

# Prêtez attention : un appel à réglementer le marché de l'attention et à prévenir la gouvernance émotionnelle algorithmique

**Franck Michel**

University Côte d'Azur, CNRS, Inria  
franck.michel@inria.fr

**Fabien Gandon**

University Côte d'Azur, CNRS  
fabien.gandon@inria.fr

## Abstract

Au cours des 70 dernières années, nous, humains, avons créé un marché économique où l'attention est captée et transformée en revenus grâce à la publicité. Au cours des deux dernières décennies, en s'appuyant sur la recherche en psychologie, en sociologie, en neurosciences et d'autres domaines, les plates-formes web ont porté le processus de captation de l'attention à une échelle sans précédent. Avec l'objectif initial banal de rendre la publicité ciblée plus efficace, la généralisation des techniques de captation de l'attention et l'utilisation qu'ils font des biais cognitifs et des émotions ont de multiples effets secondaires délétères tels que la polarisation des opinions, la diffusion de fausses informations et la menace pour la santé publique, les économies et les démocraties. Il s'agit clairement d'un cas où le web n'est pas utilisé pour le bien commun et où, en fait, tous ses utilisateurs deviennent une population vulnérable. Cet article rassemble des contributions provenant d'un large éventail de disciplines afin d'analyser les pratiques actuelles et leurs conséquences. À travers un ensemble de propositions et de principes qui pourraient servir de base à d'autres travaux, il appelle à des actions contre ces pratiques qui rivalisent pour capter notre attention sur le web, car il serait insoutenable pour une civilisation de permettre que l'attention soit ainsi gaspillée en toute impunité à l'échelle mondiale.

## 1 Un insoutenable marché de l'attention

Depuis l'avènement des marchés de masse dans les années 50, les médias et les publicitaires n'ont eu de cesse de trouver des méthodes efficaces pour capter notre attention et la transformer en revenus. Au cours des deux dernières décennies, soutenus par les avancées en intelligence artificielle (IA), les médias sociaux en ligne et les grandes plates-formes du web ont porté ce processus de captation de l'attention à une échelle sans précédent. Basé presque exclusivement sur les recettes publicitaires, leur modèle économique consiste à fournir des services gratuits qui, en retour, collectent des traces comportementales. Ces données sont ensuite utilisées pour maximiser l'impact des publicités sur les utilisateurs ① en s'assurant de l'adéquation d'une publicité à leurs goûts, leurs inclinations et leur humeur (la publicité ciblée), et ② en s'assurant de leur disponibilité mentale au moment où la publicité leur est montrée.

Sur la base de recherches en psychologie, sociologie et neurosciences, plusieurs acteurs dont les réseaux sociaux et les jeux, ont mis au point des techniques capables de piller très efficacement notre "temps de cerveau disponible" [37, 27]. Nous pouvons distinguer deux grandes catégories parmi ces techniques. Premièrement, certaines techniques sont explicitement conçues pour **exploiter les biais cognitifs** afin de capter l'attention. Par exemple, les "likes" recueillis après la publication d'un contenu activent les voies dopaminergiques du cerveau (impliquées dans le système de récompense) et exploitent notre besoin d'approbation sociale, en nous procurant des "signaux lumineux de pseudo-plaisir" [37] ; les notifications des applications alimentent notre appétit pour la nouveauté et la surprise, de sorte qu'il est difficile de résister à l'envie de les consulter ; le mécanisme "pull-to-refresh" [37], semblable à celui des machines à sous, exploite le principe de *récompense variable* selon lequel chaque fois que nous abaïssons l'écran ("swipe down"), nous pouvons obtenir une nouvelle information, ou rien du tout ; le flux infini (d'actualités, de messages ou de vidéos...) nous piège en raison de notre peur de manquer des informations importantes (FOMO<sup>1</sup>) au point que nous pouvons difficilement interrompre le flux ; l'enchaînement automatique de vidéos remplace une action requise pour continuer à visionner, par une action requise pour arrêter de visionner, et entraîne un sentiment frustrant d'incomplétude lorsqu'on l'arrête ; etc. De même, certaines techniques exploitent des *dark patterns*<sup>2</sup> [26] pour manipuler les utilisateurs afin qu'ils prennent des mesures ou des décisions qu'ils n'auraient pas prises autrement. C'est typiquement le cas lorsqu'on accepte toutes les notifications d'une application sans vraiment s'en rendre compte, alors que le rejet des notifications nécessiterait une action supplémentaire, moins intuitive.

Deuxièmement, les progrès récents dans le domaine de l'apprentissage automatique permettent l'entraînement d'**algorithmes de recommandation de contenu** sur de grandes quantités de données comportementales en ligne. Ces algorithmes apprennent à recommander des contenus qui non seulement captent l'attention mais augmentent également l'engagement utilisateur<sup>3</sup>. Ils découvrent les principales car-

<sup>1</sup>FOMO: Fear Of Missing Out

<sup>2</sup>Définition légale en Californie: "A user interface is a dark pattern if the interface has the effect of substantially subverting or impairing user autonomy, decision-making, or choice. A business's intent in designing the interface is not determinative in whether the user interface is a dark pattern, but a factor to be considered." CPRA §7004(c)

<sup>3</sup>Dans le contexte des réseaux sociaux, l'engagement utilisateur

actéristiques du contenu qui permettent de prédire si celui-ci attirera effectivement l'attention des utilisateurs, et finissent généralement par sélectionner des contenus liés à la conflictualité, la peur ou la sexualité [10]. Ils apprennent également à exploiter le biais de négativité [60, 58] et, par conséquent, les contenus véhiculant des émotions négatives de forte intensité (telles que la colère, le ressentiment, l'indignation et le dégoût) sont plus susceptibles d'être lus et éventuellement partagés en ligne que ceux qui véhiculent d'autres émotions [50, 35]. Il est assez inquiétant de constater que les fausses informations (un terme générique qui inclut la désinformation et d'autres formes de mésinformation) s'appuient généralement sur ces émotions négatives pour favoriser le partage. Enfin, les systèmes de recommandation agissent sans que rien de tout cela ne soit explicite ni dans les caractéristiques qu'ils sélectionnent, ni dans le retour d'information succinct que certains d'entre eux fournissent<sup>4</sup>.

La quantité d'attention disponible étant à la fois limitée et précieuse, il serait insoutenable pour une civilisation de permettre qu'elle soit impunément gaspillée à des fins discutables ou futiles [10]. Aujourd'hui, nous nous trouvons peut-être précisément à cet instant : alors que le temps mental est devenu un nouveau pétrole, nous avons créé une économie et un marché de l'attention [28, 29] qui, bien que soutenables d'un point de vue économique, pourraient être insoutenables d'un point de vue civilisationnel. À partir de ces premières références, définissons ce à quoi le terme "marché de l'attention" fait référence dans cet article.

**Définition 1.1 (Marché de l'attention)** *Environnement économique dans lequel les entreprises rivalisent pour capturer et conserver la ressource que représente l'engagement mental focalisé des utilisateurs, que nous appelons l'attention.*

Le marché de l'attention traite l'attention comme une marchandise négociable et implique de multiples acteurs : des producteurs (les humains dont l'attention est la ressource) aux créateurs de contenu dont le travail est utilisé pour capter l'attention, en passant par les courtiers qui échangent et monétisent l'attention et les consommateurs qui l'utilisent à leurs propres fins, par exemple pour exposer les utilisateurs à des publicités.



Dans cet article, nous proposons une discussion visant à stimuler l'introspection et le débat au sein de la communauté de recherche en informatique. Dans la lignée du Web Science Manifesto [6] appelant à des approches interdisciplinaires pour préparer l'avenir du web, nous rassemblons et synthétisons les conclusions de plus de 70 articles et ouvrages issus d'un large éventail de disciplines pour anal-

traduit le fait qu'un utilisateur interagit avec un contenu, par exemple en le "likant", en le commentant ou en le repostant. L'engagement est généralement public en ce sens qu'il laisse des traces publiques sur la plate-forme, contrairement à la consommation pure de contenu qui reste, normalement, privée [50].

<sup>4</sup>Par exemple, un système de recommandation peut nous dire "vous avez aimé ce film, vous aimerez peut-être aussi celui-ci". Mais nous ne savons pas quelles caractéristiques ont été sélectionnées pour recommander cet autre film : les deux films ont-ils un acteur en commun ? Mes contacts les ont-ils aimés tous les deux ? etc.

yser les pratiques et les dérives de ces systèmes destinés à capter l'attention à l'échelle mondiale. Nous montrons que, avec l'objectif initial banal de rendre la publicité ciblée plus efficace, la généralisation des techniques de captation de l'attention et l'utilisation qu'elles font des émotions négatives tendent à favoriser la radicalisation et la polarisation des opinions, à amplifier la diffusion de fausses informations, à favoriser l'émergence du populisme, et finalement à menacer les démocraties et les sociétés humaines en général [9, 10].

En favorisant la prise de conscience de ces problèmes, cet article est directement lié à certains des *Objectifs Développement Durable* des Nations Unies (ODD). L'ODD 16 "Paix, Justice et Institutions Fortes"<sup>5</sup> puisque l'article propose des actions pour lutter contre l'instrumentalisation des émotions négatives, les fausses informations qui augmentent mécaniquement le niveau de colère et de ressentiment parmi les populations, et qu'il promeut des "sociétés qui respectent le droit (...) à la liberté d'expression et à l'accès à l'information"<sup>6</sup>. En soulignant la montée des populismes à l'échelle mondiale, il aborde la question connexe de la manière de renforcer les institutions. Il est également pertinent au regard de l'ODD 3 "Bonne santé et bien-être", compte tenu des effets aggravants des réseaux sociaux sur la santé mentale, et des problèmes de santé publique causés par les fausses informations (comme lors de la pandémie de Covid-19).

