

PERBANDINGAN PENERAPAN TEKNIK POPULARITAS *ITEM* DALAM SISTEM REKOMENDASI

Yunus Safi'i¹, Noor Ifada²

^{1,2}Program Studi Teknik Informatika, Fakultas Teknik, Universitas Trunojoyo Madura

¹yunus.safii99@gmail.com, ²noor.ifada@trunojoyo.ac.id

Abstrak

Tantangan utama dalam era big data adalah pengguna seringkali mengalami kesulitan untuk menentukan atau memilih *item* yang relevan dari banyaknya data yang tersedia. Permasalahan ini dapat diatasi dengan pengimplementasian sistem rekomendasi untuk menyaring informasi dan memberikan rekomendasi yang sesuai dengan preferensi pengguna. Walaupun sistem rekomendasi telah berkembang pesat dalam mengatasi tantangan informasi yang melimpah, masalah popularitas *item* masih menjadi isu utama. *Item* yang populer mendominasi rekomendasi, sedangkan *item* yang kurang populer mengalami kesulitan mendapatkan eksposur kepada pengguna. Dalam konteks rekomendasi penjualan, hal ini dapat menghambat penjualan *item* yang kurang populer karena minimnya rekomendasi kepada pelanggan. Sejumlah penelitian telah dilakukan untuk mengatasi masalah ini, tetapi belum ada studi yang secara komprehensif membahas penerapan teknik popularitas *item*. Penelitian ini bertujuan melakukan studi tentang tren dari penelitian yang menerapkan teknik popularitas *item* dalam sistem rekomendasi, yaitu sejumlah 20 literatur yang dipublikasikan dari tahun 2012 sampai 2022. Hasil studi menunjukkan bahwa topik popularitas *item* mulai populer diteliti sejak tahun 2018 hingga 2022, yaitu sejumlah 16 literatur. Jenis literatur didominasi oleh prosiding yaitu sejumlah 15 literatur, dan sisanya berupa jurnal. *Dataset* yang paling banyak digunakan adalah MovieLens dan LastFM, yaitu untuk sistem rekomendasi film dan lagu. Fokus masalah yang paling mendominasi adalah penyelesaian permasalahan bias popularitas, yaitu sebanyak 12 literatur. Sedangkan luaran rekomendasi didominasi oleh rekomendasi top-N, yaitu sebanyak 18 literatur.

Kata kunci : bias popularitas, efek *long tail*, popularitas *item*, sistem rekomendasi

1. Pendahuluan

Pada era *big data*, kita dihadapkan pada efek negatif dari banyaknya jumlah informasi (Gao et al., 2018). Banyaknya dan beragamnya pilihan yang ada membuat pengguna sering kali merasa kesulitan untuk menemukan apa yang sebenarnya ia inginkan. Oleh karena itu, sistem penyaringan informasi seperti mesin pencari dan sistem rekomendasi menjadi andalan pengguna untuk mencari informasi yang relevan baginya (Hou et al., 2018).

Sistem rekomendasi dapat memandu pengguna dalam menentukan pilihan. Sistem akan memisahkan produk atau *item* yang relevan dan tidak relevan untuk menghasilkan daftar *item* yang mungkin disukai oleh pengguna. Karena kebermanfaatannya, penggunaan sistem rekomendasi telah berkembang secara signifikan di berbagai *platform* digital dalam beberapa tahun terakhir seperti Youtube, Netflix, Spotify, Amazon, dan lain-lain (Yalcin, 2022).

Popularitas *item* merupakan salah satu bagian penting dari sistem rekomendasi. Sebelumnya penelitian hanya berfokus untuk memberikan rekomendasi *item* kepada pengguna. Namun, seiring berjalannya waktu, ternyata sistem rekomendasi memiliki permasalahan-permasalahan yang disebabkan oleh popularitas *item* seperti bias

popularitas maupun efek *long tail*. Permasalahan-permasalahan tersebut dapat menyebabkan sistem rekomendasi mengalami penurunan akurasi dalam jangka panjang (Steck, 2011). *Item* yang populer akan cenderung direkomendasikan daripada *item* yang tidak populer dan dapat mengakibatkan kurang beragamnya hasil prediksi. *Item* yang tidak populer akan cenderung tidak direkomendasikan sehingga tidak akan terlihat oleh pengguna (Gao et al., 2018). Sebagai contoh, buku “Harry Potter” akan direkomendasikan ke semua pengguna karena buku ini memiliki popularitas yang tinggi pada mayoritas pengguna. Dalam dunia penjualan produk, *item* yang tidak direkomendasikan akan sulit terjual dan menyebabkan kerugian.

