

# REVISÃO INTEGRATIVA: ADEQUAÇÃO DOS SISTEMAS DE RECOMENDAÇÃO ÀS EXIGÊNCIAS IMPOSTAS PELAS LEIS DE PROTEÇÃO DE DADOS

*Fernanda Forbici<sup>1</sup>*  
*Francyne dos Passos Soares<sup>2</sup>*

## RESUMO

Os sistemas de recomendação têm sido amplamente utilizados em diferentes áreas e tecnologias para promover uma experiência mais personalizada aos usuários e filtrar os conteúdos de acordo com o momento ou o comportamento apresentado, para isso, dados históricos ou pessoais têm sido amplamente aproveitados por algoritmos a fim de realizar a personalização. Em tempos de regulamentação da proteção de dados pessoais, faz-se necessário compreender como as tecnologias de recomendação tem se adequando para atender as diferentes regulamentações existentes mundialmente. Com esse objetivo, foi realizada a pesquisa em julho de 2022 nas bases de dados Scopus e Web of Science com os descritores "sistema de recomendação" e "GDPR" ou "sistema de recomendação" e "privacidade" na língua inglesa. Como resultado, foram identificados 11 estudos que respondem a pergunta de pesquisa que foram tabelados considerando: título, autoria, base de dados e algoritmo utilizado. Na análise, destacam-se as técnicas utilizadas para adaptar os sistemas de recomendações às novas leis de privacidade dos dados dos usuários. Também verificamos que o desempenho desses algoritmos depende de muitos fatores como se há coleta inicial de dados para a recomendação, como é feita a anonimização dos dados, em qual ciclo da gestão do conhecimento esta etapa é realizada, entre outros.

Palavras-chaves: revisão integrativa, sistemas de recomendação, GDPR, LGPD , privacidade

## 1 INTRODUÇÃO

Com a evolução tecnológica e a globalização, a coleta e o compartilhamento de dados pessoais teve um avanço expressivo, principalmente após o surgimento das mídias digitais que, em sua grande maioria, exigem aos seus usuários o cadastro de dados para acesso e informações de geolocalização para promover uma experiência mais personalizada. Essas informações pessoais segundo Frazão (2019) "são de extrema importância para a economia, os dados são transformados em informações nas quais serão utilizadas pelas empresas e grandes negócios."

---

<sup>1</sup> Estudante - Programa de Pós-Graduação em Engenharia e Gestão do Conhecimento – Universidade Federal de Santa Catarina (UFSC) Florianópolis – Brasil. E-mail: fernandaforbici@gmail.com

<sup>2</sup> Estudante - Programa de Pós-Graduação em Engenharia e Gestão do Conhecimento – Universidade Federal de Santa Catarina (UFSC) Florianópolis – Brasil. E-mail: francyne.soares@gmail.com

A preocupação com a coleta desenfreada de dados fez com que muitos países promulgassem regulamentos de proteção de dados que concedem o direito de restringir o processamento de dados pessoais por outras instituições e empresas. (DETERMANN, 2018). Neste contexto, nasceu o Regulamento Geral de Proteção de Dados (GDPR) que entrou em vigor em 2018, mesmo ano em que foi denunciado pelos jornais "The Guardian" e "The New York Times" o caso da Cambridge Analytica, empresa de análise de dados, que segundo declaração do Facebook utilizou "um aplicativo para coletar informações privadas de 87 milhões de usuários sem seu conhecimento" (PRESSE, 2019) com a intenção de usar as informações comportamentais dos eleitores com o fim de direcionar anúncios que influenciassem sua opinião. O caso motivou vários países a criarem suas legislações de proteção de dados pessoais, inclusive o Brasil, que publicou em 2018 a Lei Geral de Proteção de Dados (LGPD). Segundo declaração de Laurence Goasduff (2020) no Virtual Gartner Security & Risk Management Summit "até 2023, 65% da população mundial terá seus dados pessoais cobertos por regulamentos modernos de privacidade."

Os sistemas de recomendação usam a análise de dados para fazer as sugestões, por isso foram diretamente impactados com essas mudanças e precisaram adotar técnicas e métodos para se adequar às legislações mantendo a assertividade combinada a proteção de dados dos usuários. Isso porque, o descumprimento da GDPR pode render a empresa uma notificação em casos de infração leve, nos demais uma multa de 20 milhões de euros ou até 4% sobre a receita anual global da empresa. Já na LGPD, a penalidade pode chegar a 2% sobre o faturamento com limite de 50 milhões de reais.

