



DISCRIMINATION, INTELLIGENCE ARTIFICIELLE ET DECISIONS ALGORITHMIQUES

Etude du
Prof. Frederik Zuiderveen Borgesius

COUNCIL OF EUROPE



CONSEIL DE L'EUROPE

DISCRIMINATION, INTELLIGENCE ARTIFICIELLE ET DECISIONS ALGORITHMIQUES

Etude du
Prof. Frederik Zuiderveen Borgesius
Professeur de Droit, Institut des sciences informatiques et de
l'information, Université de Radboud, Nijmegen,
et Chercheur, Institut du droit de l'information,
Université d'Amsterdam (Pay-Bas)

Les opinions exprimées dans cette étude sont de la responsabilité de l'auteur et ne reflètent pas nécessairement la ligne officielle du Conseil de l'Europe.

Publication de la
Direction générale de la Démocratie
© Conseil de l'Europe - 2018
Strasbourg

TABLE DES MATIERES

RESUME	7
I. INTRODUCTION	9
II. INTELLIGENCE ARTIFICIELLE ET DÉCISIONS ALGORITHMIQUES	11
III. LES RISQUES DE DISCRIMINATION	16
1. COMMENT L'IA PEUT DEBOUCHER SUR DE LA DISCRIMINATION	16
2. DOMAINES DANS LESQUELS L'IA SUSCITE DES RISQUES DE DISCRIMINATION.....	25
IV. GARDE-FOUS JURIDIQUES ET RÉGLEMENTAIRES	33
1. RÉGLEMENTATION ANTI-DISCRIMINATION.....	34
2. RÉGLEMENTATION RELATIVE A LA PROTECTION DES DONNEES.....	39
3. AUTRES NORMES	50
V. RECOMMANDATIONS	55
1. ORGANISATIONS REOURANT A L'IA.....	55
2. ORGANISMES DE PROMOTION DE L'EGALITE ET ORGANES DE SURVEILLANCE DU RESPECT DES DROITS DE L'HOMME.....	59
VI. AMÉLIORATION DE LA RÉGLEMENTATION	66
1. LA RÉGLEMENTATION DE TECHNOLOGIES EN RAPIDE ESSOR.....	67
2. CONTROLE DU RESPECT	69
3. LA RÉGLEMENTATION DE NOUVELLES DIFFÉRENCIATIONS.....	72
VII. CONCLUSION	79
BIBLIOGRAPHIE	81

RESUME

Le présent rapport, préparé à l'intention du Service anti-discrimination du Conseil de l'Europe, porte sur la discrimination issue des décisions algorithmiques et d'autres formes d'intelligence artificielle (IA). Cette dernière permet d'atteindre des buts importants (efficacité, santé, croissance économique, par exemple). Mais elle peut aussi avoir des effets discriminatoires, par exemple lorsque l'apprentissage du système se fonde sur des décisions humaines biaisées.

Des organisations publiques et privées peuvent fonder sur l'IA des décisions lourdes de conséquences pour des personnes. Dans le secteur public, l'IA peut par exemple être utilisée dans la prévention policière (police prédictive) ou dans les décisions de versement de pensions, d'aides au logement ou d'allocations de chômage. Dans le privé, elle peut servir par exemple à sélectionner des candidats à un emploi. Les banques peuvent l'utiliser pour accorder ou non un crédit à un consommateur et fixer le taux d'intérêt correspondant. De plus, un grand nombre de décisions de moindre poids peuvent à elles toutes avoir de larges conséquences. La différenciation des prix par l'IA pourrait par exemple aboutir à ce que certains groupes sociaux paient systématiquement plus cher.

Les principaux instruments juridiques permettant de réduire les risques de discrimination par l'IA sont la réglementation anti-discrimination et la réglementation relative à la protection des données. Effectivement appliquées, elles pourraient contribuer à la lutte contre la discrimination illicite. Les États membres du Conseil de l'Europe, les organes de surveillance du respect des droits de l'homme (comme la Commission européenne contre le racisme et l'intolérance) et les organismes de promotion de l'égalité devraient travailler à ce que le respect des normes anti-discrimination en vigueur soit mieux garanti.

Mais l'IA ouvre également sur de nouvelles formes de différenciations injustifiées (que certains qualifieraient de discriminatoires), que n'envisage pas le droit existant. La plupart des textes anti-discrimination ne s'appliquent qu'à la discrimination fondée sur des caractéristiques protégées, comme la couleur de la peau. Ils ne couvrent pas les nouvelles catégories (non corrélées avec des caractéristiques protégées) que peut créer un système d'IA pour différencier des groupes de population. Ces différenciations n'en pourraient pas moins être injustes, par exemple si elles renforcent des inégalités sociales.

Il sera probablement nécessaire de compléter la réglementation pour protéger la justice et les droits de l'homme dans le domaine de l'IA. Mais il ne convient pas de chercher à réglementer l'ensemble de ce dernier par un dispositif unique, car les applications des systèmes d'IA sont trop variées. Les valeurs sous-jacentes et les problèmes changent d'un secteur à l'autre. Il faudra donc envisager des règles sectorielles. D'autres recherches et débats sont encore nécessaires.

I. INTRODUCTION

Le présent rapport, rédigé à l'intention du Département anti-discrimination du Conseil de l'Europe, porte sur les risques de discrimination liés aux décisions algorithmiques et à d'autres formes d'intelligence artificielle (IA).

L'IA tend à des buts importants, comme l'efficacité, la santé et la croissance économique. Notre société s'appuie sur elle pour de nombreuses tâches : filtrage des courriels indésirables, planification de la circulation, gestion logistique, reconnaissance de la parole et diagnostic médical, notamment. L'IA et les décisions algorithmiques peuvent paraître rationnelles, neutres et impartiales. Malheureusement, elles peuvent aussi déboucher sur des discriminations injustes et illicites. Comme cela avait été demandé, le rapport étudie les questions ci-dessous.

- 1. Dans quels domaines les décisions algorithmiques et d'autres formes d'IA ont-elles des effets discriminatoires ou pourraient en avoir dans un avenir prévisible ?*
- 2. Quels garde-fous (et recours) prévoit actuellement le droit en ce qui concerne l'IA, lesquels envisage-t-on ?*
- 3. Quelles mesures de réduction des risques de discrimination par l'IA peuvent être recommandées aux organisations qui l'utilisent, aux organismes de promotion de l'égalité des États membres du Conseil de l'Europe, et aux organes chargés de la surveillance du respect des droits de l'homme, comme la Commission européenne contre le racisme et l'intolérance ?*
- 4. Par quels dispositifs (juridiques, réglementaires, d'autorégulation) est-il possible de réduire les risques ?*

Le mot « discrimination » est utilisé ici pour désigner la discrimination illicite et réprouvée, par exemple au motif du genre, de la couleur de la peau ou de l'origine raciale¹. C'est le mot « différenciation » qui désigne la discrimination neutre et non réprouvée².

Le rapport n'examine qu'un seul risque lié aux décisions algorithmiques et à l'IA : la discrimination. De nombreux aspects de l'IA n'y sont donc pas abordés, comme les systèmes d'armes automatiques, les véhicules autonomes, les bulles de filtrage, la singularité technologique, les monopoles fondés sur les données, le chômage de masse que pourraient susciter l'IA et les robots. Il ne parle pas non plus des questions relatives à la vie privée en rapport avec les énormes volumes de données personnelles recueillies pour alimenter les systèmes d'IA.

Le présent travail est une étude documentaire. En raison de contraintes de longueur, il faut n'y voir qu'un rapide panorama plutôt qu'un examen détaillé de tous les aspects de l'IA, des décisions algorithmiques et de la discrimination. Je tiens à remercier Bodó Balázs, Janneke Gerards, Dick Houtzager, Margot Kaminski, Dariusz Kloza, Gianclaudio Malgieri, Stefan Kulk, Linnet Taylor, Michael Veale, Sandra Wachter et Bendert Zevenbergen de leurs précieuses suggestions.

Le corps du rapport est structuré ainsi : le chapitre II introduit l'intelligence artificielle, les algorithmes décisionnels et quelques autres notions essentielles. Puis il se penche sur les questions évoquées ci-dessus. Le chapitre III repère les domaines dans lesquels l'IA provoque ou peut provoquer des discriminations. Le chapitre IV examine les garde-fous juridiques. Le chapitre V montre comment les organisations peuvent prévenir la discrimination quand elles recourent à l'IA ;

¹ En conformité avec la tradition juridique, j'utilise ici les termes d'« origine raciale » et de « race », mais je n'accepte pas les théories qui prétendent qu'il existe des races humaines distinctes.

² Une décision algorithmique a souvent un but de discrimination (au sens de différenciation ou de distinction) entre des personnes ou des entités. Pour les différents sens du mot « discrimination », voir Lippert-Rasmussen 2014.

il contient aussi des recommandations aux organes de promotion de l'égalité et de surveillance du respect des droits de l'homme sur les façons de réduire les risques de discrimination par l'IA et les décisions algorithmiques. Le chapitre VI propose des améliorations à apporter au cadre juridique, et le chapitre VII présente des conclusions.

II. INTELLIGENCE ARTIFICIELLE ET DÉCISIONS ALGORITHMIQUES

Les termes d'« IA » et de « décision algorithmique » sont diversement utilisés, et leur définition ne fait pas le consensus. Les paragraphes ci-dessous introduisent rapidement l'intelligence artificielle (IA), les décisions algorithmiques et quelques autres notions connexes.

Algorithme

Un algorithme peut être défini comme la description abstraite et formelle d'un processus de traitement informatique³. Ici, « décision » désigne simplement le produit, la conclusion ou le résultat de cette procédure. Pour concrétiser et simplifier les choses, on pourrait assimiler un algorithme à un programme informatique.

La décision algorithmique peut parfois être entièrement automatisée. Un filtre de courriers indésirables, par exemple, peut empêcher de façon complètement automatique les messages indésirables d'arriver dans une boîte. Il peut aussi arriver que des humains prennent des décisions en s'aidant d'un algorithme ; la décision est alors *partiellement* automatisée. Par exemple : un employé de banque peut accorder ou non un crédit à un client sur la base d'une évaluation de sa solvabilité fournie par un système d'IA.

S'agissant de discrimination, les risques des décisions entièrement ou partiellement automatisées sont en grande partie similaires. La recommandation émanant d'un ordinateur peut paraître rationnelle et infaillible, et être suivie aveuglément.

³ Dourish 2016, p. 3. Voir également Domingos 2015.

Comme l'indiquent Wagner *et al.*, l'être humain peut souvent avoir tendance à valider sans se poser de questions une décision préparée par un algorithme, faute de temps, de compétences ou d'informations contextuelles pour prendre une décision solidement fondée en l'espèce⁴. L'auteur de la décision peut aussi chercher à minimiser sa responsabilité en se conformant à la réponse de l'ordinateur⁵. La tendance à croire l'ordinateur et à suivre son conseil est parfois appelée « biais d'automatisation »⁶. (Nous verrons à la section IV.2 que certaines règles juridiques distinguent les décisions entièrement et partiellement automatisées⁷.)

Intelligence artificielle

L'intelligence artificielle (IA) peut être décrite de façon simplifiée comme la science visant à rendre les machines intelligentes⁸. Plus formellement, c'est l'étude et la conception d'agents intelligents⁹. Dans ce contexte, un agent est une chose qui agit, comme un ordinateur¹⁰.

L'IA est un large domaine de recherche, apparu dans les années 1940¹¹. Il en existe de nombreux types. Dans les années 1970 et 1980, par exemple, la recherche s'intéressait beaucoup aux « systèmes experts » et aux programmes capables de reproduire l'expertise et les capacités de raisonnement d'un bon spécialiste d'un domaine circonscrit¹². Les chercheurs ont programmé des ordinateurs capables de répondre à des questions, sur la base de réponses prédéfinies.

⁴ Wagner *et al.* 2018, p. 8. Voir également Broeder *et al.* 2017, p. 24-25.

⁵ Zarsky 2018, p. 12.

⁶ Parasuraman et Manzey 2010. Voir également Citron 2007, p. 1271-1272 ; Rieke, Bogen et Robinson 2018, p. 11.

⁷ Se reporter à l'analyse de l'article 22 du GDPR, dans cette même section.

⁸ Royal Society 2017, p. 16.

⁹ Russel et Norvig 2016, p. 2, citant Poole, Mackworth et Goebel 1998, p. 1 : 'Computational Intelligence is the study of the design of intelligent agents.'

¹⁰ Russel et Norvig 2016, p. p. 4.

¹¹ Deux des premières publications sont Turing 1951 et McCarthy *et al.* 1955.

¹² Puppe 1993, p. 3.

Ces systèmes experts ont connu un certain succès commercial dans les années 1980¹³. Ils avaient deux inconvénients, observe Alpaydin. D'une part, les règles logiques données au système ne correspondaient pas toujours à la réalité désordonnée du monde. Dans la vie réelle, les choses ne sont pas vraies ou fausses, elles peuvent être plus ou moins vraies : une personne n'est pas simplement vieille ou jeune, la vieillesse augmente progressivement avec l'âge¹⁴. Et d'autre part, il faut que des experts fournissent le savoir (les réponses) au système : un processus long et coûteux¹⁵.

Apprentissage automatique

Une forme d'IA a connu un vif succès ces dernières décennies : l'apprentissage automatique¹⁶. Il permet d'éviter que le savoir soit fourni à la machine par des experts. Dans les systèmes de ce type, une tâche est attribuée à la machine, à qui l'on donne aussi un gros volume de données qui lui serviront d'exemples à suivre, ou dans lesquelles elle détectera des régularités. Elle apprend ainsi la meilleure façon de produire le résultat désiré¹⁷.

En première approximation, on pourrait dire que l'apprentissage automatique est un système de prédiction fondé sur des données¹⁸. Lehr et Ohm proposent une description plus détaillée : c'est un processus automatisé de découverte de corrélations (parfois aussi appelées relations ou modèles) entre les variables d'un jeu de données, souvent dans le but de prédire ou d'estimer un résultat¹⁹.

L'apprentissage automatique s'est beaucoup répandu ces dix dernières années, notamment du fait que l'on dispose de plus en plus de données à fournir aux ordinateurs. Il connaît un tel

¹³ Alpaydin 2016, p. 51.

¹⁴ Alpaydin 2016, p. 51.

¹⁵ Alpaydin 2016, p. 51.

¹⁶ Alpaydin 2016, p. 51. p. xiii.

¹⁷ Royal Society 2017, p. 19.

¹⁸ Paul, Jolley, et Anthony 2018, p. 6.

¹⁹ Lehr et Ohm 2017, p. 671. Voir également Royal Society 2017, p. 19.

succès que l'on parle souvent d'IA pour désigner l'apprentissage automatique (qui n'est qu'une forme d'IA)²⁰.

Exploration de données (*Data Mining*), mégadonnées (*Big Data*) et profilage sont des notions connexes. L'exploration de données est un type d'apprentissage automatique qui consiste à repérer des constantes intéressantes dans d'énormes quantités de données²¹. C'est aussi une forme de découverte de savoirs dans des données²². *Big Data* (ou encore mégadonnées, ou données massives) désigne l'analyse de gros volumes de données²³. Et le profilage consiste à définir par traitement automatisé de données des profils qui permettront de prendre des décisions concernant des personnes²⁴.

Terminologie utilisée dans le présent rapport

Le présent rapport sacrifie la précision technique à la lisibilité : les termes d'IA, de système d'IA, de décision d'IA, etc. y sont utilisés sans qu'il soit précisé s'il s'agit d'apprentissage automatique ou d'une autre technique. Un système d'IA peut ainsi désigner, par exemple, un ordinateur qui utilise un algorithme exploitant des données fournies par des opérateurs humains.

²⁰ Lipton 2018 ; Jordan 2018.

²¹ Han, Pei, et Kamber 2011, p. 33. Voir également Frawley *et al.* 1992, qui définissent l'exploration des données (*data mining*) comme l'extraction significative d'informations implicites, inconnues jusque-là et potentiellement utiles d'un corpus de données.

²² Han, Pei, et Kamber 2011, p. xxiii. Pour certains, l'exploration de données est une étape dans le processus de découverte de connaissances.

²³ Boyd et Crawford 2012.

²⁴ Voir Hildebrandt 2008 ; Ferraris *et al.* 2013.

Toujours dans un souci de lisibilité, le rapport parle par exemple d'effets de l'IA un peu comme si cette dernière était une entité capable d'agir par elle-même. Or un système d'IA n'apparaît pas par génération spontanée. Comme l'observent Wagner *et al.*, les constructions mathématiques ou informatiques ne portent pas par elles-mêmes atteinte à des droits de l'homme, c'est leur mise en œuvre et leur application aux actions humaines qui le font²⁵. Lorsqu'un système d'IA formule une décision, c'est qu'une organisation a décidé de s'appuyer sur lui pour la prendre.

En fait, une organisation qui commence à recourir à l'IA prend rarement elle-même toutes les décisions sur le système lui-même. Elle pourra déployer un système d'IA dans lequel un grand nombre de choix importants ont déjà été opérés²⁶. Dans certains cas, les effets de décisions prises avant même l'achat ou la conception du système d'IA peuvent n'apparaître qu'après la mise en service dans le monde réel. De plus, une organisation se compose de nombreuses personnes : cadres, juristes et informaticiens, par exemple ; mais pour simplifier, le rapport dira parfois qu'une « organisation » fait quelque chose. Le chapitre qui suit examine comment l'IA peut conduire à de la discrimination, et fait ressortir les domaines dans lesquels elle a ou peut avoir des effets discriminatoires.

²⁵ Wagner *et al.* 2018, p. 8. Voir également Dommering 2006 ; Rieke, Bogen et Robinson 2018, p. 5.

²⁶ Sur les modes de développement de systèmes numériques modernes, voir Gürses et Van Hoboken 2017. Leur centrage est la protection de la vie privée, mais leur analyse touche également aux systèmes d'IA et à la discrimination.

III. LES RISQUES DE DISCRIMINATION

Quels sont les domaines dans lesquels les décisions algorithmiques et d'autres types d'IA ont des effets discriminatoires ou pourraient en avoir dans un avenir prévisible ?

1. COMMENT L'IA PEUT DEBOUCHER SUR DE LA DISCRIMINATION

Cette section examine comment l'IA peut déboucher sur de la discrimination ; la suivante donne des exemples dans lesquels elle l'a fait ou pourrait le faire. Beaucoup de systèmes d'IA sont des « boîtes noires »²⁷. Une personne ne comprendra souvent pas pourquoi un système a formulé telle ou telle décision à son sujet. En raison de l'opacité de la décision, il lui sera difficile de voir si elle a été victime de discrimination, par exemple en raison de son origine raciale.

Les décisions fondées sur l'IA peuvent conduire de plusieurs façons à des discriminations. Dans un article fondateur, Barocas et Selbst distinguent cinq façons dont une décision d'IA peut involontairement aboutir à une discrimination²⁸. Les problèmes proviennent 1) de la définition de la variable cible et des étiquettes de classe ; 2) de l'étiquetage des données d'apprentissage ; 3) de la collecte des données d'apprentissage ; 4) de la sélection des caractéristiques ; 5) du choix des données indirectes. De plus, 6) les systèmes d'IA peuvent être délibérément utilisés à des fins discriminatoires²⁹. Nous allons maintenant revenir sur chacun de ces éléments.

²⁷ Pasquale 2015.

²⁸ Barocas et Selbst 2016. Voir également O'Neil 2016, qui donne une introduction accessible et bien écrite aux risques de discrimination et autres rencontrés dans le domaine des systèmes d'IA.

²⁹ Barocas et Selbst 2016. Leur regroupement diffère quelque peu.

1) **Définition de la variable cible et des étiquettes de classe**

L'IA consiste pour l'ordinateur à découvrir des corrélations dans des jeux de données. Une société qui met au point un filtre de courriers indésirables, par exemple, fournit à l'ordinateur des messages étiquetés par des humains comme indésirables ou non. Ces messages étiquetés constituent les données d'apprentissage. L'ordinateur y découvre les caractéristiques d'un courrier indésirable. L'ensemble de corrélations mises au jour est souvent appelé le modèle ou le modèle prédictif. Les messages repérés comme indésirables contiendront souvent, par exemple, certaines expressions (« perte de poids massive », « millions d'euros à gagner », etc.) ou émaneront de certaines adresses IP. Comme le disent Barocas et Selbst, l'algorithme d'apprentissage automatique tire d'exemples pertinents (fraudes précédemment identifiées, courriers indésirables, défauts de paiement, mauvaise santé) les attributs ou les actions (données indirectes) qui peuvent servir à détecter la présence ou l'absence de la qualité ou du résultat recherchés (la variable cible)³⁰.

La variable cible représente ce que l'explorateur de données recherche, expliquent Barocas et Selbst, tandis que les étiquettes de classe répartissent toutes les valeurs possibles de cette variable cible entre des catégories s'excluant les unes les autres³¹. Pour le filtrage des courriers indésirables, par exemple, on s'accorde dans l'ensemble sur les étiquettes de classe de courrier bienvenu ou indésirable³². Mais dans certains cas, la définition de la valeur de la variable cible est moins évidente. Parfois, constatent Barocas et Selbst, il faut créer de *nouvelles* classes pour la décrire³³. Prenons le cas d'une entreprise qui confie à un système d'IA le soin de classer des réponses à une offre d'emploi pour en extraire de « bons

³⁰ Barocas et Selbst 2016, p. 678.

³¹ Barocas et Selbst 2016, p. 678.

³² Barocas et Selbst 2016, p. 678-679 (nous avons omis les citations internes).

³³ Barocas et Selbst 2016, p. 679.

employés ». Comment va-t-on définir le bon employé ? En d'autres termes, quelles devraient être les étiquettes de classe ? Le bon employé est-il celui qui réalise les meilleures ventes ou celui qui n'arrive jamais en retard au travail ?

Certaines variables cibles et étiquettes de classe, expliquent Barocas et Selbst, peuvent avoir un impact négatif plus ou moins marqué sur des classes protégées³⁴. Supposons par exemple que les personnes défavorisées habitent rarement en centre-ville et viennent de plus loin que les autres employés pour se rendre à leur travail. Elles seront donc en retard plus souvent, en raison des embouteillages ou de problèmes de transports publics. L'entreprise peut par exemple choisir d'apprécier si un employé est « bon » par l'étiquette de classe « rarement ou souvent en retard ». Mais si les personnes issues de la migration sont en moyenne plus pauvres et habitent plus loin de leur travail, ces étiquettes désavantagent les immigrés, même s'ils font mieux que les autres employés à d'autres égards³⁵. En bref, la discrimination peut s'introduire dans un système d'IA en raison de la façon dont une organisation définit les variables cibles et les étiquettes de classe.

2) Données d'apprentissage : exemples d'étiquetage

La décision par IA peut aussi produire des effets discriminatoires si le système « apprend » à partir de données discriminatoires. Barocas et Selbst décrivent deux façons dont des données d'apprentissage biaisées peuvent produire des effets discriminatoires : d'une part, le système peut faire son apprentissage sur des données biaisées ; et d'autre part, des problèmes peuvent surgir si le système apprend à partir d'un échantillon biaisé³⁶. Dans les deux cas, le système reproduira le biais.

Les données d'apprentissage peuvent être biaisées si elles reflètent des décisions humaines discriminatoires. C'est ce qui

³⁴ Barocas et Selbst 2016, p. 680.

³⁵ Voir Peck 2013.

³⁶ Barocas et Selbst 2016, p. 680-681.

s'est produit dans les années 1980 au Royaume-Uni, dans une école de médecine³⁷. L'établissement recevait plus de candidatures qu'il n'avait de places. Il a donc mis au point un logiciel d'aide au tri des candidatures. Les données d'apprentissage étaient constituées par les dossiers d'admission des années précédentes, lorsque des intervenants humains sélectionnaient les candidats. Elles montraient à l'ordinateur les caractéristiques (intrants) corrélées avec le résultat souhaité (admission à l'école de médecine). L'ordinateur a ainsi reproduit ce système de sélection.

