14 novembre 1940 : Une loi porte création, au sein du Ministère des Finances, d'un service de la Démographie, dont un décret du 15 novembre publie le statut du personnel, essentiellement formé d'anciens militaires. Le service comprend un service central à Lyon et des organes régionaux.
- 16 novembre 1940 : Un décret nomme René CARMILLE directeur du service de la Démographie. Ensuite, un arrêté nomme, d'une part, Christian BOURDONCLE DE SAINT-SALVY adjoint au directeur de la Démographie et d'autre part, Gaston MARIE et Pierre LOMBARDY inspecteurs du service. Un autre arrêté donne délégation de signature à René CARMILLE, avec subdélégation à SAINT-SALVY.
- 9 novembre 1940 : Un arrêté nomme Alfred SAUVY au poste de sous-directeur de la SGF, rétroactivement à compter du 1^{er} novembre 1940.
- 25 décembre 1940 : Le journal « L'Œuvre » publie un article de Marcel DEAT intitulé « De la statistique au camouflage » qui révèle que la création du service de la Démographie a pour but principal l'établissement d'un fichier de recrutement camouflé.

- 4 janvier 1941 : À partir de cette date, et jusqu'au 25 août 1944, le Journal officiel de la République française (JORF) devient le Journal officiel de l'État français.
- 14 février 1941 : Un décret rend la loi du 14 novembre créant un service de la Démographie applicable à l'Algérie, où une direction régionale du service de la Démographie est créée à Alger.
- 22 mars 1941 : Un arrêté donne pouvoir à l'administrateur DULAC pour signer au nom du service de la Démographie et dans la zone d'occupation.
- 23 mars 1941 : Un arrêté nomme Alfred SAUVY, sous-directeur à la SGF, au cabinet d'Yves BOUTHILLIER, qui reste continement ministre des finances du 5 juin 1940 jusqu'à la prise du pouvoir par Pierre LAVAL, le 18 avril 1942.
- 29 mars 1941 : Une loi porte création du Commissariat général aux questions juives (SGQJ), dont Xavier VALLAT est nommé commissaire général par un arrêté du même jour.

2. Constitution initiale du fichier national d'identification des personnes physiques

René CARMILLE rédige, le 18 mars 1941, une instruction portant sur cette constitution. Il écrit une note, le 11 avril 1941, relative à l'exécution par MM. Les Greffiers des Tribunaux de première instance, du relevé des registres des actes de naissance (des personnes nées en France de 1881 à 1940) pour l'établissement d'un répertoire d'identification destiné au service de la Démographie, afin de lancer la constitution du fichier national d'identification des personnes physiques. Le répertoire sera ensuite complété pour les personnes nées dans les colonies ou à l'étranger.

L'identifiant numérique significatif à 13 chiffres des personnes physiques développé par ce fichier, s'appuie sur un volume de 440 pages publié à Lyon par la direction de la Démographie, et interne au service, intitulé « Code officiel géographique établi à la date du 1er juin 1941 (Imprimerie Emmanuel Vitte) ».

Le statut « occulte » de ce fichier concernant la mobilisation a été approuvé par une correspondance militaire secrète relative à la création du service de la Démographie et à sa mission militaire camouflée, comprenant une lettre du 4 août 1940 du général Louis COLSON, secrétaire d'État à la guerre (armée de terre) du 16 juin au 6 septembre 1940, au général Maxime WEYGAND, ministre de la défense nationale du 16 juin au 6 septembre 1940, accompagnée d'un ensemble de 13 pièces datées du 25 juillet au 31 décembre 1940 estampillées « secret » ou « très secret » ensuite confirmées par le général Charles HUNTZINGER, devenu ministre de la défense à partir du renvoi de WEYGAND et COLSON le 6 septembre 1940 jusqu'à son remplacement par l'amiral François DARLAN le 11 août 1941 et mort dans un accident d'avion le 12 novembre 1941. L'original de ces documents a été déposé au service historique de l'armée de terre (SHAT) par le général Gaston MARIE, cependant que des doubles ont été confiés par René CARMILLE à son subordonné Xavier JACQUEY, qui les a enterrés pour les conserver secrets.

