

COUNCIL OF EUROPE



CONSEIL DE L'EUROPE

Strasbourg, le 21 octobre 2022

GEC(2022)9

CDADI(2022)21

**COMMISSION POUR L'ÉGALITÉ DE GENRE
(GEC)**

et le

**COMITE DIRECTEUR SUR L'ANTI-DISCRIMINATION, LA DIVERSITE ET
L'INCLUSION**

**Avant-projet d'étude du Conseil de l'Europe sur l'impact de l'intelligence
artificielle, sa capacité à promouvoir l'égalité, notamment l'égalité de genre, et les
risques pour la non-discrimination**

Document établi par

Ivana Bartoletti,

Responsable mondiale de la protection de la vie privée chez Wipro, chercheuse invitée à
l'Oxford Internet Institute de l'université d'Oxford et cofondatrice du réseau Women
Leading in AI Network

et

Raphaële Xenidis, maître de conférences en droit de l'UE, Université d'Édimbourg, faculté
de droit et Marie Curie Fellow, iCourts, Université de Copenhague.

Table des matières

Résumé	4
Introduction : le contexte	5
Section 1.....	8
Présentation du « biais automatisé » : comment les technologies algorithmiques peuvent-elles conduire à la discrimination ?	8
1) Qu'est-ce que l'IA ?.....	8
2) Qu'est-ce que le biais algorithmique ?	9
3) L'impact discriminatoire de l'IA : quelques exemples concrets	13
Le recrutement	13
L'accès aux biens et services, aux banques et aux assurances.....	14
L'évaluation des risques dans le domaine de la sécurité, de la prévention du crime, du maintien de l'ordre et du système judiciaire.....	15
L'accès aux services publics et administratifs.....	16
L'éducation.....	17
Les soins de santé.....	18
Les médias et les moteurs de recherche	18
La violence sexiste en ligne, le discours de haine et le harcèlement :.....	19
Les stéréotypes de genre dans tous les domaines.....	19
4) En quoi la discrimination algorithmique est-elle différente ?.....	19
5) La lutte contre la discrimination algorithmique : les meilleures pratiques et leurs limites	21
6) Questions de représentation et de participation : le manque de diversité et d'inclusion dans le secteur de l'IA.....	26
Section 2.....	28
Le paysage juridique et politique en Europe : forces et faiblesses.....	28
I. La discrimination et l'égalité : les instruments juridiques et politiques et leurs limites	30
1) Les instruments juridiques contraignants du Conseil de l'Europe	30
2) Les instruments politiques pertinents du Conseil de l'Europe	31
3) Un éclairage comparatif : autres dispositions européennes et internationales pertinentes.....	33
4) Les limites et les incertitudes : où se situe la discrimination algorithmique ?	34
II. Le droit relatif à la vie privée et à la protection des données : équité et exactitude	42
III. Les réglementations sectorielles de l'IA : forces et limites de la promotion de l'égalité et de la lutte contre la discrimination	45
Section 3.....	47
La promotion l'égalité dans et par l'utilisation de l'IA : le rôle de l'action positive et des obligations positives	47
I. La révision des règles existantes à la lumière des nouvelles asymétries de pouvoir	48

II. Une obligation de promouvoir l'égalité dans et par l'utilisation de systèmes algorithmiques : le rôle de l'action positive et des obligations positives.....	51
1) Qu'est-ce qu'une action positive ?	52
2) Les obligations positives découlant de la CEDH.....	53
3) La nécessité de recentrer l'action positive.....	54
4) L'utilisation de l'analyse des données pour détecter les discriminations.....	55
5) L'IA comme moyen de rendre des services aux communautés défavorisées et d'améliorer l'accessibilité	55

Résumé

Introduction : le contexte

L'intelligence artificielle (IA), qui est omniprésente, est souvent saluée pour sa capacité à réduire les frictions et à simplifier des processus qui étaient auparavant manuels et fastidieux. Les recherches menées dans ce domaine continuent d'accélérer sa trajectoire scientifique, d'amplifier son emprise géographique et de modifier le mode de vie de chacun d'entre nous.

Dans le domaine des soins de santé, l'automatisation du diagnostic médical pourrait donner à une patiente la possibilité d'utiliser sans rendez-vous des services aussi complexes que le dépistage du cancer du sein et les examens IRM. Le processus permettrait de diagnostiquer les maladies dangereuses en plus grand nombre et à un stade beaucoup plus précoce. Les villes intelligentes peuvent améliorer la gestion du trafic et l'allocation des ressources, et l'analyse de données massives peut optimiser les ressources de notre environnement. L'IA est également de plus en plus utilisée comme outil d'information et de prise de décision dans divers domaines, notamment l'administration et les politiques publiques, le logement et les soins de santé, l'éducation et la justice pénale.

Au cours des dernières années, ces potentialités et les avantages considérables que cette technologie peut apporter aux citoyen-ne-s ont été quelque peu éclipsés par un inconvénient majeur, à savoir l'*algorithmisation*¹ des discriminations et des inégalités existantes. Cet inconvénient apparaît notamment dans ce que les Néerlandais.es ont appelé le « toeslagenaffaire », ou le scandale des allocations familiales, dans lequel des milliers de personnes ont subi les conséquences d'un algorithme d'auto-apprentissage biaisé qui créait des profils de risque dans le but de détecter des fraudes aux allocations familiales. Les victimes de ce cas de profilage algorithmique ont été plongées dans un désarroi et une pauvreté aggravée, au point que l'une d'entre elles a fait une tentative de suicide². Un rapport parlementaire sur le scandale des allocations familiales a relevé plusieurs lacunes graves, notamment des biais institutionnels et la dissimulation ou la déformation, par les autorités, d'informations visant à tromper le parlement sur les faits³.

En 2018, Reuters a rapporté qu'Amazon a essayé d'utiliser l'IA pour mettre au point un système de sélection de CV en utilisant ceux que l'entreprise avait collectés au cours de la décennie précédente⁴. Or ces CV provenaient principalement d'éléments masculins et les conséquences de ce déséquilibre n'avaient pas été sérieusement prises en compte dans le système. Le nouveau système est donc apparu discriminatoire à l'égard des femmes et a dû être abandonné. En 2019, la carte de crédit commercialisée par Apple a été visée par une

¹ L'« algorithmisation » des biais signifie que les inégalités existantes finissent par être codées et perpétuées dans des machines obscures et protégées par la propriété intellectuelle (voir page 10 pour de plus amples explications).

² Melissa Heikkila, Dutch scandal serves as a warning for Europe over risks of using algorithms, Politico, 29 mars 2022, voir : <https://www.politico.eu/article/dutch-scandal-serves-as-a-warning-for-europe-over-risks-of-using-algorithms/> (dernière consultation le 30 août 2022)

³ Voir Tweede Kamer der Staten-Generaal, Parlementaire ondervraging kinderopvangtoeslag (2020): <https://zoek.officielebekendmakingen.nl/kst-35510-1.pdf>.

⁴ Amazon scraps secret AI recruiting tool that showed bias against women, Reuters, 11 October 2018: <https://www.reuters.com/article/us-amazon-com-jobs-automation-insight-idUSKCN1MK08G> (dernière consultation le 25 juillet 2022).

enquête parce que les femmes se voyaient attribuer une limite de crédit plus basse que leurs conjoints masculins qui avaient le même revenu et la même solvabilité⁵.

Ces exemples ne sont ni des scénarios marginaux ni des scénarios extrêmes. Les systèmes algorithmiques sont trop souvent conçus et alimentés par des données et des modèles historiques qui reproduisent des stéréotypes et de fausses hypothèses sur le genre, la race, l'orientation sexuelle, les capacités, la classe sociale, la géographie et d'autres facteurs socioculturels et démographiques. **Il en résulte que l'utilisation des technologies algorithmiques perpétue et amplifie « naturellement » les inégalités sociétales et les stéréotypes nuisibles.**

La prise de conscience des risques de discrimination algorithmique s'est cristallisée autour des discussions sur le « biais », qui est désormais devenu un enjeu public considérable. Une enquête menée en 2022 a montré que plus de 36 % des entreprises « rencontrent des difficultés ou subissent un impact commercial direct en raison d'un biais lié à l'IA dans leurs algorithmes, tels que [...] [l]a perte de revenus, [l]a perte de client.e.s, [l]a perte de salarié.e.s, [i] des frais juridiques occasionnés par une poursuite ou une action en justice [et] [d] l'atteinte à la réputation de la marque/la réaction des médias⁶ ». Les législateurs et les régulateurs du monde entier sont également aux prises avec ces risques et avec les insuffisances de la législation existante pour y faire face. Les questionnaires auxquels ont répondu les représentant.e.s des États parties à la Convention européenne des droits de l'homme (CEDH) aux fins de la présente étude montrent une large sensibilisation aux questions juridiques liées au biais algorithmique⁷. Dans presque tous les États parties, des initiatives politiques ou législatives sont en cours ou des consultations publiques ont lieu à cette fin.

Le Conseil de l'Europe, en particulier sa Commission sur l'égalité de genre (GEC) et le Comité directeur sur l'anti-discrimination, la diversité et l'inclusion (CDADI), ont également entrepris des travaux dans ce domaine. Le Comité ad hoc sur l'intelligence artificielle (CAHAI) a été chargé en 2019-2021 de consulter les parties prenantes et d'examiner la faisabilité et les éléments potentiels d'un cadre juridique pour le développement, la conception et l'application de l'intelligence artificielle, fondée sur les normes du Conseil de l'Europe en matière de droits humains, de démocratie et d'État de droit. Le Comité a publié en 2020 une « Étude de faisabilité pour un cadre juridique relatif à la conception, au développement et à l'application de l'IA, fondé sur les normes du Conseil de l'Europe », ainsi que des « Éléments potentiels d'un cadre juridique sur l'intelligence artificielle, fondés sur les normes du Conseil de l'Europe en matière de droits humains, de démocratie et d'État de droit ». À la suite de ces développements, un nouveau Comité sur l'intelligence artificielle (CAI) a été créé en 2022 et chargé de rédiger une convention-cadre « sur le développement, la conception et l'application de systèmes d'intelligence artificielle, fondée sur les normes du Conseil de l'Europe en matière de droits humains, de démocratie et d'État de droit, et propice à l'innovation⁸ ». Il s'agit d'un instrument réglementaire qui a été adopté par le Conseil de l'Europe et qui a la capacité,

⁵ Alisha Haridasani Gupta, "Are Algorithms Sexist?" *The New York Times* (15 November 2019) available at: <https://www.nytimes.com/2019/11/15/us/apple-card-goldman-sachs.html> (last accessed: 25 juillet 2022).

⁶ Voir DataRobot, "DataRobot's State of AI Bias Report Reveals 81% of Technology Leaders Want Government Regulation of AI Bias" (2022) : <https://www.datarobot.com/newsroom/press/datarobots-state-of-ai-bias-report-reveals-81-of-technology-leaders-want-government-regulation-of-ai-bias/>.

⁷ Voir la section II et l'annexe.

⁸ Voir le mandat du Comité sur l'intelligence artificielle CM(2021)131 : <https://rm.coe.int/cai-terms-of-reference/1680a7b90b>. [en anglais]

appréciable de favoriser une **approche de** l'utilisation de l'IA et des technologies algorithmiques **fondée sur les droits humains** dans et au-delà de la communauté internationale des États parties à la CEDH.

La présente étude a trois objectifs. Premièrement, elle explique comment les biais qui apparaissent dans l'IA et les technologies algorithmiques peuvent entraîner une discrimination. Elle montre que les biais ne sont pas uniquement liés aux données, mais aussi aux fondements humains et sociaux plus larges de ces outils technologiques. Deuxièmement, l'étude examine les moyens qu'ont les décideurs politiques, les législateur·rice·s et les entreprises de faire face aux risques discriminatoires des technologies algorithmiques et évalue quels instruments juridiques existants pourraient être utilisés à cette fin à l'avenir. Elle recense également les lacunes des outils juridiques existants et propose des ajustements réglementaires pour promouvoir l'égalité et empêcher que des éléments de discrimination apparaissent pendant le développement et le déploiement des systèmes algorithmiques. Troisièmement, l'étude examine les conditions sociopolitiques nécessaires pour que les technologies algorithmiques soient utilisées pour promouvoir l'égalité. Elle présente les possibilités de tirer parti de ces technologies en utilisant les voies juridiques de l'action positive et des obligations positives. Enfin, l'étude recommande plusieurs pistes pour que l'utilisation des technologies algorithmiques n'automatise pas les inégalités existantes mais contribue à une société meilleure et plus équitable. Dans l'ensemble, cette étude vise à contribuer aux travaux d'un futur comité d'expert·e·s chargé, sous l'égide de la GEC et du CDADI, de rédiger un éventuel instrument juridique sectoriel spécifique sur l'impact des systèmes d'intelligence artificielle sur l'égalité, notamment l'égalité de genre, et la non-discrimination en 2024 et 2025.

L'étude se concentre principalement sur l'Europe et présente les opportunités et les problèmes que le déploiement des technologies algorithmiques dans la société pose en matière d'égalité et de discrimination. Elle analyse les réponses qui ont été données et qui sont en cours de discussion dans plusieurs pays membres du Conseil de l'Europe ou ayant le statut d'observateur. L'étude s'appuie sur l'étude de Borgesius relative à « la discrimination, l'intelligence artificielle et la prise de décision algorithmique » commandée par le Conseil de l'Europe en 2018, ainsi que sur le corpus de recherche interdisciplinaire sur la discrimination algorithmique et les biais associés à l'IA⁹, qui se développe rapidement. Le document aborde les questions relatives à la discrimination algorithmique pour tous les motifs protégés par l'article 14 de la Convention européenne des droits de l'homme (CEDH), mais en mettant l'accent sur les trois groupes de motifs protégés que sont le genre et le sexe, l'identité de genre et les caractéristiques sexuelles ainsi que la race, l'origine ethnique et nationale, la couleur, la citoyenneté, la religion et la langue. L'étude examine les conséquences nuisibles des biais véhiculés par l'IA dans un large éventail de secteurs publics et privés, mais en mettant l'accent sur l'emploi et l'éducation.

⁹ Voir Frederik Borgesius, *Discrimination, intelligence artificielle et prise de décision algorithmique* (2018) Conseil de l'Europe : <https://rm.coe.int/etude-sur-discrimination-intelligence-artificielle-et-decisions-algori/1680925d84>. [en français]

Section 1

Présentation du « biais automatisé » : comment les technologies algorithmiques peuvent-elles conduire à la discrimination ?

Une note sur la terminologie : Par souci de clarté, le terme « **utilisateur** » d'algorithmes désigne les entreprises, les organismes publics ou toute autre partie prenante qui déploie un algorithme pour soutenir ou automatiser un processus décisionnel. En revanche, les « **utilisateurs finaux** » sont ceux qui sont soumis à des décisions algorithmiques ou soutenues par des algorithmes, par exemple les clients, les candidats à un emploi, les contribuables, etc. Les « **fournisseurs** » de systèmes algorithmiques et d'IA sont ceux qui conçoivent et commercialisent de tels systèmes sans les mettre en œuvre dans des conditions réelles. Parfois, lorsque les systèmes algorithmiques ou d'IA sont développés en interne, le fournisseur et l'utilisateur constituent la même entité.

1) Qu'est-ce que l'IA ?

Aux fins de cette analyse, nous utilisons la **définition large de l'IA** proposée par le comité ad hoc sur l'intelligence artificielle (CAHAI) du Conseil de l'Europe, qui indique que l'IA est un « terme générique » désignant diverses applications informatiques qui s'appuient sur différentes techniques et qui présentent des capacités communément et actuellement associées à l'intelligence humaine¹⁰. Le CAHAI reconnaît que « [c]es techniques peuvent consister en des modèles formels (ou systèmes symboliques) ainsi qu'en des modèles fondés sur des données (systèmes basés sur l'apprentissage) qui reposent généralement sur des approches statistiques, y compris par exemple l'apprentissage supervisé, l'apprentissage non supervisé et l'apprentissage de renforcement » et que « les systèmes d'IA agissent dans le monde réel ou numérique en percevant leur environnement par l'acquisition de données, en analysant certaines données structurées ou non structurées, en raisonnant sur les connaissances récoltées ou en traitant les informations dérivées des données, et sur cette base, décident des meilleures actions à prendre pour atteindre un certain objectif¹¹. » Un autre aspect de la définition est que « [ces systèmes] peuvent également être conçus pour **adapter leur comportement dans le temps en fonction de nouvelles données** et améliorer leurs performances en vue d'atteindre un certain objectif¹². »

Cette définition élargie de l'IA s'explique par le fait qu'à **ce jour, il n'existe pas de définition unique de l'IA acceptée par la communauté scientifique**. Par exemple, la proposition de règlement de l'UE sur l'IA considère que l'IA est « un logiciel développé au moyen d'une ou plusieurs des techniques et approches énumérées à l'annexe I et qui peut, pour un ensemble donné d'objectifs définis par l'homme, générer des résultats tels que des contenus, des prédictions, des recommandations ou des décisions influençant les environnements avec lesquels il interagit¹³ ».

Selon la définition de l'UE, les techniques et les approches permettant de considérer qu'un logiciel est un système d'IA sont les suivantes :

¹⁰ Comité ad hoc sur l'intelligence artificielle, étude de faisabilité CAHAI(2020)23 (Conseil de l'Europe, 2020), [8].

¹¹ Ibid.

¹² Ibid.

¹³ Acte AI de l'UE, Art. 3(1).

- € « Approches d'apprentissage automatique (notamment d'apprentissage supervisé, non supervisé et par renforcement, utilisant une grande variété de méthodes, dont l'apprentissage profond ;
- € Approches fondées sur la logique et les connaissances (notamment la représentation des connaissances, la programmation inductive (logique), les bases de connaissances, les moteurs d'inférence et de déduction, le raisonnement (symbolique) et les systèmes experts) ;
- € Approches statistiques, estimation bayésienne, méthodes de recherche et d'optimisation¹⁴ ».

Cette diversité de techniques relevant de la définition de l'IA comprend les logiciels qui font fonctionner, par exemple, les moteurs de recherche, les systèmes de reconnaissance d'images, la synthèse vocale, les sites web de traduction automatique, les assistants virtuels, les filtres antispams, les programmes d'aide au diagnostic médical, ainsi que des machines telles que les voitures à conduite autonome, les robots et une myriade d'objets relevant de la vaste catégorie de l'internet des objets¹⁵. Dans cette étude, nous estimons qu'il est important de souligner que **le sujet de la réglementation n'est pas l'IA prise isolément, mais plutôt le dispositif sociotechnique plus large** constitué par l'interaction des éléments sociaux avec les technologies algorithmiques.

2) Qu'est-ce que le biais algorithmique ?

Les algorithmes sont capables de traiter un éventail beaucoup plus large de données et de variables pour prendre des décisions, et ce avec une rapidité, voire une fiabilité, qui dépasse de loin les capacités humaines. Qu'il s'agisse des publicités qui nous sont diffusées, des produits qui nous sont proposés ou des résultats qui nous sont présentés après une recherche en ligne, les algorithmes jouent un rôle de plus en plus important dans ces décisions.

Cependant, étant donné qu'ils ne font que présenter les résultats de calculs **définis par des humains** à partir de données qui peuvent être fournies par des humains, des machines ou une combinaison des deux (à un moment donné du processus), les algorithmes reflètent et traitent les biais humains qui sont incorporés lorsqu'ils sont programmés, lorsqu'ils traitent des données et lorsque les humains interagissent avec eux.

Bref, « le [biais algorithmique] *se produit lorsqu'un programme apparemment inoffensif intègre les préjugés de ses créateurs ou des données qui l'alimentent*¹⁶ ». Par conséquent, les femmes (par exemple) peuvent se voir refuser des prêts et du crédit, et l'identification des mots prononcés par des Noirs par les programmes de reconnaissance vocale présentera des taux d'erreur beaucoup plus élevés que pour les Blancs¹⁷.

¹⁴ Voir l'annexe 1 de la réglementation de l'UE relative à l'IA : « Techniques et approches d'intelligence artificielle visées à l'article 3, point 1 ».

¹⁵ Parlement européen, « Intelligence artificielle : définition et utilisation » (2021) voir :

<https://www.europarl.europa.eu/news/fr/headlines/society/20200827STO85804/intelligence-artificielle-definition-et-utilisation>. [en français]

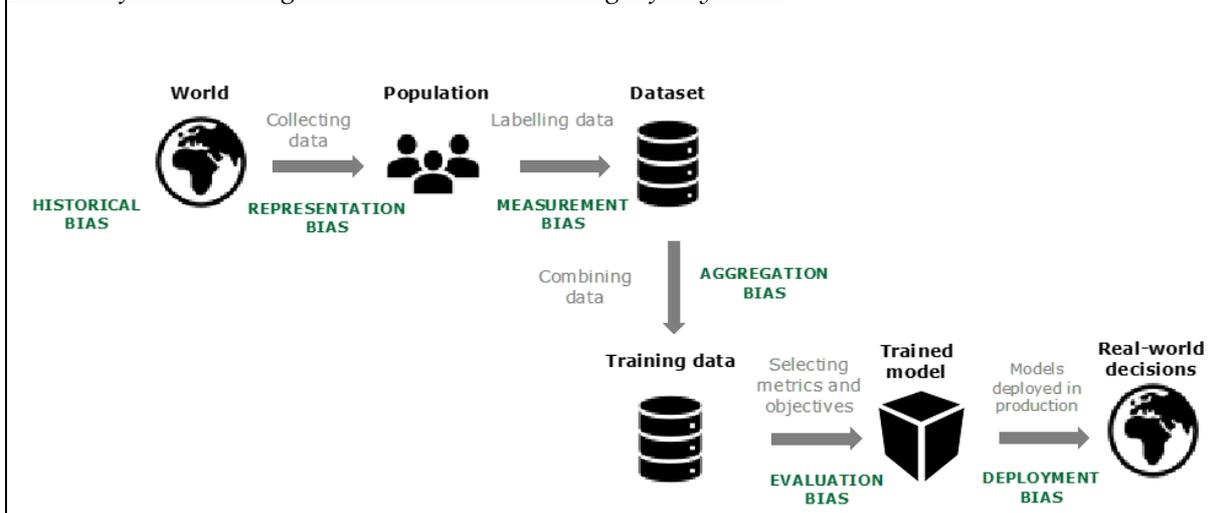
¹⁶ Garcia, Megan. « Racist in the Machine: The Disturbing Implications of Algorithmic Bias ». » *World Policy Journal* 33 (2016): 111 - 117.

¹⁷ Allison Koenecke, et al., PNAS, 23 mars 2020

Comme le précise la notion d'« oppression algorithmique » de Sofiya Noble, le biais n'est pas un « pépin » dans des systèmes par ailleurs impartiaux ; il est au contraire **systémique et propre au fonctionnement des systèmes d'information** qui alimentent les moteurs de recherche et autres applications web¹⁸.

Contrairement à une idée largement répandue, les ensembles de données ne sont pas les seuls relais des biais dans les algorithmes d'apprentissage. En effet, les biais proviennent de différentes sources tout au long du cycle de vie des applications algorithmiques, de leur conception à leur déploiement et à leur utilisation. **La complexité de l'émergence et de l'impact des biais est la raison pour laquelle une attention particulière doit être accordée à l'ensemble du cycle de vie de l'IA et des systèmes algorithmiques**¹⁹. Plusieurs taxonomies répertoriant les sources de biais et leur canalisation dans les systèmes et les résultats de l'IA ont été élaborées par les chercheurs. Par exemple, le diagramme ci-dessous, réalisé par Suresh et Guttag, montre les différents points d'entrée du biais, et ce qu'ils impliquent.