Considerando esses pressupostos relatados, a pesquisa foi realizada com a finalidade de obter resposta para o questionamento: Como as empresas estão adequando os sistemas de recomendação conforme a previsão da Lei Geral de Proteção de Dados? Sendo assim, o objetivo é compreender quais mudanças e tecnologias foram adotadas por empresas internacionais para proteger a privacidade de dados usados nos sistemas para gerar recomendações aos usuários. Acreditamos que as informações apresentadas nesta revisão sistemática de artigos internacionais contribuirão para as empresas brasileiras adotarem os aprendizados e as tecnologias

que ofereceram maior acurácia nas recomendações preservando a identidade e os dados dos usuários.

A revisão foi organizada da seguinte forma: a seção 2 apresenta o referencial teórico dos sistemas de recomendação, privacidade de dados, GDPR e LGPD, a seção 3 descreve os procedimentos metodológicos usados nesta revisão sistemática, na seção 4 mostra os resultados encontrados, na 5 as discussões e na 6 as conclusões e sugestões para os trabalhos futuros.

## **2 FUNDAMENTAÇÃO TEÓRICA**

### **2.1 SISTEMAS DE RECOMENDAÇÃO**

Sistemas de Recomendação são ferramentas e técnicas de software que fornecem sugestões de itens a serem usados por um usuário, onde o “item” é um termo geral para denotar o que o sistema de recomendação vai sugerir para o usuário, por exemplo uma música para ouvir, um produto para ser comprado, ou uma notícia para ser lida. (Ricci, Rokach & Shapira, 2011)

As recomendações são definidas de acordo com as bases de dados disponíveis e necessitam de um grande volume de dados para computar as saídas. Esses insumos são coletados através de transações efetuadas, compras realizadas, históricos de navegação e dados pessoais, por exemplo.

Os sistemas de recomendação utilizam técnicas de recomendação, em que em determinados contextos apresentam um melhor desempenho de acordo com características como se o item já tem classificação, se o usuário já tem dados suficientes para calcular similaridade com outros usuários, se tem algum fator específico (Ex: localização, horário, estação) a ser levado em consideração para recomendar itens, entre outros. (Ricci, Rokach & Shapira, 2011)

Abaixo são relacionadas algumas das técnicas usadas nos sistemas de recomendações, com suas especificidades.

#### **2.1.1 Sistema de recomendação baseado em conteúdo (CBRS)**

Os sistemas de recomendação podem ser divididos em dois propósitos: O primeiro é estimular determinado usuário a realizar algo, e o segundo é lidar com a

sobrecarga de informações, uma vez que este tipo de sistema extrai os itens mais relevantes de grandes conjuntos de dados. Nesta abordagem os itens devem manter uma lista explícita de suas características, bem como os usuários definir suas preferências em função das características dos itens. A recomendação ocorre quando há a combinação entre a característica do item e a preferência do usuário. O perfil do usuário pode ser construído de forma que ele avalie determinados itens e as características desses itens formem o perfil, ou através da valoração de cada dimensão feita pelo usuário. (Jannach et al., 2010)

### **2.1.2 Sistema de recomendação de filtragem colaborativa (CFRS)**

Conforme Ricci, Rokach & Shapira (2011), nesta técnica é calculado o grau de utilidade do usuário  $u$  para o item  $i$  como uma função (valor real)  $R(u,i)$ . considerando a classificação dos usuários para os itens. A tarefa fundamental de um filtro colaborativo é prever o valor de  $R$  sobre os pares de usuários e itens. Esta técnica não tem bom desempenho na recomendação de novos itens, quando estes ainda não possuem classificações.

A implementação mais simples desta abordagem recomenda ao usuário ativo os itens que outros usuários com gostos parecidos apreciaram no passado. A semelhança da preferência dos usuários é calculada com base no histórico de classificação deles, criando uma correlação de pessoa para pessoa. Os usuários são modelados como uma lista simples contendo as classificações fornecidas pelo usuário para alguns itens. Estes sistemas de recomendações dependem da interação dos usuários com o objetivo de obter boas recomendações para si mesmos enquanto fornecem dados úteis para seus vizinhos. Neste modelo, os usuários podem tendenciar as recomendações quando pontuando os itens de maneira injusta. (Ricci, Rokach & Shapira, 2011)

### **2.1.3 Sistema de recomendação demográfica (DRS)**

Esta abordagem recomenda itens com base no perfil demográfico de demonstração do usuário. A suposição é que diferentes recomendações devem ser geradas para diferentes nichos demográficos, como por exemplo o idioma de um site. Permite que sistemas simples forneçam soluções de personalização eficazes (Ricci,

Rokach & Shapira, 2011). Nesta técnica, são utilizados atributos sócio-demográficos como idade, sexo, profissão, escolaridade.