Il s'est avéré que l'ordinateur défavorisait les femmes et les personnes issues de la migration. Il semblerait que dans les années dont provenaient les données d'apprentissage, les personnes chargées de la sélection des étudiants avaient des préjugés contre les femmes et les personnes issues de la migration. Comme le notait le *British Medical Journal*, le programme n'introduisait pas de nouveau biais, se contentant de reproduire celui qui existait déjà dans le système³⁸. Pour conclure, si les données d'apprentissage sont biaisées, il y a des chances pour que le système d'IA reproduise ce biais.

3) Données d'apprentissage : collecte des données

La procédure d'échantillonnage peut aussi être biaisée. Par exemple, dans la collecte de données sur la criminalité, il se pourrait que la police ait interpellé dans le passé plus de personnes issues de la migration. Lum et Isaac observent que si la police se concentre sur certains groupes ethniques et certains quartiers, il est probable que ces catégories seront surreprésentées dans ses fichiers³⁹.

Si un système d'IA s'appuie sur des données ainsi biaisées, il apprend qu'il est probable que les personnes issues de la migration commettent des infractions. Pour Lum et Isaac, si l'on

³⁷ Lowry et Macpherson 1988 ; Barocas et Selbst 2016, p. 682.

³⁸ Lowry et Macpherson 1988.

³⁹ Lum et Isaac 2016, p. 15.

utilise des données biaisées pour former des modèles prédictifs, ces derniers reproduiront les mêmes biais⁴⁰.

Les effets d'un échantillon ainsi biaisé peuvent même être amplifiés par les prédictions de l'IA. Supposons que la police concentre ses activités sur un quartier à forte population immigrée, mais à criminalité moyenne. Elle y enregistra plus d'infractions qu'ailleurs. Comme les chiffres font ressortir un nombre supérieur d'infractions enregistrées (et donc censées s'être produites) dans ce quartier, les autorités y affecteront davantage encore d'agents de police. En d'autres termes, organiser le maintien de l'ordre en se fondant sur des statistiques de criminalité peut créer une boucle de rétroaction positive⁴¹.

Pour prendre un autre exemple, les pauvres peuvent être sous-représentés dans un jeu de données. L'application Street Bump pour smartphone, par exemple, recourt à la géolocalisation pour surveiller l'état des routes dans une ville. Le site explique que des bénévoles l'utilisent sur leur téléphone pour signaler l'état de la route pendant leurs trajets. Ces données sont communiquées en temps réel aux autorités, qui peuvent ainsi procéder aux réparations et planifier leurs investissements à long terme⁴². Si les pauvres sont moins nombreux à posséder un smartphone que les personnes plus aisées, ils seront sous-représentés. Cela pourrait avoir pour effet que les routes détériorées des quartiers pauvres seront moins souvent signalées dans les jeux de données, et donc moins fréquemment réparées. Street Bump était utilisé à Boston, où la municipalité s'efforce de remédier à ce biais dans la collecte des données⁴³. Mais cet exemple n'en illustre pas moins que la collecte des données peut produire un biais non voulu dans les

⁴⁰ Lum et Isaac 2016, p. 15.

⁴¹ Lum et Isaac 2016, p. 16. Voir également Ferguson 2017 ; Harcourt 2008 ; Robinson et Koepke 2016.

⁴² <http://www.streetbump.org>, consulté le 10 septembre 2018.

⁴³ Crawford 2013. Voir également Barocas et Selbst 2016, p. 685 ; Federal Trade Commission 2016, p. 27.

données. En bref, un biais dans les données d'apprentissage peut produire un biais dans le système d'IA.

4) Sélection des caractéristiques

Quatrième problème : les caractéristiques (catégories de données) que choisit une organisation pour son système d'IA. Si elle veut utiliser ce dernier pour automatiser une prédiction, il va lui falloir simplifier le monde, pour pouvoir le décrire par des données⁴⁴. Comme le disent Barocas et Selbst, une organisation doit procéder à des choix, pour sélectionner les caractéristiques qu'elle veut observer et introduire dans ses analyses⁴⁵.

Supposons qu'une organisation veuille sélectionner par prédiction automatisée les candidats qui seront de bons employés. Il est impossible, ou du moins trop coûteux, pour un système d'IA d'évaluer la totalité de chaque dossier de candidature. L'organisation peut alors retenir, par exemple, uniquement certaines caractéristiques applicables à chaque dossier.

Le choix de certaines caractéristiques peut introduire un biais contre certains groupes. Par exemple, de nombreux employeurs aux États-Unis préfèrent les personnes qui ont fait leurs études dans l'une des grandes universités onéreuses. Mais il peut être rare que les membres de certains groupes raciaux fréquentent ces établissements. Le système aura alors des effets discriminatoires dès lors qu'un employeur se fonde sur la fréquentation d'une grande université pour sélectionner les candidats⁴⁶. En bref, une organisation peut susciter des effets discriminatoires par la sélection des caractéristiques qu'utilise le système d'IA dans ses prédictions.

5) Données indirectes

⁴⁴ Barocas et Selbst 2016, p. 688.

⁴⁵ Barocas et Selbst 2016, p. 688.

⁴⁶ Barocas et Selbst 2016, p. 689.

Les données indirectes font aussi problème. Certaines données incluses dans le jeu d'apprentissage peuvent présenter des corrélations avec des caractéristiques protégées. Comme le soulignent Barocas et Selbst, des critères authentiquement pertinents de décisions rationnelles et solidement fondées peuvent aussi constituer des indicateurs fiables d'appartenance à une classe⁴⁷.

Supposons qu'une banque utilise un système d'IA censé prédire quels demandeurs de prêt auront du mal à rembourser un crédit. L'apprentissage du système a été fondé sur les données des vingt dernières années, et le jeu ne contient pas d'informations concernant des caractéristiques protégées, comme la couleur de la peau. Le système d'IA apprend que les personnes qui ont un certain code postal ont tendance à ne pas rembourser, et il utilise cette corrélation pour prédire le non-remboursement du crédit. Un critère à première vue neutre (le code postal) sert donc à prédire le défaut de paiement. Mais supposons maintenant qu'il y ait une corrélation entre ce code postal et l'origine raciale. Si la banque prend ses décisions sur la base de cette prédiction et refuse d'accorder des crédits aux habitants de ce quartier, cela fait du tort aux membres d'un certain groupe sur le critère de l'origine raciale.

Barocas et Selbst expliquent que le problème provient de ce que les chercheurs appellent un encodage redondant, c'est-à-dire l'appartenance à une classe protégée encodée dans d'autres données. C'est ce qui se passe lorsqu'une donnée ou certaines valeurs de cette donnée sont étroitement corrélées avec l'appartenance à une classe spécifique protégée⁴⁸.

Par exemple : un jeu de données qui ne contient pas de données explicites sur l'orientation sexuelle peut tout de même la dévoiler. Une étude de 2009 a montré que les liens d'« amis » sur Facebook révèlent l'orientation sexuelle par une méthode de prédiction précise de l'orientation sexuelle des utilisateurs de

⁴⁷ Barocas et Selbst 2016, p. 691.

⁴⁸ Barocas et Selbst 2016, p. 692. Voir également Dwork *et al.* 2012.

Facebook fondée sur l'analyse de leurs liens. Le pourcentage d'« amis » s'identifiant comme homosexuels serait fortement corrélé avec l'orientation sexuelle de l'utilisateur concerné⁴⁹.

Ce problème des données indirectes est délicat. Barocas et Selbst indiquent que les informaticiens ne voient pas très bien comment aborder l'encodage redondant d'un jeu de données. Se contenter de retirer les variables concernées de l'exploration des données supprime fréquemment des critères d'une pertinence démontrable et justifiée dans la décision à prendre⁵⁰. La seule façon de garantir que les décisions ne désavantagent pas systématiquement les membres de catégories protégées est de réduire la précision générale de toutes les déterminations⁵¹.

6) Discrimination délibérée

Il faut aussi parler de la discrimination délibérée⁵². Une organisation peut par exemple utiliser volontairement des données indirectes pour pratiquer la discrimination sur le critère de l'origine raciale. Comme l'observent Kroll *et al.*, des préjugés pourraient conduire un responsable à biaiser volontairement les données d'apprentissage ou à choisir certaines données codant indirectement des classes protégées pour obtenir des résultats discriminatoires⁵³. Si l'organisation utilise des données indirectes, la discrimination sera plus difficile à détecter qu'une discrimination franche.

Prenons un exemple hypothétique : une organisation pourrait vouloir écarter les femmes enceintes, et cette discrimination serait difficile à détecter. Le distributeur américain Target aurait constitué un score de prédiction de grossesse fondé sur

⁴⁹ Jernigan et Mistree 2009.

⁵⁰ Barocas et Selbst 2016, p. 720.

⁵¹ Barocas et Selbst 2016, p. 721-722.

⁵² Barocas et Selbst 2016, p. 692. Voir également Bryson 2017 ; Friedman et Nissenbaum 1996 ; Hacker 2018, p. 1149 ; Kim 2017, p. 884 ; Vetzo, Gerards, et Nehmelman 2018, p. 145.

⁵³ Kroll *et al.* 2016, p. 682.

quelque 25 produits en analysant les habitudes d'achat des clientes. Si l'une d'entre elles achetait ces produits, le magasin pouvait savoir avec une bonne certitude qu'elle était enceinte. Target voulait toucher par la publicité des personnes à un moment de leur vie où elles ont tendance à modifier leurs habitudes d'achat. Il voulait donc savoir quand ses clientes allaient avoir un enfant. Ses statisticiens savaient que s'ils arrivaient à les identifier au deuxième mois, ils avaient de bonnes chances de les fidéliser pour des années⁵⁴. Target utilisait la prédiction pour cibler son marketing, mais une organisation pourrait aussi le faire à des fins discriminatoires⁵⁵.

En résumé, toute décision d'IA peut produire de la discrimination d'au moins six façons liées 1) à la définition des variables cibles et des étiquettes de classe, 2) à l'étiquetage des données d'apprentissage, 3) à leur collecte, 4) à la sélection des caractéristiques et 5) aux données indirectes — à quoi il faut ajouter 6) l'utilisation délibérée des systèmes d'AI à des fins discriminatoires. L'IA peut aussi conduire à d'autres types de différenciations injustifiées, ou à des erreurs. Nous reviendrons sur ce point au chapitre VI.

⁵⁴ Duhigg 2012, citant le statisticien de Target. Sur le cas de Target, voir également Siegel 2013, chapitre 2.

⁵⁵ Voir Kim 2017, p. 884.

2. DOMAINES DANS LESQUELS L'IA SUSCITE DES RISQUES DE DISCRIMINATION

La section qui vient donne des exemples de décisions d'IA ayant suscité ou susceptibles de produire des discriminations.

Police, prévention de la criminalité

Commençons par le secteur public. Un exemple célèbre de système d'IA aux effets discriminatoires est le *Correctional Offender Management Profiling for Alternative Sanctions* (COMPAS)⁵⁶. Il est utilisé dans une partie des États-Unis pour prédire les risques de récidive des inculpés. Il est censé aider le juge à apprécier si la personne commettra une nouvelle infraction ou s'il peut ordonner le sursis avec mise à l'épreuve (liberté sous surveillance). Il ne tient pas compte de l'origine raciale ni de la couleur de la peau. Mais les travaux d'Angwin *et al.* (journalistes d'investigation à ProPublica), ont montré en 2016 qu'il contient un biais contre les noirs⁵⁷ : ProPublica a donc estimé que :

COMPAS prédisait bien le risque de récidive dans 61 % des cas, mais que les noirs non récidivistes avaient deux fois plus de chances que les blancs d'avoir été étiquetés comme présentant un risque supérieur, et que le système faisait l'erreur inverse pour les blancs, chez qui les récidivistes avaient beaucoup plus de chances d'avoir été considérés comme présentant un risque inférieur⁵⁸.

De plus, observe ProPublica, les inculpés noirs avaient deux fois plus de chances que les blancs d'être classés à tort comme présentant un risque accru de récidive avec violence. Et les récidivistes violents blancs avaient 63 % de chances de plus

⁵⁶ Voir Equivant 2018.

⁵⁷ Angwin *et al.* 2016.

⁵⁸ Angwin *et al.* 2016.

d'avoir été considérés à tort comme présentant un faible risque de récidive violente que les récidivistes violents noirs⁵⁹.

Northpointe, la société dont émane COMPAS, conteste que le système serait biaisé⁶⁰. ProPublica et Northpointe divergent principalement sur le degré d'impartialité à en attendre⁶¹. Des statisticiens universitaires ont fait valoir que dans certains cas, des normes différentes d'impartialité sont mathématiquement incompatibles, ce qui a des conséquences sur ce que la prévention de la discrimination pourrait ou devrait être. ProPublica s'inquiétait de ce que l'on pourrait appeler une « disparité de traitement défavorable », faisant que des groupes différents sont différemment affectés par divers types d'erreurs (les membres d'un groupe ayant par exemple plus de chances d'être considéré comme à haut risque alors qu'ils ne commettent ensuite pas d'infraction). Le bon étalonnage est un autre aspect important des scores de risque. Cela veut dire que dans un groupe dont les membres sont considérées comme ayant 80 % de chances de commettre une infraction, 80 % finissent bien par en commettre une. Les chiffres devraient aussi être les mêmes d'un groupe à l'autre (inculpés noir ou blancs, par exemple), faute de quoi le juge devrait interpréter le « haut risque » différemment selon qu'il s'agit d'un inculpé noir ou blanc, ce qui introduit d'autres biais. Les statisticiens pensent que lorsque la propension sous-jacente à la récidive diffère, il est mathématiquement impossible d'obtenir des taux d'erreur identiques⁶².

⁵⁹ Larson *et al.* 2016.

⁶⁰ Ce paragraphe a été en grande partie rédigé par Michael Veale.

⁶¹ Les discussions entre ProPublica, Northpointe et des universitaires sur COMPAS sont parfois assez techniques. On en trouvera une bonne synthèse dans Feller *et al.* 2016. Voir également *A shared statement of civil rights concerns* 2018. Pour le point de vue de Northpointe, voir Dieterich, Mendoza et Brennan 2016.

⁶² Voir Chouldechova 2017.

La police recourt parfois aussi à des systèmes d'IA pour planifier ses interventions par prédiction automatisée des auteurs, du moment et des lieux d'infractions⁶³. Comme il a été dit ci-dessus, ces systèmes prédictifs peuvent reproduire, voire amplifier, des discriminations existantes.

Recrutement d'employés et d'étudiants

L'IA peut aussi avoir des effets discriminatoires dans le secteur privé. Nous avons vu, par exemple, qu'elle peut servir au recrutement d'employés ou d'étudiants. Comme l'a montré l'exemple de l'école de médecine britannique, un système d'IA peut provoquer des discriminations en raison d'un biais présent dans ses données d'apprentissage. Amazon aurait abandonné un système d'IA pour le recrutement de son personnel en raison d'un biais défavorable aux femmes. Selon Reuters, l'entreprise se serait rendu compte que son nouveau système n'évaluait pas les candidats à des postes d'informaticiens et d'autres emplois techniques de façon non sexiste⁶⁴. Des données historiques avaient enseigné au système d'Amazon que les candidats étaient préférables aux candidates⁶⁵.

Publicité

L'IA sert au ciblage de la publicité en ligne, très rentable pour certaines entreprises (Facebook et Google, qui figurent parmi les sociétés les mieux cotées, tirent le gros de leurs bénéfices de la publicité en ligne⁶⁶). Ce type de publicité peut avoir des effets discriminatoires. Sweeney a montré en 2013 qu'une recherche sur des noms à consonance afro-américaine attirait sur Google des publicités conduisant à penser que quelqu'un avait un casier judiciaire. Pour les noms à consonance blanche, Google affichait moins de publicités liées à un casier judiciaire. On peut penser que le système d'IA de Google analysait le

⁶³ Hildebrandt 2014 ; Ferguson 2017 ; Perry et al. 2013 ; Van Brakel et De Hert 2011.

⁶⁴ Dastin 2018.

⁶⁵ Dastin 2018.

⁶⁶ Fortune 2018. La société mère de Google s'appelle officiellement Alphabet.

mode de navigation des utilisateurs et avait hérité d'un biais racial⁶⁷.

Datta, Tschantz, et Datta ont simulé des internautes identiques se déclarant hommes ou femmes dans leurs paramètres. Ils ont ensuite analysé les publicités présentées par Google⁶⁸. Pour les internautes se prétendant de sexe masculin, des publicités d'agences de gestion de carrière promettant des salaires élevés apparaissaient plus fréquemment que pour les internautes se présentant comme de sexe féminin — ce qui ferait penser à de la discrimination⁶⁹. L'opacité du système n'avait pas permis aux chercheurs de voir clairement pourquoi les femmes obtenaient moins d'offres d'emplois à forte rémunération : la faible visibilité au sein de l'écosystème publicitaire (Google, annonceurs, sites internet et utilisateurs) les empêchait de déterminer l'origine de ces résultats⁷⁰.

Cet exemple montre comment l'opacité d'un système d'IA peut entraver le repérage de la discrimination et de ses causes. Une personne pourrait être victime de discrimination sans le savoir. Dès lors qu'un système d'IA cible les offres d'emploi sur les hommes uniquement, les femmes pourraient ne pas se rendre compte qu'elles ont été exclues de la campagne publicitaire⁷¹.

L'Autorité néerlandaise de protection des données a estimé que Facebook permet de cibler la publicité sur des caractéristiques « sensibles ». Par exemple, des données relatives aux préférences sexuelles ont été utilisées pour afficher des publicités ciblées⁷². Elle indique que Facebook a modifié le système et rendu ce mode de ciblage impossible⁷³. À ProPublica, Angwin et Perris ont montré que Facebook laisse

⁶⁷ Sweeney 2013.

⁶⁸ Datta, Tschantz et Datta 2015.

⁶⁹ Datta, Tschantz et Datta 2015, p. 93.

⁷⁰ Datta, Tschantz et Datta 2015, p. 92 ; Datta *et al.* 2018.

⁷¹ Munoz, Smith et Patil, 2016, p. 9 ; Zuiderveen Borgesius 2015a, chapitre 3, section 3.

⁷² Autorité néerlandaise de protection des données 2017 ; Autorité néerlandaise de protection des données 2017a.

⁷³ Autorité néerlandaise de protection des données 2017.

les annonceurs exclure des utilisateurs sur le critère de la race. Le système leur permet d'empêcher des publicités de s'afficher pour les noirs, les hispaniques et d'autres « affinités ethniques »⁷⁴. ProPublica a aussi montré que certaines sociétés se servent des possibilités de ciblage de Facebook pour ne diffuser des offres d'emploi qu'auprès de personnes de moins d'un certain âge⁷⁵. Des chercheurs espagnols ont montré pour leur part que Facebook caractérise 73 % des utilisateurs de l'UE par des « intérêts sensibles » : Islam, santé reproductive et homosexualité, par exemple⁷⁶. Les annonceurs peuvent cibler leur publicité sur ces critères.

Discrimination par les prix

Un magasin en ligne peut différencier le prix de produits identiques sur la base d'informations qu'il détient sur le consommateur — ce que l'on appelle la différenciation des prix en ligne. Le magasin reconnaît un visiteur sur son site, par exemple par des cookies, et le classe comme sensible ou insensible au prix. Par la différenciation des prix, il cherchera à demander le prix maximum que le client est prêt à payer⁷⁷.

⁷⁴ Angwin et Perris 2016. Voir également Angwin, Tobin et Varner 2017. Dalenberg 2017 analyse l'application de la législation anti-discrimination de l'UE au ciblage publicitaire. Des ONG ont intenté en 2018 un procès à Facebook pour discrimination en se prévalant de la législation des États-Unis sur l'équité dans le logement ; elles accusaient Facebook d'avoir favorisé l'exclusion de femmes, de vétérans handicapés et de mères célibataires de l'audience potentielle d'offres de logements (Bagli 2018).

⁷⁵ Angwin, Scheiber et Tobin 2017.

⁷⁶ Cabañas, Cuevas et Cuevas 2018. Ces centres d'intérêt sont définis comme des « catégories particulières » de données ou des « données sensibles » dans la législation européenne sur la protection des données. Voir article 9 du Règlement général sur la protection des données de l'Union européenne. Sur la législation relative à la protection des données, voir section IV.2.

⁷⁷ Zuiderveen Borgesius et Poort 2017.

Princeton Review, une société américaine de cours particuliers en ligne, modulait ses prix en fonction de la zone : de 6 600 à 8 400 dollars. On peut penser que les frais de fourniture du service étaient les mêmes dans chaque zone, puisque les services sont offerts sur l'internet. Angwin *et al.* ont constaté que cette différenciation des prix pénalisait les personnes d'origine asiatique : les clients habitant dans un quartier à forte densité d'asiatiques avaient 1,8 fois plus de chances de se voir offrir un prix supérieur, quel que soit leur revenu⁷⁸. L'entreprise ne cherchait probablement pas à faire de la discrimination sur le critère de l'origine raciale. Peut-être avait-elle testé différents prix dans différents quartiers, pour s'apercevoir que dans certaines zones, les clients achetaient la même quantité de services, même à un prix supérieur. Quoi qu'il en soit, certains groupes ethniques payaient ainsi davantage.

Recherche et analyse d'images

Les systèmes de recherche d'images peuvent aussi avoir des effets discriminatoires. En 2016, une recherche sur « trois adolescents noirs » a donné dans Google Images des photos d'identité judiciaire, alors que la recherche sur « trois jeunes blancs » a surtout produit des images de jeunes blancs heureux. En réponse à des réactions indignées, Google a indiqué que les résultats reflètent les contenus trouvés sur l'ensemble du web, la fréquence des types d'images et la façon dont elles sont décrites en ligne ; les descriptions déplaisantes de sujets délicats en ligne peuvent parfois ainsi affecter les résultats d'une recherche d'images⁷⁹. On pourrait en effet dire que le système d'IA de Google reflète simplement la société⁸⁰. Mais même si la faute en est à la société plutôt qu'au système, les images ainsi trouvées peuvent teinter l'opinion des gens.

Kay, Matuszek et Munson ont constaté que les résultats de recherches d'images d'activités professionnelles exagèrent

⁷⁸ Angwin, Mattu et Larson 2015 ; Larson, Mattu et Angwin 2015.

⁷⁹ Réponse de Google, citée par York 2016.

⁸⁰ Allen 2016.

légèrement les stéréotypes de genre et représentent le genre minoritaire sous un jour moins professionnel. On constate aussi une légère sous-représentation des femmes⁸¹.

La reconnaissance d'images par les systèmes d'AI suscite d'autres problèmes. Certains logiciels de reconnaissance ont du mal à reconnaître et à analyser les visages non blancs. Un logiciel de détection faciale de Hewlett Packard ne reconnaissait pas les visages à peau foncée comme des visages⁸². Et l'application Google Photos a reconnu sur une photo un couple afro-américain comme des gorilles⁸³. Un appareil de photo Nikon demandait constamment aux personnes d'origine asiatique si quelqu'un avait cligné des yeux⁸⁴. Une personne asiatique s'est fait refuser une photo de passeport par un logiciel parce qu'elle aurait fermé les yeux, alors qu'ils étaient ouverts⁸⁵. Buolamwini et Gebru ont constaté que les femmes à la peau foncée constituent le groupe dans lequel les erreurs de classification sont les plus fréquentes (jusqu'à 34,7 %) ; le taux d'erreur maximale pour les hommes à peau claire et de 0,8 %⁸⁶. Peut-être certaines de ces erreurs provenaient-elles simplement du fait que l'apprentissage des systèmes s'était fondé sur des photos d'hommes blancs.

