

Comment se protéger de Big Brother

Alex Pentland

À l'ère des données massives, nos vies entières se retrouvent sur Internet. Comment éviter qu'elles soient surveillées sans le moindre contrôle ? En suivant trois principes.

Pendant les premières décennies de son existence, l'Agence de sécurité américaine (NSA, ou *National Security Agency*) avait pour objectif principal de surveiller l'Union soviétique. Son ennemi était alors monolithique et bien défini. Elle se fondait surtout sur des écoutes téléphoniques, des avions espions et des microphones cachés.

Après les attaques du 11 septembre 2001, la situation a changé. Le principal ennemi de la NSA est devenu un réseau diffus de terroristes. Il pouvait être utile d'espionner n'importe qui. La nature même de l'espionnage a changé, avec la prolifération de nouveaux canaux de communication numériques. La croissance exponentielle des appareils mobiles connectés à Internet ne faisait que commencer. Dès lors, les vieux outils de la NSA se semblaient plus suffisants.

L'agence a réagi en adoptant une nouvelle stratégie : tout collecter. Selon Keith Alexander, le précédent directeur de la NSA, lorsqu'on cherche une aiguille dans une botte de foin, on a besoin de toute la

L'ESSENTIEL

■ **Les données sur les individus sont essentielles aux gouvernements et aux industries, mais leur collecte peut donner lieu à des abus.**

■ **Selon l'auteur, on éviterait ces abus si l'on appliquait quelques principes, notamment la répartition des données massives dans des centres séparés et la sécurisation des transmissions et du stockage.**

■ **Les procédures doivent aussi être constamment adaptées pour suivre les évolutions techniques.**

botte. La NSA a d'abord collecté en masse des conversations téléphoniques, obtenant des enregistrements de presque toutes les personnes présentes sur le sol américain, puis elle a rassemblé des données sur le trafic Internet de presque tous les individus à l'échelle mondiale. En peu de temps, la NSA s'est mise à collecter toutes les deux heures une quantité de données équivalente à celle du recensement américain.

L'agence stockait toutes ces données dans ses propres locaux sécurisés, mais une telle concentration n'était pas sans conséquences. Les données personnelles de presque tous les individus du monde entier se trouvaient soudain à une touche de clavier de n'importe quel analyste de la NSA. En outre, le problème des fuites se posait de façon accrue.

Scandalisé par cette gigantesque collecte de l'ombre, Edward Snowden, alors consultant pour la NSA, a téléchargé des milliers de fichiers secrets depuis un serveur à Hawaï, s'est embarqué sur un vol pour Hong Kong et a remis les documents à la presse.

PRINCIPE 1

Éparpiller la botte de foin

K. Alexander se trompait sur la recherche d'aiguilles dans une botte de foin. On n'a pas besoin de toute la botte, mais juste de la capacité d'en examiner n'importe quelle partie. Non seulement le stockage d'énormes quantités de données dans un même endroit n'est pas nécessaire, mais il présente un danger aussi bien pour les espions que pour les espionnés. Pour les gouvernements, cela rend les fuites dévastatrices plus probables. Pour les individus, cela crée un risque sans précédent de violation de la vie privée.

Les révélations d'E. Snowden ont montré qu'entre les mains du gouvernement, les données massives sont devenues bien trop concentrées. La NSA et les autres organisations gouvernementales devraient laisser les données en place, sous forme chiffrée et sous la surveillance de l'organisme qui a créé la base de données. En outre, il faudrait stocker séparément les différents types de données : les informations financières dans une base de données à tel endroit, les renseignements médicaux à tel autre endroit, etc. De façon générale, les informations sur les individus devraient être traitées à part. La NSA, ou toute autre entité ayant une raison légale de le faire, sera encore capable d'examiner n'importe quelle partie de cette vaste botte de foin. Elle ne pourra simplement plus stocker la botte entière dans un seul centre de serveurs.

Le plus simple est alors de stopper l'accumulation des données par les agences gouvernementales. Laissons les compagnies de télécommunication et d'Internet garder leurs enregistrements. S'empressez de détruire les centres de données de la NSA n'aurait pas une grande utilité, car leur contenu et les logiciels associés seront bientôt périmés.

