



www.aileaders-project.eu

Algoritmos de recomendação e Bolhas de informação



Co-funded by
the European Union

Co-funded by the European Union. Views and opinions expressed are however those of the author or authors only and do not necessarily reflect those of the European Union or the Foundation for the Development of the Education System. Neither the European Union nor the entity providing the grant can be held responsible for them.

Este REA (Recurso Educacional Aberto – *Online Educational Resource (OER)*) é um **estudo de caso sobre algoritmos de recomendação e bolhas de informação**, e como isso se relaciona com as práticas de recomendação algorítmica na publicidade.

O caso é essencialmente dividido em duas partes. Primeiro, o caso enfatiza o papel da recomendação algorítmica na formação da distribuição de informação e os riscos associados para a sociedade em geral. A fim de introduzir o conceito de bolhas de informação, analisa o caso do sistema de recomendação do YouTube, explicando a sua mecânica através de um exercício prático que compara diferentes variáveis. As discussões em sala de aula centram-se nas recomendações de conteúdo do YouTube e nos desafios relacionados, bem como nas possíveis soluções.

Através da primeira parte, os alunos também são convidados a refletir sobre como as bolhas de informação e as questões relacionadas com os sistemas de recomendação podem estar relacionadas com as práticas publicitárias. A segunda parte do caso centra-se na recomendação algorítmica utilizada na publicidade online, explicando como este tipo de algoritmos funciona, utilizando a Amazon como exemplo. Em seguida, o caso passa para as possíveis questões relacionadas com a publicidade algorítmica, incluindo a análise do caso dos anúncios do Facebook e como isso pode levar à discriminação. Os alunos são então incentivados a explorar e propor soluções.

Objetivo/Finalidade

O objetivo deste estudo de caso é ilustrar como os algoritmos de recomendação se tornaram uma parte essencial da forma como consumimos informação e conteúdos nas nossas sociedades, bem como destacar os problemas e desafios que surgem com o uso generalizado da tecnologia. Em seguida, o estudo de caso estabelece ligações entre os algoritmos de recomendação em geral e os utilizados para publicidade online, sensibilizando para os usos que podem ser problemáticos e convidando os alunos a explorar possíveis soluções.



Resultados de aprendizagem esperados

- 01** O aluno será capaz de **identificar** desafios éticos e considerações regulatórias na personalização impulsionada pela IA para a sociedade em geral e **relacionar** isso com práticas relacionadas com publicidade.
- 02** O aluno será capaz de **avaliar** o impacto das práticas de personalização nos ecossistemas de informação.
- 03** O aluno será capaz de **propor** possíveis soluções para mitigar os efeitos negativos eficazes dos algoritmos de recomendação nas nossas sociedades e que priorizem a equidade e inclusão.

Abordagem metodológica sugerida

Este caso funciona melhor como aprendizagem baseada em problemas, no qual os instrutores devem orientar uma discussão com os alunos depois que eles se familiarizarem com os conceitos e a tecnologia. São fornecidos tópicos para discussão e possíveis preocupações, mas os instrutores devem incentivar os alunos a pensar por conta própria e identificar outras possíveis preocupações que possam ter. O caso do *YouTube* deve funcionar como material que pode apresentar o problema que pode ser correlacionado com desafios específicos, e o caso *Tournesol* fornece uma possível solução. Para este último, os alunos devem ser incentivados a discutir se a solução pode ser eficaz e a propor melhorias, aperfeiçoamentos ou mesmo outras soluções possíveis.



Palavras-chave

Algoritmos de recomendação, bolhas de informação, publicidade algorítmica, literacia de informação e dados, preconceito

Introdução

Os algoritmos de recomendação tornaram-se um componente crucial das plataformas digitais modernas, influenciando as escolhas dos consumidores em setores como o comércio eletrónico, o entretenimento ou o consumo de notícias. Embora os algoritmos de recomendação **melhorem a experiência do utilizador e aumentem o envolvimento**, também levantam **questões éticas e legais significativas** relacionadas com a privacidade, o preconceito, a manipulação, bem como a desinformação e a informação errada¹.

Em relação à desinformação e à informação errada, os algoritmos de recomendação são motivo de preocupação devido à forma como podem afetar a saúde dos nossos **ecossistemas de informação** e, por extensão, a própria **democracia**. Para que os cidadãos façam as escolhas certas tanto na sua vida privada como na vida pública, é essencial que tenham acesso à informação correta que lhes permita tomar decisões por si próprios com base na informação fiável a que têm acesso.