Le tableau et les définitions ci-dessous ont été empruntés à l'ouvrage « A Framework for Understanding Sources of Harm throughout the Machine Learning Life Cycle²⁰ »



Monde Biais historique	Population Collecter les données Biais de représentation	Ensemble de données Étiqueter les données Biais de mesure	Combiner les données Biais d'agrégation	Données de formation Sélectionner des critères et des objectifs Biais d'évaluation	Décisions concrètes Modèles déployés en production Biais de déploiement
---------------------------	--	---	--	--	---

Les chercheurs distinguent cinq sources et types de biais dans les systèmes d'IA. Premièrement, ce qu'ils dénomment le « **biais historique** » décrit comment les hiérarchies sociales et les désavantages institutionnalisés façonnent les données sociales²¹. Les données ne

¹⁸ Voir Safiya Noble, *Algorithms of Oppression: How Search Engines Reinforce Racism* (New York: New York University Press, 2018) ; Vanessa Ceia, Benji Nothwehr, et Liz Wagner, *Gender and Technology: A rights-based and intersectional analysis of key trends* (Oxfam Research Backgrounder, 2021), 40.

¹⁹ Ivana Bartoletti, *The Complex Issue of Algorithmic Fairness*, The Yuan, septembre 2021 : <https://www.the-yuan.com/129/The-Complex-Issue-of-Fairness-in-AI-Part-I.html> (dernière consultation le 28 juillet 2022)

²⁰ Harini Suresh et John Guttag. 2021. *A Framework for Understanding Sources of Harm throughout the Machine Learning Life Cycle*. Actes de la Conférence ACM sur l'équité et l'accès dans les algorithmes, les mécanismes et en Optimisation (EAAMO'21). ACM, New York, NY, USA, 9 pages : <https://doi.org/10.1145/3465416.3483305>.

²¹ Voir *ibid.*

sont donc pas neutres car elles sont le reflet de la société inégalitaire dans laquelle nous vivons. Les femmes, par exemple, qui gagnent généralement moins que les hommes, peuvent se voir désavantagées en ce qui concerne l'octroi d'un crédit²² ou, dans le contexte de la publicité, se voir proposer des annonces avec des postes moins bien rémunérés²³.

Le « **biais de représentation** », quant à lui, apparaît dans la collecte des données²⁴. Si, par exemple, l'équipe de marketing d'une organisation fait de la publicité dans des quartiers à prédominance blanche, la base de clients qui en résulte ne sera pas représentative de l'ensemble de la population. Cet ensemble de données introduirait un biais s'il était utilisé par la suite pour créer un algorithme visant à analyser des groupes de population plus larges.

Les chercheurs ont également mis en lumière le « **biais de mesure** », qui « survient lors du choix, de la collecte ou du calcul des caractéristiques et des étiquettes à utiliser dans un problème de prédiction²⁵ ». De nombreuses caractéristiques et étiquettes ne posent pas de problème, comme l'étiquetage d'une image identifiant un chat ou un chien, mais des problèmes peuvent apparaître lorsque certains facteurs sont utilisés comme substituts. Le code postal, par exemple, peut être un indicateur de la race ou de l'orientation sexuelle, et la profession peut être un indicateur de genre. Par ailleurs, si le substitut simplifie excessivement la caractéristique à mesurer ou reflète des variations dans la qualité des mesures entre les groupes, un biais de mesure peut apparaître²⁶.

Le « **biais d'agrégation** » se rapporte à la façon dont les données sont combinées. Il se produit lorsque des groupes de données combinés de manière inappropriée produisent un modèle qui n'est performant pour aucun groupe ou qui ne l'est que pour le groupe majoritaire²⁷. Les chercheurs mentionnent l'exemple des significations locales attribuées par des communautés spécifiques aux émojis, hashtags et phrases sur les réseaux sociaux, qui diffèrent des significations qui leur sont attribuées dans la population plus large des utilisateurs de ces réseaux²⁸. Cet écart pourrait conduire, par exemple, les modérateurs de contenus à appliquer à des groupes minoritaires des filtres sémantiques inadéquats modélisés sur les groupes majoritaires, ce qui aurait pour effet de les réduire au silence et donc de restreindre injustement leur capacité à communiquer sur les réseaux sociaux.

Les chercheurs considèrent également qu'il existe un « **biais d'évaluation** », qui se produit lors de l'évaluation d'un modèle, si les données de référence (utilisées pour comparer le modèle à d'autres modèles qui effectuent des tâches similaires) ne représentent pas la

²² Apple's 'sexist' credit card investigated by US regulator, BBC, 11 novembre 2019:

<https://www.bbc.com/news/business-50365609> (dernier accès : 15 June 2022).

²³ Samuel Gibbs, Women less likely to be shown ads for high-paid jobs on Google, study shows, The Guardian, 8 juillet 2015 : <https://www.theguardian.com/technology/2015/jul/08/women-less-likely-ads-high-paid-jobs-google-study> (dernier accès : 15 juin 2022).

²⁴ Actes de la Conférence ACM sur l'équité et l'accès dans les algorithmes, les mécanismes et en optimisation (EAAMO'21). ACM, New York, NY (États-Unis d'Amérique), 9 pages : <https://doi.org/10.1145/3465416.3483305>.

²⁵ Ibid.

²⁶ Ibid.

²⁷ Ibid.

²⁸ Ibid, citant une étude de Desmond U. Patton, William R. Frey, Kyle A. McGregor, Fei-Tzin Lee, Kathleen McKeown et Emanuel Moss. 2020. Contextual Analysis of Social Media: The Promise and Challenge of Eliciting Context in Social Media Posts with Natural Language Processing. Actes de la conférence AAAI/ACM sur l'IA, l'éthique et la société (New York, NY, États-Unis) (AIES '20). Association for Computing Machinery, New York, NY, USA, 337-342. <https://doi.org/10.1145/3375627.3375841>.

population que le modèle analysera²⁹. Par exemple, l'auteur de l'article « Gender Shades » a découvert que deux ensembles de données de référence largement utilisés pour l'analyse faciale (IJB-A et Adience) étaient principalement composés de sujets à la peau claire (79,6 % et 86,2 %, respectivement)³⁰.

Enfin, le « **biais de déploiement** » concerne l'utilisation de modèles dans le monde réel, en particulier lorsqu'un modèle conçu pour résoudre un problème est utilisé pour une autre tâche³¹. Cela peut se produire, par exemple, en raison d'un changement de stratégie marketing. En outre, un modèle fait souvent partie d'un système sociotechnique complexe où l'homme et les machines interagissent. Dans un environnement « réel », d'autres biais peuvent donc être introduits lorsque les humains interprètent les sorties algorithmiques pour les utiliser comme données d'entrée plus loin dans la chaîne de décision prise en charge par les algorithmes³².

Les **biais** dits **d'automatisation et de confirmation** peuvent également renforcer ces biais. Le biais d'automatisation se produit lorsque les êtres humains font davantage confiance aux machines et aux outils technologiques qu'à leur propre jugement ou à celui d'autres êtres humains, qui peut être contradictoire, et ont donc tendance à valider les résultats des algorithmes sans les remettre en question. Dans le contexte des machines prédictives, par exemple, un tel biais peut conduire à des évaluations de risques biaisées qui ne sont pas remises en question par les « humains dans la boucle » [qui coopèrent avec l'IA] et donc à des comportements d'approbation automatique. Le biais de confirmation se produit lorsque des croyances préexistantes influencent le traitement de nouvelles informations, lesquelles sont d'autant mieux prises en compte qu'elles sont cohérentes avec ces croyances ou interprétées en cohérence avec ces croyances. Dans le contexte de l'IA, les stéréotypes de genre pourraient ainsi servir de prisme de renforcement aux décideurs humains lorsqu'ils interprètent des résultats algorithmiques biaisés. Dans une expérience, Green et Chen montrent également que les interprètes humains des évaluations automatisées des risques fournies par un algorithme produisent des « **interactions disparates** », c'est-à-dire que les interprétations d'évaluations des risques algorithmiques similaires sont plus clémentes envers les défenseurs blancs que les défenseurs noirs³³.

D'autres taxonomies de biais ont été proposées. Par exemple, Barocas et Selbst repèrent les moments et les situations clés où le biais est canalisé dans les systèmes d'IA : la **définition des « variables cibles »** (la caractéristique à mesurer ou à prédire par un modèle, par exemple la performance professionnelle) et des « **étiquettes de classe** » (les variations possibles dans

²⁹ Voir Harini Suresh et John Guttag. 2021. A Framework for Understanding Sources of Harm throughout the Machine Learning Life Cycle. Actes de la Conférence ACM sur l'équité et l'accès dans les algorithmes, les mécanismes et en optimisation (EAAMO'21). ACM, New York, NY (États-Unis d'Amérique), 9 pages: <https://doi.org/10.1145/3465416.3483305>.

³⁰ Buolamwini J and Gebru T, *Gender shades: Intersectional accuracy disparities in commercial gender classification* (Conference on Fairness, Accountability and Transparency 2018).

³¹ Voir *ibid.*

³² Harini Suresh et John Guttag. 2021. A Framework for Understanding Sources of Harm throughout the Machine Learning Life Cycle. Actes de la Conférence ACM sur l'équité et l'accès dans les algorithmes, les mécanismes et en optimisation (EAAMO'21). ACM, New York, NY (États-Unis d'Amérique), 9 pages : <https://doi.org/10.1145/3465416.3483305>.

³³ Voir Green B et Chen Y, « Disparate interactions : An algorithm-in-the-loop analysis of fairness in risk assessments » (2019) Actes de la conférence sur l'équité, la responsabilité et la transparence 90.

l'occurrence de la variable cible, par exemple exceptionnelle, très bonne, bonne, insatisfaisante) ; l'utilisation des « **données de formation** » (les biais qui se produisent lors de l'étiquetage et de la collecte des données) ; la « **sélection des caractéristiques** » (les attributs qui doivent être considérés pertinents par un modèle, par exemple le revenu annuel) ; et l'utilisation de « **substituts** » [indicateurs indirects] (lorsque les attributs pertinents correspondent à des groupes protégés, par exemple le revenu annuel et le genre en raison de l'écart de rémunération entre les genres)³⁴.

Ces taxonomies contribuent à démystifier le mythe selon lequel les biais ne sont issus que des données, et montrent le rôle complexe des interactions sociotechniques dans la (re)production de biais discriminatoires.

3) L'impact discriminatoire de l'IA : quelques exemples concrets

Cette section illustre comment les biais peuvent donner lieu à des discriminations dans différents secteurs.

Le recrutement : M. Jeffrey Dastin, journaliste de Reuters, a rapporté en 2018 qu'Amazon avait développé un programme s'appuyant sur l'apprentissage automatique pour repérer les meilleurs CV de candidats. Le programme désavantageait systématiquement le CV des femmes car il reflétait l'écart entre les genres dans la main-d'œuvre recrutée au cours des dix dernières années. La neutralisation de termes comme « femmes » n'a pas permis de corriger le résultat discriminatoire, car le système a été en mesure de déduire l'identité de genre à partir d'autres données³⁵.

Des chercheurs de l'université d'Utrecht se sont associés à une plateforme de recherche d'emploi pour étudier comment l'utilisation d'un langage sexué dans la barre de recherche donne des résultats différents, avec des attributions discriminatoires d'informations sur les offres d'emploi³⁶. Le moteur de recherche a pour effet non seulement de renforcer les stéréotypes sur les professions typiques des hommes et des femmes, mais aussi de causer des préjudices en termes d'allocation et de distribution.

La diffusion ciblée en ligne d'offres d'emploi grâce aux services d'optimisation proposés par des plateformes de réseaux sociaux telles que Facebook renforce également les stéréotypes de genre ainsi que la ségrégation de genre sur le lieu de travail³⁷. Une expérience menée par AlgorithmWatch en 2020 a montré qu'en demandant à Facebook de diffuser des annonces « de manière neutre » (sans cibler un public spécifique), une annonce pour un poste de chauffeur de camion a été présentée à un public composé de 93 % d'hommes et 7 % de

³⁴ Barocas S et Selbst AD, " Big Data's Disparate Impact " (2016) 104 California law review, 677-693.

³⁵ Voir Dastin J, 'Amazon scraps secret AI recruiting tool that showed bias against women' *Reuters* (2018): <https://www.reuters.com/article/us-amazon-com-jobs-automation-insight/amazon-scraps-secret-ai-recruiting-tool-that-showed-bias-against-women-idUSKCN1MK08G> (dernière consultation le 22 juillet 2022).

³⁶ Voir van Es K, Everts D et Muis I, "Gendered language and employment Web sites : How search algorithms can cause allocative harm" (2021) 26 First Monday : <https://journals.uic.edu/ojs/index.php/fm/article/view/11717/10200>.

³⁷ Voir Ali M et autres, « Discrimination through optimization : How Facebook' s Ad delivery can lead to partial outcomes » (2019) 3. Actes de l'ACM sur l'interaction homme-ordinateur 1.

femmes³⁸. À l'inverse, une annonce pour un poste d'éducateur a été diffusée à un public composé de 96 % de femmes et 4 % d'hommes³⁹.

Les systèmes de reconnaissance des visages et d'analyse des émotions intégrant une IA peuvent également donner lieu à une discrimination raciale ou désavantager les candidats handicapés⁴⁰. Cette discrimination s'explique par les taux de performance plus faibles de ces appareils sur les teintes de peau plus foncées, en particulier chez les femmes⁴¹. En outre, les logiciels d'analyse des émotions qui sont formés à partir de sujets neurotypiques pourraient ne pas être en mesure de fonctionner correctement sur des sujets neurodivers. L'analyse des émotions par l'IA étant de plus en plus utilisée dans le secteur du recrutement, par exemple pour analyser les enregistrements vidéo des présentations des candidats, cette différenciation pourrait poser des problèmes d'accessibilité et d'inclusion.

L'accès aux biens et services, aux banques et aux assurances : en Finlande, le tribunal national pour l'égalité et la non-discrimination a conclu à une discrimination multiple directe dans une affaire où le requérant s'était vu refuser un prêt en ligne. Après avoir enquêté sur cette affaire, l'organisme de promotion de l'égalité de traitement (le médiateur chargé de la non-discrimination) a constaté que la société utilisait des modèles statistiques pour évaluer la solvabilité d'un demandeur en fonction de son âge, de son sexe, de sa langue et de son lieu de résidence, sans tenir compte de ses antécédents réels en matière de crédit. Dans cette affaire, le fait que le demandeur soit un homme, qu'il parle finnois et qu'il soit originaire d'une zone rurale a été considéré comme un facteur de désavantage dans l'évaluation effectuée par l'institution financière⁴².

Une histoire similaire a été rapportée en Allemagne, où une cliente s'est vu refuser un crédit lors d'un achat en ligne. En enquêtant sur les raisons du rejet auprès de l'établissement de crédit, la cliente a appris qu'une combinaison de son âge et de son sexe semblait avoir motivé

³⁸ 4 864 hommes, mais seulement 386 femmes. Voir Wulf J, Automated Decision-Making Systems and Discrimination : Understanding causes, recognition cases, supporting those affected (AlgorithmWatch 2022), 7 : https://algorithmwatch.org/en/wp-content/uploads/2022/07/AutoCheck-Guidebook_ADM_Discrimination_EN-AlgorithmWatch_June_2022_b.pdf et Kayser-Bril N, 'Automated Discrimination : Facebook uses gross stereotypes to optimize ad delivery' AlgorithmWatch : <https://algorithmwatch.org/en/automated-discrimination-facebook-google/> (dernière consultation le 22 juillet 2022).

³⁹ Ibid. 6 456 femmes, mais seulement 258 hommes.

⁴⁰ Voir Buolamwini J et Gebru T, Gender Shades: Intersectional Accuracy Disparities in Commercial Gender Classification (Proceedings of Machine Learning Research 2018) ; Hannah Devlin, « AI systems claiming to 'read' emotions pose discrimination risks » (16 février 2020), *The Guardian* : <https://www.theguardian.com/technology/2020/feb/16/ai-systems-claiming-to-read-emotions-pose-discrimination-risks> (dernière consultation le 22 juillet 2022).

⁴¹ Voir Buolamwini J et Gebru T, Gender Shades : Intersectional Accuracy Disparities in Commercial Gender Classification (Proceedings of Machine Learning Research 2018).

⁴² Voir : Lorenz Matzat and Minna Ruckenstein, "Finnish Credit Score Ruling raises Questions about Discrimination and how to avoid it" (21 November 2018) *AlgorithmWatch* : <https://algorithmwatch.org/en/finnish-credit-score-ruling-raises-questions-about-discrimination-and-how-to-avoid-it/> (dernière consultation le 22 juillet 2022); Rainer Hiltunen, "Multiple discrimination in assessing creditworthiness" (1 August 2018), European network of legal experts in gender equality and non-discrimination: <https://www.equalitylaw.eu/downloads/4658-finland-multiple-discrimination-in-assessing-creditworthiness-pdf-120-kb> (dernière consultation le 22 July 2022).

le rejet automatisé, sur la base de stéréotypes intersectionnels préjudiciables selon lesquels les femmes d'environ 40 ans sont souvent divorcées et ont donc moins de pouvoir d'achat⁴³.

Dans le secteur des assurances, une étude menée par les universités de Padoue, d'Udine et de Carnegie Mellon a montré que des facteurs tels que le lieu de naissance et la citoyenneté influencent le prix des polices d'assurance automobile payé par les clients⁴⁴. Dans une étude de cas, les auteurs ont montré que le fait d'indiquer le Ghana comme lieu de naissance d'un demandeur pouvait entraîner une augmentation de prix de 1000 EUR par rapport à un demandeur déclarant qu'il est né en Italie.

Une autre étude d'AlgorithmWatch a montré que la discrimination numérique s'étend bien au-delà de l'IA⁴⁵. Les formulaires en ligne peuvent entraîner une discrimination fondée sur la race, l'origine ethnique ou la nationalité, par exemple lorsqu'ils n'autorisent l'enregistrement que de patronymes contenant trois lettres ou plus. Les intéressés dont le nom est plus court se verront refuser l'inscription ou ne pourront pas ouvrir de compte, ce qui est souvent une condition préalable à l'achat de biens et de services en ligne.

L'évaluation des risques dans le domaine de la sécurité, de la prévention du crime, du maintien de l'ordre et du système judiciaire : en Espagne, le logiciel VioGén a été utilisé pour évaluer les risques de violence sexiste et de féminicide par des partenaires intimes. Malgré une évaluation globalement favorable, les critiques portent sur plusieurs cas de faux négatifs où des évaluations de risque faible ont conduit à la mise en œuvre de moyens de prévention insuffisants ayant débouché sur des conséquences tragiques⁴⁶.

Les Pays-Bas ont déployé plusieurs systèmes prédictifs à des fins de prévention de la criminalité, des systèmes qui ont été sévèrement critiqués car ils ont créé une discrimination fondée sur la race, l'ethnicité et la nationalité. Par exemple, une enquête menée en 2020 par Amnesty International a révélé que le « Sensing Project », qui visait à prévenir localement le vol à l'étalage et le vol à la tire, aboutissait à un profilage ethnique discriminatoire de personnes d'origine est-européenne, et en particulier de membres de la communauté rom⁴⁷. En observant le trafic automobile dans et autour de la zone de déploiement, le système a utilisé l'origine est-européenne des passagers comme facteur de risque prédictif de criminalité. D'autres systèmes d'anticipation de la criminalité, par exemple à Amsterdam, utiliseraient des facteurs tels que « le nombre de foyers monoparentaux », « le nombre de bénéficiaires des prestations sociales » et « le nombre d'immigrants non occidentaux » pour déterminer les « points chauds » de la criminalité dans tout le pays⁴⁸.

⁴³ Voir Wulf J, Automated Decision-Making Systems and Discrimination : Understanding causes, recognition cases, supporting those affected (AlgorithmWatch 2022), 6-7

⁴⁴ L'étude a été citée par AlgorithmWatch, voir ibid.

⁴⁵ Lulamae, Josephine, "Fixing Online Forms Shouldn't Wait Until Retirement", AlgorithmWatch (13 janvier 2022): <https://algorithmwatch.org/en/unding-online-forms/> (dernière consultation le 22 juillet 2022).

⁴⁶ Michele Catanzaro, "In Spain, the VioGén algorithm attempts to forecast gender violence", AlgorithmWatch (27 April 2020) : <https://algorithmwatch.org/en/viogen-algorithm-gender-violence/> ((dernière consultation le 22 juillet 2022).

⁴⁷ Amnesty International « We Sense Trouble: Automated Discrimination and Mass Surveillance in Predictive Policing in the Netherlands » (2020), 5 : <https://www.amnesty.nl/content/uploads/2020/09/Report-Predictive-Policing-RM-7.0-FINAL-TEXT-CK-2.pdf> (dernière consultation le 22 juillet 2022).

⁴⁸ <https://www.vice.com/en/article/5dpmdd/the-netherlands-is-becoming-a-predictive-policing-hot-spot>

Dans les aéroports, les technologies de contrôle de la sécurité et de contrôle aux frontières utilisant des systèmes automatisés de reconnaissance du genre se sont avérées discriminatoires à l'égard des personnes transgenres, intersexes, non binaires et non-conformes, car elles reposent sur un système de classification binaire du genre qui ne rend pas compte de la complexité réelle de l'identité de genre⁴⁹.

La reconnaissance faciale est de plus en plus utilisée pour la détection et la prévention des crimes. Par exemple, les services de répression peuvent l'utiliser pour comparer les photos de suspects aux photos d'identité judiciaire et de permis de conduire. Si « les algorithmes de reconnaissance des visages se targuent d'une grande précision en matière de classification (plus de 90 %) », ces résultats ne sont pas universels⁵⁰. En 2018, le projet Gender Shades a révélé des divergences dans la précision de cette technologie et sa capacité à reconnaître les différentes teintes de peau et les différents sexes. Les algorithmes ont systématiquement démontré que la précision la plus faible concernait les femmes à la peau foncée et que la plus élevée s'appliquait aux hommes à la peau claire⁵¹. Dans un contexte de justice pénale, les technologies de reconnaissance faciale, dont l'exactitude est intrinsèquement biaisée, peuvent mal identifier des suspects et même conduire à l'incarcération de personnes de couleur innocentes, comme cela s'est produit aux États-Unis⁵². Il est donc inquiétant de constater que, même si elle est précise, la reconnaissance faciale donne des moyens importants aux systèmes répressifs qui ont une longue histoire de surveillance raciste et anti-militante et peut aggraver les inégalités préexistantes⁵³ ».

L'accès aux services publics et administratifs : l'utilisation de technologies de reconnaissance faciale dans les services publics ou en association avec eux peut conduire à exclure ou à refuser des prestations aux utilisateurs finaux. Par exemple, un photomaton de l'Office d'État des transports de Hambourg, en Allemagne, n'a pas reconnu le visage d'une requérante aux fins de prendre une photo biométrique, ce qui était nécessaire pour sa demande administrative. Bien que l'office public ait nié que l'échec provenait du logiciel de reconnaissance faciale utilisé, un employé local a indiqué que les échecs ont souvent lieu en relation avec la couleur de peau des candidats⁵⁴.

Aux Pays-Bas, le déploiement du système SyRi (System Risk Indication) utilisé pour détecter les fraudes à l'aide sociale, s'est avéré à l'origine de discriminations fondées sur le revenu et

⁴⁹ Voir JD Shadel, « #TravelingWhileTrans : The trauma of returning to 'normal' » (The Washington Post, 2021) : <https://www.washingtonpost.com/travel/2021/06/16/trans-travel-tsa-lgbtq/> and Quinan, C. L., and Mina Hunt. « Biometric Bordering and Automatic Gender Recognition : Challenging Binary Gender Norms in Everyday Biometric Technologies. "Communication, Culture and Critique 15.2 (2022) : 211-226.

⁵⁰ Alex Najibi, **Racial Discrimination in Face Recognition Technology, Université de Harvard, octobre 2020** : [https://sitn.hms.harvard.edu/flash/2020/racial-discrimination-in-face-recognition-technology/#:~:text=Face recognition algorithms boast high,and 18-30 years old.](https://sitn.hms.harvard.edu/flash/2020/racial-discrimination-in-face-recognition-technology/#:~:text=Face%20recognition%20algorithms%20boast%20high,and%2018-30%20years%20old.)

⁵¹ Gender Shades Project, voir : <http://gendershades.org/overview.html> (dernière consultation le 31 août 2022)

⁵² RACE AND WRONGFUL CONVICTIONS IN THE UNITED STATES; https://www.law.umich.edu/special/exoneration/Documents/Race_and_Wrongful_Convictions.pdf (dernière consultation le 31 août 2022).