Jusqu'à présent, les recherches publique et privée en informatique ont déployé des efforts considérables pour traiter certains aspects du problème tels que la radicalisation, les discours violents et les fausses informations. Ces travaux s'appuient sur des mesures *post hoc* telles que la détection de contenu, la suppression ou le déclassement. Néanmoins, nous soutenons que des mesures supplémentaires doivent être envisagées pour prévenir activement les problèmes qui découlent de la captation de l'attention, plutôt que de se contenter d'atténuer leur impact une fois qu'ils se sont produits. On peut supposer que ces mesures seront autant politiques que techniques, ce qui signifie que cette situation sociotechnique problématique appelle des solutions sociotechniques. Et bien que les mesures ne soient pas nécessairement associées à des opportunités de recherche immédiates pour la communauté des chercheurs en informatique, nous pensons que les impacts potentiels sont suffisamment cruciaux pour que la communauté soit pleinement consciente de cette réflexion et y participe activement.

Dans la suite de cet article, nous examinerons tout d'abord les principes généraux des systèmes de recommandation et les conséquences de la boucle de recommandation qu'ils mettent en œuvre (section 2). Ensuite, nous expliquerons comment le fait que les systèmes de recommandation exploitent les émotions peut conduire à des situations préjudiciables, y compris ce que nous appellerons une gouvernance émotionnelle algorithmique (section 3). Nous évoquerons la menace qui pèse sur les emplois créatifs (section 4), puis nous passerons en revue certaines mesures *post hoc* connues (section 5), avant d'aborder les mesures préventives destinées à reconquérir notre attention (section 6).

<sup>5</sup><https://www.un.org/sustainabledevelopment/>

<sup>6</sup><https://www.un.org/sustainabledevelopment/peace-justice/>

## 2 Les utilisateurs dans la boucle... des systèmes de recommandation

Les algorithmes de recommandation de contenu sont un élément clé d'un large éventail d'applications, notamment les médias sociaux, les moteurs de recherche et les principales plate-formes du web en général. Dans de nombreuses applications, ils ont changé notre vie en nous aidant à être plus efficaces, en nous assistant dans nos tâches quotidiennes ou en améliorant notre éducation et notre information. Dans un certain nombre d'autres applications cependant, la réalité n'est pas aussi radieuse. Dans le cas des médias sociaux, par exemple, ces algorithmes nous sont présentés comme s'ils étaient conçus pour nous fournir un contenu correspondant à nos besoins et à nos désirs, alors qu'ils cherchent en réalité à maximiser l'attention que nous portons à leur plateforme d'hébergement et aux publicités qui s'y rapportent.

Grâce au processus d'apprentissage, les algorithmes de recommandation apprennent automatiquement à sélectionner les caractéristiques du contenu qui captent le plus efficacement notre attention et maximisent notre engagement continu sur la plate-forme. Par exemple, ils peuvent apprendre que certaines catégories de sujets, comme la conflictualité, la peur ou la sexualité, attirent irrésistiblement notre attention [10], et donc pencher vers la recommandation de ces catégories particulières. Ils peuvent également apprendre à sélectionner un contenu adapté à un utilisateur donné en tenant compte des caractéristiques du contenu (sujets, source, émotions véhiculées...) et de son adéquation avec le profil de l'utilisateur (intérêts, inclinations, comportement antérieur...). Cette adéquation inclut probablement de nombreuses autres caractéristiques dont la liste et l'utilisation sont rarement transparentes, car aucune des grandes plate-formes ne fournit aux utilisateurs des explications sur la manière dont leur fil personnalisé a été composé et dans quel but. C'est ce que souligne une étude de DeVito [18] qui a analysé les brevets, communiqués de presse et documents déposés par Facebook auprès de la Securities and Exchange Commission, afin d'identifier "l'ensemble des valeurs algorithmiques qui régissent le fil d'actualité". Certaines des caractéristiques qu'il a identifiées sont objectives, i.e. elles peuvent être observées ou mesurées : les relations avec les amis, les intérêts explicitement exprimés par les utilisateurs, l'engagement antérieur, l'âge des messages et les relations entre pages web. En revanche, d'autres caractéristiques sont sujettes à interprétation et soulèvent donc de nombreuses questions : les préférences implicites des utilisateurs (quels sont les signaux de cette expression implicite ?), les priorités de la plate-forme (quelles sont-elles et qui en décide ?), la qualité du contenu (quels sont les critères de qualité ?).

En fin de compte, il peut sembler que les algorithmes de recommandation apprennent à exploiter les traits psychologiques et les biais cognitifs. Cependant, il est important de souligner que l'algorithme ne découvre pas un trait psychologique ou un biais cognitif proprement dit. Il découvre plutôt les caractéristiques qui lui permettent d'exploiter ce que les psychologues décrivent comme un trait ou un biais. Ces critères ne sont pas explicitement formulés, ils peuvent même ne pas être explicables ou vérifiables. Ils restent implicites

dans les modèles, à moins qu'une étude ne soit menée a posteriori, qui mettrait en évidence les biais qui émergent des recommandations. Il s'agit encore là d'un exemple où les techniques d'IA sans explications ni retour d'information posent problème.

Une autre spécificité des algorithmes de recommandation est qu'ils ont tendance à mettre en œuvre une boucle d'auto-renforcement que nous définissons comme suit :

### Definition 2.1 (boucle de recommandation auto-renforcée)

*Le cycle continu des systèmes de recommandation fournissant des suggestions personnalisées à un utilisateur sur la base des données collectées à partir de ses préférences et de son comportement, et intégrant ces données à d'autres recommandations.*

Une boucle classique de recommandation auto-renforcée est illustrée dans la figure 1 : ① Les algorithmes recommandent un contenu à l'utilisateur. ② Le comportement de l'utilisateur est capturé, peut-être partiellement en raison de l'intérêt de la plate-forme et des choix limités offerts par l'interface, et peut-être biaisé par le fait que ces choix peuvent être orientés, à nouveau, par l'intérêt de la plate-forme et de l'interface choisie. ③ Les algorithmes intègrent ces réactions dans les recommandations futures. Par conséquent, les réactions de l'utilisateur renforceront la recommandation et la propagation du contenu.




Figure 1: La boucle de recommandation auto-renforcée des plateformes : les ellipses représentent les activités du côté de l'utilisateur, les cases représentent les activités du côté de la plateforme. *Select* et *Trace* sont des boîtes grises parce qu'elles ne sont que partiellement observables. Le traitement de l'I.A. est, le plus souvent, une boîte noire pour l'utilisateur final.

Bien entendu, il existe des externalités à cette boucle, qui peuvent en accroître l'impact. Les smartphones sont un exemple de ces externalités en ce sens qu'ils fournissent des moyens supplémentaires pour établir le profil des utilisateurs (e.g. la géolocalisation), ce qui rend la recommandation encore plus efficace et ciblée, au point qu'elle concurrence et parfois supplante les méthodes de publicité plus traditionnelles [64]. Une autre externalité préjudiciable de cette boucle est qu'elle ouvre la porte à des techniques de *spoofing* (usurpation d'identité) et à des acteurs malveillants qui biaisent intentionnellement les traces d'utilisation pour "détourner" les systèmes de recommandation. En effet, dès qu'un processus est connu et documenté, il court le risque d'être détourné de son but initial et manipulé. Par exemple, les faux avis et réactions modifient les recommandations ; les techniques "black hat" de référencement (Search Engine Optimization) telles que les textes cachés, les fermes de liens, le *cloaking*<sup>7</sup> ou le *text spinning* sont désapprouvés par les moteurs de recherche car ils ont

<sup>7</sup>Technique dans laquelle le contenu présenté au robot d'indexation d'un moteur de recherche est différent de celui présenté

un impact sur les recommandations qu'ils font en augmentant indûment le classement des pages ciblées ou en évitant leur déclassement.



Ainsi, le fait que quelques systèmes de recommandation influencent une fraction significative de la population humaine peut avoir un certain nombre d'effets secondaires préjudiciables pour leurs utilisateurs et nos sociétés en général. Un premier effet secondaire des algorithmes de recommandation est qu'ils tendent à enfermer les utilisateurs dans un espace informationnel conforme à leurs goûts et à leurs croyances, une "bulle de filtre" [45] qui les confine dans une "zone de confort cognitif" et active leur biais de confirmation puisqu'ils sont confrontés à des informations qui semblent aller dans le même sens ou aboutir aux mêmes conclusions [55, 34]. Finalement, ils ne sont plus confrontés à la contradiction, au débat ou à des faits ou idées dérangeants. Cette amplification algorithmique tend à être un puissant moteur de radicalisation et de polarisation des opinions, conduisant dans certains cas à des idées extrémistes [73].