Esta abordagem é bastante utilizada em partida fria, quando não existem, ou existem poucos dados no perfil do usuário.

#### **2.1.4 Sistema de recomendação baseado em conhecimento (KBRS)**

Esses sistemas de recomendação recomendam itens com base no conhecimento de domínio específico sobre como determinados recursos do item atendem às necessidades e preferências dos usuários, ou como o item é útil ao usuário. Nesses sistemas a função de semelhança estima o quanto da necessidade do usuário (descrição do problema) correspondem às recomendações (soluções dos problemas) com explicações adicionais. (Ricci, Rokach & Shapira, 2011).

Jannach et al., (2010) define que esta abordagem faz as recomendações baseadas em restrições, através de requisitos do usuário como preço máximo por exemplo, ou compatibilidade com as propriedades do item, ou pelas condições de filtragem. Outra forma de fazer a recomendação é baseada em casos, através de consultas interativas, information seeking, ou processo interativo buscando a compreensão (hermenêutica).

#### **2.1.5 Sistema de recomendação sensível ao contexto (CARS)**

Às vezes a utilidade de um usuário para um item depende de outras variáveis, denominadas de contextos, quando não apenas a classificação dos usuários interfere na recomendação, mas também outras informações de tempo real, como por exemplo a localização para locais próximos, ou pela estação climática do ano. O valor temporal das recomendações é relevante para essas recomendações. As recomendações devem ser adaptadas a esses detalhes específicos, o que torna cada vez mais difícil identificar o quão as recomendações são corretas (Ricci, Rokach & Shapira, 2011).

#### **2.1.6 Sistema de recomendação híbrido (HRS)**

São sistemas que combinam mais de uma das técnicas acima relacionadas, onde tenta usar as vantagens de uma técnica, para corrigir a desvantagem de outra. (Ricci, Rokach & Shapira, 2011). Este tipo de abordagem pode ser utilizada quando um novo usuário ou um novo item é criado, chamado partida a frio (cold start).

Tabela 1 - Técnicas no sistema de recomendação

Técnica	Descrição	Uso	Problema
CBRS	Não requer grandes conjuntos de usuários para se atingir acurácia das recomendações e se baseia em dois pontos: descrição das características dos itens e um perfil de usuário que de alguma maneira descreve seu interesse.	alguns domínios com o conceito de Web 2.0 Recuperação e filtragem de informações	-Não indicado para processos de interação infrequente -Novos usuários ainda não tem similaridade. -Novos itens que não foram comprados não tem vínculo com nenhum outro usuário. - Extrair as características automaticamente
CFRS	Usuários que compartilham interesses no passado tendem a compartilhar o mesmo interesse no futuro	Comércio eletrônico, sugestão de filmes ou músicas	-Novos usuários ainda não tem similaridade. -Novos itens que não foram comprados não tem vínculo com nenhum outro usuário.
KBRS	Não depende de dados prévios de avaliação ou interação, mas precisam de dados de aspectos temporais e preferências explícitas por parte do usuário. São calculados independentemente de avaliações de usuários, mas através de similaridades entre as preferências deste e os itens.	Comércio eletrônico, itens consumidos com pouca frequência pelo usuário e/ou com alguma especificidade, onde dificulta construir um histórico	-Dependem de um conhecimento maior sobre o domínio de recomendação - Precisa de uma interação do usuário para definir o perfil
DRS	Fazem recomendações colaborativas baseadas nas informações demográficas do usuário.	Idiomas de sites, recomendações de acordo com a localização	-Custo computacional caro - matrizes esparsas -uso de dados de dispositivos móveis
CARS	Fazem recomendações	Recomendação de	-generalizar o

	baseada nos dados do usuário, do item, mas também do contexto, que é uma informação em tempo real relevante.	viagens, de locais	contexto de forma positiva
HRS	Combina duas ou mais abordagens para gerar recomendações melhores e mais precisas	Quando apenas uma única abordagem não apresenta recomendação relevante, precisando integrar com outras técnicas.	- Como combinar as técnicas -Ponderar resultados de diferentes técnicas

Fonte: baseado em Jannach et al. (2010)

## 2.2. GENERAL DATA PROTECTION REGULATION (GDPR)

A União Europeia publicou em 7 de abril de 2016 em seu Jornal Oficial o Regulamento Geral de Proteção de Dados (GDPR) que revogou a Diretiva de Proteção de Dados 95/46/CE adotada desde 1995. O regulamento é aplicável em toda a Europa e exige a proteção de dados de pessoas que vivem na União Europeia por toda organização que coleta, processa e usa esses dados, independentemente de sua origem. (NALC, 2017) As disposições passaram a ser aplicáveis nos Estados-membros a partir de 25 de maio de 2018, 2 anos após a sua publicação, com o objetivo de garantir que a lei fosse totalmente aplicada em seus países antes do início da vigência.