Outils de traduction

Le moteur d'intelligence artificielle d'un outil de traduction automatique peut aussi refléter des inégalités et des discriminations. Si l'on donne à traduire en turc l'énoncé « Il est médecin, elle est infirmière » à Google Translate, on obtient « O bir hemşire. O bir doktor » : deux phrases ne comportant pas d'indications de sexe, car le turc ne fait pas la différence entre

⁸¹ Kay, Matuszek et Munson 2015.

⁸² Frucci 2009.

⁸³ BBC News 2015. Voir également Noble 2018.

⁸⁴ Sharp 2009.

⁸⁵ Regan 2016.

⁸⁶ Buolamwini et Gebru 2018.

« il » et « elle ». Si l'on retraduit la traduction en anglais, Google Translate répond : « elle est infirmière, il est médecin ».

Cet exemple est tiré d'une étude de Caliskan, Bryson et Narayanan, qui montre que la machine peut apprendre dans des textes écrits des associations de mots qui reflètent celles qu'apprennent les humains⁸⁷. En d'autres termes, la langue naturelle contient nécessairement des biais humains, et dès lors que la machine apprend sur des corpus linguistiques, elle reproduit inévitablement les mêmes biais⁸⁸.

Prates, Avelar et Lamb ont testé douze langues sans genres, comme le hongrois et le chinois, dans Google Translate. Ils ont écrit des phrases comme « il/elle est ingénieur » dans une langue sans genre et demandé la traduction en anglais. Ils ont conclu que Google Translate a fortement tendance à opter pour le masculin par défaut⁸⁹. De plus, cette tendance est non seulement dominante, mais aussi exagérée dans des domaines exposés à des stéréotypes de genre, comme les emplois touchant aux sciences, à la technique, à l'ingénierie et aux mathématiques⁹⁰. En somme, les outils de traduction fondés sur l'IA peuvent produire des résultats qui reflètent des inégalités de genre existantes. Ces résultats pourraient aussi empirer les inégalités par leur influence sur les représentations des lecteurs.

Nuancer le risque

Nous avons vu que les décisions d'IA peuvent avoir des effets discriminatoires, sans que les systèmes d'IA soient nécessairement pires en cela que les humains. Car bien des humains prennent malheureusement aussi des décisions discriminatoires. Dans certains cas, les systèmes d'IA produisent des discriminations qu'ils ont apprises dans des données reflétant des discriminations humaines. Il faut donc

⁸⁷ Caliskan, Bryson et Narayanan 2017.

⁸⁸ Narayanan 2016.

⁸⁹ Prates, Avelar et Lamb 2018, p. 1.

⁹⁰ Prates, Avelar et Lamb 2018, p. 28.

bien savoir si l'on évalue une décision d'IA à la lumière de décisions humaines prises dans le monde réel (malheureusement parfois discriminatoires), ou par référence aux décisions idéales qui se prendraient dans un monde exempt de discrimination⁹¹. Le but doit bien sûr être un monde exempt de discriminations injustes ou illicites.

Cela mis à part, l'IA pourrait aussi servir à mettre au jour les discriminations et inégalités⁹². Prenons le cas d'un système d'IA qui découvre des stéréotypes de genre dans une galerie de photos. Une façon d'interpréter le phénomène est de dire que le système reflète un comportement stéréotypé existant. Il peut ainsi aider à déceler des inégalités existantes, qui resteraient autrement invisibles.

IV. GARDE-FOUS JURIDIQUES ET RÉGLEMENTAIRES

Quels garde-fous (et quels recours) prévoit actuellement le droit en ce qui concerne l'IA, et lesquels envisage-t-on ?

La réglementation anti-discrimination et celle sur la protection des données sont les principales normes susceptibles d'assurer une protection contre la discrimination causée par l'IA. Le présent chapitre aborde successivement ces deux pans du droit ; il examine aussi d'autres domaines envisageables du droit, et l'autorégulation. Il s'agit d'une esquisse, qui s'en tient aux grands principes du droit. Le présent rapport ne saurait traiter par exemple des différences entre les réglementations des États membres du Conseil de l'Europe, la portée territoriale du droit, et la répression des infractions commises par des organisations depuis d'autres États.

⁹¹ Voir également Tene et Polonetsky 2017.

⁹² Voir Munoz, Smith et Patil 2016, p. 14.

1. REGLEMENTATION ANTI-DISCRIMINATION

La discrimination est interdite par nombre de traités et de constitutions — notamment la Convention européenne des droits de l’homme⁹³, dont l’article 14 se lit ainsi :

« La jouissance des droits et libertés reconnus dans la présente Convention doit être assurée, sans distinction aucune, fondée notamment sur le sexe, la race, la couleur, la langue, la religion, les opinions politiques ou toutes autres opinions, l’origine nationale ou sociale, l’appartenance à une minorité nationale, la fortune, la naissance ou toute autre situation. »⁹⁴

La Convention européenne des droits de l’homme interdit la discrimination *directe comme indirecte*⁹⁵. Nous dirons pour simplifier que la discrimination est directe lorsqu’elle s’appuie sur des caractéristiques protégées, comme l’origine raciale. La Cour européenne des droits de l’homme dit que pour qu’il y ait discrimination directe, « il doit y avoir une différence dans le traitement de personnes placées dans des situations analogues ou comparables », et cette différence de traitement doit être

⁹³ Voir par exemple l’article 7 de la Déclaration des droits de l’homme de l’Organisation des Nations Unies, l’article 26 du Pacte international relatif aux droits civils et politiques et l’article 21 de la Charte des droits fondamentaux de l’Union européenne.

⁹⁴ Le Protocole n° 12 pose une interdiction similaire, avec un champ d’application plus large à certains égards. « La *jouissance de tout droit prévu par la loi* doit être assurée, sans discrimination aucune, fondée notamment sur le sexe, la race, la couleur, la langue, la religion, les opinions politiques ou toutes autres opinions, l’origine nationale ou sociale, l’appartenance à une minorité nationale, la fortune, la naissance ou toute autre situation. » Article 1, Protocole n° 12 à la Convention de sauvegarde des droits de l’homme et des libertés fondamentales, Série des traités européens – n° 177, Rome, 4.XI.2000. Au 18 septembre 2018, vingt pays étaient parties par ratification ou adhésion au Protocole n° 12. Pour une liste à jour, voir https://www.coe.int/en/web/conventions/search-on-treaties/-/conventions/treaty/177/signatures?p_auth=0Kq9rtcM.

⁹⁵ La Convention européenne des droits de l’homme a certains effets horizontaux, mais elle ne couvre pas directement la discrimination dans le secteur privé.

fondée sur une « caractéristique identifiable »⁹⁶. La législation anti-discrimination de l'UE utilise une définition similaire⁹⁷.

Toujours en simplifiant quelque peu, nous dirons que la discrimination est indirecte lorsqu'une pratique à première vue neutre se traduit par une discrimination à l'encontre de personnes d'une certaine origine raciale (ou possédant une autre caractéristique protégée)⁹⁸. La discrimination indirecte est désignée par *disparate impact* (disparité d'impact) aux États-Unis d'Amérique. Elle est ainsi définie par la Cour européenne des droits de l'homme :

« [...] une différence de traitement [peut] consister en un effet préjudiciable disproportionné occasionné par une politique ou une mesure qui, bien que formulée de manière neutre, opère une discrimination à l'égard d'un groupe [...]. Une telle situation s'analyse en une "discrimination indirecte" qui n'exige pas nécessairement qu'il y ait une intention discriminatoire. »⁹⁹

⁹⁶ Cour européenne des droits de l'homme, *Biao c. Danemark* (Grande Chambre), n° 38590/10, 24 mai 2016, paragraphe 89.

⁹⁷ L'article 2.2.a) de la Directive 2000/43/CE du Conseil du 29 juin 2000 relative à la mise en œuvre du principe de l'égalité de traitement entre les personnes sans distinction de race ou d'origine ethnique dit : « une discrimination directe se produit lorsque, pour des raisons de race ou d'origine ethnique, une personne est traitée de manière moins favorable qu'une autre ne l'est, ne l'a été ou ne le serait dans une situation comparable ». La Directive relative à l'égalité en matière d'emploi et de travail (2000/78/CE), la Directive relative à l'égalité d'accès aux biens et aux services (2004/113/CE) et la refonte de la Directive relative à la mise en œuvre du principe de l'égalité des chances entre hommes et femmes (2006/54/CE) utilisent des définitions semblables. Mais même au sein de l'Union européenne, les législations anti-discrimination ne sont que partiellement harmonisées.

⁹⁸ Sur la notion de discrimination indirecte, voir d'une manière générale Tobler 2005 ; Ellis et Watson 2012, p. 148-155.

⁹⁹ Cour européenne des droits de l'homme, *Biao c. Danemark* (Grande Chambre), n° 38590/10, 24 mai 2016, paragraphe 103.

Le droit européen en donne une définition similaire :

« Une discrimination indirecte se produit lorsqu'une disposition, un critère ou une pratique apparemment neutre est susceptible d'entraîner un désavantage particulier pour des personnes d'une race ou d'une origine ethnique donnée par rapport à d'autres personnes, à moins que cette disposition, ce critère ou cette pratique ne soit objectivement justifié par un objectif légitime et que les moyens de réaliser cet objectif ne soient appropriés et nécessaires. »¹⁰⁰

Toute décision peut se traduire par une discrimination indirecte involontaire. Le législateur retient donc les effets pratiques de la discrimination indirecte plutôt que l'intention de discrimination de son auteur¹⁰¹, qui n'est pas pertinente.

La législation anti-discrimination peut servir à lutter contre des décisions discriminatoires d'IA. Par exemple, des décisions de ce type ayant pour effet que les personnes d'une certaine origine ethnique paient plus cher des biens et des services pourraient enfreindre l'interdiction de la discrimination indirecte. Les décisions d'IA peuvent probablement aboutir plus souvent à des discriminations indirectes accidentelles qu'intentionnelles.

La législation anti-discrimination n'en présente pas moins plusieurs points faibles en ce qui concerne les décisions d'IA. L'interdiction de la discrimination indirecte ne constitue pas une règle claire, aisément applicable¹⁰². La notion elle-même

¹⁰⁰ Article 2.2.b) de la Directive sur l'égalité raciale 2000/43/CE (typographie et ponctuation adaptées).

¹⁰¹ Cour européenne des droits de l'homme, *Biao c. Danemark* (Grande Chambre), n° 38590/10, 24 mai 2016, paragraphe 103. Voir également Hacker 2018, p. 1153.

¹⁰² Nous dirions que l'interdiction de la discrimination indirecte est plutôt un standard qu'une norme. Voir Sunstein 1995 ; Baldwin, Cave et Lodge 2011, chapitre 14.

débouche sur des normes assez vagues, souvent difficiles à mettre en œuvre dans la pratique. Il faut pouvoir prouver qu'une règle, une pratique ou une décision apparemment neutre affecte de manière disproportionnée un groupe protégé et constitue donc une présomption de discrimination. Dans bien des cas, on recourt à des preuves statistiques pour démontrer l'effet disproportionné¹⁰³.

La Cour européenne des droits de l'homme accepte qu'une accusation de discrimination indirecte puisse être rejetée si son auteur allègue une justification objective :

« Une politique ou une mesure générale qui ont des effets préjudiciables disproportionnés sur un groupe de personnes peuvent être considérées comme discriminatoires même si elles ne visent pas spécifiquement ce groupe et s'il n'y a pas d'intention discriminatoire. Il n'en va toutefois ainsi que si cette politique ou cette mesure manquent de justification "objective et raisonnable" »¹⁰⁴.

La justification doit être objective et raisonnable, critères que ne remplit pas une mesure, une pratique ou une règle si :

« elle ne poursuit pas un but légitime ou si fait défaut un rapport raisonnable de proportionnalité entre les moyens employés et le but visé »¹⁰⁵.

¹⁰³ Cour européenne des droits de l'homme, *D.H. et autres c. République tchèque* (Grande Chambre), n° 57325/00, 13 novembre 2007, paragraphes 187-188.

¹⁰⁴ Cour européenne des droits de l'homme, *Biao c. Danemark* (Grande Chambre), n° 38590/10, 24 mai 2016, paragraphe 91 et 92 (nous avons supprimé les citations internes et leurs appels de notes).

¹⁰⁵ Cour européenne des droits de l'homme, *Biao c. Danemark* (Grande Chambre), n° 38590/10, 24 mai 2016, paragraphe 90. Voir également Cour européenne des droits de l'homme, *Affaire relative à certains aspects du régime linguistique de l'enseignement en Belgique*, n° 1474/62 et autres, 23 juillet 1968, paragraphe B.10.

Dans la même veine, le droit de l'UE dit qu'une pratique ne constitue pas une discrimination indirecte pour autant qu'elle soit « objectivement justifié[e] par un but légitime et que les moyens pour parvenir à ce but soient appropriés et nécessaires »¹⁰⁶. La possibilité pour l'auteur d'une discrimination de se prévaloir d'une telle justification objective dépend des circonstances de l'espèce et appelle un test de proportionnalité nuancé¹⁰⁷. On ne discerne donc pas toujours clairement si une pratique enfreint l'interdiction de la discrimination indirecte.

La nécessité de démontrer la présomption de discrimination peut aussi susciter des difficultés, ce type de discrimination pouvant ne pas apparaître au grand jour. Prenons le cas d'une personne qui demande un crédit sur le site internet d'une banque. Cette dernière utilise un système d'IA pour accepter ou rejeter les demandes de ce type. Si elle refuse automatiquement le crédit sur son site internet, le client ne voit pas le motif du refus. De plus, il ne saura pas si le système d'IA de la banque refuse les crédits à un nombre disproportionné de femmes, par exemple¹⁰⁸. Même s'il sait que la décision a été prise par un système d'IA et non pas par un employé, il lui sera difficile de déterminer si elle est discriminatoire.

La notion de caractéristique protégée sur laquelle se fonde la législation anti-discrimination constitue un autre point faible. Les textes sur la non-discrimination mentionnent en général la discrimination (directe et indirecte) fondée sur des caractéristiques protégées, comme la race, le genre ou l'orientation sexuelle¹⁰⁹. Mais bien des formes nouvelles de différenciations opérées par l'IA paraissent injustes et problématiques, voire discriminatoires, et n'entrent pas dans le champ d'application de la plupart des lois anti-discrimination.

¹⁰⁶ Article 2.2.b) de la Directive sur l'égalité raciale 2000/43/CE.

¹⁰⁷ Collins et Khaitan 2018, p. 21 ; Hacker 2018, p. 1161-1170.

¹⁰⁸ Voir Larson *et al.* 2017 pour un exemple réel similaire : *'These are the job ads you can't see on Facebook if you're older'*.

¹⁰⁹ Gerards 2007 ; Khaitan 2015.

Ces dernières présentent donc des lacunes. Nous reviendrons à la section IV.3 sur les différenciations injustes que pourraient ne pas couvrir les textes de lutte contre la discrimination.

Les lois anti-discrimination font obstacle à de nombreux effets discriminatoires de l'IA, en particulier par la notion de discrimination indirecte. Mais elles sont délicates d'application, et présentent des points faibles. La section qui suit examine la réglementation relative à la protection des données.

2. REGLEMENTATION RELATIVE A LA PROTECTION DES DONNEES

Le cadre juridique de la protection des données est un outil de défense de la justice et des droits fondamentaux, comme le droit à la vie privée et le droit à la non-discrimination¹¹⁰. Il confère des droits à la personne dont les données font l'objet d'un traitement (personne concernée)¹¹¹ et impose des obligations aux parties associées au traitement (responsables du traitement)¹¹². Il s'appuie sur huit grands principes, que l'on peut résumer comme suit :

- (a) des données personnelles ne peuvent être traitées que licitement, loyalement et avec transparence (licéité, loyauté et transparence) ;
- (b) ces données ne peuvent être recueillies que dans un but précisé par avance, et ne doivent pas être utilisées à d'autres fins (limitation des finalités) ;

¹¹⁰ Voir article 1(2) et considérants 71, 75, et 85 du GDPR, et article 1 de la Convention du Conseil de l'Europe sur la protection des données 2018 ; Conseil de l'Europe, Lignes directrices sur la protection des personnes à l'égard du traitement des données à caractère personnel à l'ère des mégadonnées, 2017, paragraphe 2.3.

¹¹¹ Article 4(1) GDPR ; article 2(a) Convention du Conseil de l'Europe sur la protection des données 2018.

¹¹² Article 4(7) GDPR ; article 2(d) Convention du Conseil de l'Europe sur la protection des données 2018.

- (c) elles devraient être limitées à ce qui est nécessaire en relation avec les finalités pour lesquelles elles sont traitées (minimisation des données) ;
- (d) elles devraient être suffisamment exactes et à jour (exactitude) ;
- (e) elles ne devraient pas être conservées pendant une durée excessive (limitation de la conservation) ;
- (f) elles devraient être traitées d'une manière qui garantisse une sécurité appropriée contre un traitement non autorisé ou illicite, etc. (intégrité et confidentialité)¹¹³ ;
- (g) le responsable du traitement est responsable du respect des règles (responsabilité)¹¹⁴.

Ces principes figurent dans la Convention 108 du Conseil de l'Europe sur la protection des personnes à l'égard du traitement automatisé des données à caractère personnel (révisée en 2018)¹¹⁵ et dans le Règlement général de l'Union européenne sur la protection des données (GDPR, de 2016). On les retrouve dans plus d'une centaine de législations nationales sur la protection des données¹¹⁶.

¹¹³ Article 5(1)(a)-5(1)(f) GDPR ; articles 5, 7, et 10 Convention du Conseil de l'Europe sur la protection des données 2018.

¹¹⁴ Article 5(2) du GDPR ; article 10(1) Convention du Conseil de l'Europe sur la protection des données 2018.

¹¹⁵ Articles 5, 7, et 10 Convention du Conseil de l'Europe sur la protection des données 2018.

¹¹⁶ Greenleaf 2017.

Le droit relatif à la protection des données pourrait contribuer à la réduction des risques de discriminations injustes et illicites¹¹⁷. Il exige par exemple la transparence du traitement des données personnelles. Les organisations doivent ainsi fournir, par exemple dans une déclaration de confidentialité, des informations sur toutes les étapes de la préparation de la décision d'IA impliquant des données personnelles¹¹⁸. Certes, la plupart des gens ne lisent pas les déclarations de confidentialité¹¹⁹. Mais ces dernières pourraient être utiles à des chercheurs, à des journalistes et aux organes de contrôle. Si une déclaration donne à penser qu'un traitement pourrait avoir des effets discriminatoires, les autorités peuvent enquêter.

Dans certains cas, le GDPR et la Convention 108 sur la protection des données exigent des organisations (responsables des données) qu'elles procèdent à une analyse d'impact relative à la protection des données, que l'on peut décrire ainsi :

l'analyse d'impact est un outil qui sert à l'analyse des conséquences possibles d'une action pour un ou plusieurs points susceptibles d'affecter la société dès lors que ladite action peut présenter des dangers sur ces points ; elle constitue une aide à la prise d'une décision éclairée sur la réalisation de l'action concernée et de ses conditions de déploiement, en fin de compte dans un but de protection¹²⁰.

¹¹⁷ Sur les interactions entre le droit relatif à la protection des données et le droit anti-discrimination, voir Schreurs *et al.* 2008 ; Gellert *et al.* 2013 ; Hacker 2018 ; Lammerant, De Hert, Blok 2017.

¹¹⁸ Article 5(1)(a) ; article 13 ; article 14 GDPR ; articles 5(4)(a) et 8 Convention du Conseil de l'Europe sur la protection des données 2018.

¹¹⁹ Zuiderveen Borgesius 2015.

¹²⁰ Kloza *et al.* 2017, p. 1. Voir également Groupe de travail (Working Group) « article 29 » 2017 (WP248) ; Binns 2017 ; Mantelero 2017 ; Wright et De Hert 2012.

Le GDPR exige une analyse d'impact dès lors que « des opérations de traitement sont susceptibles d'engendrer un risque élevé pour les droits et libertés des personnes physiques », surtout s'il y a recours à des technologies nouvelles¹²¹. Dans certains cas, il exige systématiquement une analyse d'impact (le risque étant jugé élevé), par exemple lorsqu'une organisation s'appuie sur des décisions entièrement automatisées produisant des effets juridiques ou similaires à l'égard de personnes physiques¹²². Ce qui veut dire qu'il impose une analyse d'impact pour de nombreux systèmes d'IA formulant des décisions qui affectent des personnes physiques¹²³. L'analyse doit aussi envisager le risque de discrimination injuste ou illicite¹²⁴.

La Convention 108 du Conseil de l'Europe sur la protection des données et la Charte des droits fondamentaux de l'Union européenne prévoient que chaque État membre doit se doter d'une autorité indépendante de protection des données¹²⁵. Cette autorité doit posséder des pouvoirs d'investigation¹²⁶. C'est le GDPR qui donne le plus de détails sur ce dernier point. Une autorité indépendante peut, par exemple, obtenir l'accès aux locaux du responsable du traitement, mener des enquêtes sous forme d'audits sur la protection des données, et ordonner au responsable du traitement de lui communiquer toute

¹²¹ Article 25(1) GDPR.

¹²² Article 35(3)(a) GDPR. Voir également considérant 91 GDPR.

¹²³ L'article 35(3)(b) et 35 (3)(c) du GDPR pourrait également s'appliquer à certains systèmes d'IA.

¹²⁴ Groupe de travail (Working Group) « article 29 » 2017 (WP248), p. 6, p. 14. Voir également Kaminski 2018a, p. 25 ; Edwards et Veale 2017.

¹²⁵ Article 8(3) de la Charte des droits fondamentaux de l'Union européenne. Voir également article 51 GDPR ; chapitre IV Convention du Conseil de l'Europe sur la protection des données.

¹²⁶ Chapter VI GDPR ; chapitre IV Convention du Conseil de l'Europe sur la protection des données.

information dont elle a besoin et de lui ouvrir l'accès à ses systèmes de traitement des données¹²⁷.

Règles relatives aux décisions automatisées

Le GDPR contient des règles spécifiques pour certaines « prises de décision individuelle automatisée »¹²⁸. Ces règles visent notamment à réduire le risque de discrimination illicite¹²⁹. La Convention du Conseil de l'Europe sur la protection des données contient également des règles applicables aux décisions automatisées, moins détaillées toutefois que celle du GDPR¹³⁰. Nous nous concentrerons ici sur ce dernier.

L'article 22 du GDPR (parfois appelé « disposition Kafka ») pose l'interdiction de principe des décisions entièrement automatisées ayant des effets juridiques ou similaires ; il s'applique par exemple au recrutement entièrement automatisé, sans intervention humaine¹³¹. Le texte qui avait précédé le GDPR contenait une disposition similaire, qui n'avait guère été appliquée dans la pratique¹³². La règle principale de la disposition du GDPR sur les prises de décisions individuelles automatisées se lit ainsi :

¹²⁷ Article 58(1) GDPR. L'autorité de protection des données peut également exercer ces droits à l'encontre de sous-traitants (organisations assurant le traitement des données pour le responsable de données).

¹²⁸ Article 22 GDPR. L'analyse des règles du GDPR sur les décisions automatisées se fonde sur Zuiderveen Borgesius et Poort 2017, et leur reprend certaines phrases.

¹²⁹ Voir considérant 71 GDPR.

¹³⁰ Article 9(1)(a) Convention du Conseil de l'Europe sur la protection des données 2018.

¹³¹ Considérant 71 GDPR.

¹³² Korff 2012. Le prédécesseur était l'article 15 de la Directive sur la protection des données. Cet article était fondé sur une disposition de la loi française de 1978 sur la protection des données. Voir Bygrave 2001.