En outre, à une époque où nous devons modifier nos comportements (par exemple notre surconsommation de biens et d'énergie) et réorienter notre attention vers des questions importantes (comme le changement climatique), nous devrions nous demander si les algorithmes de recommandation font les bonnes recommandations, et pour qui. Compte tenu des milliards d'utilisateurs pris chaque jour dans des boucles de recommandation<sup>8</sup>, il est important de surveiller en permanence comment et dans quel but ces systèmes captent notre attention. Car en effet, lorsque notre attention est consacrée à un contenu choisi par ces plate-formes, elle est perdue pour toute le reste.

### 3 Gouvernance émotionnelle algorithmique

Compte tenu de la boucle de recommandation présentée dans la section 2, nous souhaitons à présent souligner que, directement ou indirectement, les émotions sont une caractéristique clé des recommandations sélectionnées. En fait, l'ensemble du marché de l'attention pourrait être considéré comme régi par une équation complexe impliquant, au minimum, les émotions, les biais cognitifs et les algorithmes de recommandation de contenu. Cela pourrait conduire à ce que nous appellerons ici une *gouvernance émotionnelle algorithmique* fusionnant deux concepts : la gouvernance émotionnelle [48] qui est la gestion informée de la dynamique émotionnelle de la population gouvernée, et la gouvernance algorithmique [54] qui est la gouvernance de nos sociétés basée sur le traitement algorithmique de données massives.

#### Definition 3.1 (Gouvernance émotionnelle algorithmique)




*La gouvernance des sociétés basée sur des algorithmes traitant des données massives pour exploiter la dynamique émotionnelle de la population gouvernée.*


à un utilisateur. Elle vise à tromper le moteur afin qu'il affiche la page qu'il aurait autrement déclassée ou rejetée. Adapté de <https://en.wikipedia.org/wiki/Cloaking>.

<sup>8</sup>En 2018, Google a révélé que 70 % du temps passé à regarder des vidéos sur Youtube concerne des vidéos recommandées par les algorithmes de Youtube. <https://qz.com/1178125/youtubes-recommendations-drive-70-of-what-we-watch>

Les émotions attirent fortement notre attention, en particulier les émotions à forte valence négative [60]. Ainsi, les informations qui suscitent la colère, la peur, l'indignation, le ressentiment, la frustration ou le dégoût sont parmi celles qui attirent le plus efficacement notre attention [50, 35]. Une explication est le fait que les émotions négatives des autres activent notre besoin de nous comparer à eux, de sorte qu'elles nous soumettent à une forme d'injonction à prendre parti, à montrer notre réaction émotionnelle, et donc à démontrer publiquement notre "moralité irréprochable" [17, 10]. Il convient de noter que capturer l'attention et augmenter l'engagement utilisateur sont deux choses différentes, et bien que les émotions négatives intenses attirent l'attention plus efficacement que les autres émotions, il n'est pas certain qu'elles induisent un engagement plus important des utilisateurs sur les médias sociaux. Dans certains cas, un taux de partage plus élevé des informations véhiculant des émotions positives a été observé [33, 36]. Néanmoins, dans plusieurs contributions, les chercheurs ont montré l'impact considérable des émotions dans l'argumentation et les débats [5, 67, 4], ainsi que les moyens de les détecter, et il a également été démontré que la colère se propage plus rapidement sur les médias sociaux que n'importe quelle autre émotion [21]. Notons que l'attraction pour les contenus négatifs s'observe également dans des domaines complètement différents. Dans la littérature par exemple où les genres de fiction anti-utopique et dystopique sont devenus plus importants au sein du genre utopique [39].

Combinées ensemble, la construction de bulles de filtres par les systèmes de recommandation et la capacité de ces systèmes à apprendre les caractéristiques du contenu qui déclenchent une réaction émotionnelle particulière chez un individu donné peuvent conduire à une certaine forme de polarisation et finir par piéger les utilisateurs dans des voies de radicalisation. Prenons l'exemple d'un supporter d'un club sportif : c'est parce que le système choisit le bon sujet (le bon sport), le bon contenu (un article sur un club adverse) et le bon ton et la bonne émotion (une critique moqueuse) qu'une émotion est provoquée, suivie d'une réaction enregistrée (like, commentaire, repost) et, avec le temps, une polarisation potentielle se développe, telle que la haine pour les supporters de l'adversaire.

Recommandation après recommandation, la bulle de filtre devient une bulle d'opinion où les utilisateurs sont isolés des opinions divergentes, et finalement une bulle d'émotion où ils sont maintenus dans certains états émotionnels à la suite de recommandations optimisées. Au final, l'interaction complexe entre les émotions négatives, les biais cognitifs (par exemple le biais de négativité et la tendance impulsive à l'indignation) et les algorithmes de recommandation conduit à une escalade émotionnelle. Souvent, cette escalade est encore aggravée par les possibilités offertes par les plate-formes (les affordances), qui tendent à rendre les échanges de plus en plus brefs et simplistes : comment exprimer une réflexion nuancée dans un tweet de 280 caractères ? Comment souligner un doute lorsque les seuls choix disponibles se limitent essentiellement à   (et parfois ) ? Comment être d'accord avec une partie d'un post et en désaccord avec une autre quand ce post est traité comme un bloc monolithique par l'interface qui ne propose

que les options  ? Cette discrétisation extrême des choix ajoute aux mécanismes à l'œuvre et renforce la polarisation des opinions et des communautés. Certains dark patterns sont même intentionnellement employés pour rendre certaines actions faciles et d'autres plus difficiles : dans Facebook par exemple, le bouton like est toujours visible alors que l'option pour signaler un contenu se trouve au bas d'un sous-menu, un pattern relevant de la catégorie dite "plus long que nécessaire" [7].

Finalement, la nuance, le doute ou l'agnosticisme sont mécaniquement rendus invisibles parce que la faible réponse émotionnelle qu'ils induisent dégrade tout simplement leur classement. Il est impératif d'avoir une opinion, de préférence tranchée et clivante. Amplifiée par la désinhibition numérique<sup>9</sup> [62], cette escalade émotionnelle peut conduire à des déferlements de violence et de haine, dont l'issue est parfois tragique comme en témoignent les tentatives de suicide d'adolescents victimes de cyberharcèlement. Par ailleurs, les conséquences exactes de l'activation et la régulation des émotions sur nos fonctions cognitives en général, et sur la mémoire en particulier, restent à étudier de manière plus approfondie [49].



Nous venons de décrire l'effet combiné des émotions, des biais cognitifs et des algorithmes de recommandation, qui est à l'œuvre quel que soit le type de contenu proposé par une plateforme. Mais les choses s'aggravent encore lorsqu'il s'agit spécifiquement des fausses informations. Les fausses informations sont souvent destinées à susciter de fortes émotions négatives [74], et la combinaison avec les biais cognitifs et les algorithmes de recommandation leur fournit un terrain particulièrement fertile et une efficacité cognitive redoutable [2, 38]. Certaines études rapportent que le fait que des fausses nouvelles soient biaisées négativement renforcent la propension des utilisateurs à les partager [14], et révèlent une corrélation positive entre la viralité des fausses nouvelles et la colère qu'elles véhiculent [12]. Une autre étude affirme que le mensonge se propage "significativement plus loin, plus vite, plus profondément et plus largement que la vérité" sur les médias sociaux [68], ce qui souligne que la recommandation d'un contenu suscitant des émotions négatives n'induit pas seulement une réaction individuelle locale : elle crée une réaction en chaîne tirant parti de l'effet de réseau des médias sociaux pour propager ce couple "contenu-émotion" par le biais des liens d'acquaintance. D'autres études ont montré que les algorithmes de recommandation tendent mécaniquement à favoriser les fausses informations véhiculant des idées clivantes, des événements choquants et des émotions négatives [22, 23]. Ce type de contenu entraîne un sentiment d'injonction à prendre parti et nous pousse à diffuser compulsivement des informations choquantes plutôt que de faire appel à l'esprit critique, de s'interroger sur leur véracité et de vérifier leur source. Et comme ces informations sont souvent relayées par des personnes que nous connaissons, le biais de preuve sociale [13] nous incite à les juger crédibles et dignes de confiance.

<sup>9</sup>le sentiment d'impunité induit par le sentiment d'anonymat

De façon inquiétante, les contenus auxquels nous sommes exposés laissent dans notre mémoire une trace implicite : nous ne nous souvenons pas de les avoir vus, pourtant ils peuvent avoir un impact sur nos choix pendant plusieurs mois [15]. Plus inquiétant encore, en raison du biais de négativité, les informations négatives laissent une trace plus longue dans la mémoire que les informations positives. Par conséquent, même lorsqu'une fausse information est démentie ou rectifiée, il subsiste un sentiment négatif découlant de la forte réaction émotionnelle qu'elle a déclenchée au départ. Répétées à l'envi, associées à des représentations du monde qui convoquent des théories du complot, renforcées sous la pression des bulles de filtres et d'émotions, propulsées par l'effet de réseau, ces informations minent progressivement et insidieusement notre confiance dans les élites (savants, experts, journalistes, politiques, etc.), comportent des risques pour la santé publique [71, 51], et favorisent l'émergence d'idées extrêmes et de populismes qui finissent par miner les démocraties [73, 1, 30, 23], entre autres écueils.