Segundo o Artigo 5º do Capítulo II referente ao tratamento de dados pessoais do GDPR "os dados pessoais devem ser processados de forma lícita, justa e transparente em relação ao titular dos dados" (UE, 2016). Que vem de encontro à preocupação do regulamento quanto ao consentimento do usuário sobre o armazenamento e tratamento dos dados coletados, a transparência sobre os objetivos do uso dessas informações que podem ser aproveitadas, por exemplo, para a personalização do conteúdo, direcionamento de anúncios nas mídias digitais ou para sugerir recomendações.

São considerados dados pessoais pelo Regulamento: números de identificação, identificadores on-line, dados de localização e outros fatores relacionados ao comportamento de um indivíduo. (BLANCHARD e SMITH, 2016) Foi incluída ainda uma categoria especial para definir os dados: genéticos, biométricos e relativos à saúde. O GDPR é aplicado quando os dados pessoais coletados são armazenados para serem processados de forma total ou parcial por meios automatizados ou manuais por empresas presentes na União Européia, a partir dela foi criada no Brasil a Lei Geral de Proteção de Dados Pessoais (LGPD).

### 2.3. LEI GERAL DE PROTEÇÃO DE DADOS PESSOAIS (LGPD)

A Lei nº 13.709/2018, amplamente conhecida como LGPD (Lei Geral de Proteção de Dados Pessoais), foi publicada em 14 de agosto de 2018 para regulamentar o tratamento de dados pessoais no Brasil, mas entrou em vigor em 18 de setembro de 2020, 2 anos após a sua publicação como a GDPR. Criada "com o objetivo de proteger os direitos fundamentais de liberdade e de privacidade e o livre desenvolvimento da personalidade da pessoa natural" (Brasil, 2018).

Além de proteger os direitos de privacidade e proteção de dados nacionalmente, sua implementação tem um papel importante na adequação das empresas brasileiras ao modelo europeu GDPR, que exige às empresas internacionais com negócios na União Européia aderirem aos seus termos para operar no país, causando uma "globalização regulatória unilateral". (BRADFORD, 2012). Com isso, os países do Terceiro Mundo o reproduziram de forma idêntica ou muito semelhante. (NIEBEL, 2021)

Para se adequar a essas mudanças, a LGPD define como dado pessoal a "informação relacionada a pessoa natural identificada ou identificável" (BRASIL, 2018) e informações como origem racial ou étnica, convicção religiosa, opinião política, filiação a sindicato ou a organização de caráter religioso, filosófico ou político, referente à saúde ou à vida sexual, dado genético ou biométrico (BRASIL,2018), como dados sensíveis. No entanto, pesquisa divulgada pela PMG Academy com 2.700

representantes de organizações em processo de adaptação, mostra que 59% dos participantes mostraram-se inseguros ao implementar as diretrizes.

Pensando nas dificuldades que as empresas estão enfrentando, foram analisados 11 artigos internacionais para compreender as mudanças e os algoritmos que as empresas adotaram para adequar seus sistemas de recomendação às novas Leis de privacidade de dados.

### 3 METODOLOGIA

As buscas dos termos se concentraram no título, resumo e palavras-chave das publicações. Como critérios de exclusão e legibilidade foram considerados: os estudos que continham a relação dos sistemas de recomendação com a LGPD ou GDPR; publicações em qualquer idioma, localização a partir de 2017. Para o levantamento das publicações foram definidas as palavras-chave e também seus sinônimos. Como termo principal para consulta, ficou definido "*recommendation system*" e "GDPR" ou "*recommendation system*" e "*privacy*".

Pela variedade de áreas que utilizam sistemas de recomendação, como turismo, saúde, aprendizagem, comércio, entre outros, optamos por não especificar as subáreas nos filtros.

