

# ALGORITHMES DE RECOMMENDATION MUSICALE, INEQUALITES ET “BIAS”

RAQUEL CAMPOS VALVERDE – POSTDOCTORAL RESEARCH FELLOW

MUSICSTREAM – UNIVERSITY OF LEEDS

[R.CAMPOSVALVERDE@LEEDS.AC.UK](mailto:R.CAMPOSVALVERDE@LEEDS.AC.UK)

@RAQUELPHD



## CONTEXTE

- Débats autour des plateformes de streaming et leurs ‘algorithmes’, ou plutôt sur l’utilisation de systèmes de recommandation de contenus culturels en ligne
- Recherche précédente commissionnée par le gouvernement du Royaume-Uni « *UK House of Commons DCMS Select Committee’s Inquiry into The Economics of Music Streaming (2020-21)* »

## QUESTIONS/DÉBATS DANS LE 'DCMS INQUIRY'

- Plusieurs contributions concernant « les algorithmes, comme d'autres systèmes de recommandation, peuvent reproduire certaines préférences [bias] et réduire l'exposition de nouvelles musiques au public, homogénéiser ces préférences et affaiblir les artistes indépendants »
- Beaucoup de témoignages envoyés par des artistes et créateurs de contenu « critiquant l'opacité de l'édition algorithmique [algorithmic curation], et faisant appel à une supervision plus proche [de la part du gouvernement] »

## QUESTIONS/DÉBATS

- Dans l'industrie musicale, une préoccupation pour les systèmes de paiement et les potentiels formes de 'payola' [payer pour emplacements/promo dessous-de-table], y compris des accords pour meilleurs emplacements en acceptant des réductions des royalties
- Pour le gouvernement et l'industrie, une préoccupation sur leur position dans le marché globale, et un possible situation défavorable du RU dans des systèmes construits autour du nombre totale de morceaux joués, qui bénéficierait des grands territoires ou des zones plus peuplés [par exemple, les Etats-Unis].

## RÉPONSE DU GOUVERNEMENT

- Le Comité recommandait que « le gouvernement commissionne une enquête sur l'impact des plateformes de streaming et les 'algorithmes de recommandation musicale' [music consumption] »
- Le gouvernement a acceptée cette recommandation, tout en faisant référence à des enquêtes déjà publiées, par exemple le *Centre for Data and Ethics Innovation 2020 report on bias in (general) algorithmic decision-making* (CDEI 2020) et les contributions sur les algorithmes de recommandation incluses dans le *Music Creators' Earnings report* commissionnée par le bureau de propriété intellectuelle [UK Intellectual Property Office] (Hesmondhalgh, Osborne, Sun and Barr, 2021)

# COMMISSION DE L'ANALYSE DOCUMENTAIRE

Le gouvernement a mis en charge de cette enquête le *Centre for Data Ethics and Innovation (CDEI)*

Comme première mesure, le CDEI a commissionnée une analyse documentaire autour de trois problèmes:

- Les questions de préférences [bias] dans les algorithmes de recommandation musicale dans les plateformes de streaming – quels sont les effets pour différents collectifs d'artistes et consommateurs?
- La question de la diversité: impacts positifs et négatifs des algorithmes sur la diversité du marché musical
- Questions de transparence, opacité, et supervision



Professor David Hesmondhalgh



Dr D. Bondy Valdovinos Kaye



Dr Raquel Campos Valverde



Dr Zhongwei 'Mabu' Li

# NOTRE TRAVAIL

- L'équipe de recherche pour *MUSICSTREAM: Music Culture in the Age of Streaming* (Conseil Européen de la Recherche 2021-2026, University of Leeds) a été mis en charge de produire cette analyse documentaire (approx. 25,000 mots) en 2022

<https://www.gov.uk/government/publications/research-into-the-impact-of-streaming-services-algorithms-on-music-consumption/the-impact-of-algorithmically-driven-recommendation-systems-on-music-consumption-and-production-a-literature-review>

- L'analyse documentaire est publiée ensemble avec le rapport du CDEI

<https://www.gov.uk/government/publications/research-into-the-impact-of-streaming-services-algorithms-on-music-consumption>

## CONTENU DE L'ANALYSE DOCUMENTAIRE

- Une des publications plus exhaustives sur les algorithmes et les systèmes de recommandation musicale (je crois!)
- Construit un dialogue entre la recherche existante dans l'informatique [computer science] et les études critiques de sciences sociales et humanités, notamment les *critical algorithm studies*
- S'occupe des potentiels problèmes créés par les plateformes de streaming et leur systèmes de recommandation, comme par exemple la reproduction, aggravation [ou contestation] des inégalités déjà existantes dans la production et consommation de la musique

# CONTENU DE L'ANALYSE DOCUMENTAIRE (RESUME)

1. Approches critiques vers les systèmes de recommandation: informatique et science sociales et humanités
2. Le rôle des algorithmes dans la recommandation musicale
3. Les problèmes de préférence/influence [bias]
  1. Popularité
  2. Genre [gender]
  3. Nationalité/ Localisation
4. Transparence, opacité et supervision

