

Nº 179794

Desafios nos sistemas de recomendação: como equilibrar personalização e criatividade?

Cassia de Souza Leal
Adriana Camargo de Brito

*Palestra apresentada no IPT,
Desafios nos Sistemas de
Recomendação 4. 47 slides*

A série "Comunicação Técnica" compreende trabalhos elaborados por técnicos do IPT, apresentados em eventos, publicados em revistas especializadas ou quando seu conteúdo apresentar relevância pública.
PROIBIDO A REPRODUÇÃO, APENAS PARA CONSULTA.



Desafios nos Sistemas de Recomendação: Como equilibrar personalização e criatividade?

Cassia de Souza Carvalho
Adriana C. de Brito



Sistemas de Recomendação

O que são?


- Algoritmos que sugerem itens (produtos, filmes, notícias) relevantes aos usuários.
- Baseiam-se em preferências e comportamento.

Por que são cruciais?

- Combatem a sobrecarga de informação.
- Aumentam o engajamento do usuário.

Onde os encontramos?

- Streaming (Netflix)
- E-commerce (Amazon)
- Redes sociais (TikTok)
- Notícias (Google News)
- Sites de viagem
- Sites de empregos



Técnicas de recomendação

Objetivos

- Maximizar a acurácia das recomendações.
- Apresentar itens mais relevantes para cada usuário.


- Utiliza:

- Comportamento dos usuários
- Características de itens e usuários



Técnicas de recomendação

Comportamento dos usuários



- Explícito

- Avaliações
- Curtidas
- Compartilhamentos
- Comentários
- Compras
- Tempo de vídeo assistido



- Implícito

- Navegação curta por páginas ou postagens
- Falta de interação
- Conteúdo "pulado"




Skip Ad



Técnicas de recomendação

Atributos de itens e usuários



- Características do usuário
 - Gênero
 - idade
 - Interesses
- Características dos itens
 - Gênero de filme
 - Tipo de produto
 - Ano de lançamento



Vamos entender os sistemas?

Tipos de sistemas

Recomendação Baseada em Conteúdo


- Características do item:
 - Segundo preferências individuais do usuário.
 - Sugere itens com atributos semelhantes ao que o usuário interagiu previamente.
 - Ao comprar um livro de romance, sugere outros do mesmo gênero.



Tipos de sistemas

Filtragem Colaborativa


- Comportamento coletivo:
 - Baseada em usuários:
 - Considera usuários com gostos similares.
 - Baseada em itens:
 - Considera itens que foram consumidos por usuários em comum.



Tipos de sistemas

Filtragem Colaborativa


- Os algoritmos de FC podem ser:
 - Baseados em memória:
 - Utiliza todo conjunto de dados para cálculo de similaridades, ou propriedades de grafos em modelagem por grafos.
 - Baseados em modelo:
 - Treinamento e predição com aprendizado de máquina.
- FC agrega diversificação mas sofre com:
 - Impacto de conteúdos muito populares.
 - *Cold-start* (usuários ou itens novos, que ainda não tem registro de atividades).



Tipos de sistemas

Sistemas Híbridos

- Utilizam o comportamento coletivo e preferências individuais, representada por atributos dos itens e usuários.
- Pode usar filtragem colaborativa e baseada em conteúdo separadamente, e depois combinar resultados, ou agregar atributos ao conjunto de preferências, para mitigar *cold-start*. [1]



Limitações comuns dos Sistemas

- **Vício e Polarização**

- Recomendações que priorizam o engajamento.
- Tendência a polarização de opiniões.

- **Viés Algorítmico**

- Sistemas podem perpetuar vieses presentes nos dados de treinamento.
- Recomendações discriminatórias.

- **Falta de Transparência**

- Usuários não entendem por que certos itens são recomendados.
- Desconfiança.

- **Privacidade de Dados**

- Coleta extensiva de dados do usuário.
- Privacidade e segurança das informações pessoais.


- **Conteúdo repetitivo**

- Falta de variedade.
- Falta de acesso a novidades.

Como personalizar sem entediar?


Personalização

- Recomendar mais do que o usuário gosta, alinhado com preferências pessoais e atividade anterior.
- Problema: "bolhas de filtro", que podem entediar e levar a uma visão de mundo limitada.



Descoberta


- Introduzir conteúdo novo e variado.



Como personalizar sem entediar?

Personalização
(Exploitation)


Descoberta
(Exploration)



Como personalizar sem entediar?

- **Experiência do usuário**

- Evitar que o usuário enjoje do conteúdo.
- Manter o interesse no consumo de produtos ou serviços.




- **Ecossistema de criadores**

- Promover conteúdo novo.
- Dar visibilidade a novos criadores de conteúdo.