Bias popularitas pada suatu *item* dapat dipengaruhi oleh dua faktor, yaitu bias pada data dan bias pada algoritma. Bias pada data dapat disebabkan oleh faktor eksternal dimana beberapa *item* tertentu memiliki kecenderungan akan lebih populer daripada *item* yang lainnya. Misalnya, musik dari beberapa artis terkenal akan cenderung lebih populer jika dibandingkan dengan musik lainnya. Sedangkan bias pada algoritma sendiri terjadi karena sifat ketidakseimbangan dari data interaksi *item*. Dalam hal ini, *item* yang populer akan memiliki interaksi yang tinggi dengan pengguna sehingga menimbulkan


bias. Seringkali algoritma dipengaruhi oleh bias ini sehingga membuat *item* akan direkomendasikan ke lebih banyak pengguna lainnya (Abdollahpouri & Mansoury, 2020).

Berbagai penelitian telah dilakukan untuk menangani permasalahan popularitas *item* dengan kelemahan dan kelebihan pada masing-masing metode yang diusulkan. Namun belum ada studi perbandingan yang secara spesifik membahas topik ini. Kontribusi dari penelitian ini melakukan studi untuk mengetahui tren dari penelitian yang menerapkan teknik popularitas *item* pada sistem rekomendasi.

2. Metode Penelitian

Pada penelitian ini menggunakan metode *Systematic Literature Review* (SLR). SLR merupakan salah satu metode dalam melakukan perbandingan penelitian-penelitian sebelumnya yang saling terkait. SLR merupakan salah satu metode standar, sehingga proses penelitian selanjutnya dapat dilakukan kembali. SLR merupakan penelitian yang dilakukan untuk memetakan, mengidentifikasi, mengevaluasi, dan mengumpulkan informasi dari hasil studi yang terkait dengan topik penelitian tertentu (Yomeldi, 2020). Studi dilakukan dengan tujuan untuk mengetahui hasil penelitian yang telah dilakukan serta untuk mengetahui perkembangan ilmu pada penerapan teknik popularitas *item* pada sistem rekomendasi.

SLR terdiri dari tiga tahap dimana pada masing-masing tahap terdapat beberapa proses didalamnya. Tiga tahap tersebut yaitu *Planning*, *Conducting* dan *Reporting*. *Planning* merupakan tahap awal sebelum melakukan studi. *Conducting* merupakan proses pencarian literatur sekaligus analisis sedangkan *Reporting* merupakan proses menyampaikan hasil dari studi. Tahapan dari SLR dapat dilihat pada Gambar 1.



Gambar 1. Metode Studi

2.1 Planning

Planning merupakan tahap yang perlu dipersiapkan sebelum mencari literatur. Hal pertama yang dilakukan yaitu menentukan pertanyaan penelitian atau *Research Question* (RQ). RQ dapat dibuat dengan melakukan tinjauan awal terkait topik penelitian. Tujuan dari RQ adalah untuk menentukan alur dari penelitian sehingga arah penelitian tetap konsisten sampai akhir. Penelitian ini menggunakan lima RQ sebagai berikut:

- RQ1 : Bagaimana pola sebaran tahun publikasi dari literatur?
- RQ2 : Apa saja jenis literatur yang digunakan dalam penelitian?
- RQ3 : *Dataset* apa saja yang digunakan dalam literatur?
- RQ4 : Fokus masalah, metode apa saja yang digunakan, dan hasil capaian dalam penerapan teknik popularitas *item*?
- RQ5 : Bentuk luaran rekomendasi apa yang digunakan dalam literatur?