La personne concernée a le droit de ne pas faire l'objet d'une décision fondée exclusivement sur un traitement automatisé, y compris le profilage¹³³, produisant des effets juridiques la concernant ou l'affectant de manière significative de façon similaire¹³⁴.

En résumé, une personne ne doit pas faire l'objet d'une décision entièrement automatisée lourde de conséquences. Le GDPR dit que la personne « a le droit de ne pas faire l'objet » de certaines décisions. Mais on s'accorde à reconnaître en général que ce droit implique l'interdiction de principe de ces décisions¹³⁵.

Selon Mendoza et Bygrave, quatre conditions doivent être remplies pour que cette disposition s'applique : a) l'existence d'une décision b) entièrement fondée sur c) le traitement automatisé de données et d) qui a des effets significatifs, juridiques ou similaires, pour la personne¹³⁶.

Pourraient par exemple avoir des effets juridiques une décision de justice ou une décision concernant le versement de prestations sociales garanties par la loi, comme une pension de retraite¹³⁷. Pourrait par exemple avoir « des effets similaires » la décision automatisée d'une banque refusant une demande

¹³³ Le GDPR définit ainsi le profilage à son article 4(4) : toute forme de traitement automatisé de données à caractère personnel consistant à utiliser ces données à caractère personnel pour évaluer certains aspects personnels relatifs à une personne physique, notamment pour analyser ou prédire des éléments concernant le rendement au travail, la situation économique, la santé, les préférences personnelles, les intérêts, la fiabilité, le comportement, la localisation ou les déplacements de cette personne physique.

¹³⁴ Art. 22 GDPR.

¹³⁵ De Hert et Gutwirth 2008 ; Korff 2012 ; Wachter, Mittelstadt, et Floridi 2017 ; Zuiderveen Borgesius 2015a.

¹³⁶ Mendoza et Bygrave 2017.

¹³⁷ Voir Groupe de travail (Working Group) « article 29 » 2018 (WP251), p. 21.

de crédit¹³⁸. Les autorités de protection des données disent également que la différenciation des prix en ligne pourrait aussi affecter quelqu'un « de manière significative » si elle se traduit par des prix excessivement hauts, interdisant à la personne concernée l'accès à certains biens ou services¹³⁹.

Il existe des exceptions : l'interdiction de certaines décisions automatisées ne s'applique pas si la décision automatisée : a) est prise avec le consentement explicite de la personne concernée ; b) est nécessitée par un contrat entre la personne concernée et le responsable des données ; c) est autorisée par la loi¹⁴⁰.

Si le responsable des données peut se prévaloir a) du consentement de la personne concernée ou b) de l'exception contractuelle, c'est une autre règle qui s'applique : il doit mettre en œuvre « des mesures appropriées pour la sauvegarde des droits et libertés et des intérêts légitimes de la personne concernée, au moins du droit de la personne concernée d'obtenir une intervention humaine de la part du responsable du traitement, d'exprimer son point de vue et de contester la décision »¹⁴¹. Ce qui veut dire que dans certains cas, la personne concernée peut demander à un humain de revoir la décision automatisée. Une banque pourrait par exemple faire en sorte que le client puisse l'appeler pour demander un contrôle humain de la décision si la banque lui refuse un crédit par décision automatisée sur son site internet.

Au-delà des exigences générales de transparence, le GDPR prévoit des exigences de transparence spécifique pour les décisions automatisées :

¹³⁸ Considérant 71 GDPR. Pour d'autres exemples qui pourraient constituer des décisions automatisées « affectant une personne de façon significative de manière similaire », voir Groupe de travail (Working Group) « article 29 » 2018 (WP251), p. 22.

¹³⁹ Groupe de travail (Working Group) « article 29 » 2018 (WP251), p. 22.

¹⁴⁰ Groupe de travail (Working Group) « article 29 » 2018 (WP251), p. 22.

¹⁴¹ Article 22(3) GDPR. Kaminski observe que le texte du GDPR crée une version algorithmique de la procédure régulière : un droit à la possibilité d'être entendu. Kaminski 2018a, p. 8.

Le responsable du traitement fournit à la personne concernée les informations suivantes : [...] « l'existence d'une prise de décision automatisée, y compris un profilage [...] et, au moins en pareils cas, des informations utiles concernant la logique sous-jacente, ainsi que l'importance et les conséquences prévues de ce traitement pour la personne concernée ».¹⁴²

Dans certains cas, l'organisation devra donc indiquer qu'elle recourt à des décisions d'IA et fournir une information suffisante sur la logique du processus.

Les spécialistes universitaires ont beaucoup travaillé sur la question de savoir si les règles du GDPR en matière de décisions automatisées créent un « droit à l'explication » des décisions à caractère individuel¹⁴³. Le considérant 71 pousserait à conclure à son existence — ce qui pourrait être un droit utile à la protection de l'impartialité¹⁴⁴.

De nombreux universitaires doutent de l'efficacité de ce droit, observant par exemple que beaucoup de formes de décision automatisée sortent du champ d'application des règles du GDPR¹⁴⁵. Ces dernières ne s'appliquent par exemple qu'aux décisions prises « sur le seul fondement d'un traitement automatisé ». Si un employé de banque refuse un crédit « sur le seul fondement » de la recommandation du système d'IA, la

¹⁴² Article 13(2)(f) et 14(2)(f) GDPR.

¹⁴³ Voir par exemple Edwards et Veale 2017 ; Goodman et Flaxman 2016 ; Kaminski 2018 ; Kaminski 2018a ; Malgieri G et Comandé 2017 ; Mendoza et Bygrave 2017 ; Selbst et Powles 2017 ; Wachter *et al.* 2017.

¹⁴⁴ Considérant 71 : un traitement de ce type devrait être assorti de garanties appropriées : « le droit [...] d'obtenir une explication quant à la décision prise à l'issue de ce type d'évaluation ».

¹⁴⁵ Voir par exemple Edwards et Veale 2017 ; Wachter *et al.* 2017 ; Zuiderveen Borgesius 2015a, chapitre 9, section 6.

disposition ne s'applique pas dès lors que l'employé ne se contente pas de valider le rejet¹⁴⁶.

Il faudra observer les effets pratiques de ces dispositions du GDPR. On l'a vu, la disposition figurant dans le texte qui avait précédé le GDPR en ce qui concerne les décisions automatisées est restée lettre morte. Quoi qu'il en soit, l'attention qu'a suscitée la disposition du GDPR a contribué à nourrir un débat interdisciplinaire sur l'explication des décisions d'IA.

La Convention 108 modernisée semble plus généreuse envers les personnes physiques dans la formulation des droits d'explication. Contrairement à la disposition du GDPR, qui s'applique aux décisions ayant des effets significatifs et prises « sur le seul fondement » d'un traitement automatisé, la Convention 108 donne à la personne concernée le droit « d'obtenir, à sa demande, connaissance du raisonnement qui sous-tend le traitement de données, lorsque les résultats de ce traitement lui sont appliqués »¹⁴⁷. Il restera à voir comment la formule « les résultats de ce traitement lui sont appliqués » sera concrètement interprétée dans les mises en œuvre nationales.

Mises en garde

Plusieurs mises en garde s'imposent en ce qui concerne les possibilités qu'offre le droit relatif à la protection de données comme instrument de lutte contre la discrimination issue de l'IA. Tout d'abord, l'insuffisance de la surveillance du contrôle du respect et de la répression. Les autorités de protection des données ont des ressources limitées. Beaucoup d'entre elles n'ont pas le pouvoir d'imposer des sanctions lourdes (le GDPR

¹⁴⁶ Voir Groupe de travail (Working Group) « article 29 » 2018 (WP251). Le Groupe de travail dit qu'un contrôle humain superficiel ne suffit pas. Mais, comme l'observent Veale et Edwards 2018, on ne voit pas clairement comment les organisations peuvent s'assurer que l'apport humain n'a pas été superficiel dans une décision.

¹⁴⁷ Article 9(1)(c) Convention du Conseil de l'Europe sur la protection des données 2018 : « Toute personne a le droit : [...] d'obtenir, à sa demande, connaissance du raisonnement qui sous-tend le traitement de données lorsque les résultats de ce traitement lui sont appliqués ». Voir Veale et Edwards 2018.

leur a conféré de nouveaux pouvoirs au sein de l'UE). Bon nombre d'organisations ne prennent pas très au sérieux le respect de la législation sur la protection des données¹⁴⁸. Il semblerait que la conformité ait progressé avec le GDPR, mais il est encore trop tôt pour se prononcer.

Deuxièmement, certains algorithmes sortent du champ d'application de la législation sur la protection des données. Cette dernière ne couvre que le traitement de données personnelles, mais pas les modèles prédictifs, parce qu'ils ne portent pas sur des personnes identifiables. Par exemple, un modèle prédictif qui dit que 80 % des habitants d'un certain quartier paient leurs factures en retard ne comporte pas de données personnelles puisqu'il ne se réfère pas à des individus (la législation sur la protection des données s'applique en revanche dès que le modèle prédictif est appliqué à un individu¹⁴⁹).

Troisièmement, la législation sur la protection des données comporte de nombreuses normes ouvertes et abstraites, plutôt que des règles bien tranchées¹⁵⁰. Elle y est contrainte parce que ses dispositions s'appliquent à des situations très diverses, dans le secteur public et privé. Cette approche « tous azimuts » présente de nombreux avantages. Les normes ouvertes n'ont par exemple pas besoin d'être adaptées à l'apparition de toute nouvelle technologie. Mais leur inconvénient est qu'elles peuvent être difficiles à appliquer¹⁵¹.

Quatrièmement, le droit relatif à la protection des données contient des règles strictes concernant les « catégories particulières » de données (parfois appelées « données

¹⁴⁸ Voir Zuiderveen Borgesius 2015a, chapitre 8, section 2.

¹⁴⁹ Voir Zuiderveen Borgesius 2015a, chapitre 2 et chapitre 5. Sur les faiblesses de la législation relative à la protection des données dans le domaine des décisions d'IA, voir Wachter et Mittelstadt 2018.

¹⁵⁰ Zuiderveen Borgesius 2015a, chapitre 9, section 1.

¹⁵¹ Sur les différents types de règles juridiques, voir chapitre VI, section 1.

sensibles »), comme l'origine raciale ou l'état de santé¹⁵². Ces règles entravent la détection et la réduction de la discrimination. De nombreuses méthodes de lutte contre la discrimination provoquée par les systèmes d'IA font l'hypothèse implicite que les organisations détiennent ces données sensibles — même si bien des organisations pourraient ne pas le faire pour se conformer à la législation sur la protection des données. Il est difficile de concilier le respect du droit relatif à la protection des données et la collecte de données sensibles à des fins de lutte contre la discrimination¹⁵³.

Cinquièmement, même si le GDPR ou la Convention 108 peuvent valablement exiger l'explication des décisions d'IA, il est souvent difficile d'expliquer la logique de la décision que prend un système d'IA par analyse d'un gros volume de données¹⁵⁴. Et on ne voit pas très bien dans certains cas l'utilité de cette explication pour la personne concernée, dès lors surtout que c'est à elle de comprendre la décision et son bien-fondé¹⁵⁵.

Cela dit, un gain de transparence et l'explication des décisions d'IA pourraient se révéler utiles. Cela fait plus de dix ans que les spécialistes demandent que soient développées des technologies d'amélioration effective de la transparence des décisions automatisées¹⁵⁶. Ces technologies devraient améliorer la transparence des flux d'information par le feedback et la sensibilisation, ce qui permettrait aux personnes et

¹⁵² Article 9 GDPR ; article 6 Convention du Conseil de l'Europe sur la protection des données 2018. Les règles strictes relatives à des catégories particulières de données visent en partie à lutter contre la discrimination. Sur les catégories particulières de données dans le contexte de l'IA, voir Malgieri et Comandé 2017a.

¹⁵³ Goodman 2016 ; Ringelheim et De Schutter 2008 ; Ringelheim et De Schutter 2009 ; Veale et Binns 2017 ; Žliobaitė et Custers 2016. Des méthodes d'audit des systèmes d'IA préservant la confidentialité des données par cryptage commencent à apparaître. Voir Kilbertus *et al.* 2018.

¹⁵⁴ Ananny et Crawford 2016 ; Burrell 2016 ; Binns *et al.* 2018 ; Edwards et Veale 2017 ; Hildebrandt 2015 ; Kroll *et al.* 2016 ; 2018 ; Wachter, Mittelstadt et Russell 2017.

¹⁵⁵ Edwards et Veale 2017.

¹⁵⁶ Hildebrandt et Gutwirth 2008, chapitre 17.

aux groupements de mieux comprendre comment l'information est recueillie, agrégée, analysée et exploitée dans la prise des décisions¹⁵⁷. Des informaticiens explorent actuellement diverses formes d'IA explicable¹⁵⁸.

Il est en tout cas bien trop tôt pour se prononcer sur les effets de la Convention 108 modernisée et du GDPR. Il faudra encore procéder à des études juridiques sur la façon dont la législation sur la protection des données pourrait contribuer à la réduction des risques de discrimination¹⁵⁹. L'emploi du droit relatif à la protection des données dans la lutte contre la discrimination n'a jamais encore été largement testé, même s'il offre indéniablement des outils de lutte contre la discrimination illicite.

3. AUTRES NORMES

D'autres domaines du droit pourraient aussi contribuer à garantir la justice des décisions d'IA, et peut-être à réduire les problèmes de discrimination. La législation sur la protection des consommateurs pourrait par exemple être invoquée pour protéger les consommateurs contre des formes manipulatoires de publicité fondées sur l'IA¹⁶⁰. Le comportement discriminatoire d'une entreprise causant des problèmes plus graves si elle détient un monopole, la législation sur la concurrence pourrait jouer un rôle dans la protection des personnes¹⁶¹. Dans le secteur public, le droit administratif et le

¹⁵⁷ Diaz et Gürses 2012.

¹⁵⁸ Voir Guidotti *et al.* 2018 ; Miller 2017 ; Selbst et Barocas 2018 ; Tickle *et al.* 1998. Voir également le projet Google *What If... you could inspect a machine learning model, with no coding required ?*, <https://pair-code.github.io/what-if-tool/index.html#about> consulté le 1^{er} octobre 2018. Ce projet s'est inspiré de Wachter, Mittelstadt et Russell 2017.

¹⁵⁹ Des chercheurs commencent à étudier comment la législation relative à la protection des données peut contribuer à la lutte contre la discrimination. Voir par exemple : Goodman 2016 ; Mantelero 2018 ; Hacker 2018 ; Hoboken et Kostic (forthcoming) ; Wachter 2018 ; Wachter et Mittelstadt 2018.

¹⁶⁰ Sur l'IA et le droit relatif à la protection des consommateurs, voir Contrôleur européen de la protection des données 2014 ; Helberger, Zuiderveen Borgesius et Reyna 2017 ; Jablonowska *et al.* 2018.

¹⁶¹ Sur l'IA et le droit de la concurrence, voir Ezrachi et Stucke 2016 ; Graef 2016 ; Graef 2017 ; Valcke, Graef et Clifford 2018 ; Van Nooren *et al.* 2018.

droit pénal pourraient servir à préserver l'impartialité des procédures¹⁶². La législation sur la liberté d'information pourrait permettre d'obtenir des informations sur les systèmes d'IA du secteur public¹⁶³. Mais l'application de toutes ces normes juridiques à la protection des personnes contre l'IA est encore largement inexplorée. Leur examen dépasserait le cadre du présent rapport.

Réglementations envisagées

Plusieurs réglementations susceptibles d'avoir des effets sur la discrimination suscitée par l'IA sont actuellement à l'étude. Le Comité consultatif de la Convention du Conseil de l'Europe pour la protection des personnes à l'égard du traitement automatisé des données à caractère personnel a publié en septembre 2018 un projet de rapport sur les problèmes suscités par l'intelligence artificielle dans la protection des données, et les solutions envisageables (*Artificial intelligence and data protection: challenges and possible remedies*¹⁶⁴).

Le Comité directeur sur les médias et la société de l'information du Conseil de l'Europe a formé le Comité d'experts sur la dimension droits de l'homme des traitements automatisés de données et différentes formes d'intelligence artificielle, qui procédera à des études et fournira des conseils en vue de la préparation éventuelle de normes pour l'avenir¹⁶⁵.

L'Union européenne se préoccupe aussi de l'IA. En 2018, la Commission européenne a publié une communication à ce sujet, et formé un groupe de haut niveau sur l'intelligence artificielle¹⁶⁶, chargé de préparer un projet de code de bonne

¹⁶² Sur l'IA et le droit administratif, voir Van Eck 2018 ; Oswald 2018, Cobbe 2018.

¹⁶³ Voir Rieke, Bogen et Robinson 2018, p. 24 ; Fink 2018 ; Oswald et Grace 2016.

¹⁶⁴ Mantelero 2018.

¹⁶⁵ Conseil de l'Europe MSI-AUT 2018.

¹⁶⁶ <https://ec.europa.eu/digital-single-market/en/high-level-expert-group-artificial-intelligence>, consulté le 26 septembre 2018.

conduite en matière d'IA¹⁶⁷. L'Agence des droits fondamentaux de l'UE se penche également sur l'IA¹⁶⁸. Et en 2017, la Commission a proposé un règlement sur la vie privée et les communications électroniques visant à protéger la vie privée sur l'internet; le document pourrait affecter l'IA et l'apprentissage automatique en limitant la collecte de certains types de données sensibles sur l'internet¹⁶⁹.

Un règlement de 2016 de l'UE porte sur un type particulier de décision d'IA : le trading algorithmique en bourse, etc. Il veut que « les entreprises d'investissement s'assurent que les membres de leur personnel chargés de la vérification de la conformité comprennent au moins de façon générale la manière dont leurs systèmes de trading algorithmique et leurs algorithmes de négociation fonctionnent »¹⁷⁰, et que « les entreprises d'investissement appliquent un dispositif de gouvernance clair et formalisé, intégré à leur cadre global de gouvernance et de prise de décision »¹⁷¹. Il serait peut-être possible d'adopter des exigences comparables dans d'autres secteurs.

¹⁶⁷ Commission européenne, L'intelligence artificielle pour l'Europe, 2018, p. 16. Voir également : European Group on Ethics in Science and New Technologies 2018.

¹⁶⁸ <http://fra.europa.eu/en/project/2018/artificial-intelligence-big-data-and-fundamental-rights>, consulté le 13 octobre 2018.

¹⁶⁹ Voir Zuiderveen Borgesius et al. 2017.

¹⁷⁰ Règlement délégué (UE) 2017/589 de la Commission du 19 juillet 2016 complétant la directive 2014/65/UE du Parlement européen et du Conseil par des normes techniques de réglementation précisant les exigences organisationnelles applicables aux entreprises d'investissement recourant au trading algorithmique, paragraphe 2.

¹⁷¹ Article 1, *ibidem*.

Autorégulation

Plusieurs organisations ont proposé des principes visant à rendre l'IA équitable, transparente et éthique. La FATLM (*Fairness, Accountability, and Transparency in Machine Learning*) a par exemple publié des principes pour des algorithmes transparents et la déclaration de l'impact social des algorithmes¹⁷². Ces principes demandent aux organisations de veiller à ce que les décisions algorithmiques n'aient pas d'effet discriminatoire ou injuste sur les divers groupes sociaux (en fonction de la race, du sexe, etc.)¹⁷³.

Il existe d'autres principes d'autorégulation sur la déontologie et l'IA, souvent moins centrés sur la discrimination. Il y aurait par exemple les principes Asilomar AI du Future Life Institute (États-Unis)¹⁷⁴, la Déclaration de Montréal pour un développement responsable de l'IA¹⁷⁵, et les Principes pour une intelligence artificielle éthique de l'UNI Global Union¹⁷⁶. L'IEE, une organisation professionnelle technique, a lancé une initiative mondiale sur la déontologie des systèmes autonomes et intelligents¹⁷⁷. Et Apple, Amazon, DeepMind et Google, Facebook, IBM et Microsoft ont créé leur *Partnership on AI to Benefit People and Society* (partenariat pour mettre l'IA au service des personnes et de la société) pour étudier et formuler de bonnes pratiques en matière d'IA¹⁷⁸. On peut en principe se féliciter de ces efforts d'autorégulation. Une IA éthique vaut

¹⁷² <https://www.fatml.org/resources/principles-for-accountable-algorithms>, consulté le 24 septembre 2018.

¹⁷³ <https://www.fatml.org/resources/principles-for-accountable-algorithms>, consulté le 24 septembre 2018.

¹⁷⁴ <https://futureoflife.org/ai-principles/> consulté le 24 septembre 2018.

¹⁷⁵ <https://www.montrealdeclaration-responsibleai.com/the-declaration>, consulté le 24 septembre 2018.

¹⁷⁶ <http://www.thefutureworldofwork.org/opinions/10-principles-for-ethical-ai/>, consulté le 24 septembre 2018.

¹⁷⁷ <https://standards.ieee.org/industry-connections/ec/autonomous-systems.html>, consulté le 24 septembre 2018. Voir également Koene *et al.* 2018.

¹⁷⁸ <https://www.partnershiponai.org/about/>, consulté le 24 septembre 2018. Pour une liste et une critique d'autres principes éthiques pour l'IA, voir Greene, Hoffman, et Stark 2018.

mieux que le contraire. Les principes d'autorégulation pourraient contribuer à la réduction des problèmes de discrimination, et inspirer le législateur.

Mais la protection des droits de l'homme ne peut pas être laissée à l'autorégulation et à des normes non contraignantes¹⁷⁹. Le problème majeur est aussi que les principes évoqués ci-dessus sont souvent assez abstraits, et ne contiennent pas de directives détaillées¹⁸⁰. Wagner se méfie du « lavage éthique » de l'IA : le débat déontologique semble se centrer de plus en plus sur les façons qu'auraient les entreprises privées d'éviter l'intervention du législateur. Devant l'impossibilité ou le refus de la mise en place d'authentiques solutions réglementaires, l'éthique constitue la solution aisée pour structurer en douceur des actions d'autorégulation existantes et leur donner un sens¹⁸¹. Mais l'autorégulation et les normes non contraignantes ne doivent pas masquer l'éventuel besoin d'une vraie réglementation. Le chapitre VI examinera comment le droit pourrait être amélioré dans ce domaine. Nous formulons auparavant des recommandations à l'intention des organisations qui recourent à l'IA, des organes de contrôle du respect des droits de l'homme et des organismes de promotion de l'égalité.

¹⁷⁹ Pour une vue générale de l'autorégulation et des droits fondamentaux, voir Angelopoulos *et al.* 2016.

¹⁸⁰ Voir Campolo *et al.* 2017, p. 34.

¹⁸¹ Wagner 2018. Voir également Nemitz 2018.

V. RECOMMANDATIONS

Quelles mesures de réduction des risques de discrimination par l'IA peuvent être recommandées aux organisations qui l'utilisent, aux organismes de promotion de l'égalité des États membres du Conseil de l'Europe, et aux organes chargés de la surveillance du respect des droits de l'homme, comme la Commission européenne contre le racisme et l'intolérance ?

1. ORGANISATIONS RECOURANT A L'IA

Il y a, pour les organisations publiques et privées désireuses de prévenir la discrimination, des mesures importantes à prendre lorsqu'elles recourent à l'IA : formation, obtention de compétences techniques et juridiques et préparation soigneuse des projets d'IA.

Formation

La formation joue un rôle important en sensibilisant l'organisation aux risques de discrimination accidentelle de l'IA. Le personnel concerné (cadres, juristes et informaticiens) doit être conscient de ces risques. Nous avons vu de nombreux exemples de discrimination par l'IA dans lesquels l'organisation n'avait pas d'intention discriminatoire. Si elle a conscience du risque, elle pourra prévenir la discrimination. Et la formation pourra peut-être aussi aider à combattre l'effet de « biais d'automatisation » au sein de son personnel¹⁸².