⁵³ Alex Najibi, Racial Discrimination in Face Recognition Technology, Harvard University, October 2020.

⁵⁴ Voir Wulf J, Automated Decision-Making Systems and Discrimination : Understanding causes, recognition cases, supporting those affected (AlgorithmWatch 2022), p. 8. Cette hypothèse est corroborée par des études indiquant qu'il existe une discrimination intersectionnelle fondée sur le genre et la couleur de la peau dans les logiciels de reconnaissance faciale, par exemple Buolamwini J et Gebbru T, Gender Shades: Intersectional Accuracy Disparities in Commercial Gender Classification (Proceedings of Machine Learning Research 2018).

l'origine ethnique avant d'être interrompu par une décision de justice en 2020⁵⁵. En 2021, un scandale lié à l'aide sociale a contraint le gouvernement néerlandais à démissionner après que plus de 20 000 parents, considérés par un système d'IA comme étant des fraudeurs aux allocations familiales, ont fait l'objet d'une enquête par les autorités fiscales néerlandaises⁵⁶. Le système AI a traité la double nationalité comme un facteur de risque élevé, ce qui a entraîné un nombre disproportionné d'enquêtes et de procédures judiciaires à l'encontre de familles issues de l'immigration, dont les allocations familiales ont été suspendues et dont certaines ont dû rembourser les prestations perçues⁵⁷. L'affaire montre également comment le manque de responsabilité et de transparence autour de l'utilisation de ces systèmes peut conduire à priver ceux qui subissent des décisions de l'IA d'une explication ou de la possibilité de faire appel de ces décisions.

L'éducation : on sait que les logiciels de reconnaissance faciale peuvent être biaisés et entraîner une discrimination intersectionnelle fondée sur la race et le genre⁵⁸. Utilisés dans des logiciels de surveillance installés dans des établissements d'enseignement, ils peuvent avoir une incidence négative sur les conditions dans lesquelles les étudiants racialisés passent les examens et même leur capacité à le faire. Par exemple, le logiciel de surveillance utilisé par plusieurs universités aux Pays-Bas avait du mal à reconnaître les étudiants à la peau foncée⁵⁹. L'université n'ayant pas pris sa plainte au sérieux, une étudiante soutenue par le Centre Racisme et Technologie a déposé une plainte officielle auprès de l'Institut des droits humains, l'autorité nationale chargée de la non-discrimination dans le pays⁶⁰. Les logiciels de surveillance peuvent également avoir un impact négatif sur les étudiants handicapés, par exemple en créant de l'anxiété, en n'autorisant pas la présence d'un accompagnateur ou en ne permettant pas aux étudiants de faire des pauses en s'éloignant de l'ordinateur⁶¹. Pour les familles à faible revenu qui partagent des chambres en raison du manque d'espace, l'utilisation d'un logiciel de surveillance peut créer un désavantage en signalant un

⁵⁵ Koen Vervloesen, "How Dutch activists got an invasive fraud detection algorithm banned", AlgorithmWatch (6 avril 2020): <https://algorithmwatch.org/en/syri-netherlands-algorithm/> (dernière consultation le 22 juillet 2022).

⁵⁶ Nadia Benaïssahet systeem doet precies wat het wordt opgedragen" (29 janvier 2021) *Bits of Freedom* : <https://www.bitsoffreedom.nl/2021/01/29/het-systeem-doet-precies-wat-het-wordt-opgedragen/>.

⁵⁷ Jon Henley, "Dutch government faces collapse over child benefits scandal" (14 January 2021) *The Guardian*: <https://www.theguardian.com/world/2021/jan/14/dutch-government-faces-collapse-over-child-benefits-scandal> and Björn ten Seldam & Alex Brenninkmeijer, "The Dutch benefits scandal: a cautionary tale for algorithmic enforcement" (30 April 2021) *EU Law Enforcement*: <https://eulawenforcement.com/?p=7941>.

⁵⁸ Buolamwini J and Gebru T, Gender shades: Intersectional accuracy disparities in commercial gender classification (Conference on Fairness, Accountability and Transparency 2018).

⁵⁹ Racism and Technology Centre, "Student stapt naar College voor de Rechten van de Mens vanwege gebruik racistische software door de VU" (15 juillet 2022) : <https://racismandtechnology.center/2022/07/15/student-stapt-naar-college-voor-de-rechten-van-de-mens-vanwege-gebruik-racistische-software-door-de-vu/#more-1691> (dernière consultation le 28 juillet 2022).

⁶⁰ Fleur Damen, "De antispieksoftware herkende haar niet als mens omdat ze zwart is maar bij de vu vond ze geen gehoor" *De Volkskrant* (15 July 2022) : <https://www.volkskrant.nl/nieuws-achtergrond/de-antispieksoftware-herkende-haar-niet-als-mens-omdat-ze-zwart-is-maar-bij-de-vu-vond-ze-geen-gehoor-b6810279/> (dernière consultation le 27 juillet 2022).

Pour la plainte, voir: <https://racismandtechnology.center/2022/07/15/student-stapt-naar-college-voor-de-rechten-van-de-mens-vanwege-gebruik-racistische-software-door-de-vu/#more-1691>

⁶¹ Lydia X. Z. Brown, « How Automated Test Proctoring Software Discriminates Against Disabled Students » (16 novembre 2020), Centre for Democracy and Technology: <https://cdt.org/insights/how-automated-test-proctoring-software-discriminates-against-disabled-students/> (dernière consultation le 28 juillet 2022).

« comportement aberrant » lorsque les membres de la famille sont identifiés en train de passer derrière l'écran⁶².

Les soins de santé : Criado Perez a révélé comment les secteurs de la recherche et des soins de santé s'appuient sur des modèles masculins pour évaluer les risques et l'efficacité des médicaments et finissent par produire des données sur la santé qui sont de moindre qualité pour les femmes et les personnes de genre différent. Ce manque de données sur le genre dans le secteur des soins de santé conduit à des systèmes prédictifs moins fiables lorsqu'il s'agit de diagnostiquer les femmes et les patients de genre différent⁶³. Des études montrent que le manque de données dans le domaine de la santé touche également d'autres groupes minoritaires⁶⁴.

Une étude américaine réalisée par Obermeyer et al. montre comment un système utilisé pour prédire des risques sanitaires aux fins d'allocation de ressources désavantageait systématiquement les patients issus de minorités ethniques. En effet, le système utilisait des données sur l'accès antérieur des groupes aux soins de santé, ce qui a progressivement intégré la discrimination structurelle existante⁶⁵.

Les médias et les moteurs de recherche : des études révèlent que les représentations des femmes dans les images renvoyées par les moteurs de recherche en ligne sont biaisées et reflètent des stéréotypes sexistes, racistes et intersectionnellement discriminatoires. Par exemple, Noble montre dans une expérience avec le moteur de recherche Google comment les images de filles et de femmes noires sont sexualisées⁶⁶. Même si les moteurs de recherche ont essayé de corriger ces biais, une étude récente portant sur les principaux moteurs de recherche indique qu'il existe des « biais de représentation » ainsi que des « biais de face-isme » [proéminence du visage] dans la façon dont les femmes sont représentées, de sorte que « les femmes sont moins susceptibles d'être représentées dans des contenus médiatiques neutres en termes de genre [...] et leur rapport visage/corps dans les images est souvent plus faible » que pour les hommes⁶⁷. Les solutions techniques de « débiaisage » peuvent traiter certains des symptômes du problème, par exemple en rééquilibrant le nombre de photos de femmes dans une recherche d'images de « PDG », mais pas ses racines, en l'occurrence les stéréotypes nuisibles, les préjugés de représentation et d'attribution ainsi que l'inégalité structurelle qui sont profondément ancrés dans notre réalité culturelle et matérielle. Par exemple, des tests récents semblent indiquer que DALLE2, qui est un outil de création d'images reposant sur l'IA et qui est actuellement testé, ajoute des « invites de diversité » à des requêtes non spécifiques, par exemple en ajoutant les étiquettes « noir » ou « femme » à une invite demandant au logiciel de générer une image d'un « PDG⁶⁸ ». Cette approche est

⁶² Ibid.

⁶³ Voir Criado Perez C, *Invisible women : Exposing data bias in a world designed for men* (Random House 2019).

⁶⁴ Ibid.

⁶⁵ Voir Obermeyer Z et autres, 'Dissecting racial bias in an algorithm used to manage the health of populations' (2019) 366 *Science* 447.

⁶⁶ Voir, par exemple, Safiya Noble, *Algorithms of oppression : how search engines reinforce racism* (New York University Press 2018).

⁶⁷ Ulloa R. et al., « Representatitiveness and face-ism : Gender bias in image search » (2022), *New Media & Society*, vol.

⁶⁸ Matthew Sparkes, "AI art tool DALL-E 2 adds 'black' or 'female' to some image prompts" (22 juillet 2022) *New Scientist*, voir : <https://www.newscientist.com/article/2329690-ai-art-tool-dall-e-2-adds-black-or-female-to-some-image-prompts/> (dernière consultation le 28 juillet 2022) ; voir également OpenAI, "Reducing Bias and Improving

analogue à une forme d'action positive comme les quotas. On peut lui reprocher de ne pas s'attaquer au manque de diversité dans les kits de formation, mais s'ils sont utilisés à grande échelle, ces correctifs ont le mérite de diffuser des représentations plus diversifiées qui, à long terme, peuvent contribuer à atténuer les stéréotypes préjudiciables.

La violence sexiste en ligne, le discours de haine et le harcèlement : la discrimination numérique prend également la forme de violences fondées sur le genre, par exemple lorsque des vidéos manipulées (deepfake) sont utilisées pour harceler les femmes dans le contexte dit du « porno de vengeance ». La diffusion non consentie de contenus à caractère sexuel, souvent sous forme d'images, a également été considérée comme une forme de violence fondée sur le genre qui touche particulièrement les femmes et les filles jeunes ou les personnalités publiques telles que les journalistes, les défenseurs des droits de l'homme ou les hommes politiques⁶⁹. En outre, il a été mis en évidence que les discours sexistes et d'autres formes de haine en ligne sont subordonnés à l'utilisation croissante des plateformes de médias sociaux⁷⁰. Dans le même temps, la modération des contenus touche particulièrement les groupes minoritaires, qui risquent d'être réduits au silence⁷¹ tout en faisant l'objet de campagnes de haine.

Les stéréotypes de genre dans tous les domaines : un récent rapport de l'ONU, intitulé « I'd blush if I could : closing gender divides in digital skills through education » (Je rougirais si je pouvais : s'appuyer sur l'éducation pour combler les écarts entre les genres en matière de compétences numériques), a révélé que les assistants numériques intégrant une IA et dotés de voix féminines peuvent renforcer les préjugés sexistes existants. Cette tendance vers les assistants virtuels à voix féminine « semble plutôt associée à la notion d'assistance que le son, le ton, la syntaxe et la cadence⁷² ». Peut-être choisit-on une voix féminine pour séduire l'utilisateur et lui faire croire que l'IA est malléable et inoffensive. Mais, finalement, l'effet produit relève de la « normalisation de cette nouvelle servitude numérique qui a pris place dans nos maisons et nos vies quotidiennes à travers Alexa, Siri et Cortana⁷³ ».

4) En quoi la discrimination algorithmique est-elle différente ?

La discrimination relayée par des technologies algorithmiques présente des **problèmes qui ne sont pas les mêmes** que ceux qui sont posés par la discrimination humaine.

Premièrement, les performances accrues des machines ont des **répercussions beaucoup plus importantes sur la société**. À cet égard, il existe un écart considérable, par exemple, entre un employé de banque qui attribue inconsciemment un taux d'intérêt hypothécaire plus élevé à

Safety in DALL-E 2" (18 juillet 2022) : <https://openai.com/blog/reducing-bias-and-improving-safety-in-dall-e-2/> (dernière consultation le 28 juillet 2022).

⁶⁹ Voir Sara De Vido et Lorena Sosa, Criminalisation of gender-based violence against women in European States, including ICT-facilitated violence (Réseau européen des experts juridiques en matière d'égalité des sexes et de non-discrimination 2021) : <https://www.equalitylaw.eu/downloads/5535-criminalisation-of-gender-based-violence-against-women-in-european-states-including-ict-facilitated-violence-1-97-mb> (dernière consultation le 23 juillet 2022).

⁷⁰ Voir Bartoletti, Ivana. Chapter 3: Algorithms and the Rise of Populism in *An artificial revolution: On power, politics and AI*. Black Spot Books, 2020.

⁷¹ Voir Rachel Griffin, "The Sanitised Platform" (2022) 13 J Intell Prop Info Tech & Elec Com L 36.

⁷² UNESCO, I'd blush if I could: closing gender divides in digital skills through education, 100 : <https://unesdoc.unesco.org/ark:/48223/pf0000367416.page=1>

⁷³ Ivana Bartoletti, *An Artificial Revolution : on Power, Politics and AI* (Indigo Press).

un demandeur issu d'une minorité et un logiciel qui traite des milliers de fichiers par jour et qui peut généraliser ce biais à tout demandeur dont le nom a une consonance africaine.

Deuxièmement, le comportement humain est contrôlé par des mécanismes sociaux et juridiques qui, sans être parfaits, sont néanmoins censés corriger les mauvais comportements à court et à long terme. En revanche, le **déploiement des technologies algorithmiques compromet souvent les principes de responsabilité et de transparence, ainsi que le contrôle des processus décisionnels**. Par exemple, « [d]es décisions humaines erronées peuvent faire l'objet d'un recours, alors que l'opacité de la technologie de l'IA et la réticence des fournisseurs à se prêter à un examen public rendent cela très difficile à réaliser dans les systèmes d'IA⁷⁴ ».

Troisièmement, les **sources de la discrimination algorithmique sont difficiles à détecter**. En raison de la complexité de ces systèmes sociotechniques, le biais peut se produire à n'importe quelle étape du pipeline algorithmique. En outre, les **algorithmes peuvent être brevetés, complexes et difficiles à comprendre**. Parfois, il s'agit en fait d'une boîte noire contenant des procédures qui peuvent être inexplicables pour un chercheur humain. Cette « logicisation » (softwarisation) des biais signifie que les inégalités existantes finissent par être codées et perpétuées dans des machines obscures et protégées par la propriété intellectuelle. Cette situation est extrêmement problématique car les biais deviennent plus difficiles à identifier et à contester.

En résumé, au moins **six problèmes** se posent en matière de discrimination algorithmique fondée sur des données⁷⁵. Les décisions qui sont prises par les machines le sont à une **échelle** beaucoup **plus grande**, mais l'interaction entre les humains et les machines rend les **sources de discrimination difficiles à détecter et à traiter**. Le « nettoyage » **des données biaisées est un problème technique** et un exercice **dépendant du contexte**, et l'existence de substituts et de corrélations avec des groupes protégés complique encore la tâche. Dans le même temps, l'IA et les systèmes algorithmiques sont souvent **opaques** et difficiles à expliquer, et **l'attribution de la responsabilité de la discrimination n'est pas claire**.

Ces biais, qui ne sont pas *in fine* technologiques, ne peuvent pas être corrigés par les seuls moyens technologiques. Au contraire, la lutte contre la discrimination algorithmique et les désavantages résultant de données biaisées exige un degré d'analyse beaucoup plus élevé et **des décisions politiques positives visant à empêcher activement le renforcement des inégalités structurelles ancrées dans les données sociales**. Par exemple, pour éviter d'« automatiser » les stéréotypes de genre et l'écart de rémunération entre les hommes et les femmes, qui ont généralement un salaire inférieur, l'employeur doit prendre consciemment la décision de cibler les femmes lorsqu'il fait de la publicité pour des emplois mieux rémunérés, qui sont généralement des emplois « masculins » ou de gestion en ligne. En effet, le risque de confier leur distribution à des algorithmes d'optimisation risque de reproduire les

⁷⁴ Gabriele Spina Ali & Ronald Yu, Artificial Intelligence between Transparency and Secrecy : From the EC Whitepaper to the AIA and Beyond, European Journal of Law and Technology: <https://www.ejlt.org/index.php/ejlt/article/download/754/1044/3716> (dernière consultation le 16 septembre 2022)

⁷⁵ Voir Gerards J et Xenidis R, *Algorithmic discrimination in Europe : Challenges and Opportunities for EU Gender Equality and Non-Discrimination Law* (Réseau européen d'experts juridiques dans le domaine de l'égalité des genres et de la non-discrimination /Commission européenne, 2021).

stéréotypes de genre et les inégalités salariales⁷⁶. Pour comprendre les biais algorithmiques, il faut commencer par prendre conscience de la façon dont les technologies algorithmiques aggravent, renforcent et perpétuent les inégalités existantes lorsqu'aucune protection n'est mise en place. Pour ces raisons, la **lutte contre la discrimination algorithmique nécessite une approche multiforme englobant diverses disciplines** telles que les sciences sociales, l'éthique et le droit, ainsi que des **domaines réglementaires**, notamment la législation sur la non-discrimination, la protection des consommateurs, la protection des données, le commerce, etc.

5) La lutte contre la discrimination algorithmique : les meilleures pratiques et leurs limites

Pour faire face aux risques discriminatoires que représentent les technologies algorithmiques, le secteur a pris diverses initiatives qui vont des **solutions techniques pour « débiaiser » et « auditer » les systèmes algorithmiques** à l'adoption de **codes de conduite volontaires, d'instruments d'IA éthique** et d'autres formes d'**autorégulation**. Cette section présente quelques **exemples des pratiques de bonne gouvernance** adoptées et évalue leurs **limites**.

Les entreprises ont intensifié les étapes de la gouvernance en prévision de la réglementation à venir, d'autant que les mesures de gouvernance ex ante et ex post gagnent en popularité et en importance. Les grandes entreprises technologiques (souvent elles-mêmes touchées par des controverses sur les biais) ont mis en place des comités d'éthique, intégré la gouvernance de l'IA dans les structures de gouvernance existantes et/ou déployé des techniques de « débiaisage » pour résoudre certains problèmes.

Par exemple, Microsoft a élaboré six principes d'IA pour accélérer ce changement culturel et améliorer la sensibilisation des salariés aux questions éthiques⁷⁷. Il s'agit notamment de l'équité, de la fiabilité et de la sécurité, du respect de la vie privée et de la sécurité, de l'inclusion, de la transparence et de la responsabilité. La gouvernance est constituée de trois équipes centrales chargées de mettre en œuvre les principes fondamentaux, de gérer les politiques, la gouvernance, l'habilitation et l'utilisation sensible, et de diriger la mise en œuvre des processus d'IA responsable dans l'adoption des systèmes et des outils.

IBM a développé et mis en œuvre AI Fairness 360⁷⁸, une boîte à outils open-source utilisée pour examiner, signaler et atténuer la discrimination et les biais dans les modèles d'apprentissage automatisé. Les principaux objectifs de cette boîte à outils sont de faire en sorte que les algorithmes de recherche sur l'équité soient progressivement utilisés dans un cadre industriel et de fournir un cadre commun aux chercheurs sur l'équité qui pourront ainsi partager et évaluer les algorithmes.

Amazon a intégré de nouveaux outils d'aide à la détection des discriminations dans les technologies d'intelligence artificielle et d'apprentissage automatisé. Dans le cadre de l'offre d'informatique en nuage (cloud) Amazon Web Services, un nouveau test a été mis en place ainsi qu'un ensemble plus large d'éléments destinés aux clients qui cherchent à développer

⁷⁶ Voir Ali M et autres, « Discrimination through optimization: How Facebook's Ad delivery can lead to partial outcomes » (2019) 3 Actes de l'ACM sur l'interaction homme-ordinateur 1 et Imana B, Korolova A et Heidemann J, *Audit for discrimination in algorithms delivering job ads* (2021).

⁷⁷ Principes de Microsoft pour une IA responsable : <https://www.microsoft.com/en-us/ai/responsible-ai?activetab=pivot1%3aprimar6> (dernière consultation le 4 octobre 2022).

⁷⁸ IBM, introducing AI Fairness 360: <https://www.ibm.com/blogs/research/2018/09/ai-fairness-360/> (dernière consultation le 4 octobre 2022).

une IA équitable et non biaisée sur la plateforme. Le test a été mis au point par M^{me} Sandra Wachter, M. Brent Mittelstadt et M. Chris Russell de l'Oxford Internet Institute de l'Université d'Oxford. Il s'agit du test dénommé « Disparité démographique conditionnelle », qui est un nouveau test visant à « garantir l'équité dans la modélisation algorithmique et les décisions fondées sur des données⁷⁹ ».

Les développeurs du programme de création d'images « DALLE-2 », fondé sur l'IA, ont mis en œuvre une technique d'atténuation des biais après avoir constaté que les images produites présentaient des défauts de représentation. Tandis que des messages génériques tels que « PDG » et « maçons » génèrent principalement des images d'hommes, des messages génériques tels qu'« hôtesse de l'air » et « infirmière » produisent des images représentant presque exclusivement des femmes⁸⁰. Les développeurs reconnaissent que ces stéréotypes peuvent être nuisibles, par exemple lorsqu'ils portent atteinte à la dignité de groupes protégés, les excluent de situations socialement valorisées et renforcent les représentations mentales de rôles sociaux ségrégués⁸¹. Les images stéréotypées contribuent à leur tour à confirmer les préjugés sociétaux et à alimenter les préjugés en matière d'allocation, en influençant la distribution de biens sociaux essentiels. La technique d'atténuation mise en œuvre par les développeurs de DALLE-2 semble augmenter la diversité des groupes de population représentés dans les images produites. Cette critique a néanmoins été critiquée car elle ne ferait qu'ajouter des termes liés à la diversité, notamment « femmes » ou « noires », aux messages génériques pour augmenter la représentativité. Certains des symptômes du biais algorithmique ont pu ainsi être traités mais par leurs causes profondes⁸².

Bien qu'il s'agisse d'exemples positifs d'efforts de gouvernance existants pour lutter contre la discrimination algorithmique dans le secteur, il est important de souligner leurs limites.

Les limites des solutions techniques : débiaisage et atténuation des biais

Premièrement, les **solutions techniques de débiaisage et d'atténuation des biais** ne peuvent pas résoudre à elles seules le problème de la discrimination algorithmique. À ce sujet, Balayn et Gürses ont souligné avec force que « [l]e biais repose sur des conceptualisations du biais qui ne rendent pas compte de la complexité de la discrimination en raison des limites de la configuration de l'apprentissage automatisé⁸³ ». Le débiaisage ne peut pas corriger la discrimination algorithmique de manière complète ou efficace pour deux raisons principales. D'une part, ces techniques se concentrent exclusivement sur les entrées et les sorties des systèmes d'IA **sans tenir compte du contexte dans lequel ils sont utilisés**⁸⁴. Elles sont

⁷⁹ AI modelling tool developed by Oxford academic incorporated into Amazon anti-bias software, Oxford Internet Institute, 21 April 2021: <https://www.oii.ox.ac.uk/news/releases/ai-modelling-tool-developed-by-oxford-academics-incorporated-into-amazon-anti-bias-software-2/> (dernière consultation le 29 septembre 2022)

⁸⁰ Voir OpenAI, "Reducing Bias and Improving Safety in DALL-E 2" (18 July 2022): <https://openai.com/blog/reducing-bias-and-improving-safety-in-dall-e-2/>.

⁸¹ Voir Pamela Mishkin et al, "DALL-E 2 Preview - Risks and Limitations" (2022) : <https://github.com/openai/dalle-2-preview/blob/main/system-card.md#bias-and-representation>.

⁸² Voir Matthew Sparkes, "AI art tool DALL-E 2 adds 'black' or 'female' to some image prompts", New Scientist (22 July 2022) : <https://www.newscientist.com/article/2329690-ai-art-tool-dall-e-2-adds-black-or-female-to-some-image-prompts/>.

⁸³ Voir Balayn A et Gürses S, Beyond Debiasing : Regulating AI and its inequalities (European Digital Rights 2021), 51 : https://edri.org/wp-content/uploads/2021/09/EDRI_Beyond-Debiasing-Report_Online.pdf.

⁸⁴ Voir *ibid*, 12, 64.

essentiellement centrées sur les algorithmes et **ne tiennent pas compte des points d'interaction entre la machine et l'homme**, qui sont également une source de biais⁸⁵.