Enfin, il convient de souligner que si "des études antérieures ont montré comment la personnalité, les valeurs, les émotions et la vulnérabilité des utilisateurs influent sur leur propension à propager de fausses informations" [22], nous n'avons considéré dans cette section que des utilisateurs moyens ne présentant pas de problème de santé particulier. Mais les choses pourraient devenir encore plus complexes si nous prenons en compte les utilisateurs souffrant de handicaps ou de troubles mentaux (e.g. dépression, anxiété, trouble d'achat compulsif, paranoïa, FOMO, FOBO<sup>10</sup>...). Mentionnons une pathologie spécifique : le trouble du déficit de l'attention (TDA). Il est prouvé que les symptômes du TDA peuvent être aggravés par l'utilisation des médias numériques et leurs systèmes de captation de l'attention. Plus important encore, leur utilisation peut provoquer le TDA chez des personnes qui n'ont pas d'antécédents de ce type de trouble [47]. Le moins que l'on puisse dire, c'est que des recherches supplémentaires sont nécessaires à cet égard.

## 4 Attention, attention, penseurs

Cette section s'adresse initialement à tous les scientifiques qui lisent cet article, en accord avec l'article de David R. Smith : "Attention, attention : vos actifs scientifiques les plus précieux sont attaqués" [59]. Dans cet article, Smith attire l'attention sur l'impact des plate-formes sur la recherche et le domaine académique. En effet, même les scientifiques et les ingénieurs les mieux informés ne sont pas à l'abri de ces problèmes [37], si bien que les "dispositifs numériques" (comme les appelle Smith) contribuent au *trouble déficitaire de l'attention des universitaires* [59]. En fait, la concentration, mais aussi l'ennui, le vagabondage intellectuel et la rêverie sont essentiels à la pensée créative. Nombre d'entre nous ont connu l'explosion soudaine d'une idée au beau milieu d'un moment de détente. Les systèmes de capture de l'attention nous volent ces moments et entravent le processus de créativité des esprits en éveil [76].

<sup>10</sup>*Fear of Better Options*: l'incapacité à choisir face à une multitude d'options.

Bien entendu, ces remarques peuvent être généralisées à de nombreuses autres activités nécessitant de la concentration, de la créativité et de l'imagination, et l'on peut se demander ce que les dispositifs numériques font à la politique, aux soins de santé ou à l'éducation, par exemple. Pour ne citer qu'un exemple, d'innombrables médias d'information rapportent aujourd'hui le cas de Youtubers en burn-out [46], ou de musiciens se plaignant de passer plus de temps à créer des vidéos Tiktok pour promouvoir leur musique qu'à écrire de la musique [56, 72]. Cela montre que, pour attirer et retenir l'attention des consommateurs de contenu, les plate-formes exercent également une sorte de tyrannie de la visibilité sur les créateurs de contenu.

En d'autres termes : attention, attention, penseurs, nous devons redéfinir les systèmes en fonction de nos propres besoins, et non l'inverse, en particulier dans les emplois créatifs, car la véritable valeur de ces emplois, ce sont les idées [59].

## 5 Contre-mesures post hoc connues

Parmi les différents problèmes soulevés dans les sections précédentes, la question de la désinformation en ligne est l'une des plus préoccupantes et a donc été largement abordée par la communauté des chercheurs [57]. Dans [22] les auteurs ont identifié trois points différents où les systèmes de recommandation peuvent être adaptés pour résoudre ces problèmes : ① pré-recommandation, ② dans le modèle de recommandation et ③ post-recommandation. La plupart des contre-mesures actuelles pour traiter les fausses informations se situent dans cette troisième catégorie. Nous en évoquons quelques-unes ci-dessous.

Tout d'abord, pour endiguer la diffusion de fausses informations et de contenus inappropriés tels que le harcèlement, les discours haineux ou violents, les médias sociaux et les plate-formes d'hébergement de contenus ont des obligations qui varient en fonction de la législation et de leur juridiction [24]. Les mesures vont de la suppression de contenus et la suspension d'utilisateurs diffusant des contenus inappropriés, au reclassement d'éléments recommandés avant de les présenter à l'utilisateur [22], en passant par le signalement de contenus potentiellement trompeurs, etc. Malgré ces différentes approches, des progrès sont encore nécessaires. Par exemple, un contenu violent subtil peut être difficile à détecter dès lors qu'il ne contient pas de termes explicitement haineux ou violents, ou qu'il utilise le sarcasme [44]. Inversement, un contenu peut être considéré à tort comme abusif ou illicite alors qu'il utilise en fait l'ironie pour véhiculer des idées tout à fait acceptables. L'analyse approfondie de l'implicite et de la subtilité du contenu linguistique reste une question ouverte [44].

En outre, toute action doit soigneusement prendre en compte les dangers du transfert de la réglementation et de son application à des entreprises privées. [61] rappelle qu'un filtrage excessif des contenus est tout aussi dangereux que de laisser les mauvais contenus se propager. En effet, la suppression et le filtrage peuvent dévier de leur objectif initial vers une surcensure du contenu s'il devient plus sûr pour les plate-formes d'agir ainsi que de prendre le risque d'être poursuivies en justice. En outre, l'évaluation de la véracité des informations soulève de multiples questions éthiques et politiques :

Qui décide de ce qui est vrai ou faux ? Selon quels critères ? Sous le contrôle de qui ?

Deuxièmement, pour atténuer l'effet des fausses informations, de nombreuses mesures post hoc s'appuient sur l'impact d'un contenu correctif supplémentaire. Pour [69], le fait d'indiquer une explication alternative cohérente, avec des références à des sources factuelles expertes et hautement crédibles, reste un point de départ solide. Les auteurs décrivent la stratégie de "correction observationnelle" en s'appuyant sur le fait que les utilisateurs qui assistent à la correction d'une information erronée, mais qui n'ont pas précédemment lu ou transmis cette information, sont moins affectés par la dissonance cognitive et se prêtent donc plus facilement à la correction. Cette constatation est cohérente avec les conclusions de [8] qui suggèrent que l'exposition des utilisateurs à des histoires connexes qui corrigent un message contenant des informations erronées réduira considérablement les perceptions erronées. L'impact de la correction peut être encore renforcé en soulignant explicitement la similarité démographique entre l'utilisateur et les auteurs du contenu opposé [25], ce qui fait appel à l'effet d'homophilie<sup>11</sup>. En d'autres termes, nous sommes plus enclins à accepter la correction lorsqu'elle émane d'une personne socialement proche de nous, par exemple ayant la même activité professionnelle ou la même formation.

## 6 Reconquérir notre attention

Les méthodes présentées dans la section précédente ont toutes un point commun : elles traitent les problèmes de manière post hoc, c'est-à-dire après que ces problèmes se soient produits, avec toutes les limites que comporte cet "après". Aujourd'hui, certains auteurs appellent les décideurs politiques à réguler l'économie de l'attention. C'est certainement une partie de la réponse, mais il est possible de trouver des moyens complémentaires de traiter ces questions, qu'ils soient juridiques, politiques ou techniques. Plus important encore, nous devons envisager cette réflexion non seulement du point de vue de la régulation des consommateurs d'attention (les plate-formes et les multiples intermédiaires), mais aussi du point de vue des producteurs d'attention (les utilisateurs) qui veulent récupérer leur attention, en particulier à une époque où notre attention est requise pour un certain nombre de questions urgentes. Il s'agit d'empêcher activement les systèmes de recommandation de trouver des moyens d'exploiter nos limites internes et de nous manipuler par le biais de structures parfois anciennes et profondément ancrées dans notre cerveau (comme le striatum) [9]. Nous formulons ci-dessous une série de propositions découlant des observations et des résultats présentés dans les sections précédentes. Nous les organisons autour des défis qu'elles abordent, en même temps que des propositions faites par d'autres auteurs issus de disciplines diverses. Enfin, nous en extrayons un ensemble de principes empiriques qui pourraient être utilisés pour conduire d'autres travaux sur des bonnes pratiques.

<sup>11</sup>Homophilie: tendance à s'associer à ceux qui nous sont similaires.

## 6.1 La carotte et le bâton

Prenant l'exemple des fausses informations, [69] insiste sur le fait que la correction a posteriori ne suffit pas et doit intervenir le plus tôt possible, c'est-à-dire avant que les perceptions erronées ne s'enracinent. De plus, éviter l'amplification algorithmique de ces informations par les systèmes de recommandation nécessite d'atténuer l'effet de popularité avant qu'il ne se produise [22]. Mais si les médias sociaux en ligne sont tenus par la loi de lutter contre les fausses informations, ils ont des incitations contradictoires à le faire, pour ne pas dire aucune incitation. En effet, comme nous l'avons décrit dans la section 3, les fausses informations s'appuient largement sur les émotions négatives pour attirer l'attention des utilisateurs. En tant que telles, elles sont très efficaces pour favoriser l'engagement des utilisateurs, ce que les médias sociaux s'efforcent d'obtenir. Par conséquent, d'un point de vue économique, il est contre-productif pour eux d'empêcher la diffusion de fausses informations. Plus généralement, il est contre-productif pour les plate-formes d'atténuer l'effet de popularité, d'atténuer l'impact des émotions négatives ou de réduire les bulles de filtres et la polarisation des opinions qui en découle.

Les auteurs de [42] suggèrent de repenser les lois de régulation du commerce existantes, telles que les lois antitrust et les lois sur la concurrence loyale, dans le nouveau domaine des marchés de l'attention. Ils proposent d'appliquer des taxes sur la consommation d'attention afin de "dissuader les intermédiaires d'aspirer autant d'attention que possible", par exemple en limitant la quantité de publicités pouvant être montrées à un utilisateur, ou en réduisant la déductibilité des dépenses publicitaires des revenus des entreprises afin de diminuer leurs impôts. Ils proposent également de réglementer les coûts de l'attention pouvant être facturés, avec l'idée que si l'attention devient moins lucrative, les ressources financières seront redirigées vers des marchés plus lucratifs, réduisant ainsi la quantité d'attention captée et échangée.