Évaluation et réduction des risques

Au lancement d'un projet d'IA, l'organisation devrait procéder à l'évaluation et à la réduction des risques : a) en associant des spécialistes de plusieurs disciplines (informatique et droit, par exemple) à la détermination des risques du projet ; b) en enregistrant les évaluations et les mesures de réduction des risques ; c) en surveillant la mise en œuvre du projet ;

¹⁸² Citron 2007, p. 1306. Sur le biais d'automatisation, voir Parasuraman et Manzey 2010 ; Rieke, Bogen et Robinson 2018, p. 11.

d) en communiquant souvent l'information à l'extérieur (grand public ou organisme de surveillance)¹⁸³.

L'organisation devrait obtenir l'appui d'informaticiens conscients des risques de discrimination (« informaticien » étant à comprendre ici au sens large : des spécialistes des données ou autres et des personnes suffisamment familiarisées avec l'IA pourraient aussi fournir leurs compétences). Les risques de discrimination dans les décisions d'IA commencent à former un nouveau domaine spécifique des sciences informatiques. Une organisation (la FATML) organise depuis 2014 des ateliers et des conférences pour rassembler un collectif grandissant de chercheurs et de praticiens soucieux de promouvoir l'équité, la redevabilité et la transparence dans l'apprentissage automatique¹⁸⁴. Des spécialistes ont publié des résultats prometteurs, par exemple sur la prévention de la discrimination dans l'exploration de gros volumes de données¹⁸⁵.

Il peut être difficile de déterminer les risques d'un projet d'IA. Laissés à eux-mêmes, les informaticiens qui créent le système doivent prendre des décisions subjectives, et ont souvent du mal à faire comprendre les risques et les choix à l'équipe de direction¹⁸⁶. Les personnes chargées du développement d'un système d'IA doivent être activement soutenues dans l'évaluation et la réduction des risques de discrimination ; le temps et les crédits nécessaires devraient être dûment pris en compte dans tout projet de ce type.

Les risques et les principes juridiques et normatifs applicables diffèrent d'un secteur à l'autre. Les risques ne sont par exemple pas les mêmes pour un système d'IA servant à sélectionner des

¹⁸³ Voir par exemple AI Now Institute 2018 ; Mantelero 2018 ; Mantelero 2018a.

¹⁸⁴ <https://www.fatml.org> consulté le 1^{er} août 2018.

¹⁸⁵ Voir par exemple Custers *et al.* 2013 ; Kamiran et Calders 2009 ; Kamiran et Calders 2012 ; Kusner *et al.* 2017 ; Pedreschi, Ruggieri, et Turini 2008.

¹⁸⁶ Veale, Van Kleek et Binns 2018. Kaminski 2018a, p. 30 : les ingénieurs ne devraient pas définir la discrimination ou l'équité sans une discussion approfondie avec des juristes et des membres de la collectivité.

candidats et pour un système de prédiction de la criminalité. Ce qui veut dire qu'il faudrait s'assurer le concours d'experts du secteur concerné¹⁸⁷. Il peut être utile de créer un comité d'éthique qui évaluera et analysera les systèmes d'IA risquant de porter atteinte à des droits de l'homme¹⁸⁸. Il peut également être utile d'aborder avec des universitaires, des groupes de la société civile et des personnes susceptibles d'être affectées les inquiétudes que leur inspire le système¹⁸⁹.

Une façon d'apprécier les risques d'un projet d'IA est de procéder à une forme appropriée d'analyse d'impact. On pourra s'inspirer de l'analyse d'impact exigée par le GDPR pour certains traitements de données à risque¹⁹⁰. Et les organisations, surtout publiques, devraient envisager de publier le rapport de l'analyse d'impact.

Les risques présentés par le système d'IA devraient aussi être surveillés en cours d'utilisation, surtout que les phénomènes que reproduit le système changeront vraisemblablement au fil du temps, ce qui veut dire que les risques et l'impact changeront aussi¹⁹¹. Les organisations devraient envisager de publier des rapports annuels de surveillance du système.

Il est souvent possible de prévenir, ou du moins de minimiser, les effets discriminatoires. Une organisation peut par exemple décider de ne pas utiliser certaines caractéristiques comme données de base dans le système d'IA. À titre d'illustration, une société américaine d'aide au recrutement indique qu'elle n'utilise pas la distance domicile-travail dans la prédiction des candidats qui se révéleront de bons employés, car la corrélation

¹⁸⁷ Campolo *et al.* 2017, p. 2.

¹⁸⁸ Conseil de l'Europe, Lignes directrices sur la protection des personnes à l'égard du traitement des données à caractère personnel à l'ère des mégadonnées, 2017, paragraphe 1.3.

¹⁸⁹ Voir article 35(9) GDPR.

¹⁹⁰ Conseil de l'Europe, Lignes directrices sur la protection des personnes à l'égard du traitement des données à caractère personnel à l'ère des mégadonnées, 2017, article 2.5. Voir également Reisman *et al.* 2018 ; Selbst 2017.

¹⁹¹ Voir également article 35(11) GDPR ; Gama *et al.* 2014.

avec la race est trop étroite. The Atlantic précise que la distance domicile-travail, par exemple, n'est jamais prise en compte dans le score d'un candidat, même si elle est communiquée à certains clients ; en effet, les quartiers et les villes peuvent présenter un certain profil racial, ce qui veut dire que la prise en compte de la distance pourrait enfreindre les normes d'égalité des chances au travail¹⁹².

Le personnel des sociétés d'IA et des laboratoires de recherche universitaires est rarement très diversifié (le plus souvent masculin et blanc, par exemple). Une organisation de ce type pourrait accorder plus d'attention à la discrimination si son personnel était plus diversifié. Les organisations devraient donc veiller à employer un personnel plus diversifié¹⁹³. Bien entendu, la diversité du personnel est toujours un objectif important.

Organismes publics

Le secteur public a plus de responsabilités que le privé. De nombreuses règles juridiques visent en effet à protéger la population contre le pouvoir de l'État, par exemple dans le domaine des droits de l'homme, des procédures pénales et du droit administratif. Ces responsabilités additionnelles s'appliquent aussi aux organismes publics qui utilisent des systèmes d'IA.

C'est pourquoi les systèmes d'IA du secteur public devraient être conçus dans un souci de transparence¹⁹⁴. Parfois, l'information sur le système d'IA pourrait être communiquée au public pour contrôle, dans l'esprit du mouvement d'ouverture des données. Mais parfois aussi, cette information pourrait laisser transparaître des données personnelles et menacer le secret de la vie privée¹⁹⁵, ou permettre à certaines personnes de manipuler le système d'IA¹⁹⁶. Les organismes publics

¹⁹² Peck 2013. Voir également Rieke, Robinson et Yu 2014, p. 15.

¹⁹³ Campolo *et al.* 2017, p. 16.

¹⁹⁴ Voir Kroll *et al.* 2016 ; Munoz, Smith et Patil, 2016.

¹⁹⁵ Veale, Binns et Edwards 2018.

¹⁹⁶ Laskov et Lippman 2011 ; Bambauer et Zarsky 2018.

pourraient donc ouvrir à des chercheurs ou à la société civile un accès contrôlé aux systèmes d'IA, dans un environnement sécurisé, comme les bureaux de statistiques le font aujourd'hui pour les microdonnées sensibles¹⁹⁷.

Le secteur public pourrait aussi adopter une clause de suppression automatique à la mise en place d'un système d'IA appelé à prendre des décisions affectant des personnes. Cette clause imposerait que le système soit soumis à une évaluation, par exemple au bout de trois ans, pour déterminer s'il a livré les résultats attendus¹⁹⁸. Si ce n'est pas le cas, ou si les inconvénients ou les risques l'emportent, il faudrait envisager son abandon. Certes, le secteur public a plus de responsabilités, mais les organisations privées (entreprises, par exemple) pourraient prendre les mêmes mesures que celles qui ont été proposées pour le secteur public.

2. ORGANISMES DE PROMOTION DE L'EGALITE ET ORGANES DE SURVEILLANCE DU RESPECT DES DROITS DE L'HOMME

Quelles mesures de réduction des risques de discrimination par l'IA peuvent être recommandées aux organismes de promotion de l'égalité des États membres du Conseil de l'Europe, et aux organes chargés de la surveillance du respect des droits de l'homme, comme la Commission européenne contre le racisme et l'intolérance ?

Formation et compétences techniques

Les organismes de promotion de l'égalité et les organes chargés de la surveillance du respect des droits de l'homme devraient comprendre les promesses et les menaces de l'IA. Il est donc nécessaire de leur fournir une formation de base sur l'IA et ses risques.

¹⁹⁷ Sur les degrés variables de liberté dans le contexte des données libres, voir Zuiderveen Borgesius, Gray, et Van Eechoud 2015.

¹⁹⁸ McCray, Oye et Petersen 2010 ; Broeders, Schrijvers et Hirsch Ballin, p. 23.

Les organismes de promotion de l'égalité et les organes de surveillance du respect des droits de l'homme devraient aussi veiller à disposer des compétences techniques nécessaires en matière d'IA en s'assurant le concours de spécialistes des sciences informatiques¹⁹⁹. Ces derniers sont mieux à même de percevoir et de comprendre certains risques que, par exemple, des juristes²⁰⁰. Même si ce ne sont pas des spécialistes de l'IA, ils pourraient procéder eux-mêmes à certaines recherches sur la discrimination provoquée par l'IA. Comme l'observent Rieke, Bogen et Robinson, la surveillance n'a pas besoin d'être très complexe pour donner de bons résultats²⁰¹. Les problèmes que présente un système d'IA peuvent souvent être découverts par la simple observation de ses intrants et extrants²⁰². Et les informaticiens non spécialisés dans l'IA savent souvent à quels spécialistes faire appel dans une enquête. Selon leur budget, les organismes de promotion de l'égalité et les organes de surveillance du respect des droits de l'homme pourraient recruter des informaticiens pour un projet, ou de façon plus permanente.

Ils pourraient envisager d'organiser des campagnes de sensibilisation des organisations publiques et privées²⁰³. On l'a vu, c'est souvent par accident que les organisations utilisent des systèmes d'IA discriminatoires. La sensibilisation pourrait se révéler utile.

D'une façon plus générale, les écoles et les universités qui enseignent l'informatique, la science des données, l'IA et des

¹⁹⁹ Comme nous l'avons dit, l'expression « spécialistes des sciences informatiques » est ici une étiquette générale : des spécialistes des données et d'autres personnes possédant une connaissance suffisante de l'IA pourraient également apporter leurs compétences.

²⁰⁰ Sur l'importance des compétences techniques des autorités de protection des données, voir Raab et Szekely 2017.

²⁰¹ Rieke, Bogen et Robinson 2018, p. 2.

²⁰² Rieke, Bogen et Robinson 2018, p. 8. On y trouvera également des exemples de surveillance de systèmes d'IA (p. 31-34).

²⁰³ Voir Résolution de 2002 relative au statut de l'ECRI, article 12 ; ECRI, Recommandation de politique générale n° 2 (2018), paragraphe 13(e) ; paragraphe 34, et exposé des motifs, paragraphe 64.

matières connexes devraient familiariser aussi leurs étudiants avec les droits de l'homme et la déontologie. Beaucoup d'universités offrent déjà des cours de ce type à leurs étudiants d'informatique²⁰⁴. Les organismes de promotion de l'égalité et les organes de surveillance du respect des droits de l'homme pourraient envisager d'aider les écoles et les universités à organiser ces cours²⁰⁵.

Il serait possible de favoriser le débat public en familiarisant le grand public avec les risques de discrimination par l'IA, mais aussi avec les nombreux avantages et possibilités qu'elle offre. La sensibilisation ne devrait cependant pas conduire à la responsabilisation, c'est-à-dire à la responsabilité individuelle d'une mission précédemment confiée à une autre entité (normalement de l'État) ou simplement non reconnue auparavant comme une responsabilité²⁰⁶. On ne saurait remettre à l'individu le soin de se défendre lui-même contre la discrimination²⁰⁷. La sensibilisation n'en est pas moins nécessaire à un débat inclusif sur les risques des décisions d'IA.

²⁰⁴ Fiesler 2018 a dressé une liste de plus de 200 cours de déontologie technique.

²⁰⁵ Voir ECRI, Recommandation de politique générale n° 10 sur la lutte contre le racisme et la discrimination raciale dans et travers l'éducation scolaire, 15 décembre 2006, Strasbourg, CRI(2007)6 <https://rm.coe.int/ecri-general-policy-recommendation-no-10-on-combating-racism-and-racia/16808b5ad5>, consulté le 14 octobre 2018.

²⁰⁶ Wakefield et Fleming 2009.

²⁰⁷ Voir également Ellis et Watson 2012, p. 502-503.

Consultation préalable des organismes de promotion de l'égalité

Les organismes de promotion de l'égalité pourraient demander aux organes publics de leur soumettre leurs projets de décisions automatisées affectant des personnes ou des groupes. Un tel organisme pourrait par exemple les aider à vérifier si les données d'apprentissage sont biaisées²⁰⁸. Il pourrait aussi demander à chaque organe public utilisant une IA pour des décisions automatisées affectant des personnes de s'assurer qu'il possède les compétences juridiques et techniques nécessaires à l'évaluation et la surveillance du risque. Et il pourrait aussi être exigé des organismes publics qu'ils vérifient régulièrement que leur système d'IA ne produit pas d'effets discriminatoires. (Selon le contexte national, les organismes de promotion de l'égalité pourraient aussi suggérer plutôt qu'exiger.)

Les organismes de promotion de l'égalité et les organes de surveillance du respect des droits de l'homme pourraient contribuer à la conception d'une méthode spécifique d'évaluation des droits de l'homme et de l'impact de l'IA. Comme indiqué précédemment, l'analyse d'impact peut être utile, mais il n'en existe pas pour l'instant de forme spécifiquement adaptée à l'IA²⁰⁹. Diverses parties prenantes et spécialistes de plusieurs disciplines devraient être associés à sa conception. Il serait possible de s'inspirer des analyses d'impact sur la vie privée et la protection des données²¹⁰.

²⁰⁸ Voir ECRI Recommandation de politique générale n° 2 (2018), paragraphe 13(g). Voir également article 36 GDPR sur la consultation préalable.

²⁰⁹ Reisman *et al.* 2018 examinent l'évaluation d'impact algorithmique aux États-Unis. Les États membres du Conseil de l'Europe ayant des systèmes juridiques différents de celui des États-Unis, ces méthodes pourraient les inspirer, mais ne seraient pas directement transférables.

²¹⁰ Voir Binns 2017 ; Kloza *et al.* 2017 ; Mantelero 2017 ; Wright et De Hert 2012. Voir également the Brussels Laboratory for Data Protection and Privacy Impact Assessments <http://dpialab.org/>.

Participation à la passation des marchés publics

Les organismes de promotion de l'égalité devraient s'appuyer sur les dispositions et processus nationaux et faire pression pour obtenir un meilleur accès afin de se faire associer très précocement à la passation de marchés publics d'acquisition de systèmes d'IA. Ils peuvent veiller à ce que la conception de ces systèmes tienne compte des inquiétudes suscitées par les risques de discrimination, et à ce que les systèmes soient suffisamment ouverts aux audits et fassent l'objet de garanties appropriées.

Coopération avec les autorités de protection des données

Nous avons dit que les deux instruments juridiques les plus utiles, en ce qui concerne la discrimination provoquée par l'IA, sont la législation anti-discrimination et la législation sur la protection des données. Il serait extrêmement dommage de ne pas les combiner²¹¹. Les organismes de promotion de l'égalité devraient coopérer avec les autorités de protection des données. Il pourrait être utile, par exemple, qu'ils échangent leurs savoirs et leur expérience²¹². Nombre d'autorités de protection des données possèdent certaines compétences techniques au sein de leur personnel²¹³, et certaines ont l'expérience du recrutement d'informaticiens extérieurs pour des projets de recherche²¹⁴. Les autorités de protection des données pourraient par exemple, si elles ont vent d'organisations qui utilisent des systèmes d'IA présentant un risque de discrimination, alerter l'organisme de promotion de l'égalité. Ce dernier pourrait communiquer des informations aux autorités de protection des données, par exemple sur les risques de discrimination. Selon la situation constatée dans

²¹¹ Voir Schreurs *et al.* 2008 ; Gellert *et al.* 2013 ; Hacker 2018 ; Lammerant, De Hert, Blok 2017.

²¹² Voir ECRI, Recommandation de politique générale no 2 (2018), paragraphe 13(b).

²¹³ Raab et Szekeley 2017.

²¹⁴ Des chercheurs de l'université de Louvain ont par exemple examiné le système de suivi de Facebook pour l'Autorité belge de protection des données. Voir Autorité belge de protection des données 2018.

chaque pays, il pourrait aussi être utile que des organismes de promotion de l'égalité coopèrent avec les autorités de protection des consommateurs et les autorités de surveillance de la concurrence.

Au chapitre de la coopération et du partage de savoirs entre les organes de régulation, le Contrôleur européen de la protection des données a proposé en 2016 de créer un réseau volontaire d'organismes de contrôle leur permettant de partager des informations sur les abus possibles de l'écosystème numérique et les formes les plus efficaces de lutte²¹⁵. Cette initiative pourrait servir d'inspiration aux organismes de promotion de l'égalité et aux organes de surveillance du respect des droits de l'homme²¹⁶.

Coopération avec le monde universitaire

Les organismes de promotion de l'égalité et les organes de surveillance du respect des droits de l'homme devraient maintenir des contacts, voire coopérer, avec les universitaires. Notre rapport révèle de nombreux exemples de décisions discriminatoires d'IA découvertes par des chercheurs universitaires (et des journalistes d'investigation)²¹⁷. Les universitaires sont souvent heureux d'aider les organes de régulation, mais n'ont pas de contacts réguliers avec eux. Dans un premier temps, les organismes de promotion de l'égalité et les organes de surveillance pourraient assister à des conférences et autres rencontres de chercheurs universitaires. La discrimination par l'IA est très souvent abordée dans des conférences internationales sur la protection de la vie privée. Plusieurs de ces conférences attirent des organismes de régulation, des praticiens, des groupes de la société civile et des universitaires de différentes disciplines (droit, informatique,

²¹⁵ Contrôleur européen de la protection des données 2016.

²¹⁶ D'ailleurs, il faudrait aussi intensifier la coopération entre juristes de différentes disciplines au sein des universités : spécialistes du droit relatif à la non-discrimination (qui travaillent fréquemment dans des instituts des droits de l'homme) et du droit relatif à la protection des données (souvent rattachés à des instituts de droit et de technologie).

²¹⁷ Voir Rieke, Bogen et Robinson 2018, p. 31.

philosophie et sociologie)²¹⁸. Les organismes de promotion de l'égalité et les organes de surveillance pourraient aussi envisager d'organiser des conférences, des tables rondes et d'autres rencontres sur les risques de discrimination par l'IA, pour encourager les contacts entre les chercheurs et les organes de promotion de l'égalité. Et peut-être est-ce que ces derniers et les organes de surveillance pourraient faire procéder à davantage de recherches sur les risques de discrimination par l'IA (se reporter à ce sujet à la section VI.3), ou former un groupe de travail à ce sujet²¹⁹.

Les organismes de promotion de l'égalité et les organes de surveillance du respect des droits de l'homme devraient se rapprocher non seulement des groupes de la société civile travaillant sur la discrimination²²⁰, mais aussi des associations de consommateurs²²¹ et des groupes de la société civile spécialisés dans les politiques technologiques et les droits numériques²²². Les groupes de la société civile qui travaillent sur la discrimination possèdent souvent des compétences différentes de ceux qui travaillent sur la technologie et les droits numériques. Il serait utile de multiplier les contacts entre eux,

²¹⁸ Voir par exemple CPDP Computers, Privacy and Data Protection conference in Brussels <https://www.cpdpconferences.org> ; APC Amsterdam Privacy Conference <https://www.apc2018.com> ; TILTING Perspectives <https://www.tilburguniversity.edu/research/institutes-and-research-groups/tilt/events/tilting-perspectives> ; et PLSC Privacy Law Scholars Conference <http://law.berkeley.edu/plsc>. L'ACM Conference on Fairness, Accountability, and Transparency (ACM FAT*) se tiendra à Amsterdam en 2020 : <https://www.fatml.org> . Consultés le 14 octobre 2018.

²¹⁹ Voir Résolution de 2002 relative au statut de l'ECRI, article 6(1) et 6(2) ; ECRI, Recommandation de politique générale no 2 (2018), paragraphe 13(d).

²²⁰ Voir Résolution de 2002 relative au statut de l'ECRI, articles 10(1) et 13.

²²¹ Le BEUC (Bureau européen des unions de consommateurs) pourrait constituer un point de contact avec les associations de consommateurs. Il rassemble 43 associations de consommateurs de 32 pays européens. [HTTPS://www.beuc.eu/about-beuc/who-we-are](https://www.beuc.eu/about-beuc/who-we-are), consulté le 10 octobre 2018. Voir également Bureau européen des unions de consommateurs BEUC 2018.

²²² En ce qui concerne les groupes centrés sur les droits et libertés dans l'environnement numérique, un point de contact pourrait être Droit numérique européen (EDRI), une association d'organisations de défense des droits civils et des droits de l'homme de toute l'Europe. <https://edri.org/members/>, consulté le 10 octobre 2018.

car beaucoup s'intéressent aussi à la discrimination causée par l'IA²²³.

Traitement des contentieux et réglementation

En fonction de la situation nationale, les organismes de promotion de l'égalité pourraient aussi assurer le traitement stratégique des contentieux dans le domaine des décisions d'IA²²⁴. Avec les organismes de surveillance du respect des droits de l'homme, ils pourraient demander l'adoption de normes réduisant les risques de discrimination par l'IA²²⁵. Le chapitre suivant propose des améliorations possibles en la matière.

VI. AMÉLIORATION DE LA RÉGLEMENTATION

Par quels dispositifs (juridiques, réglementaires, d'autorégulation) est-il possible de réduire les risques ?

On a vu au chapitre IV que la législation actuelle présente des points faibles en matière de discrimination provoquée par l'IA. D'autres textes seront probablement nécessaires pour protéger les personnes contre la discrimination illicite et la différenciation injuste. La section 1 présente des observations liminaires sur la réglementation d'une technologie en rapide développement. La section 2 se penche sur l'amélioration du respect des normes actuelles de lutte contre la discrimination. La section 3 examine si les décisions d'IA appellent une modification des normes juridiques elles-mêmes. Les idées proposées dans ce chapitre sont à considérer comme des pistes de réflexion, et non comme des conseils à proprement parler pour la définition de politiques en la matière.

²²³ Voir Gangadharan et Niklas 2018, qui ont interrogé des ONG et conclu à la nécessité d'une meilleure coopération entre les ONG spécialisées dans la vie privée et la technologie d'une part, et les ONG spécialisées dans la discrimination de l'autre.

²²⁴ Voir ECRI, Recommandation de politique générale n° 2 (2018), paragraphes 14-16.

²²⁵ Voir Résolution de 2002 relative au statut de l'ECRI, article 1 ; ECRI, Recommandation de politique générale no 2 (2018), paragraphe 13(j).

1. LA REGLEMENTATION DE TECHNOLOGIES EN RAPIDE ESSOR

La réglementation d'une technologie en rapide essor pose des difficultés particulières. L'adoption de textes juridiques ou de traités peut prendre des années, voire des dizaines d'années. Pendant ce temps, la technologie concernée, le marché et la société évoluent rapidement.