- **Impacto social**

- Mitigar a formação de "câmaras de eco".
- Promover exposição a perspectivas diferentes.



Estratégias para evitar a superpersonalização

- **Exploração (Serendipidade)**

- Introduzir intencionalmente itens "surpresa" que estão ligeiramente fora do perfil do usuário para expandir seus horizontes.

- **Diversidade**

- Priorizar a apresentação de itens de diferentes categorias, fornecedores ou gêneros nas listas de recomendação.


- **Randomização Controlada**

- Adicionar um pequeno grau de aleatoriedade nas recomendações para introduzir novidades e evitar padrões repetitivos.



Estratégias para evitar a superpersonalização

- **Recomendações baseadas em "Long Tail"**
 - Promover itens menos populares, mas que podem ser altamente relevantes para nichos específicos de usuários.
- **Filtros explícitos**
 - Mecanismos para o usuário evitar conteúdo indesejado, como botões de “não interessado”.
 - Filtros de conteúdo por palavras-chave/*hashtags*.
 - Usuários moldam ativamente a diversidade de seus feeds.




Estratégias para Evitar a Superpersonalização

- **Interfaces que Promovem a Descoberta**
 - Design de UI/UX que encoraja a exploração, com categorias "Para Explorar", "Novidades" ou "Itens Aleatórios".
- **Modelos que Otimizam Diversidade**
 - Algoritmos que incluem uma métrica de diversidade como parte da função de otimização, não apenas a precisão.



Técnicas de exploração


- **Multi-Armed Bandits (MABs)**
 - Algoritmos como ϵ -greedy ou amostragem de Thompson.
 - Alocam dinamicamente uma pequena parte das recomendações para itens menos testados. [2]



Técnicas de exploração

- **Reranking**


- Após um conjunto inicial de candidatos relevantes, uma etapa final de reordenação incorpora explicitamente critérios de diversidade.
 - Exemplos de critérios
 - Proibição de itens consecutivos do mesmo criador, ou a garantia de uma mistura de tipos de conteúdo.
- [3]



Técnicas de exploração


- **Intent-Based Diversification**

- Modela as motivações subjacentes de um usuário.
- Por exemplo, usuário busca por:
 - Entretenimento
 - Aprendizado
 - Pura exploração
- Garante que as recomendações estejam de acordo com essas intenções. [4]



Técnicas de exploração

- **Estratégias de treinamento**
 - Treinar os modelos em todas as interações do usuário, para evitar que o sistema se torne excessivamente especializado, permitindo o surgimento de novos conteúdos.




Casos de Estudo

Casos de Estudo

Meta (Facebook/Instagram)

- **Personalização**

- Arquitetura de classificação em vários estágios: *Retrieval, First-stage, Second-stage, Final-stage*.
- Instagram e Facebook, usando redes neurais (*Two Tower NN*) para restringir bilhões de opções de conteúdo. [5]
- *Sequence learning* em anúncios, para entender o comportamento do usuário, priorizando a relevância. [6]



Casos de Estudo

Meta (Facebook/Instagram)

- **Exploração**

- Instagram Explore:

- Aplica uma etapa final de *re-ranking* para aumentar a diversidade, incluindo regras como "Não mostrar itens dos mesmos autores em uma sequência".
 - Usuários tem controles para ativamente receber ou recusar conteúdo.



- Para anúncios, a diversidade não é o foco principal.

Casos de Estudo

TikTok

- **Personalização**

- O feed "Para Você" é hiper-personalizado.
- Prioriza a relevância do conteúdo em detrimento da popularidade do criador. [7]
- O algoritmo "Monolith" se adapta em tempo real ao *feedback* do usuário, como tempo de exibição, curtidas e compartilhamentos. [8]



Casos de Estudo

TikTok

- **Exploração**

- Esforços para evitar fluxos de conteúdo homogêneos:
 - Não mostra dois vídeos consecutivos do mesmo criador.
 - Promove a descoberta.
- Os usuários têm controles "Não interessado" ou filtrar o conteúdo por palavras-chave. [9]
- Ainda assim:
 - A hiper-personalização pode levar à redução da exposição a conteúdo multicultural.
 - "Efeito solidão". [10]



Casos de Estudo

Youtube

- **Personalização**
 - Utiliza um sistema de rede neural de dois estágios:
 - *Candidate Generation.*
 - Ranking para recuperar e gerar *score* de vídeos relevantes. [11]