Uma preocupação relacionada é que **as bolhas de informação**² – ou situações em que os algoritmos expõem os utilizadores apenas a certas instâncias de informação, mas não a outras – podem não só afetar a qualidade da informação que recebemos, mas também contribuir para confirmar os nossos preconceitos, ao não nos expor a outros pontos de

vista e isolar-nos numa realidade própria. Existem receios de que as bolhas de informação se tornem tão extremas que possam até levar algumas pessoas à radicalização e ao extremismo.³

Este estudo de caso explora os desafios éticos que envolvem os algoritmos de recomendação nas nossas sociedades. Os algoritmos de recomendação utilizam **a aprendizagem automática e a inteligência artificial** para analisar os comportamentos dos utilizadores e sugerir conteúdos personalizados. Empresas como a Amazon, a Netflix, o YouTube e o Facebook empregam **sistemas de recomendação sofisticados para aumentar o envolvimento dos utilizadores e impulsionar as receitas**. Estes sistemas baseiam-se em **dados como as interações dos utilizadores, o histórico de navegação e as preferências para selecionar recomendações personalizadas**.

1 No seu livro, *Filterworld*, o jornalista Kyle Chayka discute o papel proeminente dos algoritmos de recomendação na nossa sociedade, para o bem ou para o mal. Aqui está uma entrevista sobre o trabalho de Chayka: <https://www.theverge.com/24094338/kyle-chayka-filterworld-algorithmic-recommendation-tiktok-instagram-culture-decoder-interview>

2 Aqui está uma palestra TED sobre bolhas de informação, também conhecidas como bolhas de filtro: https://www.ted.com/talks/eli_pariser_beware_online_filter_bubbles?language=en

3 Leitura adicional: No caso *Gonzalez v. Google*, julgado pela Suprema Corte dos Estados Unidos, foi discutida a possibilidade de os algoritmos de recomendação levarem à radicalização terrorista. Os alunos podem aceder a um podcast sobre o caso: <https://www.techpolicy.press/a-deep-dive-into-gonzalez-v-google/> Mais informações sobre o caso: <https://www.oyez.org/cases/2022/21-1333>

4 Como a Netflix recomenda coisas para você assistir: <https://www.youtube.com/watch?v=nq2QtatuF7U>

5 Aqui está uma explicação sobre como funciona o algoritmo de recomendação do Spotify: https://www.youtube.com/watch?v=pGntmcy_HX8&t=37s

6 Como o Tik Tok o entende: <https://www.youtube.com/watch?v=nfczi2cl6Cs>

Sistemas de recomendação

Sistema de recomendação do YouTube - Como funciona?

Um dos sistemas de recomendação mais analisados é o **algoritmo do YouTube**. O algoritmo de recomendação do YouTube é um **sistema complexo baseado em IA, projetado para maximizar o envolvimento do utilizador, sugerindo vídeos** personalizados de acordo com as preferências individuais, muitas vezes com base no **histórico de visualizações anteriores**. Ele se baseia em uma combinação de **técnicas de aprendizagem profunda, análise de dados do utilizador e avaliação de conteúdo** para fornecer recomendações personalizadas.

O que impulsiona o algoritmo de recomendação do YouTube?⁷ ...

01 Recolha e processamento de dados:

O YouTube rastreia as interações dos utilizadores, incluindo histórico de visualizações, histórico de pesquisas, *likes*, comentários e partilhas, bem como inscrições e preferências de notificação, tempo de visualização e duração da sessão.

02 Modelos de classificação e previsão:


O algoritmo usa **modelos de aprendizagem profunda para analisar o comportamento passado e prever o que um utilizador provavelmente assistirá a seguir**. Ele avalia diferentes fatores, como a frequência com que os utilizadores clicam num vídeo recomendado; por quanto tempo os utilizadores interagem com um vídeo (tempo de visualização); e *likes*, partilhas e comentários (métricas de interação).

03 Processo de recomendação:

O YouTube utiliza um processo de recomendação que pode ser descrito da seguinte forma:

- **Geração de candidatos:** O sistema primeiro filtra milhões de vídeos para criar um conjunto menor de recomendações relevantes.
- **Pontuação:** outro modelo **pontua e classifica os candidatos para selecionar o conjunto de itens a ser exibido ao utilizador** (de 1 a 10). Como esse modelo avalia um subconjunto relativamente pequeno de itens, o sistema pode usar um modelo mais preciso com base em consultas adicionais.
- **Reordenação:** O sistema deve levar em consideração **restrições adicionais para a classificação final**. Por exemplo, o sistema **remove itens que o utilizador explicitamente não gostou ou aumenta a pontuação de conteúdos mais recentes**.