Tabela 2 - Distribuição dos artigos

BASES	Palavras de busca	ARTIGOS ENCONTRADOS	ARTIGOS EXCLUÍDOS	AMOSTRA PARCIAL	AMOSTRA FINAL
Scopus	"recommendation system" AND Privacy	274	173	101	8
Scopus	"recommendation system" AND GDPR	5	3	2	0
	"recommen				

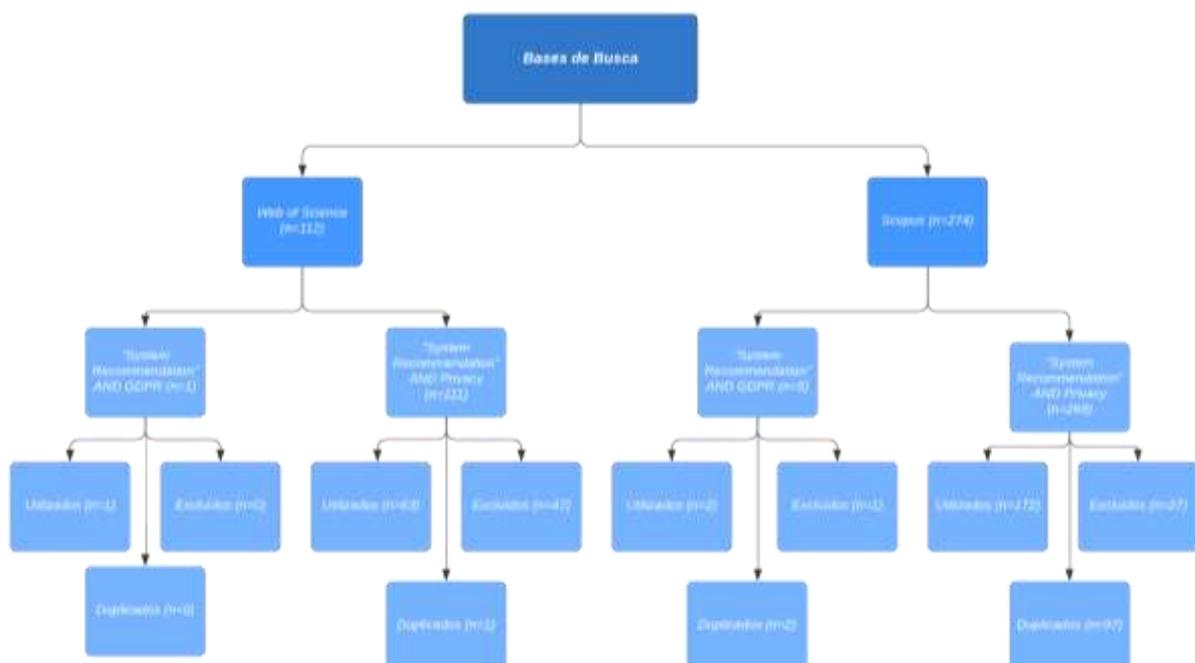
Web of Science	"recommen dation system" AND Privacy	111	47	64	11
Web of Science	"recommen dation system" AND GDPR	1	0	1	0
<b>TOTAL</b>		<b>391</b>	<b>223</b>	<b>168</b>	<b>19</b>

Fonte: elaborado pelas autoras (2022).

Como critério de inclusão foi selecionada a maior quantidade de artigos relevantes em duas bases científicas confiáveis, que tivessem como foco principal demonstrar a correlação entre o uso de dados privados com a acurácia dos sistemas de recomendação.

Desta seleção, foram excluídos os artigos duplicados nas duas bases, e através da leitura dos resumos dos resultados, eliminamos aqueles que não apresentavam a adequação dos sistemas de recomendação à privacidade de dados.

**Figura 2 - Mapa conceitual**



Fonte: elaborado pelas autoras (2022).

Para uma maior filtragem, na amostra final foram consideradas apenas as produções realizadas em 2022, e pela escassez de tempo nos detivemos apenas nos estudos relacionados na base Web Of Science, restando 11 artigos destacados no quadro a seguir.

**Quadro 1. Publicações relativas a consulta "recommendation system" AND Privacy na Web of Science**

<b>ID</b>	<b>TÍTULOS</b>	<b>AUTORES</b>	<b>OBJETIVOS</b>	<b>RESULTADOS</b>
1	A Matrix Factorization Recommendation System-Based Local Differential Privacy for Protecting Users' Sensitive Data	Zheng, Xiaoyao; Guan, Manping; Jia, Xianmin; Guo, Liangmin; Luo, Yonglong	Manter o equilíbrio entre o desempenho do sistema de recomendação e preservação da privacidade dessas informações	Os resultados experimentais mostram que o algoritmo proposto alcança melhor desempenho de recomendação no mesmo nível de preservação de privacidade.
2	Recommendation System for Privacy-Preserving Education Technologies	Xu, Shasha; Yin, Xiufang	Propõe um sistema de recomendação para tecnologias de educação que preservem a privacidade utilizando machine learning e privacidade diferenciada para superar esta questão.	O sistema classificou automaticamente cada aluno em uma categoria com base em suas habilidades, sendo possível usar dados não estruturados, um mecanismo de recomendação inteligente baseado na filtragem colaborativa oferece dados personalizados em tempo real para a privacidade dos usuários.
3	Personalized federated recommendation system with historical	Jie, Zhiyong; Chen, Shuhong; Lai, Junqiu;	Enfrentar o problema da distribuição não independente e idêntica na aprendizagem	Os resultados experimentais mostram que o método de recomendação