D'autre part, les **techniques de débiaisage n'ont pas encore atteint un stade de développement permettant un déploiement généralisé** : « [I]es cas d'utilisation sont limités, les conceptualisations proposées des biais peuvent simplifier à l'excès les questions de discrimination, et l'efficacité et la facilité d'utilisation des méthodes de débiaisage et des outils d'audit restent à établir⁸⁶ ». L'application pratique des techniques de débiaisage pose également un problème en raison des difficultés entourant l'accès aux données sensibles ainsi que des variations contextuelles pouvant survenir en fonction des cas d'utilisation⁸⁷. Par exemple, la loi anti-discrimination peut exiger que différentes conceptions de l'équité interviennent dans différents cas d'utilisation ou à différentes étapes d'un même cas d'utilisation, ce qui est difficile à traduire en termes techniques et à mettre en cohérence.

D'où la **question de savoir ce que signifie être « équitable » pour un algorithme**. Un grand nombre d'études en informatique sont consacrées à l'équité algorithmique. Les approches de l'équité sont parfois présentées comme pouvant garantir la conformité éthique et juridique des systèmes algorithmiques. Pourtant, les **notions de « biais » et d'« équité » sont des notions techniques qui ne se recoupent pas parfaitement avec leurs équivalents éthiques et juridiques**. Dans la législation sur la discrimination, en particulier, l'interdiction des biais sera limitée à ceux qui ciblent ou ont un impact négatif sur les groupes protégés. L'élimination de ces biais à un moment donné du cycle de vie de l'IA pourrait permettre d'atteindre l'équité d'un point de vue technique sans pour autant satisfaire aux obligations légales existantes en matière d'égalité tout au long du cycle en question.

En outre, les informaticiens ont élaboré un **large éventail de définitions de l'équité**, dont certaines sont contradictoires. Dès lors, **en fonction de la définition, un algorithme peut être techniquement équitable sans nécessairement respecter la législation anti-discrimination⁸⁸**. Par exemple, l'équité consiste-t-elle à donner la « même chance » à toutes les personnes en ne tenant pas compte des points de départ extrêmement différents, ou à reconnaître qu'il existe des différences entre les personnes et à donner à certaines un avantage temporaire pour compenser un désavantage⁸⁹ ? D'un point de vue mathématique, il existe plusieurs façons d'obtenir un résultat équitable, qui sont toutes liées à différentes perceptions et interprétations de l'équité elle-même. On pourrait faire valoir, par exemple, que le fait de traiter « comme les autres » une personne issue d'une minorité qui sollicite un prêt est équitable. Or, si la personne en question présente, en raison d'un racisme historique tenace, un risque plus élevé de perdre son emploi et de se retrouver insolvable sans qu'il y ait faute de sa part, l'application de

⁸⁵ Voir *ibid*, 50.

⁸⁶ *Ibid*, 12, 50.

⁸⁷ Voir *ibid*.

⁸⁸ Voir la discussion sur les différentes façons de mesurer les biais et les définitions divergentes de l'équité dans l'exemple du système de prédiction du risque de récidive COMPAS : Angwin, Julia, et al. « Machine bias ». *Ethics of Data and Analytics*. Auerbach Publications, 2016. 254-264 and Jeff Larson, Surya Mattu, Lauren Kirchner and Julia Angwin, « How We Analyzed the COMPAS Recidivism Algorithm » (2016) ProPublica: <https://www.propublica.org/article/how-we-analyzed-the-compas-recidivism-algorithm>.

⁸⁹ Dans l'optique d'une égalité réelle et transformatrice, les mesures spéciales temporaires ou les actions positives fournissent un soutien spécial ou un avantage provisoire à un groupe défavorisé afin de transformer un *statu quo* inégal à long terme. Voir la discussion dans la section 3 de la présente étude.

l'équité comme simple moyen d'égaliser des résultats peut conduire à un renforcement de l'inégalité car cette catégorie de personnes peut voir sa solvabilité continuer de se dégrader.

Les définitions de « l'équité en tant que critère d'exactitude » et les techniques de « débiaisage » visant à acquérir *d'avantage de données* et à concevoir des systèmes algorithmiques *plus* précis présentent également des limites importantes. Si les « **injustices qui influent sur l'exactitude** » en raison de problèmes liés à la représentativité des données, à la collecte des données et aux pratiques de traitement des données peuvent être résolues par des modifications des politiques en matière de données visant à accroître la précision des décisions algorithmiques⁹⁰, les biais découlant d'injustices passées requièrent des solutions différentes. Les « **injustices qui n'influencent pas sur l'exactitude** » donnent lieu à des biais qui ne peuvent pas être corrigés par des améliorations des pratiques de collecte de données⁹¹. Ils expriment des faits qui sont exacts mais problématiques car résultant d'une discrimination et d'une exclusion historiques. **Seules des politiques ciblant les causes profondes et les effets de ces inégalités peuvent remédier à ce type de biais.** Par exemple, si un service du personnel souhaite automatiser le recrutement en prédisant quels candidats seront les plus performants, l'intégration d'un plus grand nombre de données sur les recrutements passés ne permettra pas de s'attaquer aux causes des préjugés sexistes, qui résident dans la ségrégation des sexes sur le marché de l'emploi, les problèmes de plafond de verre, l'écart de rémunération entre les sexes, les stéréotypes de genre, etc.

En raison de ces limites, les récits solutionnistes de débiaisage doivent être démystifiés, d'autant que le **débiaisage ne peut être qu'un élément d'une stratégie antidiscrimination plus large** par rapport aux systèmes algorithmiques. **Une telle stratégie devrait être centrée sur les droits humains et tenir compte de l'ensemble du cycle de déploiement des systèmes de prise de décisions algorithmiques** allant de la formulation du problème à traiter, au contexte de mise en œuvre du système, de ses performances réelles et de son impact pratique. En outre, comme l'ont souligné Balayn et Gürses, les fournisseurs de services d'IA ne devraient pas bénéficier d'une grande latitude dans le choix des stratégies visant à prévenir l'impact discriminatoire de leurs systèmes⁹². Au contraire, le **contrôle démocratique et les garanties réglementaires devraient établir un cadre autour des approches acceptées en matière d'équité et de lutte contre la discrimination, en tenant pleinement compte des limites techniques et de la nécessité de s'attaquer aux causes profondes de la discrimination algorithmique.** La participation des utilisateurs finaux directement touchés par ces systèmes, en particulier des groupes minoritaires, doit également être assurée. À cet égard, nous soulignons dans nos recommandations ci-dessous que cela devrait également s'appliquer aux activités de normalisation.

Les limites des audits de biais : accès aux données et normes divergentes

Deuxièmement, l'**audit de biais** a été présenté comme une autre solution pouvant traiter la discrimination algorithmique. Pourtant, des problèmes se posent en ce qui concerne l'accès aux données et les normes divergentes.

⁹⁰ Hellman, Deborah. "Big Data and Compounding Injustice." *Journal of Moral Philosophy*, à paraître, *Virginia Public Law and Legal Theory Research Paper* 2021-27 (2021).

⁹¹ Ibid.

⁹² Voir *ibid*, 11.

L'audit est « une série d'approches permettant de réexaminer les systèmes de traitement algorithmique ». Ces approches « peuvent prendre différentes formes, notamment la vérification des documents de gouvernance, le test des résultats d'un algorithme, voire l'inspection de son fonctionnement interne⁹³ ». Il a été suggéré que l'audit pourrait être utilisé comme un moyen de prévention contre la mise sur le marché de systèmes algorithmiques discriminatoires⁹⁴. Toutefois, le **manque d'accès aux données sur l'égalité**, les **incertitudes liées au RGDP** sur le traitement autorisé des catégories de données sensibles et l'**absence de normes uniformément acceptées** rendent difficile l'audit des algorithmes de discrimination.

D'une part, les juristes **ne savent pas si le RGPD autorise le traitement de catégories sensibles de données à caractère personnel à des fins de débiaisage** ou, plus largement, à des **fins d'antidiscrimination**⁹⁵. D'autre part, le **manque de données sur l'égalité**, qui découle de pratiques souvent restrictives en matière de collecte de données sur l'égalité en Europe, pose des problèmes lorsqu'il s'agit d'identifier les inégalités dans des domaines spécifiques tels que l'accès au logement, à l'éducation, aux soins de santé, à l'emploi, etc. pour divers groupes de population protégés⁹⁶. Il limite l'accès à des informations précises sur la vérité du terrain et l'ampleur des inégalités structurelles dans la société.

Ce problème d'accès à des données à caractère sensible doit également être considéré dans le contexte plus large de l'**extraction et de l'exploitation des données** par les grandes entreprises technologiques. L'**accès à ces données à des fins d'audit de la discrimination et de l'antidiscrimination en général devrait donc être confié à d'autres entités, notamment des organismes de promotion de l'égalité, les inspections du travail, les OSC ayant un intérêt légitime** au sens des articles 11, 12, 13 et 14 des directives européennes sur l'égalité 2000/43/CE et 2000/78/CE, etc. La mise en place d'une **collecte de données sur l'égalité plus systématique, éthique et réglementée** dans toute l'Europe serait également un progrès à des fins d'audit algorithmique. L'inspiration pourrait venir du Royaume-Uni où le gouvernement a annoncé, au titre de la politique intitulée « Data : a new direction strategy⁹⁷ », qu'une nouvelle condition sera introduite dans le cadre de la loi sur la protection des données (2018) pour autoriser le

⁹³ Digital Regulation Cooperation Forum, "Auditing algorithms : the existing landscape, role of regulators and future outlook" (2022): <https://www.gov.uk/government/publications/findings-from-the-drcf-algorithmic-processing-workstream-spring-2022/auditing-algorithms-the-existing-landscape-role-of-regulators-and-future-outlook>.

⁹⁴ Voir Kim PT, 'Auditing Algorithms for Discrimination' (2017) 166 University of Pennsylvania Law Review Online 189.

⁹⁵ Van Bekkum, Marvin et Zuiderveen Borgesius, Frederik, Using Sensitive Data to Prevent Discrimination by AI : Does the GDPR Need a New Exception ? (2022): <http://dx.doi.org/10.2139/ssrn.4104823> (dernière consultation le 28 juillet 2022).

⁹⁶ Voir Commission européenne, *Analyse et examen comparatif des pratiques de collecte de données sur l'égalité dans l'Union européenne : cadre juridique et pratique dans les États membres de l'UE* (Office des publications, 2017) [en anglais uniquement] : <https://data.europa.eu/doi/10.2838/6934> (dernière consultation le 28 juillet 2022) ; Lilla Farkas, *Analyse et examen comparatif des pratiques de collecte de données sur l'égalité dans l'Union européenne : collecte de données dans le domaine de l'ethnicité* (Office des publications, 2020) [en anglais uniquement] : <https://data.europa.eu/doi/10.2838/447194> (dernière consultation le 28 juillet 2022) ; Ringelheim, Julie, "Processing Data on Racial or Ethnic Origin for Antidiscrimination Policies : How to Reconcile the Promotion of Equality with the Right to Privacy?" (2007) NYU School of Law Jean Monnet Working Paper No. 08/06 : <http://dx.doi.org/10.2139/ssrn.983685> (dernière consultation le 28 juillet 2022).

⁹⁷ Data: a new direction - government response to consultation, 22 June 2022: <https://www.gov.uk/government/consultations/data-a-new-direction/outcome/data-a-new-direction-government-response-to-consultation> (dernière consultation le 28 juillet 2022)

traitement de données de catégorie spéciale pour le suivi et l'atténuation des biais algorithmiques.

En outre, il n'existe pas encore d'obligations légales ni de normes uniformes pour l'audit algorithmique. Diverses méthodologies ont été proposées⁹⁸. Certaines des boîtes à outils développées par les chercheurs ont été adoptées par de grandes entreprises, par exemple l'instrument « Aequitas » conçu par l'Oxford Internet Institute et adopté par Amazon⁹⁹. Néanmoins, l'élaboration de normes réglementaires uniformes pour l'audit algorithmique dans le domaine de la non-discrimination augmenterait considérablement la sécurité juridique pour les fournisseurs. Elle permettrait également de renforcer la confiance du public dans les systèmes algorithmiques. Enfin, des normes réglementaires uniformes en matière d'audit algorithmique inciteraient les entreprises à réaliser des audits sur la discrimination, ce qui permettrait aux victimes potentielles de disposer d'informations utiles pour évaluer l'opportunité d'intenter une action (en justice) et de fournir aux juges des éléments de preuve compréhensibles.

6) Questions de représentation et de participation : le manque de diversité et d'inclusion dans le secteur de l'IA

La sous-représentation des groupes minoritaires dans les communautés professionnelles qui contribuent au développement de l'IA est un aspect important du problème de la discrimination algorithmique. Le manque de diversité et d'inclusion dans ces communautés indique que les groupes sous-représentés ne participent pas (suffisamment) à l'élaboration des technologies algorithmiques qui **ne prennent donc pas suffisamment en compte les besoins de ces groupes, les désavantagent ou les excluent complètement.** Une enquête publiée par le Conseil de l'Europe aux fins de la présente étude montre que **la plupart des États parties à la CEDH qui ont répondu sont conscients de la question de la diversité** dans le secteur de l'IA. Les États parties soulignent la **nécessité d'orienter davantage de femmes vers les disciplines STIM** (science, technologie, ingénierie et mathématiques), qui sont considérées comme un facteur majeur contribuant à une IA discriminatoire.

Certains exemples notables de partialité de l'IA due au manque de diversité ont été exposés dans un rapport de l'AI Now Institute, fondé par Meredith Whittaker, ancienne cadre de Google, et Kate Crawford, chercheuse principale chez Microsoft Research¹⁰⁰. Il s'agit notamment de services de reconnaissance d'images qui ont classé les personnes noires comme des gorilles et de la technologie Amazon qui ne reconnaît pas les utilisateurs à la peau plus foncée. La thèse du rapport (qui reflète une opinion largement répandue dans la communauté universitaire, politique et de l'IA au sens large) est que de tels exemples sont dus à des « angles morts », car les développeurs conçoivent et testent les modèles en fonction de leur propre

⁹⁸ Pour une analyse, voir par exemple Jack Bandy, (2021) 'Problematic Machine Behaviour : A Systematic Literature Review of Algorithm Audits' À paraître, Proceedings of the ACM (PACM) Human-Computer Interaction, CSCW '21.

⁹⁹ Voir Saleiro, P, Kuester, B, Hinkson, L, London, J, Stevens, A, Anisfield, A, Rodolfa, KT, Ghani, R (2018) 'Aequitas : A Bias and Fairness Audit Toolkit.' Arxiv and Oxford Internet Institute (2021) 'AI modelling tool developed by Oxford Academics incorporated into Amazon anti-bias software': <https://www.oii.ox.ac.uk/news-events/news/ai-modelling-tool-developed-by-oxford-academics-incorporated-into-amazon-anti-bias-software-2/>.

¹⁰⁰ Sarah Myers West, Meredith Whittaker et Kate Crawford, *Discriminating Systems : Gender, Race, and Power in AI*, AI Now Institute NYU, April 2019 : <https://ainowinstitute.org/discriminatingystems.pdf> (dernière consultation : 27 juillet 2022).

point de vue. L'absence d'une main-d'œuvre diversifiée conduit à une perspective limitée et peut entraîner des biais qui peuvent être difficiles à détecter et à corriger avant qu'ils ne conduisent à la discrimination.

Outre le problème répandu des **biais implicites**, un groupe homogène est susceptible d'avoir une **vision tronquée influencée par des identités et des expériences similaires**. À titre d'exemple, le programme Google AI Experiments a mis au point un jeu intitulé "Quick, Draw!". Les participants sont invités à dessiner des objets du quotidien, comme des chaussures, pour former un modèle¹⁰¹. Les cinq développeurs du jeu chez Google étaient des hommes. Les premiers utilisateurs du jeu et eux-mêmes dessinaient des baskets d'homme pour représenter une chaussure. Ce jeu ne savait donc pas que les escarpins à talons hauts étaient aussi des chaussures. Il ne s'agit pas d'une erreur intentionnelle puisqu'elle émane d'un groupe représentatif dominant qui conçoit les algorithmes dans le secteur technologique. **En tant que tel, tout algorithme construit par un groupe majoritaire risque de ne pas intégrer les points de vue des groupes minoritaires marginalisés et de ne fonctionner que pour les membres du groupe dominant.**

La diversité est importante car elle permet d'adopter des approches globales pour rendre les technologies d'IA plus responsables. Elle contribue à relever les défis plus rapidement et plus clairement, car les connaissances locales et l'expérience de première ligne seront intégrées au cœur de chaque processus de décision ou de travail. Il est essentiel d'obtenir le bon dosage de talents afin d'avoir suffisamment de recul pour éliminer les biais et acquérir un avantage concurrentiel. **La diversité doit donc être considérée comme une « mission essentielle » en matière d'innovation.** Elle devrait se traduire par des politiques de recrutement plus diversifiées dans les communautés éducatives et professionnelles qui contribuent au développement des systèmes d'IA et à leur utilisation. Nous avons expliqué dans la section 3 que les obligations juridiques liées à la notion d'action positive pourraient jouer un rôle majeur à cet égard. En outre, les politiques favorables à la diversité dans le recrutement éducatif et professionnel devraient être complétées par une formation adéquate.

Le rapport *AI Now* (Université de New York)¹⁰² a identifié une « crise de la diversité » dans le secteur de l'IA, en particulier dans le secteur technologique mondial, qui est très majoritairement composé de mâles blancs, et affirme que cette prédominance a contribué aux biais sexistes et raciaux des algorithmes. Un rapport du Forum économique mondial de 2020¹⁰³ a dressé un tableau tout aussi sombre : malgré les discours sur une plus grande inclusion, la représentation des femmes dans les emplois liés à la technologie a diminué de 32 % depuis 1990. Selon une étude lancée par la Commission européenne en 2016, « seules 24 femmes diplômées sur 1 000 avaient une discipline liée aux TIC dans leur bagage de compétences ».

¹⁰¹ Josh Lovejoy, *Fair Is Not the Default – Why building inclusive tech takes more than good intentions*, 15 February 2018 <https://design.google/library/fair-not-default/> (dernière consultation le 28 juillet 2022).

¹⁰² Kari Paul, *'Disastrous' lack of diversity in AI industry perpetuates bias, study finds*, The Guardian, 17 April 2019: <https://www.theguardian.com/technology/2019/apr/16/artificial-intelligence-lack-diversity-new-york-university-study> (dernière consultation le 27 juillet 2022).

¹⁰³ Ronit Avi et Rana El Kaliouby, *Here's why AI needs a more diverse workforce*, Forum économique mondial, 21 septembre 2020 : <https://www.weforum.org/agenda/2020/09/ai-needs-diverse-workforce/> (dernière consultation le 27 juillet 2022).

En matière d'emploi, seules 6 de ces filles et femmes ont finalement trouvé un emploi dans le secteur numérique¹⁰⁴.

Une start-up canadienne a constaté que les femmes ne représentent que 12 % des chercheurs de premier plan dans le domaine de l'apprentissage automatisé¹⁰⁵. Un autre rapport¹⁰⁶ de l'université de New York - *Discriminating Systems - Gender, Race, and Power in AI* - affirme que la discrimination dans les systèmes d'IA est associée au manque de diversité dans les équipes qui travaillent sur ces technologies. **Que l'accent soit mis sur l'atténuation des biais dans les processus d'entrée ou sur l'équité dans les résultats, la diversité et l'inclusion sont l'un des outils les plus puissants dont disposent les entreprises.** Les angles morts créés par le manque de diversité (diversité en matière d'éducation, de perspectives, de vécu et d'origines) rendent plus difficile l'anticipation des biais dans les systèmes algorithmiques et leur impact potentiel sur les différents individus et groupes.

Les groupes déjà marginalisés sont systématiquement et de manière disproportionnée plus vulnérables au risque d'être lésés par des outils de décision algorithmiques qui ne représentent pas leurs perspectives et leurs intérêts. Au-delà de l'impératif moral de prévenir la discrimination raciale et sexuelle systémique dans la conception de nouveaux outils d'IA, il existe également un impératif économique. Des recherches ont montré que « les entreprises qui se situent dans le quartile supérieur en matière de diversité des sexes sont 21 % plus susceptibles de connaître une rentabilité supérieure à la moyenne, tandis que la diversité ethnique et culturelle est corrélée à une augmentation de 33 % des performances¹⁰⁷ ».

Section 2

Le paysage juridique et politique en Europe : forces et faiblesses

Les **décideurs politiques sont généralement conscients** que l'IA offre de nombreuses opportunités mais que cette technologie comporte le risque de renforcer et de perpétuer les inégalités existantes. Dans une enquête publiée par le Conseil de l'Europe pour connaître l'opinion des États parties à la CEDH, plus de **80 % des personnes interrogées ont estimé que l'IA présentait des risques pour les droits humains. 40 % des répondants ont déclaré qu'il existe un risque direct de discrimination fondée sur le genre.**

Plusieurs initiatives qui ont été lancées dans des gouvernements englobent plusieurs aspects, notamment la participation des femmes dans les domaines des STIM, les vidéos manipulées, la cyberintimidation et la discrimination algorithmique. Certains pays comme la **Finlande**,

¹⁰⁴ Women in AI : Promoting inclusive participation across society, Aimee Van WYNSBERGH, Alliance européenne de l'IA <https://futurium.ec.europa.eu/en/european-ai-alliance/blog/women-ai-promoting-inclusive-participation-across-society?language=hu> : <https://futurium.ec.europa.eu/en/european-ai-alliance/blog/women-ai-promoting-inclusive-participation-across-society?language=hu> (dernière consultation le 31 août 2022).

¹⁰⁵ Archie de Berker, Women in Machine Learning : Negar Rostamzadeh, 20 février 2018 ; <https://medium.com/element-ai-research-lab/women-in-machine-learning-negar-rostamzadeh-dbb58dc75e81> (dernière consultation le 31 août 2022).

¹⁰⁶ Sarah Myers West, Meredith Whittaker et Kate Crawford, *Discriminating Systems : Gender, Race, and Power in AI*, AI Now Institute NYU, avril 2019 : <https://ainowinstitute.org/discriminatingystems.pdf> (dernière consultation le 27 juillet 2022).

¹⁰⁷ Les cinq avantages commerciaux d'une équipe diversifiée, CMI, 3 juillet 2019 : <https://www.managers.org.uk/knowledge-and-insights/listicle/the-five-business-benefits-of-a-diverse-team/> (dernière consultation le 31 août 2022).

par exemple, ont abordé de front la question du manque de transparence des systèmes algorithmiques conduisant à la discrimination, en publiant des recommandations et des orientations pour sensibiliser au problème¹⁰⁸. Les **Pays-Bas ont** adopté une « analyse d'impact des algorithmes sur les droits fondamentaux » qui comprend une « ligne directrice sur la non-discrimination dès la conception¹⁰⁹ ». Le Parlement néerlandais a récemment adopté une motion rendant les évaluations d'impact sur les droits humains obligatoires pour les institutions publiques utilisant des algorithmes¹¹⁰.

Le gouvernement **autrichien** a publié un plan d'action sur les « vidéos manipulées » comprenant diverses mesures pour s'attaquer au problème. En **Finlande**, Aurora AI vise à orienter les citoyens, notamment les jeunes, vers les services dont ils ont besoin grâce à l'intelligence artificielle. Si les jeunes estiment que ces services sont de meilleure qualité, leur appréciation est susceptible de promouvoir l'égalité, par exemple dans l'accès aux services ou dans la fourniture d'une assistance et d'un soutien. L'Agence **portugaise** pour la modernisation administrative (AMA) a élaboré, avec l'aide de la Commission pour la citoyenneté et l'égalité de genre et d'autres parties prenantes concernées, le « Guide pour l'utilisation de l'intelligence artificielle dans l'administration publique ». Le guide est conçu pour répondre aux préoccupations suscitées par la non-discrimination en général ainsi que la protection des droits individuels et collectifs dans le développement des systèmes algorithmiques. Le document appelle l'attention sur la fiabilité et la représentativité des données à collecter et à traiter et met l'accent sur les questions liées à l'éthique, à la justice, à la transparence, à la responsabilisation et à la compréhension des systèmes.