CLIQUE
PARA
VER



⁷ Ver <https://static.googleusercontent.com/media/research.google.com/en//pubs/archive/45530.pdf>




Figure 2: Overview of YouTube recommendation algorithm (source: Covington et al., RecSys'16).

Isto é basicamente o que acontece dentro do sistema de recomendação do YouTube⁸, que determina o que cada um experimenta nessa plataforma.

CLIQUE
PARA
VER

Veja por si mesmo como funciona o algoritmo do YouTube

O projeto DataSkop da Platform Dynamiken⁹ criou uma simulação do sistema de recomendação do YouTube usando dados doados por utilizadores voluntários. Isso nos permitirá discutir e entender como as diferentes variáveis afetam a lista de vídeos que vemos no YouTube. Clique na imagem a seguir para aceder à simulação.

CLIQUE
PARA
VER

monetization Verified sources Sort by actuality

flora	Valerio	Till
# 545 15 96%	# 698 4 91%	# 565 15 94%
# 777 15 96%	# 886 4 87%	# 138 4 48%
# 432 19 96%	# 474 2 81%	# 777 5 96%
# 895 39 71%	# 730 17 28%	# 433 19 96%
# 138 4 45%	# 728 11 88%	# 855 30 71%
# 698 6 91%	# 487 19 68%	# 275 1 28%
# 886 4 87%	# 282 3 54%	# 439 5 53%
# 316 1 52%	# 910 11 52%	# 171 13 16%
# 275 11 28%	# 934 3 38%	# 946 4 15%
# 336 1 53%	# 585 15 94%	# 338 8 43%
# 474 2 81%	# 777 5 96%	# 750 13 28%
# 780 19 28%	# 433 19 96%	# 898 1 28%
# 946 11 28%	# 804 35 32%	# 813 18 21%
# 728 11 88%	# 886 4 87%	# 658 5 4%

⁸ <https://blog.youtube/inside-youtube/on-youtubes-recommendation-system/>
⁹ <https://dataskop.net/recommender-sim/?en>

O que as plataformas estão a fazer - Esforços do YouTube

O YouTube (e a sua controladora, o Google) parece estar **bem ciente dos problemas** com os seus algoritmos de recomendação. A empresa tem envidado esforços para resolver essas questões.

Por exemplo, o YouTube introduziu funcionalidades como «*Up Next*» para **aumentar a diversidade de conteúdos** apresentados aos utilizadores e **incentivar a exploração**. O YouTube também incentiva os utilizadores a fazerem pausas para evitar o envolvimento excessivo com tipos específicos de conteúdos. O YouTube também **ajustou** o seu algoritmo para **considerar conteúdos novos e em destaque**, a fim de **melhorar a descoberta** de conteúdos diversificados.

O YouTube também usa a verificação de factos para **mitigar os efeitos da desinformação e da informação errada** na sua plataforma, restringe a

monetização de conteúdos enganosos e fez ajustes adicionais nos seus algoritmos para **reduzir a disseminação de conteúdos prejudiciais**. Os utilizadores também passaram a ter mais controlo sobre as suas **configurações de recomendação**, podendo limpar o histórico de visualizações ou marcar conteúdos como "Não interessante" num esforço para **refinar as suas recomendações**.

O YouTube também se esforça para **explicar como o seu algoritmo funciona**, a fim de **aumentar a conscientização** sobre como é decidido o que os utilizadores veem.¹⁰

Intervenções de terceiros

Para resolver questões associadas aos algoritmos de recomendação, está a ser explorada uma série de soluções de terceiros, muitas das quais se concentram em **«intervenções suaves» independentes do conteúdo**, tais como **«disjuntores de viralidade»** que interrompem temporariamente o reforço algorítmico de publicações que se espalham rapidamente, ou a introdução de **«atrito direcionado»** e o uso de prompts e pop-ups que incentivam os utilizadores a ler um artigo antes de o partilhar.

Além disso, legislação como a Lei de Serviços Digitais (DSA) da UE também visa dar mais autonomia aos utilizadores, exigindo que as grandes plataformas ofereçam pelo menos uma alternativa de sistema de recomendação que não se baseie no perfil do utilizador. **De acordo com a lei**, as grandes plataformas são obrigadas a monitorizar ativamente e tomar medidas para mitigar **o que a DSA chama de «riscos sistémicos» ou ameaças que os algoritmos, ou a sua utilização, podem representar para os direitos das pessoas ou para a própria democracia, entre outros**.