Casos de Estudo

Youtube

- **Exploração**

- Estratégia de treinamento de dados:
 - Gera exemplos de treinamento a partir de todas as visualizações dos usuários (mesmo aquelas incorporadas em outros sites).
- Diversificação por intenção:
 - Incorpora as intenções dos usuários, garante recomendações que abranjam essas intenções.
 - Proporciona "diversidade personalizada", ao recomendar conteúdo de outros tópicos com base no histórico de visualizações. [12]



Casos de Estudo

Youtube

- Moderação de conteúdo:
 - Rebaixa informações de baixa qualidade.
 - Promove vídeos confiáveis, especialmente sobre tópicos sensíveis.
- Descobertas empíricas:
 - Pesquisas com "bots contrafactuais" sugerem que o sistema de recomendações do YouTube, especialmente após as mudanças no algoritmo de 2019, tende a moderar, em vez de amplificar, conteúdo extremamente partidário, com as preferências do usuário sendo o fator dominante no consumo. [13]




Casos de Estudo


Netflix

- **Personalização**

- Mais de 80% da atividade de visualização proveniente de recomendações
- Adapta:
 - Os textos da página inicial
 - A arte
 - Conteúdo conforme o horário do dia. [14],[15]



Casos de Estudo



Netflix

- **Exploração**

- Emprega "Algoritmos de Diversidade de Conteúdo" (eg., MAB, FM-Intent)
- Inclui intencionalmente uma ampla gama de gêneros, culturas e vozes, mesmo que estejam fora do histórico imediato do usuário.
- Práticas de dados inclusivas e explicações de recomendação para reduzir bolhas de filtro e viés algorítmico.

**Crianças
tem a
Magic Box**



Como avaliar o sistema?

Tipos de métricas

Relevância

- Medem o quanto o item recomendado está próximo da preferência do usuário.
- Qualidade da recomendação em termos do que o usuário espera.

Diversidade

- Medem o grau de criatividade nas recomendações.
- Identificam vieses, se os itens recomendados representam o todo etc.

Métricas de relevância



- **Precision@K**

- Proporção das top-K recomendações que são relevantes ao usuário.