# 1. APPROCHES CRITIQUES (INFORMATIQUE)

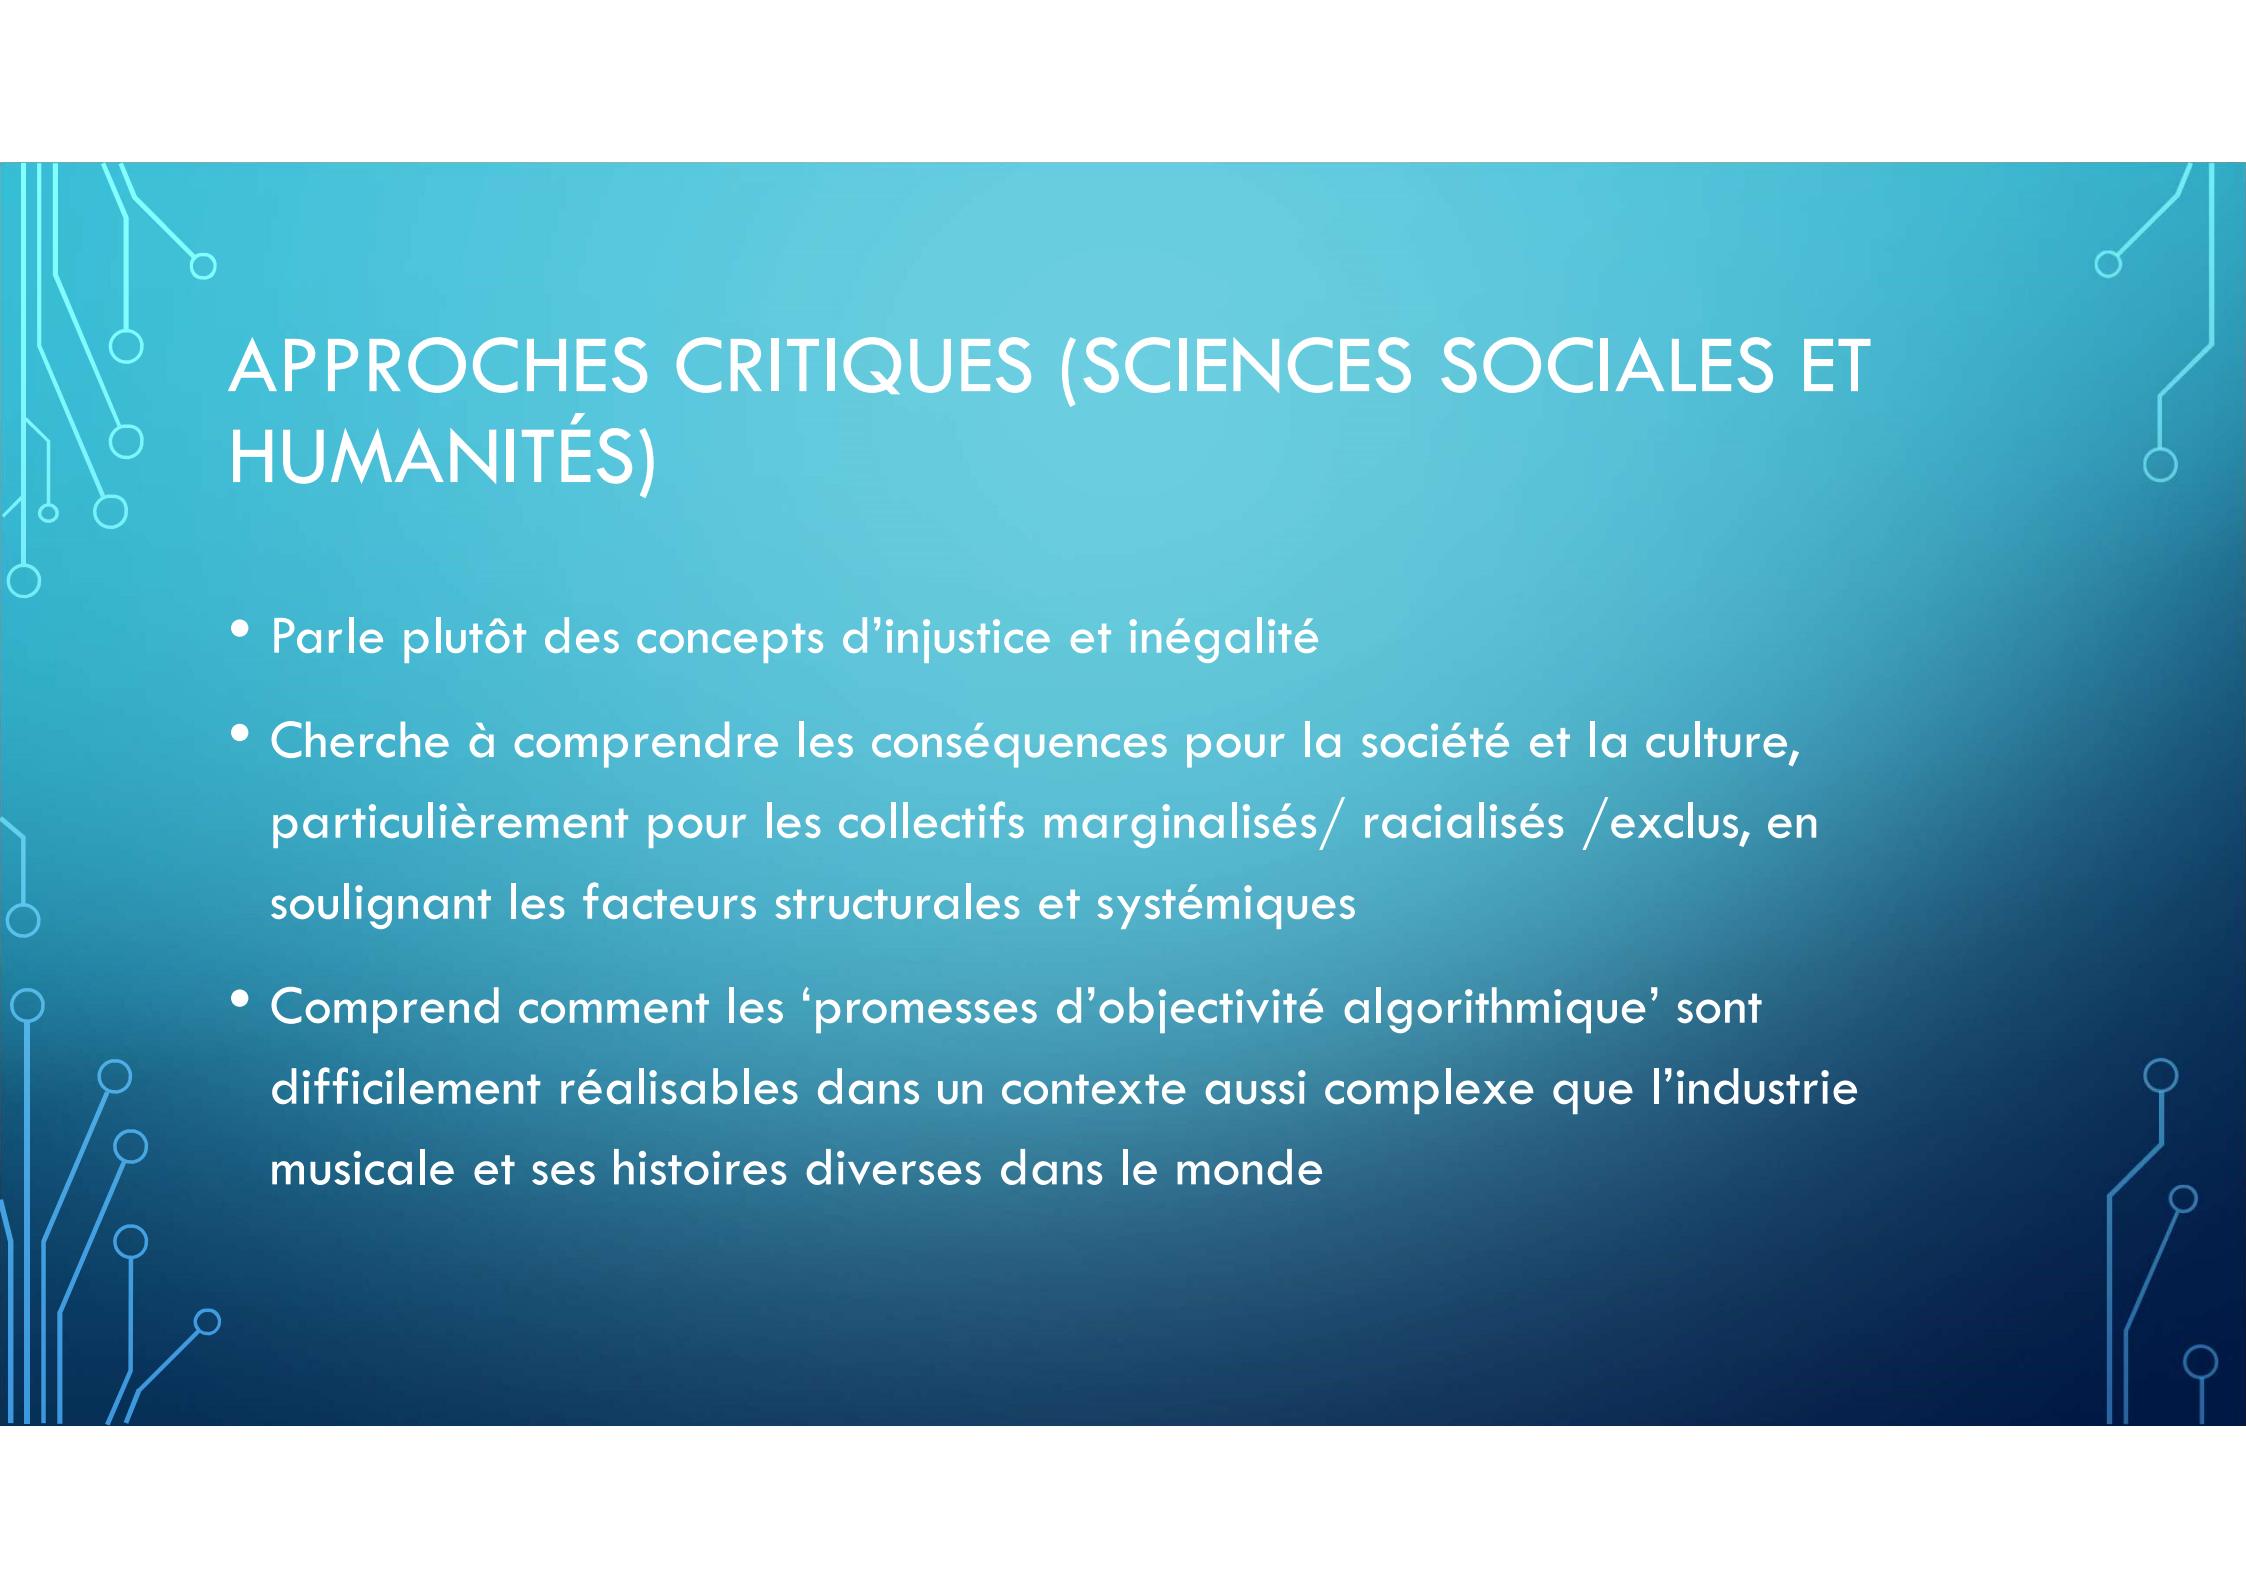
- L'analyse utilise principalement les publications académiques d'informatique [academic computer science], où il y a un vaste nombre de publications sur les systèmes de recommandation en général, y compris spécifiquement pour la recommandation musicale
- Certaines publications appartenant à la récupération des données sur la musique [music information retrieval] sont aussi incluses quand elles étudient les moyens d'identification et classification