Para além de exigir mudanças em plataformas como o YouTube, existem projetos focados na colaboração impulsionada pelos utilizadores para melhorar as experiências dos utilizadores que interagem com sistemas de recomendação, procurando dar-lhes algum controlo sobre o que veem online. Um exemplo disso é **o Project Tournesol**, uma plataforma de código aberto que fornece uma ferramenta para decisões colaborativas.¹¹ **O principal**

objetivo do projeto Tournesol é identificar colaborativamente os vídeos mais interessantes para o público, solicitando a opinião dos colaboradores sobre a qualidade do conteúdo para construir uma grande base de dados aberta de avaliações da qualidade dos vídeos.

O efeito imediato deste banco de dados é **melhorar os vídeos recomendados pelo YouTube, usando as contribuições de milhares de pessoas que usam a plataforma**. O Tournesol também fornece aos usuários **uma extensão de navegador** que permite **exibir vídeos recomendados pela comunidade diretamente na página inicial do YouTube**.

A Tournesol incentiva **a transparência, a partilha de conhecimento e a literacia mediática**, tornando o seu algoritmo e todo o código-fonte **open source** e disponibilizando-os como **Software Livre**. Também disponibiliza a sua base de dados **de forma aberta e gratuita** ao abrigo da Licença *Creative Commons*, na esperança de que isso também ajude a melhorar a investigação sobre algoritmos de recomendação.

¹⁰ Para uma visão geral destes esforços, consulte: <https://developers.google.com/machine-learning/recommendation/overview/types>

¹¹ Leia mais sobre a Tournesol: <https://tournesol.app/about>

Outros exemplos

CaptainFact: ferramenta baseada na web que permite a verificação colaborativa de vídeos da Internet, sobrepondo-os com fontes confiáveis.

Climate Feedback: usa uma rede de cientistas credenciados para anotar artigos online quanto à sua precisão, classificando-os por meio de uma pontuação de credibilidade.



No geral, iniciativas como estas procuram **transferir o poder para as comunidades e especialistas**, para que **avaliem e contextualizem coletivamente a informação**, oferecendo um contrapeso aos algoritmos de recomendação puramente orientados para o envolvimento.

Discussão

De onde vêm os problemas potenciais

O algoritmo do YouTube tem sido criticado por criar **bolhas de informação** ou **labirintos de conteúdo**, como os discutidos na nossa introdução ao caso.

O problema é que parece que os algoritmos de recomendação alimentam continuamente um tipo específico de conteúdo ou estão a polarizar cada vez mais os utilizadores, o que leva a potenciais desinformações e câmaras eco e ideológicas.

Como o algoritmo **atualiza continuamente as recomendações** com base na atividade do utilizador **em tempo real**, ele **prioriza apenas conteúdos** que provavelmente **manterão os utilizadores envolvidos**, o que às vezes pode levar a situações em que apenas **conteúdos semelhantes são repetidamente recomendados**.

Falando sobre as questões

Com base na experiência com o algoritmo do YouTube, agora podemos discutir os **potenciais problemas sociais** associados ao uso de algoritmos de recomendação que determinam o que as pessoas veem online em geral e, em particular, com as bolhas de informação.

Potenciais problemas sociais

01 Preocupações com a privacidade:

- **Violação da privacidade.** Os algoritmos de recomendação dependem de grandes quantidades de dados dos utilizadores, muitas vezes recolhidos sem o consentimento explícito dos mesmos.
- **Falta de consciência e falta de transparência.** Os utilizadores podem não estar totalmente cientes de como os seus dados são utilizados e partilhados.

02 Preconceito e discriminação:

- **Reforço de preconceitos.** Os algoritmos podem reforçar preconceitos existentes ao promover conteúdos que se alinham com comportamentos passados, limitando a exposição a perspetivas diversas.
- **Preocupações com a equidade.** Os preconceitos históricos nos dados de treino podem resultar em tratamento injusto de determinados grupos demográficos.

03 Manipulação e exploração:

- **Algoritmos que buscam primeiro o lucro e, em segundo lugar, ecossistemas de informação saudáveis.** As empresas podem projetar algoritmos para priorizar conteúdos voltados para o lucro em detrimento do bem-estar do utilizador, incentivando o consumo excessivo ou comportamentos não saudáveis.
- **Manipulação do utilizador.** Algumas plataformas utilizam técnicas de design persuasivas para maximizar o envolvimento, muitas vezes à custa da autonomia do utilizador.

04 Desinformação e radicalização:

- Os algoritmos de recomendação podem **amplificar conteúdos enganosos ou sensacionalistas** devido ao seu elevado potencial de envolvimento.
- Os algoritmos de recomendação **também podem ocultar informações importantes** dos utilizadores, diminuindo a qualidade das informações que recebem, mas também levantando preocupações sobre possível **exclusão ou discriminação**.
- Estudos demonstraram que **tais algoritmos contribuem para a disseminação** de teorias da conspiração e ideologias extremistas.

