



CONSEIL GÉNÉRAL DE L'ÉCONOMIE
DE L'INDUSTRIE, DE L'ÉNERGIE ET DES TECHNOLOGIES

TELEDOC 792
BATIMENT NECKER
120, RUE DE BERCY
75572 PARIS CEDEX 12

N° 2015/36/CGE/SG

13 mai 2016

Modalités de régulation des algorithmes de traitement des contenus

Rapport à

Madame la Secrétaire d'Etat chargée du numérique

Établi par

Ilarion PAVEL
Ingénieur en Chef des Mines

Jacques SERRIS
Ingénieur Général des Mines

SOMMAIRE

SYNTHESE	4
TABLE DES RECOMMANDATIONS.....	6
1 Introduction	7
1.1 La révolution de l'apprentissage	7
1.2 Les algorithmes de traitement des contenus prennent des décisions.....	10
2 Trois scénarios de développement	11
2.1 Les algorithmes deviennent des commodités en mode service (SaaS).....	11
2.2 Les algorithmes « maitres du monde »	13
2.3 Le développement de silos de données dans le Cloud	14
3 L'analyse des enjeux.....	15
3.1 Enjeux économiques.....	16
3.1.1 Les marchés financiers.....	17
3.1.2 Le commerce électronique	20
3.1.3 La publicité en ligne	23
3.1.4 Le domaine des médias, produits culturels et réseaux sociaux.....	25
3.1.5 L'emploi et la gestion des talents	27
3.2 Enjeux sociétaux.....	29
3.3 Enjeux juridiques	32
4 Quelles pratiques de régulation ?.....	33
4.1 Les actions de la Commission Européenne	33
4.2 L'exemple américain.....	36
4.3 Une initiative allemande	37
4.4 Faut-il tester les algorithmes eux-mêmes ?	38
5 Des pistes d'action.....	39
5.1 Une plateforme collaborative scientifique française pour tester les algorithmes.....	39
5.2 La montée en compétence des autorités de contrôle	42
5.3 Le développement de pratiques d'autorégulation	43
5.3.1 Communiquer sur le traitement des données et le fonctionnement des algorithmes	44
5.3.2 Promouvoir de bonnes pratiques dans quelques secteurs clé	45
5.4 L'engagement citoyen	47

ANNEXES	50
Annexe 1 : Lettre de mission	50
Annexe 2 : Liste des acronymes utilisés	52
Annexe 3 : Liste des personnes rencontrées ou interrogées	54
Annexe 4 : Glossaire	57
Annexe 5 : Bibliographie	59

SYNTHESE

La secrétaire d'Etat chargée du numérique a confié au Conseil général de l'économie une mission d'analyse et de propositions relative aux modalités de régulation des algorithmes de traitement des contenus. Il s'agit des algorithmes utilisés sur le web pour filtrer des contenus, ordonner des réponses à une recherche, sélectionner les informations pertinentes, faire des recommandations, calculer un score, prédire un évènement ou un risque.

Ces algorithmes peuvent être très complexes, composés de multiples briques logicielles : Google indique que les algorithmes de son moteur de recherche prennent en compte 200 critères, Netflix décompose son moteur de recommandation en 12 algorithmes différents. Parmi ces briques logicielles, l'apprentissage machine connaît depuis quelques années un développement fulgurant, lié à l'augmentation de la puissance de calcul (utilisation de cartes graphiques pour réaliser un très grand nombre d'opérations en parallèle) et à la disponibilité de grandes quantités de données permettant l'apprentissage : on fait croître de tels algorithmes, plus qu'on ne les écrit.

Par la nature de leur architecture et de leur fonctionnement, il est très difficile de comprendre le processus de raisonnement interne des algorithmes d'apprentissage machine, et donc d'expliquer un résultat particulier. Ces algorithmes posent donc des problèmes de transparence et de contrôle originaux. Les algorithmes sont inséparables des données qu'ils traitent et des plateformes qui les utilisent pour proposer un service. L'originalité du point de vue de ce rapport est cependant de s'intéresser aux algorithmes eux-mêmes et de faire des propositions pour de meilleures pratiques concernant leur développement, leur utilisation et leur contrôle, tout en préservant l'innovation.

Trois scénarios de développement de « l'économie des algorithmes » sont en cours de déploiement en parallèle et poseront des questions de régulation différentes. Selon le 1^{er} scénario, les algorithmes se banalisent au sein de l'économie du logiciel, en large partie en open source. Cette fragmentation pose des problèmes de contrôle du traitement des données et de la performance des algorithmes, auxquels il faudra apporter des réponses par la certification des composants logiciels. Selon le 2nd scénario, des leaders de l'intelligence artificielle conservent une longueur d'avance et agrègent des écosystèmes dédiés autour d'algorithmes propriétaires aux performances inégalées. Ces grands systèmes posent des problèmes de concurrence, de position dominante sur certains marchés et d'opacité pour les acteurs extérieurs, à commencer par les régulateurs eux-mêmes. Selon le 3^{ème} scénario, des producteurs de données et des spécialistes du traitement algorithmique s'organisent en silos indépendants pour acquérir une taille critique, tant en termes de masse de données que de compétences en traitement. Cette organisation en silo pose des problèmes de conditions d'accès pour les nouveaux entrants, ainsi que de propriété et de portabilité des données.

Trois questions sont posées à la mission :

- **L'analyse des enjeux économiques, sociétaux et juridiques.** Les enjeux concurrentiels sont bien connus, et rentrent largement dans le cadre de l'économie des plateformes. Mais il y a encore peu d'analyses de l'impact économique des algorithmes. La prise de conscience des enjeux sociétaux est récente, qu'il s'agisse des effets sur les comportements des usagers, isolés dans des « bulles de filtres » ou des risque de discrimination pour l'accès à la santé, à l'emploi, au logement, au crédit, à l'éducation. Les enjeux juridiques sont essentiellement liés

à la capacité d'analyse des pouvoirs publics, pour la vérification de la conformité aux règles de droit. Pour une vision plus concrète de ces enjeux, la mission s'est livrée à une rapide revue de quelques domaines : marchés financiers, commerce électronique, publicité en ligne, médias, produits culturels et réseaux sociaux, emploi et gestion des talents.

- **L'étude des dispositions de régulation.** Pour être efficace face à des acteurs mondialisés, la France se place dans un cadre de régulation européen. Ce cadre est en train d'évoluer, avec l'entrée en vigueur d'un nouveau règlement sur la protection des données et suite à la consultation sur les plateformes menée par la Commission Européenne. Avec la loi République numérique, la France est plutôt en avance : définition des plateformes, obligations de transparence des algorithmes publics, projet de plateforme collaborative expérimentale, réflexion éthique animée par la CNIL. Deux initiatives internationales intéressantes sont présentées. Aux Etats-Unis, un Office of Technology Research and Investigation (OTRI) a été créé au sein de la Federal Trade Commission (FTC), notamment pour promouvoir des travaux de tests d'algorithmes. En Allemagne, le ministère de la justice finance deux réseaux de plateformes dans les länder, les « veilleurs de marché » (Marktwächter), l'un pour les services financiers, l'autre pour l'économie numérique, s'appuyant sur des associations de consommateurs.
- **Le développement des outils de droit souple.** Dans ce domaine, beaucoup reste à faire. Les grandes entreprises du numérique ont évidemment leurs propres procédures de contrôle interne, mais les bonnes pratiques professionnelles sont rares et récentes (code d'engagements volontaires dans la publicité - Digital Advertising Alliance (DAA) de 2015). Les pratiques de test ou de certification des algorithmes par des tiers sont embryonnaires.

Ce rapport ne propose pas une nouvelle régulation sectorielle qui s'appliquerait aux algorithmes. En revanche, il souligne qu'il **faut développer la capacité à tester et contrôler les algorithmes eux-mêmes**. Pour y parvenir la mission propose cinq pistes d'action :

- Créer une plateforme collaborative scientifique de développement d'outils logiciels et de méthodes de test d'algorithmes ;
- Créer un « bureau des technologies de contrôle de l'économie numérique » au sein de la DGCCRF ;
- Pour les entreprises, communiquer sur le fonctionnement des algorithmes visibles pour l'utilisateur et identifier l'équipe où la personne responsable (« chief algorithm officer ») ;
- Développer, dans les domaines de l'emploi, de la santé, de la finance et de l'assurance, les réflexions sur les bonnes pratiques pour de nouveaux services utilisant des algorithmes de traitement des contenus ;
- Former au respect des obligations de transparence inscrites dans la loi République numérique, les agents opérant un service public utilisant un algorithme.

La régulation peut contribuer à préserver une image positive des progrès et des performances des technologies d'intelligence artificielle, et donc des femmes et des hommes qui travaillent dans ce domaine. C'est essentiel pour continuer à attirer les jeunes générations dans les filières de formation correspondantes (mathématiques, ingénieurs ou « data scientists ») et pour créer des emplois. Trouver des solutions aux problèmes émergents posés par les progrès de l'intelligence artificielle est une dimension de la confiance dans l'économie numérique.

TABLE DES RECOMMANDATIONS

Avertissement : l'ordre dans lequel sont récapitulées ci-dessous les recommandations du rapport ne correspond pas à une hiérarchisation de leur importance mais simplement à leur ordre d'apparition au fil des constats et analyses du rapport.

- | | |
|-----------------------------|---|
| Recommandation n° 1. | Créer une plateforme collaborative scientifique, destinée à favoriser le développement d'outils logiciels et de méthodes de test d'algorithmes, ainsi que de promouvoir l'utilisation de ces outils et méthodes. Cette plateforme permettrait de faire appel à des équipes de recherche, des enseignants, des étudiants ou des experts, publics ou privés..... 41 |
| Recommandation n° 2. | Créer une cellule de contrôle spécialisée « bureau des technologies de contrôle de l'économie numérique », pour l'ensemble des pouvoirs publics, implantée au sein de la DGCCRF..... 42 |
| Recommandation n° 3. | Communiquer sur le fonctionnement des algorithmes. Quand un algorithme est affiché explicitement, ou perceptible pour l'utilisateur, identifier l'équipe où la personne responsable de son fonctionnement (« chief algorithm officer ») et communiquer au nom de cette équipe, pour rendre visible l'action humaine qui est aux commandes derrière l'algorithme. 45 |
| Recommandation n° 4. | Développer, dans les secteurs de l'emploi, de la santé, de la finance et de l'assurance, les réflexions avec les parties prenantes pour identifier de nouveaux services utilisant des algorithmes de traitement des contenus. Pour ces « services algorithmiques », identifier un pilote chargé de réunir un forum pour établir et promouvoir au niveau international des règles de bonnes pratiques. 47 |
| Recommandation n° 5. | Lancer un programme de formation à l'attention des agents opérant un service public utilisant un algorithme, pour les former au respect des obligations de transparence et de communication inscrites dans la loi République numérique..... 49 |

1 INTRODUCTION

Utilisés par les babyloniens il y a deux millénaires, progressant avec Euclide et Eratosthène, ou plus récemment avec Alain Turing ou John Von Neumann, les algorithmes sont entrés dans la vie économique après la deuxième guerre mondiale.

Un algorithme utilise des données d'entrée, les traite suivant des instructions précises et fournit un résultat. Aujourd'hui, le développement rapide de l'Internet et l'utilisation généralisée des moyens informatiques ont conduit à générer une masse énorme de données hétérogènes : chaque jour Google reçoit 3,3 milliards de requêtes, qu'il traite sur quelque 30 000 milliards de pages indexées, Facebook distribue 4,5 milliards de "likes" et reçoit 350 millions de photos, les 3 milliards d'internautes échangent 144 milliards de courriers électroniques. La quantité de données augmentera encore d'au moins un facteur dix avec l'arrivée des objets communicants (Internet des objets), qui feront bientôt partie de notre environnement. Ces données peuvent représenter un potentiel économique considérable, à condition de savoir les exploiter convenablement, ce qui demande le développement permanent d'algorithmes appropriés.

Par lettre de mission datée du 27 octobre 2015, la secrétaire d'Etat chargée du numérique a demandé au Conseil général de l'économie de faire des propositions relatives aux modalités de régulation des algorithmes de traitement des contenus (voir lettre de mission en annexe 1). Il s'agit des algorithmes utilisés sur le web pour filtrer des contenus, ordonner des réponses à une recherche, sélectionner les informations pertinentes, faire des recommandations, calculer un score ou prédire un événement (risque de défaut de paiement par exemple).

Parmi les algorithmes de traitement des contenus les plus utilisés, se trouve celui du moteur de recherche de Google. Initialement fondé sur l'évaluation de la notoriété d'un site web (PageRank : plus une page reçoit de liens issus d'autres sites, plus sa notoriété est forte), il prend désormais en compte 200 critères ou signaux, comme le comportement des visiteurs, l'évolution du contenu, etc. Un autre algorithme bien connu est celui d'Amazon, dont le principe de base est le filtrage collaboratif par objets : on calcule la similitude des préférences entre les produits vendus, à partir des notes d'appréciation données par divers clients. Lorsqu'un client achète un produit, on lui recommande alors d'autres produits ayant les similitudes les plus élevées avec le produit qu'il vient d'acheter.

Ces algorithmes de traitement des contenus sont en général complexes, composés d'une multitude de briques logicielles, et doivent être souvent révisés pour optimiser leur fonctionnement dans un environnement en changement permanent. Une de ces briques logicielles connaît aujourd'hui un développement fulgurant, c'est l'apprentissage machine.

1.1 La révolution de l'apprentissage

« C'est l'apprentissage qui anime les systèmes de toutes les grandes entreprises d'Internet. Elles l'utilisent depuis longtemps pour filtrer les contenus indésirables, ordonner des réponses à une recherche, faire des recommandations, ou sélectionner les informations intéressantes pour chaque utilisateur » - L'apprentissage profond : une révolution en intelligence artificielle, leçon inaugurale au collège de France par Yan LeCun, directeur de la recherche en intelligence artificielle de Facebook, février 2016.

L'apprentissage machine (Machine Learning) est une branche de l'intelligence artificielle, fondée sur des méthodes d'apprentissage et d'acquisition automatique de nouvelles connaissances par les ordinateurs, utilisant les exemples, les cas ou les expériences passées, ou à partir des propres expériences ou explorations de la machine.




Figure 1 : Apprentissage machine pour la reconnaissance d'image – on fait passer en boucle, à travers le système, les données d'entrée et valeurs cibles connues ; à chaque erreur on corrige systématiquement les paramètres internes du modèle. Lorsqu'il n'y a plus d'erreur, l'apprentissage est terminé et le modèle est prêt à être utilisé pour classer des séries inconnues de données.

Parmi les méthodes les plus répandues d'apprentissage machine on compte les réseaux de neurones, dont le principe est inspiré du fonctionnement du cerveau : on organise des unités de traitement simples (neurones) dans une architecture en couches et hautement parallèle, capable d'effectuer des opérations complexes, se traduisant par un système de classification très puissant. L'apprentissage se fait à partir de nombreux exemples d'entrée/sortie, en effectuant des petites modifications répétées au niveau des poids des connexions des neurones individuels. Cela rend difficile la compréhension du processus de raisonnement interne, et par conséquent une explication simple du résultat de sortie.




Figure 2 : Réseau de neurones à deux couches cachées – chaque entrée est connectée aux neurones de la première couche, eux-mêmes connectés aux neurones de la deuxième, à leur tour connectés à la sortie. L'intensité de ces multiples connexions constitue les paramètres internes du modèle, qui seront déterminés par l'apprentissage.

On utilise les réseaux des neurones quand il est plus important d'obtenir un résultat dans une situation complexe que de comprendre comment celui-ci a été obtenu. Les applications sont nombreuses : la reconnaissance d'images, en particulier l'écriture manuscrite, la conduite autonome d'un véhicule, la traduction automatique, l'aide au diagnostic, l'analyse de crédit, etc.

Bien qu'inventés dans les années 1950, les réseaux de neurones ont connu des hauts et des bas dans leur développement, et c'est en 2012 qu'on assiste à une révolution. L'amélioration de la puissance des ordinateurs, en particulier celle des cartes graphiques, due au développement du jeu vidéo, a permis la réalisation d'architectures spécifiques, avec un très grand nombre de neurones et un nombre élevé de couches (Deep Learning). Celles-ci se sont avérées si performantes, que dans un laps de temps d'un an et demi, une large partie de la communauté des chercheurs en apprentissage machine a basculé vers ce type d'architecture¹, sans toutefois que l'on comprenne bien pourquoi cela marche aussi bien. Plusieurs applications pratiques en ont bénéficié : la reconnaissance et l'indexation d'images, la navigation de robots, la reconnaissance de la parole, la conduite automobile autonome et la traduction automatique.

L'apprentissage exposé précédemment s'appelle *supervisé* : on utilise des données d'entrée et de sortie connues pour déterminer, corriger et améliorer les paramètres internes de l'algorithme.

Une autre méthode d'apprentissage dite *par renforcement*, fait également appel à des itérations sur des données d'entrée et de sortie, mais plutôt que de corriger chaque erreur, on optimise une fonction qui additionne des « récompenses » chaque fois que le modèle fournit un bon résultat. C'est un des éléments clés de l'algorithme du jeu de Go qui a battu récemment le champion mondial².

Enfin, une dernière méthode porte sur l'*apprentissage non-supervisé* : cette fois-ci la structure des données d'entrée/sortie n'est pas connue a priori, c'est l'algorithme qui doit les structurer lui-même. Cependant, il n'y a pas actuellement de principes satisfaisants pour effectuer ce type d'apprentissage, qui fait l'objet d'intenses recherches. Sa mise au point pourrait conduire à d'importantes conséquences pour l'économie numérique.

Par rapport aux algorithmes classiques, l'apprentissage machine pose des problèmes de transparence et contrôle des algorithmes. En effet, dans le cas d'un algorithme classique de *scoring* pour un crédit bancaire, par exemple, il est relativement facile d'expliquer un refus à une personne : l'algorithme prend en compte ses données personnelles (niveau de salaire, âge, profession, durée du dernier emploi, etc.) et les utilise pour calculer un score qui est comparé avec une valeur seuil. En revanche, un algorithme d'apprentissage machine prend en compte l'expérience passée de l'établissement bancaire avec des personnes ayant obtenu un crédit : les données personnelles du

¹ Yoshua Bengio : « C'est la fin d'une croyance sur les réseaux de neurones », La Recherche no. 507, jan. 2016.

² En 1997, lors de la victoire aux échecs de l'ordinateur Deep Blue contre Gary Kasparov, il était impensable qu'un jour on puisse développer un algorithme qui pourrait gagner au jeu de Go contre un humain : le nombre de parties possibles était beaucoup trop grand (10^{600} pour le Go, par rapport à 10^{120} pour le jeu d'échecs).

nouveau demandeur sont utilisées pour calculer un risque de défaut de paiement selon une multitude de paramètres internes disséminés dans toute la structure de l'algorithme. Par la nature de leur architecture et de leur fonctionnement, il est très difficile de comprendre le processus de raisonnement interne des algorithmes d'apprentissage machine, et donc d'expliquer un résultat particulier.

La structure d'un algorithme classique est déterminée lors de sa conception : les paramètres de l'algorithme et la suite des étapes à suivre pour aboutir à un résultat sont fixés dès le début. En revanche, les algorithmes d'apprentissage machine utilisent les données pour déterminer leurs paramètres de fonctionnement au fur et à mesure de l'apprentissage. Ils peuvent évoluer au fil du temps avec la prise en compte de nouvelles données et, éventuellement, avec l'élimination des anciennes. Avec l'apprentissage machine, la technologie des algorithmes fait un saut qualitatif : par leur nature, ces algorithmes augmentent leur taille et s'améliorent de manière automatique, grâce aux jeux de données, sans rajouter des lignes de codes "à la main". Pour reprendre l'expression d'Yves Caseau³, on fait croître les algorithmes plus qu'on ne les écrit (« *systems that are grown, not designed* »). C'est particulièrement important pour les algorithmes de traitement des contenus, qui font largement appel à des briques logicielles d'apprentissage machine. La séparation entre les paramètres de l'algorithme et les corpus de données qu'il traite n'existe plus.

1.2 Les algorithmes de traitement des contenus prennent des décisions

Ces corpus de données sont les traces de la navigation des internautes. Les plateformes (ordinateurs, serveurs), présentent des contenus, des services ou des applications aux internautes⁴. De plus en plus d'objets sont connectés à l'Internet, mobiles (smartphone de l'internaute mesurant sa géolocalisation) ou fixes (caméras de vidéosurveillance). Plateformes, internautes et objets connectés échangent des données, qui sont récupérées et traitées par des algorithmes, qui produisent à leur tour d'autres données. Seule une petite partie de ces échanges est perçue par l'internaute, autour des « contenus, applications ou services » auxquels il s'intéresse, le reste appartient au domaine des « traces ».