La NSA n'abandonnera probablement pas ses activités de collecte de données sans une loi qui l'y oblige ou un ordre de l'exécutif. Pourtant, ce serait dans son intérêt, et les autorités semblent le savoir. En 2013, Ashton Carter, alors adjoint du Secrétaire de la Défense, a diagnostiqué : « L'échec [l'affaire Snowden] a pour origine deux pratiques que nous devons abolir [...]. Il y avait une énorme quantité d'informations concentrée en un endroit. C'est une erreur. » Eten second lieu, « un individu a reçu l'autorité pour



Les gouvernements et les industries ont toujours eu besoin de rassembler des informations sur les individus, par exemple lors des recensements. Mais un saut qualitatif a été franchi avec la collecte de données sur des populations entières par une agence secrète, leur stockage dans des salles de serveurs clandestines et leur exploitation presque sans contrôle extérieur. Il n'est donc pas surprenant que les révélations d'E. Snowden aient déclenché un débat public intense.

Jusqu'ici, ce débat s'est surtout focalisé sur les dimensions morales et politiques du problème, tandis que les aspects techniques et structurels ont peu retenu l'attention. Pourtant, ils sont essentiels et permettraient de mettre en place certains garde-fous. En outre, en matière de collecte et d'utilisation des données massives (ou *big data*), les pratiques gouvernementales sont inadéquates. Ces pratiques, ainsi que leurs processus d'évaluation, doivent évoluer aussi vite que les techniques. Il n'existe pas de solution simple, mais on devrait appliquer quelques principes de base. Présentons-les.

accéder à cette information et la déplacer. Ce n'aurait pas dû être le cas non plus. » Des bases de données chiffrées, réparties sur différents systèmes informatiques, auraient non seulement compliqué une fuite de ce type, mais elles protégeraient aussi contre des cyberattaques venues de l'extérieur. Une intrusion ne donnerait accès qu'à une partie de la base de données. Même des gouvernements autoritaires y trouveraient leur intérêt : la concentration des données faciliterait un piratage massif par des individus qui se seraient introduits dans un centre de stockage.

Répartir les données aiderait aussi à protéger la vie privée, parce que cela rend possible l'analyse des « schémas de communication » entre les bases de données et les opérateurs humains. Chaque fois que quelqu'un rechercherait un élément particulier ou établirait des statistiques, cette opération laisserait une signature caractéristique, composée d'un réseau de liens et de transmissions entre bases de données. On pourrait utiliser ces signatures, métadonnées à propos de métadonnées, pour surveiller les opérations réalisées.

Considérons l'analogie suivante : au sein d'une entreprise, quand les schémas de communication sont visibles (par exemple lorsque des lettres sont transmises d'un service à l'autre), les employés peuvent identifier ceux qui correspondent à des opérations normales, même si les opérations elles-mêmes (le contenu des lettres) leur demeurent cachés. Supposons que le service financier se mette à examiner une quantité anormale de données privées sur la santé des employés : la personne chargée de garder à jour ces informations peut s'en apercevoir et en demander la raison. De même, structurer les opérations liées aux données massives de façon à créer des métadonnées à propos de métadonnées rendrait la surveillance possible. Les sociétés de télécommunication accèderaient à une certaine traçabilité de leurs données. Des associations civiles indépendantes et la presse pourraient s'assurer que les agences gouvernementales ne vont pas trop loin. Avec les métadonnées sur les métadonnées, nous serions capables de faire à la NSA ce que la NSA fait aux autres.

■ L'AUTEUR



Alex PENTLAND est directeur du Laboratoire de dynamique humaine du MIT, aux États-Unis, et codirige les projets du Forum économique mondial en matière de *big data* et données personnelles.



EDWARD SNOWDEN, ALORS CONSULTANT POUR LA NSA, a rendu public en 2013 le programme de surveillance de masse exercé par l'agence.