O impacto das bolhas de informação nas empresas

Para as empresas, as redes sociais são uma excelente forma de se conectar com os clientes online, partilhar informações sobre os seus produtos, envolver o público e desenvolver a reputação da marca. A facilidade e rapidez das redes sociais tornaram possível alcançar um público muito mais vasto do que era possível anteriormente.

Ao mesmo tempo, também traz novos riscos para as empresas, pois elas também podem tornar-se alvos de desinformação, que é prontamente consumida por um número significativo de pessoas online.¹²

Outros tipos de empresas, muito diferentes do YouTube, usam algoritmos para recomendar conteúdos ou produtos aos utilizadores. Um excelente exemplo é a **Amazon**, que usa o seu próprio algoritmo para recomendar aos utilizadores produtos que eles podem querer comprar.

O algoritmo da Amazon baseia as recomendações de produtos em **correlações entre produtos** e não em semelhanças entre perfis de utilizadores e o seu comportamento de compra. Isto permite à Amazon evitar a análise de históricos de compras em toda a sua base de dados de clientes. Em vez disso, os investigadores da Amazon utilizaram uma **métrica de relação baseada em probabilidades diferenciais**: o item B está relacionado com o item A se os compradores de A forem mais propensos a comprar B do que o cliente médio da Amazon. Quanto maior for a diferença na probabilidade, maior será a relação entre os itens.¹³

Como os algoritmos de recomendação veiculam anúncios

Os algoritmos de recomendação servem a publicidade **analisando os dados dos utilizadores para apresentar anúncios personalizados**. Estes algoritmos recolhem **dados do histórico de navegação, comportamento de compra, envolvimento com o conteúdo e informações demográficas** para criar **perfis de utilizadores**. Com base nesses perfis, **os anúncios são direcionados aos utilizadores que provavelmente os acharão relevantes**.

Para combinar anúncios com utilizadores, as plataformas utilizam técnicas como a **filtragem baseada em conteúdo, que recomenda anúncios semelhantes a conteúdos visualizados anteriormente, e a filtragem colaborativa**. Muitos sistemas também utilizam modelos híbridos e aprendizagem profunda para refinar ainda mais as recomendações de anúncios. O Google, a Amazon ou a Meta utilizam algoritmos proprietários para apresentar anúncios.

Depois que um anúncio é exibido, os algoritmos rastreiam continuamente as interações, como cliques ou conversões, para melhorar as recomendações futuras. Isso cria um ciclo de feedback que otimiza a exibição de anúncios ao longo do tempo. Plataformas como Google¹⁴, Facebook¹⁵ e Amazon¹⁶ usam esses métodos para maximizar a eficácia dos anúncios e, ao mesmo tempo, manter o envolvimento dos utilizadores.

¹² https://www.pssi.cz/download/docs/8209_764-blog-private-companies-and-disinformation.pdf

¹³ Ver: <https://www.amazon.science/the-history-of-amazons-recommendation-algorithm>

¹⁴ Anúncios do Google explicados pelo Google: <https://business.google.com/es/google-ads/>

¹⁵ Pode ouvir como funciona pelos próprios cientistas da Amazon: <https://www.youtube.com/watch?v=GSQj27ps854>

¹⁶ É assim que funciona o Meta: <https://www.facebook.com/business/news/good-questions-real-answers-how-does-facebook-use-machine-learning-to-deliver-ads#:~:text=Como%20o%20Facebook%20decide%20quais,resultados%20do%20nosso%20leilão%20de%20anúncios>

Potenciais problemas: publicidade e discriminação

Um problema com os algoritmos que recomendam anúncios é que, em geral, os algoritmos de recomendação podem **discriminar ativamente as pessoas**, porque **não são neutros**; são **sistemas sociotécnicos** que podem perpetuar preconceitos sociais, pois **os algoritmos são projetados por humanos e treinados com dados históricos** que podem ser imprecisos, incompletos ou distorcidos, o que pode **levar a um «preconceito de automação»** contra grupos marginalizados com base na raça, género ou orientação sexual.¹⁷

Isto pode ser **particularmente prejudicial na publicidade direcionada**, porque os interesses publicitários, combinados com técnicas de otimização, podem ser usados para **excluir grupos demográficos específicos de oportunidades de habitação, emprego ou crédito**, mesmo sem intenção. Mesmo que a forma como a tecnologia «decide» que anúncios são, ou não, pareça neutra, esta está longe de o ser e pode acabar por perpetuar


a discriminação histórica contra pessoas vulneráveis, algo conhecido como «impacto desigual». ¹⁸

O impacto desigual resultante das práticas de publicidade online foi documentado em várias ocasiões. O que se segue é um dos casos comprovados mais conhecidos em relação às práticas publicitárias do Facebook.