Figure 3 : Sur le web, l'internaute ne perçoit qu'une faible partie des échanges de données, il s'intéresse aux contenus, applications et services et n'a pas toujours conscience des multiples traces de ses connexions.

³ <http://informationsystemsbiology.blogspot.fr/2015/06/strong-artificial-intelligence-is.html>

⁴ Le réseau de communication est jugé neutre, c'est le principe de la neutralité de l'Internet.

En revanche, rien n'échappe aux algorithmes, qui sont seuls capables de traiter les énormes masses de données produites chaque jour sur le net. Ils décident ce qui sera visible ou pas, et proposent des réponses à des questions subjectives : qu'est-ce qui est important ? Parmi 1000 postulants, qui sont les 50 meilleurs candidats pour ce poste ?

Depuis deux ans, les utilisateurs sont de plus en plus conscients de cette réalité, qu'il s'agisse des individus ou des entreprises, à qui les données sont présentées comme leur « mine d'or ». Cette prise de conscience est souvent positive, avec le développement de nouveaux services personnalisés, mais elle n'est pas exempte d'interrogations, voire de réactions de méfiance, auxquelles ce rapport propose d'apporter des réponses.

Le « Big Data » et les plateformes numériques font l'objet d'analyses importantes et d'une régulation en cours de modernisation. L'originalité du point de vue de ce rapport est de s'intéresser aux algorithmes⁵ eux-mêmes et de faire des propositions pour de meilleures pratiques concernant leur développement, leur utilisation et leur contrôle, tout en préservant l'innovation.

2 TROIS SCÉNARIOS DE DÉVELOPPEMENT

Nous présentons trois scénarios de développement des algorithmes. L'ambition de cet exercice est modeste : il ne s'agit pas de prévoir l'avenir du domaine et de ses applications, qui dépendent d'un grand nombre de paramètres, tels que le développement de la science des algorithmes, l'évolution de la loi de Moore ou le déploiement de l'Internet des objets, mais de présenter trois tendances qui sont déjà à l'œuvre aujourd'hui et les principales questions de régulation qui leur sont associées.

Selon le 1^{er} scénario, les algorithmes se banalisent au sein de l'économie du logiciel, en large partie en open source. Selon le 2nd, des leaders de l'intelligence artificielle conservent une longueur d'avance et agrègent des écosystèmes dédiés autour d'algorithmes propriétaires aux performances inégalées. Selon le 3^{ème}, producteurs de données et spécialistes du traitement algorithmique s'organisent en silos indépendants pour acquérir une taille critique, tant en termes de masse de données que de compétences en traitement.

2.1 Les algorithmes deviennent des commodités en mode service (SaaS)

C'est le scénario présenté par Peter Sondergaard, senior vice-président et responsable mondial de la recherche du cabinet Gartner, s'adressant à un parterre de 8 500 DSI et responsables informatiques⁶ : « *L'économie de l'algorithme sera à l'origine du prochain grand saut de l'évolution du machine to machine vers l'Internet des objets. Les produits et services seront déterminés selon la sophistication de leurs algorithmes et de ce qu'ils offriront. Les organisations ne seront pas seulement évaluées en fonction de leurs gros volumes de données mais par leurs algorithmes qui transformeront ces données en actions pour finalement impacter le consommateur* ».

⁵ Dans la suite du rapport, « algorithme » sera employé comme raccourci pour « algorithme de traitement des contenus »

⁶ Gartner Symposium/ITxpo, Orlando (Floride), octobre 2015

Le foisonnement de l'apprentissage machine

Fin avril 2016, le site Programmableweb affiche **105 API de machine learning**, parmi lesquelles : Amazon Machine Learning, Windows Azure Machine Learning Recommendations, Hutoma, Indico, PredicSis, The IBM Watson Retrieve and Rank API, Guesswork, Wise.io ...

Kaggle, créée en 2010, est une plateforme web en science des données pour l'enseignement, la recherche et l'industrie (*Kaggle helps you learn, work, and play*). Des entreprises ou des universités proposent des challenges en science des données. Les entreprises offrent un prix aux équipes obtenant les meilleures performances. Kaggle affiche plus de 500 000 participants, data scientists de tous niveaux. **Algorithmia**, créée en 2013 et basée à Seattle, est une plateforme de marché collaborative qui permet aux développeurs d'algorithmes de les proposer, avec une tarification à l'usage, à des développeurs d'applications qui les intègrent dans leurs services.

En avril 2016, en machine learning, la Crunchbase recense 733 entreprises spécialisées et Venture Scanner liste environ 390 start-ups, dont 130 développent des outils génériques et 230 des applications. Trois exemples en marketing / gestion de clients :

- **H2O.ai** (35 personnes, fonds levés 33,6 M\$), créée en 2011 à Mountain View (Californie), est l'éditeur d'une plate-forme de machine learning open source, utilisée notamment pour prédire les fraudes, anticiper les désabonnements de clients et améliorer le taux de conversion des ventes par plus de 5 000 entreprises, dont Cisco, PayPal ...
- **PredicSis** (27 personnes) créée en 2013 à Lannion, propose une solution d'analyse prédictive pour le marketing, avec une API de machine learning et un service Churnspotter, pour détecter les clients fragiles avant qu'ils ne s'en aillent.
- **Heuritech** (12 personnes), créée à Paris en 2013, propose des solutions logicielles d'analyse sémantique, de tagging et classement automatiques de textes, images et vidéos, et permet aux entreprises d'améliorer leur connaissance clients et d'anticiper leurs comportements, besoins et actions. Heuritech ambitionne d'être un leader du deep learning en France et anime une communauté de développeurs avec des séminaires réguliers (2000 inscrits). La start-up s'appuie sur les travaux de recherche de deux laboratoires publics, le LIP6 et l'ISIR (UPMC).

Nvidia, leader de la production des cartes graphiques (GPU), propose des modules complets d'intelligence embarquée (cartes graphiques + processeur + logiciel d'apprentissage profond d'un réseau de neurones) pour l'automobile ou les objets connectés.

Selon ce scénario, un marché va s'ouvrir avec la commercialisation des algorithmes propriétaires par les grandes organisations qui les ont développés, pour maximiser leur valeur. **En 2018, des places de marché d'algorithmes devraient voir le jour, combinées avec des outils de « Platform as a Service » (PaaS).** Ce nouveau modèle devrait permettre d'apporter l'analyse avancée à ceux qui n'ont pas les moyens de développer leurs propres algorithmes, tout en sécurisant les transactions et la commercialisation de données brutes. « *Aujourd'hui, la question du partage des données est problématique* » mentionne Alexander Linden, directeur de recherche chez Gartner. « *Les fournisseurs de données ne font généralement pas confiance aux utilisateurs finaux (...). D'autre part, les consommateurs de données n'aiment pas les complexités des licences* ». **Dans les trois ans qui**

viennent, le Gartner ajoute qu'un système de certification sur les composants des outils d'analyse devrait voir le jour. Eux seuls seront en mesure d'exécuter des données sensibles et de les transformer en modèles de notation et d'optimisation. En conséquence, le traitement des données sera contraint de manière à veiller à ce que les données ne puissent être copiées, enregistrées ou subir un projet de rétro-ingénierie.

Scénario n°1 : questions de régulation autour de la qualité des algorithmes

L'intégration de composants logiciels divers pour fournir un service pose plusieurs questions :

- Quel est le niveau d'engagement des fournisseurs de briques logicielles, certains pouvant eux-mêmes assembler différents composants logiciels « out-sourcés » ?
- Comment est garantie l'intégrité des données traitées ?
- In fine, quelle est la qualité (au sens industriel du terme) du service ?

La certification a pour objet d'aider à répondre à ces questions. La compréhension du modèle économique des acteurs qui fabriquent et commercialisent les différentes briques logicielles est également nécessaire pour éviter de mauvaises surprises. Dans ce scénario, l'utilisation des algorithmes relève essentiellement de relations interentreprises. Pour le régulateur, c'est la complexité des services et du traitement des données qui peut poser problème pour s'assurer de la conformité avec le droit : traçabilité, identification de l'origine des non-conformités, attribution des responsabilités ...

2.2 Les algorithmes « maitres du monde »

Quelques systèmes, comme IBM Watson avec le jeu Jeopardy, ou AlphaGo de Google – Deep Mind pour le jeu de Go, ont médiatisé les avancées de l'intelligence artificielle (IA), progressant vers ce que les spécialistes appellent **l'émergence de l'intelligence artificielle forte**. Ces grands systèmes sont complexes, associant de multiples algorithmes, selon différentes technologies. Pour leur développement, surtout depuis deux ans, les grands du numérique américains investissent des milliards de \$ dans des capacités de calculs et de stockage, rachètent de nombreuses start-ups et recrutent les meilleurs spécialistes :

- **Google** est très actif, avec le rachat de nombreuses sociétés dans les domaines de l'IA et de la robotique, dont le très médiatisé rachat de Deep Mind ;
- **IBM**, outre ses développements internes, a beaucoup investi pour intégrer, avec son logiciel phare d'intelligence artificielle Watson, des solutions développées par des start-ups, mais aussi pour avoir accès à des données, notamment médicales ;
- **Facebook** dont le laboratoire « Facebook Artificial Intelligence Research », dirigé par Yan LeCun, a une filiale à Paris depuis 2015, vient de lancer un partenariat avec 25 institutions de recherche en Europe, en commençant par l'Allemagne dans le domaine de la santé ;
- **Microsoft** s'appuie depuis longtemps sur ses propres équipes de recherche (suite Cortana-Bing – Edge, Azure ML), mais a aussi fait récemment quelques acquisitions en IA ;
- **Apple** a intégré l'application SIRI pour la reconnaissance vocale, racheté quelques start-up dont Emotient Inc début 2016, travaillerait sur un véhicule électrique autonome et a signé un partenariat avec IBM Watson dans le domaine de la santé utilisant les objets connectés ;
- **Baidu** a ouvert en 2014, en Californie, un centre de R&D sur l'intelligence artificielle. Pour le diriger, il a recruté Andrew Ng, co-fondateur de Coursera à Stanford (plateforme de cours en ligne) et créateur de la cellule Google Brain d'intelligence artificielle ;

- **Amazon**, outre son moteur de recommandation, commercialise Echo, commandé par l'IA Alexa, travaille sur des robots autonomes et a racheté Orbeus (reconnaissance d'image) ;
- LinkedIn, Salesforce, Pinterest, Twitter, Adobe et Oracle ont racheté quelques start-ups qui développent des applications métiers dans leurs domaines.

De son côté, la Corée du Sud a annoncé en mars 2016 un plan de R&D sur cinq ans dans l'IA, avec de grandes entreprises comme Samsung, LG, Hyundai et SK Telecom, doté d'un financement public de 850 M\$.

Ces entreprises cherchent à rester en pointe en créant des écosystèmes autour d'**algorithmes propriétaires aux performances inégalées**, s'appuyant en amont sur des communautés de développeurs et chercheurs en IA, certaines briques logicielles étant en open source, et en aval sur le développement d'applications chez des partenaires accédant à leurs API. C'est peut-être IBM Watson qui est le plus avancé : à côté de *Watson Health*, la division spécialisée d'IBM dans le domaine de la santé, le *Watson Developer Cloud*, est une plateforme qui associe 400 *Watson Ecosystem partners* développant des produits et services dans les domaines de la santé, des services financiers, de la distribution, de l'éducation, de la musique et du sport, dont une centaine sont déjà commercialisés. En janvier 2016, par exemple, Sopra Steria a annoncé la création d'un centre de compétences cognitives IBM Watson, qui ouvrira à Lille.

Scénario n°2 : questions de régulation autour de l'opacité des algorithmes

Comme le montre l'exemple des moteurs de recherche, une tendance forte de ces grands systèmes (c'est le « *winner takes all* ») est d'évoluer vers de quasi monopôles sur divers marchés.

- Quel sera le niveau de concurrence dans des domaines tels que la santé, la recherche d'emploi, ... ?
- Comment s'assurer que des avancées technologiques ne se traduisent pas par des rentes indues ou des abus de position dominante ?
- Plus généralement, comment développer une capacité de contrôle *extérieure* à ces grands systèmes, pour s'assurer du respect des règles de droit, telle que la non-discrimination ?

Les grandes entreprises maîtrisant ces systèmes opérant au niveau mondial, en Europe, le dialogue entre les régulateurs et ces entreprises devra se tenir au niveau communautaire. Face à la complexité et à l'opacité des systèmes, le régulateur devra développer de nouvelles approches techniques.

2.3 Le développement de silos de données dans le Cloud

Dans ce scénario intermédiaire, l'apprentissage machine reste une technologie accessible mais qui doit être maîtrisée par des équipes de spécialistes, et surtout, dont **la performance dépend de l'accès à de grandes quantités de données**. La forte augmentation du volume des données produites a entraîné le développement d'entrepôts de données dans le Cloud, et ce secteur va continuer à croître avec le déploiement de l'Internet des objets. **Google, Amazon et Microsoft** sont aujourd'hui les leaders de cette offre et proposent de la coupler avec un traitement des données par leurs moteurs analytiques.

Face à ces offres intégrées, certaines plateformes (Facebook, Twitter, Apple ...) peuvent développer une stratégie autonome. D'autres opérateurs cherchent à constituer des alliances entre des métiers

qui ne sont pas concurrents (opérateur télécom, assurance, banque, automobile, domotique, ...), pour atteindre une taille critique en partageant données et capacité de traitement dans une infrastructure commune.

Dans ce marché émergent et en forte croissance, l'intégration de services autour de ces infrastructures ou plateformes aura tendance à précéder l'interopérabilité. Les développeurs de nouveaux produits / services seront alors poussés à faire le choix d'une plateforme pour éviter des coûts de développement trop importants au départ.

On verrait ainsi apparaître de **véritables « silos de données » et leurs écosystèmes associés**.

Scénario n°3 : questions de régulation autour de l'accès aux algorithmes et aux données

La mise en place de silos de données pose des questions :

- De condition d'accès pour les entreprises proposant des services ayant besoin d'utiliser ces données.
- De propriété et de portabilité des données pour les producteurs ou pour les consommateurs.

Le développement des nouveaux services numériques se fait dans un contexte de forte innovation : les opérateurs de silos de données devraient adopter une stratégie d'innovation ouverte pour rester compétitifs, ce qui pourrait modérer les barrières à l'entrée pour les porteurs de nouveaux produits / services.

3 L'ANALYSE DES ENJEUX

Des algorithmes neuronaux d'apprentissage profond commencent à être employés - souvent associés à d'autres types d'algorithmes - dans des secteurs aussi variés que le diagnostic médical, le scoring financier, le trading programmatique, la détection de fraude, la recommandation de produits, la reconnaissance d'image, la reconnaissance vocale, la traduction automatique et les véhicules autonomes. Selon une analyse du cabinet Tractica⁷, le marché des systèmes d'intelligence artificielle pour les entreprises devrait connaître une très forte croissance (de 202,5 M\$ en 2015 à 11,1 Mds\$ en 2024). Les principaux secteurs concernés cités sont la publicité et les médias, les services financiers, la fabrication industrielle, l'énergie et la distribution, puis la santé. En attendant l'émergence du véhicule autonome !

D'après certaines analyses, l'impact le plus important pourrait être l'impact sur l'emploi dans le secteur tertiaire, les algorithmes devenant assez performants pour permettre des gains de productivité dans tout un ensemble de tâches administratives. La problématique des robots logiciels rejoint ainsi celle des robots du monde matériel : ceux qui espèrent que les machines aideront l'homme s'opposent à ceux qui craignent qu'elles ne le remplacent. Ces analyses sortent du cadre de cette étude. Les missionnés n'ont pas non plus analysé les enjeux dans les domaines de la défense et de la sécurité, de la lutte contre le terrorisme, le crime ou le blanchiment d'argent.

⁷ <https://www.tractica.com/newsroom/press-releases/artificial-intelligence-technologies-are-quietly-penetrating-a-wide-range-of-enterprise-applications/>

3.1 Enjeux économiques

Il existe plusieurs études de marché concernant le traitement des données. *Markess* estime ainsi qu'en 2016 le marché français de l'analytique, du Big Data et de la gestion des données (logiciels, solutions SaaS/Cloud et services associés) sera de 1,9 milliards d'euros, avec une croissance moyenne de 12% par an pour les trois années à venir. La croissance serait encore plus forte pour **l'analyse prédictive**, avec « *l'essor des objets connectés, du machine learning, de l'usage des algorithmes... dans les activités et les métiers des entreprises* ».

L'intérêt pour le développement du « *data mining and analytics* », notamment dans les entreprises, se traduit par la vogue du métier de « *data scientist* » : la plateforme web en sciences des données Kaggle affiche la participation de plus de 500 000 *data scientists* dans le monde. Cependant, le nombre des postes directement concernés reste limité, avec 500 offres d'emploi référencées « *data scientist* » en France sur le site Indeed, fin mars 2016. Car les **impacts économiques des algorithmes sont évidemment surtout indirects**, mais la construction d'une métrique pour les mesurer sort du cadre de cette mission.

Pour les régulateurs, le premier enjeu économique est lié au fonctionnement de la concurrence : les algorithmes ont un impact majeur sur l'activité des entreprises en les positionnant (référencement, classement, recommandations ...) dans les résultats de recherche via des moteurs génériques ou spécialisés, dans les médias sociaux, les places de marché et les sites comparatifs, qu'il s'agisse des entreprises elles-mêmes, de leurs produits ou de leurs services.

Le numérique prend ainsi une part croissante du marché de la « réputation » ou de l'image, ce qui se traduit par l'augmentation des dépenses que les entreprises consacrent à leur présence sur le net (sites propres, publicité, relations publiques, sponsoring) et symétriquement, par l'augmentation des recettes, essentiellement publicitaires, des plateformes numériques, notamment celles opérant des moteurs de recherche ou des réseaux sociaux.

Il existe une littérature économique importante sur les logiques de marchés multi-faces et les plateformes⁸. Quand celles-ci se trouvent en position dominante, les régulateurs examinent le risque d'abus de position dominante. Dans le domaine du numérique, l'impact économique peut aller très au-delà des flux financiers, ce qui est parfois visible dans la capitalisation boursière des plateformes, qui anticipe leur capacité à monétiser leur impact, c'est-à-dire à en tirer un revenu.

La difficulté de prise en compte des services gratuits dans les analyses de concurrence et la détermination des positions dominantes est un sujet d'étude identifié par les régulateurs⁹.

Un deuxième enjeu est lié à la protection des consommateurs (voir § 3.1.2 Le commerce électronique). Dans ce domaine, la question de la protection des données personnelles, qui sort du champ de la mission, joue un rôle majeur. La mission a focalisé son attention sur les analyses qui ont

⁸ Verdier M. (2015) Les Développements Récents de la Littérature sur les Plateformes. i3 Working Papers Series, 15-CER-02

⁹ Table ronde « Les données et la concurrence dans l'économie numérique », Autorité de la concurrence, 8 mars 2016

été réalisées concernant les algorithmes eux-mêmes. Celles-ci ont porté sur la loyauté¹⁰ des algorithmes, notamment à travers deux cas particuliers. Sur quelles bases les algorithmes proposant des prix pour des produits ou services (yield management et algorithmes de pricing) font-ils des offres différenciées ? Quels sont tous les critères réellement pris en compte par des algorithmes produisant des recommandations (« ceux qui ont aimé ce produit ont aussi aimé ... ») ou proposant des classements fondés sur des notations par les internautes ?

Aujourd'hui, l'accent est de plus en plus mis sur **le risque de discrimination**. Est particulièrement visé le rôle des algorithmes dans l'accès au logement, au travail, au crédit, à l'assurance, à la santé et à l'éducation. Aux USA, la Federal Trade Commission (FTC) insiste sur la nécessité pour les entreprises elles-mêmes de vérifier la conformité au droit du traitement des données (« *compliance* » et « *accountability* »). Comme le souligne E. Geffray, secrétaire général de la CNIL, c'est aussi l'esprit du nouveau règlement européen de protection des données : « ... *répondre désormais à la question « Mes traitements sont-ils conformes » plutôt qu'à la simple question « Quelle formalité devons-nous réaliser ? »* ».

La perception que le consommateur peut avoir de l'équité des traitements réalisés par les algorithmes va se traduire en termes de **confiance - ou de perte de confiance - dans l'économie numérique**. Les analyses auxquelles a eu accès la mission sont surtout sociétales (voir § 3.2 Enjeux sociétaux) et pourraient utilement être couplées avec davantage d'analyses économiques. *Il faut noter que l'Autorité de la concurrence collabore depuis fin 2015 avec le Bundeskartellamt, l'Autorité de la concurrence allemande, à une étude conjointe des enjeux concurrentiels liés à la place des données dans l'économie numérique. La publication de cette étude est prévue en 2016 et pourrait précéder une étude sectorielle plus détaillée.*

Pour une approche plus concrète, la mission s'est livrée ci-dessous à une analyse rapide de quelques secteurs : la finance, le commerce électronique, la publicité en ligne, les médias, services culturels et réseaux sociaux, l'emploi et la gestion des talents.