En d'autres termes, les choses ne changeront pas sans de fortes incitations d'un côté et des mesures dissuasives de l'autre. Nous pouvons résumer cela par le principe général suivant :

### **⚡ principe de la bonne incitation**

Les organes de gouvernance doivent exploiter les moyens juridiques et économiques pour orienter les pratiques des plate-formes vers des comportements souhaitables, tout en pénalisant les comportements non souhaités.

## 6.2 Régulation de l'utilisation

Certaines des mesures destinées à réguler le marché de l'attention concernent la manière dont les services sont consommés. Comme cela a déjà été fait dans certains pays, des lois pourraient être votées pour limiter le temps quotidien passé par les utilisateurs sur certains services, en particulier chez les plus jeunes [32, 11]. Une autre mesure simple s'applique aux plate-formes de streaming vidéo, qui consiste à imposer des pauses de quelques secondes entre les vidéos. Cette technique apparemment naïve peut en fait briser le piège du flux infini en donnant aux utilisateurs le court

laps de temps dont ils ont besoin pour réaliser qu'ils ont été dans un tunnel attentionnel pendant un certain temps, et qu'ils veulent "récupérer" leur attention. Cette technique peut être généralisée en formulant le principe suivant :

### **⚡ principe de soutien à la diligence raisonnable**

Tous les moyens doivent être mis en œuvre pour encourager et soutenir la diligence raisonnable des utilisateurs. En particulier, ils doivent toujours être informés des possibilités qui s'offrent à eux pour échapper aux boucles, processus et objectifs des systèmes.

Les décideurs politiques pourraient également s'attaquer au problème de la fragmentation de l'attention engendrée par les notifications multiples, souvent invasives, que les applications pour smartphones suscitent. Chaque fois qu'une notification survient, les utilisateurs sont tentés d'interrompre leur activité en cours, de vérifier la raison de la notification, éventuellement d'y réagir, avant de reprendre leur activité. Il a été démontré que le fait de passer d'une tâche ou d'un contexte à l'autre a un coût : cela prend du temps et crée un contexte plus propice aux erreurs [31, 40, 52]. En outre, il a même été démontré que la simple présence de ces appareils, même s'ils sont éteints, diminue nos capacités cognitives [70]. À l'instar du règlement général européen sur la protection des données (RGPD)<sup>12</sup> qui impose le consentement des utilisateurs pour l'utilisation de cookies, la loi pourrait imposer que les applications pour smartphones obtiennent le consentement explicite et informé des utilisateurs pour les notifications qu'elles émettent, et que ces notifications soient désactivées par défaut ("opt-in only"). D'où le principe suivant :

### **⚡ principe de l'opt-in par défaut**

Les services de recommandation et de notification doivent être désactivés par défaut et n'être activés que sur demande et après consentement éclairé et réglage dans les préférences.

Ces mesures pourraient être complétées par des mesures plus punitives, comme proposé dans [41], par exemple en démonétisant et en interdisant la collaboration avec les plate-formes qui ne respectent pas les règles.

## 6.3 Surveillance des recommandations de contenu

L'effet d'écho des algorithmes de recommandation est à l'origine de nombreux exemples de polarisation et de radicalisation. Il pourrait être atténué en imposant une certaine proportion de contenus non recommandés, de contenus qui ne correspondent pas aux intérêts de l'utilisateur ou de contenus provenant d'utilisateurs qu'il ne connaît pas ou avec lesquels il n'est pas souvent en contact. À cet égard, certaines approches relèvent de la deuxième catégorie proposée par [22], c'est-à-dire des modifications "dans le modèle de recommandation". Par exemple, les mêmes auteurs suggèrent d'utiliser des approches de clustering pour regrouper les contacts d'un utilisateur en fonction de différents niveaux de similarité avec

<sup>12</sup>General Data Protection Regulation (GDPR) <https://gdpr-info.eu/>

l'utilisateur, et d'exploiter ces groupes pour augmenter la diversité de la recommandation tout en maintenant une certaine cohérence et similarité. [20] proposent une méthode pour formuler des recommandations pertinentes tout en réduisant la probabilité d'entraîner l'utilisateur sur la voie de la radicalisation. En outre, pour contrer l'utilisation abusive de la colère, de l'indignation ou de la peur, qui sont souvent associées à de fausses informations, les plate-formes pourraient être tenues d'effectuer une analyse des sentiments sur chaque contenu afin de maintenir le nombre de recommandations associées à des émotions négatives en dessous d'un seuil donné.

#### 📌 principe de recommandations équilibrées

Les plates-formes et médias sociaux en ligne doivent empêcher la spécialisation excessive des recommandations, et permettre de surveiller et d'empêcher la formation de bulles de tout type (opinion, source, émotion, etc.).

En outre, il existe une asymétrie de visibilité entre la diffusion virale d'une information qui s'est avérée fautive ou trompeuse, et le démenti ou la rectification de cette information. Le démenti d'une fautive information met généralement en avant une position réfléchie et nuancée qui fait appel au raisonnement et aux faits (*logos*) plutôt qu'à l'émotion (*pathos*). Il ne déclenche donc pas de réaction émotionnelle en comparaison de celle qu'a entraînée la fautive information, et il est donc silencieusement déclassé par les algorithmes de recommandation. Ce phénomène est généralement résumé par la loi dite de Bradolini qui stipule que "la quantité d'énergie nécessaire pour réfuter une fautive information est d'un ordre de grandeur supérieur à celle nécessaire pour la produire".<sup>13</sup> En conséquence, les utilisateurs qui propagent de fautes informations n'ont souvent jamais connaissance de leur erreur. En accord avec [66] qui insistent sur le fait qu'il est essentiel de traiter conjointement le contrôle du contenu et la viralité numérique, une solution pourrait consister à contrebalancer cette asymétrie de visibilité en demandant aux médias sociaux d'imposer au démenti ou à la rectification d'une fautive information une visibilité équivalente à celle de l'information initiale, par exemple en veillant à ce que la population qui a été exposée à la fautive information soit également exposée au démenti. Un avertissement pourrait également être présenté aux utilisateurs qui ont propagé cette fautive information afin de les sensibiliser. Bien entendu, ce type de mesure pourrait être couplé à d'autres mesures de post-recommandation telles que les stratégies impliquant la correction observationnelle ou la similarité démographique présentées dans la section 5. Plus généralement, nous devons déterminer comment nous pouvons utiliser les systèmes de recommandation pour recommander des contre-mesures, i.e. nous pourrions entraîner un système de recommandation à apprendre le contenu le plus pertinent et les entrées les plus percutantes dans le réseau de connaissances afin d'injecter une contre-mesure.

<sup>13</sup>Bradolini's law: [https://en.wikipedia.org/wiki/Brandolini%27s\\_law](https://en.wikipedia.org/wiki/Brandolini%27s_law)

#### 📌 principe de visibilité équilibrée

Les plate-formes et médias sociaux en ligne doivent veiller à ce que les mesures préventives et correctives aient une visibilité au moins égale à celle des problèmes à prévenir ou à corriger.

### 6.4 Affordances et conception de l'interaction

Comme nous l'avons vu dans la section 3, les possibilités offertes par les plate-formes sont optimisées pour des échanges extrêmement brefs et basiques, ne laissant aucune place à la nuance, la réflexion, le doute ou un raisonnement étayé. Les interfaces pourraient être repensées pour faciliter les réactions non binaires, en commençant par une gamme d'émotions nuancées. Plutôt que de mettre en œuvre des dark patterns trompeurs, elles pourraient s'appuyer sur des "nudges" pour conduire de façon bienveillante les utilisateurs vers la pensée critique, et en valorisant/récompensant ce type de comportement. [1] recommandent d'impliquer les utilisateurs dans la validation du contenu avant de le partager, à la fois manuellement et avec des méthodes d'analyse automatisées sur le contenu et le contexte. Par exemple, X (anciennement Twitter) demande une confirmation avant de retweeter le lien d'un article sur lequel l'utilisateur n'a pas cliqué. De même, les interfaces pourraient encourager les utilisateurs à commenter le contenu au lieu de simplement cliquer sur ❤️, 👍 ou 🗨️ et elles pourraient demander à un utilisateur s'il souhaite vraiment partager ou soutenir un contenu associé à de fortes émotions négatives ou pour lequel une contre-mesure a été déclenchée.

#### 📌 principe de conception d'interactions bienveillantes

Les affordances et les interactions doivent être conçues et évaluées en tenant compte en premier lieu du bien-être des utilisateurs finaux.