Pesquisa da ProPublica sobre publicidade online e exclusão

Em 2016, a ProPublica, uma organização jornalística, documentou de que forma o sistema de publicidade do Facebook excluía utilizadores de determinados anúncios com base na sua raça, o que é uma prática ilegal nos termos da lei.

CLIQUE
PARA
VER



¹⁷ Ver: Noble, S. U. (2018). Algoritmos de opressão: como os motores de busca reforçam o racismo. New York University Press.

¹⁸ https://www.law.cornell.edu/wex/disparate_impact#:~:text=A%20disparate%20impact%20policy%20or,by%20the%20Wex%20Definitions%20Team%5D

Falando sobre as questões

- 01 Consegue identificar desafios semelhantes aos identificados com o algoritmo do YouTube?
- 02 Que **problemas** potenciais acha que podem surgir da **publicidade personalizada** ou das **recomendações de produtos**?

O que podemos fazer ?

Como podemos ver, **os algoritmos de recomendação em publicidade** são projetados para personalizar conteúdos, analisando dados do utilizador e prevendo preferências. Embora isso melhore a relevância e o envolvimento do anúncio, também pode levar a **consequências indesejadas**, como a exclusão do utilizador, como mostra o caso da ProPublica.

Esses algoritmos **podem reforçar preconceitos** ao limitar a exposição a diversos produtos, serviços ou oportunidades de emprego, afetando desproporcionalmente certos grupos. Além disso, os utilizadores que não se enquadram nos padrões comportamentais comuns podem receber menos recomendações relevantes, o que reduz praticamente o seu acesso a oportunidades.

Como podem os anunciantes e as plataformas **equilibrar a personalização com a inclusão** para garantir que os sistemas de recomendação atendam a um público mais amplo e equitativo?

*Que soluções
você
proporia?*

Sobre o estudo de caso

O estudo de caso tem como objetivo fornecer aos professores exemplos específicos de recomendações algorítmicas utilizadas por empresas de tecnologia relevantes, a fim de explorar o papel que desempenham na sociedade e na formação do nosso ecossistema de informação.

As práticas de empresas conhecidas, como YouTube, Amazon ou Meta, são exploradas para que possamos entender como funciona a recomendação algorítmica bem como os desafios e questões a ela associados. O estudo de caso está essencialmente dividido em duas partes.

A primeira parte é dedicada aos algoritmos de recomendação em geral, explorando o seu papel na determinação das informações e conteúdos que as pessoas consomem, bem como questões relacionadas, como as bolhas de informação. Ao longo dos exemplos e das demonstrações práticas do estudo de caso, o professor deve, para além de explorar as questões e possíveis soluções, garantir que os alunos estabeleçam a ligação entre o uso generalizado de algoritmos de recomendação de conteúdo na sociedade e os seus usos nas práticas publicitárias contemporâneas, que é o foco da segunda parte.

A segunda parte é mais curta, porque a Parte Um deve fornecer aos alunos contexto e conhecimento suficientes para preencher as lacunas e porque a Parte Dois pode ser substituída por outros usos relevantes da recomendação algorítmica na sociedade. Se os instrutores decidirem personalizar o estudo de caso, a Parte Dois pode ser uma tela em branco, onde o instrutor pode decidir se concentrar ainda mais em algoritmos de

recomendação usados para divulgação de notícias, plataformas semelhantes ao YouTube ou outras redes sociais, como Instagram ou TikTok, ou para alimentar modelos de negócios como os adotados pela Netflix, Spotify ou comércio eletrónico no caso da Amazon. Os instrutores também podem optar por se concentrar em seu uso em finanças e bancos, saúde, transporte (Google Maps ou Uber) ou outras áreas além da publicidade.

O estudo de caso é especialmente adequado para explorar os potenciais desafios e riscos da utilização de algoritmos de recomendação na sociedade e é mais útil quando utilizado para sensibilizar para estas questões, a fim de **levar os alunos a pensar criticamente sobre as tecnologias que se tornaram uma parte essencial da nossa economia e da forma como conduzimos os negócios online, bem como, idealmente, levá-los a evitar as armadilhas e propor soluções**. Assim, este estudo de caso deve ser particularmente útil sempre que se quiser dar um **contexto geral de como a tecnologia está a mudar a sociedade, as responsabilidades de um líder empresarial** que lida com a transformação digital e o avanço tecnológico, ou em qualquer aula em que se queira introduzir material que ajude a **pensar criticamente sobre a tecnologia que usamos hoje**.