Cependant, le ministre de la justice de Vichy, Raphaël ALIBERT, sous les ordres duquel opérait le SGQJ, souhaitait distinguer les juifs des autres habitants. CARMILLE objecta que ce renseignement ne figurait pas à l'état civil, sauf peut-être en Algérie, à cause du « décret CREMIEUX » du 24 octobre 1870 du gouvernement de la défense nationale fixant le statut des juifs indigènes des départements de l'Algérie, qui avait donné la citoyenneté française aux juifs autochtones (un des premiers actes du gouvernement de Vichy a d'ailleurs été une loi du 7 octobre 1940 abrogeant ce décret). Une telle distinction pouvait aussi avoir un sens en cas de mobilisation en Algérie, car les rancunes nées de décret CREMIEUX y restaient tenaces et il n'était pas vraiment envisageable de faire cohabiter des juifs et des musulmans algériens dans

la même unité combattante. Aussi deux instructions du 15 avril et du 6 novembre 1941 ont modifié le codage de la première composante de l'identifiant comme suit :

- 1 ou 2 pour les citoyens français d'origine ou naturalisés ;
- 3 ou 4 pour les indigènes des colonies, à l'exception des juifs ;
- 5 ou 6 pour les juifs indigènes d'Algérie ;
- 7 ou 8 pour les étrangers ;
- 9 ou 0 pour statut mal défini.

Mais ce codage n'a été mis en œuvre qu'en Algérie.

3. Réactions du personnel de la Statistique général de France (SGF)

La création du service de la Démographie, administration puissante et nombreuse est très mal vécue par les statisticiens de la SGF, administration pauvre et peu nombreuse, qui y voient une concurrence déloyale. Toujours est-il que, sans doute obnubilé par ces circonstances, Henri BUNLE propose à deux reprises, dès le 4 mars 1941 dans une lettre adressée au ministre de l'intérieur, puis le 7 avril 1941 dans une lettre adressée au SGQJ (créé le 29 mars !), les services de la SGF pour centraliser les renseignements sur les Juifs rassemblés par les préfets, notamment pour donner une estimation du nombre des Juifs, mais tout en promettant à Xavier VALLAT qu'en cas d'acceptation « les résultats de l'enquête seraient tenus rigoureusement secrets par la SGF et uniquement communiqués au SGQJ ». Heureusement pour l'honneur de la statistique publique, ces offres furent déclinées.

En effet, le ressentiment de la SGF est encore exacerbé par la publication du décret n° 2275 du 27 mai 1941, qui prescrit de procéder au recensement des activités professionnelles par les soins des maires, et porte en visa, d'une part, les articles 1 et 2 de la loi du 22 juillet 1791 et surtout, d'autre part, la loi du 14 novembre 1940 portant création d'un service de la Démographie au secrétariat d'État aux finances, ce qui indique que c'est bien ce service qui est chargé du dépouillement du recensement. En réalité, même s'il est muni du visa traditionnel et tombe dans l'année adéquate pour le cycle quinquennal associé au recensement général de la population, le décret ne prescrit pas vraiment un recensement général au sens habituel car, d'une part, il ne s'applique pas à la zone occupée et, d'autre part, comme l'indique son titre, il ne s'adresse qu'aux personnes des deux sexes nées entre le 1er janvier 1876 et le 31 décembre 1926, c'est-à-dire âgées de 15 à 65 ans, donc en âge de travailler. L'article 1^{er} écrit d'ailleurs qu'il s'agit de recenser les activités professionnelles.