# LE CONCEPT DU “BIAS”

- Concept statistique, utilisé dans l'informatique comme antonyme de l'impartialité, mis en relation avec des idées de transparence et responsabilité
- Approche l'éthique de la recherche et du développement du numérique de manière technique
- Maintenant devenu un concept populaire dans les équipes de développement des produits numériques, et aussi dans le système législatif

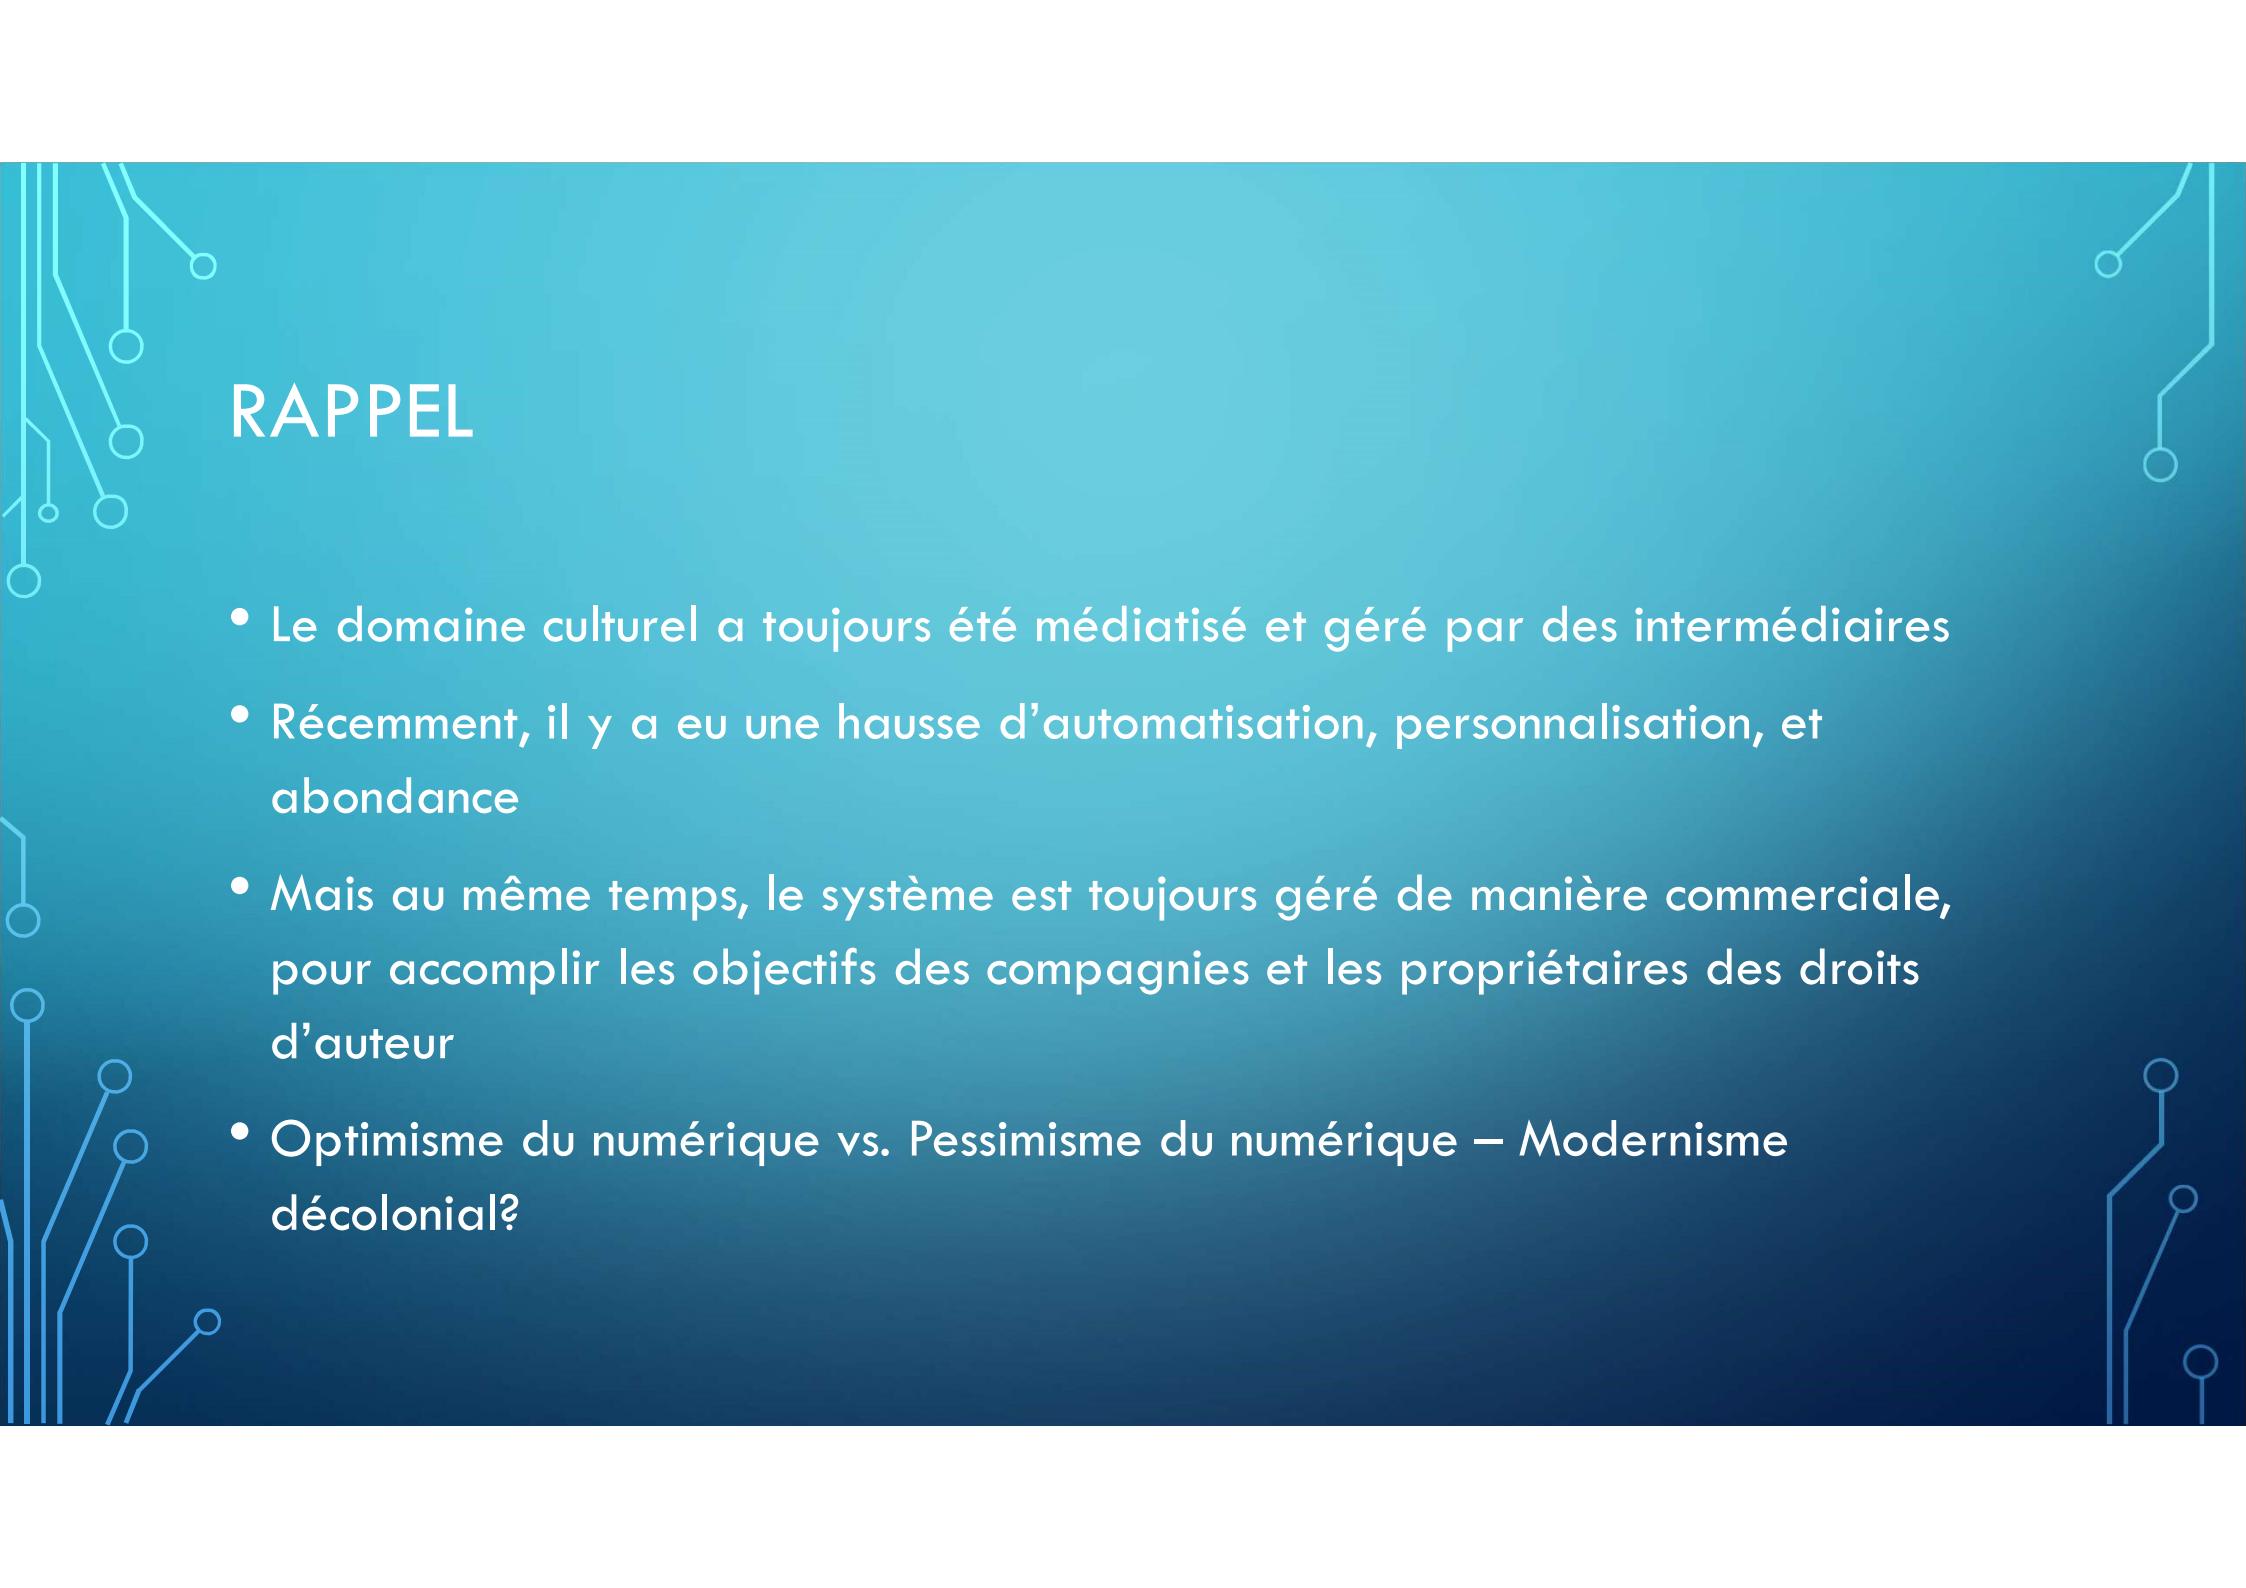
## APPROCHES CRITIQUES (SCIENCES SOCIALES ET HUMANITÉS)