Sobre os recursos

Ao longo do material, instrutores e alunos encontrarão recursos que os ajudarão a aprender sobre o que está a ser discutido no estudo de caso. Vários vídeos contribuem para explicar como funcionam os algoritmos de recomendação e para identificar problemas ou riscos conhecidos associados à sua utilização.

Existem também links com leituras mais longas que permitem um conhecimento mais aprofundado sobre os tópicos discutidos aqui. Alguns dos recursos, particularmente aqueles representados por uma imagem clicável no estudo de caso, são componentes essenciais, pois são demonstrações práticas dos conceitos discutidos no estudo de caso. Quando for esse o caso, há uma indicação clara convidando o instrutor e os alunos a **clicar na imagem** que os levará ao recurso.

Os materiais de vídeo e as leituras são de curta duração, o que significa que o instrutor pode optar

por atribuí-los como trabalho de preparação antes de vir para a aula para trabalhar no estudo de caso ou, se a estrutura do curso permitir, também podem ser vistos e lidos enquanto se trabalha com o estudo de caso dentro da sala de aula.

Existem alguns **termos técnicos** usados ao longo do estudo de caso. As notas de rodapé geralmente contêm links para vídeos ou textos acessíveis que explicam esses termos. Recomenda-se que o **instrutor se familiarize com esses termos com antecedência**, em preparação para o uso do estudo de caso.

Falando sobre as questões

Introdução

O professor deve apresentar o seguinte exercício preliminar para incentivar a reflexão sobre o tema em questão e garantir que todos os alunos estejam em sintonia.

Exercício preliminar:

- 01** Em grupos, peça aos alunos que explorem os seus perfis individuais **no Netflix¹⁹, Spotify²⁰, TikTok²¹** (ou similares) e anotem os dez programas de TV/músicas mais populares que veem no aplicativo.
- 02** Peça aos membros do grupo que comparem o que veem e discutam as semelhanças e diferenças que observam. **Por que acham que esses conteúdos específicos lhes são mostrados?**
- 03** Peça aos membros do grupo para discutirem **como acham que isso se relaciona com os anúncios que veem nos seus feeds** nas redes sociais, como o Instagram ou o YouTube.

Para a Parte Um

Usando a experiência com o algoritmo do YouTube, o professor deve ser capaz de discutir **os potenciais problemas sociais** associados ao uso de algoritmos de recomendação que determinam o que as pessoas veem online em geral e, em particular, as

bolhas de informação. O professor deve conduzir a **discussão em sala de aula em torno dos seguintes tópicos importantes**, mas também deve incentivar os alunos a **apresentarem e discutirem as suas próprias preocupações**.

Potenciais problemas sociais

- 01 Preocupações com a privacidade:**
 - **Violações de privacidade.** Os algoritmos de recomendação dependem de grandes quantidades de dados dos utilizadores, muitas vezes recolhidos sem o consentimento explícito dos mesmos.
 - **Falta de consciência e falta de transparência.** Os utilizadores podem não estar totalmente cientes de como os seus dados são utilizados e partilhados.
- 02 Preconceito e discriminação:**
 - **Reforço de preconceitos.** Os algoritmos podem reforçar preconceitos existentes ao promover conteúdos que se alinham com comportamentos passados, limitando a exposição a perspetivas diversas.
 - **Preocupações com a equidade.** Os preconceitos históricos nos dados de treino podem resultar em tratamento injusto de determinados grupos demográficos.

¹⁹ Como a Netflix recomenda coisas para você assistir: <https://www.youtube.com/watch?v=nq2QtatuF7U>

²⁰ Aqui está uma explicação sobre como funciona o algoritmo de recomendação do Spotify: https://www.youtube.com/watch?v=pGntmcy_HX8&t=37s

²¹ Como o Tik Tok o compreende: <https://www.youtube.com/watch?v=nfczi2cl6Cs>

- **Potenciais problemas sociais**

03 Manipulação e exploração:

- **Algoritmos que buscam primeiro o lucro e, em segundo lugar, ecossistemas de informação saudáveis.** As empresas podem projetar algoritmos para priorizar conteúdos voltados para o lucro em detrimento do bem-estar do utilizador, incentivando o consumo excessivo ou comportamentos prejudiciais à saúde.
- **Manipulação do utilizador.** Algumas plataformas utilizam técnicas de design persuasivas para maximizar o envolvimento, muitas vezes à custa da autonomia do utilizador.