Cependant, René CARMILLE ne peut réussir à s'opposer à l'insertion dans la page 2 du bulletin individuel, qui sert de questionnaire pour ce recensement des activités professionnelles, d'une question n° 11 libellée comme suit :

« 11 a) Êtes-vous de race juive ? b) Si vous êtes de race juive (voir note n° 2 page 4), êtes-vous bénéficiaire de l'article 3 de la loi du 3 octobre 1940 »

En page 4 du bulletin individuel, la note 2 (relative à la question n° 11) reproduit l'article 1^{er} de la loi du 3 octobre 1940 portant statut des juifs :

« Est regardé comme juif, pour l'application de la présente loi, toute personne issue de trois grands-parents de race juive ou de deux grands-parents de la même race, si son conjoint lui-même est juif. »

Pour sa part, l'article 3 de la loi écrit « L'accès et l'exercice de toutes les fonctions publiques autres que celles énumérées à l'article 2 [dont la liste comprend tous les mandats politiques, l'appartenance à tous les grands corps de l'État et les postes les plus élevés de la fonction publique, tous interdits aux juifs] ne sont ouverts aux juifs que s'ils peuvent exciper de l'une des conditions suivantes :

a) Être titulaire de la carte du combattant 1914-1918 ou avoir été cité au cours de la campagne 1914-1918 ;

- b) Avoir été cité à l'ordre du jour au cours de la campagne 1939-1940 :
- c) Etre décoré de la Légion d'honneur à titre militaire ou de la médaille militaire ».

Outre les scrupules d'ordre philosophique ou humanitaire pouvant inciter le personnel de la statistique publique à résister à toute exploitation de cette question 11 du recensement des activités professionnelles, un doute de nature plus (déonto-)logique peut tarauder des statisticiens professionnels en ce qui concerne cette question. Car la définition issue de la loi sur le (premier) statut des juifs qu'elle utilise de la « personne de race juive » est en fait inapplicable si on la prend au pied de la lettre, comme devrait le faire tout statisticien public (et a fortiori tout magistrat ou policier, s'agissant d'un texte relatif aux libertés publiques fondamentales).

En effet, pour établir qu'une personne est de race juive, deux problèmes distincts se posent selon la branche de la définition dans laquelle on se trouve :

(i) Pour montrer qu'une personne est de race juive, il faut dans la première branche établir qu'elle possède trois grands-parents qui sont eux-mêmes de race juive. Mais pour montrer cela, il faut établir que chacune de ces trois personnes est issue de trois grands-parents de race juive, et ainsi de suite... On remonte donc ainsi jusqu'à ABRAHAM, dont il faudra encore prouver qu'il est bien de race juive au sens de la loi !

(ii) Si maintenant on suppose que, n'ayant pas réussi à montrer que la personne concernée est issue de trois grands-parents de race juive, on ait néanmoins réussi à le prouver dans deux cas, on se trouve alors dans la seconde branche de la définition et se tournant vers le cas du conjoint de cette personne, dans le cas où on parvient à montrer qu'elle est issue de deux personnes de race juive (mais pas de trois), il y a difficulté à conclure. La définition est intraitable, et nous renvoie sans fin de conjoint à conjoint comme un miroir.

Signalons d'ailleurs que, saisi de ce mouvement perpétuel, le Conseil d'État a jugé que dans le cas de deux conjoints issus chacun de deux grands-parents de race juive, il fallait conclure qu'aucun des deux n'était de race juive.

Quoi qu'il en soit, aucune exploitation de cette question 11 du recensement des activités professionnelles de 1941 n'a jamais été trouvée.

4. Le second statut des juifs.

Peu après la publication du décret du 27 mai 1941 prescrivant le recensement des activités professionnelles, paru au Journal officiel de l'État français du 31 mai 1941, ce Journal officiel publie le 14 juin 1941 la loi n° 2232 du 2 juin 1941 remplaçant la loi du 3 octobre 1940 portant statut des juifs. Ce second statut « corrige les défauts » du précédent concernant la définition des Juifs, dont la périlleuse situation est encore aggravée, en recourant à l'appartenance à la religion juive.