Setelah RQ terbentuk maka selanjutnya adalah menentukan kata kunci yang sesuai dengan studi yang akan dikerjakan. Literatur yang digunakan pada penelitian ini dicari dengan menggunakan kata kunci “*item popularity collaborative filtering*”, “*item popular in collaborative filtering*” atau “*bias popularity in collaborative filtering*”.

Proses selanjutnya adalah identifikasi kriteria untuk menyaring literatur yang didapat agar sesuai dengan standar tertentu. Kriteria yang digunakan dalam penelitian ini sebagai berikut.

1. Literatur terbit dari rentang 2012-2022.
2. Literatur merupakan artikel ilmiah yang dipublikasikan oleh publisher terkenal seperti ACM, IEEE, Elsevier, Springer dan lain-lain.
3. Jika literatur tidak memenuhi Poin 2 maka akan dicek rankingnya. Literatur harus memiliki ranking mulai dari Q3 hingga Q1 untuk paper internasional, sedangkan untuk nasional dengan rentang S3 hingga S1.
4. Literatur dari publikasi ilmiah Bahasa Inggris atau Bahasa Indonesia.
5. Literatur memuat metode yang digunakan dalam penelitian.

2.2 Conducting

Tahap *conducting* diawali dengan pencarian literatur berdasarkan kata kunci yang telah dibuat. Pencarian dilakukan dengan memasukkan kata kunci pada situs Google Scholar, IEEE, Springer dan *website* penyedia naskah ilmiah lainnya. Literatur yang dipilih berjumlah 20 literatur dan pemilihan dilakukan berdasarkan kajian singkat yang didapatkan dari judul, abstrak serta kesimpulan. Literatur yang didapat akan diseleksi berdasarkan kriteria. Setelah itu dilakukan analisis sesuai dengan RQ.

2.3 Reporting

Reporting merupakan tahap penyampaian hasil dari analisis terhadap literatur. Tujuan utama dari *reporting* untuk menunjukkan jawaban dari RQ yang telah dibuat sehingga dapat ditarik kesimpulan penelitian. Pada penelitian ini hasil dari analisis akan disampaikan secara terperinci pada bagian 3.

3. Hasil dan Pembahasan

Pada bab ini akan dijelaskan hasil dan pembahasan dari analisis literatur yang telah dilakukan sesuai dengan RQ. Sesuai dengan tahapan *planning*, kriteria literatur yang akan digunakan memiliki rentang waktu mulai dari tahun 2012 sampai 2022. Identitas dari seluruh literatur dapat dilihat pada Tabel 1.

Untuk selanjutnya, penggunaan nomor pada tabel merujuk pada literatur sesuai pada Tabel 1. Misal pada tabel selanjutnya disebutkan informasi literatur dengan nomor urut 2, maka informasi tersebut merupakan informasi dari literatur Chen et al. (2014).

3.1 Tahun Publikasi

Pada Gambar 2 dapat dilihat sebaran tahun publikasi dari seluruh literatur. Meskipun kriteria tahun publikasi memiliki rentang waktu 10 tahun, hasilnya didominasi oleh literatur dengan publikasi rentang tahun 2018 hingga 2022. Hal ini dapat menunjukkan bahwa topik popularitas *item* sedang populer diteliti pada kurun waktu lima tahun tersebut.

3.2 Jenis Literatur


Literatur yang digunakan terdiri dari dua macam yaitu jurnal dan prosiding. Jurnal merupakan karya ilmiah hasil dari penelitian. Sedangkan prosiding merupakan karya ilmiah yang telah diseminarkan. Gambar 3 menunjukkan bahwa jumlah prosiding lebih banyak dibandingkan dengan jurnal. Dari 20 literatur yang digunakan, 75% diantaranya merupakan jenis prosiding.