L'émergence de l'utilisation d'algorithmes d'apprentissage profond dans l'industrie, par exemple pour le pilotage d'unités industrielles, la robotique ou la maintenance prédictive, mériterait d'être étudiée dans le cadre des réflexions sur l'industrie du futur.

3.1.1 Les marchés financiers

Le trading algorithmique (dont le trading haute fréquence n'est qu'une partie) participe notablement à la sensibilité sociétale vis-à-vis des algorithmes, notamment en termes d'opacité¹¹. S'il ne rentre pas en tant que tel dans le cadre des algorithmes de traitement des contenus, il donne un exemple des challenges auxquels sont confrontés les régulateurs.

Les marchés financiers font l'objet d'une réglementation importante, notamment en Europe depuis la directive MIF (Marchés d'instruments financiers). En 2007, la MIF a autorisé la création de places

¹⁰ Selon Dominique Cardon, on peut définir la loyauté d'un algorithme comme la nécessité de ne faire que ce qu'il est censé faire et de le faire bien.

¹¹ C'est le principal danger évoqué dans l'ouvrage « Black Box Society » de Frank Pasquale

de marché (les MTF multilateral trading facilities). Avec la concurrence entre MTF et places de marché traditionnelles, la fragmentation de la liquidité (autant de cours que de places) a multiplié les opportunités d'arbitrage et provoqué l'essor du trading algorithmique. Il représenterait aujourd'hui 75 à 80 % des transactions aux USA et près de 60% en Europe, dont à peu près les 2/3 en trading haute fréquence (HFT).

Ces algorithmes de trading prennent eux-mêmes des décisions, par opposition à de simples algorithmes d'exécution. Ils testent en permanence le marché, en passant de nombreux ordres dont la plupart sont annulés très rapidement : le ratio d'ordres exécutés par rapport aux ordres saisis peut être très faible (moins de 1% pour certains traders HFT). Sur Euronext, les ordres étaient enregistrés à la seconde jusqu'en 2009, on utilise aujourd'hui 6 chiffres après la virgule ! Le trading algorithmique tend à induire une course à la puissance informatique, au détriment des petits opérateurs et de simples investisseurs ; il est responsable d'un certain nombre d'incidents : baisses brutales et inexpliquées des cours (flash crash), parfois d'un petit groupe de titres, voire même d'un seul.

Cette situation a entraîné la mise en place d'une nouvelle réglementation, avec notamment la directive MIF II (l'un des apports de MIF II est la mise en place d'un régime harmonisé des pas de cotation « tick sizes » fondé sur le prix et la liquidité des instruments financiers). L'entrée en vigueur de la directive devrait être retardée d'un an, au 1^{er} janvier 2018. Il a donc fallu 10 ans pour adapter la réglementation ! Pour la lutte contre les manipulations de cours, les textes existant donnaient de bons principes, mais pas les bons critères de détection, à l'heure du trading algorithmique : de nouveaux critères permettant d'identifier les comportements délictueux doivent être proposés par l'European securities and market authority (ESMA).

Techniquement, la régulation repose sur l'enregistrement des données de transaction (conservation des données d'ordre qui seront transmises au régulateur sous un format spécifique), des tests de robustesse effectués sur les plateformes financières, et l'obligation pour les opérateurs de notifier l'utilisation d'un algorithme. Les entreprises d'investissement qui utilisent des algorithmes doivent assurer elles-mêmes certains contrôles (notamment si l'opérateur donne accès à d'autres opérateurs ou des particuliers).

En pratique, la régulation repose sur l'exploitation quotidienne d'indicateurs d'anomalies de marché, ainsi que sur l'obligation pour tous les opérateurs de déclarer les opérations suspectes. L'AMF reçoit une centaine de déclarations chaque année, le régulateur britannique en reçoit beaucoup plus et fait moins de surveillance du marché. Indicateurs d'anomalies et déclarations des opérateurs sont analysés et font le cas échéant l'objet d'une enquête détaillée.

La multiplication des ordres impose aux régulateurs de mettre en œuvre des moyens techniques et humains adaptés pour déceler et pourchasser les manipulations de cours. L'autorité des marchés financiers française dispose de deux équipes de contrôle, l'une de 5 personnes chargées de la surveillance du marché, l'autre de 4 « Quants » (ingénieurs et actuaires ayant travaillé en front office et gestion alternative), dédiées aux enquêtes. Les moyens nécessaires pour apporter la preuve d'une fraude sont importants : il faut retraiter d'importants volumes de données et modéliser les transactions pour permettre à la commission des sanctions de jouer son rôle. Les régulateurs américains, anglais et français sont les seuls à disposer de ces moyens en Occident.

Logiquement, les moyens techniques de la régulation devraient monter en puissance : pour la surveillance en temps réel, avec l'accès aux données, **le régulateur devrait développer l'utilisation d'algorithmes d'analyse plus performants que la seule surveillance d'indicateurs.**

Avec l'augmentation des obligations de reporting, la charge pour les entreprises augmente. Une réponse pourrait être ce que le régulateur britannique appelle les « Reg Tech » : les technologies qui facilitent le respect des exigences réglementaires. Elles devraient permettre l'automatisation de certains process de « *due diligence* » et d'alléger le coût de collecte des informations actuellement requises dans la vie de tous les jours des institutions financières : mesure des risques et calcul des exigences de fonds propres, lutte anti blanchiment (know-your-customer), prévention des ventes abusives (mis-selling) ...

La régulation technologique est l'avenir de la régulation financière
Une consultation publique par la UK Financial Conduct Authority (FCA)

RegTech¹² is a sub-set of FinTech that focuses on technologies which may facilitate the delivery of regulatory requirements more efficiently and effectively than existing capabilities.

Call for Input: we issued a Call for Input on the 23 November 2015, to better understand how we can support the adoption and development of RegTech as part of the wider FinTech community. We have now closed the call for input and the RegTech team would like to thank those that responded. We will be looking to publish our findings in the summer.

RegTech Roundtables: in order to give an opportunity for individuals to provide their view to us directly a number roundtables were held at techUK on 1 March, Burges Salmon on 3 March, JWG on 11 March and Innovate Finance 23 March.

If you have any comments, queries or questions that you would like to direct to the RegTech team then you can email us at RegTech@fca.org.uk.

Aux Etats-Unis ou en Grande-Bretagne, d'autres thèmes font l'objet de travaux ou de réflexions :

- **Les modèles de scoring pour l'accès au crédit.** Aux USA, des agences (Credit reference agencies) recueillent une information sur les crédits (y compris arriérés de paiement), locations, jugements de tribunaux locaux et inscription sur les listes électorales des individus. Cette information est utilisée par des algorithmes pour déterminer un score financier, conduisant à l'acceptation ou au refus d'une demande de crédit et déterminant parfois le taux de celui-ci (prime de risque individuelle). De nouveaux algorithmes d'apprentissage utilisant ces données financières, mais aussi d'autres données, issues par exemples de réseaux sociaux, sont développés pour réaliser une prédiction du risque de crédit. La Federal trade commission (FTC) a mené des enquêtes sur le risque de discrimination posé par de telles pratiques.

¹² <https://innovate.fca.org.uk/innovation-hub/regtech-programme>

- **L'application d'algorithmes de traitement des contenus à l'information financière.** Des outils d'analyse des données financières peuvent être utilisés pour faire des prédictions, en analysant de grosses quantités de données pour découvrir des tendances avant le marché. Ces analyses peuvent être couplées à des algorithmes de trading, ou servir, via des conseillers-robots (robot advisers), à conseiller des particuliers pour leurs investissements. Ces services poseront de nouveaux challenges aux régulateurs. Le régulateur britannique (FCA) souhaite explorer cette voie : *"The FCA should build on the success of Project Innovate and establish an Advice Unit to help firms develop their automated advice models"* (Financial Advice Market Review, march 2016).

3.1.2 Le commerce électronique

Selon la Fédération e-commerce et vente à distance (FEVAD), le chiffre d'affaire du e-commerce atteint 65 Milliards d'€ en France en 2015, après une croissance de 14%. L'arrivée de nouveaux acheteurs et l'augmentation de la fréquence des achats compensent la baisse tendancielle du panier moyen (78€). La France compte 182 000 sites actifs, mais les 0,5 % de sites qui réalisent plus de 10 M€ de recettes par an représentent 70 % du CA du secteur. Les principaux secteurs sont dans l'ordre le tourisme, l'habillement, l'équipement de la maison, le « drive produits de consommations » (retrait en magasin de produits commandés par Internet, en particulier pour la grande distribution) et enfin les produits culturels. La part des terminaux mobiles croît régulièrement dans le trafic.

En France, **plus d'un site de e-commerce sur deux cherche à monétiser son audience** (vente de services complémentaires, d'espaces publicitaires, élargissement du catalogue via une marketplace, asile colis et monétisation des bases de données clients).

Concernant le fonctionnement des algorithmes, en Europe, en termes de concurrence, c'est le fonctionnement du moteur de recherche de Google qui apparaît comme le plus problématique aujourd'hui. En termes de protection des consommateurs, des travaux ont concerné les pratiques d'élaboration des prix (yield management) par des algorithmes de pricing. Des thèmes émergents sont ceux de la loyauté des algorithmes de recommandation et du risque de discriminations.

L'impact du moteur de recherche de Google sur l'activité des sites web

Page Rank est loin d'être aujourd'hui le seul algorithme constituant le moteur de recherche de Google. L'entreprise indique que *« À l'heure actuelle, les algorithmes de Google font appel à plus de 200 signaux ou indices uniques qui permettent de deviner plus précisément ce que vous recherchez »*. Parmi les critères pris en compte, les sites qui existent depuis plus de six mois, dont les pages se chargent vite, qui ne contiennent pas de fautes de grammaire et d'orthographe, dont le contenu est original, qui s'affichent correctement sur un écran de smartphone, qui permettent une connexion chiffrée sécurisée ... Ce qui n'est pas connu est le poids exact de chacun de ces critères. Les évolutions des algorithmes de Google sont régulières et sont scrutées par les spécialistes du SEO¹³ (*Search Engine Optimisation*), parmi les principales :

- **Panda**, introduit en 2011, régulièrement mis à jour, pénalise les sites qui reproduisent du contenu non original ;

¹³ <http://searchengineland.com/search-update-impact-on-seo-content-strategies-240558>

- **Penguin**, depuis 2012, identifie les liens entrants de mauvaise qualité, tels que ceux issus des fermes de liens, et dégrade le classement du site ;
- **Hummingbird**, en 2013, cherche à améliorer la recherche sémantique du moteur, en utilisant des éléments de contexte, diminuant l'impact de la seule présence des mots-clés ;
- une « **Mise à jour Mobile** », en 2015, favorise dans les résultats du moteur de recherche, pour les recherches réalisées à partir d'un terminal mobile tel qu'un smartphone, les sites dont l'ergonomie est adaptée à celle du terminal. C'est la 1^{ère} fois que Google a prévenu à l'avance les utilisateurs de l'introduction d'un nouvel algorithme ;
- **RankBrain** annoncé à l'automne 2015 et intégré avec Hummingbird, marque l'entrée de Google dans le domaine de l'intelligence artificielle et du machine learning : il sert à interpréter le texte de la recherche pour trouver les résultats les plus pertinents.

Les changements de l'algorithme effectués entre 2010 et 2013 (Panda, Penguin) ont diminué la visibilité des comparateurs de prix, avec un fort impact sur leur chiffre d'affaire. A la même époque, Google a introduit son propre service Google shopping, ce qui a conduit au dépôt de plusieurs plaintes, en cours de traitement par la Commission européenne, qui a publié au printemps 2015 une communication de griefs.

Une nouvelle fonctionnalité de Google, « Destinations » (mars 2016)¹⁴

C'est une nouvelle fonctionnalité du moteur de recherche, uniquement disponible sur mobile (Android ou via l'app Google sur iPhone) : à partir d'une recherche sur une destination (201 villes indexées), le moteur présente les vols, hôtels, conseille des itinéraires pour le voyage et des lieux à visiter, sur une seule page de recherche. Il faudra ensuite se rendre sur le site choisi pour réserver un vol ou l'hôtel.

L'algorithme utilise les requêtes effectuées par les internautes : *"Destinations integrates a deep understanding of all the places in the world with Google Flights and Hotel search, so you can see available flight and hotel prices instantly... The results instantly update with real-time fares and rates, pulling from the trillions of flight itineraries and hotels we price every day on Google Flights and Hotel search... The suggested itineraries are based on historic visits by other travelers to those places, so you can use the wisdom of the crowd and save time researching"*.

Cette application entre en concurrence avec les sites de comparateurs de prix pour les voyages, comme Kayak ou Ligo, dont l'activité dépend elle-même des recherches des internautes via Google. En cas de succès, elle pourra également être amenée à jouer un rôle prescripteur, suscitant alors des interrogations sur les critères réels utilisés pour mettre en avant certaines offres et donc sur **la transparence du fonctionnement de l'algorithme**.

Peu de détail semblent être disponibles sur RankBrain, depuis l'article original de Bloomberg (octobre 2015) annonçant son déploiement progressif. Un représentant de Google a indiqué

¹⁴ <https://googleblog.blogspot.fr/2016/03/new-ways-to-plan-your-vacation-while-on.html>

qu'environ 15% des requêtes étaient traitées par l'algorithme, et que cela en faisait le 3^{ème} critère de pertinence dans la hiérarchie du moteur de recherche. Il n'agirait pas directement sur le classement des sites (ranking), mais sur la compréhension de la requête en lien avec le contenu des sites. Début mars 2016, un ingénieur de Google, Paul Haahr, a alimenté le buzz en déclarant lors du SMX West de San José que « *Google comprenait comment RankBrain fonctionne mais pas vraiment ce qu'il fait...* ». Avec cet algorithme, Google franchit une étape significative vers une personnalisation croissante des résultats du moteur de recherche.

Google a toujours considéré que les algorithmes de son moteur de recherche étaient sa « sauce secrète », qu'il fallait protéger contre la concurrence tout autant que contre les manœuvres des spécialistes du référencement. Mais depuis plusieurs années, la firme a développé sa stratégie de communication. Matt Cutts, responsable de la lutte contre le spam chez Google jusqu'à l'été 2014, était un blogueur réputé. Un site à l'attention des webmasters, le Google Webmaster Central Blog, diffuse les annonces officielles sur l'indexation et le crawling des sites et permet de poster des commentaires et des questions.

Yield management ou discriminations de prix ?

Dès 2000, Amazon a été amené à faire machine arrière sur certaines pratiques tarifaires (*Sept 28, 2000, Amazon.com Inc. founder and CEO Jeff Bezos said today it was "a mistake" for the Seattle-based online retailer to experiment with charging different customers different prices for the same products*).

Plus récemment l'attention s'est portée sur les tarifs aériens. L'INRIA a participé à une étude internationale¹⁵ qui conclut *"Price discrimination refers to the practice of dynamically varying the prices of goods based on a customer's purchasing power and willingness to pay. In this paper, motivated by several anecdotal accounts, we report on a three-week experiment, conducted in search of price discrimination in airline tickets. Despite presenting the companies with multiple opportunities for discriminating us, and contrary to our expectations, we do not find any evidence for systematic price discrimination. At the same time, we witness the highly volatile prices of certain airlines which make it hard to establish cause and effect. Finally, we provide alternative explanations for the observed price differences"*.

Cependant, selon autre une étude américaine¹⁶ de 2014 : *"there is mounting evidence that e-commerce sites are using personalization algorithms to implement price steering and discrimination"*.

Même si peu de pratiques non conformes au droit et directement liées à l'utilisation d'un algorithme ont été identifiées, cette question fait évidemment toujours l'objet d'une vigilance des pouvoirs publics et de la société.

Aujourd'hui, c'est également la loyauté des algorithmes de recommandation et la fiabilité des avis des internautes qui attirent l'attention des autorités de contrôle.

¹⁵ Crying Wolf? On the Price Discrimination of Online Airline Tickets – November 2014

¹⁶ Measuring Price Discrimination and Steering on E-commerce Web Sites

3.1.3 La publicité en ligne

En France, avec une croissance de 6% en 2015, la publicité digitale¹⁷, après avoir dépassé la publicité presse, atteint presque le niveau de la TV. Cela représente 3 216 M€ et une part de marché de 27,7% dans les dépenses médias, comparable à ce qu'on observe aux USA ou en Allemagne, mais largement moins qu'au Royaume-Uni (44,4%). La publicité sur les moteurs de recherche (Search) représente 1 815 M€, les bannières (display) 1 051 M€ et l'affiliation, les comparateurs et le e-mailing 434 M€. Pour les bannières, le programmatique (inventaires vendus via une mise en relation automatique entre acheteurs et vendeurs) est en forte croissance et sa part pourrait passer à plus de 50% en 2016. Le mobile représente aujourd'hui plus de la moitié des connexions, mais ne pèse que 26% des investissements publicitaires (search et display) en 2015 et devrait donc continuer à croître fortement.

L'encadrement de la publicité s'est construit depuis longtemps par l'addition de règles édictées par les pouvoirs publics, d'une part, et de pratiques issues de l'autorégulation par les professionnels, d'autre part. Dans tous les pays, les bonnes pratiques des professionnels ont pour objet de trouver un équilibre entre la pression publicitaire et le respect du consommateur, dans le but de préserver l'efficacité de la publicité, comme rouage de l'économie de marché contribuant au développement économique. Si l'objectif est commun, le point d'équilibre trouvé est différent selon les pays, comme le montre l'exemple de la publicité à la télévision.

Les annonceurs ont l'habitude de déclarer que « la moitié de la publicité ne sert à rien, mais on ne sait pas quelle moitié ». Par contraste, la publicité digitale se développe en promettant aux annonceurs comme aux internautes, « d'adresser le bon message à la bonne personne au bon moment ». Ce « ciblage comportemental » se distingue du marketing direct, qui s'adresse à une personne nommément identifiée et fait l'objet d'une régulation, notamment pour la protection de données personnelles et la gestion des fichiers nominatifs. Pour le courrier ou le téléphone, l'union du marketing direct gère une liste d'opposition, la liste Robinson¹⁸. Pour le fax, l'e-mail et les SMS, le principe du consentement explicite préalable a été imposé par les pouvoirs publics.

Le « ciblage comportemental » ne cherche pas en principe à identifier nommément l'internaute mais seulement des caractéristiques pertinentes pour choisir une offre qui peut l'intéresser à un instant donné. C'est au départ ce qui a fait le succès de la publicité sur les moteurs de recherche : un internaute qui tape un mot-clé manifeste à l'instant où il le fait un intérêt pour ce que ce mot recouvre. Aujourd'hui, le profilage de l'internaute à partir de ses traces de navigation permet de prédire à chaque instant son intérêt pour une annonce et donc de calculer en temps réel une valeur pour l'espace publicitaire présent sur la page qu'il est en train de regarder. Des algorithmes sophistiqués sont utilisés pour réaliser ce couplage entre l'annonce et l'internaute. Deux innovations marketing ont favorisé la croissance de ce marché : le paiement au clic (l'annonceur ne paye que si l'internaute clique sur la publicité) et la vente des espaces publicitaires (bannières ou mots-clés) aux enchères en temps réel, impression par impression, sur des plateformes d'achat programmatique (ad exchange¹⁹).

¹⁷ Source : 15^{ème} observatoire de l'e-pub – SRI 2015

¹⁸ S'inscrire sur la liste Robinson permet de faire savoir aux entreprises membres de l'union du marketing direct que l'on ne veut plus recevoir de publicités adressées à son nom.

¹⁹ La nécessité de contrôler ces plateformes au regard du droit de la concurrence a été signalée à la mission.

La publicité comportementale fait l'objet de codes de bonnes pratiques

Le ciblage publicitaire peut évidemment être perceptible par l'internaute, qu'il s'agisse de la technique du « reciblage » (proposer à un internaute un produit auquel il s'est déjà intéressé) ou d'un profilage conduisant à une offre spécifique (proposer des produits pour bébé à un internaute qui a une certaine probabilité d'être une femme enceinte).

La Chambre de Commerce Internationale publie un code de bonnes pratiques²⁰, qui établit des standards éthiques et des lignes directrices pour l'autorégulation des secteurs du marketing et de la publicité. Il a été mis à jour pour traiter spécifiquement des médias numérique interactifs.