Pourtant, les réponses nationales **manquent, dans une large mesure, de coordination**. Alors que des législateurs comme l'Union européenne sont en train d'adopter un cadre réglementaire uniforme sur l'IA, **le Conseil de l'Europe pourrait avoir une grande influence réglementaire dans le domaine des droits humains**. Sachant que l'UE préconise une « IA centrée sur la personne », l'action réglementaire du Conseil de l'Europe pourrait favoriser une **approche distincte de l'IA fondée sur les droits humains**.

Cette section de l'étude met en évidence les **instruments juridiques qui existent au niveau du Conseil de l'Europe et qui peuvent être utilisés pour traiter les divers aspects du problème de la discrimination algorithmique, allant de la non-discrimination à la protection des données et de la vie privée en passant par les réglementations sectorielles**. Elle dresse également une brève cartographie des instruments juridiques européens existants et à venir et montre que ces deux cadres présentent des **lacunes et des incertitudes lorsqu'il s'agit de traiter la discrimination algorithmique**. Ces lacunes appellent une action réglementaire du Conseil de l'Europe, dont certains contours possibles sont mis en évidence dans la section 3.

¹⁰⁸ Automaattisessa päätöksenteossa on turvattava virkavastuu ja hyvän hallinnon toteutuminen : <https://valtioneuvosto.fi/-/10623/automaattisessa-paatoksenteossa-on-turvattava-virkavastuu-ja-hyvan-hallinnon-toteutuminen> (dernière consultation le 28 juillet 2022).

¹⁰⁹ Ministère de l'Intérieur et des Relations au sein du Royaume, "Fundamental rights and algorithms Impact Assessment" (mars 2022): <https://www.government.nl/binaries/government/documenten/reports/2022/03/31/impact-assessment-fundamental-rights-and-algorithms/Fundamental+Droits+et+Algorithmes+Impact+Assessment.pdf>.

¹¹⁰ Voir European Centre for Not-for-Profit Law, "Netherlands sets precedent for human rights safeguards in use of AI" (2022) : <https://ecnl.org/news/netherlands-sets-precedent-human-rights-safeguards-use-ai>.

I. La discrimination et l'égalité : les instruments juridiques et politiques et leurs limites

Cette section met en lumière les instruments juridiques existants qui fournissent un socle juridique pour lutter contre la discrimination algorithmique et les formes connexes de violence algorithmique.

1) Les instruments juridiques contraignants du Conseil de l'Europe

La Convention européenne des droits de l'homme

L'article 14 de la CEDH et l'article 1 du Protocole n° 12 énoncent une interdiction de la discrimination qui fournit une **base juridique pour interdire la discrimination algorithmique**.

L'article 14 de la CEDH interdit toute discrimination fondée sur une liste non exhaustive de caractéristiques protégées :

« 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. »

Son application dépend de l'existence d'une violation d'un droit substantiel protégé par la CEDH.

Entré en vigueur en 2005, le **Protocole n° 12 à la Convention** a été ratifié par 20 des 46 États parties à la CEDH à ce jour. L'article 1^{er} énonce une interdiction générale et autonome de la discrimination :

« 1. 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.

2. Nul ne peut faire l'objet d'une discrimination de la part d'une autorité publique quelle qu'elle soit fondée notamment sur les motifs mentionnés au paragraphe 1. »

La Convention d'Istanbul

La Convention du Conseil de l'Europe sur la prévention et la lutte contre la violence à l'égard des femmes et la violence domestique fournit une **base pour interdire la violence algorithmique à l'égard des femmes, y compris les stéréotypes algorithmiques, et la violence en ligne telle que le cyber-harcèlement, l'intimidation et le discours de haine sexiste en ligne**.

La Convention d'Istanbul, adoptée en 2011, est entrée en vigueur en 2014 et a été ratifiée par 37 États parties. Elle reconnaît que la violence fondée sur le sexe (VFS) est une forme de discrimination. Ses dispositions sont axées sur la prévention, la protection, les poursuites et le développement de politiques intégrées en matière de lutte contre la violence à l'égard des femmes.

L'article 17 sur la « participation du secteur privé et des médias » est particulièrement pertinent pour les questions de violence sexiste en ligne. Il énonce à cet égard que :

« Les Parties encouragent le secteur privé, le secteur des technologies de l'information et de la communication et les médias, dans le respect de la liberté d'expression et de leur indépendance, à participer à l'élaboration et à la mise en œuvre des politiques, ainsi qu'à mettre en place des lignes directrices et des normes d'autorégulation pour prévenir la violence à l'égard des femmes et renforcer le respect de leur dignité ».

La Convention-cadre pour la protection des minorités nationales

La Convention-cadre pour la protection des minorités nationales fournit une **base juridique pour combattre la discrimination algorithmique fondée sur le statut de minorité nationale ainsi que la violence en ligne, notamment le discours de haine.**

Entrée en vigueur en 1998, la Convention compte 39 Etats parties. Dans son **article 4**, la Convention énonce que :

« 1. Les Parties s'engagent à garantir à toute personne appartenant à une minorité nationale le droit à l'égalité devant la loi et à une égale protection de la loi. À cet égard, toute discrimination fondée sur l'appartenance à une minorité nationale est interdite.

2. Les Parties s'engagent à adopter, s'il y a lieu, des mesures adéquates en vue de promouvoir, dans tous les domaines de la vie économique, sociale, politique et culturelle, une égalité pleine et effective entre les personnes appartenant à une minorité nationale et celles appartenant à la majorité. Elles tiennent dûment compte, à cet égard, des conditions spécifiques des personnes appartenant à des minorités nationales. »

L'**article 6(2)** prévoit que *« [l]es Parties s'engagent à prendre toutes mesures appropriées pour protéger les personnes qui pourraient être victimes de menaces ou d'actes de discrimination, d'hostilité ou de violence en raison de leur identité ethnique, culturelle, linguistique ou religieuse ».*

L'**article 9** relatif à la liberté d'expression, qui énonce que *« les Parties veillent, dans le cadre de leurs systèmes juridiques, à ce que les personnes appartenant à une minorité nationale ne fassent pas l'objet de discrimination dans leur accès aux médias »*, pourrait devenir particulièrement pertinent en ce qui concerne les questions de discrimination sur les plateformes de réseaux sociaux, de harcèlement informatique et de discours haineux.

La Charte européenne des langues régionales ou minoritaires

Entrée en vigueur en 1998, la Charte a été ratifiée à ce jour par 25 pays. L'**article 7(2)** de la Charte stipule que *« [l]es Parties s'engagent à éliminer, si elles ne l'ont pas encore fait, toute distinction, exclusion, restriction ou préférence injustifiées portant sur la pratique d'une langue régionale ou minoritaire et ayant pour but de décourager ou de mettre en danger le maintien ou le développement de celle-ci. »* Là encore, **cette disposition s'étend en principe aux domaines algorithmiques et en ligne, où elle peut être invoquée pour lutter contre la discrimination numérique sous ses nombreuses formes.**

2) Les instruments politiques pertinents du Conseil de l'Europe

Un certain nombre de **normes et d'instruments de politique générale non contraignants** complètent les dispositions juridiques contraignantes et **prennent effet lorsqu'il s'agit de traiter les effets discriminatoires de l'IA et de la prise de décision algorithmique.**

En mars 2019, la « **Recommandation sur la prévention et la lutte contre le sexisme** » élaborée par la Commission pour l'égalité de genre a été adoptée par le Conseil des ministres¹¹¹. Elle reconnaît que « [l']Internet a donné une nouvelle dimension à l'expression et à la transmission du sexisme et en particulier du discours de haine sexiste à un large public, même si les origines du sexisme ne sont pas à chercher du côté des technologies mais dans la persistance des inégalités entre les femmes et les hommes¹¹² ». Elle enjoint les États membres à « [i]ntégrer une perspective d'égalité entre les femmes et les hommes dans toutes les politiques, programmes et recherches en matière d'intelligence artificielle afin d'éviter les risques de perpétuation du sexisme et des stéréotypes de genre¹¹³ ». La recommandation prévoit également un rôle positif pour l'IA puisqu'elle demande aux États parties « d'examiner comment l'intelligence artificielle pourrait aider à combler les écarts entre les femmes et les hommes et éliminer le sexisme¹¹⁴. » Elle énumère des aspects essentiels tels que la participation des femmes et des filles à l'enseignement et à la pratique des technologies informatiques, l'intégration de l'égalité des genres dans la conception d'instruments axés sur les données, la sensibilisation aux préjugés sexistes dans le big data, la transparence et la responsabilité. En outre, la récente recommandation « **sur la lutte contre les discours de haine** », rédigée conjointement par le Comité directeur sur l'anti-discrimination, la diversité et l'inclusion (CDADI) et le Comité directeur sur les médias et la société de l'information (CDMSI), indique que « les intermédiaires d'internet devraient identifier les formes de discours de haine qui sont diffusées par leurs systèmes et y réagir dans le cadre de leur responsabilité d'entreprise¹¹⁵ ».

La **Stratégie 2018-2023 du Conseil de l'Europe pour l'égalité entre les femmes et les hommes** reconnaît également que le « **sexisme et la discrimination à l'égard des femmes englobent les discours haineux sexistes en ligne** » ainsi que la violence fondée sur le genre¹¹⁶. En outre, le GREVIO, qui surveille la mise en œuvre de la Convention d'Istanbul a également publié une recommandation générale n° 1 sur la **dimension numérique de la violence à l'égard des femmes** en 2021, qui met en lumière les problèmes juridiques liés au harcèlement sexuel en ligne, à la traque et à la dimension numérique de la violence psychologique¹¹⁷.

En mai 2022, le Comité des Ministres a adopté une nouvelle **Recommandation sur la lutte contre les discours de haine** rédigée conjointement par le Comité directeur pour la lutte contre la discrimination, la diversité et l'inclusion (CDADI) et le Comité directeur sur les

¹¹¹ Conseil de l'Europe, Recommandation CM/Rec(2019)1 sur la prévention et la lutte contre le sexisme adoptée par le Comité des ministres du Conseil de l'Europe (27 mars 2019) : <https://rm.coe.int/cm-rec-2019-1-prevention-et-lutte-contre-le-sexisme/168094d895>. [en français]

¹¹² Ibid.

¹¹³ Recommandation II.B.7, *ibid.*, p. 19.

¹¹⁴ Ibid.

¹¹⁵ Conseil de l'Europe, Recommandation CM/Rec(2022)16[1] du Comité des Ministres aux États membres sur la lutte contre le discours de haine (20 mai 2022), [30].

¹¹⁶ Stratégie du Conseil de l'Europe pour l'égalité entre les femmes et les hommes 2018-2023 adoptée par le Comité des ministres (mars 2018), pages 10, 16, 18 : <https://www.coe.int/fr/web/genderequality/gender-equality-strategy>.

¹¹⁷ Groupe d'experts sur la lutte contre la violence à l'égard des femmes et la violence domestique, Recommandation générale n° 1 sur la dimension numérique de la violence à l'égard des femmes (20 octobre 2021) : <https://rm.coe.int/recommandation-no-du-grevio-sur-la-dimension-numerique-de-la-violence-1680a49148#:~:text=Le%20GREVIO%20consid%C3%A8re%20que%20la,11>. (dernière consultation le 22 juillet 2022). [en français]

médias et la société de l'information (CDMSI)¹¹⁸. Le texte reconnaît l'existence d'« **asymétries de pouvoir entre certaines plateformes numériques et leurs utilisateurs** », et formule des recommandations pour lutter contre le **discours de haine en ligne en ce qui concerne les politiques relatives à la modération du contenu, au microciblage et à la publicité en ligne, à l'amplification du contenu, aux systèmes de recommandation et aux stratégies de collecte de données sous-jacentes**.

En mai 2022, le Comité des Ministres a adopté une « **Recommandation sur la protection des droits des femmes et des filles migrantes, réfugiées et demandeuses d'asile** » qui exige que **des évaluations d'impact sur les droits humains soient réalisées avant l'introduction de l'IA et des systèmes de prise de décision automatisés dans le domaine de la migration et que la conception, le développement et l'application de ces systèmes soient non discriminatoires**¹¹⁹. Elle appelle également à associer les femmes réfugiées, demandeuses d'asile et migrantes, ainsi que les OSC représentatives, aux « discussions sur le développement et le déploiement des nouvelles technologies qui les concernent ».

D'autres instruments tels que les **Lignes directrices du Comité des Ministres du Conseil de l'Europe sur la défense de l'égalité et la protection contre la discrimination et la haine pendant la pandémie de covid-19 et les crises similaires à l'avenir** mentionnent la nécessité de veiller à ce que « les outils numériques permettant de faire face à la crise et aux risques qui en résultent « ne soient pas discriminatoires à l'égard des personnes issues de groupes vulnérables ou ne portent pas atteinte de toute autre manière à leurs droits¹²⁰ ».

Ensemble, ces recommandations abordent un certain nombre de **problèmes contribuant à la discrimination algorithmique** (voir plus haut dans cette étude), à savoir : **le manque de diversité, de représentation et de participation équitables dans les domaines éducatifs et professionnels liés au secteur de l'IA, l'absence d'obligation contraignant les concepteurs à intégrer les préoccupations liées à l'égalité dans le développement des systèmes algorithmiques et l'absence de mécanismes de responsabilité clairement définis**.

3) Un éclairage comparatif : autres dispositions européennes et internationales pertinentes

L'Union européenne dispose également d'un cadre juridique très étoffé en matière de discrimination et d'égalité. L'**article 21(1)** de la **Charte des droits fondamentaux de l'UE** interdit toute discrimination « *fondée notamment sur le sexe, la race, la couleur, les origines ethniques ou sociales, les caractéristiques génétiques, la langue, la religion ou les convictions, les opinions politiques ou toute autre opinion, l'appartenance à une minorité nationale, la fortune, la naissance, un handicap, l'âge ou l'orientation sexuelle* » et l'**article 21(2)** énonce que « [d]ans le domaine d'application des traités et sans préjudice des dispositions particulières qu'ils prévoient, est

¹¹⁸ Conseil de l'Europe, Recommandation CM/Rec(2022)16 sur la lutte contre le discours de haine : https://search.coe.int/cm/Pages/result_details.aspx?ObjectId=0900001680a67951. [en français]

¹¹⁹ Conseil de l'Europe, Recommandation CM/Rec(2022)17 du Comité des Ministres aux Etats membres sur la protection des droits des femmes et des filles migrantes, réfugiées et demandeuses d'asile, [22]-[25] : <https://rm.coe.int/prems-092122-fra-2573-recommandation-cm-rec-2022-17-a5-bat-web/1680a6ef9b>.

¹²⁰ Comité directeur pour la lutte contre la discrimination, la diversité et l'inclusion (CDADI), Lignes directrices du Comité des Ministres du Conseil de l'Europe sur la défense de l'égalité et la protection contre la discrimination et la haine pendant la pandémie de covid-19 et les crises similaires à l'avenir (2020), [27] : <https://rm.coe.int/prems-066621-fra-cdadi-lignes-directrices-a5-web-ok2-2764-3779-6356-1/1680a339c9>. [en français]

interdite toute discrimination exercée en raison de la nationalité ». L'article 23 indique que « [l]égalité entre les femmes et les hommes doit être assurée dans tous les domaines, y compris en matière d'emploi, de travail et de rémunération » et autorise les actions positives. Dans le droit dérivé, la **directive 2000/43/CE** garantit l'égalité de traitement fondée sur la race ou l'origine ethnique au travail, dans l'accès aux biens et aux services et dans l'éducation. La **directive 2000/78/CE** interdit toute discrimination fondée sur le handicap, l'orientation sexuelle, la religion ou les convictions, l'âge sur le lieu de travail et la formation professionnelle. La **directive 2004/113/CE** garantit l'égalité entre les femmes et les hommes dans l'accès aux biens et services, tout comme la **directive 2006/54/CE** en matière d'emploi.

En 2022, la Commission européenne a publié une « **Déclaration européenne sur les droits et principes numériques pour la décennie numérique** » qui reflète la volonté de la Commission de développer une « **IA centrée sur l'humain** » et expose l'approche de l'UE en matière de transformation numérique. Le raisonnement de la Commission est que les droits numériques doivent garantir que les citoyens de l'UE ont accès aux technologies numériques et sont protégés de leurs conséquences nuisibles. Le chapitre III de la Déclaration comprend un engagement à « veiller à ce que les systèmes algorithmiques reposent sur des ensembles de données appropriés, afin d'éviter toute discrimination illicite et de permettre une surveillance humaine des résultats qui touchent des personnes¹²¹. »

Au niveau de l'ONU, un certain nombre d'instruments protègent contre la discrimination au-delà des instruments généraux des droits humains existants : en particulier la **Convention internationale sur l'élimination de toutes les formes de discrimination raciale (CERD)**, la **Convention sur l'élimination de toutes les formes de discrimination à l'égard des femmes (CEDAW)** et la **Convention relative aux droits des personnes handicapées (CRPD)**. Plus précisément, le Comité CERD a émis une **recommandation générale n° 36 relative à la prévention et la lutte contre le profilage racial par les services répressifs** en 2020. Ce document reconnaît que l'utilisation de l'intelligence artificielle contribue au renforcement des inégalités raciales et fait des recommandations pour prévenir et corriger les préjugés et la discrimination raciale.

Bien que ces instruments juridiques et politiques ne s'arrêtent pas aux frontières du monde numérique, leur applicabilité aux différentes formes de discrimination algorithmique souffre d'un certain nombre de lacunes.

4) Les limites et les incertitudes : où se situe la discrimination algorithmique ?

Ce patchwork juridique et politique aborde certains des risques discriminatoires de l'IA et de la prise de décision automatisée. Pourtant, **de nombreuses incertitudes subsistent quant à la mesure dans laquelle les dispositions légales existantes peuvent être utilisées pour promouvoir l'égalité et lutter contre la discrimination découlant de l'utilisation de ces technologies.** L'objectif de cette sous-section est donc d'examiner les lacunes existantes dans le cadre de l'égalité et de la non-discrimination décrit ci-dessus lorsqu'il s'agit de discrimination algorithmique. **Trois questions principales** se posent : 1) l'**absence de chevauchement net entre les notions existantes de discrimination directe et indirecte et les formes de discrimination algorithmique**, 2) les **questions de procédure** liées à la **preuve** et à la **responsabilité**, 3) et les **défis liés à la protection par la législation de caractéristiques**

¹²¹ Commission européenne, « Déclaration européenne sur les droits et principes numériques pour la décennie numérique », COM(2022) 28 final (Bruxelles 2022).

spécifiques. Il a été expliqué à la section 3 que pour combler ces lacunes, il convient d'appliquer les obligations positives existantes en matière de promotion de l'égalité et d'intégrer des approches préventives de la discrimination algorithmique au titre de l'article 14 de la CEDH.

Les questions de qualification : discrimination algorithmique directe ou indirecte

Bien que l'article 14 de la CEDH ne fasse pas de distinction entre la discrimination directe et indirecte, la Cour européenne des droits de l'homme (la Cour) a établi cette distinction dans sa jurisprudence¹²². **La discrimination directe** résulte « d'une **différence de traitement de personnes se trouvant dans des situations analogues ou similaires** », notamment lorsque cette différence est « **fondée sur une caractéristique identifiable** » ou un « **statut**¹²³ ». Par exemple, lorsque deux travailleurs qui ont des qualifications similaires sollicitent une promotion mais que l'un d'eux est préféré à l'autre « en raison de » son genre, il s'agit d'une discrimination directe fondée sur le genre.

Au début des années 2000, la **Cour a reconnu l'existence d'une discrimination indirecte** lorsque les États « n'appliquent pas un traitement différent à des personnes se trouvant dans des situations différentes¹²⁴ ». Elle a statué dans l'affaire *D.H. et autres c. République tchèque* qu'« une différence de traitement pouvait aussi consister en l'effet préjudiciable disproportionné d'une politique ou d'une mesure qui, bien que formulée de manière neutre, a un effet discriminatoire sur un groupe¹²⁵ ». Par exemple, une politique formulée de manière neutre qui conditionnerait le recrutement de candidats à une taille minimale pourrait avoir des effets indirectement discriminatoires sur les femmes, qui sont en moyenne plus petites que les hommes.

Dès lors qu'un constat *prima facie* de discrimination directe ou indirecte a été établi, un **système de justification ouvert** s'applique, selon lequel une **discrimination** ne peut être constatée que s'il n'y a « **aucune justification objective et raisonnable**¹²⁶ ». En d'autres termes, tant la discrimination directe qu'indirecte peut être justifiée si elle poursuit un **but légitime** et s'il existe un « rapport de **proportionnalité entre les moyens employés et le but recherché**¹²⁷ ».

¹²² La distinction a été établie en se référant au droit européen en matière d'égalité et à la jurisprudence de la Cour européenne de justice, voir *D.H. et autres c. République tchèque* Requête n° 57325/00 (Cour européenne des droits de l'homme, Grande Chambre, 13 novembre 2007), [184].

¹²³ Voir par exemple *Kjeldsen, Busk Madsen et Pedersen c. Danemark*, requêtes n° 5095/71, 5920/72, 5926/72 (Cour européenne des droits de l'homme, Grande Chambre, 7 décembre 1976), [56] *Burden c. Royaume-Uni*, requête 13378/05 (Cour européenne des droits de l'homme, Grande Chambre, 29 avril 2008), [60] *Carson et autres c. Royaume-Uni*, requête n° 42184/05 (Cour européenne des droits de l'homme, Grande Chambre, 16 mars 2010), [61], et plus récemment *Biao c. Danemark*, requête n° 38590/10 (Cour européenne des droits de l'homme, Grande Chambre, 24 mai 2016), [89]. Voir également l'Agence des droits fondamentaux de l'Union européenne et le Conseil de l'Europe, *Manuel sur le droit européen en matière de non-discrimination* (Office des publications de l'Union européenne 2018), 43 et Cour européenne des droits de l'homme, *Guide sur l'article 14 de la Convention européenne des droits de l'homme et sur l'article 1 du Protocole n° 12 à la Convention* (Conseil de l'Europe 2020), 11.

¹²⁴ *Thlimmenos c. Grèce*, requête n° 34369/97 (Cour européenne des droits de l'homme, 2 avril 2000), [44].

¹²⁵ *D.H. et autres c. République tchèque*, requête n° 57325/00 (Cour européenne des droits de l'homme, Grande Chambre, 13 novembre 2007), [184].

¹²⁶ *Affaire « relative à certains aspects du régime linguistique de l'enseignement en Belgique » c. Belgique*, requêtes n° 1474/62 ; 1677/62 ; 1691/62 ; 1769/63 ; 1994/63 ; 2126/64 (Cour européenne des droits de l'homme, 23 juillet 1968), [10], p. 34.

¹²⁷ *Ibid*, voir aussi *Marckx c. Belgique*, requête n° 6833/74 (Cour européenne des droits de l'homme, 13 juin 1979), [33].

Étant donné que le même système de justification s'applique en principe dans les deux cadres, qualifier la discrimination algorithmique de directe ou d'indirecte a des répercussions moins importantes sur les moyens de recours disponibles que dans le droit communautaire, où cette qualification conditionne l'applicabilité d'un système fermé ou ouvert de justifications¹²⁸. Néanmoins, il est important de comprendre comment les tribunaux, notamment la Cour européenne des droits de l'homme, qualifieront la discrimination algorithmique.

On a considéré jusqu'à présent que la discrimination algorithmique s'inscrivait principalement dans le cadre de la discrimination indirecte, notamment parce que les développeurs sont peu susceptibles d'entrer des caractéristiques protégées dans les ensembles de données utilisés pour former les systèmes de prise de décision algorithmique (ADM)¹²⁹. Selon Hacker, par exemple, « dans les contextes d'apprentissage automatisé, la discrimination indirecte est le type de discrimination le plus pertinent » tandis que « la discrimination directe sera rare dans la prise de décision algorithmique, et se limitera en grande partie aux cas de partialité implicite dans l'étiquetage¹³⁰ ». Borgesius et Kelly-Lyth font également valoir respectivement que « la loi sur la non-discrimination interdit de nombreux effets discriminatoires du processus décisionnel algorithmique, en particulier par le biais du concept de discrimination indirecte¹³¹ » et que « la plupart des algorithmes biaisés relèveront du cadre de la discrimination indirecte¹³² ».