L'article 1^{er} de la loi écrit :

« Art 1^{er} – Est regardé comme juif :

1° Celui ou celle, appartenant ou non à une confession quelconque, qui est issu d'au moins trois grands-parents de race juive, ou de deux seulement si son conjoint est lui-même issu de deux grands-parents de race juive. Est regardé comme étant de race juive le grand-parent ayant appartenu à la religion juive ;

2° Celui ou celle qui appartient à la religion juive ou y appartenait le 25 juin 1940, et qui est issu de deux grands-parents de race juive.

La non-appartenance à la religion juive est établie par la preuve de l'adhésion à l'une des autres confessions reconnues par l'État avant la loi du 9 décembre 1905. Le désaveu ou l'annulation de la reconnaissance d'un enfant considéré comme juif sont sans effet au regard des dispositions qui précèdent. »

Le nouveau statut comprend également l'article 8 nouveau suivant :

« Peuvent être relevés des interdictions prévues par la présente loi, les juifs :

1° Qui ont rendu à l'Etat français des services exceptionnels ;
2° Dont la famille est établie en France depuis au moins cinq générations et a rendu à l'État français des services exceptionnels.
Pour les interdictions prévues par l'article 2, la décision est prise par décret individuel pris en Conseil d'État sur rapport du commissaire général aux questions juives et contresigné par le secrétaire d'État intéressé. Pour les autres interdictions, la décision est prise par arrêté du commissaire général aux questions juives. Le décret ou l'arrêté doivent être dûment motivés. Les dérogations accordées en vertu des dispositions qui précèdent n'ont qu'un caractère personnel et ne créeront aucun droit en faveur des ascendants, descendants, conjoints et collatéraux des bénéficiaires. »

Ajoutons que si le point 2° de l'article 8 a engendré une véritable industrie de recherche relative aux bons, loyaux et exceptionnels services (notamment militaires) rendus à l'État par les ascendants de nombreuses familles juives établies depuis longtemps en France, les résultats de ces efforts ont été très peu productifs car le nombre des décisions de dérogation a été infime.

Par contre, quelques prêtres courageux, peu nombreux, et quelques pasteurs courageux, un peu plus nombreux, ont accepté de fabriquer des certificats de conversion permettant à des personnes juives d'échapper au statut.

5. L'enregistrement des juifs rendu inutilisable.

Le même Journal officiel de l'Etat français du 14 juin 1941 publie également, à la suite du second statut des juifs, la loi n° 2233 prescrivant le recensement des juifs.

L'article 1er de la loi écrit : « Toutes personnes qui sont juives au regard de la loi du 2 juin 1941 portant statut des juifs doivent, dans le délai d'un mois à compter de la publication de la présente loi, remettre au préfet du département ou au sous-préfet de l'arrondissement dans lequel elles ont leur domicile ou leur résidence, une déclaration écrite indiquant qu'elles sont juives au regard de la loi, et mentionner leur état civil, leur situation de famille, leur profession et l'état de leurs biens. La déclaration est faite par le mari pour la femme, et par le représentant légal pour le mineur ou l'interdit. »

Cette opération policière criminelle de recensement des juifs est donc entièrement distincte du recensement des activités professionnelles. Mais le SNS est sollicité par le SGQJ pour « identifier » les documents recueillis dans les préfectures et sous-préfectures et pour les exploiter dans ses directions régionales de Limoges et de Clermont-Ferrand. CARMILLE n'est pas en position de refuser, mais il exige de garder l'entière maîtrise de l'opération en excipant de lourds problèmes techniques à résoudre. Il accumule les difficultés matérielles et retarde le plus possible l'exploitation par des consignes orales aboutissant à une sorte de « grève du zèle » d'autant plus facile à appliquer que beaucoup des personnes concernées étaient nées à l'étranger ou en Alsace annexée et n'avaient donc pas eu de numéro d'identification attribué. Il fit si bien que le chiffrage demande par Xavier VALLAT n'aboutit, après trois ans d'atermoiements, qu'à un « état numérique des Juifs français et étrangers recensés en juin 1941 », en exemplaire unique, qui n'était pas terminé lors de l'arrestation de CARMILLE en février 1944.