Pour répondre aux critiques, les professionnels regroupés au sein de la Digital advertising alliance ont adopté un protocole²¹ matérialisé par une icône visible dans, ou à côté de la publicité :



En cliquant sur cette icône, l'internaute obtient des informations sur le fonctionnement de la publicité ciblée, la possibilité d'interdire ce type de publicité (ce qui ne veut pas dire que l'internaute ne recevra plus de publicités) et un lien pour déposer une réclamation auprès de l'association du marketing direct. Les entreprises qui adhèrent au programme s'engagent également à respecter des règles sur l'utilisation des données. Les annonceurs qui ont obtenu une licence pour utiliser l'icône réalisent une auto-certification, les tiers intermédiaires sont audités : les adserveurs par exemple, pour avoir le certificat, sont contrôlés par des auditeurs, qui vérifient que la technologie de l'adserveur permet de ne pas délivrer de publicité ciblée à quelqu'un qui la refuse.

La consultation du site youronlinechoices.eu montre que l'utilisation de cette icône (accompagnée du sous-titre « EU good practice ») n'est promue que dans 3 pays (Irlande, Malte, Royaume-Uni), avec une liste d'entreprises certifiées, dont Criteo.

Contactée à ce propos, l'ARPP a indiqué que la version française du site sera rapidement corrigée, pour inclure l'icône. En outre, une nouvelle vague de communication grand public en faveur de *Youronlinechoices* est en cours de réalisation.

L'utilisation de bloqueurs de publicité (Adblock) par certains internautes pousse les entreprises à poursuivre le travail de développement de règles d'autorégulation. Dans un avis publié en septembre 2015 « Blocages publicitaires : l'impasse », le Conseil de l'Éthique Publicitaire indique que : « *Les internautes, dont il est légitime de penser qu'ils puissent garder la maîtrise de l'affichage de tout contenu sur leur(s) écran(s), utilisent ces systèmes, car ils ressentent certains formats publicitaires sur*

²⁰ <http://www.codescentre.com/about-you/regulator-views.aspx>

²¹ En Europe <http://www.youronlinechoices.eu/>

Internet comme trop intrusif, et estiment les techniques de (re)ciblage abusivement apparentes, voire insistantes ». Il rappelle que ces dispositifs seraient utilisés par un internaute français sur dix.

« Nous avons foiré »

Déclarant sans ambages « *We messed it up* », l'Interactive Advertising Bureau (IAB) a lancé en octobre 2015 une initiative LEAN (*LEAN stands for Light, Encrypted, Ad choice supported, Non-invasive ads*). Au menu : *“we must also address frequency capping on retargeting in Ad Tech and make sure a user is targeted appropriately before, but never AFTER they make a purchase. If we are so good at reach and scale, we can be just as good, if not better, at moderation. Additionally, we must address volume of ads per page as well as continue on the path to viewability”*. Cette initiative est soutenue par les acteurs français, dont le Syndicat des Régies Internet (SRI).

3.1.4 Le domaine des médias, produits culturels et réseaux sociaux

Le domaine des médias, produits culturels et réseaux sociaux est celui où l'impact du numérique a été le plus rapide (presse, musique, vidéos), le plus créatif (réseaux sociaux) et le plus profond. Aujourd'hui, les algorithmes de traitement des contenus jouent un rôle clé pour l'accès à une offre pléthorique et mondialisée. Mais en publiant en mai 2014 une lettre ouverte au PDG de Google, intitulée « Pourquoi nous avons peur de Google », Mathias Döpfner, le patron d'Axel Springer, a marqué les esprits : « *Les appareils et les algorithmes de Google ne sont pas un programme de gouvernement* ». **Faut-il laisser les machines déterminer ce que nous voyons en ligne ?**

Le projet de recherche ALGODIV

Comment mesurer, vérifier et contrôler la qualité des choix réalisés par les algorithmes du web lorsqu'ils décident de mettre en visibilité telle ou telle information ?

L'objectif d'ALGODIV, projet de recherche collaborative relative à la recommandation algorithmique et à la diversité des informations du web, est d'apporter une contribution scientifique à l'enjeu politique, économique et culturel de la diversité informationnelle sur le web. Le projet se donne pour objectif de concevoir des métriques permettant de mesurer les effets des algorithmes sur le comportement des internautes.

Le projet est financé par l'agence nationale de la recherche (ANR). Il associe le laboratoire d'informatique de Paris 6 (LIP6, unité mixte UPMC / CNRS), le centre d'analyse et de mathématiques sociale (CAMS, unité mixte CNRS / EHESS), le centre Marc Bloch Berlin (CMB, unité mixte internationale du CNRS) et le département SENSE (Sociology and Economics of Networks and Services) d'Orange labs, en partenariat avec le journal Le Monde. Il a démarré en avril 2016 et doit durer 42 mois. Le projet est piloté par Camille Roth.

Une publication de la CNIL²², « *Les données, muses et frontières de la création – Lire, écouter, regarder et jouer à l’heure de la personnalisation* » fait une analyse prospective en insistant sur l’ambiguïté du rôle des algorithmes (*compagnons de plus en plus indispensables pour naviguer dans l’immensité des catalogues de contenus, ces algorithmes peuvent tout autant favoriser la découverte et la diversité qu’enfermer les individus dans des goûts stéréotypés ou des horizons très limités*) et sur leur impact potentiel sur la création (*les films et séries, très chers à produire, sont de plus en plus calibrés par des algorithmes pour être des succès*). Les questions posées touchent à la neutralité, à la pertinence et à la transparence des algorithmes qui proposent des choix ou les orientent.

Concernant la politique culturelle, à laquelle la France est attachée, la difficulté vient du caractère mondial des services et des prescriptions : **comment vérifier des règles d’exposition du public français à des œuvres européenne et françaises ?**

2016, L’algorithme de Netflix devient global

En janvier 2016, Netflix a annoncé l’ouverture de son service dans 130 pays, portant à 190 le nombre de pays où il est accessible. Parallèlement, Netflix annonce que son moteur de recommandation, qui est en fait composé d’une douzaine d’algorithmes différents, va devenir global. Alors que les algorithmes tournaient indépendamment sur des régions regroupant des pays disposant de catalogues similaires, un seul moteur de recommandation va désormais partager les données de tous les pays. L’ensemble des données des utilisateurs du monde entier va servir de base à ses recommandations. L’ambition est de présenter « *les meilleurs drames français en Asie, la meilleure animation japonaise en Europe* » (The Netflix Recommender System: Algorithms, Business Value, and Innovation, 2016).

Quelle politique de contenus culturels pour la France ? A une question sur la suppression de l’offre de contenus français, Reed Hastings, PDG de Netflix répond²³ en mars 2016 : « *Je vous dirai simplement que si nous supprimons certains contenus, c’est selon deux raisons : nos droits de distribution se finissent ou les abonnés ne les regardent pas, tout simplement.* »

Vers un standard pour la transparence des algorithmes dans les médias

Aux USA, des travaux impulsés par N. Diakopoulos (Tow Center for Journalism, Université de Columbia) analysent le fonctionnement des algorithmes qui interviennent dans les médias numériques, tels que ceux qui permettent l’écriture automatique des dépêches ou qui pilotent les fils de nouvelles (news feeds) des réseaux sociaux ou de la presse en ligne. Ces travaux conduisent à proposer une esquisse de l’information qui devrait être publiée pour assurer plus de transparence²⁴ :

- **Le pilotage humain** : qui est derrière l’algorithme, qui le contrôle et en rend compte dans l’entreprise, et quel sont ses objectifs ?

²² Cahiers Innovation & Pprospective n°3

²³ <http://www.lesnumeriques.com/vie-du-net/netflix-bienvenue-dans-arme-diffusion-massive-a2689.html>

²⁴ <http://towcenter.org/towards-a-standard-for-algorithmic-transparency-in-the-media/>

- **Les données** : quelle est la qualité des données, comment sont-elles collectées, validées et traitées ?
- **Le modèle** : quelles sont les variables ou les paramètres utilisés par l'algorithme ? S'il s'agit d'apprentissage machine, sur quelles données et en fonction de quels paramètres (supervision) ou selon quelle méthode cet apprentissage est-il fait ?
- **Les inférences** : pour des classifications ou des prédictions, quelles sont les marges d'erreur, les taux de faux positifs ou de faux négatifs, les marges de confiance ? Quelles procédures sont utilisées pour corriger les erreurs ?
- **La visibilité de l'algorithme** : expliquer ce que fait l'algorithme, où et quand il intervient. S'il propose un résultat personnalisé, à partir de quelles données personnelles ? En quoi cette personnalisation produit-elle un résultat différent ?

En résumé, ces règles reposent sur l'identification d'une équipe responsable et sur la communication d'une « politique algorithmique » analogue à la politique éditoriale d'une publication. Elles peuvent évidemment s'appliquer dans d'autres domaines que les médias.

3.1.5 L'emploi et la gestion des talents

Le rapport du conseil d'orientation pour l'emploi (COE) de mars 2015, « *L'impact d'Internet sur le marché du travail* », constate que l'utilisation systématique du numérique par les acteurs du marché du travail « *soulève la nécessité et les défis de la régulation, par les pouvoirs publics ou par les pairs, afin d'encadrer les pratiques et d'assurer leur légalité sans compromettre leur évolution* ». Car le développement des technologies de traitement des *Big Data* ouvre des perspectives pour la connaissance du marché du travail et peut permettre d'améliorer l'appariement entre l'offre et la demande de travail. Le *Big Data* permet également des analyses quantitatives de la performance de la force de travail, avec l'émergence de ce que les Américains appellent la « *workforce science* ».

Aujourd'hui, les entreprises gèrent une « *image employeur* » sur le net et publient leurs offres d'emploi plusieurs fois, sur leurs sites propres, sur des sites spécialisés (jobboards généralistes ou sectoriels), sur des réseaux sociaux (LinkedIn, Viadeo) ou sur Le Bon Coin pour les emplois de proximité. Ces offres peuvent être reprises par des agrégateurs mondiaux, comme Indeed. De leur côté, les individus postent leurs CV et candidatent sur ces mêmes sites, mais doivent aussi gérer leur profil sur les sites sociaux, généralistes ou professionnels.

L'abondance d'information entraîne l'émergence de nouveaux services :

- d'appariement entre l'offre et la demande, pour aider un candidat à choisir parmi les offres d'emploi ou pour aider une entreprise à sélectionner les meilleurs profils parmi des CV (*matching emploi – compétences*) ;
- d'aide à la recherche d'emploi ou à l'évolution de carrière, via du coaching, l'identification de formations pour améliorer l'employabilité du candidat, ou encore l'identification d'entreprises potentiellement intéressées par ses compétences, même si celles-ci n'ont pas publié de poste, afin de leur proposer une candidature spontanée (accès au *marché caché de l'emploi*) ;
- d'aide aux entreprises pour trouver des profils potentiellement intéressants, même s'ils ne se sont pas ouvertement déclarés en recherche d'emploi (pratiques de *sourcing emploi*).

Ces nouveaux services mobilisent de nombreuses start-ups et des équipes de *data scientists* chez les *pure players* existants, français ou groupes mondiaux. Aujourd'hui tous misent sur leurs algorithmes pour se différencier, face à la perspective de consolidation du secteur. Ils cherchent à dépasser la simple mise en relation de personnes à la recherche d'un emploi avec des entreprises qui recrutent.

Une base de données de 100 millions de profils IT dans le monde

TalentBin by Monster est une base de données de profils identifiés par leurs compétences, intérêts et actions, telles qu'ils apparaissent sur le web à partir de leur activité et traces, sur les médias sociaux (Facebook, LinkedIn, Twitter ...), des sites comme Meetup, Pinterest ou Quora et jusqu'à la base de données américaine des brevets. La base affiche plus de 100 millions de profils identifiés à partir de leur activité sur plus de 100 sites. Présentés comme des « candidats passifs », ils peuvent être contactés grâce à des services personnalisés proposés aux recruteurs.

Tous les intervenants sont d'accord : les algorithmes de traitement et l'intelligence des données doivent rester **un support pour la prise de décision**. La décision finale d'embaucher ou de retenir un talent doit revenir à un humain, qui doit vérifier et interpréter les corrélations issues des données. Mais est-ce suffisant ?

- Face à l'afflux de postulants, ce sont souvent les algorithmes qui proposent une short-list des « meilleurs candidats » à interviewer. Sur quels critères sont éliminés les autres ?
- La diffusion ciblée d'offres de postes, par exemple sur le fil Twitter de profils sélectionnés par un algorithme, respecte-t-elle de facto des critères de non-discrimination ?

Des comités d'évaluation des candidatures fiables et efficaces ?

L'entreprise Expert System a annoncé²⁵ en mars 2016 un contrat avec l'Institut National de la Santé et de la Recherche Médicale (INSERM). L'Institut utilisera un portail d'information biomédicale développé par la société pour identifier des experts internationaux et constituer ainsi des comités d'évaluation de candidatures efficaces et fiables. Parmi les avantages de cette procédure pour l'INSERM, le respect de la neutralité : le logiciel est *conforme au code d'éthique de l'institution car il permet d'automatiser la phase d'Identification d'Experts. En fournissant une vue globale et indépendante des experts actuels, il évite le favoritisme et les partis pris. En plus de sa capacité à rassembler rapidement 3 ou 5 experts extérieurs, il permet d'éviter que la décision finale ne soit influencée par un conflit d'intérêt.*

Le répertoire d'experts est constamment mis à jour par un logiciel qui permet également d'évaluer le niveau d'excellence d'un expert selon le niveau de réputation des journaux dans lesquels il a publié. Les mots clé associés à l'expert sont également révélateurs de la pertinence du choix.

²⁵ <http://www.expertsystem.com/fr/inserm-accelere-processus-de-recrutement-de-nouveaux-talents-portail-luxid-navigator-dexpert-system/>

Potentiellement, l'utilisation d'algorithmes peut améliorer les processus de recrutement. Des études²⁶ ont montré que les algorithmes pouvaient être plus objectifs que des humains pour estimer la qualité d'un candidat. Des entreprises offrant de nouveaux services de sourcing utilisant des algorithmes, mettent en avant l'augmentation de la diversité des profils proposés, par rapport à la tendance de certains recruteurs à privilégier des candidats présentant les mêmes profils que ceux déjà présents dans l'entreprise. Mais d'autres exemples²⁷ montrent aussi que les algorithmes peuvent reproduire des biais déjà présents dans les données qu'ils utilisent.

Les systèmes automatisés d'aide à la gestion des ressources humaines doivent pouvoir être testés : diversité des profils, respect des règles de droit contre les discriminations (genre, origine ethnique ...). Le cas échéant, des contraintes doivent pouvoir être programmées « à la main » pour éviter les dérives.

3.2 Enjeux sociétaux

« Faire entrer tous les phénomènes de l'univers dans la catégorie de la contingence plutôt que dans celle de la causalité, c'est là une opération qui fait époque dans l'histoire des idées ». Karl Pearson, 1912, cité par Alain Derosières, « La politique des grands nombres ».

Il y a un siècle déjà, avec la mise en œuvre des outils modernes des statistiques mathématiques (c'est Karl Pearson qui a développé l'étude des corrélations et le test du χ^2), a été formalisée une question qui se pose aujourd'hui avec une acuité nouvelle :

« Faut-il comprendre les causalités ou peut-on agir à partir de corrélations ? »

Les algorithmes cherchent à établir des corrélations entre des données, comme le remarque Chris Anderson²⁸ : *« Qui sait pourquoi les gens font ce qu'ils font ? Le fait est qu'ils le font et on peut l'enregistrer avec une fidélité sans précédent. Avec assez de données, les chiffres parlent d'eux-mêmes »*. L'algorithme peut prédire un comportement, à partir d'un modèle élaboré sur un premier corpus de données et appliqué ensuite à un second, mais comme le souligne Dominique Cardon²⁹ : *« il serait cependant trompeur de considérer que ces méthodes sont à l'affût de corrélations qui marchent sans se préoccuper de les expliquer. En réalité, elles produisent bien des modèles de comportement, mais ceux-ci n'apparaissent qu'ex-post et se présentent comme une suite enchevêtrée d'explications dont les variables jouent différemment selon les profils »*.

L'utilisation de ces méthodes par les décideurs, dans les entreprises ou pour les politiques publiques, risque de conduire à ce qu'Antoinette Rouvroy appelle la « *gouvernementalité algorithmique*³⁰ » dont la 1^{ère} caractéristique est « *l'abandon de toute forme d'« échelle », d'« étalon », de hiérarchie, au profit d'une normativité immanente et évolutive en temps réel, dont émerge un « double*

²⁶ <http://psycnet.apa.org/journals/apl/98/6/1060/>

²⁷ Big data's disparate impact, Solon Barocas et Andrew D. Selbst, 2015

²⁸ Chris Anderson, The End of Theory : the Data Deluge Makes the Scientific Method Obsolete, Wired Magazine, 2008

²⁹ Dominique Cardon – A quoi rêvent les algorithmes ? (Seuil, 2015)

³⁰ <https://www.cairn.info/revue-reseaux-2013-1-page-163.htm>

statistique » du monde et qui semble faire table rase des anciennes hiérarchies dessinée par l'homme normal ou l'homme moyen ».

Sa 2^{ème} caractéristique est l'effet sur les comportements des individus, « l'évitement de toute confrontation avec les individus dont les occasions de subjectivation se trouvent raréfiées. » On rejoint ainsi ce qu'E. Pariser a appelé « la bulle de filtres ».

« Les moteurs de recherche et systèmes de recommandation proposent des résultats personnalisés qui restreignent le champ de vision des utilisateurs. De telles performances de classement renforcent les acteurs les plus forts, les plus populaires, au détriment des plus faibles. Par ailleurs, l'excès de personnalisation peut conduire à un repli sur soi, au communautarisme. Il sera difficile pour les autorités publiques de répondre à cette dérive car elle répond à une demande des utilisateurs³¹ ».

Répondant à ce type de critiques, une étude à grande échelle a été publiée en mai 2015 par des chercheurs de Facebook³², qui ont analysé la navigation de plus de 10 million de personnes sur une période de 6 mois : *"Finally, we conclusively establish that on average in the context of Facebook, individual choices more than algorithms limit exposure to attitude-challenging content. Despite the differences in what individuals consume across ideological lines, our work suggests that individuals are exposed to more cross-cutting discourse in social media they would be under the digital reality envisioned by some"*. L'enjeu est important pour Facebook, car on estime que 30% des adultes américains s'informent via son fil de nouvelles (news feed), dont les décisions éditoriales sont prises par un algorithme de filtrage critiqué comme peu transparent³³.

Leaders d'opinion, humains ou algorithmes ?

Aux Etats-Unis, Oprah Winfrey, animatrice jusqu'en 2011 de l'Oprah Winfrey Show, a été créditée de la capacité à faire fluctuer le marché sur un simple commentaire : elle transformait en best-sellers les ouvrages qu'elle choisissait de présenter lors de l'Oprah's Book Club, et aurait contribué à lancer aux USA la nouvelle friteuse Actifry de SEB d'un simple Tweet. Devenue l'une des plus grosses fortunes des USA, et malgré de nombreuses controverses, notamment sur la qualité réelle des ouvrages qu'elle recommandait, elle reste l'une des personnalités les plus appréciées des Américains.

Peut-on imaginer qu'un algorithme de recommandation bénéficie d'une capacité d'influence comparable sans susciter des inquiétudes sur sa transparence ou sa loyauté ?

Les équipes qui développent des algorithmes s'emploient à améliorer leurs performances et à montrer, quand on peut les comparer à un travail humain, que les algorithmes sont plus efficaces. Ce

³¹ Collège des Bernardins – Réclamer des comptes aux algorithmes – 12 mai 2015 – S. Abiteboul

³² Exposure to ideologically diverse news and opinion on Facebook, Eytan Bakshy, Solomon Messing, Lada Adamic, Science

³³ I always assumed that I wasn't really that close to [her]": Reasoning about invisible algorithms in the news feed, M.Eslami

n'est souvent pas suffisant : ce que la société attend, c'est aussi la production de meilleurs résultats au sens du respect des lois et de l'éthique !

L'acceptation sociale du progrès technique impose généralement d'être plus exigeant pour la machine qu'on ne l'est pour l'homme. C'est la même chose pour les algorithmes.