### 6.5 Impact sociétal et mission éducative

En tant que société, nous pourrions décider que les grands médias sociaux en ligne, en raison de leur influence sur la société, l'opinion publique, la santé publique et l'économie, ne peuvent plus être considérés comme de simples entreprises privées régies par la seule loi du marché. Au contraire, ils pourraient être considérés comme des biens communs numériques et se voir attribuer un statut spécifique qui les doterait d'une mission sociétale, comme par exemple d'avoir un objectif éducatif. À titre d'exemple, ils pourraient apprendre aux utilisateurs à détecter les informations fautes ou trompeuses, promouvoir des contenus destinés à sensibiliser aux mécanismes de l'attention et aux biais cognitifs, encourager l'esprit critique et "distiller" la méthode scientifique, etc. Dans le même ordre d'idée, les auteurs de [1] insistent sur la nécessité d'une éducation civique, et [43] recommandent d'intégrer des valeurs démocratiques dans les algorithmes qui ont un impact sur nos vies, en particulier ceux qui participent à une gouvernance algorithmique (e.g. les plate-formes utilisées pour les débats, l'information, les actions en justice, l'éducation), ce qui, dans notre cas, signifie aller au-delà de l'optimisation de l'engagement des utilisateurs et de la captation de l'attention, et inclure des critères éthiques.



### **📌 principe de préservation des communs numériques**

Lorsqu'un service, une plate-forme ou une ressource numérique est susceptible d'avoir un impact mondial sur les sociétés humaines, il faut lui attribuer le statut de commun numérique et le soumettre à des règles et des politiques de préservation.

## **6.6 Retour et transparence des applications**

Comme l'un des écueils que nous avons identifiés est le fait que les utilisateurs sont pris dans les boucles de recommandation, une piste pourrait consister à spécialiser des approches telles que le "quantified self" et le "lifelog" dans le cas des plate-formes basées sur la recommandation, afin de favoriser la prise de conscience et l'introspection. Les outils de suivi automatisé pourraient fournir aux utilisateurs des mesures et un retour concernant le temps total passé sur la plate-forme, l'exposition totale à des informations négatives, etc. Cela pourrait être un moyen de contrer le fait que le partage en ligne de fausses informations augmente avec la fatigue numérique [63]. Des indicateurs pourraient informer les utilisateurs de la diversité des recommandations qui leur sont présentées et les sensibiliser aux risques d'une faible diversité. Par exemple, le fait que "90% du contenu que l'on voit provient de 10% de ses contacts ou concernent les mêmes sujets" peut indiquer que l'on se trouve dans une bulle de filtres. Dans le principe ci-dessous, nous appelons réflexivité la capacité des utilisateurs à être conscients de leur utilisation et de leur engagement avec le système.

### **📌 principe de réflexivité permanente**

Les utilisateurs doivent recevoir un retour d'information actualisé en permanence sur leur utilisation du système et sur eux-mêmes, afin de soutenir leur réflexivité et maintenir un consentement éclairé actualisé.

Entre autres mesures, la loi européenne sur les services numériques [65], qui est entrée en vigueur en août 2023, exige que les plate-formes mettent en place des mécanismes pour expliquer les raisons qui les ont conduit à recommander un contenu particulier, et offrent aux utilisateurs une recommandation alternative qui ne soit pas basée sur le profilage.

### **📌 principe de la pleine connaissance par l'utilisateur**

Les utilisateurs doivent être informés de toutes les caractéristiques et motivations conduisant à une recommandation, avant et au moment où celle-ci est faite.

Ces mesures sont particulièrement cruciales lorsqu'il s'agit de coupler l'IA et le web, où nous devons faire de la transparence et de l'explication une condition préalable à toute approche, afin d'assurer le consentement conscient et éclairé de milliards d'utilisateurs potentiels [6].

## **6.7 S'appuyer sur les pratiques existantes**

Enfin, et bien que cela puisse paraître évident, une règle mérite d'être rappelée : examiner les meilleures pratiques existantes dans d'autres domaines et s'en inspirer. Dans la plupart des juridictions, il existe des lois sur la publicité pour protéger les consommateurs, veiller à ce qu'ils puissent prendre des

décisions en connaissance de cause et, plus généralement, pour maintenir des conditions de concurrence équitables entre tous les acteurs. La plupart des pays réglementent la publicité au moyen de lois qui ciblent différentes formes de contenus et allégations faux, trompeurs ou mensongers, et interdisent toute une série de pratiques (comparaison non fondée, faux témoignages, publicité mensongère, emballage/étiquette trompeur, messages commerciaux non sollicités, prétendus concours et loteries...). Les travaux et la littérature sur la réglementation de la publicité devraient être examinés et mis à profit pour réglementer le marché de l'attention dans son ensemble. Ce sujet est également proche de celui des clickbaits (appâts à clics) qui sont des liens recommandés conçus pour attirer l'attention et inciter les utilisateurs à les suivre, tout en étant typiquement trompeurs, sensationnels ou malhonnêtes d'une manière quelconque. Les clickbaits ne sont pas de simples accroches, mais des titres comportant un élément de malhonnêteté, "utilisant des incitations qui ne reflètent pas exactement le contenu fourni"<sup>14</sup>. A notre connaissance, il n'existe pas de réglementation des pratiques de clickbait qui se répandent sur le web, bien que certaines de ces techniques présentent des similitudes avec les pratiques publicitaires trompeuses ou mensongères que nous venons de mentionner et qui, au contraire, sont réglementées.

### **📌 principe de transfert des meilleures pratiques**

Les méthodes et outils utilisés pour réguler des situations similaires dans des domaines pertinents devraient être étudiés, comparés et systématiquement pris en compte dans le cadre d'une gouvernance du web et de l'IA.

Pour donner un autre exemple sous un angle différent, nous savons que les pratiques parentales en matière de télévision ont un impact sur le comportement des jeunes téléspectateurs [3]. Là encore, les approches et les bonnes pratiques dans ce domaine, et plus généralement dans celui de l'éducation et de la parentalité à l'ère des médias numériques [16], doivent être prises en compte dans le cas du web en général et lorsqu'il s'agit d'aborder le problème de la captation de l'attention en particulier.

Plus généralement, nous devons mettre en place des instances de gouvernance, en commençant par le web et l'IA, prêtes à s'attaquer aux nouvelles pratiques problématiques et à les réguler, comme cela se fait dans d'autres domaines d'activité. Et nous devons également exercer une veille constante sur ces autres domaines, ne serait-ce que pour nous inspirer des initiatives et des retours d'expérience qu'ils ont sur des questions similaires. Si l'on prend l'exemple de l'industrie du jeu vidéo, il est prouvé qu'il existe une relation entre les "loot boxes"<sup>15</sup> et la dépendance au jeu de hasard [75], et qu'une loot box est psychologiquement proche du jeu [19] et peut entraîner des comportements addictifs et mettre les joueurs en danger. La façon d'étudier et d'aborder cette exploitation indésirable de nos comportements est inspirante pour d'autres pratiques problématiques comme celles

<sup>14</sup>Définition adaptée de <https://en.wikipedia.org/wiki/Clickbait>

<sup>15</sup>Les "loot boxes" sont des objets de jeux vidéo dont le contenu est aléatoire et qui peuvent être payés avec de l'argent réel.

que nous avons étudiées.

## 7 Merci pour... votre attention

L'IA est indépendante des domaines dans lesquels elle s'applique, et ceux-ci sont nombreux : information, business, économie, politique, emploi, sport, jeux, sexe, etc. Et le déploiement mondial de ces techniques, en partie dû à leur couplage avec le web, pourrait avoir des conséquences néfastes dans tous ces domaines également, s'il n'est pas correctement réglementé. Il s'agit d'une observation banale, mais c'est la raison pour laquelle, afin de prévenir de tels effets néfastes, une approche éthique de la gouvernance de l'IA et du web doit être pluridisciplinaire et interdisciplinaire.

C'est dans cet esprit que cet article a rassemblé les conclusions de plus de 70 articles et ouvrages de différentes disciplines (psychologie, sociologie, neurosciences, politique, domaine juridique, informatique, éducation, etc.) afin d'analyser et d'appeler à des actions contre les pratiques actuelles qui rivalisent pour capter notre attention dans tous les recoins du "Web Wild West". Comme le mentionne le Web Science Manifesto [6], un tel problème nécessite en effet des approches interdisciplinaires pour empêcher la généralisation des techniques de capture de l'attention et leurs multiples effets secondaires néfastes sur nos sociétés. Le problème est à la fois critique et complexe, et les auteurs de [34] défendent la nécessité d'une "vision multidimensionnelle nuancée de la manière dont l'utilisation des médias sociaux peut façonner la consommation d'informations" et nous invitent à prendre en compte "la variété complexe des plate-formes de médias sociaux [et] la variation considérable des impacts observés entre elles". Dans [22] les auteurs ajoutent que "cette recherche nécessite de naviguer dans la tension entre vie privée, sécurité, intérêts économiques, censure et différences culturelles, et nécessite d'être abordée à partir de disciplines multiples qui peuvent évaluer non seulement l'aspect technologique, mais aussi l'aspect individuel et social (...). Cela laisse beaucoup de place à l'investigation (...), ouvrant une nouvelle ligne de recherche passionnante et interdisciplinaire".

Dans le même temps, le problème s'aggrave à chaque innovation technologique. L'omniprésence des smartphones dans nos vies a encore renforcé l'efficacité de ces techniques qui peuvent désormais capter notre attention à chaque instant de la journée, et en particulier les moments qui étaient auparavant ceux de l'ennui, l'attente, la rêverie ou la flânerie intellectuelle. Comme nous l'avons souligné dans la section 4, on sait que ces moments sont nécessaires pour stimuler l'imagination et la créativité. Dans le prolongement des smartphones, les objets intelligents et l'internet des objets et le web des objets qui en découlent ne feront qu'aggraver les choses.