■ BIBLIOGRAPHIE

A. Pentland, *Social Physics: How Good Ideas Spread - The Lessons from a New Science*, Penguin Press, 2014.

Personal Data: The Emergence of a New Asset Class, World Economic Forum, 2011, www.weforum.org/reports/personal-dataemergence-new-asset-class

A. Pentland, *Orienter la société grâce aux données massives*, *Pour la Science* n° 443, nov. 2013.

PRINCIPE 2

Sécuriser les transmissions

L'élimination des grands centres de données de la NSA n'est qu'une des étapes vers le respect de la vie privée. Il importe aussi de sécuriser le stockage et la transmission des données, notamment *via* le chiffrement. Appliquer cette forme de protection est particulièrement urgent dans un monde où la cybercriminalité et les menaces de cyber-guerre se développent.

Chaque utilisateur de données personnelles – gouvernement, entreprise ou individu –, devrait suivre des règles de sécurité de base. Il faudrait que le partage de données ne soit autorisé qu'entre des systèmes ayant des niveaux de sécurité équivalents. Chaque opération devrait requérir une chaîne fiable de certificats d'identité, afin de savoir d'où viennent les données et où elles vont. Les métadonnées utilisées devraient être contrôlées et les entités qui s'en servent soumises à diverses vérifications, comme on le fait pour lutter contre la fraude touchant les cartes de crédit.

Un bon modèle est ce qu'on appelle un réseau de confiance. Un tel réseau garde la trace des autorisations accordées aux utilisateurs pour chaque opération sur les données, en prenant en compte un cadre légal qui spécifie ce qui peut ou ne peut pas être fait, ainsi que les conséquences d'une violation des autorisations. Grâce à cet historique, les réseaux de confiance peuvent être automatiquement audités afin de vérifier que les données ne sont pas utilisées de façon abusive.

Ces réseaux se sont révélés à la fois sûrs et robustes. Le plus connu est celui de la Société pour les télécommunications financières entre les banques à l'échelle mondiale (SWIFT, pour *Society for Worldwide Interbank Financial Telecommunication*), par lequel quelque 10 000 banques et autres organisations transfèrent de l'argent. Le réseau de SWIFT n'a jamais été piraté (pour autant que nous le sachions).

Lorsqu'on lui a demandé pourquoi il s'était attaqué aux banques, le cambrioleur Willie Sutton aurait répondu : « parce que c'est là que se trouve l'argent ». Aujourd'hui, l'argent se trouve dans le réseau de SWIFT,

La solution dans une décentralisation extrême ?

Si les pratiques de la NSA ont causé un scandale international, les agences de renseignement françaises ne sont pas en reste pour la surveillance téléphonique et électronique de grande envergure. Moins d'un mois après les révélations d'Edward Snowden, l'interception des communications privées en France, aux frontières de la légalité, était dénoncée par les médias.

Cette dérive résulte de la centralisation des données, comme l'explique Alex Pentland dans cet article, et du fait qu'il soit devenu trivial de les consulter et de les croiser. Au-delà des pratiques des agences de renseignement, l'ère des données massives est confrontée à des enjeux contradictoires : comment à la fois publier des données d'utilité publique (recensement, fréquentation du métro, géolocalisation pour le covoiturage, etc.) et protéger la vie privée des individus ?

Depuis près d'une dizaine d'années, l'équipe Systèmes d'information sécurisés et mobiles de Inria (Institut national de recherche en informatique et

en automatique), à Paris, dont je suis membre associé, travaille sur le projet PlugDB (pour *Plug Database*, littéralement base de données à brancher). Ce projet se fonde sur des principes proches de ceux présentés par A. Pentland, en particulier la décentralisation des données, tout en allant plus loin sur la sécurité et la confiance. L'élément central du dispositif est un petit appareil sécurisé connectable à un ordinateur. Il permet aux individus de stocker leurs données ou des liens sur ces données, et surtout d'en contrôler l'accès, le partage, la modification et la destruction.