La réflexion sur l'éthique

En janvier 2015, un séminaire organisé par Max Tegmark pour le Future of life Institute a réuni des chercheurs autour de la question de l'impact de la recherche en intelligence artificielle sur la société. A l'occasion du séminaire, une lettre sur « des priorités de recherche pour une intelligence artificielle robuste et bénéfique » a été ouverte à la signature. Popularisée par Stephen Hawking ou Elon Musk, cette initiative a rencontré un écho important. Début 2016, 8 600 personnes avaient signé la lettre, dont un grand nombre de chercheurs en intelligence artificielle du monde entier. **Cette initiative souligne la prise de conscience, par la communauté des chercheurs, des enjeux éthiques liés à l'intelligence artificielle.**

En France, la CERNA, commission de réflexion sur l'éthique de la recherche en sciences et technologies du numérique d'Allistene (l'alliance des organismes de recherche français dans le domaine du numérique) a lancé une réflexion sur les enjeux éthiques de la gouvernance des algorithmes.

Il est possible de s'imposer des règles d'éthique lors de la conception ou de la mise en œuvre d'un algorithme. Par exemple, on peut vérifier que, si on tient compte de la localisation géographique dans l'apprentissage d'un algorithme de prédiction de défauts de paiement, celui-ci va éliminer certaines zones. On peut alors pallier ce défaut en s'interdisant a priori de traiter ce critère de localisation.

L'enjeu est de faire de cette question un débat de société plus large, et surtout de faire en sorte que les développeurs eux-mêmes soient amenés à la prendre systématiquement en compte. Dans le monde numérique, cela implique de **mettre en jeu la réputation** des entreprises, plateformes ou services qui utilisent des algorithmes.

« Les algorithmes sont toxiques si nous nous en servons pour optimiser l'intolérable en abdiquant de nos responsabilités – celle de nous tenir dans une position juste par rapport à notre propre ignorance et celle de faire usage des capacités collectives que nous avons de faire changer le monde. Les algorithmes sont utiles, par contre, lorsqu'ils nous permettent de devenir plus intelligents, plus sensibles au monde et à ses habitants, plus responsables, plus inventifs. Le choix de les utiliser d'une manière paresseuse et toxique ou courageuse et émancipatrice nous appartient » (Antoinette Rouvroy).

3.3 Enjeux juridiques

Comme l'explique bien Lawrence Lessig dans son article³⁴ « Code Is Law - On Liberty in Cyberspace », la loi du cyberspace dépend de la manière dont il est codé. Et ce code - c'est particulièrement vrai dans le domaine des algorithmes - est largement élaboré sous la direction d'acteurs multinationaux : l'enjeu pour la France est de porter le respect de ses normes juridiques au niveau international, souvent d'abord au niveau européen, afin de peser sur l'évolution du code.

Dans le système (voir figure 3) qui recouvre les échanges de données entre internautes, plateformes, objets connectés et algorithmes :

- les données font l'objet du nouveau règlement européen sur la protection des données personnelles, qui vient d'être adopté et va entrer en vigueur en 2018 ;
- avec la loi « République numérique », la France est plutôt en avance sur la réglementation européenne avec la définition des plateformes et d'obligations qui s'imposent à elles. La Commission européenne a de son côté lancé une consultation sur la régulation des plateformes (voir § 4.1) ;
- la réglementation applicable aux objets connectés est émergente. On voit naître toute une série de problèmes juridiques nouveaux, comme le montrent les exemples des drones ou de la voiture connectée.

Concernant les algorithmes proprement dits, qui sont l'objet de cette mission, le projet de loi République numérique institue une exigence de transparence des algorithmes publics, qui prend sa place, au côté de la mise en libre accès des données publique (open data) comme un axe de « l'open government ».

C'est dans le cadre international de « l'open government » que pourrait être promue cette notion de transparence des algorithmes publics et les modalités de son application.

Publiée en 2014, l'étude du conseil d'Etat « Le numérique et les droits fondamentaux » préconise trois méthodes d'encadrement de l'utilisation des algorithmes : assurer l'effectivité de l'intervention humaine dans les prises de décision, mettre en place des garanties de procédure et de transparence lorsque des algorithmes sont utilisés pour prendre des décisions à l'égard d'une personne, développer le contrôle des résultats produits par les algorithmes, notamment pour détecter l'existence de discriminations illicites.

Pour les interlocuteurs rencontrés par la mission, dans le monde économique c'est ce dernier point qui est aujourd'hui le plus important. L'enjeu juridique principal posé par l'utilisation d'algorithmes tient à l'effectivité de l'application des règles de droit existantes.

En outre, pour combattre les abus, la question du contrôle est inséparable de celle de la constitution d'une preuve pour les tribunaux ou commissions de sanctions spécialisées : c'est techniquement particulièrement difficile pour des algorithmes personnalisés de traitement des contenus. Cela nécessite des moyens humains et matériels performants.

³⁴ Harvard magazine, janvier 2000

Trois autres questions mériteraient un examen plus approfondi :

- La consultation de la Commission Européenne sur les plateformes a mis en évidence la nécessité, pour les plateformes qui donnent accès à des contenus fournis par des tiers, d'établir des lignes directrices sur leur responsabilité, quand elles mettent en œuvre des mesures volontaires pour lutter contre les contenus illégaux en ligne, afin qu'elles puissent continuer à bénéficier de la clause d'exemption de responsabilité de la sphère de sécurité (*safe harbour*) prévue dans la directive e-commerce ;
- L'extension de la brevetabilité des algorithmes, en échange de leur protection, favoriserait leur divulgation et donc la transparence ;
- Les conditions générales d'utilisation d'un service interdisent souvent le test par des robots, ce qui peut empêcher en pratique de contrôler les résultats produits par les algorithmes utilisés pour ce service. Des exceptions pour contrôle pourraient être demandées.

L'enjeu juridique principal de l'utilisation des algorithmes dans le monde économique est lié à la capacité de contrôler les résultats produits par ces algorithmes.

4 QUELLES PRATIQUES DE RÉGULATION ?

Avec l'appui de la direction du Trésor, la mission a interrogé les services économiques des ambassades de France à Berlin, Washington, Tokyo, Séoul et Brasília. Parmi les réponses, la mission a retenu deux initiatives, développées aux USA et en Allemagne et qui sont citées ci-dessous. Mais c'est d'abord l'action européenne, en pointe de la réflexion sur la régulation des plateformes, qui mérite d'être développée.

4.1 Les actions de la Commission Européenne

Le rôle grandissant des plateformes est évoqué dans la Stratégie pour un marché unique numérique en Europe³⁵. Un des axes de cette stratégie est d'établir un environnement réglementaire approprié pour les plateformes et les intermédiaires, suivant trois directions d'action:

- améliorer l'accès aux biens et services numériques, afin de mettre en place un marché digital européen transparent et de taille conséquente ;
- favoriser le développement des infrastructures en tirant profit des évolutions technologiques et créer ainsi un environnement propice au développement des réseaux et services numériques ;
- faire en sorte que l'économie, l'industrie et l'emploi en Europe tirent pleinement parti des possibilités offertes par le numérique, moteur de croissance.

Ces actions reposent sur le document de travail «A Digital Single Market Strategy for Europe – Analysis and Evidence»³⁶, qui contient davantage de précisions sur la nature des problèmes abordés ainsi que des éléments étayant la stratégie. Une attention particulière est accordée aux problèmes rencontrés par les consommateurs et les PME (manque de clarté sur les données collectées et sur les informations affichés, manque de sensibilisation des consommateurs quant à la valeur et l'utilisation

³⁵ <https://ec.europa.eu/digital-single-market/digital-single-market>

³⁶ <http://eur-lex.europa.eu/legal-content/EN/TXT/PDF/?uri=CELEX:52015SC0100&from=EN>

de leurs données, les conditions d'accès aux plateformes) et les grandes entreprises (discrimination des tiers due à l'intégration verticale, prix de vente opaque dû aux frais d'envoi variables), d'où la nécessité de mettre en place un environnement réglementaire au sujet des plateformes.

Une consultation publique a eu lieu entre septembre 2015 et janvier 2016³⁷. Les questions posées ont porté sur diverses thématiques : la transparence (en particulier celle des moteurs de recherche), l'utilisation des informations collectées par les plateformes, les relations entre plateformes et fournisseurs (en particulier les contraintes sur les personnes et les entreprises qui souhaitent changer de plateforme), la meilleure manière de lutter contre les contenus illicites sur l'Internet.

Elles ont visé une grande diversité de plateformes : moteurs de recherche génériques (par exemple, Google, Bing) et spécialisés (Google Shopping, Kelkoo, Twenga, TripAdvisor), géolocalisation (Google ou Bing Maps), fils de nouvelles (Google News), sites de vente en ligne (Amazon, eBay, Allegro, Booking), films et musique (Deezer, Spotify, Netflix, Apple TV), partage de vidéo (YouTube, Dailymotion), systèmes de paiement (PayPal, Apple Pay), réseaux sociaux (Facebook, LinkedIn, Twitter, Tuenti), app stores (Apple App Store, Google Play), plateformes collaboratives (AirBnB, Uber, TaskRabbit, Bla-bla car).

Plus de mille réponses ont été collectées, en provenance de 27 pays européens mais aussi des Etats-Unis, et ont couvert une large gamme d'utilisateurs : citoyens individuels, entreprises commerciales, fournisseurs de services, plateformes de commerce électronique, instituts de recherche, associations de consommateurs. Une autre série de dix mille réponses individuelles a été reçue par l'intermédiaire d'une association de défense des consommateurs.

Voici les premières conclusions présentées par la Commission Européenne :

- **Plateformes** : elles devraient être plus transparentes, notamment sur les résultats de la recherche, la clarté des liens avec des fournisseurs et des critiques réelles. Elles ne fournissent pas suffisamment d'informations sur les données collectées et sur leurs conditions d'utilisation. La majorité des répondants citoyens et plateformes en ligne ont estimé que ces problèmes pourraient être mieux traités par une combinaison de réglementation, autorégulation et dynamique du marché. En revanche, les réponses en provenance des entreprises sont partagées entre des mesures purement réglementaires d'une part, ou une combinaison de dynamique du marché, d'autorégulation et de mesures réglementaires d'autre part;
- **données** : il est souhaitable d'établir une distinction claire entre les données personnelles et non personnelles, cependant une telle séparation reste difficile à faire. Les données engendrées dans le cadre d'opérations de recherche publique doivent être en accès ouvert. Le cadre juridique existant (lois, directives) ne répond pas aux questions de responsabilité posées par le développement de l'Internet des objets et d'autre objets connectés ;
- **Cloud** : la majorité des citoyens et des PME pensent que les fournisseurs de services Cloud ne sont pas suffisamment transparents quant à la sécurité et la protection des données des utilisateurs dans les services qu'ils fournissent, en revanche les entreprises et les associations professionnelles sont plus partagées. Une majorité de répondants attire l'attention sur le fait

³⁷ <https://ec.europa.eu/digital-single-market/news/first-brief-results-public-consultation-regulatory-environment-platforms-online-intermediaries>

que les termes et conditions contractuelles applicables aux services de Cloud ne sont pas négociables pour les consommateurs et souvent même pour les entreprises ;

- **économie collaborative** : une grande majorité des entreprises et des consommateurs reconnaissent qu'il existe des obstacles réglementaires au développement de l'économie collaborative en Europe, en particulier l'incertitude sur les droits et obligations des utilisateurs et des fournisseurs. Les fournisseurs de services d'économie collaborative, les plateformes et les pouvoirs publics privilégient davantage une meilleure orientation et information sur l'application de la réglementation existante, alors que les fournisseurs «traditionnels» de services (qui n'utilisent pas les plateformes en ligne) souhaitent plutôt promouvoir une nouvelle réglementation de l'économie collaborative. La majorité des répondants représentant les consommateurs considère que les plateformes de collaboration de l'économie fournissent suffisamment d'informations sur les fournisseurs de services, les droits des consommateurs, les caractéristiques et les modalités de l'offre et les droits statutaires.

La Commission Européenne a également lancé trois études externes qui appuient le cadre de l'analyse de ces réponses, les résultats sont attendus en principe pour ce printemps.

Onze gouvernements³⁸ viennent d'écrire à la Commission Européenne³⁹ en réponse à sa consultation sur les plates-formes, les données et le Cloud. Ces pays soulignent que les plateformes devraient être considérées comme des opportunités, pas des menaces, qu'elles sont déjà régulées significativement et ne devraient pas faire l'objet d'une régulation paralysante. C'est en favorisant les conditions de leur croissance que l'on favorisera le développement des plateformes européennes.

Avec l'initiative Franco-Allemande sur l'économie numérique⁴⁰, puis avec la loi République numérique, la France a pris une position en pointe sur la régulation, notamment des plateformes. L'enjeu de la capacité à contrôler le respect des dispositions réglementaires doit continuer à être porté au niveau européen.

Suite à la consultation sur les plateformes, la Commission Européenne pourrait lancer plusieurs actions. Ces informations ne sont pas encore confirmées officiellement. Concernant l'aide au développement de plateformes européennes compétitives, la Commission Européenne ciblerait le soutien à l'innovation dans les domaines de la santé, des véhicules autonomes et des villes intelligentes (*smart cities*).

Soucieuse d'harmoniser les règles dans l'espace économique européen, la Commission Européenne veut améliorer la coopération entre autorités de contrôle. Elle proposerait d'établir **un plan d'action pour augmenter la capacité technique des autorités** en matière de traitement et d'analyse de masses de données.

La Commission Européenne pourrait développer une **action en faveur de l'autorégulation pour la transparence**, avec un forum des parties prenantes en 2016, suivi d'un plan d'action, à réaliser avant fin 2018. Notamment, une action plus résolue est attendue de la part des plateformes de contenu en

³⁸ UK, Luxembourg, Finlande, Suède, Danemark, Estonie, Lettonie, Lituanie, République Tchèque, Pologne, Bulgarie

³⁹ <https://www.gov.uk/government/publications/digital-single-market-platforms>

⁴⁰ Conférence numérique franco-allemande « Accélérer la transformation numérique de nos économies » 27 octobre 2015

matière de lutte contre les incitations à la haine et d'accès à une information transparente et non-discriminatoire, *en particulier quand cette information est filtrée via un algorithme, ou manipulée par un processus de modération opaque.*

4.2 L'exemple américain

Un récent rapport du bureau exécutif de la Maison Blanche⁴¹ analyse l'évolution vers des offres de prix personnalisées : *"Broadly speaking, Big Data seems likely to produce a shift from third-degree price discrimination based on broad demographic categories towards personalized pricing and individually targeted marketing campaigns"*. Selon ce rapport, le jeu de la concurrence doit permettre aux consommateurs de rechercher les meilleures offres. Il souligne que le droit existant semble suffisant pour protéger les citoyens contre le risque de discrimination, mais que plus de transparence sur l'utilisation des données est nécessaire. Le rapport ajoute que le **"Big Data also provides new tools for detecting problems, both before and perhaps after a discriminatory algorithm is used on real consumers. For example, it is often straightforward to conduct statistical tests for disparate impact by asking whether the prices generated by a particular algorithm are correlated with variables such as race, gender or ethnicity"**.

L'attention des régulateurs américains se focalise sur le risque de discrimination dans les domaines sensibles de l'accès à l'emploi, au logement, au crédit, à l'assurance, à l'éducation et à la santé. Dans ces domaines, de nouveaux outils de tests statistiques doivent permettre, en amont ou en aval, de détecter ou tester les risques de discrimination.

Lors d'une conférence en février 2015 (NYU Conference on Algorithms and Accountability), la commissaire Julie Brill a déclaré *"it took the FTC nearly four years to study the ramifications of using credit scores for auto insurance underwriting. The FTC – and all other federal agencies for that matter – simply do not have the capacity to study every score out there. To borrow a phrase from the technology community, this approach doesn't scale."* Elle poursuit en expliquant que pour passer à l'échelle, il faut mobiliser à la fois les entreprises, les technologies, les consommateurs et les régulateurs.

En mars 2015, la Federal Trade Commission⁴² (FTC), qui disposait déjà d'un Chief Technologist Officer, a créé une équipe technique dédiée, chargée de développer l'expertise, les techniques d'investigation et les analyses pour faire face aux problématiques technologiques dues au rythme rapide des innovations dans l'économie numérique, impliquant plusieurs aspects de la protection des consommateurs : vie privée, sécurité des données, voitures connectées, maison intelligente, transparence des algorithmes, nouvelles méthodes de paiement, Big Data, Internet des objets. *"OTRI will provide expert research, investigative techniques and further insights to the agency on technology issues involving all facets of the FTC's consumer protection mission, including privacy, data security, connected cars, smart homes, algorithmic transparency, emerging payment methods, Big Data, and the Internet of Things"*.

⁴¹ Big data and differential pricing - The Council of Economic Advisers February 2015

⁴² La FTC, agence fédérale américaine, a comme mission d'appliquer le droit de la consommation et de contrôler les pratiques commerciales anticoncurrentielles.

L'**Office of Technology Research and Investigation (OTRI)** compte actuellement neuf personnes (6 agents de la FTC, 2 juristes et 1 expert). En cas de besoin, d'autres experts de la FTC peuvent également être affectés pour une durée déterminée (1 an) sur des projets de recherche conduits par l'OTRI. Il dispose des moyens, équipements et ressources du laboratoire technique de la FTC. Il peut faire également appel à des ressources externes et s'appuyer sur les travaux de chercheurs du monde académique et de l'industrie. Il anime un programme de stagiaires⁴³ (Internship).

Une partie des travaux de l'OTRI sont rendus publics, au travers des séminaires ou des communications, dont le but est de faire monter sa compétence technique sur le sujet mais également d'informer le grand public sur la mission de défense du consommateur de la FTC. Par exemple, la conférence FTC Privacy Con⁴⁴ du 14/01/2016 a réuni une grande diversité d'acteurs (organismes de réglementation, associations de défense des consommateurs, juristes, industriels, chercheurs, universitaires) dans le but de discuter des dernières recherches et tendances relatives à la vie privée des consommateurs et la sécurité des données.

Lors de cette conférence, plusieurs logiciels outils permettant de tester la "transparence" des systèmes ont été présentés :

- **AdFisher** (Universités Berkeley et Carnegie Mellon) est un système qui détermine les informations récoltées par les logiciels "traqueurs en ligne" et les corrèle avec les annonces publicitaires proposées lors de la navigation des Internauts ;
- **Sunlight** (Université Columbia) est un service en ligne qui étudie le ciblage des annonces publicitaires à partir d'informations issues des boîtes de courriel Gmail des Internauts ;
- **FairTest** (Université Columbia) est une boîte à outils pour les développeurs de logiciel, qui leur permet de tester la qualité d'un algorithme, en détectant des associations non souhaitées.

4.3 Une initiative allemande

En Allemagne, le ministère de la justice finance deux réseaux de plateformes dans les länder, les « veilleurs de marché » (Marktwächter), l'un pour les services financiers, l'autre pour l'économie numérique.

La **Markwächter « offre numérique »** s'appuie sur un réseau de 16 centres de protection des consommateurs dans toute l'Allemagne. Ils procèdent par des requêtes sur les portails en ligne qu'ils investiguent (c'est le « *mystery shopping* »). Il n'y a pas d'automatisation, les requêtes manuelles sont réalisées par les collaborateurs selon un protocole défini (une seule fois ou plusieurs jours de suite jusqu'à l'achat, à des horaires différents, depuis des terminaux différents, etc.). Pour l'analyse des cas qu'ils recensent à travers leurs centres de protection des consommateurs, ils ont pour l'instant un souci de qualité des données, qui ne sont pas uniformisées et pas toujours bien renseignées. Ils n'ont pas encore engagé de coopération avec un organisme spécialisé dans les technologies de l'information. Il n'y a pas non plus d'analyse des algorithmes sous-jacents ni de dialogue établi à ce jour avec les plateformes sur ce thème. Les responsables de la Markwächter pensent cependant que c'est une idée intéressante et vont essayer d'engager ce dialogue lors d'une prochaine opportunité.

⁴³ Un collaborateur de la CNIL a rejoint l'OTRI pour une durée de 3 mois.

⁴⁴ <https://www.ftc.gov/news-events/events-calendar/2016/01/privacycon>

4.4 Faut-il tester les algorithmes eux-mêmes ?

En Europe, les récentes décisions des autorités de la concurrence n'incriminent pas directement des algorithmes. A propos de sa communication des griefs adressée à Google au sujet de son service de comparaison de prix en avril 2015, la Commission européenne indique que « *pour mettre fin à un tel comportement, Google devrait traiter son propre service de comparaison de prix de la même manière que ceux de ses concurrents. Cela n'affecterait ni les algorithmes appliqués par Google, ni la manière dont cette dernière conçoit ses pages de résultats de recherche* ».

Les décisions françaises s'appuient sur l'analyse de documents publiés ou contractuels, rarement sur l'étude du fonctionnement des algorithmes de traitement des contenus. Par exemple :

- Les décisions de l'autorité de la concurrence vis à vis de Booking portent sur les conditions contractuelles imposées par Booking aux hôtels référencés ;
- La décision de l'Autorité de la Concurrence de septembre 2015, relative à une demande de mesures conservatoires de la société Gibmedia, critique le manque de transparence des conditions d'utilisation d'Adwords : « *Google, qui est susceptible de disposer d'une position dominante sur le marché français de la publicité en ligne liée aux recherches, a mis en œuvre la suspension du compte Adwords dans des conditions d'information difficilement compréhensibles pour Gibmedia* ».

