

# Explorando Formas de Calibração e Redução do Viés de Popularidade em Sistemas de Recomendação

Rodrigo F. Souza  
Universidade de São Paulo  
São Carlos-SP, Brasil  
rodrigofsouza@usp.br

Marcelo G. Manzato  
Universidade de São Paulo  
São Carlos-SP, Brasil  
mmanzato@icmc.usp.br

## ABSTRACT

Recommender systems aim to enhance user engagement by suggesting new content based on their interests. Common algorithms like collaborative filtering recommend items similar to those users prefer, facilitating content discovery. However, recent research has identified issues such as unfairness, calibration errors, and popularity bias. While popularity bias promotes popular item consumption, it can lead to unfair recommendations that do not accurately reflect individual user interests. Current calibration methods focus on fairness but often overlook the amplifying effect of popularity bias. Our study addresses this gap by investigating calibration techniques and bias reduction strategies to deliver fairer recommendations aligned with user preferences, across various popularity levels. This research contributes insights into system calibration, fairness, user experience, and evaluation metrics.

## KEYWORDS

Sistemas de Recomendação, Viés de Popularidade, Justiça, Calibração

## 1 INTRODUÇÃO

Embora presentes em diversos sistemas de mídia, os sistemas de recomendação enfrentam desafios como vieses, injustiça e bolhas de filtro que reduzem a eficácia de suas recomendações. A injustiça decorre de vieses nos dados, como o viés de popularidade, que favorece itens populares em detrimento de menos conhecidos [2].

A justiça em um sistema de recomendação está ligada à capacidade de fornecer recomendações alinhadas com as preferências de todos os usuários. Uma abordagem promissora para medir essa capacidade é a calibração [11], que utiliza metadados de itens (por exemplo, gêneros) para alinhar a distribuição de categorias com o perfil do usuário.

O trabalho [4] propõe um sistema de pós-processamento que gera recomendações conforme as preferências dos usuários pelos gêneros dos itens, equilibrando a acurácia. De forma similar, [11] apresenta uma calibração para retornar proporções coerentes com as preferências dos usuários.

Para reduzir o viés de popularidade, [1] propõe a reclassificação dos itens usando o histórico de interação dos usuários com itens da cauda longa, permitindo medir o interesse por itens de nicho. No

entanto, esse sistema não recomenda itens em proporção consistente com as preferências dos usuários de forma calibrada. Outros trabalhos [3, 5–7, 12, 13] focam na redução do viés de popularidade, mas não abordam a justiça na distribuição dos itens recomendados.

Há uma lacuna na literatura quanto a recomendações que reduzam o viés de popularidade, forneçam itens calibrados e sejam agnósticas ao modelo de recomendação. O objetivo do projeto é investigar como calibrar sistemas de recomendação para atender a diferentes preferências dos usuários, combinando técnicas de calibração com métodos para reduzir o viés de popularidade, como a reclassificação das recomendações.

## 2 METODOLOGIA

Para validar a pesquisa, foram conduzidos experimentos para medir o efeito da calibração do sistema com base na popularidade, buscando entender seu impacto na geração e justiça das recomendações e na redução do viés de popularidade.

Foram realizados experimentos *online* e *offline*, resultando em cinco trabalhos submetidos e aceitos. A pesquisa avaliou cinco abordagens para reduzir o viés de popularidade em sistemas de recomendação: duas em processamento, duas em pós-processamento e uma por alterações na interface.

Os trabalhos validaram que itens calibrados são percebidos como relevantes pelos usuários. Os *nudges* foram eficazes para promover itens de nicho e aumentar a diversidade, reduzindo o viés de popularidade.

As abordagens de pós-processamento podem ser combinadas com qualquer modelo, balanceando a lista conforme o interesse do usuário usando estratégias de *switch* ou *stack*. As abordagens de calibração em processamento também apresentaram bons resultados, aumentando a diversidade e lidando com o viés de popularidade.

## 3 CONTRIBUIÇÕES

A principal contribuição desta pesquisa é o estudo de abordagens de calibração e redução do viés de popularidade em Sistemas de Recomendação, verificando como elas fornecem recomendações relevantes para diferentes grupos de usuários, medidos por métricas de injustiça.

Os experimentos *online* e *offline* validaram cinco abordagens para proporcionar recomendações mais justas e diversificadas. Abordagens de pós-processamento mostraram-se flexíveis e eficazes, enquanto métodos de calibração em processamento também mitigaram o viés de popularidade. As abordagens analisadas foram:

- Abordagem que modifica o algoritmo BPR (*Bayesian Personalized Ranking from Implicit Feedback*) [8], permitindo

**Tabela 1: Comparação das abordagens no Movie Lens 20M. Os melhores valores estão em negrito.**

Algoritmo	MAP	MRMC Gên.	MRMC Pop.	F1 Score	LTC	$\Delta GAP_{BB}$	$\Delta GAP_N$	$\Delta GAP_D$	RMSE
BPR Modificado	0.001	0.45	0.33	0.596	<b>0.46</b>	-0.865	-0.060	-0.693	0.370
SVD++ + Calibração personalizada [9]	0.001	0.41	0.69	0.407	0.42	-0.992	-0.970	-0.985	0.568
SVD++ + Calibração dupla [10]	0.001	0.26	0.68	0.447	0.38	-0.990	-0.969	-0.983	0.566
NMF + Calibração personalizada [9]	0.077	0.35	<b>0.11</b>	0.752	0.01	-0.171	0.238	-0.212	<b>0.121</b>
NMF + Calibração dupla [10]	<b>0.081</b>	<b>0.23</b>	0.17	<b>0.799</b>	0.01	-0.379	0.046	-0.152	0.137
VAE + Calibração personalizada [9]	0.079	0.47	0.35	0.584	0.14	0.850	1.553	1.386	0.750
VAE + Calibração dupla [10]	0.055	0.27	0.28	0.725	0.11	0.359	1.636	0.981	0.647

explorar outras abordagens em pós-processamento e mecanismos de *nudges*.