Ces difficultés ne concernent pas spécifiquement l'IA, et il existe une certaine expérience de la réglementation de technologies nouvelles. Dans ce domaine, les politiques peuvent combiner des normes variées : textes législatifs pour poser les grands principes, et lignes directrices (émanant des organes de régulation, par exemple) fixant des règles plus précises²²⁶. La loi pourrait être formulée d'une façon raisonnablement indépendante de la technologie. Les dispositions de ce type définissent les grands principes et ont pour avantage de ne pas nécessiter de modification à chaque avancée de la technologie ; en revanche, elles peuvent se révéler difficiles d'application dans la pratique. Les lignes directrices formulées par l'organe de régulation peuvent donc se révéler utiles²²⁷ ; elles peuvent être modifiées plus rapidement, ce qui leur permet d'être plus spécifiques et concrètes ; elles devraient faire l'objet d'évaluations régulières, et être modifiées dès que cela devient nécessaire²²⁸.

La réglementation de la protection des données adopte en partie cette approche combinée²²⁹. Les textes juridiques (comme le GDPR et la Convention 108 modernisée) contiennent de nombreuses dispositions à la formulation large,

²²⁶ Voir Koops 2006.

²²⁷ Voir Zuiderveen Borgesius 2015a, chapitre 9, section 1 ; Baldwin, Cave et Lodge 2011, chapitre 14.

²²⁸ Voir Koops 2006.

²²⁹ Je ne dis pas que la législation sur la protection des données devrait être considérée comme une bonne pratique de réglementation des domaines dans lesquels une technologie se développe rapidement. La législation sur la protection des données est loin d'être irréprochable.

applicables à diverses situations et technologies²³⁰. Ils ne prévoient par exemple pas de règles spécifiques pour la vidéosurveillance ou pour la surveillance sur le lieu de travail. Mais ils s'appliquent à ces deux cas dès lors qu'il y a données personnelles (notamment des images vidéo).

Outre les textes juridiques sur la protection des données, les autorités de protection des données adoptent fréquemment des lignes directrices interprétatives fixant des exigences plus spécifiques et plus concrètes pour des situations diverses, comme la vidéosurveillance²³¹, le lieu de travail²³² et les décisions automatisées²³³. Au sein de l'UE, le Comité européen de la protection des données et son prédécesseur ont adopté plus de 250 lignes directrices depuis 1995²³⁴. De même, le Conseil de l'Europe a adopté des lignes directrices en plus de la Convention 108 sur la protection des données, par exemple sur les mégadonnées (*Big Data*)²³⁵, la police²³⁶ et le profilage²³⁷.

²³⁰ La législation sur la protection des données mise en place à partir du début des années 1970 pourrait elle-même être perçue comme la réponse juridique à un phénomène nouveau : les administrations de grande envergure et le traitement automatisé des données personnelles. Depuis ses débuts, la législation sur la protection des données a été continuellement adaptée au fil de l'évolution du domaine, comme en témoignent le récent GDPR et la Convention 108 modernisée.

²³¹ Groupe de travail (Working Group) « article 29 » 2004 (WP89).

²³² Groupe de travail (Working Group) « article 29 » 2017 (WP249).

²³³ Groupe de travail (Working Group) « article 29 » 2018 (WP251).

²³⁴ Voir site internet du Comité européen de la protection des données https://edpb.europa.eu/edpb_en. Son prédécesseur était appelé Groupe de travail (Working Group) « article 29 » http://ec.europa.eu/newsroom/article29/news.cfm?item_type=1308. Les avis et lignes directrices sont également réunis sur le site <https://iapp.org/resources/article/all-of-the-european-data-protection-board-and-article-29-working-party-guidelines-opinions-and-documents/>. Liens consultés le 10 octobre 2018.

²³⁵ Conseil de l'Europe, lignes directrices sur les mégadonnées 2017.

²³⁶ Conseil de l'Europe, Guide pratique sur l'utilisation de données à caractère personnel dans le secteur de la police, 2018.

²³⁷ Conseil de l'Europe, Recommandation sur le profilage 2010.

Ce qui veut dire que pour réduire par de nouvelles règles les risques de discrimination par l'IA, il conviendrait sans doute de combiner des normes juridiques à des possibilités offertes aux organes de régulation de préparer des lignes directrices plus aisées à modifier. Il existe d'autres possibilités que les textes de loi et les textes d'orientation des organes de contrôle, comme la corégulation : de l'autorégulation soumise à divers degrés d'influence des organes publics de contrôle. L'idée de base reste la même : combiner des règles de nature différente ²³⁸ . Comme le dit Koops, la réglementation multiniveaux, les formulations ouvertes et un mélange de règles abstraites et concrètes régulièrement réévaluées permettent d'obtenir une bonne sécurité juridique en ce qui concerne les technologies du moment, tout en laissant une marge suffisante de développement aux technologies concernées²³⁹ .

Évidemment, les entités chargées de formuler les règles et les lignes directrices doivent posséder une légitimité démocratique, avec un dispositif suffisant de freins et de contrepoids. La réglementation de nouvelles technologies est donc difficile, mais possible — et souvent nécessaire.

2. CONTROLE DU RESPECT

Meilleur respect des normes anti-discrimination existantes

Les normes générales applicables à la discrimination causée par les décisions d'IA sont raisonnablement claires : notre société n'accepte pas ni ne doit accepter la discrimination au motif des caractéristiques protégées, comme l'origine raciale. Nous suggérons ci-dessous quelques moyens de faire respecter les normes anti-discrimination dans le domaine de l'IA.

²³⁸ Voir Angelopoulos *et al.* 2016, p. 5-6 ; Brown et Marsden 2013. Et sur la corégulation : Hirsch 2010 ; Kaminsky 2018a.

²³⁹ Koops 2006.

Transparence

Nous avons déjà mentionné le manque de transparence parmi les problèmes suscités par les systèmes d'IA, qui fonctionnent comme des « boîtes noires »²⁴⁰. Cette opacité est un problème en soi, mais elle freine aussi la découverte des effets discriminatoires.

La réglementation (ce qui englobe les lignes directrices, etc.) pourrait viser à améliorer la transparence, par exemple en exigeant que la conception des systèmes d'IA du secteur public permette les audits et les explications²⁴¹. Ces exigences pourraient aussi s'appliquer aux acteurs privés²⁴². Il existe des précédents en la matière dans le secteur privé : certains algorithmes de trading doivent être interprétables²⁴³.

Pour certains types de systèmes, il pourrait être utile que les organes publics publient le code source du logiciel. Son examen peut parfois fournir des informations sur le fonctionnement du système. Rieke, Bogen et Robinson observent que les audits de code source ont les plus grandes chances d'être utiles lorsqu'il s'agit de répondre à une question claire sur le fonctionnement d'un logiciel dans un espace réglementé, avec des normes particulières sur la base desquelles juger le comportement ou les performances d'un système²⁴⁴. Il serait possible de modifier les lois sur la liberté de l'information de façon à leur faire couvrir le code source des systèmes d'IA. Cette modification permettrait aux journalistes, aux universitaires et à d'autres d'obtenir et d'examiner le code source.

²⁴⁰ Pasquale 2015. Voir également Zarsky 2018.

²⁴¹ Voir Rieke, Bogen et Robinson 2018, p. 6 ; Pasquale 2017. Sur l'audit des systèmes d'IA, voir Sandvig *et al.* 2014.

²⁴² Voir Rieke, Bogen et Robinson 2018, p. 6.

²⁴³ Voir section IV.3 ; partie sur le trading algorithmique.

²⁴⁴ Rieke, Bogen et Robinson 2018, p. 19.

Les systèmes d'IA sont protégés par le secret des affaires, les droits de propriété intellectuelle ou les conditions de vente des entreprises²⁴⁵. Cette protection entrave les organes de contrôle, les journalistes et les universitaires dans l'examen des systèmes. La législation pourrait être modifiée et admettre davantage d'exceptions pour motif de recherche, de façon à rendre possibles certains types de recherche. Et elle devrait peut-être aussi imposer aux organisations de fournir certaines informations aux chercheurs à leur demande. Les textes devront judicieusement arbitrer entre l'intérêt public de transparence et l'intérêt commercial, la confidentialité et autres intérêts protégés par l'opacité²⁴⁶.

Bien souvent, le code source ne renseigne pas beaucoup à lui seul sur le système d'IA, dont l'évaluation n'est possible que par observation de son fonctionnement dans la réalité. Même pour des programmes modérément complexes, constatent Rieke, Bogen et Roginson, il peut se révéler nécessaire de voir fonctionner un programme dans des conditions réelles, avec de vrais utilisateurs et de vraies données, pour véritablement appréhender ses effets²⁴⁷.

La législation pourrait imposer au secteur public de n'utiliser que des systèmes d'IA dont les risques ont été convenablement évalués, et qui permettent la surveillance et les audits²⁴⁸. On pourrait envisager une exigence analogue pour le secteur privé lorsque les systèmes d'IA servent à prendre certaines décisions (assurance, crédit ou emploi, par exemple)²⁴⁹. Des recherches et des débats sont encore nécessaires pour déterminer qui procéderait à ces audits. Une organisation chargée du contrôle

²⁴⁵ Voir Bodo *et al.* 2017, p. 171-175 ; Malgieri 2016 ; Wachter et Mittelstadt 2018, p. 63-77.

²⁴⁶ Des questions similaires se posent en ce qui concerne les données libres et la protection de la confidentialité. Voir Zuiderveen Borgesius, Gray, et Van Eechoud 2015.

²⁴⁷ Rieke, Bogen et Robinson 2018, p. 19.

²⁴⁸ Voir Campolo *et al.* 2018, p. 1.

²⁴⁹ Voir Campolo *et al.* 2018, p. 1.

et de l'audit de systèmes d'IA a besoin de compétences considérables²⁵⁰.

Pouvoirs d'investigation et de répression

Les États membres du Conseil de l'Europe devraient faire en sorte que les organismes de promotion de l'égalité et les autorités de protection des données soient convenablement financés et disposent de pouvoirs suffisants d'investigation et de répression²⁵¹. Sans répression des infractions, la transparence ne conduira pas nécessairement à la responsabilisation²⁵².

En conclusion, les organismes de promotion de l'égalité et les organes de surveillance du respect des droits de l'homme peuvent demander que la réglementation impose mieux le respect des normes anti-discrimination actuelles dans le domaine des décisions d'IA. Mais ces dernières ouvrent sur de nouvelles formes de discrimination et de différenciation qui échappent largement à la réglementation actuelle, notamment de lutte contre la discrimination. C'est la question sur laquelle nous allons nous pencher à présent.

3. LA RÉGLEMENTATION DE NOUVELLES DIFFÉRENCIATIONS

Le dispositif de réglementation de la non-discrimination et de la protection des données comporte des lacunes en ce qui concerne l'IA²⁵³. De nombreux textes de lutte contre la discrimination ne couvrent que certaines caractéristiques protégées, comme la race, le genre ou l'orientation sexuelle²⁵⁴. Ils ne s'appliquent pas à la discrimination au motif de l'état de fortune, par exemple. La législation sur la protection des

²⁵⁰ Il a été suggéré qu'un organisme spécial de surveillance du profilage automatisé (décisions d'IA) pourrait être utile. Voir Koops 2008.

²⁵¹ Voir ECRI Recommandation de politique générale n° 2 (2018), paragraphe 28.

²⁵² Voir Kaminski 2018a, p. 21.

²⁵³ Voir sections IV.1 et IV.2.

²⁵⁴ Gerards 2007 ; Khaitan 2015.

données pourrait aider à combler certaines de ces lacunes, mais certainement pas toutes.

Les systèmes d'IA peuvent échapper aux dispositions anti-discrimination lorsqu'ils différencient des catégories non encore répertoriées²⁵⁵. Pour prendre un exemple simple, supposons qu'un système d'IA découvre une corrélation entre l'utilisation d'un certain navigateur et l'acceptation de prix supérieurs. Un magasin en ligne pourrait demander des prix plus élevés aux utilisateurs de ce navigateur²⁵⁶. Cela ne relèverait pas de la législation anti-discrimination, le navigateur ne faisant pas partie des caractéristiques protégées (nous faisons ici l'hypothèse que le navigateur ne peut pas servir de donnée indirecte de détection d'une caractéristique protégée).

L'IA peut renforcer les inégalités sociales

Les décisions d'IA peuvent procéder à des différenciations injustes ou présentant d'autres effets indésirables même si elles n'entrent pas dans le champ d'application de la législation anti-discrimination. Une compagnie d'assurances, par exemple, pourrait utiliser un système d'IA pour fixer les primes de chaque assuré ou pour refuser une police. La différenciation par le risque est dans une certaine mesure nécessaire, et c'est une pratique acceptée chez les assureurs. On peut considérer comme équitable qu'un assuré présentant un risque supérieur verse une prime supérieure.

Mais il y a des inconvénients. La différenciation exagérée par le risque pourrait rendre l'assurance impossible à certains consommateurs et compromettre la fonction de mutualisation du risque de l'assurance. Elle pourrait aussi avoir pour effet de faire payer davantage aux pauvres. Un consommateur qui habite dans un quartier pauvre, où les cambriolages sont

²⁵⁵ Custers 2004. Voir également Mittelstadt *et al.* 2016.

²⁵⁶ Il n'y a pas d'indice de recours à cette pratique, mais cette discrimination par le prix serait techniquement aisée. Il a existé toutefois un site de voyages et de réservations qui présentait des hôtels plus chers aux utilisateurs de matériel Apple, et moins chers aux utilisateurs de PC (Mattioli 2012).

nombreux, paiera une prime d'assurance supérieure pour son logement, du fait que le risque de vol est plus élevé. Mais si les quartiers où habitent de nombreux pauvres présentent un risque supérieur, les pauvres paieront davantage en moyenne²⁵⁷.

L'IA pourrait renforcer les inégalités sociales d'une façon plus générale. Valentino-De Vroes, Singer-Vine et Soltani ont par exemple montré que certaines pratiques de différenciation des prix en ligne aux États-Unis avaient pour effet que les habitants de zones d'habitation pauvres paient des prix plus élevés. Plusieurs magasins demandaient plus aux personnes vivant à la campagne qu'aux citadins²⁵⁸. À la campagne, le consommateur doit parcourir une longue distance pour se rendre chez un concurrent. Un magasin en ligne n'a donc pas besoin de recourir à des prix bas : la plupart des consommateurs ne feront pas le trajet pour obtenir un meilleur prix. Dans une grande ville, le consommateur peut aisément acheter le même produit chez un concurrent ; certains magasins en ligne y pratiquent donc des prix inférieurs. Ce mode de formation des prix avait pour effet — sans doute non intentionnel — que les gens pauvres payaient en moyenne davantage, du fait que les personnes habitant à la campagne ont tendance à être plus pauvres aux États-Unis²⁵⁹. L'IA peut donc renforcer les inégalités sociales. Or l'état de fortune ne constitue pas une caractéristique protégée, et la législation anti-discrimination ne couvre donc pas une telle pratique (à moins

²⁵⁷ Sur l'IA dans l'assurance, voir Dutch Association of Insurers 2016 ; Financial Conduct Authority 2016 ; Peppet 2014 ; Swedloff 2014. L'Allemagne a adopté des règles spécifiques sur les décisions automatisées dans l'assurance. Voir Bundesdatenschutzgesetz (loi fédérale sur la protection des données) du 20 juin 2017 (BGBl. I S. 2097), section 37 https://www.gesetze-im-internet.de/englisch_bdsch/englisch_bdsch.html#p0310 consulté le 13 octobre 2018. Voir également Malgieri 2018, p. 9-11. Sur la discrimination dans l'assurance, voir Avraham 2017.

²⁵⁸ Valentino-De Vries, Singer-Vine et Soltani 2012.

²⁵⁹ Valentino-De Vries, Singer-Vine et Soltani 2012. Sur le renforcement des inégalités sociales et le « tri social », voir également Atrey 2018 ; Danna et Gandy 2002 ; Lyon 2002 ; Naudts 2017 ; Taylor 2017 ; Turow 2011. Gandy mettait en garde il y a 25 ans déjà contre les effets discriminatoires du traitement de données à grande échelle (Gandy 1993).

qu'elle ne débouche sur une discrimination indirecte fondée sur une caractéristique protégée)²⁶⁰.

L'IA peut se tromper

Le droit relatif à la discrimination n'aborde guère les erreurs de prédiction de l'IA (faux positifs ou négatifs). Or les décisions d'IA sont souvent erronées à l'échelon individuel, car elles appliquent fréquemment un modèle prédictif à un individu. Prenons un exemple : 80 % des personnes ayant le code postal XYZ règlent leurs factures en retard. Si, sur cette base, une banque refuse d'accorder un crédit à tous les habitants de ce quartier, son refus s'applique aussi aux 20 % d'habitants qui règlent leurs factures à temps²⁶¹. Une telle pratique pourrait pénaliser de façon disproportionnée certains groupes sociaux. Un système d'AI fait parfois plus d'erreurs parmi les groupes minoritaires que dans la population majoritaire²⁶².

Nouvelles normes ?

Il faudrait envisager de compléter la réglementation parce que les décisions d'IA non couvertes par les lois anti-discrimination peuvent être injustes. Mais il ne serait probablement pas très utile d'adopter des règles applicables à l'ensemble des décisions de ce type. L'IA est en effet utilisée dans bien des secteurs et à bien des fins, et menace rarement les droits de l'homme²⁶³. L'IA d'un jeu d'échecs ne comporte pas les mêmes risques qu'un système de prédiction policière par IA.

Même parmi les systèmes d'IA prenant des décisions qui affectent des êtres humains, les risques varient en fonction du secteur, et les règles devraient varier aussi. Il est impossible de juger dans l'abstrait de l'équité des décisions d'IA. Dans chaque

²⁶⁰ Le droit sur la protection des données ne traite pas l'état de fortune d'une personne comme une catégorie particulière de données (article 9 GDPR).

²⁶¹ Zarsky 2002.

²⁶² Pour un exemple de système commettant davantage d'erreurs dans les minorités, voir Rieke, Robinson et Yu 2014, p. 12. En pareil cas, la décision d'IA pourrait constituer une forme de discrimination indirecte interdite. Voir également Hardt 2014.

²⁶³ Voir Royal Society 2017, p. 99.

secteur, dans chaque domaine d'application, un même argument prend un poids différent²⁶⁴. Et dans chaque secteur s'appliquent des principes normatifs et juridiques différents. Par exemple, le droit à un procès équitable et la présomption d'innocence sont importants en droit pénal. En revanche, la liberté contractuelle est un principe important dans les transactions commerciales avec les consommateurs. Les nouvelles règles envisagées doivent donc couvrir des secteurs spécifiques.

Le besoin de nouvelles normes pourrait être évalué comme suit. Dans chaque secteur, il conviendrait de répondre à plusieurs questions :

- (i) quelles règles s'appliquent dans ce secteur, avec quelle logique sous-jacente ? Une règle peut par exemple viser à protéger un droit de l'homme, exprimer un principe de droit (comme l'égalité, la liberté contractuelle, ou le droit à un procès équitable). Les impératifs économiques diffèrent aussi d'un secteur à l'autre : la mutualisation des risques est importante dans l'assurance, mais pas dans la plupart des autres secteurs. La justification sous-jacente des règles varie donc selon le secteur.
- (ii) Comment est ou pourrait être utilisée la prise de décision automatisée dans le secteur concerné, et moyennant quels risques ? Un faux positif constitue un grave problème dans le système pénal : il peut conduire à l'interrogation, à l'arrestation, voire à la punition d'une personne. Nous ne devrions pas accepter un mode de décision d'IA qui porte atteinte aux valeurs fondamentales du droit pénal. En revanche, si une erreur d'IA fait payer davantage un consommateur par différenciation des prix, les conséquences sont souvent moins graves que celles de l'erreur de décision d'IA entraînant une arrestation.

²⁶⁴ Schauer 2003. Voir également Wachter et Mittelstadt 2018, p. 83.

- (iii) Au vu de la logique sous-jacente des règles applicables au secteur concerné, faudrait-il revoir la réglementation pour tenir compte des décisions d'IA ? L'IA menace-t-elle les principes fondamentaux et les buts de la loi ? Si les textes en vigueur ne couvrent pas des risques importants, des modifications seraient à envisager.

En conclusion, les décisions d'IA pourraient appeler de nouvelles règles de protection de la justice et des droits de l'homme, comme le droit à la non-discrimination. Mais des recherches et des débats doivent encore être consacrés à la question de savoir si des règles sont nécessaires, et lesquelles.

Recherche empirique et technique

Une bonne politique se fonde sur une bonne information. Il est clair qu'il faudrait en savoir davantage sur la discrimination provoquée par l'IA, et donc intensifier la recherche dans ce domaine²⁶⁵. Les États membres du Conseil de l'Europe devraient encourager la recherche des organes de surveillance du respect des droits de l'homme, des organismes de promotion de l'égalité et des universités. Il faudrait par exemple procéder à de nouvelles recherches empiriques. On ne distingue pas clairement à quelle échelle il est recouru aux décisions automatisées. Les décisions algorithmiques conduisent-elles fréquemment à des discriminations (sur la base de l'origine raciale, par exemple) et à d'autres formes de discrimination injustifiée ?

Il faudrait aussi consacrer davantage de recherche en informatique aux solutions. Comment pourrait, par exemple, être conçu un système d'IA qui respecte et promeuve les droits de l'homme, la justice et la transparence ? Est-il possible de vérifier que les données d'apprentissage ne vont pas produire de biais discriminatoires²⁶⁶ ? Nous l'avons vu, ces questions constituent un domaine en plein essor dans les sciences

²⁶⁵ Voir Wagner *et al.* 2018, p. 43.

²⁶⁶ Voir Campolo *et al.* 2018, p. 1

informatiques²⁶⁷. D'une manière plus générale, dans les pays qui financent la recherche en IA, une partie des crédits devrait être affectée à la recherche sur les risques d'atteinte à la justice et aux droits de l'homme et sur leur réduction.

Recherche normative et juridique

Un débat public est également nécessaire, de même que des recherches normatives et juridiques. Comment serait-il possible d'imposer plus efficacement le respect de l'interdiction de la discrimination indirecte ? Comment la loi devrait-elle aborder la différenciation injustifiée qui échappe encore aux textes d'interdiction de la discrimination ? Comment définir la notion de justice selon le secteur ? Comment la loi — et la technologie — devraient-elles assurer la protection contre les aspects intersectionnels²⁶⁸ et structurels de la discrimination²⁶⁹ ? La loi devrait-elle protéger la confidentialité de certaines formes de « renseignements collectifs », et comment²⁷⁰ ? Comment sauvegarder l'État de droit dans les décisions d'IA qui affectent des personnes²⁷¹ ? Certaines décisions ne devraient-elles jamais être laissées à un ordinateur, et lesquelles ? Comment le droit relatif à la protection des données pourrait-il être utilisé dans la pratique pour lutter contre la discrimination ? Faut-il fixer de nouvelles règles, ou suffirait-il d'ajuster les textes existants sur la discrimination et la protection des données ? Quels seraient les ajustements nécessaires ? Quelles seraient les nouvelles règles nécessaires ?

²⁶⁷ <https://www.fatml.org>, consulté le 2 octobre 2018.

²⁶⁸ Sur la discrimination intersectionnelle, voir Crenshaw 1989 ; Fredman 2016. Voir également ECRI Recommandation de politique générale n° 14 sur la lutte contre le racisme et la discrimination raciale dans le monde du travail, adoptée le 22 juin 2012, CRI(2012)48, <https://rm.coe.int/ecri-general-policy-recommendation-no-14-on-combating-racism-and-racial/16808b5afc> (consulté le 14 octobre 2018).

²⁶⁹ Sur la discrimination structurelle, voir le paragraphe 20 de l'exposé des motifs de la Recommandation de politique générale n° 2 (2018) de l'ECRI.

²⁷⁰ Voir Bygrave 2002, chapitre 9-16 ; Taylor, Van der Sloot, et Floridi 2017 ; Vedder 1997.