Une enquête de la DGCCRF portant sur l'utilisation d'un algorithme

La société X exploite un site Internet de classement d'établissements touristiques établi par un algorithme propriétaire à partir des contributions des utilisateurs du site. Ce classement a fait l'objet de plaintes de professionnels, pour son opacité et des incohérences perçues entre classement affiché et réalité de la profession.

L'enquête de la DGCCRF a porté sur la véracité du classement mis en œuvre. Les enquêteurs ont tenté de reproduire les calculs de l'algorithme par des tests de masse sur un échantillon d'établissements. La méthode a consisté à collecter l'ensemble des données publiques en entrée, à utiliser les critères de classement annoncés par la société X sur son site Internet et à confronter les résultats avec les données affichées en sortie. En faisant varier certains critères à la définition incertaine et leur pondération, plusieurs classements ont été produits mais aucun n'a permis d'aboutir à celui affiché par la société X. Cette méthode aboutit à une conclusion partielle, démontrant l'existence de l'anomalie sans en déterminer les composantes. La réunion de la totalité des éléments recueillis durant l'enquête a permis toutefois de poursuivre la société X pour pratique commerciale trompeuse.

En phase d'enquête, les réponses de la société X aux demandes d'information de la DGCCRF étaient quasi-inexistantes. En phase contentieuse, elle a contesté la méthode, indiquant que l'algorithme prenait en compte un nouveau critère, l'ancienneté des avis des internautes, et était doté d'une précision de 16 décimales, rendant quasiment impossible une égalité entre établissements classés. Cette explication autorise la société X à contester la démonstration faite par la DGCCRF.

Les infractions recherchées en droit de la consommation portent essentiellement sur la réalité des allégations et promesses faites aux consommateurs, ainsi que sur la loyauté des informations qui leur sont délivrées. Il en est de même en droit de la concurrence s'agissant des professionnels.

Pour les services de contrôle, la démonstration de la déloyauté de l'information ou de la pratique commerciale trompeuse passe par le décryptage de l'algorithme, la connaissance de ses critères de fonctionnement et leur pondération. L'utilisation d'une méthode statistique ad hoc n'est pas suffisante et est sujette à forte contestation. Cela pose la question des moyens techniques et humains nécessaires pour pouvoir mener à bien les contrôles.

Les autorités de contrôle françaises doivent mettre en œuvre des moyens techniques et humains supplémentaires pour analyser les flux d'échanges de données et le fonctionnement des algorithmes de traitement des contenus.

5 DES PISTES D'ACTION

Autant le dire clairement, pour éviter toute ambiguïté : ce rapport ne propose pas une nouvelle régulation sectorielle qui s'appliquerait aux algorithmes.

Cependant, pour mieux comprendre le rôle joué par ces algorithmes de traitement des contenus et mieux concevoir l'encadrement de leur utilisation, il devient nécessaire de pouvoir contrôler les résultats qu'ils produisent. En ce qui concerne les pouvoirs publics, il s'agit de détecter l'existence de discriminations illicites et plus généralement de vérifier la conformité aux lois et règlements. En cas de présomption de non-conformité, se posera la question du lien avec la justice et de la valeur probante des contrôles. Non seulement c'est une tâche difficile, mais **les méthodes utilisables actuellement ne « passent pas à l'échelle »** : elles nécessitent trop de moyens, sont relativement lentes et ne permettent donc pas de suivre l'évolution des technologies.

Les bonnes pratiques professionnelles sont rares et récentes, comme par exemple le code d'engagements volontaires dans la publicité de la Digital Advertising Alliance (DAA) de 2015, donc beaucoup reste à faire. La certification des algorithmes et la normalisation sont embryonnaires. Quelques travaux sont consacrés au développement d'outils de contrôle et de prévention des discriminations, à la mesure de la performance ou de la robustesse des traitements, mais ils sont encore peu connus et peu utilisés.

5.1 Une plateforme collaborative scientifique française pour tester les algorithmes

L'objectif est de contribuer à développer des savoir-faire pour une production, une analyse et une valorisation des données qui soient responsables et éthiques et à en diffuser les bonnes pratiques. Pour y parvenir, il faut développer des outils de contrôle, mais aussi des outils permettant de faciliter la production d'analyses de données par de nouvelles approches technologiques de conception responsable (*responsible by design*).

Les questions de contrôle relèvent de trois types :

- Identifier les données traitées par l'algorithme et les échanges de ces données (supervision des entrées et des sorties) ;

- Tester le fonctionnement de l'algorithme à une échelle suffisante pour comprendre ce qu'il fait réellement ;
- Expliciter la qualité des résultats de l'algorithme.

De nombreux projets de recherche sont menés dans ces domaines. Aux USA, la conférence NICAR 2016, panel *“Algorithmic accountability: Case studies from the field”*⁴⁵, cite des investigations sur la censure dans la fonction d'auto-complétion de mots-clés de Google et de Bing, sur les pratiques de prix des cours en lignes de Princeton ou sur l'impact de l'algorithme d'Uber sur les prix et le temps d'attente. En France, l'INRIA a lancé le projet Mobilities⁴⁶, pour mieux comprendre les mécanismes d'accès aux données personnelles par les applications des Smart Phones. L'ANR finance le projet ALGODIV (recommandation algorithmique et diversité des informations du web, voir § 3.1.4).

Pour amplifier les travaux en France et « passer à l'échelle », nous proposons d'encourager le développement de logiciels de test et de mobiliser les équipes via une plateforme collaborative.

Exemples de plateformes collaboratives

Les plateformes de sciences citoyennes sont des programmes de recherche associant des scientifiques et une participation « citoyenne » d'amateurs volontaires, éclairés ou spécialistes. Il existe plus de 1100 projets de Sciences citoyennes (recensement effectué par SciStarter).

- Berkeley Open Infrastructure for Network Computing (BOINC) est une plate-forme de calcul distribué, fonctionnant sur la base de volontariat : il suffit à l'utilisateur d'installer une application sur leur ordinateur et d'effectuer quelques paramétrages. Sur cette plateforme tournent actuellement quelque 90 projets dans diverses disciplines (mathématique, informatique, physique, astronomie, biologie, médecine, climatologie) ;
- Citizen Science Alliance réunit des chercheurs académiques, des vulgarisateurs scientifiques et des développeurs de logiciels. Elle compte parmi ses collaborateurs une vingtaine d'universités américaines et britanniques et fait intervenir plus d'un million de participants bénévoles structurés autour du portail Zooniverse, qui participent activement aux travaux de recherche (astronomie, écologie, biologie, sciences du climat et sciences humaines) ;

D'autres types de plateformes collaboratives sont dédiés aux algorithmes et aux données :

- Data transparency lab est une *“community of technologists, researchers, policymakers and industry representatives working to advance online personal data transparency through scientific research and design”* ;
- Kaggle est une plateforme web organisant des compétitions en science des données pour l'enseignement, la recherche et l'industrie. Ses challenges en science des données, parfois accompagnés d'un prix pour les *datascientists* obtenant les meilleures performances, ont attiré plus de 500 000 participants ;

⁴⁵ <http://towcenter.org/exposing-algorithms-nicar2016/>

⁴⁶ <https://team.inria.fr/privatics/mobilities/>

Le projet de loi “République numérique” avait prévu dans son article 23 II : la « mise en place [...] d’une plateforme d’échange citoyen qui permet, dans une logique participative, de recueillir et de comparer des avis d’utilisateurs sur le respect des obligations des opérateurs de plateforme en ligne mentionnées à l’article L. 111-5-1 du code de la consommation, de mettre en place des outils d’évaluation de leurs pratiques, d’élaborer des bonnes pratiques visant à renforcer leurs obligations de clarté, de transparence et de loyauté, de définir des indicateurs permettant d’apprécier le respect de ces obligations et de rendre périodiquement publics les résultats de l’évaluation des indicateurs mentionnés ». Cette disposition a été supprimée lors du vote de la loi au Sénat.

Nous proposons plutôt **la création d’une plateforme collaborative scientifique.**

Recommandation n° 1. Créer une plateforme collaborative scientifique, destinée à favoriser le développement d’outils logiciels et de méthodes de test d’algorithmes, ainsi que de promouvoir l’utilisation de ces outils et méthodes. Cette plateforme permettrait de faire appel à des équipes de recherche, des enseignants, des étudiants ou des experts, publics ou privés.

Cette plateforme devrait faire l’objet d’un programme de recherche collaboratif à préciser avec les partenaires potentiels du projet. Les consultations menées par la mission conduisent à proposer :

- Périimètre : couvrir la recherche sur les différents aspects que représente la transparence des algorithmes et la loyauté ou l’équité des algorithmes d’analyse des données, non seulement sur Internet mais aussi, par exemple, pour les apps sur smartphone ou pour des logiciels embarqués ;
- Mode de fonctionnement : créer un portail logiciel d’outils de tests qui centralise les efforts de la communauté française spécialiste du sujet. Dans un deuxième temps, le projet pourrait évoluer vers une plateforme logicielle, dont les fonctions clés doivent être définies par un comité d’experts, avec des API bien spécifiées, maintenues par un centre de compétence logiciel faisant partie de la plateforme ;
- Gouvernance : créer un comité de pilotage (représentants d’autorités publiques, d’académiques, d’industriels, d’associations de citoyen) s’appuyant sur un comité d’experts scientifiques, chargé de proposer la spécification des fonctionnalités, la prospective et les orientations scientifiques de la plateforme, l’évaluation des projets, ... Mettre en place un centre de compétence (ingénierie logicielle) pour la mise à disposition d’outils de mesure et pour l’utilisation de la plateforme par des tiers ;
- Partenaires : associer des organismes de recherches, écoles, universités pour le développement de la recherche ; des entreprises pour apporter des cas d’usages, des données, des problématiques mais aussi pour tester des composants logiciels dans le cadre d’une démarche volontaire ; des associations apportant un point de vue citoyen dans la conception technique et scientifique ;
- Prise en charge et opération : le projet doit être porté par un ou plusieurs pilotes académiques, avec un financement public. Un programme d’affiliation pour soutenir les développements de cette plateforme devrait être proposé aux industriels ;

- International : des liens internationaux devraient être recherchés, par exemple avec l'initiative Data Transparency Lab (DTL⁴⁷) citée ci-dessus ou dans un cadre européen.

Deux projets ont été signalés à la mission comme pouvant présenter un fort lien avec la plateforme :

- Le projet TeraLab, lauréat de l'appel à projet Big Data 2012 du programme d'investissement d'avenir, est porté par l'Institut Mines – Télécom et le groupe des écoles nationales d'économie et de statistique (GENES). Ce projet s'appuie sur une plateforme technique évolutive pour offrir un service dédié à l'innovation en matière d'analytique de données.
- L'INRIA nous a signalé qu'une proposition « d'Institut Convergence » vient d'être déposée sous le nom I2---DRIVE: "Interdisciplinary Institute for Data Research: Intelligence, Values and Ethics". Ses objectifs présentent des intersections importantes avec le projet de plateforme.

5.2 La montée en compétence des autorités de contrôle

En France (hors questions de sécurité et de lutte contre le crime), l'Autorité des Marchés Financiers (AMF), l'autorité de régulation des jeux en ligne (ARJEL) et la Commission nationale informatique et libertés (CNIL) disposent d'équipes et de moyens de contrôle et d'investigation leur permettant de tester le fonctionnement d'algorithmes. La DGCCRF dispose d'un service spécialisé de contrôle du commerce électronique.

Sur le modèle américain de l'Office of Technology Research and Investigation (OTRI) créée en mars 2015 au sein de la Federal Trade Commission (voir 4.2), nous proposons de créer un **bureau spécialisé des technologies de contrôle de l'économie numérique**, chargé de développer et de mettre en œuvre des techniques de contrôle adaptées à un ensemble de thèmes nouveaux de l'économie numérique : loyauté des algorithmes, voitures connectées, maison intelligente, nouvelles méthodes de paiement, Big Data, Internet des objets.

La mission suggère que ce bureau dispose d'environ six personnes, à compétences surtout techniques / scientifiques, mais aussi juridiques et économiques. Il doit pouvoir faire appel aux compétences de laboratoires académiques ou industriels. Il pourrait être localisé au sein de la DGCCRF, mais pourrait être saisi par l'ensemble de la communauté intéressée, dont les autorités de contrôle (Autorité de la concurrence, ARCEP, CSA, CNIL, AMF, ARJEL, ACAM⁴⁸, ACPR, ANSM⁴⁹, ...). Le bureau serait doté d'un conseil d'orientation formé de représentants des pouvoirs publics, d'experts et de chercheurs. Il pourrait publier des éléments de doctrine de contrôle, pour aider les entreprises à mieux comprendre et à maîtriser les enjeux.

Recommandation n° 2. Créer une cellule de contrôle spécialisée « bureau des technologies de contrôle de l'économie numérique », pour l'ensemble des pouvoirs publics, implantée au sein de la DGCCRF.

⁴⁷ <http://www.datatransparencylab.org>

⁴⁸ Autorité de Contrôle des Assurances et des Mutuelles

⁴⁹ Agence Nationale de Sécurité du Médicament

5.3 Le développement de pratiques d'autorégulation

Face à la montée des interrogations sur l'impact des algorithmes de traitement des contenus et plus largement des différents progrès de l'intelligence artificielle, c'est évidemment d'abord aux entreprises de maîtriser ce qu'elles font et de le montrer à leurs clients, partenaires, pouvoirs publics et partenaires sociaux. C'est le sens du rapport de janvier 2016 de la FTC *"Big Data: A Tool for Inclusion or Exclusion? Understanding the issues"*. Ce rapport a pour objet d'informer les entreprises sur les travaux et les règlements pertinents concernant les analyses de données et de proposer des pistes pour en maximiser les bénéfices et en minimiser les risques.

Big Data: A Tool for Inclusion or Exclusion? Understanding the issues

FTC, January 2016

To maximize the benefits and limit the harms of Big Data, the Commission encourages companies to consider the following questions raised by research in this area:

How representative is your data set? Companies should consider whether their data sets are missing information about certain populations, and take steps to address issues of underrepresentation and overrepresentation. For example, if a company targets services to consumers who communicate through an application or social media, they may be neglecting populations that are not as tech-savvy.

Does your data model account for biases? Companies should consider whether biases are being incorporated at both the collection and analytics stages of Big Data's life cycle, and develop strategies to overcome them. For example, if a company has a Big Data algorithm that only considers applicants from "top tier" colleges to help them make hiring decisions; they may be incorporating previous biases in college admission decisions.

How accurate are your predictions based on Big Data? Companies should remember that while Big Data is very good at detecting correlations, it does not explain which correlations are meaningful. A prime example that demonstrates the limitations of Big Data analytics is Google Flu Trends, a machine-learning algorithm for predicting the number of flu cases based on Google search terms.

While, at first, the algorithms appeared to create accurate predictions of where the flu was more prevalent, it generated highly inaccurate estimates over time. This could be because the algorithm failed to take into account certain variables. For example, the algorithm may not have taken into account that people would be more likely to search for flu-related terms if the local news ran a story on a flu outbreak, even if the outbreak occurred halfway around the world.

Does your reliance on Big Data raise ethical or fairness concerns? Companies should assess the factors that go into an analytics model and balance the predictive value of the model with fairness considerations. For example, one company determined that employees who live closer to their jobs stay at these jobs longer than those who live farther away. However, another company decided to exclude this factor from its hiring algorithm because of concerns about racial discrimination, particularly since different neighborhoods can have different racial compositions.

C'est d'abord aux entreprises elles-mêmes de faire des contrôles internes et de tester la robustesse des traitements qu'elles réalisent. Les grandes entreprises du numériques ont leurs propres procédures, qui peuvent être très élaborées, comme le montre l'exemple du *news feed algorithm*⁵⁰ de Facebook. Elles cherchent en permanence à améliorer l'expérience utilisateur.

Dans certains cas, il peut être utile de communiquer sur les algorithmes et leurs tests, voire de permettre à des tiers de challenger les contrôles, par exemple via des hackathons sur des jeux de données d'entrée / sortie des algorithmes, comme on le fait parfois pour tester la sécurité des systèmes d'information.

5.3.1 Communiquer sur le traitement des données et le fonctionnement des algorithmes

Some designers prefer systems that operate as if by magic, delivering results without muddying the user experience with details of a complicated process. In contrast, we suggest that enabling active engagement with the process shows users that an algorithm exists and gives them an important sense that they are not controlled by an algorithm but are a part of one, and can have some influence on its results (M. Eslami and al).

L'exemple des évolutions du moteur de recherche de Google, montre l'importance croissante de la communication avec les utilisateurs. L'algorithme de Netflix est une des composantes de son succès, et il est vanté comme tel : le *Netflix tech blog* détaille ses composantes (il en combinerait 12), comment il fonctionne, comment il est testé : *"This is a Netflix blog focused on technology and technology issues. We'll share our perspectives, decisions and challenges regarding the software we build and use to create the Netflix service"*.

Comme le propose N. Diakopoulos⁵¹, il peut être intéressant de **personnaliser cette communication** : *"At a high level, transparency here might involve explaining the goal, purpose, and intent of the algorithm, including editorial goals and the human editorial process or social context crucible from which the algorithm was cast. Who at your company has direct control over the algorithm, who has oversight and is accountable? Ultimately we want to know who are the authors, or the designers, or the team that created this thing. **Who are behind these algorithms?**"*

Il existe déjà, dans de nombreuses entreprises et administrations françaises, une personne chargée de s'assurer du respect de la réglementation en matière de données personnelles, le correspondant informatique et libertés (CIL). Le règlement européen sur les données a prévu qu'à partir de 2018, il deviendra un Data Privacy Officers (DPO). La désignation d'un DPO est rendue obligatoire dans toutes les entreprises du secteur public, mais aussi pour toutes celles qui traitent de données sensibles. Le DPO ne doit pas être une simple fonction mais une expertise reconnue au sein de l'organisme.

Pour les entreprises qui utilisent des algorithmes de traitement des contenus qui sont affichés explicitement, ou perceptibles pour l'utilisateur, **nous proposons d'aller plus loin et d'identifier l'équipe ou la personne responsable du fonctionnement de ces algorithmes** (« chief algorithm

⁵⁰ http://www.slate.com/articles/technology/cover_story/2016/01/how_facebook_s_news_feed_algorithm_works.html

⁵¹ <http://towcenter.org/towards-a-standard-for-algorithmic-transparency-in-the-media/>

officer ») et de communiquer au nom de cette équipe, pour rendre visible l'action humaine qui est aux commandes derrière l'algorithme. Ce responsable doit être capable de donner les objectifs, les finalités et les contraintes du système. Il doit expliciter la fonction que l'algorithme optimise.

Recommandation n° 3. Communiquer sur le fonctionnement des algorithmes. Quand un algorithme est affiché explicitement, ou perceptible pour l'utilisateur, identifier l'équipe où la personne responsable de son fonctionnement (« chief algorithm officer ») et communiquer au nom de cette équipe, pour rendre visible l'action humaine qui est aux commandes derrière l'algorithme.

5.3.2 Promouvoir de bonnes pratiques dans quelques secteurs clé

Parfois, comme le montre l'exemple de la publicité en ligne, l'expérience accumulée peut progressivement conduire des acteurs du domaine à vouloir mettre en œuvre plus d'autorégulation, via un code de bonnes pratiques. Pour les acteurs français intéressés, il faut identifier le bon niveau de coordination – en général international – et être en mesure de se faire entendre à ce niveau.

Concernant les bonnes pratiques pour la gestion des données personnelles, une recherche conduite dans le cadre de la Chaire « Valeurs et politiques des informations personnelles⁵² », a recensé plus de 120 labels différents en Europe et aux USA (dont une centaine en Europe) ! C'est un domaine foisonnant et ces labels manquent donc encore de visibilité.

Quelques cas identifiés par la mission montrent des initiatives intéressantes, mais de portée limitée, avec quelques dizaines d'entreprises certifiées au maximum dans chaque cas. La CNIL a mis en place :

- Des « packs de conformité » : le pack de conformité « lutte contre la fraude » pour les assurances, couvre les méthodes de détection de la fraude *à l'aide de techniques de croisement de données s'appuyant sur des méthodes statistiques et des algorithmes permettant de modéliser des comportements pouvant se révéler frauduleux (scénarios, profils, produits...)*.
- Des labels. Adopté en 2014, le *référentiel de gouvernance « Informatique et Libertés »*, définit les règles et les bonnes pratiques permettant à un organisme d'assurer une gestion de ses données respectueuse des principes Informatique et Libertés.