Ce document est un tableau totalement inoffensif qui a été retrouvé à l'INSEE en 1946 par le démographe Marcel CROZE et légué en 1980 au Centre de documentation juif contemporaine (CDJC) par Michel-Louis LEVY (ancien rédacteur en chef d'Économie et Statistique, de Population et Société et des Annales des Mines). Cet épais document donne la répartition croisée par sexe, département de résidence, nationalité et activité professionnelle du nombre des juifs recensés. Il s'agit donc d'un tableau parfaitement anonyme et presque inutilisable, dans lequel il y a énormément de 0 et de 1.

6. Repères chronologiques qui donnent des indications sur la situation générale et l'état de la statistique publique jusqu'à la fin de la guerre

- 1^{er} septembre 1941 : Une loi porte organisation de l'Institut de conjoncture, rattaché à la SGF et placé sous les ordres directs d'un sous-directeur.
- 11 octobre 1941 : Une loi porte création du Service national des statistiques (SNS), au sein duquel sont fusionnés le service de la Démographie et la SGF.
- L'article 1^{er} écrit « Les informations statistiques nécessaires à la politique démographique, économique et sociale du Gouvernement sont rassemblées par un organisme unique dénommé Service national des statistiques. » L'article 3 précise que le SNS comprend une direction générale dont dépend l'Institut de conjoncture avec les attributions qui lui ont été dévolues par la loi du 1^{er} septembre 1941, ainsi que des organes régionaux placés au chef-lieu des régions économiques et des organes rattachés à chacun des secrétariats d'État.
- 24 octobre 1941 : Un décret fixe l'organisation et le fonctionnement du SNS, qui comprend notamment un service de la Statistique générale dont Henri BUNLE est nommé responsable. 25 octobre 1941 : Un décret nomme René CARMILLE directeur général du SNS (cependant que Michel HUBER et Léopold DUGE DE BERNONVILLE en sont nommés directeurs généraux honoraires). Un arrêté du même jour nomme Henri BUNLE et Christian BOURDONCLE DE SAINT-SALVY au grade d'inspecteur général de 1^{ere} classe et Alfred SAUVY, Gaston MARIE, Pierre LOMBARDY, Jean ADAM et Gaston BOURNIER au grade d'inspecteur général de 2^{eme} classe. Christian BOURDONCLE DE SAINT-SALVY est nommé adjoint au directeur général du SNS.
- 28 juillet 1942 : Un décret porte création d'un service des statistiques du gouvernement général en Algérie.
- Par ailleurs, en vue de compléter l'activité de service de recrutement camouflé du SNS par une activité de service de mobilisation industrielle, René CARMILLE donne dès mars 1942 des instructions pour lancer les travaux de constitution par le service des inventaires économiques (pendant du service des inventaires démographiques du SNS) d'un fichier général des établissements industriels et commerciaux, ayant également une visée de mobilisation industrielle. En l'absence d'un recensement direct des établissements concernés, le fichier comprend un dossier ouvert pour chaque établissement, nourri initialement par les fiches d'inspection du travail des années 1931 à 1936, les fiches « Moteurs à vapeur » et les fiches « Forces hydrauliques » issues du recensement industriel de 1931, ainsi que certains bulletins individuels du recensement général de la population de 1936. Quelques mois plus tard, une instruction prescrit de créer pour chacun des établissements répertoriés un identifiant numérique formé de 13 chiffres et composé à partir, d'une part, du code d'activité résultant de la nomenclature des industries et professions établie par la SGF et approuvée par le décret du 9 avril 1936, et d'autre part, du code du département et du code de la commune du lieu d'activité de l'établissement concerné issus du code officiel géographique.