C'est au sein même de ce dispositif hautement sécurisé

que s'exécutent les applications de gestion de données, et non dans un serveur d'Internet ou sur un ordinateur. Il faudra alors que les concepteurs d'applications fournissent les logiciels nécessaires pour les faire fonctionner. Le dispositif est sécurisé même contre l'utilisateur : quand ce dernier souhaite utiliser un logiciel, il est assuré que c'est bien lui qui s'exécute, mais il ne peut ni voir ni modifier le code sous-jacent. Les concepteurs sont alors libres de publier ou non le code, pour des raisons de transparence ou de secret industriel.

Prenons l'exemple de l'application *Google Flu Trends*, qui permet de prévoir les épidémies de grippe. Même si Google garantit contractuellement l'anonymat des utilisateurs et explique n'avoir besoin que de données agrégées (par exemple le nombre de fois que certains mots clés apparaissent dans une zone géographique),

il stocke en réalité de manière centralisée l'intégralité des requêtes posées, ainsi que différents paramètres liés à l'utilisateur (telle l'adresse IP). Et ce pendant plusieurs années ! Ces données sont à la merci d'un piratage et d'un usage abusif par Google ou par les États faisant pression sur l'entreprise.

Avec un instrument comme PlugDB, l'utilisateur n'a pas besoin de dévoiler ses données personnelles, dont il reste maître. Il peut choisir la précision de celles qui sont divulguées, surveiller les accès et leur fixer une date limite, etc. La confiance est permise par l'utilisation d'un système d'exploitation transparent (dont le code est librement consultable) et de matériel sécurisé, qui n'autorise pas la falsification des données, même par leur détenteur.

- Benjamin Nguyen
Institut national des sciences appliquées (INSA), Bourges

où des milliers de milliards de dollars transitent chaque jour. Grâce notamment à ses systèmes de contrôle de métadonnées et de vérification automatique, ce réseau de confiance repousse les cambrioleurs et assure un trajet fiable des fonds jusqu'à la destination souhaitée.

Autrefois, les réseaux de confiance étaient complexes et leur fonctionnement coûteux, mais la démocratisation des capacités de calcul les a rendus accessibles à de petites organisations, voire à des individus. En partenariat avec l'Institut de conception guidée par les données, à Boston, mon équipe de l'Institut de technologie du Massachusetts (MIT) a participé à la construction de centres de données personnelles ouverts, ou *open PDS* (pour *Personal Data Store*), une version grand public de ce type de système. À l'heure actuelle, nous les testons avec des partenaires industriels et gouvernementaux. L'idée est de permettre à tous un partage de données sensibles, notamment sanitaires et financières, avec un niveau de

sécurité équivalent à celui de SWIFT. Quand les réseaux de confiance se répandront, il deviendra plus sûr d'échanger des données, dont l'enregistrement dans des architectures de stockage réparties et sécurisées protégera à la fois les individus et les organisations ; ainsi, les mauvaises utilisations des données massives devraient être évitées.

PRINCIPE 3

Toujours expérimenter

Le dernier principe, peut-être le plus important, est d'admettre que nous n'avons pas toutes les réponses et qu'il n'y a pas de solution définitive. Nous devons continuellement nous adapter. L'ère du numérique est totalement nouvelle, de sorte que nous ne pouvons pas nous contenter de méthodes classiques.

Sous la pression des autres pays, des citoyens et des entreprises du Web, la Maison Blanche a déjà proposé de limiter

la surveillance exercée par la NSA. Dans un effort pour restaurer la confiance, les entreprises du Web cherchent à obtenir le droit de diffuser des informations sur les requêtes de l'agence – des métadonnées sur des métadonnées. En mai 2014, la Chambre des Représentants a voté une loi qui, bien que jugée insuffisante par de nombreux défenseurs de la vie privée, commençait à restreindre les collectes massives de données et à introduire un peu plus de transparence (cette loi a cependant été refusée par le Sénat en novembre).

Ces mesures vont dans la bonne direction, mais nous ne pourrions trouver que des solutions à court terme. Les techniques évoluent et les procédures gouvernementales doivent suivre le rythme. Finalement, le changement le plus important serait que nous décidions de conduire en continu des expériences et des tests à petite échelle, afin d'innover sans cesse et de trier ce qui fonctionne de ce qui ne fonctionne pas. ■