Lancer des réflexions françaises relayées au niveau international

De nombreux algorithmes de recommandation prennent en compte les avis des internautes. La qualité de ces avis est parfois problématique. Avec la norme AFNOR NF Z74-501, sur la sincérité des avis en ligne de consommateurs, qui engage les certifiés à des audits réguliers, la France a anticipé les travaux internationaux. Le comité technique « réputation en ligne » de l'organisation internationale de normalisation (ISO), comité qu'elle a contribué à créer, a lancé des travaux sur une future norme ISO sur le même thème, qui sera présentée fin 2016 en enquête publique. Même si le nombre d'entreprises françaises certifiées est aujourd'hui très faible (une quinzaine de sites certifiés)

⁵² Chaire de l'Institut Mines Télécom, coordonnée par C. Levallois-Barth

la démarche est intéressante car elle **permet à la France de porter au niveau international des exigences** de fiabilisation du traitement des avis en ligne de consommateurs.

Commercialisation à distance de produits financiers et d'assurance

Le Pôle commun à l'Autorité de contrôle prudentiel et de résolution (ACPR) et à l'Autorité des marchés financiers (AMF) a mis en place, courant 2014, un groupe de travail spécifique pour mener une réflexion prospective sur la commercialisation à distance des produits financiers et d'assurance et anticiper sur les travaux européens en la matière. Dans les travaux européens en cours, on peut citer principalement le groupe de travail « *automated advice* » du comité joint des 3 autorités européennes (European Banking Authority (EBA), European Securities and Market Authority (ESMA), European Insurance and Occupational Pensions Authority (EIOPA)).

Le groupe de travail a cherché à caractériser les pratiques actuelles et les évolutions probables par des contrôles sur place d'acteurs significatifs du marché, par des visites mystères menées par l'AMF auprès d'une vingtaine d'établissements de crédit sur le thème de la souscription à distance d'instruments financiers, par des entretiens auprès d'acteurs présents dans la vente à distance : courtiers en ligne « *pure players* », prestataires de services d'investissement ou bancassureurs intégrés ou en lien avec des réseaux physiques.

Sur la base de cet état des lieux et d'une première analyse de la réglementation, le groupe a identifié les problématiques relatives aux différentes étapes : en amont de la commercialisation elle-même, les différents types de sollicitations ou d'orientation des prospects que permet internet, les questions d'identification dans les chaînes d'intermédiation virtuelles, la présentation des offres produits sur les sites, les modalités de recueil (et la mise à jour) des informations sur le client et de ses besoins, y compris lorsque ce recueil se fait par plusieurs acteurs, l'arbre de décision aboutissant au conseil (ou à sa mise à jour), la formalisation de ce conseil, la contractualisation de l'opération (avec une problématique spécifique liée à la signature électronique), les schémas de vente « mixte » associant par exemple internet et le téléphone.

La question des algorithmes se pose particulièrement pour la phase amont (orientation du client) et pour la phase recueil des informations et conseil délivré.

La suite des travaux consistera, en 2016 et 2017, à **identifier, pour chacun des thèmes retenus, les bonnes pratiques à promouvoir** ainsi que la forme la plus adéquate pour le faire. Un suivi des évolutions techniques et de leur impact sur les pratiques commerciales est également assuré par le groupe.

Nous proposons de développer ce type de réflexions sectorielles, avec l'établissement de forums nationaux proposant des codes de bonnes pratiques, qui seraient portés au niveau international.

La démarche serait la suivante, pour un secteur donné :

- Identifier des services, utilisant des algorithmes de traitement des contenus, en cours de déploiement avec des acteurs présents sur le territoire national ;

- Pour ces « services algorithmiques », retenir un pilote français du projet, chargé d'animer un forum national avec les acteurs du secteur, pour développer une réflexion sur les enjeux et les règles de bonnes pratiques adaptées ;
- Avec ces acteurs, identifier le bon cadre international pour établir et promouvoir des règles de bonnes pratiques reconnues concernant ces services.

Nous proposons de développer ce type de démarche dans des secteurs tels que l'emploi, la santé, la finance et l'assurance.

Recommandation n° 4. Développer, dans les secteurs de l'emploi, de la santé, de la finance et de l'assurance, les réflexions avec les parties prenantes pour identifier de nouveaux services utilisant des algorithmes de traitement des contenus. Pour ces « services algorithmiques », identifier un pilote chargé de réunir un forum pour établir et promouvoir au niveau international des règles de bonnes pratiques.

5.4 L'engagement citoyen

L'engagement citoyen est souhaitable pour préserver la confiance de la population dans l'économie numérique, mais aussi pour la rassurer contre une inquiétude émergente vis-à-vis des algorithmes « boîtes noires » ou contre les fantasmes du type « Terminator », où des machines munies d'intelligence artificielle, devenues autonomes, pourraient remplacer l'homme et dominer le monde.

L'engagement citoyen repose sur :

- Le partage d'un bon niveau de compréhension des problèmes à travers la société ;
- La possibilité d'accéder à l'information ou de la partager ;
- L'existence d'outils collectifs adaptés.

Le séminaire Heuritech et les échanges d'expériences.

Une initiative remarquable a été développée par la start-up Heuritech, qui a effectué une série de cours et séminaires, appelés Deep-Learning Paris Meetup⁵³. Ces séminaires sont destinés à des participants ayant des notions d'algorithmique et de programmation, qui souhaitent aborder le domaine du machine learning, ou à des spécialistes.

Après deux cours d'initiation aux réseaux de neurones et aux principaux outils de modélisation et programmation, la start-up a poursuivi par des séminaires plus spécialisés, donnés par les meilleurs spécialistes du domaine de l'apprentissage machine. Cette initiative connaît un grand succès, avec au total 2000 participants, le dernier séminaire d'avril 2016 étant suivi par quelque 330 personnes.

⁵³ <http://www.meetup.com/fr-FR/Deep-Learning-Paris-Meetup/>

Pour qu'ils puissent jouer un rôle, il est important de donner aux citoyens les bases nécessaires à la compréhension et à la maîtrise de l'utilisation de ces nouvelles technologies, en poursuivant des actions à divers niveaux :

- information auprès du grand public pour expliquer en grandes lignes le fonctionnement de divers algorithmes, par l'intermédiaire des conférences grand public, tables rondes et publications de vulgarisation scientifique ;
- introduction dans le cursus d'enseignement des programmes d'éducation numérique, où une partie sera consacrée aux algorithmes ;
- information de tous les publics sur les risques présentées par les applications utilisées, notamment d'exposition concernant les données personnelles, sur les règles élémentaires de vigilance à observer ou encore sur les divers moyens de protection, installation sur l'ordinateur personnel de logiciel de protection ou paramétrage des applications pour une protection effective, notamment pour prévenir la récolte abusive de données.

Pour les entreprises de l'économie numérique, très attachées à leur réputation, **l'engagement citoyen peut être un levier pour les entraîner dans un cercle vertueux**. Répondant à cet objectif, le projet loi "République numérique" avait prévu dans son article 23 II la mise en place d'une plateforme d'échange citoyen, déjà citée ci-dessus en §5.1.

Transparence : l'Etat exemplaire

#CodeImpot : un hackathon autour de l'ouverture du code source du calculateur impôts

Pour la première fois en France, une administration va au-delà de l'ouverture des données publiques et met à disposition le code source d'un de ses calculateurs. La Direction générale des finances publiques (DGFIP) a mis à partir du 1^{er} avril 2016 le code source du calculateur impôt à la disposition de tous. Acte de transparence et de gouvernement ouvert, cette ouverture permet d'explicitier les modalités de calcul des impôts, dans l'esprit de l'article 2 du projet de loi numérique. Elle est aussi un gage d'innovation car de nouveaux usages pourraient en découler, à l'image du micro-simulateur ouvert OpenFisca, que ce code enrichira.

Pour accompagner l'ouverture et développer des cas d'usage, Etalab et la DGFIP ont organisé les 1^{er} et 2 avril un hackathon autour de ce code source. Pourront en découler, à travers différents ateliers, des traductions de la « calculette impôt » vers d'autres langages de programmation, permettant le développement d'applications ou d'API Web, et des réutilisations par des chercheurs et des économistes pour réaliser des évaluations et des études. Après deux longues journées de travail, neuf projets ont été présentés lors des restitutions ouvertes au public.

En s'engageant dans le mouvement d'ouverture des codes sources des logiciels, la DGFIP ouvre la voie à la transparence des calculs et algorithmes qu'ils produisent. Cette démarche inédite pourrait faire école dans d'autres domaines, comme le calcul des droits à la retraite ou bien l'affectation des élèves dans l'enseignement supérieur.

Comme l'ont montré certaines interventions lors de la consultation sur le projet de loi « République numérique », la société attend de l'Etat une démarche exemplaire en matière de transparence de l'utilisation des algorithmes par la puissance publique. Cette attente s'est traduite dans plusieurs dispositions nouvelles du projet de loi. Le thème de la transparence des algorithmes rejoint celui de « l'open government ». Ces dispositions pourraient être complétées par une action de sensibilisation / formation spécifique à l'attention des agents publics.

Au sein des ministères économiques et financiers, l'Institut de la gestion publique et du développement économique (IGPDE) a signé un partenariat avec le Centre d'études des programmes économiques (Cepe), centre de formation continue qui appartient au Groupe des écoles nationales d'économie et statistique (Genes), pour une offre de formation au big data. En outre, au catalogue de l'IGPDE, deux actions de formation nouvelles ont été ouvertes en 2016 :

- Transformation numérique : opportunités économiques et risques (code 7771⁵⁴). A l'issue de la formation, les participants seront en mesure de : mieux appréhender les principaux concepts de l'économie numérique ; mieux saisir les opportunités et les risques liés au numérique ; préciser les politiques publiques et les réflexions en cours pour développer et accompagner la transformation numérique.
- **Transformation numérique : Etat et « Big Data »** (code 7783⁵⁵). À l'issue de la formation, les participants seront en mesure de : mieux comprendre de quelle manière la transformation numérique impacte l'Etat ; saisir les opportunités de la transformation numérique pour l'Etat ; mieux cerner les enjeux de l'ouverture et du traitement massif des données pour les acteurs publics. Cette session de formation est prévue sur un jour en octobre 2016.

Cette 2^{ème} action de formation pourrait être étendue en incluant une information sur les algorithmes utilisés par des acteurs publics et sur les enjeux juridiques, économiques et sociaux liés à la transparence des traitements réalisés par ces algorithmes. Elle devrait être promue pour toucher les agents publics concernés.

Recommandation n° 5. Lancer un programme de formation à l'attention des agents opérant un service public utilisant un algorithme, pour les former au respect des obligations de transparence et de communication inscrites dans la loi République numérique.

La régulation peut contribuer à préserver une image positive des progrès et des performances des technologies d'intelligence artificielle, et donc des femmes et des hommes qui travaillent dans ce domaine. C'est essentiel pour continuer à attirer les jeunes générations dans les filières de formation correspondantes (mathématiques, ingénieurs ou « data scientists ») et pour créer des emplois. Trouver des solutions aux problèmes émergents posés par les progrès de l'intelligence artificielle est une dimension de la confiance dans l'économie numérique.

⁵⁴ <http://alize.alize/brehat/catalogue/2016/CataloguewebAC/co/7771.html>

⁵⁵ <http://alize.alize/brehat/catalogue/2016/CataloguewebAC/co/7783.html>

ANNEXES

Annexe 1 : Lettre de mission



SECRETARIAT D'ETAT CHARGE DU NUMERIQUE

Paris, le

La Secrétaire d'Etat

à **27 OCT. 2015**

Monsieur le Vice-président du Conseil général
de l'Economie, de l'Industrie, de l'Energie et
des Technologies

Objet : Mission relative aux modalités de régulation des algorithmes de traitement des contenus.

N/Réf : NUM/2015/058160 C

Comme l'a souligné le récent rapport du Conseil National du Numérique¹, le modèle de développement propre aux plateformes induit des interrogations sur la pertinence des modes de régulation existants. Certaines plateformes dominantes sur leur marché (moteurs de recherche, réseaux sociaux, plateformes d'achat en ligne, etc.) jouent ainsi un rôle de prescripteur en orientant une grande part du trafic utilisateur, alors même que les mécanismes de tri et de sélection des contenus proposés apparaissent souvent opaques (liens publicitaires, contenus personnalisés, sélection algorithmique générique, etc.). De même, l'utilisation faite par ces plateformes des données personnelles des utilisateurs n'est généralement pas explicite et peut, par exemple, conduire à des pratiques illicites de différenciation de prix. Enfin, sur le plan de la relation entre entreprises, il est d'intérêt général pour la vitalité de l'économie et la liberté de concurrence de garantir l'équilibre des relations commerciales et de permettre l'arrivée de nouveaux entrants, dont les startups et entreprises innovantes, en évitant les situations abusives de dépendance ou de position dominante.

Le gouvernement a donc fait de la régulation des plateformes un axe important de sa stratégie numérique, présentée en juin. Je souhaite que le Conseil Général de l'Economie conduise une mission visant à proposer un plan d'actions sur le sujet.

Dans le cadre de votre mission, vous aborderez notamment les questions suivantes :

1° Quels sont les principaux enjeux liés à la régulation des algorithmes (sur le plan économique, juridique, de protection du consommateur, etc.) et quels sont les principaux secteurs économique concernés pour la France et pour l'Europe ?

¹ « Ambition numérique », Conseil National du Numérique, juin 2015, pp. 58-70

2° Quelles dispositions permettraient d'assurer une régulation efficace de leurs algorithmes, à la fois sur le plan de la concurrence et de la protection des utilisateurs, tout en préservant la capacité d'innovation du secteur ? Vous étudierez d'une part les contraintes législatives et réglementaires envisageables (par exemple : obligation d'ouverture du code à un tiers de confiance, obligation d'information des utilisateurs sur les critères utilisés par les algorithmes, évolution de la réglementation existante sur les « pratiques déloyales » et la notion de « déséquilibre significatif », etc.) ; et d'autre part l'organisation et les compétences à mettre en œuvre pour assurer effectivement un dynamisme économique et une régulation adéquate (montée en compétence de l'administration, mise en place de structures dédiées aux tests de neutralité des algorithmes², recours au crowdsourcing pour recueillir les informations adéquates, évolution des missions des autorités de régulation, etc.).

3° Quels outils de « droit souple » pourraient être adoptés pour encourager la transparence des algorithmes (sensibilisation du grand public, mise en place de dispositifs de certification, de labels, de chartes, etc.) ?

Vous veillerez à inscrire votre analyse et vos recommandations à la fois dans la perspective d'actions nationales et d'actions qui pourraient être portées au niveau européen, dans le prolongement de la stratégie numérique de la Commission européenne³, voire au niveau d'instances internationales (Organisation mondiale du commerce, organisations internationales de gouvernance ou de normalisation du secteur numérique, etc.).

Vous pourrez vous appuyer pour la conduite de votre mission sur le concours de l'ensemble des services ministériels concernés (en particulier la DGE dont son Agence du Numérique, la DGCCRF, la DG Trésor et son réseau international). Vous veillerez également à consulter les autorités administratives concernées (Autorité de la concurrence, CNIL, ARCEP,...).

Votre rapport me sera remis sous 5 mois, et une note d'étape me sera transmise d'ici 3 mois.


Axelle LEMAIRE



² Aux Etats-Unis, la Federal Trade Commission vient de créer un « Office of Technology Research and Investigation (OTRI) » dédié à l'étude de ces questions et aux tests de neutralité des algorithmes.

³ Communication de la commission « Stratégie pour un marché unique numérique en Europe », 6 mai 2015

Annexe 2 : Liste des acronymes utilisés

ACAM	Autorité de Contrôle des Assurances et des Mutuelles
ACPR	Autorité de Contrôle Prudentiel et de Résolution
ALLISTENE	Alliance des Sciences et Technologies du Numérique
AMF	Autorité des Marchés Financiers
ANSM	Agence Nationale de Sécurité du Médicament
API	Application Programming Interface
ARCEP	Autorité de Régulation des Communications Électroniques et des Postes
ARJEL	Autorité de Régulation des Jeux En Ligne
ARPP	Autorité de la Régulation Professionnelle de la Publicité
CGE	Conseil Général de l'Économie
CERNA	Commission de réflexion sur l'Éthique de la Recherche en sciences et technologies du Numérique d'Allistene
CIL	Correspondants Informatique et Libertés
CNIL	Commission Nationale de l'Informatique et des Libertés
CNNum	Conseil National du Numérique
COE	Conseil d'Orientation de l'Emploi
CSA	Conseil Supérieur de l'Audiovisuel
DAA	Digital Advertising Alliance
DGCCRF	Direction Générale de la Concurrence, de la Consommation et de la Répression des Fraudes
DGE	Direction Générale des Entreprises
DGFIP	Direction Générale des Finances Publiques
DPO	Data Privacy Officers
EBA	European Banking Authority
EIOPA	European Insurance and Occupational Pensions Authority
ESMA	European Securities and Market Authority
ETF	Exchange Traded Funds
FCA	Financial Conduct Authority (UK)
FEVAD	Fédération E-commerce et Vente à Distance
FTC	Federal Trade Commission
GAFA	Google – Amazon – Facebook – Apple
GFII	Groupement Français des l'Industrie de l'Informatique
HFT	High-Frequency Trading
IA	Intelligence Artificielle
IAB	Interacting Advertising Bureau
IGPDE	Institut de la Gestion Publique et du Développement Économique
INRIA	Institut National de Recherche en Informatique et en Automatique
INSERM	Institut National de la Santé et de la Recherche Médicale
MIF	Marchés d'Instruments Financiers
MTF	Multilateral Trading Facilities
NATU	Netflix – Airbnb – Tesla – Uber

OIP	Open Internet Project
OTRI	Office of Technology Research and Investigation
PaaS	Platform as a Service
SEO	Search Engine Optimisation
SRI	Syndicat des Régies Internet
SGMAP	Secrétariat Général pour la Modernisation de l'Action Publique

Annexe 3 : Liste des personnes rencontrées ou interrogées

Organismes publics et parapublics

Cabinet de la Secrétaire d'Etat chargée du Numérique

- M. Bertrand PAILHÈS, Directeur du cabinet
- M. Julien CHAUMONT, Chargé de mission

Direction Générale de la Concurrence, de la Consommation et de la Répression des Fraudes (DGCCRF)

- M. Vincent DESIGNOLLES, Directeur du cabinet
- Mme Cécile PENDARIES, Sous-directrice, Politiques de la concurrence et affaires juridiques
- M. Didier GAUTIER, Chef du service national des enquêtes
- M. Jean-Marc LEREST, Inspecteur principal
- Mme Claire-Lise BORDES, Inspectrice principale

Direction Générale des Entreprises (DGE)

- Mme Chantal RUBIN, Adjointe au sous-directeur Réseaux et usages numériques
- M. Benoît PELLIN, Chargé de mission, bureau de l'audiovisuel et du multimédia
- Mme Claire IFFLI, Chargé de mission, bureau règlement européen et commerce électronique

Direction générale du Trésor (pour l'interrogation des missions économiques à l'étranger)

- Mme. Catherine FERRIOL, Cheffe bureau Stratégie, Études et Pilotage
- Mme Pascale SAINT-SULPICE BODIN, Adjointe à la cheffe bureau Stratégie, Études et Pilotage

Secrétariat général pour la modernisation de l'action publique (SGMAP)

- Mme Laure LUCCHESI, Directrice adjointe mission ETALAB
- M. Simon CHIGNARD, Chargé de mission

Agence du numérique

- M. Igor PRIMAUT, Directeur mission « Très Haut Débit »
- M. Eric DELANNOY, Chef du pôle Outils, Technique et Standardisation
- M. Bertrand VANDEPUTTE, Expert technique, mission « Très Haut Débit »

Autorité de la concurrence

- M. Nicolas DEFFIEUX, Rapporteur général adjoint
- Mme Clémence HARDY, Rapporteur
- M. Mathieu GUENNEC, Rapporteur

Autorité de contrôle prudentiel et de résolution (ACPR)

- M. Olivier FLICHE, Directeur du contrôle des pratiques commerciales (DCPC)
- Maryvonne MARY, Chef du service du contrôle des intermédiaires (DCPC)
- Véronique LE-OMBY, Service de coordination (DCPC)
- Patrig HERBERT, Contrôleur des pratiques commerciales (DCPC)
- M. Bernard REY, Chef de mission, Délégation au Contrôle sur Place

Autorité des marchés financiers (AMF)

- Mme Claire CASTANET, Directrice des relations avec les épargnants
- M. Laurent COMBOURIEU, Directeur des enquêtes
- Mme Christine BONNET, Enquêtrice
- Mme Diane HAMILTON, Direction des marchés affaires internationales