- Par exemple dans la recherche anglophone, *critical internet studies* et *critical algorithm studies* critiquent ces approches réductionnistes des problèmes du numérique
- Reconnaissance des racines historiques et sociales de ces problèmes (tels que le racisme et la discrimination), pas toujours faciles à capturer dans les formules mathématiques des algorithmes
- “mathematical fairness criteria are mutually exclusive” (AI Now think tank)



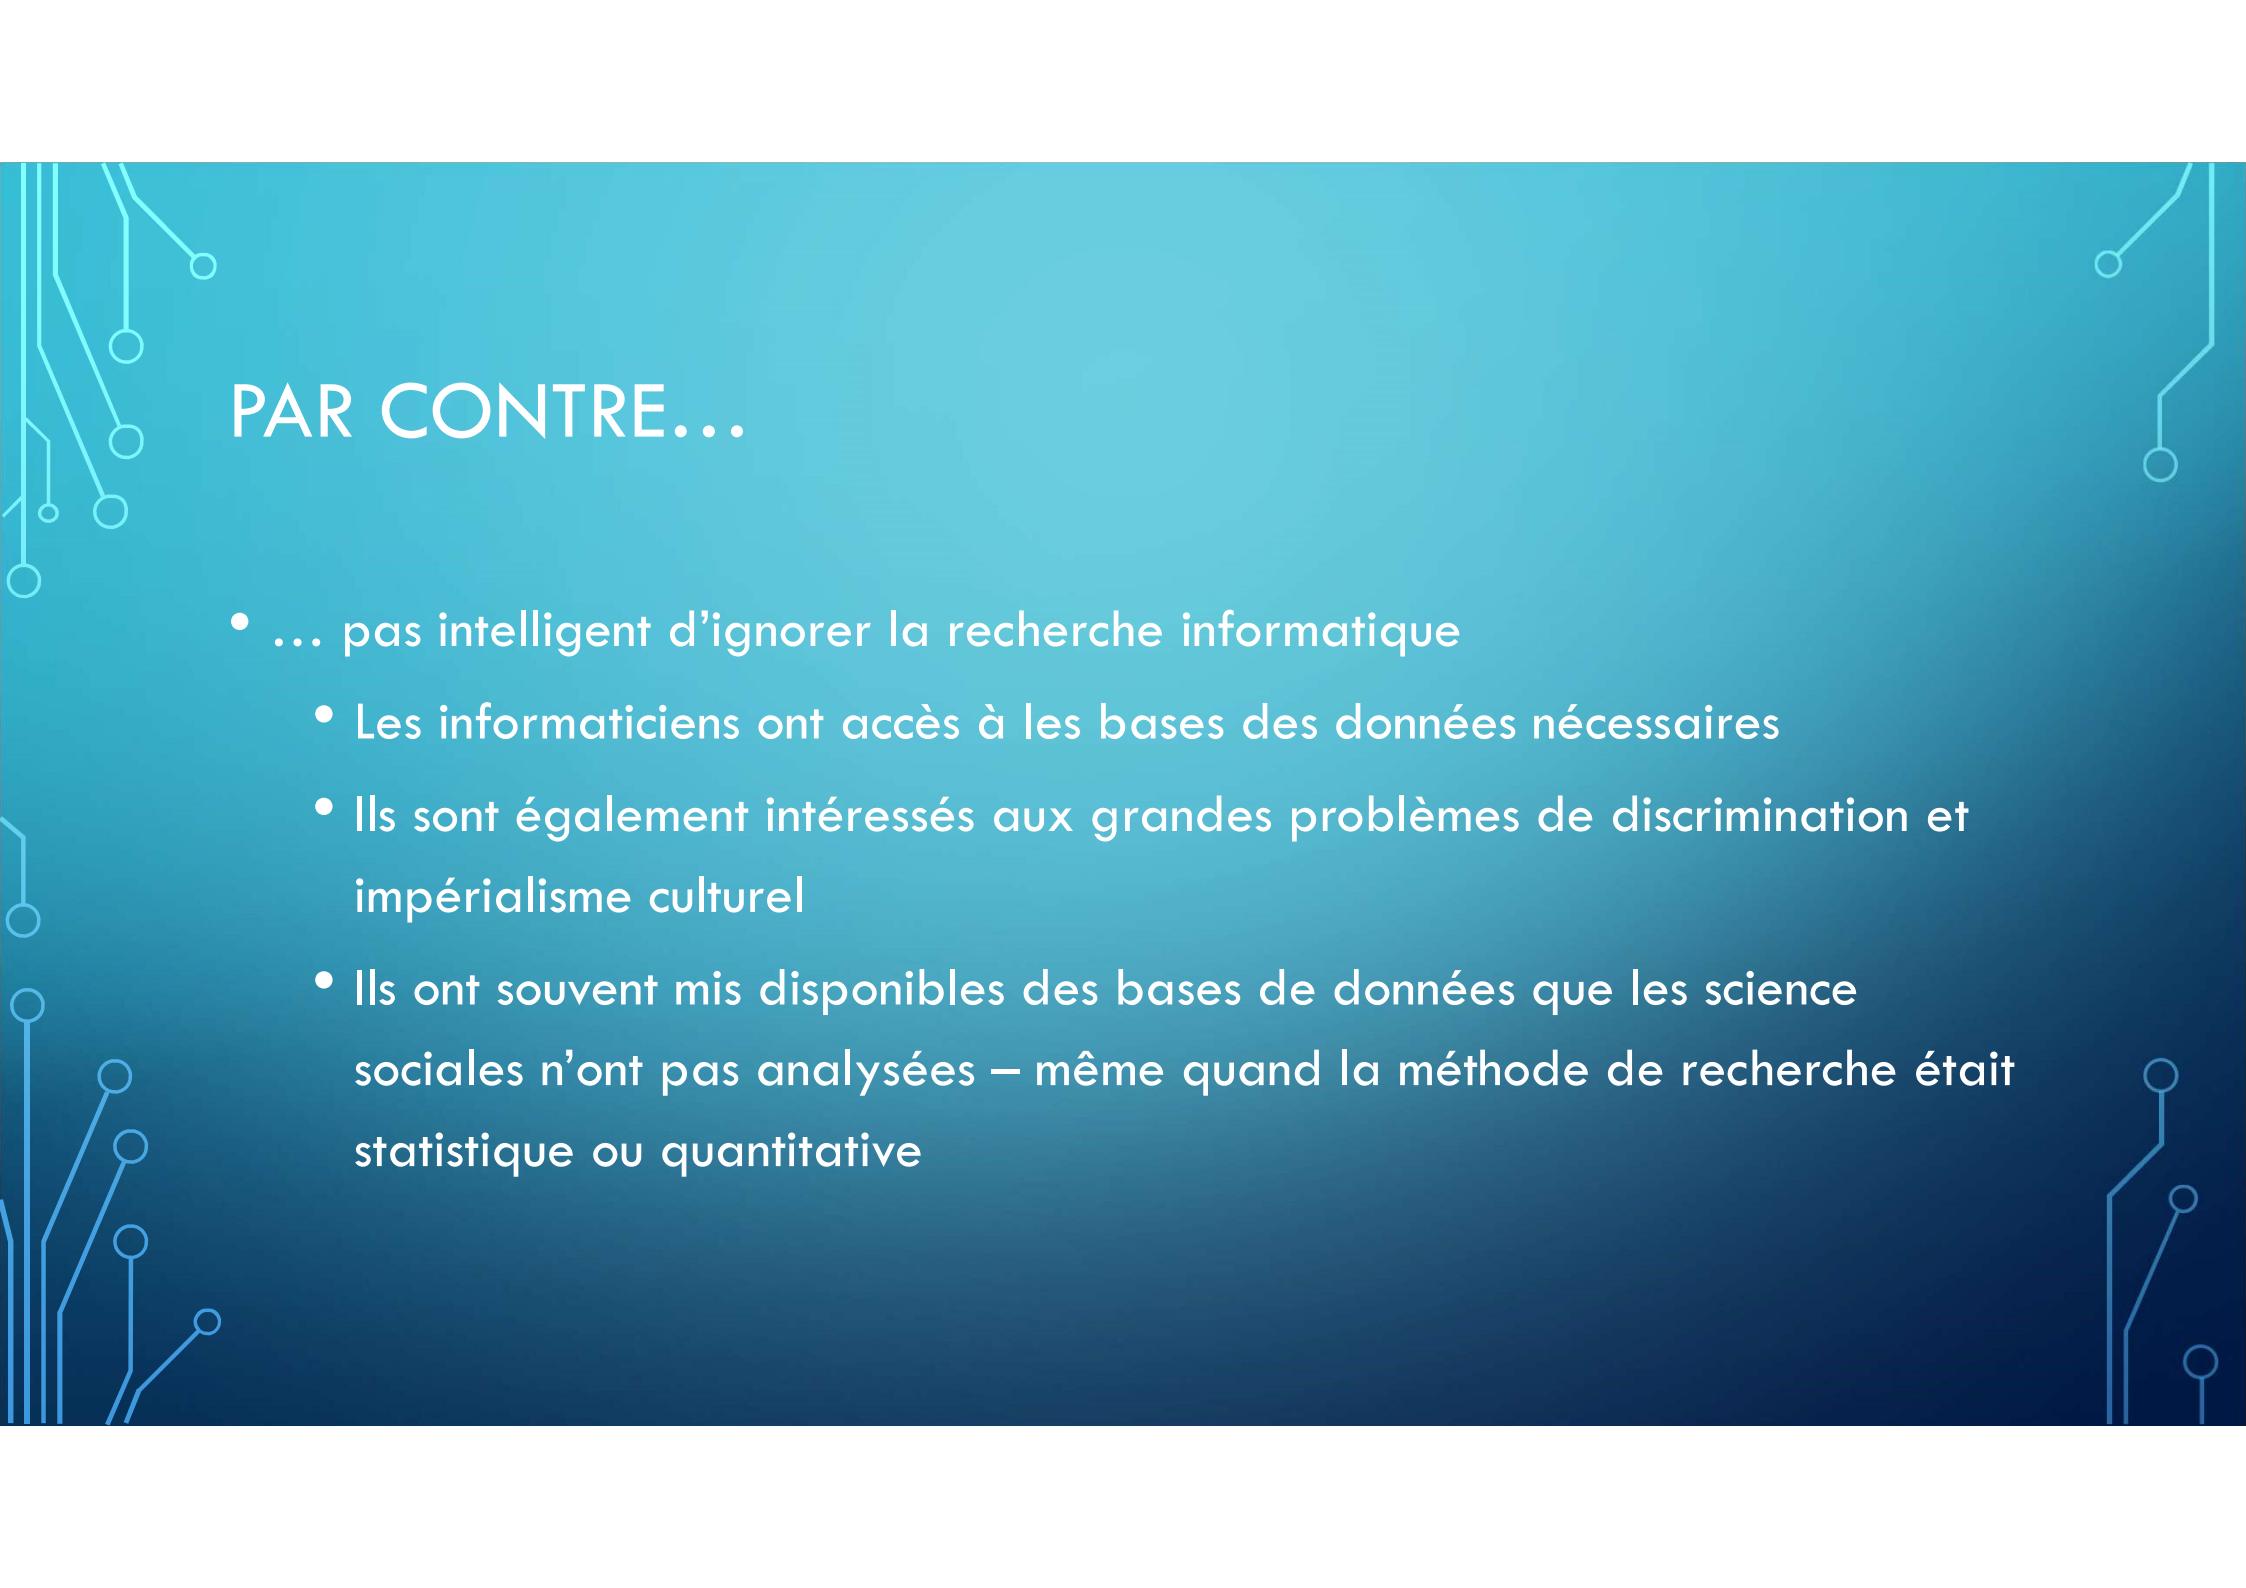
## APPROCHES CRITIQUES (SCIENCES SOCIALES ET HUMANITÉS)