Au moins trois arguments viennent à l'appui de ce point de vue : 1) la discrimination indirecte englobe les situations dans lesquelles des mesures formellement neutres entraînent des désavantages parce qu'elles interviennent dans un contexte social inégal et l'intègrent¹³³. Cela reflète la manière dont les technologies fondées sur les données intègrent et perpétuent le *statu quo* inégal de la société¹³⁴, 2) la discrimination indirecte met l'accent sur la dimension structurelle de la discrimination.¹³⁵ Cette orientation correspond au fait que les algorithmes d'apprentissage automatisé déduisent des règles à partir de modèles de groupes. Troisièmement, le concept de discrimination indirecte permet d'aborder les distinctions qui ne sont pas fondées sur des motifs légalement protégés mais qui, dans les faits, ont un impact

¹²⁸ Dans le droit de l'UE, la discrimination directe ne peut, en principe, être justifiée (sauf exceptions fermées), tandis que la discrimination indirecte donne lieu à un test de proportionnalité assorti d'un régime de justifications illimité.

¹²⁹ Cet argument s'appuie sur une analogie avec le cadre américain de lutte contre la discrimination, voir par exemple Solon Barocas et Andrew D. Selbst, "Big Data's Disparate Impact" (2016) 104 California law review 671. Pourtant, la distinction entre la discrimination directe et indirecte dans le droit de la Cour diffère de la distinction américaine entre les notions de « traitement disparate » et d'« impact disparate ».

¹³⁰ Hacker, "Teaching fairness to artificial intelligence: Existing and novel strategies against algorithmic discrimination under EU law", 1152-1153.

¹³¹ Zuiderveen Borgesius, "Strengthening legal protection against discrimination by algorithms and artificial intelligence", 1578. Il reconnaît néanmoins l'existence d'une série de problèmes d'application.

¹³² Aislinn Kelly-Lyth, "Challenging Biased Hiring Algorithms" (2021) 41 Oxford Journal of Legal Studies 899, 906.

¹³³ Voir Tobler, *Limits and potential of the concept of indirect discrimination*, 85. Sur le point de vue de l'auteur et de la victime, voir Alan David Freeman, « Legitimizing Racial Discrimination Through Anti-discrimination Law : A Critical Review of Supreme Court Doctrine' (1978) 62 Minnesota Law Review 1049.

¹³⁴ Voir Anna Lauren Hoffmann, 'Where fairness fails: data, algorithms, and the limits of antidiscrimination discourse' (2019) 22 Information, Communication & Society 900.

¹³⁵ Voir Hugh Collins et Tarunabh Khaitan, « Indirect Discrimination Law: Controversies and Critical Questions » in Hugh Collins et Tarunabh Khaitan (eds), *Foundations of Indirect Discrimination Law* (1 edn, Hart Publishing 2018), 19.

sur les groupes protégés¹³⁶. Étant donné que cette discrimination est l'une des formes dominantes de la discrimination algorithmique (voir plus loin), le cadre qui la définit présente un avantage supplémentaire.

Malgré le consensus sur la classification de la discrimination algorithmique comme étant indirecte, **une telle qualification « par défaut » soulève un certain nombre de questions doctrinales et procédurales**¹³⁷. Des études récentes montrent que la notion de **discrimination directe pourrait englober certains cas de discrimination algorithmique dans lesquels un groupe entier est systématiquement touché**, quel que soit le critère utilisé pour la prise de décision¹³⁸. En outre, **l'intégration des effets discriminatoires du biais algorithmique dans l'une ou l'autre notion soulève des questions normatives cruciales** sur les concepts clés du droit de la non-discrimination¹³⁹. En ce sens, le CAHAI a reconnu dans son étude de faisabilité 2020 que **« [l']importance accrue de la discrimination par procuration dans le contexte de l'apprentissage machine peut soulever des questions d'interprétation sur la distinction entre discrimination directe et indirecte ou, en fait, sur l'adéquation de cette distinction telle qu'elle est traditionnellement comprise**¹⁴⁰ ». Par exemple, qu'est-ce qui peut être considéré comme un critère « neutre » pour la prise de décision à la lumière des boucles de rétroaction existantes et des problèmes de codage redondants ? La discrimination algorithmique, qui alimente les inégalités structurelles dans les décisions individuelles, est-elle une forme collective ou individuelle de traitement inéquitable ? L'utilisateur d'un algorithme doit-il être considéré comme un agresseur lorsqu'une machine apprend de manière autonome à discriminer ? Les réponses à ces questions détermineront, en théorie, si la notion de discrimination directe ou indirecte peut être utilisée pour appréhender la discrimination algorithmique¹⁴¹.

Les questions de procédure : preuve, proportionnalité, responsabilité et obligation

Dans la pratique, cependant, l'opacité des systèmes de décision algorithmiques laisse penser que les preuves nécessaires pour caractériser une discrimination directe feront souvent défaut. L'information pourrait n'être disponible qu'*ex post* et rester partielle, de sorte que l'on ne peut observer les effets d'un système algorithmique qu'après son utilisation. Par exemple,

¹³⁶ Par exemple, le travail à temps partiel est une question d'égalité de genre puisque la plupart des travailleurs à temps partiel sont des femmes. Voir Tobler, *Limits and potential of the concept of indirect discrimination*, 24 et Janneke Gerards, « Discrimination grounds », in: Dagmar Schiek, Lisa Waddington et Mark Bell (eds), *Cases, Materials and Text on National, Supranational and International Non-Discrimination Law*, Oxford and Portland, Oregon : Hart Publishing 2007, 33-184.

¹³⁷ Gerards J and Xenidis R, *Algorithmic discrimination in Europe: Challenges and Opportunities for EU Gender Equality and Non-Discrimination Law* (Réseau européen d'experts juridiques dans le domaine de l'égalité de genre et de la non-discrimination / European Commission, 2021).

¹³⁸ Voir Adams-Prassl, Binns et Kelly-Lyth, "Directly discriminatory algorithms", *Modern Law Review* (à paraître).

¹³⁹ Gerards J et Xenidis R, *Algorithmic discrimination in Europe : Challenges and Opportunities for EU Gender Equality and Non-Discrimination Law* (Réseau européen d'experts juridiques dans le domaine de l'égalité de genre et de la non-discrimination / European Commission, 2021).

¹⁴⁰ CAHAI, "Feasibility Study on legal framework on AI design, development and application based on CoE standards" (2020), [13], p. 5.

¹⁴¹ Voir Gerards J et Xenidis R, *Algorithmic discrimination in Europe : Challenges and Opportunities for EU Gender Equality and Non-Discrimination Law* (Réseau européen d'experts juridiques dans le domaine de l'égalité de genre et de la non-discrimination / European Commission, 2021) et Xenidis R, "Tuning EU Equality Law to Algorithmic Discrimination : Three Pathways to Resilience" (2021) 27 *Maastricht Journal of European and Comparative Law* 736.

si un algorithme de notation de crédit refuse systématiquement un crédit aux personnes vivant avec un handicap, il est possible que l'on ne puisse pas accéder aux critères utilisés pour une telle décision mais que l'on soit en mesure d'observer un modèle de rejet par rapport aux demandeurs ayant un handicap. De même, il est possible que l'on ne puisse pas accéder aux informations concernant l'ensemble des demandeurs, de sorte qu'il n'y a pas de certitude concernant les demandeurs potentiels handicapés qui ont obtenu un crédit ou les autres demandeurs qui se sont vu opposer un refus.

Le problème des preuves : pour les demandeurs potentiels, l'opacité des décisions algorithmiques constitue des obstacles substantiels à la réparation de la discrimination. Les asymétries d'information entre les utilisateurs et les sujets de la prise de décision algorithmique ou des systèmes d'aide à la décision signifient que les utilisateurs finaux isolés n'auront pas la capacité de surveiller l'impact des décisions algorithmiques sur des groupes d'autres utilisateurs finaux. Ils ne pourront pas non plus accéder aux informations sur les critères de décision. Même dans les cas potentiels de discrimination algorithmique indirecte, l'absence d'informations transparentes et significatives sur les critères de décision pertinents et le fait que les victimes n'aient pas une vue d'ensemble des décisions prises pourraient empêcher de prendre conscience de l'existence d'une discrimination. Cela peut éventuellement empêcher toute action en justice d'être engagée.

Toutefois, lorsqu'il saisira la justice, **le requérant sera aidé par les règles existantes relatives à la charge de la preuve** : lorsqu'il aura établi la preuve *prima facie* de discrimination, la charge de la preuve incombe en principe au défendeur, qui est chargé de démontrer que la différence de traitement est justifiée. **Pourtant, des problèmes juridiques continuent de se poser : comment fournir suffisamment d'éléments, et quel type d'informations présenter, pour établir une preuve *prima facie* de discrimination afin de déclencher le transfert de la charge de la preuve au défendeur ?** Dans le contexte algorithmique, les asymétries d'information pourraient même empêcher de démontrer une discrimination *prima facie*.

Test de proportionnalité : dès qu'une différence de traitement entre des personnes se trouvant dans une situation similaire ou l'absence de différence de traitement entre des personnes se trouvant dans une situation différente a été établie, les juges doivent effectuer un test de proportionnalité pour évaluer si elle peut être objectivement justifiée. Ce test en deux étapes vise à déterminer si la pratique répond à un objectif légitime et si les moyens employés sont raisonnablement proportionnés à l'objectif poursuivi¹⁴². La réponse à ces questions conduit à une incertitude juridique considérable en raison de la nécessité pour les juges d'évaluer des compromis techniques qu'ils ne maîtrisent peut-être pas (par exemple, quelles mesures d'équité devaient être utilisées ? Comment équilibrer les compromis entre les différentes

¹⁴² Greffe de la Cour européenne des droits de l'homme, Guide sur l'article 14 de la Convention européenne des droits de l'homme et sur l'article 1 du Protocole n° 12 à la Convention (30 avril 2022): https://www.echr.coe.int/Documents/Guide_Art_14_Art_1_Protocol_12_FRA.pdf (dernière consultation le 22 juillet 2022).

définitions de l'équité¹⁴³ ? Comment équilibrer l'exactitude et l'équité¹⁴⁴ ? Les barrières techniques qui en découlent pourraient contribuer à protéger les systèmes automatisés de prise de décision du contrôle judiciaire. Dans ces conditions, les études récentes vont dans le sens d'une application permissive du test de proportionnalité dans le contexte de l'opacité algorithmique¹⁴⁵.

La responsabilité et l'obligation : la question de la responsabilité de la discrimination algorithmique est épineuse. Certains commentateurs font valoir que la loi devrait permettre « une extension des motifs de défense des défendeurs [qui] pourrait leur permettre d'établir que les biais ont été développés de manière autonome par un algorithme¹⁴⁶ ». Cependant, un tel argument soulève la question difficile de savoir qui doit être tenu responsable de la discrimination algorithmique en l'absence de personnalité juridique des systèmes d'IA ? En outre, la répartition de la responsabilité entre les fournisseurs et les utilisateurs d'IA (ceux qui les déploient) est une autre difficulté, car les deux pourraient porter la responsabilité d'un système discriminatoire. Compte tenu des nombreuses sources de biais algorithmique, qu'il s'agisse des données, des caractéristiques des modèles ou de leur mise en œuvre, il est presque impossible d'identifier une cause unique et précise de discrimination algorithmique.

Les questions relatives au champ d'application personnel de la loi sur la non-discrimination : l'inadéquation entre les systèmes algorithmiques et les motifs de discrimination protégés

La dernière série de défis qui se pose concerne l'absence de chevauchement entre le champ d'application personnel des dispositions juridiques en matière de non-discrimination et les formes idiosyncratiques de la subjectivité algorithmique.

La discrimination secondaire et la discrimination indirecte : Les études montrent que la discrimination algorithmique a lieu même lorsque les caractéristiques protégées sont supprimées d'un ensemble de données particulier. En effet, le profilage algorithmique repose sur des points de données qui, combinés, peuvent conduire à un regroupement qui chevauche les groupes protégés. Par exemple, le temps de trajet entre le domicile et le lieu de travail ou le code postal pourrait conduire à des déductions sur le statut socio-économique et l'ethnicité, étant donné la spatialisation existante des inégalités socio-économiques et raciales¹⁴⁷. En particulier, les problèmes de **codage redondant** se posent lorsque les variables d'un ensemble de données sont en corrélation avec une catégorie protégée, par exemple le temps de trajet domicile-travail et l'origine ethnique, qui peuvent être déduits par des algorithmes

¹⁴³ L'équité est un terme philosophique et statistique utilisé pour décrire si un système algorithmique traite différents groupes de manière équitable. Il existe différentes définitions de l'équité (par exemple, tous les groupes obtiennent des taux similaires de faux positifs et de faux négatifs, ou les performances d'un algorithme sont calibrées pour être similaires pour tous les groupes) qui peuvent être incompatibles entre elles. Le terme statistique « équité » et le terme juridique « égalité de traitement » ne se recoupent pas nettement.

¹⁴⁴ Voir Binns R, "Algorithmic Decision-making : A Guide For Lawyers" (2020) 25 Judicial Review 2.

¹⁴⁵ Pablo Martínez-Ramil, "Discriminatory algorithms. A proportionate means of achieving a legitimate aim?" (2022) Journal of Ethics and Legal Technologies 4(1).

¹⁴⁶ Grozdanovski L, 'In search of effectiveness and fairness in proving algorithmic discrimination in EU law' (2021) 58 Common Market Law Review, 99.

¹⁴⁷ Voir Williams BA, Brooks CF et Shmargad Y, « How Algorithms Discriminate Based on Data They Lack : Challenges, Solutions, and Policy Implications » (2018) 8 Journal of Information Policy 78.

d'apprentissage automatique. S'ajoutent à cela les questions de **boucles de rétroaction**, qui décrivent des situations où un système s'appuie sur des données issues de discriminations passées pour établir des prédictions. La discrimination algorithmique a donc de fortes chances de prendre la forme d'une **discrimination secondaire**.

L'article 14 de la CEDH interdit toute discrimination « 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 ». La discrimination indirecte qui repose, par exemple, sur des **données comportementales telles que le temps d'écran, l'utilisation du wifi, les données de géolocalisation**, etc. pourrait donc relever de l'article 14 CEDH **par la voie de la discrimination indirecte**, en démontrant un effet très désavantageux fondé sur l'un des motifs explicitement énumérés¹⁴⁸. **Le problème est que cette discrimination indirecte pourrait échapper à la protection juridique contre la discrimination en raison des difficultés de procédure** exposées dans la section ci-dessus¹⁴⁹.

Les « nouveaux » groupes algorithmiques et la notion d'« autre statut » : **en outre, les algorithmes peuvent créer de nouvelles catégorisations fondées sur des caractéristiques apparemment inoffensives, telles que les préférences du navigateur web ou le numéro d'appartement, ou des catégories plus compliquées combinant de nombreux points de données. Par exemple, un magasin en ligne peut constater que la plupart des consommateurs utilisant un certain navigateur web font moins attention aux prix et décider de faire payer plus cher ces consommateurs. Bien qu'ils ne correspondent pas à des critères protégés par la législation sur la non-discrimination, certains de ces groupes algorithmiques pourraient mériter une protection juridique, par exemple si des modèles de différenciation algorithmique les exposent à un désavantage socio-économique systématique.**

Lorsque la discrimination résultant de certains groupes algorithmiques ne recoupe pas des catégories explicitement protégées par l'article 14 de la CEDH, **la liste non limitative des motifs protégés de l'article 14 et l'approche flexible de la Cour européenne des droits de l'homme (la Cour) à l'égard de la protection des « nouveaux motifs » offrent sans doute une possibilité de protection**¹⁵⁰. Il a été avancé que les clauses anti-discrimination « semi-ouvertes » telles que l'article 14 de la CEDH offrent de meilleures solutions pour remédier à la discrimination algorithmique que les dispositions antidiscriminatoires totalement fermées

¹⁴⁸ La discrimination indirecte pourrait, dans certains cas, être traitée comme une discrimination directe, en fonction de la manière dont sont délimitées la portée et les limites des groupes protégés. Pour une discussion de ce problème dans le cadre de la notion de discrimination directe dans le contexte européen, voir Xenidis R, "Tuning EU Equality Law to Algorithmic Discrimination : Three Pathways to Resilience" (2021) 27 *Maastricht Journal of European and Comparative Law* 736.

¹⁴⁹ Voir, par exemple, Anton Vedder et Laurens Naudts (2017) *Accountability for the use of algorithms in a big data environment*, *International Review of Law, Computers & Technology*, 31:2, 206-224 et Naudts, L. (2019). *How Machine Learning Generates Unfair Inequalities and How Data Protection Instruments May Help in Mitigating Them*. In R. Leenes, R. van Brakel, S. Gutwirth & P. De Hert (Editors), *Data Protection and Privacy : The Internet of Bodies (Computers, Privacy and Data Protection)*.

¹⁵⁰ Voir Gérards, Janneke et Frederik Zuiderveen Borgesius. « Protected Grounds and the System of Non-Discrimination Law in the Context of Algorithmic Decision-Making and Artificial Intelligence. » *Colorado Technology Law Journal*, à paraître (2020).

telles que celles du droit dérivé de l'UE¹⁵¹. Par exemple, la Cour a protégé des groupes sur la base de leur statut professionnel ou de leur lieu de résidence¹⁵². Cette approche ouverte, basée sur la notion d'« **autre statut** », pourrait faciliter l'extension de la portée de nouveaux groupes algorithmiques au titre de l'article 14 de la CEDH. Elle pose pourtant la question des **limites normatives de la législation contre la discrimination** : quels sont ses contours ? À quels types d'injustices est-elle censée s'attaquer ?

En outre, **certains groupes algorithmiques n'ont pas d'importance sociale et il est donc difficile de les considérer comme des groupes méritant d'être protégés par la loi sur la discrimination**¹⁵³. Les « nouveaux » groupes algorithmiques issus d'un regroupement algorithmique intangible font l'objet de distinctions qui ont des effets socio-économiques très tangibles et pourraient former à la longue une **discrimination structurelle « émergente**¹⁵⁴ ». Contrairement aux groupes algorithmiques fondamentaux sur le plan social, ces distinctions échapperont systématiquement à la législation sur l'égalité des chances découlant de la CEDH. Des études récentes ont proposé d'étendre le champ d'application de la législation sur la lutte contre la discrimination pour couvrir ces distinctions algorithmiques préjudiciables¹⁵⁵.

Dès lors se pose un dernier problème relatif au champ d'application de la législation sur l'égalité des chances découlant de la CEDH lorsque la **prise de décision algorithmique brouille les frontières entre l'individu et le groupe**. On s'aperçoit, en particulier, que les modèles fondés sur le groupe sont utilisés pour prendre des décisions concernant les individus. Cela présuppose que l'appartenance à des groupes algorithmiques donnés peut être attribuée à des individus, même si cela n'est pas exact dans les faits. Par exemple, un utilisateur qui correspond au modèle de trafic web typique d'une femme de 25 à 30 ans résidant dans un environnement urbain peut se voir attribuer cette identité de genre et d'âge qui servira de base à une prise de décision ultérieure. Si le groupe algorithmique attribué ne correspond pas à l'identité réelle de l'utilisateur, ce dernier n'aura aucune possibilité de corriger les résultats du profilage algorithmique et du traitement qui en découle. Cependant, l'utilisateur qui a été victime d'une discrimination fondée sur le sexe, par exemple une hausse des prix de l'assurance maladie, peut invoquer une « **discrimination par association** », notion reconnue par la Cour en 2008¹⁵⁶.

La **discrimination intersectionnelle** : enfin, la discrimination algorithmique est susceptible d'être de nature intersectionnelle, c'est-à-dire d'impliquer plusieurs motifs de discrimination ou vecteurs de désavantage¹⁵⁷. En raison de la granularité du profilage algorithmique, les

¹⁵¹ Ibid.

¹⁵² Voir Van der Musselle c. Belgique, requête n° 8919/80 (Cour européenne des droits de l'homme, 23 novembre 1983) et Carson et autres c. Royaume-Uni (2010), [70]-[71].

¹⁵³ Voir Matthias Leese, The new profiling : Algorithms, black boxes, and the fail of anti-discriminatory safeguards in the European Union, 45 SECURITY DIALOGUE 494-511, 501 (2014) ; Monique Mann & Tobias Matzner, Challenging algorithmic profiling : The limits of data protection and anti-discrimination in responding to Emerging discrimination, 6 BIG DATA & SOCIETY, 5-6 (2019).

¹⁵⁴ Ibid.

¹⁵⁵ Voir Wachter S, « The Theory of Artificial Immutability : Protecting Algorithmic Groups Under Anti-Discrimination Law » (2022), Tulane Law Review (à paraître).

¹⁵⁶ Molla Sali c. Grèce requête n° 20452/14 (Cour européenne des droits de l'homme, 19 décembre 2018), [141].

¹⁵⁷ L'exposé des motifs de la Recommandation de politique générale n°14 de l'ECRI [1] indique que la discrimination intersectionnelle est « une situation dans laquelle plusieurs motifs de discrimination interagissent au point de devenir inséparables, leur combinaison créant alors un motif nouveau ».

systèmes d'IA sont capables de déduire plusieurs appartenances sociales protégées et de **regrouper** potentiellement **les utilisateurs en fonction de différentes classifications problématiques**. Par exemple, les profils algorithmiques peuvent contenir des informations concernant le sexe, l'âge, l'origine ethnique, les croyances religieuses, l'orientation sexuelle ou l'identité de genre, sur la base de l'analyse des comportements en ligne, des préférences des consommateurs, etc. L'identification et la correction des cas de discrimination algorithmique intersectionnelle s'avèrent encore plus difficiles que les cas à facteur unique en raison du manque de données désagrégées sur l'égalité, qui ne permet pas de comparer les disparités potentielles entre les résultats algorithmiques et la situation réelle des groupes marginalisés intersectionnellement¹⁵⁸. Les approches de débiaisage montrent également des limites lorsqu'il s'agit de remédier aux conséquences discriminatoires des biais visant les minorités intersectionnelles¹⁵⁹. Dans ce contexte, la discrimination intersectionnelle est souvent passée à travers les mailles du filet des recours judiciaires. Bien que la Cour européenne des droits de l'homme se soit attaquée avec succès (même implicitement) à la discrimination intersectionnelle dans une affaire comme *BS c. Espagne*,¹⁶⁰ elle ne l'a pas reconnue explicitement et n'y a pas remédié dans d'autres affaires comme *SAS c. France* ou *Garib c. Pays-Bas*¹⁶¹. Cette **absence de cadre juridique solide contre la discrimination intersectionnelle**, souvent due à des conceptions formalistes de l'égalité fondées sur la comparaison, se révélera particulièrement problématique dans le contexte de la discrimination algorithmique.

II. Le droit relatif à la vie privée et à la protection des données : équité et exactitude

Outre les instruments juridiques relatifs à l'égalité et à la discrimination, la **législation relative à la vie privée et à la protection des données peut également être mise à profit pour lutter contre la discrimination algorithmique**. Le concept d'équité dans la loi sur la protection de la vie privée concerne l'intention d'une organisation d'utiliser de bonnes fois des informations à caractère personnel dans le but d'équilibrer les intérêts des responsables du traitement des données et des personnes concernées (les individus). On s'accorde généralement à dire, par exemple, que le traitement d'informations à caractère personnel qui est effectué sans que l'intéressé n'en soit avisé ou n'y consente conduirait à une situation injuste aux yeux des régulateurs de la vie privée. **Cependant, l'idée d'équité peut avoir de nombreuses nuances possibles : non-discrimination, juste équilibre, équité procédurale, bonne foi, etc.**

La relation entre discrimination et (in)équité se retrouve dans de nombreux textes législatifs, propositions et documents politiques à travers le monde. La Convention 108+, aux côtés du

Voir également Gerards J et Xenidis R, Algorithmic discrimination in Europe : Challenges and Opportunities for EU Gender Equality and Non-Discrimination Law (European network of legal experts in gender equality and non-discrimination / European Commission, 2021).