	parameter clustering	Arif, Muhammad; He, Zongyuan	federada, é proposto um sistema de recomendação federada baseada no agrupamento de parâmetros históricos.	federada proposto neste artigo tem uma certa melhoria tanto na precisão quanto supera a recomendação personalizada federada cross-end baseada no aprendizado federado tradicional.
4	A Secure and Privacy Preserved Parking Recommender System Using Elliptic Curve Cryptography and Local Differential Privacy	Khaliq, Awais Abdul; Anjum, Adeel; Ajmal, Abdul Basit; Webber, Julian L.; Mehbodniya, Abolfazl; Khan, Shawal	Propõe um sistema de recomendação de estacionamento usando a LDP e ECC como base para um mecanismo de autenticação mútua usando HMAC para fornecer anonimato e integridade	Os experimentos demonstram que, além de preservar a privacidade e a segurança do motorista, nosso modelo proposto tem baixos custos de armazenamento, computação e comunicação.
5	A Safer Approach to Build Recommendation Systems on Unidentifiable	Gupta, Kishor Datta; Sadmanee, Akib; Sadman, Nafiz	Apresentar uma abordagem, ingênua, mas segura, para recomendar filmes aos consumidores sem coletar qualquer informação pessoalmente identificável	Observamos que o D3QN superou as outras duas arquiteturas e alcançou uma precisão de 0,880, recordação de 0,805 e pontuação de F1 de 0,830. Os resultados mostram que podemos construir um sistema competitivo de recomendação de filmes usando dados não identificáveis.
6	A privacy-aware deep learning framework for health recommendation	Selvi, T. Mahesh; Kavitha, V	É proposto um auto-codificador com um esquema de recomendação bidirecional que	A eficiência de desempenho do sistema de recomendação de saúde proposto é

	system on analysis of big data		forneça dados de saúde seguros e eficientes aos usuários finais	melhor, pois a perda é menor do que os métodos tradicionais. O SDDCAED atinge a convergência dentro de um número limitado de iterações e mostra distribuições de perda muito baixas do que os outros métodos, o que indica eficiência de alto desempenho.
7	Nonnegative matrix factorization-based privacy-preserving collaborative filtering on cloud computing	Li, Tao; Wang, Yanqing; Ren, Yongjun; Ren, Yongzhen; Qian, Qi; Gong, Xi	É proposto um algoritmo híbrido baseado na fatoração matricial nonnegative e na tecnologia de perturbação aleatória, que implementa o sistema de recomendação e resolve o problema de proteção dos dados de privacidade do usuário no processo de recomendação sobre computação em nuvem.	A análise e os experimentos reais mostram que o algoritmo não é sensível ao número de vizinhos $k$ e $t$ com base na proteção da privacidade do usuário. Na computação em nuvem, ele pode atingir certa precisão de recomendação e atender às necessidades do sistema de recomendação com base na proteção da privacidade do usuário.
8	Unlearning Protected User Attributes in Recommendations with Adversarial Training	Ganhör C., Penz D., Rekabsaz N., Lesota O., Schedl M.	Identificar a possibilidade e os desafios de remover informações específicas protegidas dos usuários das representações de interações aprendida	Os resultados mostram que Adv-MultVAE atenua amplamente os vieses inerentes ao modelo em ambos os conjuntos de dados

			de um algoritmo RS, mantendo sua eficácia.	
9	Privacy-Preserving Synthetic Data Generation for Recommendation Systems	Liu F., Cheng Z., Chen H., Wei Y., Nie L., Kankanhalli M.	Apresentar um modelo de Geração de Dados Sintáticos Controláveis de Privacidade do Usuário (UPC-SDG), que visa fornecer certas garantias sobre privacidade enquanto maximiza a utilidade dos dados sintéticos tanto do nível de dados quanto do nível de item	. Os resultados experimentais demonstram a eficácia do nosso modelo. Os estudos de ablação validam ainda mais a importância dos vários componentes do nosso modelo.
10	Privacy-preserving federated learning framework in multimedia courses recommendation	Qin Y.J., Li M., Zhu J.	Propor um sistema de recomendação de cursos multimídia capaz de lidar com usuários inscritos em vários cursos e com o risco de vazamento de dados de atividades do usuário centralizados	Os experimentos mostram que os FedMCsRes podem ter um bom desempenho em conjuntos de dados reais. A estrutura não aprendeu totalmente com os dados de treinamento, mas ainda assim atingiram um resultado aceitável.
11	Item-Based Collaborative Filtering Blockchain for Secure Movie Recommendation System	Padhy S.K., Singh A.K., Vetrivelan P.	Propor um sistema que tende a recomendar filmes usando blockchain para manter a privacidade	Não conseguimos acesso neste estudo

Fonte: elaborado pelas autoras (2022).