Entre les 16 et 17 juillet 1942, 13 152 personnes juives, dont 4 115 enfants et 5 919 femmes, très majoritairement étrangers ou apatrides, sont arrêtés par plus de 7 000 policiers et gendarmes français, aidés de 300 militants du Parti Populaire Français (PPF) de Jacques DORNIOT. Une partie des personnes arrêtées est dirigée vers le camp de transit de Drancy, cependant que 8 160 autres, dont tous les enfants, sont parqués pendant 5 jours, sans nourriture et avec un seul point d'eau, dans le vélodrome d'hiver, situé rue Nélaton dans le 15^e arrondissement de Paris, avant d'être conduits dans les camps de Drancy, Pithiviers et Beaune-la-Rolande, puis déportés à Auschwitz. Le bilan de la « rafle du Vel' d'Hiv' », qui représente plus du quart des 42 000 Juifs envoyés de France à Auschwitz en 1942 est effroyable, car il ne survivra que moins d'une

centaine des personnes raflées.

Le fichier principalement utilisé pour organiser cette rafle est le fichier des juifs étrangers tenu par André TULARD, sous-directeur chargé du service des étrangers et des affaires juives à la préfecture de police de Paris (ce fichier a été détruit par la femme d'André Tulard, qui était, semble-t-il, l'archiviste de la préfecture de police). Ce fichier ne semble pas avoir été nourri par le recensement des juifs de la loi du 14 juin 1941.

Le 8 novembre 1942 les troupes anglo-américaines débarquent en Algérie et au Maroc (opération « Torch »), sans que DE GAULLE ait été consulté.

5 décembre 1942 : La direction régionale d'Alger du SNS, dirigée par l'administrateur BRACONNOT, est réquisitionnée par les autorités militaires et va rester sous statut militaire jusqu'au 1er septembre 1946. Elle utilise le fichier des personnes physiques pour mobiliser une armée française d'Afrique, dans laquelle les juifs d'Algérie forment des unités de « pionniers israéliques » au régime fort sévère et distinctes des unités dans lesquelles européens et arabes sont mobilisés.

La deuxième édition du livre de René CARMILLE « De la mécanographie dans les Administrations » paraît chez SIREY en 1942. L'ouvrage expose très clairement (dans ses pages 122 à 124) les idées conduisant à la création du numéro d'identification et prophétise magistralement l'avenir de l'usage de la mécanographie (c'est-à-dire de l'informatique) dans le traitement des fichiers administratifs. Par ailleurs, la première édition officielle du Code officiel géographique (établie à la date du 1er octobre 1943) est publiée le 10 octobre 1943.

René CARMILLE est arrêté par les Allemands dans son bureau à Lyon, ainsi que son chef de cabinet Raymond JAOUEN le 3 février 1944. Il est torturé par Klaus BARBIE au fort de Montluc, puis déporté à Dachau où il meurt le 25 janvier 1945.

Henri BUNLE devient alors directeur général par intérim du SNS jusqu'à la nomination de Francis-Louis CLOSON par un décret du 6 avril 1946.

Conclusions

Sur la question des fichiers juifs et de la statistique publique pendant la guerre 1940-1945, aussi bien le rapport remis en 1996 au premier ministre par une commission présidée par René REMOND (et dont Jean-Pierre AZEMA fait partie), que le rapport remis en 1998 au directeur général de l'INSEE par une mission formée de Jean-Pierre AZEMA, Béatrice TOUCHELAY et Raymond LEVY-BRUHL multiplient les confusions, comme le démontre notamment la lecture critique qu'en fait Robert CARMILLE, fils de René CARMILLE, puis Robert PAXTON, ainsi, bien plus tard, que le livre de Michèle TRIBALAT sur les statistiques ethniques.

Pour sa part, bien ultérieurement, Henri BUNLE tentera de justifier l'envoi de ses deux lettres d'offre de services de mars et avril 1941 par la nécessité d'utiliser le matériel mécanographique de la SGF, privée du dépouillement du recensement de la population prévu en 1941.