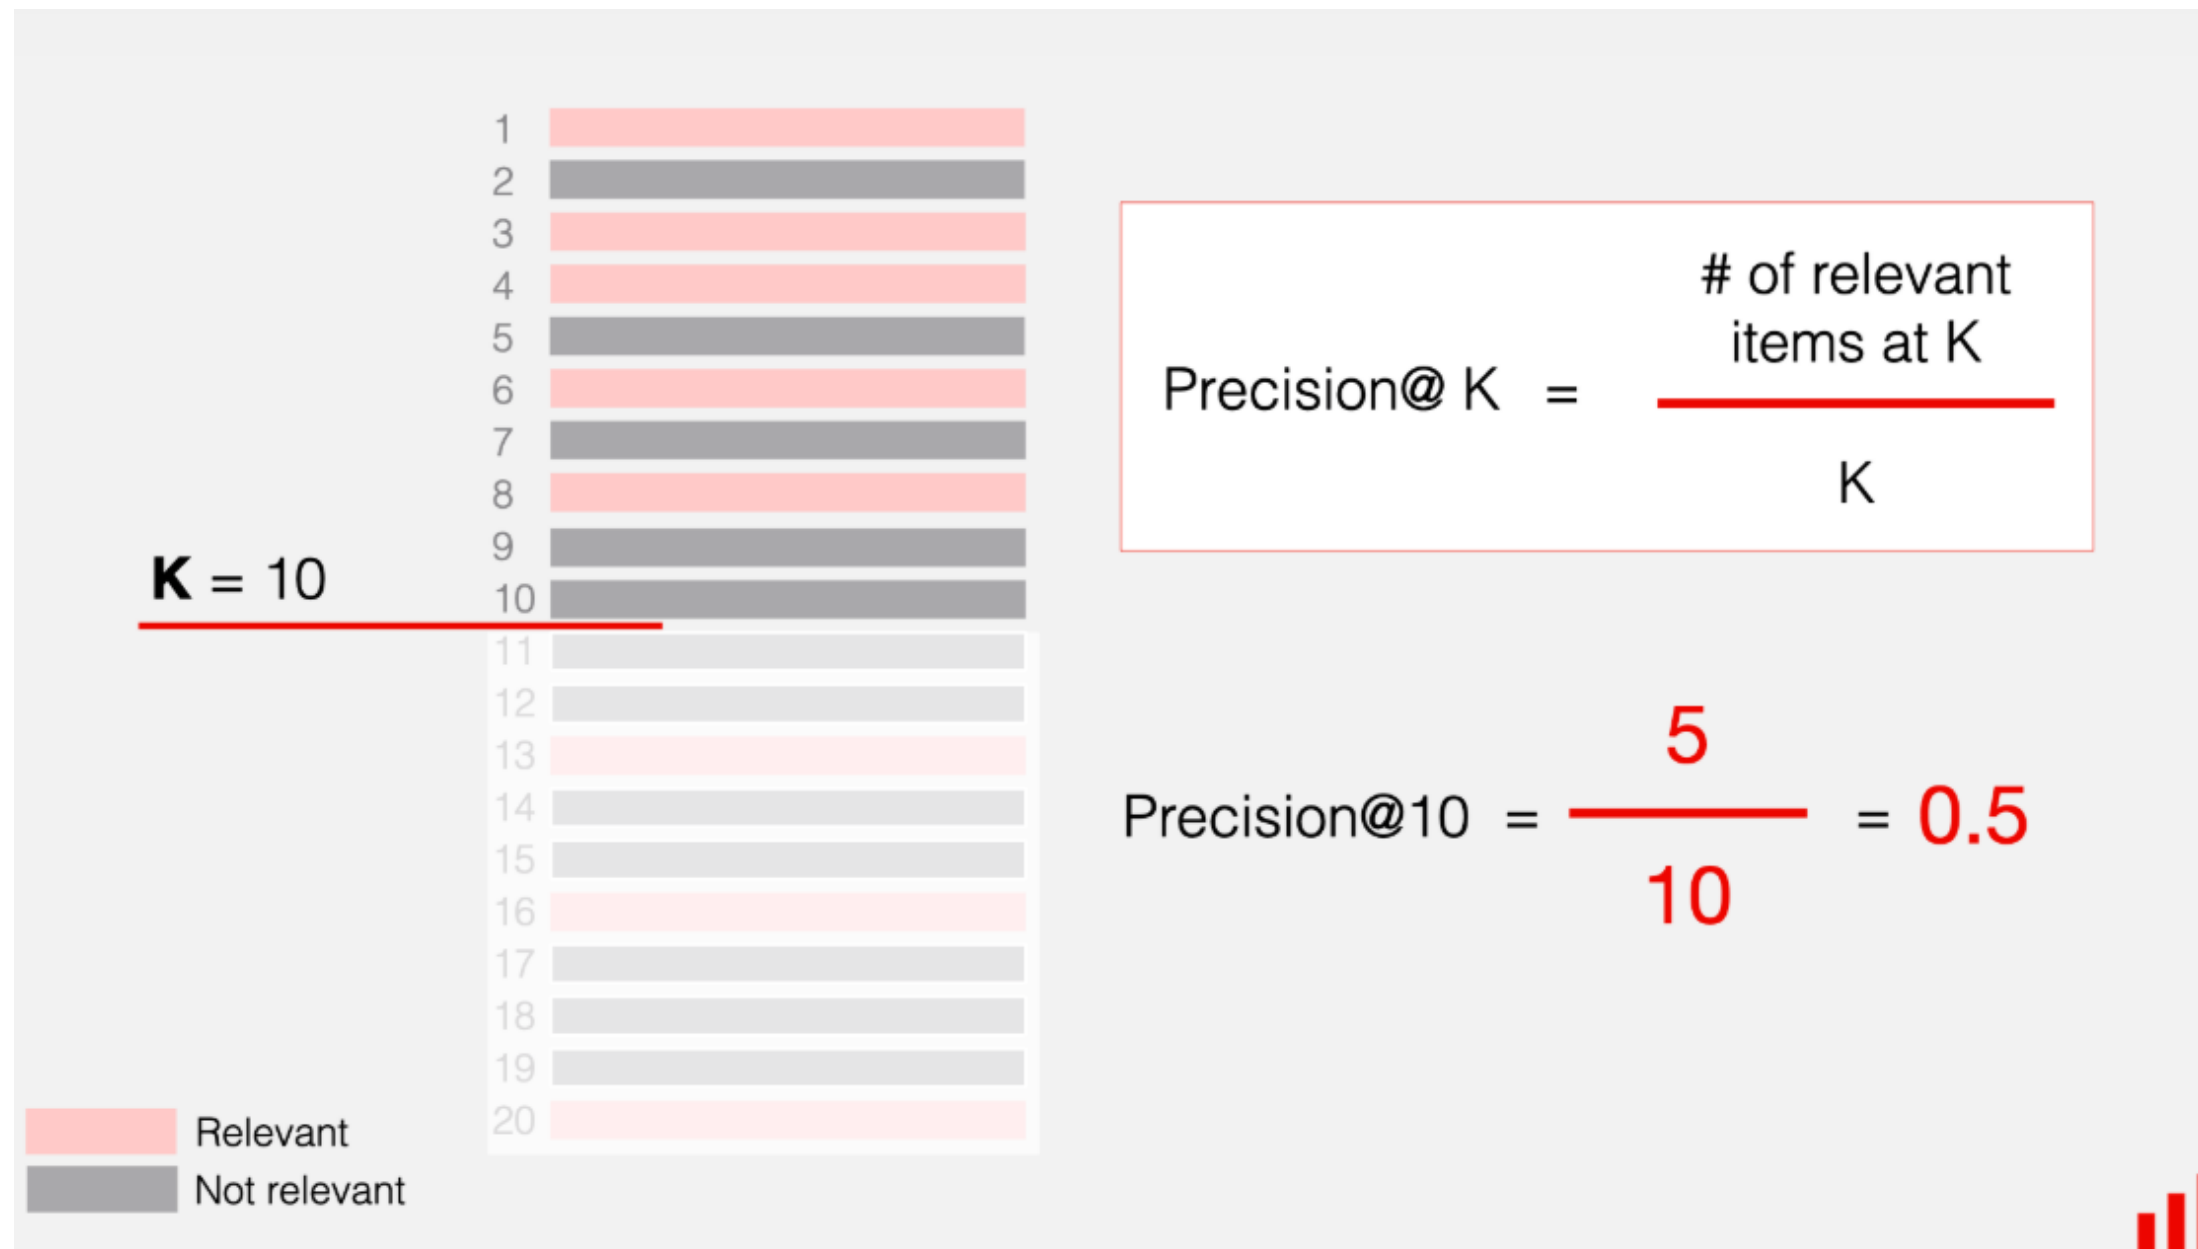
$$Precision@K = \frac{\text{Number of relevant items in top } K}{K}$$