04 Desinformação e radicalização:

- Os algoritmos de recomendação podem **amplificar conteúdos enganosos ou sensacionalistas** devido ao seu elevado potencial de envolvimento.
- Estudos demonstraram **que esses algoritmos contribuem para a disseminação** de teorias da conspiração e ideologias extremistas.



Para a discussão da Parte Um, os professores devem explorar «o que as plataformas estão a fazer», bem como «intervenções de terceiros» (ver página 6). Os instrutores podem estruturar a discussão em torno de possíveis soluções usando as seguintes sugestões para discussão:


Quem irá resolver o problema e como?

- **Perguntas:**

- 01 Acha que o **YouTube** está a envidar esforços suficientes para resolver o **problema das bolhas de informação** dentro da sua própria plataforma?
- 02 Que **barreiras** ou **conflitos de interesse** vê nos esforços do próprio YouTube?
- 03 O que acha das soluções da **Tournesol**? Vê algum **potencial para um impacto positivo**? Quais são as suas **limitações**?
- 04 Que estratégias podem as plataformas, os decisores políticos e os tecnólogos implementar para **tornar os sistemas de recomendação mais equilibrados, transparentes e resistentes ao preconceito, mantendo** ao mesmo tempo o **envolvimento dos utilizadores**?
- 05 Que soluções **proporia**?

● Para a Parte Um

O professor deve **certificar-se de que os alunos estabelecem as conexões entre algoritmos de recomendação mais gerais**, as questões relacionadas às **bolhas de informação**, os problemas descritos acima e o uso de **algoritmos de recomendação em publicidade**.



Os alunos também devem ser convidados a avaliar as soluções propostas, comparando os problemas identificados para avaliar se as soluções são suficientes e para ter ideias sobre que tipos de soluções devem ser propostas.

● Para conduzir a discussão, os professores podem fazer as seguintes perguntas:

- 01** De que forma os sistemas de publicidade algorítmica **contribuem para a discriminação**, particularmente em áreas como recrutamento de pessoal, habitação e serviços financeiros? Consegue pensar em exemplos do mundo real que ilustrem esses riscos?
- 02** Qual é o papel **dos algoritmos de recomendação** na definição **da forma como os anúncios são direcionados** aos utilizadores?
- 03** Como os algoritmos de recomendação podem levar à **exclusão de certos grupos demográficos do acesso a oportunidades**?
- 04** Como é que a personalização de anúncios cria «**bolhas de filtragem** publicitária» e de que forma isso pode **reforçar a desigualdade económica ou social**?
- 05** Até que **ponto as empresas devem ser responsabilizadas pela discriminação algorítmica** na segmentação de anúncios e que políticas ou regulamentos poderiam promover a equidade na publicidade algorítmica?
- 06** Quais são as **compensações éticas entre maximizar a relevância dos anúncios** para o envolvimento e o lucro e garantir a inclusão na publicidade online?
- 07** Como podem as empresas **equilibrar estas prioridades concorrentes**? Como podem elas **lidar com potenciais preconceitos**?



Leitura adicional

- Jannach, D., Zanker, M., Felfernig, A., & Friedrich, G. (2010). Sistemas de recomendação: uma introdução. Cambridge University Press. <https://www.cambridge.org/core/books/recommender-systems/C6471B59388D8A9F684C49C198691B53>
- Chayka, K. (2024). Filterworld: Como os algoritmos achataram a cultura. Doubleday. <https://www.penguinrandomhouse.com/books/695902/filterworld-by-kyle-chayka/>
- Noble, S. U. (2018). Algoritmos de opressão: como os motores de busca reforçam o racismo. New York University Press. <https://nyupress.org/9781479837243/algorithms-of-oppression/>
- Selbst, A., boyd, d., Friedler, S., Venkatasubramanian, S. & Vertesi, J. (2018). Justiça e abstração em sistemas sociotécnicos (23 de agosto de 2018). Conferência ACM 2019 sobre Justiça, Responsabilidade e Transparência (FAT*), 59-68, disponível em SSRN: <https://ssrn.com/abstract=3265913>
- Kourabi, F., & Tapp, A. (2021). Os desafios éticos dos sistemas de recomendação. arXiv. <https://arxiv.org/abs/2105.05265>
- Sweeney, L. (2013). Discriminação na entrega de anúncios online. Comunicações da ACM, 56(5), 44-54. <https://doi.org/10.1145/2447976.2447990>



leaders

Acompanhe a nossa jornada

www.aileaders-project.eu



Co-funded by
the European Union

Co-funded by the European Union. Views and opinions expressed are however those of the author or authors only and do not necessarily reflect those of the European Union or the Foundation for the Development of the Education System. Neither the European Union nor the entity providing the grant can be held responsible for them.