- Redução do viés de popularidade através de *nudges*, recomendando itens diferentes do perfil do usuário.
- Calibração em pós-processamento, validada por experimento com usuários, demonstrando a relevância dos itens calibrados.
- Calibração personalizada, usando uma estratégia de chaveamento para recomendações baseadas na popularidade ou no gênero dos itens.
- Calibração dupla, uma evolução da personalizada, empilhando calibração por gênero seguida de popularidade.

A Tabela 1 resume os resultados obtidos na base de dados Movie Lens 20M com as abordagens propostas neste trabalho. Cada abordagem tem vantagens específicas, compatíveis com as necessidades do sistema.

A abordagem BPR modificado obteve altos valores para a métrica LTC, indicada para diversidade. Para precisão, a calibração dupla combinada com NMF é a melhor. Se o objetivo for justiça em popularidade e gêneros, a calibração dupla com NMF também é recomendada. Para reduzir o viés de popularidade em diferentes grupos, a calibração personalizada combinada com NMF é mais eficaz.

## 4 AGRADECIMENTOS

Os autores agradecem CAPES, CNPq e FAPESP pelo apoio financeiro.

## REFERÊNCIAS

- [1] Himan Abdollahpouri, Robin Burke, and Bamshad Mobasher. 2019. Managing popularity bias in recommender systems with personalized re-ranking. In *The thirty-second international flairs conference*. AAAI Press, California, USA.
- [2] Jiawei Chen, Hande Dong, Xiang Wang, Fuli Feng, Meng Wang, and Xiangnan He. 2023. Bias and debias in recommender system: A survey and future directions. *ACM Transactions on Information Systems* 41, 3 (2023), 1–39.
- [3] Zhihong Chen, Jiawei Wu, Chenliang Li, Jingxu Chen, Rong Xiao, and Binqiang Zhao. 2022. Co-training disentangled domain adaptation network for leveraging popularity bias in recommenders. In *Proceedings of the 45th International ACM SIGIR Conference on Research and Development in Information Retrieval*. ACM, New York, NY, USA, 60–69.
- [4] Diego Corrêa da Silva, Marcelo Garcia Manzato, and Frederico Araújo Durão. 2021. Exploiting personalized calibration and metrics for fairness recommendation. *Expert Systems with Applications* 181 (2021), 115112.
- [5] Oleg Lesota, Alessandro Melchiorre, Navid Rekabsaz, Stefan Brandl, Dominik Kowald, Elisabeth Lex, and Markus Schedl. 2021. Analyzing item popularity bias of music recommender systems: are different genders equally affected?. In *Proceedings of the 15th ACM Conference on Recommender Systems*. ACM, New York, NY, USA, 601–606.
- [6] Allen Lin, Jianling Wang, Ziwei Zhu, and James Caverlee. 2022. Quantifying and mitigating popularity bias in conversational recommender systems. In *Proceedings of the 31st ACM International Conference on Information & Knowledge Management*. ACM, New York, NY, USA, 1238–1247.
- [7] Mohammadmehdi Naghiaei, Hossein A Rahmani, and Mahdi Dehghan. 2022. The unfairness of popularity bias in book recommendation. In *International Workshop on Algorithmic Bias in Search and Recommendation*. Springer, New York, NY, USA, 69–81.
- [8] Steffen Rendle, Christoph Freudenthaler, Zeno Gantner, and Lars Schmidt-Thieme. 2012. BPR: Bayesian personalized ranking from implicit feedback. *arXiv preprint arXiv:1205.2618* (2012).
- [9] André Sacilotti, Marcelo Garcia Manzato, and Rodrigo Ferrari de Souza. 2022. Counteracting popularity-bias and improving diversity through calibrated recommendations. In *Sixteenth ACM conference on recommender systems*. Association for Computing Machinery, New York, NY, USA. (Sob avaliação).
- [10] Rodrigo Souza and Marcelo Manzato. 2024. A Two-Stage Calibration Approach for Mitigating Bias and Fairness in Recommender Systems. In *Proceedings of the 39th ACM/SIGAPP Symposium on Applied Computing*. ACM, New York, NY, USA, 1659–1661.
- [11] Harald Steck. 2018. Calibrated Recommendations. In *Proceedings of the 12th ACM Conference on Recommender Systems (Vancouver, British Columbia, Canada) (RecSys '18)*. Association for Computing Machinery, New York, NY, USA, 154–162. <https://doi.org/10.1145/3240323.3240372>
- [12] Emre Yalcin. 2021. Blockbuster: A new perspective on popularity-bias in recommender systems. In *2021 6th International Conference on Computer Science and Engineering (UBMK)*. IEEE, New York, NY, USA, 107–112.
- [13] Emre Yalcin and Alper Bilge. 2022. Treating adverse effects of blockbuster bias on beyond-accuracy quality of personalized recommendations. *Engineering Science and Technology, an International Journal* 33 (2022), 101083.