- **Recall@K**

- Proporção de todos itens relevantes que estão incluídos nas top-K recomendações.

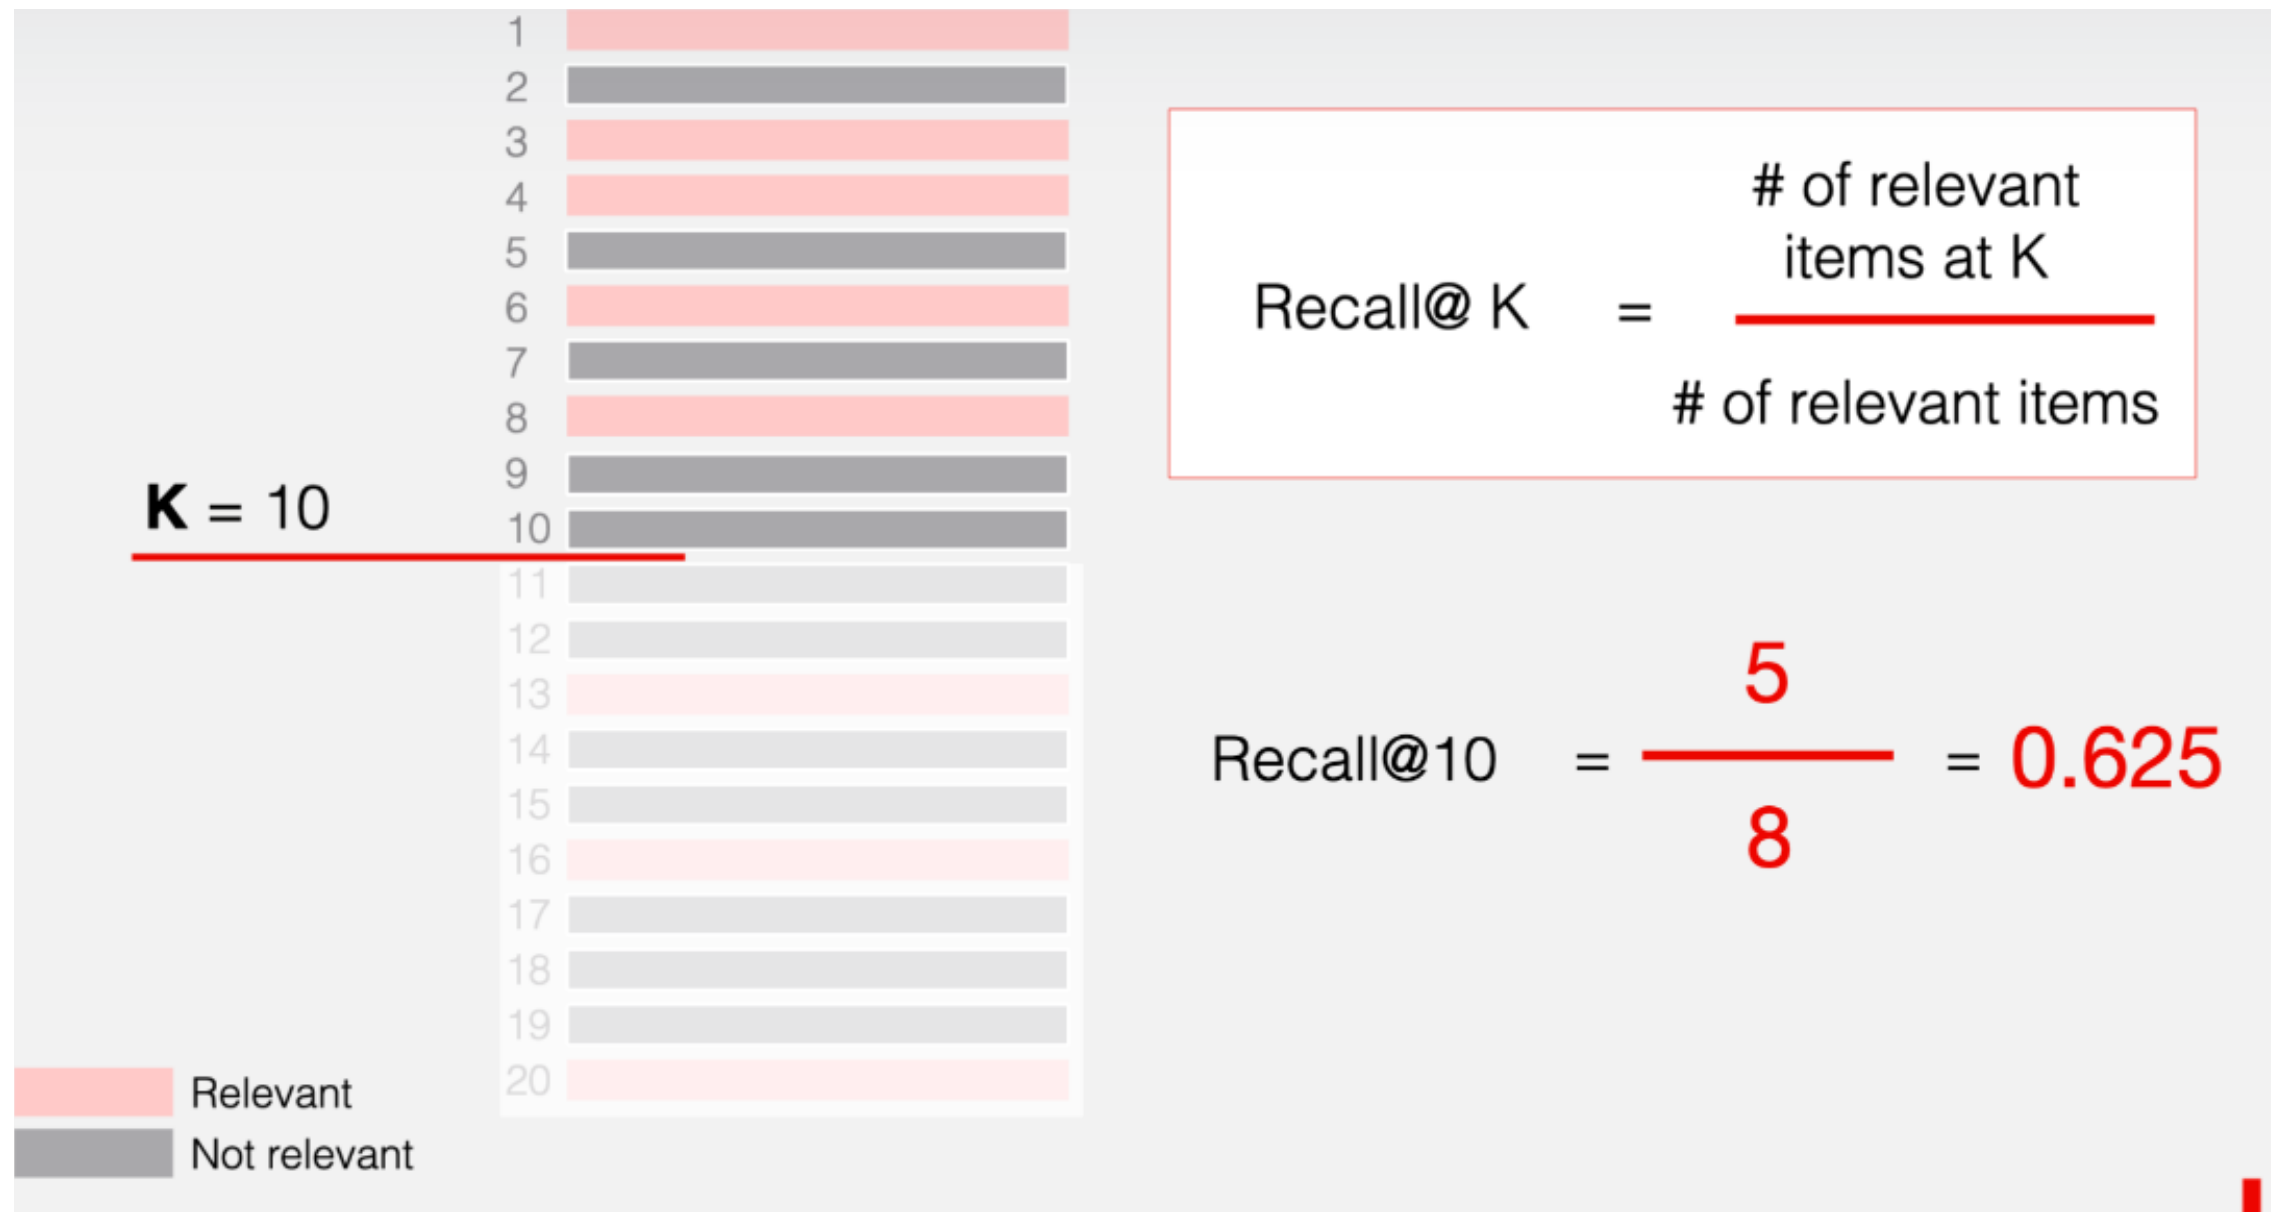
$$Recall@K = \frac{\text{Number of relevant items in top } K}{\text{Total number of relevant items}}$$