²⁷¹ Hildebrandt 2015 ; Bayamlioglu et Leenes 2018.lo

VII. CONCLUSION

En conclusion, l'IA offre des possibilités nombreuses et précieuses pour améliorer nos sociétés. Mais ses décisions présentent aussi des risques : souvent opaques, elles peuvent avoir des effets discriminatoires — par exemple lorsque l'apprentissage du système se fonde sur des données reflétant des décisions humaines biaisées.

Les organisations publiques et privées peuvent recourir à des décisions d'IA lourdes de conséquences pour des personnes. Les entités publiques peuvent le faire à des fins de « police prédictive » ou pour recommander une peine, ou encore pour accorder ou refuser le versement de pensions de retraite, d'aides au logement ou d'allocations de chômage. Le privé peut aussi le faire d'une façon qui affecte gravement des personnes, comme en matière d'emploi, de logement ou de crédit. De plus, l'accumulation d'un grand nombre de décisions de moindre importance peut avoir des effets considérables. Une annonce publicitaire ciblée est rarement un problème majeur en soi, mais la publicité ciblée prise dans son ensemble peut exclure certains groupes. Et la différenciation des prix par l'IA pourrait faire que certains groupes paient systématiquement des prix supérieurs.

Les principaux instruments juridiques permettant de réduire les risques de discrimination par l'IA sont la réglementation anti-discrimination et la réglementation relative à la protection des données. Convenablement appliquées, toutes deux pourraient contribuer à la lutte contre la discrimination illicite. Les États membres du Conseil de l'Europe, les organes de contrôle du respect des droits de l'homme (comme la Commission européenne contre le racisme et l'intolérance) et les organismes de promotion de l'égalité devraient travailler à ce que le respect des normes actuelles de lutte contre la discrimination soit mieux garanti.

Mais l'IA permet aussi d'opérer de nouvelles formes de différenciations injustifiées (ou de discrimination) que n'envisagent pas les textes en vigueur. La plupart des lois anti-

discrimination ne s'appliquent qu'à la discrimination fondée sur des caractéristiques protégées, comme l'origine raciale. Elles ne couvrent pas les organisations qui pratiquent la différenciation sur des catégories nouvelles, non corrélées avec des caractéristiques protégées. Cette différenciation n'en pourrait pas moins être injuste, par exemple lorsqu'elle renforce les inégalités sociales. De nouvelles normes seront très probablement nécessaires pour protéger la justice et les droits de l'homme dans le domaine de l'IA. Mais réglementer l'ensemble de cette dernière ne serait pas une bonne façon de faire, car les utilisations des systèmes d'IA sont trop diverses pour un seul dispositif réglementaire. Il faudra concevoir des règles sectorielles, du fait que les valeurs sous-jacentes et les problèmes varient d'un secteur à l'autre. Des débats et des recherches interdisciplinaires sont encore nécessaires. Si nous faisons aujourd'hui les bons choix, nous pourrions bénéficier de tous les avantages de l'IA, tout en minimisant les risques de discrimination injustifiée.

BIBLIOGRAPHIE

A shared statement of civil rights concerns 2018, 'The use of pretrial risk assessment instruments. A shared statement of civil rights concerns', signed by 119 civil rights organisations in the US' (2018)

<http://civilrightsdocs.info/pdf/criminal-justice/Pretrial-Risk-Assessment-Full.pdf> accessed on 4 October 2018.

Allen A, 'The 'three black teenagers' search shows it is society, not Google, that is racist', 10 June 2016, The Guardian,

<https://www.theguardian.com/commentisfree/2016/jun/10/three-black-teenagers-google-racist-tweet> accessed 1 October 2018.

Alpaydin E, Machine learning: the new AI (MIT Press 2016).

Ananny M and Crawford K, 'Seeing without knowing: Limitations of the transparency ideal and its application to algorithmic accountability' (2018) 20(3) New Media & Society 973.

Angelopoulos, C. et al. 'Study of fundamental rights limitations for online enforcement through self-regulation, report IViR Institute for Information Law, University of Amsterdam' (2016)

<https://www.ivir.nl/publicaties/download/1796> accessed 1 October 2018.

Angwin J, Scheiber N and Tobin A, 'Dozens of companies are using Facebook to exclude older workers from job ads', ProPublica, December 2017 <https://www.propublica.org/article/facebook-ads-age-discrimination-targeting> accessed 19 September 2018.

Angwin J, Tobin A and Varner M, 'Facebook (still) letting housing advertisers exclude users by race', ProPublica, November 2017

<https://www.propublica.org/article/facebook-advertising-discrimination-housing-race-sex-national-origin> accessed 19 September 2018.

Angwin J et al., 'Machine bias: There's software used across the country to predict future criminals. And it's biased against blacks'. ProPublica, May 23, 2016 <https://www.ProPublica.org/article/machine-bias-risk-assessments-in-criminal-sentencing> accessed 19 September 2018.

Angwin J, Mattu S and Larson J, 'The tiger mom tax: Asians are nearly twice as likely to get a higher price from Princeton Review' (2015) ProPublica.

<https://www.ProPublica.org/article/asians-nearly-twice-as-likely-to-get-higher-price-from-princeton-review>.

Article 29 Working Party, 'Opinion 4/2004 on the Processing of Personal Data by means of Video Surveillance' (WP 89), 11 February 2004.

Article 29 Working Party, 'Guidelines on Data Protection Impact Assessment (DPIA) and determining whether processing is "likely to result in a high risk" for the purposes of Regulation 2016/679' (WP 248 rev.01), Brussels, 4 October 2017.

Article 29 Working Party, 'Opinion 2/2017 on data processing at work' (WP249), 8 June 2017.

Article 29 Working Party, 'Guidelines on Automated individual decision-making and Profiling for the purposes of Regulation 2016/679' (WP251rev.01), 6 February 2018.

Atrey S, 'The intersectional case of poverty in discrimination law' (2018) 18(3) Human Rights Law Review 411.

Avraham R, 'Discrimination and Insurance' in Lippert-Rasmussen, Kasper (ed), *The Routledge handbook of the ethics of discrimination* (Routledge 2017).

Bagli, CV, 'Facebook vowed to end discriminatory housing ads. Suit says it didn't', *New York Times* 27 March 2018, <https://www.nytimes.com/2018/03/27/nyregion/facebook-housing-ads-discrimination-lawsuit.html> accessed 14 October 2018.

Baldwin R, Cave M and Lodge M, *Understanding regulation: Theory, strategy, and practice* (2nd edition) (Oxford University Press 2011).

Bambauer JR and Zarsky T, 'The algorithm game', 7 March 2018, *Notre Dame Law Review* (2018 Forthcoming) <https://ssrn.com/abstract=3135949> accessed 12 October 2018.

Barocas S and Selbst AD, 'Big Data's disparate impact' (2016) 104 *Calif Law Rev* 671.

Bayamlioğlu E and Leenes R, 'The "rule of law" implications of data-driven decision-making: a techno-regulatory perspective' (2018) DOI: 10.1080/17579961.2018.1527475 *Law, Innovation and Technology*.

BBC News, 'Google apologises for Photos app's racist blunder', 1 July 2015, <https://www.bbc.com/news/technology-33347866> accessed 1 October 2018.

Belgian Data Protection Authority, 'Victory for the authority in Facebook proceeding', 16 February 2018, <https://www.dataprotectionauthority.be/news/victory-privacy-commission-facebook-proceeding> accessed 2 October 2018.

Binns R, 'Data protection impact assessments: A meta-regulatory approach' (2017) 7(1) *International Data Privacy Law* 22.

Binns et al., 'It's reducing a human being to a percentage'; Perceptions of justice in algorithmic decisions', *CHI 2018*, April 21–26, 2018, Montréal, QC, Canada, <https://dl.acm.org/citation.cfm?id=3173951> accessed 1 October 2018.

Bodo B et al., 'Tackling the algorithmic control crisis-the technical, legal, and ethical challenges of research into algorithmic agents' (2017) 19 *Yale JL & Tech*. 133.

Broeders D, Schrijvers E and Hirsch Ballin E, 'Big data and security policies: serving security, protecting freedom, WRR-Policy Brief 6, Netherlands Scientific Council for Government Policy (WRR)' (2017) <https://www.wrr.nl/binaries/wrr/documenten/policy-briefs/2017/01/31/big-data-and-security-policies-serving-security-protecting->

[freedom/WRR_PB6_BigDataAndSecurityPolicies.pdf](#) accessed 1 October 2018, p. 24-25.

Bryson J, 'Three very different sources of bias in AI, and how to fix them', *Adventures in NI*, 13 July 2017, <https://joanna-bryson.blogspot.com/2017/07/three-very-different-sources-of-bias-in.html>, accessed 11 October 2018.

boyd dm and Crawford K, 'Critical questions for big data: Provocations for a cultural, technological, and scholarly phenomenon' (2012) 15(5) *Information, Communication & Society* 662.

Brown I and Marsden CT, *Regulating code: Good governance and better regulation in the information age* (MIT Press 2013).

Buolamwini J and Gebu T, 'Gender shades: Intersectional accuracy disparities in commercial gender classification' (Conference on Fairness, Accountability and Transparency 2018) 77.

Burrell J, 'How the machine 'thinks': understanding opacity in machine learning algorithms', *Big Data & Society* (2016) 3(1). p. 1-12.

Bygrave LA, 'Minding the machine: Article 15 of the EC Data Protection Directive and automated profiling' (2001) 17 *Computer Law & Security Report* 17.

Bygrave LA, *Data protection law: approaching its rationale, logic and limits* (Information Law Series, Kluwer Law International 2002).

Cabañas JG, Cuevas Á and Cuevas R, 'Facebook use of sensitive data for advertising in Europe' (2018) arXiv preprint arXiv:1802.05030.

Caliskan A, Bryson JJ and Narayanan A, 'Semantics derived automatically from language corpora contain human-like biases' (2017) 356(6334) *Science* 183.

Campolo A et al, 'AI Now 2017 Report' (2017) https://ainowinstitute.org/AI_Now_2017_Report.pdf accessed 1 October 2018.

Chouldechova A, 'Fair prediction with disparate impact: A study of bias in recidivism prediction instruments' (2017) 5 *Big Data* 153 <http://dx.doi.org/10.1089/big.2016.0047> accessed 10 October 2018.

Citron DK, 'Technological due process' (2007) 85 *Wash.UL Rev.* 1249.

Cobbe J, 'Administrative Law and the machines of government: Judicial review of automated public-sector decision-making' (2018) Presented at the Microsoft Cloud Computing Research Centre 2018 Symposium, University of Cambridge. Available on SSRN https://papers.ssrn.com/sol3/papers.cfm?abstract_id=3226913 accessed 4 October 2018.

Collins H and Khaitan T, 'Indirect discrimination law: Controversies and critical questions' in Collins, H. and T. Khaitan (eds), *Foundations of Indirect Discrimination Law* (Hart Publishing 2018).

Council of Europe Big Data Guidelines 2017: Consultative Committee of the Convention for the Protection of Individuals with regard to Automatic Processing of Personal Data. 'Guidelines on the protection of individuals with regard to the processing of personal data in a world of Big Data', Strasbourg, 23 January 2017, T-PD(2017)01, <https://rm.coe.int/16806ebe7a> accessed 1 October 2018.

Council of Europe MSI-AUT 2018, Council of Europe Committee of experts on Human Rights Dimensions of automated data processing and different forms of artificial intelligence, [https://www.coe.int/en/web/freedom-expression/msi-aut#{"32639232":0}](https://www.coe.int/en/web/freedom-expression/msi-aut#{) accessed 30 September 2018.

Council of Europe Police and Personal Data Guide 2018, Consultative Committee of the Convention for the Protection of Individuals with regard to Automatic Processing of Personal Data, 'Practical guide on the use of personal data in the police sector', T-PD(2018)01, 15 February 2018.

Council of Europe, Profiling recommendation 2010, 'Recommendation CM/Rec(2010)13 of the Committee of Ministers to member states on the protection of individuals with regard to automatic processing of personal data in the context of profiling' (Adopted by the Committee of Ministers on 23 November 2010 at the 1099th meeting of the Ministers' Deputies).

Crawford K, 'Think again: Big data', Foreign Policy 10 May 2013 <https://foreignpolicy.com/2013/05/10/think-again-big-data/> accessed on 10 October 2018.

Crenshaw K, 'Demarginalizing the intersection of race and sex: A black feminist critique of antidiscrimination doctrine, feminist theory and antiracist politics' (1989) U.Chi.Legal F. 139.

Custers B, The power of knowledge, Ethical, legal, and technological aspects of data mining and group profiling in epidemiology (Wolf Legal Publishers 2004).

Custers B; Calders T; Schermer BW; Zarsky TZ, Discrimination and Privacy in the Information Society (Springer 2013).

Dalenberg DJ, 'Preventing discrimination in the automated targeting of job advertisements' (2018) 34(3) Computer Law & Security Review 615.

Danna A and Gandy Jr OH, 'All that glitters is not gold: Digging beneath the surface of data mining' (2002) 40(4) J Bus Ethics 373.

Dastin J, 'Amazon scraps secret AI recruiting tool that showed bias against women', 10 October 2018. Reuters, <https://www.reuters.com/article/us-amazon-com-jobs-automation-in...-ai-recruiting-tool-that-showed-bias-against-women-idUSKCN1MK08G> accessed 10 October 2018.

Datta A, Tschantz MC and Datta A, 'Automated experiments on ad privacy settings' (2015) 2015(1) Proceedings on Privacy Enhancing Technologies 92.

Datta A et al., 'Discrimination in online advertising: A multidisciplinary inquiry' (Conference on Fairness, Accountability and Transparency 2018) 20.

De Hert P and Gutwirth S, 'Regulating profiling in a democratic constitutional state' in Hildebrandt M and Gutwirth S (eds), *Profiling the European Citizen* (Springer 2008).

De Schutter O and Ringelheim J, 'Ethnic profiling: A rising challenge for European human rights law' (2008) 71(3) *The Modern Law Review* 358.

Dieterich W, Mendoza C and Brennan T, 'COMPAS risk scales: Demonstrating accuracy equity and predictive parity' (2016) Northpoint Inc.

Diaz C and Gürses S, 'Understanding the landscape of privacy technologies' (2012) www.cosic.esat.kuleuven.be/publications/article-2215.pdf accessed 10 October 2018.

Domingos P, *The master algorithm: How the quest for the ultimate learning machine will remake our world* (Basic Books 2015).

Dommering E, 'Regulating technology: code is not law', in Dommering E and Ascher L, *Coding regulation: Essays on the normative role of information technology 1*, Asser Press.

Dourish P, 'Algorithms and their others: Algorithmic culture in context' (2016) 3(2) *Big Data & Society*.

Dutch Association of Insurers, 'Grip op data: green paper Big Data' ['Understanding data: green paper Big Data'] <https://www.verzekeraars.nl/media/1489/grip-op-data-green-paper-big-data.pdf> accessed on 2 October 2018.

Dutch Data Protection Authority 2017, 'Dutch data protection authority: Facebook violates privacy law', 16 May 2017, <https://autoriteitpersoonsgegevens.nl/en/news/dutch-data-protection-authority-facebook-violates-privacy-law> accessed 1 October 2018.

Dutch Data Protection Authority 2017a, 'Informal English translation of the conclusions of the Dutch Data Protection Authority in its final report of findings about its investigation into the processing of personal data by the Facebook group, 23 February 2017', https://autoriteitpersoonsgegevens.nl/sites/default/files/atoms/files/conclusies_facebook_february_23_2017.pdf accessed 1 October 2018.

Duhigg C, 'How companies learn your secrets', *New York Times*, 16 February 2012 < <https://www.nytimes.com/2012/02/19/magazine/shopping-habits.html> accessed 10 October 2018.

Dwork C et al., 'Fairness through awareness' (Proceedings of the 3rd Innovations in Theoretical Computer Science Conference ACM, 2012) 214.

ECRI general policy recommendation no. 2 (2018): Equality Bodies to combat racism and intolerance at national level, 7 December 2017, Strasbourg, CRI (2018)06 <https://rm.coe.int/ecri-general-policy-/16808b5a23> accessed 14 October 2018.

ECRI Statute Resolution 2002: Council of Europe Committee of Ministers, Resolution Res(2002)8 on the statute of the European Commission against

Racism and Intolerance,
https://search.coe.int/cm/Pages/result_details.aspx?ObjectId=09000016805e255a accessed 1 October 2018.

Edwards L and Veale M, 'Slave to the algorithm: Why a right to an explanation is probably not the remedy you are looking for' (2017) 16 Duke L. & Tech.Rev. 18.

Edwards L and Veale M, 'Enslaving the algorithm: from a "right to an explanation" to a "right to better decisions"?'. IEEE Security & Privacy, 2018, 16(3), 46-54.

Ellis E and Watson P, EU anti-discrimination law (OUP Oxford 2012).

European Agency for Fundamental Rights, Handbook on European data protection law (2018 edition) (Publications Office of the European Union 2018).

European Commission, Communication from the Commission to the European Parliament, the European Council, the Council, the European Economic and Social Committee and the Committee of the Regions, Brussels, 25.4.2018 COM(2018) 237 final, {Swd(2018) 137 Final}
<https://ec.europa.eu/digital-single-market/news-redirect/624220> accessed 26 September 2018.

European Consumer Organisation BEUC. 'Automated decision making and artificial intelligence - a consumer perspective, BEUC position paper, by Schmon C.' (June 2018) https://www.beuc.eu/publications/beuc-x-2018-058_automated_decision_making_and_artificial_intelligence.pdf accessed on 1 October 2018.

European Data Protection Supervisor, 'Privacy and competitiveness in the age of big data: The interplay between data protection, competition law and consumer protection in the Digital Economy', March 2014,
https://edps.europa.eu/sites/edp/files/publication/14-03-26_competition_law_big_data_en.pdf accessed 26 September 2018.

European Data Protection Supervisor. 'EDPS Opinion on coherent enforcement of fundamental rights in the age of big data (Opinion 8/2016)' (23 September 2016)
https://secure.edps.europa.eu/EDPSWEB/webdav/site/mySite/shared/Documents/EDPS/Events/16-09-23_BigData_opinion_EN.pdf accessed 24 September 2018.

Equivant, COMPAS Classification, 2018,
<http://www.equivant.com/solutions/inmate-classification> accessed 19 September 2018.

European Group on Ethics in Science and New Technologies, 'Statement on Artificial Intelligence, Robotics and 'Autonomous' Systems', March 2018,
https://ec.europa.eu/research/ege/pdf/ege_ai_statement_2018.pdf accessed 26 September 2018.

Ezrahi A and Stucke ME, Virtual Competition (Harvard 2016)

Federal Trade Commission. 'Big data: A tool for inclusion or exclusion? Understanding the issues' (January 2016) <https://www.ftc.gov/system/files/documents/reports/big-data-tool-inclusion-or-exclusion-understanding-issues/160106big-data-rpt.pdf> accessed on 14 October 2018.

Feller A et al., 'A computer program used for bail and sentencing decisions was labeled biased against blacks. It's actually not that clear' (2016) The Washington Post.

Ferguson AG, *The Rise of Big Data Policing: Surveillance, Race, and the Future of Law Enforcement* (NYU Press 2017).

Ferraris V et al., 'Defining Profiling' (Profiling Project working paper 2013) <http://dx.doi.org/10.2139/ssrn.2366564> accessed 3 October 2018.

Frawley WJ, Piatetsky-Shapiro G and Matheus CJ, 'Knowledge discovery in databases: An overview' (1992) 13(3) *AI magazine* 57.

Fiesler C, 'Tech ethics curricula: A collection of syllabi', <https://medium.com/@cfiesler/tech-ethics-curricula-a-collection-of-syllabi-3eedfb76be18> accessed 29 September 2018.

Financial Conduct Authority. 'Feedback statement: call for inputs on Big Data in retail general insurance' (September 2016) www.fca.org.uk/sites/default/files/fs16-05-big-data-retail-general-insurance.pdf accessed on 23 December 2016.

Fink K, 'Opening the government's black boxes: freedom of information and algorithmic accountability' (2018) 21(10) *Information, Communication & Society* 1453.

Fortune, 'Here Are the Fortune 500's 10 Most Valuable Companies', <http://fortune.com/2018/05/21/fortune-500-most-valuable-companies-2018/> accessed 24 September 2018.

Fredman S. 'Intersectional discrimination in EU gender equality and non-discrimination law, European network of legal experts in gender equality and non-discrimination' (Report for European Commission, Directorate-General for Justice and Consumers), May 2016 <https://publications.europa.eu/en/publication-detail/-/publication/d73a9221-b7c3-40f6-8414-8a48a2157a2f/language-en> accessed on 9 October 2018.

Friedman B and Nissenbaum H, 'Bias in computer systems' (1996) 14(3) *ACM Transactions on Information Systems (TOIS)* 330.

Frucci A, 'HP Face-Tracking Webcams Don't Recognize Black People', *Gizmodo* 21 December 2009, <https://gizmodo.com/5431190/hp-face-tracking-webcams-dont-recognize-black-people> accessed 1 October 2018.

Gama J et al., 'A Survey on concept drift adaptation' (2014) 46 *ACM Comput. Surv.* 44.

Gandy OH, *The Panopticon Sort: A Political Economy of Personal Information* (Westview 1993).

Gellert, R, De Vries, K, De Hert, P, and Gutwirth, S, 'A comparative analysis of anti-discrimination and data protection legislations', in *Discrimination and privacy in the information society* (pp. 61-89). Springer, Berlin, Heidelberg 2013.

Gerards JH, 'Discrimination grounds', in M. Bell and D. Schiek (eds.), *Ius commune case books for a common law of Europe – Non-discrimination* (Hart 2007), p. 33-184.

Goodman B, 'Discrimination, data sanitisation and auditing in the European Union's General Data Protection Regulation' (2016) 2 *Eur.Data Prot.L.Rev.* 493.

Goodman B and Flaxman S, 'European Union regulations on algorithmic decision-making and a "right to explanation"' (2016) arXiv preprint arXiv:1606.08813.

Graef I, *EU Competition Law, Data Protection and online platforms: Data as essential facility* (Kluwer Law International 2016).

Graef I, 'Algorithms and fairness: What role for competition law in targeting price discrimination towards end consumers?' (2017) <https://ssrn.com/abstract=3090360> accessed 26 September 2018.

Greene D, Hoffman AL, Stark L, 'Better, nicer, clearer, fairer: A critical assessment of the movement for ethical artificial intelligence and machine learning', <http://dmgreene.net/wp-content/uploads/2018/09/Greene-Hoffman-Stark-Better-Nicer-Clearer-Fairer-HICSS-Final-Submission.pdf> 2018, accessed 26 September 2018.

Greenleaf G, 'Global tables of data privacy laws and bills (5th Ed 2017)'. 145 *Privacy Laws & Business International Report*, 14-26, <https://ssrn.com/abstract=2992986> accessed 8 September 2018.

Guidotti R and others, 'A survey of methods for explaining black box models' (2018) 51(5) *ACM Computing Surveys (CSUR)* 93.

Gürses S and Van Hoboken J, 'Privacy after the agile turn' (2017) *Cambridge Handbook of Consumer Privacy*. Cambridge University Press, Cambridge, <https://osf.io/ufdvb/> accessed 1 October 2018.

Hacker P, 'Teaching fairness to artificial intelligence: Existing and novel strategies against algorithmic discrimination under EU law' (2018) 55 *Common Market Law Review*, Issue 4, pp. 1143–1185.

Han J, Pei J and Kamber M, *Data mining: concepts and techniques* (Elsevier 2011).

Harcourt BE, *Against prediction: Profiling, policing, and punishing in an actuarial age* (University of Chicago Press 2008).

Hardt M, 'How big data is unfair. Understanding sources of unfairness in data driven decision making' (2014) <https://medium.com/@mrtz/how-big-data-is-unfair-9aa544d739de> accessed on 2 October 2018.