Autorité de régulation des communications électroniques et des postes (ARCEP)

- M. Stéphane LHERMITE, Directeur affaires économiques et de la prospective
- M. Pierre-Jean BENGHOZI, Membre du Collège de l'ARCEP

Autorité de la régulation professionnelle de la publicité (ARPP)

- M. Stéphane MARTIN, Directeur Général
- Mme Magali JALADE, Responsable des affaires publiques et réglementaires
- M. Mohamed MANSOURI, Directeur des opérations et des systèmes d'information

Commission nationale de l'informatique et des libertés (CNIL)

- M. Edouard GEFFRAY, Secrétaire Général
- M. Gwendal LE GRAND, Directeur des technologies et de l'innovation
- M. Stéphane GREGOIRE, Chef du service des affaires économiques

Conseil national du numérique (CNNum)

- M. Yann BONNET, Secrétaire Général

Conseil supérieur de l'audiovisuel (CSA)

- M. Nicolas CURIEN, Conseiller
- Mme Nathalie SONNAC, Conseiller

Institut National de Recherche en Informatique et en Automatique (INRIA)

- Mme Nozha BOUJEMAA, Conseillère auprès du président-directeur général
- M. François SILLION, Directeur général délégué à la science

Institut de la Gestion Publique et du Développement Économique (IGPDE)

- Patricia BARDOUX, Chargée de clientèle, Relations avec les clients

Telecom-ParisTech

- M. Stéphan CLEMENÇON, Professeur
- Mme Claire LEVALLOIS-BARTH, Maître de conférences en droit, Coordinatrice de la Chaire Valeurs et politiques des informations personnelles
- M. Patrick WAELBROECK, Professeur d'économie industrielle et économétrie

Telecom Ecole de Management

- Mme Christine BALAGUE, professeure, Titulaire de la Chaire Réseaux Sociaux et Objets Connectés

Ecole Normale Supérieure

- M. Stéphane MALLAT, Professeur

Université Paris Dauphine

- M. Alexis TSOUKIAS, Directeur du LAMSADE (UMR CNRS)

Université Pierre et Marie Curie

- M. Jean-Gabriel GANASCIA, Professeur, directeur de l'équipe ACASA (LIP6)

Universcience

- M. Pierre DUCONSEILLE, Commissaire d'exposition (entretien téléphonique)

Entreprises, Organisations professionnelles, Cabinets Conseil**Critéo**

- M. Romain NICCOLI, CTO

Heuritech

- M. Tony PINVILLE, CEO
- M. Charles OLLION, CTO

Digital-Ethics

- M. Paul-Olivier GIBERT, CEO

Google

- Mme Maria GOMRI, Directrice juridique France, Afrique du Nord, Moyen Orient
- M. Fabien CURTO- MILLET, Chef économiste adjoint
- Mme Alexandra ALAFERRIERE, affaires publiques
- M. Oliver ESPER, affaires publiques

Groupeement Français des l'Industrie de l'Informatique (GFI)

- M. Alain COUILLAUT, Délégué général
- M. Eric VILLEMONTÉ de la CLERGERIE, Expert
- M. Guillaume PRIGENT, Expert

Le Guide

- M. Olivier SICHEL, Chaiman @ CEO

Médiation & Arguments

- M. Léonidas KALOGEROPOULOS, Président-directeur général

Orange Labs

- M. Dominique CARDON, sociologue, professeur associé à l'Université de Marne-la-Vallée

QWANT

- M. Eric LEANDRI, Directeur général

Successionweb

- M. Patrick ALBERT, Président

Annexe 4 : Glossaire

Intelligence artificielle : technologie qui imite la pensée humaine et autres processus cognitifs, afin de résoudre de manière automatique des problèmes complexes, avec des multiples applications : reconnaissance automatique d'image ou de la parole, conduite autonome des véhicules, navigation autonome des robots, traduction automatique, traitement automatique du langage naturel, aide au diagnostic et à la décision, fusion de données, génération et détection de nouveaux concepts et abstractions.

Algorithme : une succession finie et bien définie d'opérations ou d'instructions qui permettent de résoudre un problème ou d'obtenir un résultat. En général, l'algorithme utilise des données d'entrée, les traite suivant des instructions précises et fournit un résultat.

Data Mining : processus d'extraction de relations à partir de grands ensembles de données en combinant les méthodes de statistiques et de l'intelligence artificielle avec la gestion des bases de données. Il est devenu un outil incontournable des entreprises modernes pour la connaissance du marché et la prise de décisions.

Page Rank : le premier algorithme du moteur de recherche Google qui évalue la popularité des sites web, donc influence l'ordre de leur référencement lors d'une requête Google. Le Page Rank d'un site web est donné par la somme des Page Rank des autres sites qui pointent vers le site donné, divisé par le nombre des liens dont dispose chaque site. Actuellement Google n'utilise plus uniquement Page Rank mais plutôt une série d'algorithmes de référencement qui prennent en compte deux cents paramètres ou signaux (date du site, évolution du contenu, analyse des requêtes et des clics, trafic sur la site, etc.)

Filtrage collaboratif : méthodes qui utilisent les opinions et les évaluations collectés à partir d'un groupe d'utilisateurs pour construire des systèmes de recommandation (du type Amazon ou Netflix), afin d'aider un utilisateur dans ses choix, par exemple pour l'achat d'un produit. Le principe de base est que si la personne A a la même opinion que la personne B sur une question, il est plus probable que la personne A ait la même opinion que la personne B sur une autre question, plutôt que la personne X, choisie au hasard.

Machine Learning : branche de l'intelligence artificielle, fondé sur des méthodes d'apprentissage et d'acquisition automatique de nouvelles connaissances par les ordinateurs, utilisant des exemples, des cas ou des expériences passées ou à partir de ses propres expériences ou explorations. L'apprentissage peut être supervisé (utilisation de données d'entrées/sorties connues pour déterminer, corriger et améliorer les paramètres de l'algorithme), par renforcement (même méthode mais on ne récompense le système que chaque fois qu'il a fourni un bon résultat) ou non-supervisé (utilisation de données non connues à priori, l'algorithme doit les structurer lui-même), cette dernière méthode n'étant pas encore maîtrisée de manière satisfaisante et faisant objet d'intenses recherches.

Réseau de Neurones : méthode de Machine Learning fondée sur des principes de traitement de données inspirés du fonctionnement du cerveau. En organisant des unités de traitement simples (neurones) dans une architecture en couches et hautement parallèle, on peut effectuer des calculs

très complexes, se traduisant par un système de classification très puissant. L'apprentissage se fait à partir de très nombreux exemples d'entrées / sorties (apprentissage supervisé), en effectuant des petites modifications répétées au niveau des neurones, ce qui rend difficile la compréhension du processus de raisonnement interne, et donc l'explication pour une conclusion particulière. On utilise cette méthode lorsque la production de résultats est plus importante que la compréhension de son fonctionnement, avec des applications dans la reconnaissance d'images, en particulier l'écriture manuscrite, la conduite autonome du véhicule, la traduction automatique, l'aide au diagnostic, l'analyse de crédit, etc.

Réseau de Neurones Convolutif : architecture particulière d'un réseau de neurones, caractérisée par un grand nombre de couches et un nombre limité de connections pour chaque neurone, qui a connu un développement important ces dernières années, grâce à la amélioration de la puissance de calcul des cartes graphiques des ordinateurs. Cette technique a permis de grandes avancées dans la reconnaissance d'images, la conduite autonome du véhicule (Google Car, Tesla), la navigation autonome des robots (Spot et Atlas, construits par Boston Dynamics) ou la reconnaissance de la parole (Goggle Voice utilisé par Android). Ce type de réseau, caractérisé par un grand nombre de couches, est génériquement qualifié de « *Deep Learning* ».

Algorithmes de recommandation : algorithme dont le but est la mise au point d'une forme spécifique de filtrage de l'information visant à présenter les éléments d'information (pages Web, news, livres, images, musique, clips vidéo, films) ou les éléments sociaux (personnes, groupes, communautés), qui sont susceptibles d'intéresser l'utilisateur. En général, ce type d'algorithme compare le profil d'un utilisateur à certaines caractéristiques de référence, et cherche à prédire « l'avis » que donnerait un utilisateur à un élément cité auparavant (pages Web, news, ... communautés) qu'il n'avait pas encore considéré. Une grande partie de ces algorithmes sont fondés sur le filtrage collaboratif.

Loyauté (d'un algorithme) : la nécessité pour un algorithme de ne faire que ce qu'il est censé faire et de le faire bien.

Transparence (d'un algorithme) : caractéristique d'un algorithme de permettre aux utilisateurs de comprendre où visualiser son fonctionnement et ses résultats.

Neutralité du Net : principe qui garantit l'égalité de traitement de tous les flux de données sur Internet, il exclut toute discrimination à l'égard de la source, de la destination ou du contenu de l'information transmise sur le réseau. Ce principe garantit que les utilisateurs ne seront jamais confrontés à une gestion du trafic Internet qui aurait pour effet de limiter leur accès aux applications et services distribués sur le réseau. La neutralité du Net assure que les flux d'information ne sont ni bloqués, ni dégradés, ni favorisés par les opérateurs de télécommunications, permettant ainsi aux utilisateurs d'utiliser librement l'architecture communicationnelle.

Annexe 5 : Bibliographie

Livres :

Dominique Cardon – A quoi rêvent les algorithmes ? (Seuil, 2015)

Pedro Domingos – The master algorithm (Basic books, 2015)

Evgeny Morozov – Le mirage numérique (Les Prairies Ordinaires, 2015)

Frank Pasquale – The Black Box Society (Harvard University Press, 2015)

Eli Pariser – The Filter Bubble (Penguin, 2012)

Eric Sadin – La vie algorithmique (L'Échappée Editions, 2015)

George Heineman, Gary Pollice and Stanley Selkow – Algorithms in a Nutshell: A Practical Guide (O'Reilly, 2015)

Thomas Cormen, Charles Leiserson, Ronald Rivest, Clifford Stein – Introduction to Algorithms (MIT Press, 2009)

Ethem Alpaydin – Introduction to Machine Learning (MIT Press, 2014)

Stuart Russell, Peter Norvig – Artificial Intelligence: A Modern Approach (Pearson Education, 2016)

Rapports, brochures et textes juridiques :

Projet de Loi pour une République numérique (déc. 2015)

<http://www.assemblee-nationale.fr/14/projets/pl3318.asp>

Neutralité des plateformes (CNNum, mai 2014)

http://www.cnnumerique.fr/wp-content/uploads/2014/06/CNNum_Rapport_Neutralite_des_plateformes.pdf

Ambition numérique – pour une politique française et européenne de la transition numérique (CNNum, juin 2015)

<https://contribuez.cnnumerique.fr/sites/default/files/media/CNNum--rapport-ambition-numerique.pdf>

Etude annuelle 2014 du Conseil d'Etat - Le numérique et les droits fondamentaux (sept. 2014)

<http://www.ladocumentationfrancaise.fr/var/storage/rapports-publics/144000541.pdf>

A Digital Single Market Strategy for Europe – Analysis and Evidence (mai 2015)

<http://eur-lex.europa.eu/legal-content/EN/TXT/PDF/?uri=CELEX:52015SC0100&from=EN>

US Department of Homeland Security - Cybersecurity Insurance Workshop Readout Report (Nov 2012)

www.dhs.gov/sites/default/files/publications/November%202012%20Cybersecurity%20Insurance%20Workshop.pdf

Propositions de la CNIL sur les évolutions de la loi informatique et libertés dans le cadre du projet de loi numérique (janv 2015)

https://www.cnil.fr/sites/default/files/typo/document/Les_propositions_de_la_CNIL_sur_les_evolutions_de_la_loi_Informatique_et_Libertes.pdf

La dynamique d'Internet - Prospective 2030 (juin 2013)

http://www.strategie.gouv.fr/sites/strategie.gouv.fr/files/atoms/files/presentation_cgsp_28_juin_2013_v4.pdf

Cahiers IP Innovation & Prospective No.3 – Lire Écouter, Regarder et Jouer à l'Heure de la Personnalisation (CNIL)

https://www.cnil.fr/sites/default/files/typo/document/CNIL_CAHIERS_IP3.pdf

Le numérique, comment réguler une économie sans frontières ? France Stratégie (oct. 2015)

http://www.strategie.gouv.fr/sites/strategie.gouv.fr/files/atoms/files/note_danalyse_n35_-_15.10.16_h_30.pdf

Application of the Self-Regulatory Principles of Transparency and Control to Data Used Across Devices (DAA)

http://www.aboutads.info/sites/default/files/DAA_Cross-Device_Guidance-Final.pdf

Lire, écouter, regarder et jouer en ligne à l'heure de la personnalisation, Cahier IP n°3 (CNIL)

<https://www.cnil.fr/fr/lire-ecouter-regarder-et-jouer-en-ligne-lheure-de-la-personnalisation-decouvrez-le-nouveau-cahier-ip>

Articles :

Scalable Approaches to Transparency and Accountability in Decisionmaking Algorithms (Julie Brill)

https://www.ftc.gov/system/files/documents/public_statements/629681/150228nyualgorithms.pdf

A Field Trial of Privacy Nudges for Facebook (Yang Wang et al)

<http://repository.cmu.edu/cgi/viewcontent.cgi?article=1341&context=heinzworks>

Airline Price Discrimination (Brian Stacey)

https://mpra.ub.uni-muenchen.de/69168/1/MPRA_paper_69168.pdf

Crying Wolf? On the Price Discrimination of Online Airline Tickets (Thomas Vissers et al)

<https://hal.inria.fr/hal-01081034/document>

What's next for artificial intelligence in the enterprise (James Haight)

<http://www.computerworld.com/article/2872312/whats-next-for-artificial-intelligence-in-the-enterprise.html>

Strong Artificial Intelligence is Emerging as we Talk (Yves Caseau)

<http://informationsystemsbiology.blogspot.fr/2015/06/strong-artificial-intelligence-is.html>

Twitter's new timeline faces skeptical advertisers (Patrick Kulp)

<http://mashable.com/2016/02/10/twitter-timeline-brands/>

Twitter's new timeline is here, and it's all about the algorithm (Karissa Bell)

<http://mashable.com/2016/02/10/twitter-launches-new-timeline/>

Twitter - Un algorithme peut-il être accusé de violation de la vie privée ? (Elodie)

<http://www.journaldugeek.com/2015/09/16/twitter-algorithme-vie-privee/>

Big Data : vers des places de marché pour les algorithmes (Guillaume Serries)

<http://www.zdnet.fr/actualites/big-data-vers-des-places-de-marche-pour-les-algorithmes-39831896.htm>

Les Big Data n'ont aucune utilité sans les algorithmes annonce Gartner (Dirk Basyn)

<http://www.channelnews.fr/bienvenue-dans-leconomie-algorithmique-annonce-gartner-56506>

The Internet of Things Will Give Rise To The Algorithm Economy (Peter Sondergaard)

<http://blogs.gartner.com/peter-sondergaard/the-internet-of-things-will-give-rise-to-the-algorithm-economy/>

Big Data et objets connectés : quand les algorithmes prennent le pouvoir (Philippe Rosé)

<https://www.bestpractices-si.fr/blogs/l-avis-de-la-redaction/quand-les-algorithmes-prennent-le-pouvoir>

Antitrust and the Robo-Seller: Competition in the Time of Algorithms (Salil Mehra)

http://papers.ssrn.com/sol3/papers.cfm?abstract_id=2576341

Conseil d'Analyse Économique - note n°26 (oct. 2015)

<http://www.cae-eco.fr/Economie-numerique.html>

L'Autorité de la concurrence :

- plainte à l'encontre de Google par GibMedia

http://www.autoritedelaconcurrence.fr/user/standard.php?id_rub=606&id_article=2612

- engagements de Booking.com

http://www.autoritedelaconcurrence.fr/user/standard.php?id_rub=606&id_article=2534

Autorité de la concurrence : propagande ou incompétence ? (Guilain Denisselle)

<http://www.tendancehotellerie.fr/articles-breves/associations-politiques-institutionnels-syndicats/4767-article/autorite-de-la-concurrence-propagande-ou-incompetence>

La CNIL a délivré plus de 50 labels

<https://www.cnil.fr/fr/la-cnil-delivre-plus-de-50-labels-0>

Le numérique, l'emploi à réinventer ?

http://digital-society-forum.orange.com/fr/les-forums/700-le_numerique_lremploi_a_reinventern

AMF - La Lettre de la régulation financière n° 16 (Janvier 2015)

<http://www.amf-france.org/Publications/Lettres-et-cahiers/Lettre-de-la-regulation-financiere/Archives.html?>

Les cahiers de l'ARCEP :

<http://www.arcep.fr/index.php?id=21&L=1> (voir no. 11, pages 56 et 57)

Le Big Data des banques sous l'oeil des régulateurs européens (Katherine Noyes)

<http://www.lemondeinformatique.fr/actualites/lire-le-big-data-des-banques-sous-l-oeil-des-regulateurs-europeens-62578.html>

The new age of algorithms (Mircea Mihaescu)

<http://banknxt.com/49972/new-age-of-algorithms/>

Algorithms Everywhere (Nicholas Diakopoulos)

<http://towcenter.org/algorithms-everywhere/>

Towards a Standard for Algorithmic Transparency in the Media (Nicholas Diakopoulos)

<http://towcenter.org/towards-a-standard-for-algorithmic-transparency-in-the-media/>

The Anatomy of a Robot Journalist (Nicholas Diakopoulos)

<http://towcenter.org/the-anatomy-of-a-robot-journalist/>

Accountability in Algorithmic Decision-making (Nicholas Diakopoulos)

<http://queue.acm.org/detail.cfm?id=2886105>

The Perils of Algorithm-Based Marketing (Utpal Dholakia)

<https://hbr.org/2015/06/the-perils-of-algorithm-based-marketing>

Bulle de filtres

https://fr.wikipedia.org/wiki/Bulle_de_filtres

Faut-il un CSA des algorithmes ? (Viuz)

<http://viuz.com/2014/09/13/le-coin-du-contrarian-faut-il-un-csa-des-algorithmes/>

La régulation des géants du Web reste à inventer (Romain Gueugneau)

http://www.lesechos.fr/20/11/2015/LesEchos/22070-102-ECH_la-regulation-des-geants-du-web-reste-a-inventer.htm

La future loi Lemaire inquiète les professionnels du numérique (Sandrine Cassini)

http://www.lemonde.fr/economie/article/2015/12/09/la-future-loi-lemaire-inquiete-les-professionnels-du-numerique_4827819_3234.html

Conference FTC PrivacyCon (janvier 2016)

<https://www.ftc.gov/news-events/events-calendar/2016/01/privacycon> (voir Part 3)

Two Points and a Lesson from PrivacyCon, FTC's Digital-Privacy Conference (Abraham Rein)

<http://www.postschell.com/publications/1176-two-points-lesson-from-privacycon-ftcs-digital-privacy-conference>

Testing the Platforms that Test Us (Christian Sandvig et al)

<http://www-personal.umich.edu/~csandvig/research/An%20Algorithm%20Audit.pdf>

Auditing Algorithms: Research Methods for Detecting Discrimination on Internet Platforms (Christian Sandvig et al)

<http://www-personal.umich.edu/~csandvig/research/Auditing%20Algorithms%20--%20Sandvig%20--%20ICA%202014%20Data%20and%20Discrimination%20Preconference.pdf>

The spreading of misinformation online (Del Vicario et al)

<http://www.pnas.org/content/113/3/554.abstract?sid=a6d85c5f-3640-48c1-9f0d-c0c68582ad38>

Racial Discrimination in the Sharing Economy: Evidence from a Field Experiment (Edelman et al)

<http://www.benedelman.org/publications/airbnb-guest-discrimination-2016-01-06.pdf>

Discrimination in Online Ad Delivery (Latanya Sweeney)

<http://dataprivacylab.org/projects/onlineads/1071-1.pdf>

The Ethics of Algorithms (The Global Conference on CyberSpace, 2015)

https://www.gccs2015.com/sites/default/files/documents/Ethics_Algorithms-final%20doc.pdf

La lettre innovation et prospective de la CNIL no. 8 (nov. 2014)

https://www.cnil.fr/sites/default/files/typo/document/Lettre_IP_N-8-Mobilitics.pdf

Deep learning (Yann LeCun, Yoshua Bengio and Geoffrey Hinton)

<http://www.cs.toronto.edu/~hinton/absps/NatureDeepReview.pdf>

Big Data's disparate impact, Solon Barocas et Andrew D. Selbst, 2015

http://papers.ssrn.com/sol3/papers.cfm?abstract_id=2477899