Para uma melhor análise, as técnicas utilizadas foram agrupadas no quadro abaixo.

**Quadro 2. Tabela de Técnicas aplicadas por artigo**

ID	Abordagem
1	Filtragem Colaborativa
2	Híbrido: Filtragem Colaborativa e decomposição de Matriz
3	Não especificado: O sistema de recomendação é terceirizado
4	Baseada em Conhecimento
5	Híbrido: Demográfico e baseado em conhecimento
6	Híbrido: Filtragem colaborativa e demográfico
7	Filtragem colaborativa com aprendizagem federada
8	Baseado em conhecimento com aprendizagem federada

Fonte: elaborado pelas autoras (2022).

#### **4 ANÁLISE DOS DADOS / RESULTADOS / DISCUSSÃO**

Identificamos que 45% dos estudos utilizaram a técnica de Filtragem Colaborativa, pelo de ser uma técnica usada em vários domínios. A abordagem híbrida foi adotada em 27% dos estudos analisados. Em todos os artigos os autores relataram que foi possível manter a privacidade dos dados, mantendo ou até mesmo melhorando o desempenho dos resultados das recomendações.

Foram verificados também que os sistemas de recomendação foram usados em diversos domínios, como recomendação de cursos, filmes, saúde, estacionamento e outros.

Muitos algoritmos foram aplicados para as técnicas de recomendação, com destaque para os de aprendizagem supervisionado como o K-means, o blowfish, PyTorch, entre outros. Técnicas como blockchain, hash, anonimização foram adotadas nos estudos para manter a privacidade dos dados.

A privacidade dos dados é uma preocupação recente entre os autores, devido às legislações de proteção a dados pessoais vigorarem em diversos países, sendo que só identificamos estudos relacionados à lei europeia e nenhum se referindo a LGPD. Sem o tratamento adequado nos algoritmos, muitos sistemas de recomendação perderam desempenho, e não entregavam os resultados esperados, mas com a combinação de algumas técnicas, ou em alguns casos, incluindo uma

camada de proteção entre os dados e os sistemas de recomendação, todos os estudos relataram resultados satisfatórios.

## 9 CONCLUSÃO

No levantamento de artigos para a realização da revisão integrativa nos deparamos com uma lacuna que não deixou claro se existem pesquisas em andamento sobre as adequações dos sistemas de recomendação à LGPD ou se é um campo de pesquisa ainda não explorado. Surge então, a necessidade de publicitar essa pesquisa para que se desperte o interesse em estudos acerca deste tema, visto que pesquisas estrangeiras já estão abordando como as empresas estão adaptando os seus sistemas de recomendação a regulamentos como a GDPR.

A sugestão é que o artigo sirva de inspiração para que pesquisas sejam desenvolvidas e publicadas para ajudar empresas a adequarem seus sistemas de recomendação. Portanto, em trabalhos futuros sugere-se um novo levantamento a fim de identificar artigos que contemplem informações que relacionem a LGPD com os sistemas de recomendação para servir de base às empresas brasileiras em fase de implementação, ou ainda a realização de um cruzamento de dados para verificar se as mesmas técnicas e algoritmos aplicadas por empresas do exterior aqui levantadas, são as mesmas utilizadas no Brasil. Também é importante relacionar as diversas técnicas de anonimização dos dados, com as técnicas de sistemas de recomendação para conferir a qualidade e acurácia nos resultados de cada um desses, usando uma única fonte de dados para essa análise.

## REFERÊNCIAS

ANTONIO, Adriano Martins. Pesquisa: as empresas estão se adaptando à LGPD? PMG Academy, 2021. Disponível em: <<https://www.pmgacademy.com/blog/noticias/pesquisa-as-empresas-estao-se-adaptando-a-lgpd/>>. Acesso em 2 jun. 2022.