Helberger N., Zuiderveen Borgesius F.J. and Reyna A., 'The perfect match? A closer look at the relationship between EU consumer law and data protection law', *Common Market Law Review*, 2017-54, p. 1427-1466.

Hildebrandt M, 'Defining profiling: a new type of knowledge?' in Hildebrandt M and Gutwirth S (eds), *Profiling the European citizen* (Springer 2008).

Hildebrandt M, *Criminal Law and Technology in a Data-Driven Society*, in: M Dubber and T Hörnle, *The Oxford Handbook of Criminal Law*, Oxford University Press 2014, p. 174-197.

Hildebrandt, M, *Smart technologies and the end (s) of law: Novel entanglements of law and technology*, Edward Elgar Publishing 2015.

Hildebrandt M and Gutwirth S (eds), *Profiling the European Citizen* (Springer 2008).

Hirsch DD, 'The law and policy of online privacy: Regulation, self-regulation, or co-regulation' (2010) 34 *Seattle UL Rev.* 439.

Jablonowska A et al., 'Consumer law and artificial intelligence: challenges to the EU consumer law and policy stemming from the business' use of artificial intelligence: final report of the ARTSY project' (2018) http://cadmus.eui.eu/bitstream/handle/1814/57484/WP_2018_01.pdf?sequence=1&isAllowed=y accessed 26 September 2018.

Jernigan C and Mistree BF, 'Gaydar: Facebook friendships expose sexual orientation' (2009) 14(10) *First Monday*.

Jordan M, 'Artificial intelligence-The revolution hasn't happened yet' (April 2018) <https://medium.com/@mijordan3/artificial-intelligence-the-revolution-hasnt-happened-yet-5e1d5812e1e7> accessed 1 August 2018.

Kay M, Matuszek C and Munson SA, 'Unequal representation and gender stereotypes in image search results for occupations' (Proceedings of the 33rd Annual ACM Conference on Human Factors in Computing Systems ACM, 2015) 3819.

Kaminski M 2018, 'The right to explanation, explained' (2018). <https://osf.io/preprints/lawarxiv/rgeus/> accessed 2 October 2018.

Kaminski M 2018a, 'Binary governance: A two-part approach to accountable algorithms' (2018). 92 *S. Calif. L. Rev* (forthcoming 2019).

Kamiran F and Calders T, 'Classifying without discriminating', 2009 2nd International Conference on Computer, Control and Communication. (17-18, February 2009): 1–6. doi:10.1109/IC4.2009.4909197

Kamiran F and Calders T, 'Data preprocessing techniques for classification without discrimination' (2012) 33(1) *Knowledge and Information Systems* 1.

Khaitan T, *A theory of discrimination law* (OUP Oxford 2015).

Kilbertus N. et al., 'Blind justice: Fairness with encrypted sensitive attributes' (2018) Proceedings of the 35th International Conference on Machine Learning (ICML 2018).

Kim PT, 'Data-driven discrimination at work' (2016) 58 Wm.& Mary L.Rev. 857.

Kloza D, Van Dijk N, Gellert R, Maurice, Borocz I, Tanas A, Mantovani E, Quinn P, Data protection impact assessments in the European Union: complementing the new legal framework towards a more robust protection of individuals. d.pia.lab Policy Brief Article 2017, pp. 1-4.
https://cris.vub.be/files/32009890/dpialab_pb2017_1_final.pdf accessed 25 September 2018.

Koene A et al., 'IEEE P70xx, Establishing standards for ethical technology' (2018) Lu Wang (East China Normal University).

Koops BJ, 'Should ICT regulation be technology-neutral?' in Koops, Bert-Jaap et al. (eds), Starting Points for ICT Regulation - Deconstructing Prevalent Policy One-liners (Information Technology and Law Series, Asser 2006). <https://ssrn.com/abstract=918746> accessed 10 October 2018.

Koops BJ, 'Some reflections on profiling, power shifts, and protection paradigms' in Hildebrandt M and Gutwirth S (eds), Profiling the European citizen: cross-disciplinary perspectives (Springer 2008).

Korff D, 'Comments on Selected Topics in the Draft EU Data Protection Regulation' (17 September 2012) <http://ssrn.com/abstract=2150145> accessed 25 September 2018.

Kroll JA et al., 'Accountable algorithms' (2016) 165 University of Pennsylvania Law Review 633-705.

Lammerant H, de Hert P and Blok P, 'Big data en gelijke behandeling (Big data and equal treatment)' in Blok, P (ed), Big data & het recht (Sdu Uitgeverij) 2017,
https://cris.vub.be/files/35864071/pdh17_hlpb_big_data_en_gelijke_behandeling_H6_Blok.pdf accessed 15 October 2018.

Lippert-Rasmussen K, Born free and equal? A philosophical inquiry into the nature of discrimination (Oxford University Press 2014).

Kusner MJ et al., 'Counterfactual fairness' (Advances in Neural Information Processing Systems 2017) 4066.

Larson J et al., 'These are the job ads you can't see on Facebook if you're older', The New York Times, 19 December 2017.

Larson J et al., 'How we analyzed the COMPAS recidivism algorithm' ProPublica, May 2016 <https://www.ProPublica.org/article/how-we-analyzed-the-compas-recidivism-algorithm> accessed 1 August 2018.

Larson J, Mattu S and Angwin J, 'Unintended consequences of geographic targeting', Technology Science 2015.

Laskov P and Lippmann R, 'Machine learning in adversarial environments' (2010) 81 Machine Learning 115

Lehr D and Ohm P, 'Playing with the data: What legal scholars should learn about machine learning' (2017) 51 UCDC Rev. 653, p, 671.

Lipton ZC, 'From AI to ML to AI: On swirling nomenclature & slurred thought' (5 June 2018) <http://approximatelycorrect.com/2018/06/05/ai-ml-ai-swirling-nomenclature-slurred-thought/> accessed 1 August 2018.

Lowry S and Macpherson G, 'A blot on the profession' (1988) 296(6623) Br Med J (Clin Res Ed) 657.

Lum K and Isaac W, 'To predict and serve?' (2016) 13(5) Significance 14.

Lyon D, 'Surveillance as social sorting: computer codes and mobile bodies' in Lyon, D. (ed), Surveillance as social sorting: privacy, risk and automated discrimination (Routledge 2002).

Malgieri G, 'Trade secrets v personal data: a possible solution for balancing rights' (2016) 6 International Data Privacy Law 2, 103.

Malgieri G, 'Right to explanation and algorithm legibility in the EU Member States legislations', 17 August 2018, <https://ssrn.com/abstract=3233611> accessed 10 October 2018.

Malgieri G and Comandé G 2017, 'Why a right to legibility of automated decision-making exists in the general data protection regulation' (2017) International Data Privacy Law.

Malgieri G and Comandé G 2017a, 'Sensitive-by-distance: quasi-health data in the algorithmic era' (2017) 26(3) Information & Communications Technology Law 229.

Mantelero A, 'Artificial Intelligence and data protection: Challenges and possible remedies', draft report for the Council of Europe's Consultative Committee of the Convention for the Protection of Individuals with regard to Automatic Processing of Personal Data, 17 September 2018, T-PD(2018)09Rev <https://rm.coe.int/report-on-artificial-intelligence-artificial-intelligence-and-data-pro/16808d78c9> accessed 30 September 2018.

Mantelero A, 'AI and Big Data: A blueprint for a human rights, social and ethical impact assessment' (2018) 34(4) Computer Law & Security Review 754.

Mattioli, D, 'On Orbitz, Mac users steered to pricier hotels', Wall Street Journal, 23 August 2012.

McCarthy J et al., 'A proposal for the Dartmouth summer research project on artificial intelligence, august 31, 1955, <http://www-formal.stanford.edu/jmc/history/dartmouth/dartmouth.html> accessed 1 October 2018.

McCray LE, Oye KA and Petersen AC, 'Planned adaptation in risk regulation: An initial survey of US environmental, health, and safety regulation' (2010) 77 Technological Forecasting and Social Change 951

Mendoza I and Bygrave LA, 'The right not to be subject to automated decisions based on profiling' (2017).

Miller T, 'Explanation in artificial intelligence: insights from the social sciences' (2017) arXiv preprint arXiv:1706.07269.

Mittelstadt BD et al., 'The ethics of algorithms: Mapping the debate' (2016) 3(2) *Big Data & Society* 2053951716679679.

Munoz C, Smith M and Patil DJ, 'Big data: A report on algorithmic systems, opportunity, and civil rights' (White House, Executive Office of the President) 2016
https://obamawhitehouse.archives.gov/sites/default/files/microsites/ostp/2016_0504_data_discrimination.pdf accessed 1 October 2018.

Narayanan A, 'Language necessarily contains human biases, and so will machines trained on language corpora', *Freedom to Tinker* 24 August 2016, <https://freedom-to-tinker.com/2016/08/24/language-necessarily-contains-human-biases-and-so-will-machines-trained-on-language-corpora/> accessed 29 September 2018.

Naudts, L, 'Fair or unfair algorithmic differentiation? Luck Egalitarianism As a Lens for Evaluating Algorithmic Decision-Making', 18 August 2017, <https://ssrn.com/abstract=3043707> accessed 2 October 2018.

Nemitz, P, 'Constitutional democracy and technology in the age of artificial intelligence', *Phil. Trans. R. Soc. A* 376.2133 (2018): 20180089, <http://rsta.royalsocietypublishing.org/content/376/2133/20180089> accessed 16 October 2018.

Noble SU, *Algorithms of Oppression: How search engines reinforce racism* (NYU Press 2018).

O'Neil C, *Weapons of math destruction: How big data increases inequality and threatens democracy* (Crown Publishing Group (NY) 2016).

Oswald M, 'Algorithm-assisted decision-making in the public sector: framing the Issues using administrative law rules governing discretionary power' (2018) 376 *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences* 20170359.

Oswald M and Grace J, 'Intelligence, Policing and the Use of Algorithmic Analysis: A Freedom of Information-Based Study' (2016) 1 *Journal of Information Rights, Policy and Practice*.

Parasuraman R and Manzey DH, 'Complacency and bias in human use of automation: An attentional integration' (2010) 52(3) *Hum Factors* 381.

Pasquale F, *The black box society: The secret algorithms that control money and information* (Harvard University Press 2015).

Pasquale F, 'Toward a fourth law of robotics: Preserving attribution, responsibility, and explainability in an algorithmic society', 14 July 2017, *Ohio State Law Journal*, Vol. 78, 2017; <https://ssrn.com/abstract=3002546> accessed 1 October 2018.

Paul A, Jolley C, and Anthony A. 'Reflecting the past, shaping the future: Making AI work for international development (report United States Agency for International Development)' (2018) <https://www.usaid.gov/sites/default/files/documents/15396/AI-ML-in-Development.pdf> accessed 1 October 2018.

Peck D, 'They're watching you at work', The Atlantic, December 2013, <https://www.theatlantic.com/magazine/archive/2013/12/theyre-watching-you-at-work/354681/> accessed 1 October 2018.

Pedreschi D, Ruggieri S, Turini F, 'Discrimination-aware data mining' (2008) ACM Int. Conf. on Knowledge Discovery and Data Mining (KDD 2008) 560–568:

Peña Gangadharan S and Niklas J, 'Between antidiscrimination and data: understanding human rights discourse on automated discrimination in Europe' (2018).

Peppet SR, 'Regulating the Internet of Things: first steps toward managing discrimination, privacy, security, and consent' (2014) 93 Texas Law Review 85.

Perry WL et al., 'Predictive policing: The role of crime forecasting in law enforcement operations' (2013) https://www.rand.org/content/dam/rand/pubs/research_reports/RR200/RR233/RAND_RR233.pdf accessed on 29 September 2017.

Poole DL, Mackworth AK and Goebel R, Computational intelligence: a logical approach (Oxford University Press New York 1998).

Prates M, Avelar P and Lamb L, 'Assessing gender bias in machine translation - A case study with Google translate' 2018 <https://arxiv.org/abs/1809.02208> accessed 11 September 2018, p. 1.

Puppe F, Systematic introduction to expert systems: Knowledge representations and problem-solving methods (Springer Science & Business Media 1993).

Raab C and Szekeley I, 'Data protection authorities and information technology' (2017) 33(4) Computer Law & Security Review 421.

Regan J, 'New Zealand passport robot tells applicant of Asian descent to open eyes', Reuters 7 December 2016, <https://www.reuters.com/article/us-china-tencent/tencent-announces-a-restructuring-as-challenges-rise-idUSKCN1MA04T> accessed 1 October 2018.

Reisman D, Schultz J, Crawford K, and Whittaker M, 'Algorithmic impact assessments: A practical framework for public agency accountability' (AI Now Institute 2018).

Rieke A, Bogen M and Robinson DG, 'Public scrutiny of automated decisions: Early lessons and emerging methods, Upturn and Omidyar Network' (2018) http://www.omidyar.com/sites/default/files/file_archive/Public%20Scrutiny%20of%20Automated%20Decisions.pdf accessed on 3 October 2018.

Rieke A, Robinson DG and Yu H, 'Civil rights, big data, and our algorithmic future: A September 2014 report on social justice and technology (Version 1.2), Washington, DC: Upturn, PDF version, <https://bigdata.fairness.io> accessed 1 October 2018.

Ringelheim J and De Schutter O, 'The processing of racial and ethnic data in antidiscrimination policies: Reconciling the promotion of equality with privacy rights' (2009) Brussels, Bruylant.

Robinson, D. and L. Koepke. 'Stuck in a pattern' (2016) https://www.upturn.org/static/reports/2016/stuck-in-a-pattern/files/Upturn_-_Stuck_In_a_Pattern_v.1.01.pdf accessed on 4 October 2018.

Royal Society (UK). 'Machine learning: the power and promise of computers that learn by example' (April 2017) <https://royalsociety.org/~media/policy/projects/machine-learning/publications/machine-learning-report.pdf> accessed 1 May 2017.

Russell SJ and Norvig P, Artificial intelligence: a modern approach (third edition) (Prentice Hall 2016).

Sandvig C et al., 'Auditing algorithms: Research methods for detecting discrimination on internet platforms' (2014) Data and discrimination: converting critical concerns into productive inquiry 1.

Selbst AD, 'Disparate impact in Big Data policing' (2017) 52 Ga.L.Rev. 109.

Selbst AD and Powles J, 'Meaningful information and the right to explanation' (2017) 7(4) International Data Privacy Law 233.

Selbst AD and Barocas S, 'The intuitive appeal of explainable machines', 2018, Fordham Law Review, Forthcoming. <https://ssrn.com/abstract=3126971> accessed 11 October 2018.

Sharp G, 'Nikon camera says asians: people are always blinking', <https://thesocietypages.org/socimages/2009/05/29/nikon-camera-says-asians-are-always-blinking/> 29 May 2009, accessed 1 October 2018.

Schauer FF, Profiles, probabilities, and stereotypes (Harvard University Press 2003).

Schreurs W, Hildebrandt M, Kindt, E, and Vanfleteren M, 'Cogitas, ergo sum. The role of data protection law and non-discrimination law in group profiling in the private sector' in Profiling the European citizen (Springer 2008).

Siegel E, Predictive analytics: The power to predict who will click, buy, lie, or die (John Wiley & Sons 2013).

Sunstein CR, 'Problems with rules' (1995) 83(4) California Law Review 953.

Swedloff R, 'Risk classification's Big Data (r)evolution' (2014) 21 Connecticut Insurance Law Journal 339.

Sweeney L, 'Discrimination in online ad delivery' (2013) 11(3) ACM Queue 10.

Taylor L, 'What is data justice? The case for connecting digital rights and freedoms globally' (2017) 4(2) Big Data & Society

Taylor L, van der Sloot B, Floridi L (eds.), Group privacy: New challenges of data technologies (Springer 2017).

Tene O and Polonetsky J, 'Taming the Golem: Challenges of ethical algorithmic decision-making' (2017) 19 NCJL & Tech. 125.

Tickle AB et al., 'The truth will come to light: Directions and challenges in extracting the knowledge embedded within trained artificial neural networks' (1998) 9(6) IEEE Trans Neural Networks 1057-1067.

Tobler C, Indirect discrimination: a case study into the development of the legal concept of indirect discrimination under EC law, vol 10 (Intersentia 2005).

Turing A, 'Can digital computers think?', 1951, reprinted in Copeland, BJ, The essential Turing (Clarendon Press 2004).

Turow J, The Daily You: How the new advertising industry is defining your identity and your worth (Yale University Press 2011).

Valcke P, Graef I and Clifford D, 'iFairness – Constructing fairness in IT (and other areas of) law through intra-and interdisciplinarity' (2018) 34(4) Computer Law & Security Review 707.

Valentino-Devries, J., Singer-Vine, J., and Soltani, A, 'Websites vary prices, deals based on users' information', Wall Street Journal, 23 December 2012.

Van Brakel R and De Hert P, 'Policing, surveillance and law in a pre-crime society: Understanding the consequences of technology based strategies.' (2011) 20 Technology-led policing 165.

Van Eck, B.M.A., Geautomatiseerde ketenbesluiten and rechtsbescherming: Een onderzoek naar de praktijk van geautomatiseerde ketenbesluiten over een financieel belang in relatie tot rechtsbescherming [Automated administrative chain decisions and legal protection. Research into legal safeguards regarding the practice of automated chain decisions about financial interests] PhD thesis University of Tilburg, https://pure.uvt.nl/portal/files/20399771/Van_Eck_Geautomatiseerde_ketenbesluiten.pdf accessed 26 September 2018.

Van Nooren P, Van Gorp N, Van Eijk N, Fathaigh R, 'Should we regulate digital platforms? A new framework for evaluating policy options', Policy & Internet 2018, 264-301, https://www.ivir.nl/publicaties/download/Policy_and_Internet_2018.pdf accessed 15 October 2018.

Veale M and Binns R., 'Fairer machine learning in the real world: Mitigating discrimination without collecting sensitive data' (2017) 4(2) Big Data & Society.

Veale M, Binns R., and Edwards L. 'Algorithms that remember: Model inversion attacks and data protection law' (2018) 376 Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences 20180083.

Veale M, Van Kleef M and Binns R, 'Fairness and accountability design needs for algorithmic support in high-stakes public sector decision-making'

(2018) Proceedings of the 36rd Annual ACM Conference on Human Factors in Computing Systems (CHI 2018).

Veale M and Edwards L, 'Clarity, surprises, and further questions in the Article 29 Working Party Draft Guidance on automated decision-making and profiling' (2018) 34 Computer Law & Security Review 398.

Vedder, AH, 'Privatization, information technology and privacy: Reconsidering the social responsibilities of private organizations', in Moore G (ed.), Business ethics: Principles and practice, 215–226 (Sunderland: Business Education Publishers 1997).

Vetzo M, Gerards J, and Nehmelman R. Algoritmes en grondrechten [Algorithms and fundamental rights], Utrecht University/Boom Juridisch (2018) https://www.uu.nl/sites/default/files/rebo-montaigne-algoritmes_en_grondrechten.pdf accessed on 12 October 2018.

Wachter S, 'Normative challenges of identification in the Internet of Things: Privacy, profiling, discrimination, and the GDPR', Computer Law & Security Review, Volume 34, Issue 3, June 2018, p. 436-449.

Wachter S and Mittelstadt B, 'A right to reasonable inferences: Re-thinking data protection law in the age of Big Data and AI', September 13, 2018, Columbia Business Law Review, forthcoming, <https://ssrn.com/abstract=3248829> accessed 9 October 2018.

Wachter S, Mittelstadt B and Russell C, 'Counterfactual explanations without opening the black box: automated decisions and the GDPR' (2017) 31(2 Spring 2018) Harvard Journal of Law & Technology 841.

Wachter S, Mittelstadt, B, and Floridi, L, 'Why a right to explanation of automated decision-making does not exist in the general data protection regulation', International Data Privacy Law 2017-2.

Wagner B (2018). Ethics as an Escape from Regulation: From ethics-washing to ethics-shopping? In M. Hildebrandt (Ed.), Being Profiling. Cogitas ergo sum. Amsterdam University Press, draft available at https://www.privacylab.at/wp-content/uploads/2018/07/Ben_Wagner_Ethics-as-an-Escape-from-Regulation_2018_BW9.pdf accessed 24 September 2018.

Wagner B. et al. 'Algorithms and human rights. Study on the human rights dimensions of automated data processing techniques and possible regulatory implications, DGI(2017)12, prepared by the Committee of Experts on internet intermediaries (MSI-NET) for the Council of Europe' (2018) <https://rm.coe.int/algorithms-and-human-rights-en-rev/16807956b5> accessed 12 June 2018.

Wakefield A and Fleming J, 'Responsibilization', The SAGE dictionary of policing (SAGE Publications Ltd 2009).

Wright D, De Hert P (eds.) Privacy Impact Assessment (Springer 2012).

York C, 'Three black teenagers: Is Google Racist? It's not them, it's us', 8 June 2016, https://www.huffingtonpost.co.uk/entry/three-black-teenagers-google-racism_uk_575811f5e4b014b4f2530bb5 accessed 1 October 2018.

Zarsky TZ, 'Mine your own business: making the case for the implications of the data mining of personal information in the forum of public opinion' (2002) 5 Yale Journal of Law and Technology 1.

Zarsky TZ, 'An analytic challenge: discrimination theory in the age of predictive analytics' (2017) 14 ISJLP 11.

Zarsky TZ, 'The trouble with algorithmic decisions - An analytic road map to examine efficiency and fairness in automated and opaque decision making' (2015) Science, Technology & Human Values 0162243915605575.

Žliobaitė I and Custers B, 'Using sensitive personal data may be necessary for avoiding discrimination in data-driven decision models' (2016) 24(2) Artificial Intelligence and Law 183.

Zuiderveen Borgesius 2015, 'Behavioural sciences and the regulation of privacy on the Internet', in A-L Sibony and A. Alemanno (eds.), Nudge and the law - what can EU law learn from behavioural sciences? (Hart Publishing 2015), p. 179-207. <https://ssrn.com/abstract=2513771> accessed 25 September 2018.

Zuiderveen Borgesius 2015a, Improving privacy Protection in the Area of Behavioural Targeting, Kluwer law International. <http://hdl.handle.net/11245/1.434236> accessed 25 September 2018.

Zuiderveen Borgesius FJ and Poort J, 'Online price discrimination and EU data privacy law', Journal of Consumer Policy, 2017, p. 1-20. <https://ssrn.com/abstract=3009188> accessed 25 September 2018.

Zuiderveen Borgesius FJ, Gray J and van Eechoud M, 'Open data, privacy, and Fair Information Principles: Towards a balancing framework' (2015) 30 Berkeley Tech.LJ 2073. <https://ssrn.com/abstract=2695005> accessed 25 September 2018.

Zuiderveen Borgesius FJ, Van Hoboken J, Fahy R, Irion K, Rozendaal M, 'An assessment of the Commission's proposal on privacy and electronic communications', Directorate-General for Internal Policies, Policy Department C: Citizen's Rights and Constitutional Affairs, May 2017. <https://ssrn.com/abstract=2982290> accessed 26 September 2018.

Direction générale de la Démocratie
Conseil de l'Europe
Tél. : +33 (0) 3 90 21 46 62

www.coe.int/democracy/fr

Pierre 007119

FRA

www.coe.int

Le Conseil de l'Europe est la principale organisation de défense des droits de l'homme du continent. Il comprend 47 États membres, dont l'ensemble des membres de l'Union européenne. Tous les États membres du Conseil de l'Europe ont signé la Convention européenne des droits de l'homme, un traité visant à protéger les droits de l'homme, la démocratie et l'État de droit. La Cour européenne des droits de l'homme contrôle la mise en œuvre de la Convention dans les États membres.

COUNCIL OF EUROPE



CONSEIL DE L'EUROPE