3.3 Dataset


Salah satu komponen penting dari suatu penelitian adalah *dataset* yang digunakan dalam uji coba. Pada sistem rekomendasi, *dataset* yang digunakan biasanya berhubungan dengan korelasi antara pengguna dan *item*. Dalam hal ini, *item* dapat berupa lagu, film, video, buku dan lain-lain. Gambar 4 menunjukkan bahwa *dataset* yang paling banyak digunakan adalah MovieLens dan LastFM, yaitu tentang film dan lagu. Perlu diperhatikan bahwa sebagian besar literatur menggunakan lebih dari satu *dataset*. Hal ini bertujuan untuk membuktikan kedinamisan metode yang diusulkan. Jika metode mengalami keberhasilan menggunakan satu *dataset*, diharapkan metode tersebut menghasilkan performa yang sama pada *dataset* lain.

Tabel 1. Identitas literatur penerapan teknik popularitas item pada sistem rekomendasi


No	Judul	Literatur
1	<i>Challenging the Long Tail Recommendation</i>	Yin et al. (2012)
2	<i>An Enhanced Collaborative Filtering with Flexible Item Popularity Control for Recommender Systems</i>	Chen et al. (2014)
3	<i>A New Hybrid Popular Model for Personalized Tag Recommendation</i>	Wang and Luo (2016)
4	<i>Item-based relevance modelling of recommendations for getting rid of long tail products</i>	Valcarce et al. (2016)
5	<i>Missing Data Modeling with User Activity and Item Popularity in Recommendation</i>	Chen et al. (2018)
6	<i>Similarity Measure based on Punishing Popular Items for Collaborative Filtering</i>	Gao et al. (2018)
7	<i>Balancing the popularity bias of object similarities for personalised recommendation</i>	Hou et al. (2018)
8	<i>Topic Model-based Recommender System for Longtailed Products against Popularity Bias</i>	Sun and Xu (2019)
9	<i>HPCF: Hybrid Music Group Recommendation System based on Item Popularity and Collaborative Filtering</i>	Chen et al. (2020)
10	<i>Hybrid Popularity Model for Solving Cold-start Problem in Recommendation System</i>	Ifada et al. (2020)
11	<i>Combining novelty and popularity on personalised recommendations via user profile learning</i>	Bertani et al. (2020)
12	<i>The Unfairness of Popularity Bias in Music Recommendation: A Reproducibility Study</i>	Kowald et al. (2020)
13	<i>Dynamic Clustering Personalization for Recommending Long Tail Items</i>	de Sousa Silva and Durão (2020)
14	<i>User-centered Evaluation of Popularity Bias in Recommender Systems</i>	Abdollahpour et al. (2021)
15	<i>Popcorn: Human-in-the-loop Popularity Debiasing in Conversational Recommender Systems</i>	Fu et al. (2021)
16	<i>Disentangling User Interest and Conformity for Recommendation with Causal Embedding</i>	Zheng et al. (2021)
17	<i>Causal Intervention for Leveraging Popularity Bias in Recommendation</i>	Zhang et al. (2021)
18	<i>PopHybrid: a novel item popularity-aware hybrid approach for long-tail recommendation</i>	Yalcin (2022)
19	<i>Quantifying and Mitigating Popularity bias in Conversational Recommender Systems</i>	Lin et al. (2022)
20	<i>Adaptive Alleviation for Popularity Bias in Recommender Systems with Knowledge Graph</i>	Wei et al. (2022)




Gambar 2. Tahun publikasi literatur penerapan teknik popularitas item pada sistem rekomendasi



Gambar 3. Jenis literatur penerapan teknik popularitas *item* pada sistem rekomendasi



Gambar 4. *Dataset* dalam literatur penerapan teknik popularitas *item* pada sistem rekomendasi



Gambar 5. Fokus masalah dalam literatur penerapan teknik popularitas *item* pada sistem rekomendasi

3.4 Fokus masalah, metode yang diusulkan, dan hasil yang dicapai

Literatur yang digunakan dalam penelitian ini memiliki topik yang sama yaitu penerapan

popularitas *item*, namun memiliki fokus masalah yang berbeda. Keberagaman fokus masalah itu sendiri merupakan dampak dari permasalahan popularitas *item*. Dalam literatur, setiap fokus masalah ditangani dengan metode yang berbeda yang dirancang khusus untuk menangani masalah tersebut. Dengan demikian, hasil yang dicapai oleh masing-masing literatur pun juga berbeda.