¹⁵⁸ La catégorisation des données peut également être problématique et manquer de représentativité, ce qui peut avoir des conséquences sur les tentatives de correction de la discrimination algorithmique. Voir Ruberg, B. et Ruelos, S., « Data for queer lives : How LGBTQ gender and sexuality identities challenge standards of demographics » (2020), *Big Data & Society*, vol.

¹⁵⁹ Balayn A et Gürses S, Beyond Debiasing : Regulating AI and its inequalities (European Digital Rights 2021), 62-63.

¹⁶⁰ B.S. c. Espagne Requête n° 47159/08 (Cour européenne des droits de l'homme, 24 juillet 2012).

¹⁶¹ Voir, par exemple, S.A.S. c. France requête n° 43835/11 (Cour européenne des droits de l'homme, 1^{er} juillet 2014) ou Garib c. Pays-Bas requête n° 43494/09 (Cour européenne des droits de l'homme, Grande Chambre, 6 novembre 2017).

RGPD et de nombreuses autres lois sur la protection de la vie privée, énonce que le responsable du traitement doit, afin d'assurer un traitement équitable et transparent à l'égard de la personne concernée, utiliser des procédures mathématiques ou des statistiques appropriées pour le profilage et mettre en œuvre des mesures techniques et organisationnelles appropriées pour prévenir les risques pouvant nuire aux intérêts et aux droits de la personne concernée. Les risques peuvent inclure la discrimination fondée sur l'origine raciale ou ethnique, les opinions politiques, l'appartenance syndicale, le statut génétique ou l'orientation sexuelle.

L'équité est un principe fondamental selon lequel des données à caractère personnel ne doivent pas être traitées d'une manière préjudiciable, discriminatoire, inattendue ou trompeuse pour la personne concernée. On peut affirmer que l'équité dans la législation sur la protection de la vie privée est liée à la **nécessité de remédier au déséquilibre des pouvoirs entre les personnes concernées (individus) et l'écosystème numérique**. C'est pour cette raison que la législation sur la protection de la vie privée a récemment été assez largement exploitée pour faire face aux méfaits de l'IA et de la prise de décision algorithmique, comme le souligne un rapport publié par le Future Privacy Forum¹⁶². Le rapport met en lumière les mesures prises par les autorités chargées de la protection des données, notamment des obligations de transparence détaillées sur les paramètres qui ont conduit à une décision individuelle automatisée, une lecture large du principe d'équité pour éviter les situations de discrimination, et des conditions strictes pour un consentement valable en cas de profilage et de prise de décision automatisée.

Dans le cadre de cette étude, nous nous intéressons à deux éléments d'équité du point de vue de la vie privée :

- *L'équité en tant que procédures* : la transparence et l'équité sont inextricablement liées parce qu'il est possible de soutenir que l'ouverture du code source à un examen externe ou la fourniture d'une explication significative sur le traitement des informations à caractère personnel par le système d'IA pourrait conduire à l'identification des biais et de leurs causes profondes, et donc à une augmentation positive de la responsabilité publique. Par exemple, la *Corte di Cassazione* italienne a rendu une sentence en 2021 indiquant que le consentement d'une personne concernée ne peut être considéré comme valide si l'algorithme n'est pas transparent, car la personne concernée n'est pas en mesure de comprendre ce à quoi elle consent¹⁶³. Cette affaire a été accueillie favorablement par le régulateur italien de la protection de la vie privée, Garante, qui a estimé qu'elle montrait la manière dont la loi sur la protection de la vie privée (et le RGPD en l'espèce) est apte à défendre les droits des individus à l'ère de l'IA.
- *L'équité en tant que protection des vulnérabilités individuelles* : dans le droit de la vie privée, l'équité est souvent conçue comme un outil de correction visant à rééquilibrer les relations asymétriques ou déséquilibrées entre les organisations et les individus.

¹⁶² AUTOMATED DECISION-MAKING UNDER THE GDPR - A COMPREHENSIVE CASE-LAW ANALYSIS, Future Privacy Forum : <https://fpf.org/blog/fpf-report-automated-decision-making-under-the-gdpr-a-comprehensive-case-law-analysis/>

¹⁶³ *Corte di Cassazione, Civile Ord. Sez. 1 Num. 14381*, ItalgireWeb, 25 May 2021 : <http://www.italgiure.giustizia.it/xway/application/nif/clean/hc.dll?verbo=attach&db=snciv&id=/20210525/snciv@s10@a2021@n14381@tO.clean.pdf> (dernière consultation le 26 mai 2021)

Prenons par exemple le cas des plateformes algorithmiques au sujet desquelles le Conseil d'État français (tel que reformulé par la CNIL) affirme que « [l]a loyauté consiste à assurer de bonne foi le service de classement ou de référencement, sans chercher à l'altérer ou à le détourner à des fins étrangères à l'intérêt des utilisateurs¹⁶⁴ ». À un niveau plus général, dans l'environnement algorithmique, « l'équité pourrait bien représenter une solution au problème des *relations déséquilibrées* entre les contrôleurs d'algorithmes et les utilisateurs¹⁶⁵ ».

Pour de nombreux pays, européens ou non européens, la modernisation de la Convention 108, qui a consisté à introduire de **nouveaux droits pour les personnes concernées dans des contextes de prise de décision algorithmique**, notamment en lien avec l'intelligence artificielle, représente un terrain d'entente, car le traité sert de norme limite sur la manière dont les pays doivent s'y prendre pour protéger le droit à la vie privée de leurs citoyens à l'ère de l'IA. Le RGPD, qui présente de nombreuses similitudes avec la **Convention 108 +** (bien que le Conseil de l'Europe ait une portée et une territorialité beaucoup plus larges que celles de l'UE), contient également des dispositions visant à soutenir les droits individuels dans le contexte de l'IA et des algorithmes, y compris le célèbre article 22, qui protège les individus de la prise de décision automatisée.

Plusieurs autres protections s'appliquent à ces activités de traitement des données, notamment celles qui découlent des principes généraux de traitement des données énoncés à l'article 5, des motifs juridiques du traitement énoncés à l'article 6, des règles relatives au traitement de catégories particulières de données (telles que les données biométriques) énoncées à l'article 9, des exigences spécifiques en matière de transparence et d'accès concernant la prise de décision algorithmique (ADM) énoncées aux articles 13 à 15, et de l'obligation de procéder à des évaluations d'impact sur la protection des données dans certains cas prévue à l'article 35.

Toutefois, les instruments actuels de protection de la vie privée présentent des **limites** lorsqu'il s'agit de l'IA et de la prise de décision algorithmique, notamment :

- L'exercice des droits des personnes concernées dans le contexte de l'IA et de la prise de décision algorithmique est assez complexe. Par exemple, même avec les conseils du groupe de travail 29 sur la protection des données concernant la prise de décision et le profilage individuels automatisés, l'affirmation de l'article 22 du RGPD (« **uniquement** » automatisé, et « **effets juridiques ou similaires significatifs** ») présente des défis pratiques.

La transparence de la gestion algorithmique est le premier pas vers une véritable responsabilisation. Toutefois, les obligations de **transparence et d'explicabilité** relatives à l'atténuation des biais soulèvent des questions concernant l'**intersection des lois sur la protection de la vie privée et sur les secrets commerciaux**. Pour qu'un algorithme soit explicable, il doit avoir un certain degré d'accessibilité, que ce soit par des auditeurs internes ou externes, un organisme de réglementation ou un tribunal. Cependant, l'algorithme propre à une entreprise peut également être couvert par la législation sur les secrets commerciaux. Il existe des développements intéressants dans

¹⁶⁴ Conseil d'État, « Le Numérique et les droits fondamentaux », 2014, p. 273 et 278-281 »

¹⁶⁵ Understanding algorithmic decision-making : Opportunities and challenges, disponible à l'adresse : [https://www.europarl.europa.eu/RegData/etudes/STUD/2019/624261/EPRS_STU\(2019\)624261_FR.pdf](https://www.europarl.europa.eu/RegData/etudes/STUD/2019/624261/EPRS_STU(2019)624261_FR.pdf)

ce sens grâce à l'émergence du calcul multipartite sécurisé qui peut permettre d'interroger une IA sans avoir accès au code réel. Mais on en est encore loin.

III. Les réglementations sectorielles de l'IA : forces et limites de la promotion de l'égalité et de la lutte contre la discrimination

Outre les lois sur la discrimination, la vie privée et la protection des données, les réglementations sectorielles seront également pertinentes pour lutter contre la discrimination algorithmique.

Le Conseil de l'Europe élabore actuellement une réglementation qui traiterai de la discrimination algorithmique dans le cadre d'une initiative visant à promouvoir les droits humains, la démocratie et l'État de droit. Il pourrait s'agir d'un instrument transversal juridiquement contraignant traitant des questions relatives au secteur public, ainsi que de réglementations sectorielles contraignantes et non contraignantes¹⁶⁶. En 2020, le CAHAI a préparé une « **Étude de faisabilité sur un cadre juridique relatif à la conception, au développement et à l'application de l'IA, fondé sur les normes du Conseil de l'Europe** », qui reconnaît que « les systèmes d'IA [peuvent] être utilisés d'une manière qui perpétue ou amplifie les biais injustes, qui sont aussi fondés sur de nouveaux motifs de discrimination en cas de discrimination dite « par procuration¹⁶⁷ ». En même temps, le CAHAI considère que « les systèmes d'IA peuvent promouvoir et renforcer les droits humains de manière plus générale, et contribuer à faire en sorte qu'ils soient respectés et effectivement appliqués », par exemple « en détectant des décisions (humaines ou automatisées) biaisées, en surveillant les modes de représentation de différents groupes (comme les femmes dans les médias) ou en analysant les structures discriminatoires au sein des organisations¹⁶⁸ ».

Dans son document de 2021 intitulé « **Éléments potentiels d'un cadre juridique sur l'intelligence artificielle, fondés sur les normes du Conseil de l'Europe en matière de droits humains, de démocratie et d'État de droit** », le CAHAI recommande d'inclure « une disposition sur le respect de *l'égalité de traitement et de la non-discrimination* des individus en lien avec le développement, la conception et l'application des systèmes d'IA, afin d'éviter que des biais injustifiés ne soient intégrés dans ces systèmes et l'utilisation de systèmes d'IA entraînant des effets discriminatoires » dans la convention-cadre transversale juridiquement contraignante sur la réglementation de l'IA, actuellement en cours d'élaboration¹⁶⁹.

Le CAHAI propose également une réglementation complémentaire pour le secteur public et recommande que « le processus de documentation et de journalisation » relatif au développement du système soit « méticuleusement conservé afin d'assurer la transparence et la traçabilité du système ». Il recommande également que « des processus de test et de validation adéquats, ainsi que des mécanismes de gouvernance des données, soient mis en place » pour évaluer le risque « le risque potentiel d'accès ou de traitement inégal, les

¹⁶⁶ Voir CAHAI, « Étude de faisabilité sur un cadre juridique relatif à la conception, au développement et à l'application de l'IA, fondé sur les normes du Conseil de l'Europe » (2020), [54].

¹⁶⁷ Comité sur l'intelligence artificielle, « Éléments potentiels d'un cadre juridique sur l'intelligence artificielle, fondés sur les normes du Conseil de l'Europe en matière de droits de l'homme, de démocratie et d'État de droit », *Conseil de l'Europe* (2022), [13]

¹⁶⁸ Ibid, [20].

¹⁶⁹ Ibid, [27]

différentes formes de préjugés et de discrimination, ainsi que l'impact sur l'égalité de genre¹⁷⁰ ».

Étant donné que d'autres réglementations sectorielles sont envisagées en Europe, il est important de préciser la **valeur ajoutée d'une réglementation de l'IA au niveau du Conseil de l'Europe**. Il est vrai que la réglementation du Conseil de l'Europe peut avoir **une forte influence au niveau mondial** en raison du grand nombre de ses membres, de son approche particulière fondée sur les droits humains et du fait que l'instrument serait également ouvert à la ratification de parties non étatiques. Le document « Éléments potentiels » du CAHAI fait référence à des normes minimales et une approche axée sur le secteur public, conformément au mécanisme de la Convention européenne des droits de l'homme, ce qui diffère de « l'approche axée sur le marché » adoptée par l'UE dans son projet de législation européenne relative à l'IA¹⁷¹. L'approche fondée sur les risques qu'ils adoptent tous deux pour les systèmes d'IA est une caractéristique commune aux deux règlements¹⁷². Pourtant, le Conseil de l'Europe a la capacité de favoriser une **approche distincte de l'IA et des technologies algorithmiques, fondée sur les droits humains**.

Une réglementation sectorielle de l'IA est également en cours dans l'UE. Le projet de **législation de l'UE** relative à l'IA suit une approche fondée sur le **risque et classe les systèmes d'IA comme « à haut risque »** s'ils sont déployés dans les domaines suivants : identification et catégorisation biométriques des personnes physiques, gestion et exploitation des infrastructures critiques (circulation routière, eau, gaz, chauffage et fourniture d'électricité), éducation et formation professionnelle, emploi, gestion des travailleurs et accès à l'emploi indépendant, accès et jouissance des services privés essentiels et des services et avantages publics, application des lois, migration, asile et gestion du contrôle aux frontières, administration de la justice et processus démocratiques. Les systèmes d'IA qui présentent un **« risque inacceptable »** sont interdits, par exemple « les pratiques qui présentent un risque important de manipuler des personnes par des techniques subliminales agissant sur leur inconscient, ou d'exploiter les vulnérabilités de groupes vulnérables spécifiques tels que les enfants ou les personnes handicapées afin d'altérer sensiblement leur comportement d'une manière susceptible de causer un préjudice psychologique ou physique à la personne concernée ou à une autre personne ». Les systèmes d'IA qui présentent un **risque limité** sont soumis à des obligations de transparence spécifiques et ceux qui présentent un **risque faible ou minime** à des codes de conduite.

Bien que la réglementation de l'UE relative à l'IA prévoit des obligations de transparence prometteuses en vue d'atténuer les biais, en particulier en ce qui concerne les données de formation et les critères de décision¹⁷³, plusieurs **critiques** ont été formulées concernant la manière dont ladite réglementation propose de garantir le respect des droits fondamentaux. Par exemple, elle aborde les systèmes d'IA du point de vue de la responsabilité du fait des

¹⁷⁰ Ibid, [60]

¹⁷¹ Voir Marten Breuer, "The Council of Europe as an AI Standard Setter" *Verfassungsblog* (4 avril 2022) : <https://verfassungsblog.de/the-council-of-europe-as-an-ai-standard-setter/>.

¹⁷² Voir Comité sur l'intelligence artificielle, « Éléments potentiels d'un cadre juridique sur l'intelligence artificielle, fondé sur les normes du Conseil de l'Europe en matière de droits de l'homme, de démocratie et d'État de droit », *Conseil de l'Europe* (2022), [19].

¹⁷³ Voir en particulier l'article 10 sur la gouvernance des données et des données de la réglementation de l'UE sur l'IA.

produits et **ne prévoit donc pas de mécanismes de plainte** qui permettraient **aux victimes de discrimination algorithmique** ou aux ONG ayant un intérêt légitime de **demandeur que des modifications soient apportées à ces systèmes après leur déploiement**, conformément à la loi contre la discrimination¹⁷⁴. En outre, les commentateurs ont critiqué le fait que les fournisseurs et les utilisateurs de systèmes d'IA n'ont pas l'obligation légale **de procéder à des évaluations *ex ante* de l'impact sur les droits humains**¹⁷⁵. L'absence de toute clause d'intégration de l'égalité ou d'obligation positive exigeant que l'IA et les systèmes algorithmiques favorisent l'égalité est également regrettable. **Il s'agit là d'aspects sur lesquels l'instrument du Conseil de l'Europe devrait se concentrer afin de créer une complémentarité avec les réglementations sectorielles de l'IA de l'UE et de garantir que son mandat en matière de droits humains soit au cœur des nouvelles dispositions légales.**

Il est expliqué dans la section 3 ci-dessous que les futures réglementations sectorielles de l'IA au niveau du Conseil de l'Europe devraient également inclure une **obligation légale pour l'IA et les systèmes algorithmiques de promouvoir l'égalité**. La législation norvégienne sur l'égalité pourrait constituer une référence utile dans ce contexte, car elle indique que la promotion de l'égalité doit être considérée comme une obligation légale¹⁷⁶.

Section 3

La promotion l'égalité dans et par l'utilisation de l'IA : le rôle de l'action positive et des obligations positives

Si la section précédente a mis en évidence les instruments juridiques et politiques pertinents du Conseil de l'Europe, de l'UE et au niveau international, elle a également signalé les lacunes, les insuffisances et les incertitudes liées à l'applicabilité de ces instruments au problème de la discrimination algorithmique. Cette section montre que la résolution de ces problèmes passe par un **changement de paradigme**. Nous suggérons d'abord de **revoir les règles existantes à la lumière des nouvelles asymétries de pouvoir et d'information propres aux technologies algorithmiques**. Nous recommandons ensuite que **l'action positive et les obligations positives soient utilisées comme un moyen d'élaborer une obligation juridique de prévenir la discrimination et de promouvoir l'égalité dans et par l'utilisation des systèmes algorithmiques**. L'adoption de ces deux mesures ferait du principe d'« **égalité dès la conception** » **une caractéristique importante de l'approche du Conseil de l'Europe fondée sur les droits humains** visant à lutter contre la discrimination algorithmique.

¹⁷⁴ Voir Joan Lopez Solano, Aaron Martin, Siddharth de Souza et Linnet Taylor, "Governing data and artificial intelligence for all Models for sustainable and just data governance" (Panel pour l'avenir de la science et de la technologie, Service de recherche du Parlement européen 2022), 52 disponible sur [https://www.europarl.europa.eu/RegData/etudes/STUD/2022/729533/EPRS_STU\(2022\)729533_FR.pdf](https://www.europarl.europa.eu/RegData/etudes/STUD/2022/729533/EPRS_STU(2022)729533_FR.pdf).

¹⁷⁵ Voir *ibid.*

¹⁷⁶ Voir le chapitre 4 de la loi norvégienne relative à l'égalité et à l'interdiction de la discrimination (loi sur l'égalité et l'interdiction de la discrimination) : https://lovdata.no/dokument/NLE/lov/2017-06-16-51#KAPITTEL_4.

I. La révision des règles existantes à la lumière des nouvelles asymétries de pouvoir

La présente section a pour objet de définir les moyens de répondre aux questions soulevées à la section 2 en ce qui concerne l'applicabilité des dispositions juridiques existantes.

Premièrement, à la lumière des études actuelles qui montrent qu'en l'absence de protections, le biais algorithmique imprègne systématiquement les décisions algorithmiques, une **présomption de biais algorithmique** pourrait être posée lorsqu'aucune mesure préventive n'a été prise par les utilisateurs des systèmes algorithmiques. La présomption se justifie par l'omniprésence des biais dans le processus de conception des systèmes d'IA, notamment les biais dans la collecte des données et les ensembles de données, les biais dans la conception des problèmes, les modèles algorithmiques et la mise en œuvre des recommandations en matière d'IA¹⁷⁷. Selon Eubanks, « lorsque les outils de décision automatisés ne visent pas explicitement à éliminer les inégalités structurelles, leur vitesse accrue et leur ampleur les aggravent considérablement¹⁷⁸ ». En d'autres termes, la probabilité que la discrimination algorithmique se produise est très grande lorsqu'aucune mesure de protection n'a été mise en place. Lorsqu'elle perpétue l'inégalité, l'utilisation de systèmes d'IA biaisés devrait être comparée à une mise en œuvre active d'un désavantage structurel et à l'amplification de la distribution injuste de biens sociaux essentiels. La **prévisibilité des préjudices discriminatoires découlant d'un biais algorithmique** justifie donc que la discrimination algorithmique soit considérée conceptuellement comme une forme de **négligence**. À cet égard, les travaux de Moreau sur la discrimination et les théories de la discrimination fondées sur la responsabilité civile¹⁷⁹ nous permettent de déduire qu'il existe une **responsabilité sociale pour les utilisateurs de systèmes algorithmiques de prendre des mesures raisonnables pour prévenir l'aggravation de la discrimination** dans la société. Cette approche fait écho aux discussions qui ont lieu actuellement dans le contexte de l'UE et, en particulier, à la proposition de la Commission relative à une « présomption réfragable pour les dommages liés à l'IA¹⁸⁰ ».

Deuxièmement, l'utilisation généralisée des systèmes d'IA crée **de nouvelles asymétries de pouvoir et d'information**. Il devient très **difficile pour ceux qui sont l'objet de décisions algorithmiques d'identifier la discrimination** car elle résulte de la combinaison de la personnalisation, de l'automatisation et de l'opacité des processus décisionnels. La comparaison avec des personnes de même rang et les interactions sociales sont des dispositifs heuristiques importants lorsqu'il s'agit de poser des présomptions de discrimination. Or il devient impossible de prendre connaissance d'indices sociaux ou de se comparer à d'autres demandeurs de prêt dans le contexte d'un service de crédit en ligne. Cette asymétrie

¹⁷⁷ Grozdanovski suggère qu'il est possible de remarquer l'existence d'une telle présomption dans le livre blanc de l'UE sur l'intelligence artificielle. Voir Grozdanovski L, "In search of effectiveness and fairness in proving algorithmic discrimination in EU law" (2021) 58 Common Market Law Review.

¹⁷⁸ Eubanks V, *Automating inequality: how high-tech tools profile, police, and punish the poor* (First edition. edn, St. Martin's Press 2018).

¹⁷⁹ Voir Sophia Moreau, "Discrimination as negligence" (2010) 40 Canadian Journal of Philosophy 123 ; Oppenheimer DB, "Negligent Discrimination" (1993) 141 University of Pennsylvania law review 899.

¹⁸⁰ Voir en ce sens Luca Bertuzzi, « LEAK : La Commission va proposer une présomption réfragable pour les dommages liés à l'IA » (Euractiv, 2022) : <https://www.euractiv.com/section/digital/news/leak-commission-to-propose-rebuttable-presumption-for-ai-related-damages/>.

d'information fait qu'il est difficile de soupçonner une discrimination en premier lieu. Même en cas de suspicion, **la collecte de preuves représente un problème supplémentaire** car les décisions ou les recommandations algorithmiques qui les sous-tendent ne sont pas facilement consultables et souvent non divulguées par les utilisateurs des systèmes de prise de décision algorithmique. Par conséquent, **la présentation de preuves établissant une présomption de discrimination devant les tribunaux est un défi juridique majeur**. Même si le déplacement de la charge de la preuve peut contribuer à atténuer les asymétries de pouvoir créées par des systèmes algorithmiques opaques¹⁸¹, le seuil de déclenchement de ce déplacement devrait tenir compte de la position des utilisateurs finaux et de leur accès limité aux preuves *prima facie*.

Le fait de rapprocher la prévisibilité des biais algorithmiques et les asymétries d'information existantes montre que le déploiement généralisé des systèmes d'IA dans **les processus décisionnels perturbe l'équilibre entre la situation des victimes potentielles de discrimination et celle des fournisseurs et des utilisateurs de ces systèmes**. D'un côté, les victimes font l'objet d'une discrimination généralisée qu'elles ne sont pas actuellement en mesure d'identifier et de prouver, de l'autre, les entreprises à but lucratif jouissent d'un pouvoir accru grâce à des systèmes d'IA qui augmentent leurs profits tout en les dégageant éventuellement de toute responsabilité à l'égard de leurs conséquences discriminatoires en raison des obstacles juridiques énumérés ci-dessus. Il importe donc que **le cadre juridique soit ajusté pour mieux refléter et intégrer les changements de pouvoir et les déséquilibres** qui découlent de l'utilisation des systèmes d'IA dans un large éventail de décisions qui offrent ou non de meilleures chances à chacun et peuvent donc aggraver les inégalités dans la société.