Les systèmes de recommandation qui apprennent à nous prédire apprennent en fait à nous manipuler : être prévisible, c'est perdre sa liberté. Chaque jour, nous alimentons les prédicteurs en échange d'une satisfaction et d'un plaisir immédiats, au détriment de notre liberté future. Cela revient à hypothéquer continuellement notre liberté. Par ailleurs, ces systèmes qui se disputent notre attention finissent par nous pousser à consommer et à réagir de plus en plus vite à leurs recommandations. Or, comme nous le savons, l'accélération

est une forme d'aliénation [53].

Dans un autre contexte et pour faire face à nos propres limites humaines, [10] recommande de trouver des moyens d'accroître notre niveau général de conscience et de se réapproprier le pouvoir de la réflexion à long terme. Nos dirigeants et nos *role models*<sup>16</sup> peinent à incarner les valeurs de patience, de conscience et de modération [10], mais nos systèmes informatiques ne nous poussent également que rarement dans cette direction. Au contraire, les applications actuelles de l'IA nous poussent à ne pas utiliser notre conscience, mais à jouer leur jeu de l'automatisation. Pourtant, il n'y a aucune raison pour que ces systèmes vivent dans notre esprit gratuitement et il est urgent de les repenser pour qu'ils nous poussent régulièrement à prendre du recul, à être plus conscients de ce que nous faisons, regardons, disons, diffusons, etc. Le défi est de (re)prendre et (re)donner du temps pour la conscience, l'attention et la réflexion : nous devons (re)prendre cette source de liberté. Pour ce faire, nous avons proposé une première série non exhaustive de principes pour commencer à (re)concevoir des applications et y inscrire un ensemble de valeurs décidées collectivement.

## References

- [1] Carlos Abreu and Leandro Ayres França. "Algorithm-driven populism: An introduction [Populizm oparty na algorytmach. Wprowadzenie.]" In: *Archives of Criminology [Archiwum Kryminologii]* (2021).
- [2] Alberto Acerbi. "Cognitive attraction and online misinformation". In: *Palgrave Communications* 5.1 (2019), pp. 1–7. ISSN: 2055-1045. DOI: 10.1057/s41599-019-0224-y.
- [3] Danielle T. Barradas et al. "Parental Influences on Youth Television Viewing". In: *The Journal of Pediatrics* 151.4 (2007), 369–373.e4. ISSN: 0022-3476. DOI: 10.1016/j.jpeds.2007.04.069.
- [4] Valerio Basile et al. "A Pragma-Semantic Analysis of the Emotion/Sentiment Relation in Debates". In: *Proceedings of the 4th International Workshop on Artificial Intelligence and Cognition co-located with the Joint Multi-Conference on Human-Level Artificial Intelligence (HLAI 2016), New York City, NY, USA, July 16-17, 2016*. Vol. 1895. CEUR Workshop Proceedings. CEUR-WS.org, 2016, pp. 117–123.
- [5] M. Sahbi Benlamine et al. "Emotions in Argumentation: an Empirical Evaluation". In: *Proceedings of the Twenty-Fourth International Joint Conference on Artificial Intelligence, IJCAI 2015, Buenos Aires, Argentina, July 25-31, 2015*. AAAI Press, 2015, pp. 156–163.
- [6] Bettina Berendt et al. "Web Futures: Inclusive, Intelligent, Sustainable The 2020 Manifesto for Web Science". In: *Dagstuhl Manifestos* (2021). DOI: 10.4230/DagMan.9.1.1.
- [7] European Data Protection Board. *Guidelines 03/2022 on deceptive design patterns in social media platform interfaces: how to recognise and avoid them - v2/0*. Tech. rep. 2022.

<sup>16</sup>personnalité dont l'exemple est imité par des tiers.

- [8] Leticia Bode and Emily K Vraga. “That Was Wrong: The Correction of Misinformation Through Related Stories Functionality in Social Media”. In: *Journal of Communication* 65.6 (2015), pp. 619–638. DOI: 10.1111/jcom.12166.
- [9] Sébastien Bohler. *Le Bug humain: Pourquoi notre cerveau nous pousse à détruire la planète et comment l’en empêcher*. Robert Laffont, 2019.
- [10] Gérald Bronner. *Apocalypse cognitive*. Presses Universitaires de France, 2021. ISBN: 978-2-13-073304-1.
- [11] Rory Carroll and Rory Carroll Ireland correspondent. “‘Much easier to say no’: Irish town unites in smartphone ban for young children”. In: *The Guardian* (2023). ISSN: 0261-3077.
- [12] Yuwei Chuai and Jichang Zhao. “Anger can make fake news viral online”. In: *Frontiers in Physics* 10 (2022), p. 970174. ISSN: 2296-424X. DOI: 10.3389/fphy.2022.970174.
- [13] Robert B. Cialdini. *Influence: Science and practice*. Pearson Education, 2008.
- [14] Nicoleta Corbu et al. “Fake News Going Viral: The Mediating Effect Of Negative Emotions”. In: *Media Literacy and Academic Research* 4.2 (2021), pp. 58–87. ISSN: 2585-8726.
- [15] Didier Courbet et al. “The Long-Term Effects of E-Advertising: The Influence of Internet Pop-ups Viewed at a Low Level of Attention in Implicit Memory”. In: *Journal of Computer-Mediated Communication* 19.2 (2014), pp. 274–293. DOI: 10.1111/jcc4.12035.
- [16] Sarah M. Coyne et al. “Parenting and Digital Media”. In: *Pediatrics* 140.Supplement 2 (2017), S112–S116. ISSN: 0031-4005. DOI: 10.1542/peds.2016-1758N.
- [17] M. J. Crockett. “Moral outrage in the digital age”. In: *Nature Human Behaviour* 1.11 (2017), pp. 769–771. ISSN: 2397-3374. DOI: 10.1038/s41562-017-0213-3.
- [18] Michael A DeVito. “From editors to algorithms: A values-based approach to understanding story selection in the Facebook news feed”. In: *Digital journalism* 5.6 (2017), pp. 753–773.
- [19] Aaron Drummond and James D Sauer. “Video game loot boxes are psychologically akin to gambling”. In: *Nature human behaviour* 2.8 (2018), pp. 530–532.
- [20] Francesco Fabbri et al. “Rewiring What-to-Watch-Next Recommendations to Reduce Radicalization Pathways”. In: *Proceedings of the ACM Web Conference 2022*. WWW ’22. New York, NY, USA: Association for Computing Machinery, 2022, pp. 2719–2728. ISBN: 978-1-4503-9096-5. DOI: 10.1145/3485447.3512143.
- [21] Rui Fan et al. “Anger Is More Influential than Joy: Sentiment Correlation in Weibo”. In: *PLOS ONE* 9.10 (2014), e110184. ISSN: 1932-6203. DOI: 10.1371/journal.pone.0110184.
- [22] Miriam Fernández, Alejandro Bellogín, and Iván Cantador. *Analysing the Effect of Recommendation Algorithms on the Amplification of Misinformation*. 2021. DOI: 10.48550/arXiv.2103.14748.
- [23] Piergiuseppe Fortunato and Marco Pecoraro. “Social media, education, and the rise of populist Euroscepticism”. In: *Humanities and Social Sciences Communications* 9.1 (2022), pp. 1–13. ISSN: 2662-9992. DOI: 10.1057/s41599-022-01317-y.
- [24] Daniel Funke and Daniela Flamini. *A guide to anti-misinformation actions around the world*. 2023.
- [25] R Kelly Garrett, Erik C Nisbet, and Emily K Lynch. “Undermining the corrective effects of media-based political fact checking? The role of contextual cues and naive theory”. In: *Journal of Communication* 63.4 (2013), pp. 617–637.
- [26] Colin M. Gray et al. “Mapping the Landscape of Dark Patterns Scholarship: A Systematic Literature Review”. In: *Designing Interactive Systems Conference*. Pittsburgh PA USA: ACM, 2023, pp. 188–193. ISBN: 978-1-4503-9898-5. DOI: 10.1145/3563703.3596635.
- [27] Tristan Harris. *How Technology is Hijacking Your Mind — from a Former Insider*. 2019.
- [28] Andreas Hefti and Steve Heinke. “On the economics of superabundant information and scarce attention”. In: *Economia. History, Methodology, Philosophy* 5-1 (2015), pp. 37–76. ISSN: 2113-5207.
- [29] Vincent F. Hendricks and Mads Vestergaard. “The Attention Economy”. In: *Reality Lost: Markets of Attention, Misinformation and Manipulation*. Cham: Springer International Publishing, 2019, pp. 1–17. ISBN: 978-3-030-00813-0. DOI: 10.1007/978-3-030-00813-0\_1.
- [30] GlobalData Thematic Intelligence. *Social media, algorithms, and populism*. 2022.
- [31] Arthur Thomas Jersild. *Mental set and shift*. 89. Columbia university, 1927.
- [32] Alex Kantrowitz. *5 Ways China is Mandating Social Media Changes*. 2021.
- [33] Kate Keib et al. “Picture This: The Influence of Emotionally Valenced Images, On Attention, Selection, and Sharing of Social Media News”. In: *Media Psychology* 21.2 (2018), pp. 202–221. ISSN: 1521-3269, 1532-785X. DOI: 10.1080/15213269.2017.1378108.
- [34] Brent Kitchens, Steve L. Johnson, and Peter Gray. “Understanding Echo Chambers and Filter Bubbles: The Impact of Social Media on Diversification and Partisan Shifts in News Consumption”. In: *MIS Quarterly* 44.4 (2020), pp. 1619–1649. ISSN: 02767783, 21629730. DOI: 10.25300/MISQ/2020/16371.
- [35] Susann Kohout, Sanne Kruike-meier, and Bert N. Bakker. “May I have your Attention, please? An eye tracking study on emotional social media comments”. In: *Computers in Human Behavior* 139 (2023), p. 107495. ISSN: 0747-5632. DOI: 10.1016/j.chb.2022.107495.
- [36] Adam D.I. Kramer. “The spread of emotion via Facebook”. In: *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems*. CHI ’12. New York, NY, USA: Association for Computing Machin-