Métricas de relevância



<https://www.evidentlyai.com/ranking-metrics/evaluating-recommender-systems>

Métricas de relevância




<https://www.evidentlyai.com/ranking-metrics/evaluating-recommender-systems>

Métricas de relevância

- **Mean Average Precision (MAP@K)**

- Precisão média de todas as classificações relevantes dentro das top K recomendações, recompensando as recomendações corretas no topo.



$$AP@K = \frac{1}{m} \sum_{k=1}^K P(k) \cdot rel(k)$$

onde m é o número de itens relevantes e $rel(k)$ é a relevância do item em k (1 se relevante, 0 caso contrário).

$$MAP@K = \frac{1}{U} \sum_{u=1}^U AP@K(u)$$

onde U é o número de usuários, $AP@K(u)$ para o usuário u .

Métricas de relevância

- **Normalized Discounted Cumulative Gain (NDCG@K)**

- Mede a qualidade do *ranking*, atribuindo pontuações mais altas a itens relevantes em posições mais altas.



$$DCG@K = \sum_{i=1}^K \frac{Cr_i}{\log_2(1 + i)}$$

onde Cr_i é o score de relevância do item no *rank* i

$$NDCG@K = DCG@K / \max DCG@K$$

onde $\max DCG@K$ é o DCG ideal

- **Hit Rate@K**

- A proporção de usuários que recebem pelo menos uma recomendação relevante em sua lista top K.

Métricas de diversidade



- **Novidade**

- Avalia o quão únicos ou incomuns os itens recomendados.
- Mede o grau em que diferem dos populares.
 - Ex: logaritmo negativo da probabilidade de um item ser encontrado no conjunto de treinamento.

- **Serendipidade**

- Mede o inesperado ou a surpresa agradável nas recomendações.
- Considera a dissimilaridade entre os itens recomendados com sucesso e as preferências históricas do usuário.


Métricas de diversidade

- **Cobertura**


- Proporção de todos os itens do catálogo presentes nas recomendações ao longo de um período, indicando o quanto do espaço do item está sendo explorado.

- **Viés de Popularidade**

- Ajuda a avaliar se há um viés indevido em relação à recomendação de itens populares.
- Usar métricas como o índice de Gini ou a Popularidade Média das Recomendações.



Métricas de diversidade



- **Intra-list Diversity**

- Mede a variedade de itens dentro de uma única lista de recomendações, geralmente calculando a dissimilaridade média.
 - Exemplo: Distância de Cosseno, entre pares de itens na lista.

$$Average(1 - CosineSimilarity(item_a, item_b))$$

para todos os pares únicos de itens (item_a, item_b) dentro de uma lista de recomendações.