La révision des règles existantes sur la charge de la preuve peut contribuer à restaurer l'efficacité de la législation sur la lutte contre la discrimination à la lumière des nouvelles asymétries de pouvoir et d'information entre les utilisateurs et les sujets des systèmes décisionnels algorithmiques. Poser une présomption de partialité algorithmique (voir ci-avant) permettrait de **transférer la charge de la preuve au défendeur dès lors qu'aucune mesure préventive n'a été prise**. Ces mesures préventives pourraient prendre la forme, par exemple, d'une analyse d'impact, d'un audit ou d'une certification du système algorithmique utilisé (voir la section des recommandations). Le fait de ne pas prendre de mesures préventives adéquates pourrait alors constituer une négligence. Ce mécanisme aiderait les victimes potentielles à présenter des preuves *prima facie* accessibles en vue de renverser la charge de la preuve sur les utilisateurs. Une telle adaptation du cadre juridique **intégrerait également l'action positive** et les **obligations préventives** contre les biais algorithmiques, (voir ci-dessous).

Troisièmement, l'adaptation des règles existantes suggérées ci-dessus devrait être combinée avec une approche de contrôle public¹⁸². À cet égard, il serait bon de **donner aux organismes de promotion de l'égalité, aux médiateurs pour les questions de discrimination et aux institutions nationales de défense des droits humains les moyens de contrôler l'impact discriminatoire des systèmes algorithmiques de prise de décision et des systèmes qui**

¹⁸¹ Voir C-109/88 Handels- og Kontorfunktionærernes Forbund I Danmark v Dansk Arbejdsgiverforening, agissant au nom de Danfoss EU:C:1989:383.

¹⁸² Voir Xenidis R et Senden L, « EU Non-discrimination Law in the Era of Artificial Intelligence : Mapping the Challenges of Algorithmic Discrimination » in Bernitz U and others (eds), *General Principles of EU Law and the EU Digital Order* (Wolters Kluwer 2019).

viennent en soutien. Il s'agit donc de fournir à ces institutions les droits légaux et les pouvoirs d'investigation nécessaires (par exemple, pour accéder aux ensembles de données et aux critères de décision), les ressources adéquates, mais aussi la capacité de prévenir la discrimination en coopérant avec les utilisateurs des systèmes de prise de décision automatisée (par exemple des entreprises qui utilisent ces systèmes à l'appui des procédures de recrutement) afin de collecter des données pertinentes sur l'impact de leurs décisions, et d'aider les victimes potentielles à obtenir réparation. Le contrôle pourrait prendre la forme d'un **test de situation** qui permettrait à ces autorités de tester les résultats d'un système donné en comparant les résultats obtenus pour différents groupes. Elles pourraient par exemple tester des CV ou des demandes de crédit provenant de groupes majoritaires et minoritaires pour détecter une éventuelle discrimination algorithmique dans les contextes où les entreprises utilisent des systèmes de prise de décision automatisée. Les autorités pourraient également effectuer des **audits** pour détecter les biais potentiels si elles ont accès aux systèmes pertinents. Ces méthodes de **contrôle public** pourraient aider les victimes en atténuant les obstacles existants à l'établissement d'une discrimination *prima facie*.

La fonction de contrôle des organismes de promotion de l'égalité doit être renforcée par **des obligations légales en matière de transparence**. Les utilisateurs de systèmes algorithmiques devraient être tenus de **fournir des informations significatives et intelligibles sur les critères utilisés pour la prise de décision**. Pour l'instant, le RGPD n'offre pas de droit à une explication¹⁸³. Dans le domaine des biens et services, la protection des consommateurs devrait également être étudiée en tant qu'outil permettant de demander des informations sur les décisions algorithmiques concernant des personnes qui ont été potentiellement victimes de discrimination. Ce domaine pourrait contribuer à corriger les asymétries de pouvoir créées par l'opacité des systèmes de prise de décision automatisée entre les sujets des décisions algorithmiques et leurs auteurs.

Quatrièmement, il est nécessaire de garantir la possibilité de révision des systèmes algorithmiques à la lumière des obligations de non-discrimination. Lorsque les demandeurs, les avocats ou les juges se voient présenter des informations techniques concernant un système spécifique, il est peu probable que ces informations soient suffisamment intelligibles pour qu'ils puissent déterminer la nature discriminatoire ou non discriminatoire du système. **Les discussions techniques sur l'adéquation des paramètres d'équité donnés et les seuils appropriés des compromis entre l'exactitude et l'équité sont difficiles à évaluer du point de vue des obligations juridiques découlant de la législation contre la discrimination.** Dans ce contexte, comment faire en sorte que les systèmes de prise de décision automatisée soient soumis à un **test de proportionnalité** qui garantisse l'efficacité du droit de la non-discrimination ? Là encore, plusieurs solutions peuvent être envisagées (voir la section des recommandations de cette étude). D'une part, les **obligations de transparence** qui incombent aux utilisateurs des systèmes de prise de décision automatisée pourraient garantir l'accès à un compte rendu intelligible des choix techniques et équitables effectués par les développeurs et les utilisateurs. D'autre part, **l'intégration de l'action positive** pourrait conduire à une **obligation positive de prévenir les biais algorithmiques qui déplacerait l'évaluation de la proportionnalité du terrain technique au terrain juridique**. Dans ce cas, les juges

¹⁸³ Voir Wachter, Sandra, Brent Mittelstadt, and Luciano Floridi. "Why a right to explanation of automated decision-making does not exist in the general data protection regulation." *International Data Privacy Law* 7.2 (2017): 76-99.

examineraient plutôt la pertinence des mesures préventives prises pour éviter les biais que les choix techniques en faveur de l'équité.

Enfin, nous suggérons que **l'obligation juridique, en tant que notion judiciaire se rapprochant de la responsabilité, devrait être répartie stratégiquement afin de faciliter l'accès à la justice et aux recours** dans les cas de discrimination algorithmique. Dans le contexte de la CEDH et d'autres instruments juridiques du Conseil de l'Europe, qui imposent des obligations aux autorités publiques, nous suggérons que **les États parties tiennent les utilisateurs des systèmes d'IA responsables de la discrimination algorithmique découlant du déploiement de leur système**. La section consacrée aux recommandations explique que **cette responsabilité peut être complétée par l'obligation juridique faite aux prestataires de procéder à des évaluations *ex ante* de l'impact sur les droits humains afin de prévenir les préjudices discriminatoires**. Un tel dispositif permettra également d'encourager la **consignation de toutes les mesures préventives** prises par le fournisseur afin que **des informations essentielles puissent être fournies à l'utilisateur et aux utilisateurs finaux** du système en cas de procédure judiciaire.

L'approche proposée ici, qui s'articule autour d'une présomption de biais algorithmique, de négligence et de prévention, pourrait contribuer à la sécurité juridique et à l'efficacité des dispositions antidiscriminatoires de la CEDH en allégeant la charge de la preuve des victimes, en favorisant les garanties préventives, en clarifiant la répartition des responsabilités et en aidant à mieux définir les justifications auxquelles les défenseurs peuvent avoir accès. Dans l'ensemble, nous suggérons qu'**une approche plus substantielle de l'égalité devrait guider l'interprétation des dispositions antidiscriminatoires** afin de préserver leur efficacité dans le contexte de la discrimination algorithmique.

II. Une obligation de promouvoir l'égalité dans et par l'utilisation de systèmes algorithmiques : le rôle de l'action positive et des obligations positives

Ce rapport a montré comment les systèmes d'IA, sans les garde-fous et les contrôles appropriés, peuvent conduire à une plus grande exclusion des groupes vulnérables. Malgré le potentiel discriminatoire de l'IA, les chercheurs et les développeurs ont étudié les possibilités offertes par l'IA pour déterminer et corriger les inégalités. L'analyse nécessite un **changement de paradigme dans lequel les bases de la conception et du déploiement des logiciels sont systématiquement remises en question et vérifiées par rapport à leur impact en matière d'inclusion ou d'exclusion**. En d'autres termes, le déploiement d'un nouveau système d'IA devrait être « délibérément et intentionnellement inclusif » et « doit autonomiser les communautés et présenter un avantage pour toute la société¹⁸⁴ ». Pour ce faire, il faut que les entreprises soient tenues de respecter une série d'obligations, ainsi qu'un ensemble de contrôles avant et après la mise sur le marché. Selon nous (voir ci-après), un tel changement de paradigme exige que le vaste éventail de mesures d'action positive disponibles, notamment

¹⁸⁴ Renee Cummings, "[This is how AI can support diversity, equity and inclusion](https://www.weforum.org/agenda/2022/03/ai-support-diversity-equity-inclusion/)", World Economic Forum: <https://www.weforum.org/agenda/2022/03/ai-support-diversity-equity-inclusion/>. Voir aussi Equality Now, A Call For An Intersectional Feminist Informed Universal Declaration On Digital Rights : https://www.equalitynow.org/news_and_insights/universal-declaration-on-digital-rights/.

la sensibilisation, les mesures basées sur la promotion, les mesures temporaires spéciales et les quotas, soit utilisé à des fins d'égalité, de diversité et d'inclusion dans tous les domaines.

L'éradication des biais et des inégalités impose de faire un choix conscient, sans doute politique et social. Dans un premier temps, il convient d'admettre que les systèmes d'IA ne sont pas neutres mais reproduisent et amplifient les inégalités structurelles et les systèmes d'exclusion et de désavantage qui sont institutionnalisés dans la société. Il faut donc s'éloigner du point de vue de l'auteur de la discrimination et reconnaître au contraire que les normes prédominantes et les hypothèses incontestées qui sous-tendent le développement et le déploiement des logiciels empêchent de prendre en compte les besoins des groupes minoritaires¹⁸⁵. Le fait de supposer qu'un système répondra de manière égale aux besoins de différents groupes empêchera *de facto* les groupes minoritaires de bénéficier des applications de l'IA et des opportunités qui y sont liées dans la même mesure que les autres groupes. Par conséquent, **l'égalité réelle et la lutte contre la discrimination « dès la conception » devraient être placées au centre de la réglementation juridique du développement et du déploiement de l'IA.**

1) Qu'est-ce qu'une action positive ?

L'action positive, également appelée mesures temporaires spéciales ou mesures positives dans le contexte européen, est une série de politiques qui peuvent être adoptées en vue de parvenir à l'égalité totale ou *de facto*. Elle s'appuie sur une critique de l'égalité formelle ou de l'égalité des chances qui dénonce l'aveuglement de ces cadres vis-à-vis des différentes situations de départ des différents groupes sociaux. Par exemple, donner la même possibilité d'emploi à un travailleur handicapé et à un travailleur valide pourrait conduire à un taux d'abandon plus élevé dans le premier cas parce qu'aucune mesure d'adaptation n'a été prise pour que le travailleur handicapé soit effectivement capable d'accomplir ses tâches. En revanche, l'ancrage de politiques dans les théories de l'égalité réelle exige l'adoption de mesures d'accommodement spéciales qui créent des conditions permettant aux groupes historiquement défavorisés de participer à la société et de récolter les bénéfices de cette participation au même titre que les groupes privilégiés. Il s'agit concrètement de veiller à ce qu'un travailleur vivant avec un handicap puisse accéder à un environnement de travail physique et psychologique sûr et adapté, par exemple grâce à des équipements spéciaux, des horaires de travail flexibles, etc. Les théories dites de l'égalité transformative vont dans le même sens, mais mettent davantage l'accent, d'un point de vue conceptuel, sur la transformation du statu quo inégalitaire à long terme, par exemple en accordant des avantages spécifiques et temporels aux groupes structurellement défavorisés. Un exemple de ces politiques d'égalité est constitué par les systèmes de quotas flexibles selon lesquels, par exemple, un employeur confronté à des candidats masculins et féminins également qualifiés dans un processus de recrutement donnera la préférence à la candidate féminine lorsque les femmes sont sous-représentées dans la communauté professionnelle concernée.

¹⁸⁵ Pour un compte rendu éloquent du point de vue de l'agresseur sur la discrimination par rapport à la compréhension de la discrimination comme un phénomène structurel, voir par exemple Freeman AD, « Legitimizing Racial Discrimination Through Anti-discrimination Law : A Critical Review of Supreme Court Doctrine" (1978) 62 Minnesota Law Review. La distinction a été reconnue par la loi à travers la notion de discrimination indirecte.

Dans le contexte du Conseil de l'Europe, l'action positive n'est pas une obligation juridique, mais elle a été encouragée par la Commission européenne contre le racisme et l'intolérance (ECRI) qui estime qu'il s'agit d'un « outil efficace pour parvenir à des conditions équitables dans la société pour les membres des groupes défavorisés¹⁸⁶ ». Dans l'UE, la législation sur la non-discrimination autorise les mesures spéciales dans le cadre de l'action positive, dans certaines limites telles que l'interdiction d'un quota strict qui donnerait une préférence automatique aux groupes sous-représentés et la nécessité pour les mesures spéciales de viser à transformer le statu quo à long terme¹⁸⁷. La définition de l'action positive dans le contexte du Conseil de l'Europe et de la Convention européenne des droits de l'homme est similaire. La notion de « mesures temporaires spéciales » est souvent utilisée. La Recommandation de politique générale n°7 de l'ECRI indique par exemple que « [l]a loi doit prévoir que l'interdiction de la discrimination raciale n'empêche pas de maintenir ou d'adopter des mesures spéciales temporaires destinées à prévenir ou à compenser les désavantages subis par [les groupes protégés] ou à faciliter leur pleine participation dans tous les domaines de la vie¹⁸⁸ ». Elle indique également que "[c]es mesures ne doivent pas être maintenues une fois atteints les objectifs visés¹⁸⁹ ».

2) Les obligations positives découlant de la CEDH

Pour aborder la question de savoir comment promouvoir l'égalité dans et par l'utilisation de l'IA, la base juridique exposée ci-dessus, qui autorise l'action positive, peut être examinée conjointement avec une autre caractéristique spécifique importante de la CEDH qui est la notion d'**obligations positives**. Ces obligations impliquent que les États ont, dans certaines circonstances, le devoir de prendre activement des mesures pour parvenir à l'égalité et prévenir la discrimination¹⁹⁰. Elles vont plus loin que les obligations passives ou négatives limitées de ne pas discriminer, parce qu'elles imposent de prendre des mesures préventives contre la discrimination ou des mesures d'action positive pour promouvoir l'égalité comme moyen de se conformer à l'article 14 de la CEDH.

Dans sa Recommandation de politique générale n° 7, l'ECRI souscrit spécifiquement aux obligations positives de promouvoir l'égalité et de prévenir la discrimination sous la forme de dispositions constitutionnelles, d'obligations pour les autorités publiques, ainsi que d'obligations pour les organismes publics de conditionner l'attribution de marchés, de prêts, de subventions ou d'autres avantages au respect de l'obligation positive de promouvoir l'égalité et de prévenir la discrimination¹⁹¹. Ces obligations peuvent être utilisées comme base

¹⁸⁶ Commission européenne contre le racisme et l'intolérance, Séminaire réunissant les organismes nationaux spécialisés dans la lutte contre le racisme et la discrimination raciale sur l'action positive : note explicative (2007) : <https://rm.coe.int/seminar-with-national-specialised-bodies-to-combat-racism-and-racial-d/16808b54b0>.

¹⁸⁷ Pour un compte rendu détaillé, voir Raphaële Xenidis et Hélène Masse-Dessen, " Positive action in practice : some dos and don'ts in the field of EU gender equality law " (2018) 2 European equality law review 36.

¹⁸⁸ Recommandation de politique générale n° 7 de l'ECRI sur la législation nationale pour lutter contre le racisme et la discrimination raciale (2002), [5].

¹⁸⁹ Ibid.

¹⁹⁰ Voir Cour européenne des droits de l'homme, Guide sur l'article 14 de la Convention (interdiction de la discrimination) et sur l'article 1 du Protocole n° 12 (interdiction générale de la discrimination) (2022), [42-43] : https://www.echr.coe.int/Documents/Guide_Art_14_Art_1_Protocol_12_FRA.pdf. Voir aussi, par exemple, Cour européenne des droits de l'homme, requête n° 34369/97 *Thlimmenos c. Grèce* (2 avril 2000) et Cour européenne des droits de l'homme, requête n° 11146/11 *Horváth et Kiss c. Hongrie* (29 janvier 2013).

¹⁹¹ Ibid, [2], [8] et [9].

juridique pour créer une obligation d'intégration de l'égalité dans le contexte de l'utilisation de l'IA par les autorités publiques.

Les obligations positives et l'action positive constituent un socle juridique intéressant pour utiliser l'IA afin de promouvoir l'égalité à deux égards. On peut en effet considérer que les obligations positives de prévention de la discrimination doivent imposer aux États de recourir à des actions positives afin de créer des garanties pour empêcher l'apparition de biais algorithmiques illégaux à n'importe quel niveau du cycle de vie de l'IA. On peut aussi estimer que les obligations positives de promouvoir l'égalité sont une obligation pour les États d'investir dans l'utilisation des nouvelles opportunités créées par l'IA pour mieux servir les communautés défavorisées afin qu'elles puissent jouir pleinement des droits garantis par la CEDH. Les paragraphes suivants présentent des stratégies pour y parvenir.

3) La nécessité de recentrer l'action positive

L'action positive est **une condition *sine qua non*** pour utiliser l'IA à bon escient. Elle peut prendre de nombreuses formes, notamment des mesures de soutien telles que la diffusion d'informations auprès des communautés ciblées, des programmes de formation et de financement ciblés, des mesures spéciales temporaires et des systèmes de quotas flexibles¹⁹². Il faudrait par exemple que les principales priorités incluent la **diversification** des communautés éducatives et professionnelles impliquées dans toutes les phases du développement et du déploiement des applications de l'IA, grâce à un soutien financier et à des efforts de sensibilisation. La diversification peut s'inscrire dans le cadre d'un effort plus large visant à attirer et à retenir davantage de femmes et de personnes issues de communautés marginalisées dans les domaines STIM.

Si nécessaire, des mesures spéciales temporaires et des systèmes de quotas flexibles seront utilisés pour assurer la parité et l'inclusion dans les communautés éducatives et professionnelles. Des mesures d'action positive sous la forme, par exemple, de mesures spéciales d'hébergement et de lutte contre les stéréotypes devraient viser à rendre ces environnements plus inclusifs afin de fidéliser les groupes minoritaires à long terme et de réduire les taux d'abandon scolaire.

La **formation** de ces communautés doit passer par une transformation des programmes d'enseignement et l'adoption d'une approche des questions éthiques, des obligations juridiques et des sciences sociales en matière de discrimination et d'inégalité faisant partie intégrante de l'enseignement supérieur et professionnel. Il faudrait également que des formations complémentaires soient dispensées régulièrement aux experts, aux parties prenantes et aux communautés professionnelles du secteur de l'IA, sur une base *ad hoc* ou en tant que formation continue. Cette formation doit aborder des questions telles que les inégalités structurelles, l'intégration de la dimension de genre et les stéréotypes.

Une approche centrée sur l'égalité réelle et l'action positive pourrait également nécessiter l'adaptation des dispositions juridiques existantes. En effet, à mesure que l'émergence des nouvelles technologies déplace la dynamique du pouvoir entre les utilisateurs et les sujets des systèmes d'IA, les arrangements judiciaires et les dispositions normatives qui sous-tendent les règles juridiques deviennent instables. Rééquilibrer ces asymétries de pouvoir

¹⁹² Voir Christopher McCrudden, Resurrecting positive action (2020) 18(2) *International Journal of Constitutional Law*, 429.

implique donc d'adapter l'architecture juridique. Il est expliqué ci-après que les règles relatives au renversement de la charge de la preuve pourraient être allégées pour les victimes de discrimination algorithmique en posant une présomption de partialité algorithmique¹⁹³. Une telle présomption pourrait être envisagée tant que les usagers d'un système d'IA n'ont pas mis en place de mesures de protection contre la discrimination, c'est-à-dire tant qu'ils supposent que les systèmes d'IA sont neutres vis-à-vis des groupes protégés. On verra ci-après que les protections appropriées peuvent prendre plusieurs formes telles que des audits, des certifications, des évaluations de l'impact sur l'égalité. De plus amples détails sur cette proposition d'adaptation juridique sont présentés à la section 4.

4) L'utilisation de l'analyse des données pour détecter les discriminations

Une deuxième possibilité pour l'IA d'être utilisée pour promouvoir l'égalité consiste à exploiter les capacités de l'analyse des données pour détecter les modèles discriminatoires dans l'allocation des ressources, la diffusion de l'information, la représentation des groupes ou la performance de systèmes donnés. Plusieurs exemples montrent que l'analyse des données peut également être utilisée pour débusquer les mauvais modèles et les pratiques finales qui reproduisent les préjugés. Par exemple, les technologies de reconnaissance d'image de l'IA pourraient être utilisées pour analyser de grandes quantités de données et évaluer les représentations des femmes et des minorités dans différents secteurs des médias, des programmes télévisés aux films, en passant par la publicité en ligne et physique, etc. Dans le domaine de la modération de contenu, l'IA a été utilisée pour détecter les discours haineux afin de signaler et de supprimer les contenus offensants¹⁹⁴. Dans le même temps, il faut absolument éviter que ce déploiement de l'IA ne réduise au silence les groupes minoritaires¹⁹⁵. Détecter automatiquement les propos discriminatoires dans les offres d'emploi pourrait également être un moyen de mettre l'IA au service de la promotion de l'égalité. En allant encore plus loin, les systèmes de recommandation pourraient être utilisés pour recommander un langage inclusif alternatif pour remplacer le contenu discriminatoire des offres d'emploi.

5) L'IA comme moyen de rendre des services aux communautés défavorisées et d'améliorer l'accessibilité

Au-delà de la détection, les systèmes d'IA peuvent également être développés à dessein pour rendre des services aux communautés marginalisées, à risque ou défavorisées. Ils peuvent être utilisés, par exemple, pour améliorer l'accessibilité aux informations ou aux biens et services existants. Le recours à des systèmes automatisés de traduction dans les langues régionales ou minoritaires qui ne sont parlées que par un petit nombre de personnes améliorerait l'accès à des services essentiels. L'IA pourrait également servir à promouvoir

¹⁹³ À ne pas confondre avec une présomption de discrimination algorithmique, car un tel biais pourrait ou non être discriminatoire. Pour d'autres suggestions sur l'allègement de la charge de la preuve en matière de discrimination algorithmique, voir Janneke Gerards et Raphaële Xenidis, *Algorithmic discrimination in Europe : Challenges and Opportunities for EU Gender Equality and Non-Discrimination Law* (Réseau européen d'experts juridiques dans le domaine de l'égalité des genres et de la non-discrimination / Commission européenne, 2021) et AlgorithmAudit, White Paper : Reversing the burden of proof in the context of (semi-)automated decision-making (2022) : <https://drive.google.com/file/d/1RHdqqGVgww-FTv8qC9fAlsVI8eUTcR7s/preview>.

¹⁹⁴ Commission européenne contre le racisme et l'intolérance, Recommandation de politique générale n° 15 sur la lutte contre les discours de haine CRI(2016)15, [140] : <https://rm.coe.int/recommandation-de-politique-generale-n-15-de-l-ecri-sur-la-lutte-contr/16808b5b03>. [en français]

¹⁹⁵ Voir par exemple les effets sexistes et racistes de la modération automatique du contenu : Gerrard Y et Thornham H, "Content moderation : Social media's sexist assemblages" (2020) 22 1266.

l'égalité dans le secteur pénal et policier, par exemple lorsqu'elle est utilisée pour prévenir les risques de violence sexiste, comme en Espagne avec le logiciel VioGen. Dans le secteur de la santé, l'IA pourrait être utilisée pour améliorer l'accès aux soins dans les zones défavorisées et renforcer les capacités de diagnostic des groupes traditionnellement sous-représentés.

La condition de ces utilisations positives de l'IA est cependant de mobiliser des ressources au profit de la diversification et de la formation des communautés professionnelles impliquées dans son développement et son utilisation et de prendre des mesures d'action positive pour garantir que ces systèmes sont au service des groupes marginalisés. Dans le même temps, le « technosolutionnisme » devrait être évité et l'IA ne devrait pas être perçue comme une panacée pour résoudre le problème de la discrimination. Il est essentiel de se rappeler que les questions sociales nécessitent une approche sociale, et non une approche purement technologique. Si l'IA peut certainement être développée et utilisée pour promouvoir l'égalité, il est important de la considérer comme un outil complémentaire dans le cadre de politiques d'égalité financées comme il se doit et mûrement réfléchies. Ce changement de paradigme impose de réfléchir à l'adoption d'une nouvelle approche.