- ery, 2012, pp. 767–770. ISBN: 978-1-4503-1015-4. DOI: 10.1145/2207676.2207787.
- [37] Paul Lewis. “‘Our minds can be hijacked’: the tech insiders who fear a smartphone dystopia”. In: *The Guardian* (2017). ISSN: 0261-3077.
- [38] Cameron Martel, Gordon Pennycook, and David G. Rand. “Reliance on emotion promotes belief in fake news”. In: *Cognitive Research: Principles and Implications* 5.1 (2020), p. 47. ISSN: 2365-7464. DOI: 10.1186/s41235-020-00252-3.
- [39] Andrea Burgos Mascarell. “A bibliometric analysis of utopian literature”. In: *ES Review. Spanish Journal of English Studies* 41 (2020), pp. 77–103.
- [40] Stephen Monsell. “Task switching”. In: *Trends in cognitive sciences* 7.3 (2003), pp. 134–140.
- [41] Cas Mudde and Cristóbal Rovira Kaltwasser. *Populism: A very short introduction*. Oxford University Press, 2017.
- [42] John M Newman. “Regulating Attention Markets”. In: *University of Miami Legal Studies Research Paper* (2019). DOI: 10.2139/ssrn.3423487.
- [43] Cathy O’neil. *Weapons of math destruction: How big data increases inequality and threatens democracy*. Crown, 2017.
- [44] Nicolas Ocampo et al. “An In-depth Analysis of Implicit and Subtle Hate Speech Messages”. In: *Proceedings of the 17th Conference of the European Chapter of the Association for Computational Linguistics*. Dubrovnik, Croatia: Association for Computational Linguistics, 2023, pp. 1997–2013.
- [45] Eli Pariser. *The filter bubble: How the new personalized web is changing what we read and how we think*. Penguin, 2011.
- [46] Simon Parkin. “The YouTube stars heading for burnout: ‘The most fun job imaginable became deeply bleak’”. In: *The Guardian* (2018). ISSN: 0261-3077.
- [47] Chaelin K. Ra et al. “Association of Digital Media Use With Subsequent Symptoms of Attention-Deficit/Hyperactivity Disorder Among Adolescents”. In: *JAMA* 320.3 (2018), pp. 255–263. ISSN: 0098-7484. DOI: 10.1001/jama.2018.8931.
- [48] Barry Richards. *Emotional governance: Politics, media and terror*. Springer, 2007.
- [49] Jane M Richards and James J Gross. “Emotion regulation and memory: the cognitive costs of keeping one’s cool.” In: *Journal of personality and social psychology* 79.3 (2000), p. 410.
- [50] Claire E. Robertson et al. “Negativity drives online news consumption”. In: *Nature Human Behaviour* 7.5 (2023), pp. 812–822. ISSN: 2397-3374. DOI: 10.1038/s41562-023-01538-4.
- [51] Yasmim Mendes Rocha et al. “The impact of fake news on social media and its influence on health during the COVID-19 pandemic: a systematic review”. In: *Journal of Public Health* 31.7 (2023), pp. 1007–1016. ISSN: 1613-2238. DOI: 10.1007/s10389-021-01658-z.
- [52] Robert D Rogers and Stephen Monsell. “Costs of a predictable switch between simple cognitive tasks”. In: *Journal of experimental psychology: General* 124.2 (1995), p. 207.
- [53] Hartmut Rosa and Thomas Chaumont. *Aliénation et accélération: vers une théorie critique de la modernité tardive*. La découverte, 2017.
- [54] Antoinette Rouvroy and Thomas Berns. “Gouvernementalité algorithmique et perspectives d’émancipation”. In: *Réseaux* 177.1 (2013), pp. 163–196.
- [55] Kazutoshi Sasahara et al. “Social Influence and Unfollowing Accelerate the Emergence of Echo Chambers”. In: *Journal of Computational Social Science* 4.1 (2021), pp. 381–402. ISSN: 2432-2717, 2432-2725. DOI: 10.1007/s42001-020-00084-7.
- [56] Neil Shah. “Making TikTok Videos Leaves Musicians Feeling Burnout”. In: *Wall Street Journal* (2022). ISSN: 0099-9660.
- [57] Karishma Sharma et al. *Combating Fake News: A Survey on Identification and Mitigation Techniques*. 2019. DOI: 10.48550/arXiv.1901.06437.
- [58] Michael Siegrist and Gorge Cvetkovich. “Better negative than positive? Evidence of a bias for negative information about possible health dangers”. In: *Risk Analysis: An Official Publication of the Society for Risk Analysis* 21.1 (2001), pp. 199–206. ISSN: 0272-4332. DOI: 10.1111/0272-4332.211102.
- [59] David R Smith. “Attention, attention: your most valuable scientific assets are under attack”. In: *EMBO reports* 19.3 (2018), e45684. ISSN: 1469-221X. DOI: 10.15252/embr.201745684.
- [60] Stuart Soroka, Patrick Fournier, and Lilach Nir. “Cross-national evidence of a negativity bias in psychophysiological reactions to news”. In: *Proceedings of the National Academy of Sciences* 116.38 (2019), pp. 18888–18892. ISSN: 0027-8424, 1091-6490. DOI: 10.1073/pnas.1908369116.
- [61] Birgit Stark et al. “Are algorithms a threat to democracy? The rise of intermediaries: A challenge for public discourse”. In: *Algorithm Watch* 26 (2020).
- [62] John Suler. “The Online Disinhibition Effect”. In: *CyberPsychology & Behavior* 7 (2004), pp. 321–326. ISSN: 1094-9313. DOI: 10.1089/1094931041291295.
- [63] Shalini Talwar et al. “Why do people share fake news? Associations between the dark side of social media use and fake news sharing behavior”. In: *Journal of Retailing and Consumer Services* 51 (2019), pp. 72–82. ISSN: 09696989. DOI: 10.1016/j.jretconser.2019.05.026.
- [64] The Economic Times. “No time to kill: How smartphone is pushing chewing gum out of fashion”. In: (2017). ISSN: 0013-0389.
- [65] European Union. “Regulation (EU) 2022/2065 of the European Parliament and of the Council of 19 October 2022 on a Single Market For Digital Services and amending Directive 2000/31/EC (Digital Services

- Act)”. In: *Official Journal of the European Union* (2022).
- [66] Tommaso Venturini. “From fake to junk news: The data politics of online virality”. In: *Data politics*. Routledge, 2019, pp. 123–144.
- [67] Serena Villata et al. “Assessing Persuasion in Argumentation through Emotions and Mental States”. In: *Proceedings of the Thirty-First International Florida Artificial Intelligence Research Society Conference, FLAIRS 2018, Melbourne, Florida, USA. May 21-23 2018*. AAAI Press, 2018, pp. 134–139.
- [68] Soroush Vosoughi, Deb Roy, and Sinan Aral. “The spread of true and false news online”. In: *Science* 359.6380 (2018), pp. 1146–1151. ISSN: 0036-8075, 1095-9203. DOI: 10.1126/science.aap9559.
- [69] Emily K Vraga and Leticia Bode. “Correction as a solution for health misinformation on social media”. In: *American Journal of Public Health* 110.S3 (2020), S278–S280.
- [70] Adrian F Ward et al. “Brain drain: The mere presence of one’s own smartphone reduces available cognitive capacity”. In: *Journal of the Association for Consumer Research* 2.2 (2017), pp. 140–154.
- [71] Przemyslaw M. Waszak, Wioleta Kasprzycka-Waszak, and Alicja Kubanek. “The spread of medical fake news in social media – The pilot quantitative study”. In: *Health Policy and Technology* 7.2 (2018), pp. 115–118. ISSN: 2211-8837. DOI: 10.1016/j.hlpt.2018.03.002.
- [72] Dan Whateley. *TikTok’s music influence is ‘exhausting’ artists and marketers alike as the industry grapples with the pressure to go viral*. 2023.
- [73] Joe Whittaker et al. “Recommender systems and the amplification of extremist content”. In: *Internet Policy Review* 10.2 (2021). ISSN: 2197-6775.
- [74] Razieh Nokhbeh Zaeem, Chengjing Li, and K. Suzanne Barber. “On Sentiment of Online Fake News”. In: *2020 IEEE/ACM International Conference on Advances in Social Networks Analysis and Mining (ASONAM)*. 2020, pp. 760–767. DOI: 10.1109/ASONAM49781.2020.9381323.
- [75] David Zendle and Paul Cairns. “Video game loot boxes are linked to problem gambling: Results of a large-scale survey”. In: *PloS one* 13.11 (2018), e0206767.
- [76] Manoush Zomorodi. *Bored and brilliant: How time spent doing nothing changes everything*. Pan Macmillan, 2017.