BLANCHARD, Simon; SMITH, Rosemary. ***The General Data Protection Regulation (GDPR) A practical guide for businesses***. BlueVenn, 2016. Disponível em

<[https://www.figarodigital.co.uk/wp-content/uploads/2017/03/GDPR\\_eBook.pdf](https://www.figarodigital.co.uk/wp-content/uploads/2017/03/GDPR_eBook.pdf)>

Acesso em 20 jun. 2022.

BRADFORD, Anu. The Brussels Effect. *Northwestern University Law Review*, Vol. 107, No. 1, 2012. Disponível

em:<[https://papers.ssrn.com/sol3/papers.cfm?abstract\\_id=2770634](https://papers.ssrn.com/sol3/papers.cfm?abstract_id=2770634)> Acesso em 2 jun. 2022.

BRASIL, Lei nº 13.709, de 14 de agosto de 2018. Dispõe sobre a proteção de dados pessoais. Brasília. 2018. Disponível em:

<[http://www.planalto.gov.br/ccivil\\_03/\\_ato2015-2018/2018/lei/l13709.htm](http://www.planalto.gov.br/ccivil_03/_ato2015-2018/2018/lei/l13709.htm)>. Acesso em 16 jun. 2022.

DETERMANN, Lothar. **No One Owns Data**. *Hastings Law Journal*, Vol. 70, No. 1, 2018. Disponível em

<[https://papers.ssrn.com/sol3/papers.cfm?abstract\\_id=3123957](https://papers.ssrn.com/sol3/papers.cfm?abstract_id=3123957)>. Acesso em: 21 mai. 2022.

FRAZÃO, Ana. Lei Geral de Proteção de Dados Pessoais e suas repercussões no Direito Brasileiro. 1 .ed. São Paulo: Thomson Reuters Brasil, 2019. Disponível em <[https://www.academia.edu/40040675/Fundamentos\\_da\\_prote%C3%A7%C3%A3o\\_dos\\_dados\\_pessoais\\_No%C3%A7%C3%B5es\\_introdu%C3%B3rias\\_para\\_a\\_compreens%C3%A3o\\_da\\_import%C3%A2ncia\\_da\\_Lei\\_Geral\\_de\\_Prote%C3%A7%C3%A3o\\_de\\_dados](https://www.academia.edu/40040675/Fundamentos_da_prote%C3%A7%C3%A3o_dos_dados_pessoais_No%C3%A7%C3%B5es_introdu%C3%B3rias_para_a_compreens%C3%A3o_da_import%C3%A2ncia_da_Lei_Geral_de_Prote%C3%A7%C3%A3o_de_dados)>. Acesso em: 21 mai. 2022.

GOASDUFF, Laurence. **Gartner Says By 2023, 65% of the World's Population Will Have Its Personal Data Covered Under Modern Privacy Regulations**.

Gartner, 2020. Disponível em:<<https://www.gartner.com/en/newsroom/press-releases/2020-09-14-gartner-says-by-2023--65--of-the-world-s-population-w>>

JANNACH, Dietmar; ZANKER, Markus; FELFERNIG, Alexander; FRIEDRICH, Gerhard. **Recommender Systems: An Introduction**. New York: Cambridge University Press, 2010.

NALC (The National Association of Local Councils). **Reform of data protection legislation and introduction of the General Data Protection Regulation**. Legal

Briefing, L03-17, 2017. Disponível em <<https://www.nalc.gov.uk/library/members-library/toolkits/gdpr-toolkit/2643-national-association-of-local-councils-general-data-protection-regulation-february-2018>> Acesso em 20 jun. 2022.

NIEBEL, Crispin. *The impact of the general data protection regulation on innovation and the global political economy*. Computer Law & Security Review, v. 40, p. 105523, 2021. Disponível em <<https://www.sciencedirect.com/science/article/abs/pii/S026736492030128X>> Acesso em 18 jun. 2022.

PRESSE, France. Cambridge Analytica se declara culpada em caso de uso de dados do Facebook. G1, 2019. Disponível em <<https://g1.globo.com/economia/tecnologia/noticia/2019/01/09/cambridge-analytica-se-declara-culpada-por-uso-de-dados-do-facebook.ghtml>> Acesso em 05 jun. 2022.

Ricci, F., Rokach, L., & Shapira, B. (2011). **Introduction to Recommender Systems Handbook**. In *Recommender Systems Handbook* (pp. 1–35). Springer US. [https://doi.org/10.1007/978-0-387-85820-3\\_1](https://doi.org/10.1007/978-0-387-85820-3_1)

UE. **Regulation 2016/679 of the European Parliament and of the Council**. Official Journal of the European Union, 2016. Disponível em <<https://eur-lex.europa.eu/eli/reg/2016/679/oj>> Acesso em 18 jun. 2022.