- Parle plutôt des concepts d'injustice et inégalité
- Cherche à comprendre les conséquences pour la société et la culture, particulièrement pour les collectifs marginalisés/ racialisés /exclus, en soulignant les facteurs structurales et systémiques
- Comprend comment les 'promesses d'objectivité algorithmique' sont difficilement réalisables dans un contexte aussi complexe que l'industrie musicale et ses histoires diverses dans le monde



## RAPPEL

- Le domaine culturel a toujours été médiatisé et géré par des intermédiaires
- Récemment, il y a eu une hausse d'automatisation, personnalisation, et abondance
- Mais au même temps, le système est toujours géré de manière commerciale, pour accomplir les objectifs des compagnies et les propriétaires des droits d'auteur
- Optimisme du numérique vs. Pessimisme du numérique – Modernisme décolonial?



## PAR CONTRE...

- ... pas intelligent d'ignorer la recherche informatique
  - Les informaticiens ont accès à les bases des données nécessaires
  - Ils sont également intéressés aux grandes problèmes de discrimination et impérialisme culturel
  - Ils ont souvent mis disponibles des bases de données que les science sociales n'ont pas analysées – même quand la méthode de recherche était statistique ou quantitative

## 2. LE RÔLE DES ALGORITHMES DANS LA RECOMMANDATION MUSICALE

- Les systèmes de recommandation musicale sont aussi algorithmiques que éditoriales (humains), y compris les listes et compilations qui sont souvent le centre des débats

# COMMENT ÇA MARCHE?

- Trois systèmes:
- 1. *Collaborative filtering* – le procès d'évaluation ou filtration du contenu depuis les opinions/évaluations d'autres utilisateurs (mais en musique, pas d'évaluations explicites suffisantes)
- 2. *Content-based* – recommandent des contenus similaires (dépendant des métadonnées et des classifications taxonomiques)
- 3. *Contextual* – utilisent les données des utilisateurs (heure, endroit, activité, émotion, personnalité etc) – essentiel pour la personnalisation mais extrêmement invasif

## COMMENT ÇA MARCHE POUR LA MUSIQUE?

- Systèmes hybrides de recommandation automatique pour créer une ‘radio’ à partir d’un morceau
- Pensés pour la musique parce que un seul utilisateur consomme plusieurs morceaux à chaque écoute/engagement
- Parfois pas logique ou effectif

### 3. RECHERCHE SUR “BIAS”

- Popularité
- Démographique:
  - Gender
  - Nationalité / Localisation

# 1. POPULARITÉ

- Tendance des SRM à recommander le contenu qui est déjà populaire, renforcement des superstars – *winner takes all*
- Opposé à l'image 'démocratisante' du numérique (*long tail thesis*)
- Mais les SRM sont pas configurés seulement par rapport à la popularité des contenus, normalement posant en équilibre la popularité, la nouveauté, la découverte, et la adéquation – processus complexe

## POPULARITÉ: CONTENU DE L'ANALYSE

- Exemple: Spotify
- 2018: top 500,000 morceaux aux USA joués 12.2 fois comparés à tous les autres morceaux disponibles ensemble (14.6 en 2017)
- Source: *Music Business International*
- Est-ce que cela indique des corrections de la part de Spotify?

## POPULARITÉ: CONTENU DE L'ANALYSE

- Dans le sciences sociales et humanités, très peu de recherche à propos de ce sujet, y compris concernant les sources du problème
- Culture du secret - Pas d'information sur ce qui se passe directement dans ces entreprises
- Dans l'informatique, quelques publications adressent ce problème et comment le réduire, par exemple des expériences pratiques qui cherchent un équilibre entre la satisfaction des consommateurs, la pertinence des recommandations, et l'impartialité vers les artistes (Mehrotra et al. 2018)

## 2. GENDER: CONTENU DE L'ANALYSE

- Pas mal de recherche en **science sociales** indique une favoritisme vers les artistes de sexe masculin:
- Maria Eriksson et Sofia Johansson (2017) – expérience avec 288 comptes bots Spotify (144 'male' et 144 'female'): Sur 485 artistes recommandés, 80% masculin, 15% féminin, 5% groupes mixtes 😞
- Ann Werner (2020): expérience avec artistes recommandés, utilisant Damien Rice comme source - Résultats majoritairement masculins et blancs
- Liz Pelly (2018): les listes des chansons plus populaires sont « clairement dominées par les hommes »

## GENDER: CONTENU DE L'ANALYSE

- Expériences **informatiques**:
- Schedl, Hauger et al. (2015): expérimentent avec différentes combinaisons algorithmiques pour recommander des artistes de genre différent
- Le succès de ces expériences est mesuré de manière informatique, en termes de ‘précision’, ‘rappel’ et ‘satisfaction’ – en plus, très peu de différence entre les chiffres de satisfaction des consommateurs hommes/femmes
- Shakespeare et al. (2020): TOUS les systèmes algorithmiques testés sur une (petite) base de données disponible dans Last.fm donnent les mêmes résultats en termes de « bias »: une amplification des problèmes déjà existantes dans les données (c-à-d une préférence pour les artistes masculins)