Conclusão e Perspectivas Futuras

- A personalização é o aspecto mais valorizado em sistemas de recomendação, pelo alinhamento com as preferências do usuário. No entanto, a descoberta de conteúdo diversificado pode melhorar a experiência do usuário, promover diversidade e mitigar problemas como “bolhas de filtro”.
- Existem diversas técnicas para exploração de conteúdo novo, e métricas para avaliar seu desempenho nos sistemas de recomendação.
- Os avanços na área de Grandes Modelos de Linguagem podem redefinir as recomendações de preditivas para generativas, abrindo novas possibilidades para personalização e diversificação. [16]

Referências Bibliográficas

- [1] C. C. Aggarwal. 2016. **Recommender Systems: The Textbook**. Springer. <https://doi.org/10.1007/978-3-319-29659-3>
- [2] Z. Yan. 2022. **Bandits for Recommender Systems**. <https://eugeneyan.com/writing/bandits/>
- [3] C. Pei, Y. Zhang, Y. Zhang, F. Sun, X. Lin, H. Sun, J. Wu, P. Jiang, W. Ou, and D. Pei. 2019. **Personalized Context-aware Re-ranking for E-commerce Recommender Systems**. CoRR abs/1904.06813. <http://arxiv.org/abs/1904.06813>
- [4] Y. Wang, C. Banerjee, S. Chucuri, F. Soldo, S. Badam, E. H. Chi, and M. Chen. 2025. **Beyond Item Dissimilarities: Diversifying by Intent in Recommender Systems**. In Proceedings of the 31st ACM SIGKDD Conference on Knowledge Discovery and Data Mining V.1 (KDD '25). ACM, New York, NY, USA, 2672–2681. <https://doi.org/10.1145/3690624.3709429>

Referências Bibliográficas

- [5] **Scaling Instagram Explore Recommendations System.** 2023. <https://engineering.fb.com/2023/08/09/ml-applications/scaling-instagram-explore-recommendations-system/>
- [6] **Sequence learning for personalized ads recommendations.** 2024.
<https://engineering.fb.com/2024/11/19/data-infrastructure/sequence-learning-personalized-ads-recommendations/>
- [7] **How TikTok recommends videos for you.** <https://newsroom.tiktok.com/en-us/how-tiktok-recommends-videos-for-you>
- [8] Z. Liu, L. Zou, X. Zou, C. Wang, B. Zhang, D. Tang, B. Zhu, Y. Zhu, P. Wu, K. Wang, and Y. Cheng. 2022.
Monolith: Real Time Recommendation System With Collisionless Embedding Table. arXiv preprint arXiv:2209.07663. <https://arxiv.org/abs/2209.07663>

Referências Bibliográficas

[9] **An update on our work to safeguard and diversify recommendations.**

<https://newsroom.tiktok.com/en-us/an-update-on-our-work-to-safeguard-and-diversify-recommendations>

[10] J. Yin. 2025. **From Connection to Isolation: The Role of TikTok Algorithmic Personalization in Computational Media and Cross-cultural Communication.** Communications in Humanities Research 61, 44–52. <https://www.ewadirect.com/proceedings/chr/article/view/20620>

[11] P. Covington, J. Adams, and E. Sargin. 2016. **Deep Neural Networks for YouTube Recommendations.** In Proceedings of the 10th ACM Conference on Recommender Systems (RecSys '16). Association for Computing Machinery, New York, NY, USA, 191–198. <https://doi.org/10.1145/2959100.2959190>

[12] **On YouTube's recommendation system.** <https://blog.youtube/inside-youtube/on-youtubes-recommendation-system/>

Referências Bibliográficas

- [13] H. Hosseinmardi, A. Ghasemian, M. Lanas, and D. J. Watts. 2023. **Causally estimating the effect of YouTube's recommender system using counterfactual bots.** Proceedings of the National Academy of Sciences. <https://doi.org/10.1073/pnas.2313377121>
- [14] **FM-Intent: Predicting User Session Intent with Hierarchical Multi-Task Learning.** <https://netflixtechblog.com/fm-intent-predicting-user-session-intent-with-hierarchical-multi-task-learning-94c75e18f4b8>
- [15] **Artwork Personalization at Netflix.** <https://netflixtechblog.com/artwork-personalization-c589f074ad76>
- [16] L. Wu, Z. Zheng, Z. Qiu, H. Wang, H. Gu, T. Shen, C. Qin, C. Zhu, H. Zhu, Q. Liu, H. Xiong, and E. Chen. 2024. **A Survey on Large Language Models for Recommendation.** arXiv preprint arXiv:2305.19860. <https://arxiv.org/abs/2305.19860>

Obrigada!

- cassiasouza@ipt.br
- adrianab@ipt.br

 linkedin.com/school/iptsp/

 instagram.com/ipt_oficial/

 youtube.com/@IPTbr/

www.ipt.br

 **ipt**
INSTITUTO DE
PESQUISAS
TECNOLÓGICAS

 **SÃO
PAULO**
GOVERNO
DO ESTADO