## GENDER: CONTENU DE L'ANALYSE

- Des basses de données plus grandes donnent des résultats plus complexes:
- Aguiar et a. (2021): le bas pourcentage de femmes qui ont du succès « est principalement à cause des bas pourcentages de femmes dans la plateforme, plutôt qu'à cause des décisions sur les listes »

## GENDER: CONTENU DE L'ANALYSE

- Epps-Darling et al. (2020): L'équipe inclut 2 chercheurs chez Spotify avec accès à une grande base de données extraite des vrais utilisateurs (pas une simulation construite sur une base de données disponible publiquement) –
- Résultats:
  1. Généralement, les utilisateurs écoutent moins artistes femmes ou groupes mixtes qu'artistes hommes, mais il y a des grandes différences selon le style de musique
  2. Les recommandations (algorithmiques ou éditoriales) ont toujours plus d'artistes femmes que le contenu cherché 'organiquement' par les utilisateurs. Mais:
    - Les pourcentages sont toujours bas
    - Ils ont pas séparées les recommandations algorithmiques et éditoriales, donc impossible à savoir si ce sont des « bias » humains ou algorithmiques

### 3. NATIONALITÉ / LOCALISATION: CONTENU DE L'ANALYSE

Les résultats de la recherche informatique semblent contradictoires. Par exemple, chez Spotify:

Way et al. (2020): Base de données 2014-2019 montre des préférences pour les artistes locaux/nationaux, même dans les groupes d'utilisateurs de différents âges et styles de musique.

Anderson et al. (2020): Les recommandations algorithmiques produisent des formes de consommation moins diverses, et quand les utilisateurs ignorent les recommandations l'écoute devient plus variée.

Avec des données de Spotify: Bello and Garcia (2021) les listes de hits sont progressivement devenues plus diverses depuis 2017 dans plusieurs pays différents.

Le problème semble se trouver dans la manière dont 'diversité' est définie dans les différents projets de recherche. Vargas et al. (2014); Garg et al. (2020): style de musique (genre); Ferreira and Waldfogel (2013): nationalité

# NATIONALITÉ / LOCALISATION: CONTENU DE L'ANALYSE

Dans les sciences sociales, longue histoire de recherche sur les inégalités de l'industrie musicale:

- Le hégémonie des États-Unis et le nord global (Negus 1992; Laing 2008) et les formes de 'impérialisme culturel' qui bénéficient le Royaume-Uni ou la France (Malm and Wallis 1992)
- L'influence globale de certains pays comme la Suède (Baym 2011) ou l'interconnexion des labels quand ils représentent des artistes d'un pays moins puissant (Tofalvy and Koltai 2021)
- Les politiques de promo et conception des services de streaming et des labels ayant une vision de l'homme blanc occidental au centre du savoir musical, pour lequel ils fournissent des services de 'audiotourisme' (Seaver 2015; Kassabian 2004)

# NATIONALITÉ / LOCALISATION: CONTENU DE L'ANALYSE

L'informatique n'a pas ignoré ces débats:

- Expériences sur l'effet des personnalisations (Kang and Lam 2021; Koppe 2021; McDonald 2019; Allen et al. 2017; Forsblom et al. 2012; Taramigkou et al. 2013; Zhang et al. 2012) et des recommandations sur les préférences (possiblement déjà inégales) des utilisateurs (Villermet et al. 2021; Roth et al. 2020; Chang et al. 2021).
- Expériences pour améliorer les bases de données avec la récolte d'informations des utilisateurs pour mieux catégoriser les contenus (Barragáns-Martínez et al. 2010a; Barragáns-Martínez et al. 2010b; Sánchez Moreno et al. 2020; Lozano Murciego et al. 2021).
- Les plateformes ont répondu à ces débats avec des campagnes publicitaires de diversification (Spotify Newsroom 2018a; 2018b; 2018c; 2018d)

## NATIONALITÉ / LOCALISATION: CONTENU DE L'ANALYSE

- Les sciences sociales ont soulignés que les utilisateurs peuvent reproduire ces problèmes (Cureño 2021) ou bien les compenser (Besseny 2020) avec leur savoir vernaculaire sur les algorithmes (Seaver 2017; Bishop 2020; Siles et al. 2020; DeVito et al. 2018; Freeman et al. 2022; Haider and Sundin 2021)
- Il est possible que l'on se trouve dans une période d'internationalisation du streaming au niveau financier (Jia and Winseck 2018), du pouvoir (Punathambekar and Mohan 2019), et de la consommation (Leight 2018a).

## 4. DERNIERS POINTS SUR LA TRANSPARENCE, L'OPACITÉ ET LA SUPERVISION DES SRM

- Les débats sur l'opacité du numérique continuent des débats précédents sur les droits d'auteur (jamais faciles à comprendre!) et les structures et le contrôle des médias
- La manque de transparence des entreprises nourrit le mythe du 'black box', mais au même temps les développeurs ne comprennent pas toujours comment l'algorithme marche
- Quel serait le niveau de transparence idéale? Quels informations devraient être publiques, mais sans créer des nouveau risques?
- Il semble évident que les utilisateurs et les citoyens méritent avoir une meilleure compréhension de ces services et leurs problèmes

# CONCLUSION

- Les effets des SRM et ses inégalités doivent s'étudier par rapport a l'histoire de l'industrie musicale et ses problèmes structurels, ainsi qu'en relation avec les inégalités déjà existantes dans la société contemporaine
- Il est désormais nécessaire d'aller au-delà des explications simplistes du rôle négatif des plateformes numériques, particulièrement dans les cas où il y a une manque de données ou indices, tout en reconnaissant les asymétries de pouvoir de l'industrie musicale en général et des systèmes de streaming particulièrement

*“The telecommunications infrastructure is not a metaphor for the conflict, it is the conflict in material form”* Tawil-Souri (2015)



# THANK YOU! MERCI BEAUCOUP!

RAQUEL CAMPOS VALVERDE – POSTDOCTORAL RESEARCH FELLOW

MUSICSTREAM – UNIVERSITY OF LEEDS

[R.CAMPOSVALVERDE@LEEDS.AC.UK](mailto:R.CAMPOSVALVERDE@LEEDS.AC.UK)

@RAQUELPHD