Metode usulan dapat dibuat dengan mengimplementasikan metode yang sudah ada maupun berupa hasil modifikasi metode. Metode dengan fokus masalah *cold-start* kemungkinan besar akan menunjukkan performa yang berbeda ketika menghadapi masalah efek *long tail* atau bias popularitas. Hal tersebut membuktikan bahwa fokus masalah sangat berpengaruh terhadap metode yang diusulkan. Berbagai metode telah diusulkan dengan menerapkan teknik popularitas *item* terkait fokus masalah yang digunakan. Meskipun beberapa metode memiliki kekurangan namun setiap metode memiliki masing-masing keunggulan sehingga dapat digunakan dalam sistem rekomendasi.

Gambar 5 memperlihatkan bahwa fokus masalah dalam literatur penerapan teknik popularitas *item* yang didominasi untuk menyelesaikan permasalahan bias popularitas, yaitu sebanyak 12 literatur. Detail lengkap tentang fokus masalah serta metode yang diusulkan dari masing-masing literatur dapat dilihat pada Tabel 2. Sedangkan, ringkasan hasil capaiannya dapat dilihat dalam Tabel 3.

Tabel 2. Tabel fokus masalah dan metode dalam literatur penerapan teknik popularitas *item* pada sistem rekomendasi


No	Fokus Masalah	Metode
1	Bias popularitas	Hitting Time (HT), Absorbing Time (AT), item-based Absorbing Cost algorithm (AC1) dan topic-based Absorbing Cost algorithm (AC2)
2	Bias popularitas	Enhanced Collaborative Filtering Approach (ECF)
3	Personalisasi <i>tag</i>	Item Based Hybrid Popular (IBHP)
4	Efek <i>long tail</i>	Item Relevance Modelling 2 (IRM2)
5	Data yang hilang	User Activity and Item Popularity Matrix Factorization (UIMF)
6	Peningkatan Akurasi	New-MSD
7	Bias popularitas	Balanced Common Neighbour (BCN)
8	Bias popularitas	Joint User and Social Tags (JUST)
9	Peningkatan akurasi	Hybrid of item Popularity and Collaborative Filtering (HPCF)
10	<i>Cold-start</i>	Hybrid Popularity (Hpop)
11	Bias popularitas	User Profile Oriented Diffusion (UPOD)
12	<i>Grouping</i>	Group item Popularity
13	Efek <i>long tail</i>	Personalized-Hitting Time Clustered (P-HTCL)
14	Bias popularitas	Calibrated Popularity (CP)

15	Bias popularitas	POPularity debiasing in CONversational Recommendation (POPCORN)
16	Bias popularitas	Disentangling Interest and Conformity with Causal Embedding (DICE)
17	Bias popularitas	Popularity-bias Deconfounding and Adjusting (PDA)
18	Bias popularitas	Novel item Popularity-aware Hybrid (PopHybrid)
19	Bias popularitas	Debias
20	Bias popularitas	Adaptive Alleviation for Popularity Bias with Knowledge Graph (AWING)

Tabel 3. Hasil penelitian dalam literatur penerapan teknik popularitas *item* pada sistem rekomendasi

No	Hasil Penelitian
1	Algoritma usulan mengungguli akurasi, kualitas, dan keragaman rekomendasi algoritma pembandingan untuk mengatasi permasalahan efek <i>long tail</i> dan bias popularitas
2	Metode ECF meningkatkan akurasi dan keragaman dibandingkan metode pembandingan
3	Metode IBHP memiliki <i>precision</i> dan <i>recall</i> yang lebih tinggi secara signifikan untuk rekomendasi Top-3 atau Top-4, namun performanya cenderung menurun ketika jumlah rekomendasi ditambah
4	Metode IRM2 bekerja lebih baik dibandingkan metode pembandingan, serta bekerja efektif pada data dengan tingkat <i>sparsity</i> yang tinggi
5	Metode UIMF menunjukan kinerja yang lebih baik dari pada metode pembandingan
6	Metode new-MSR dapat mengungguli metode pembandingan secara keseluruhan
7	Metode BCN dapat mencapai akurasi dan keragaman yang baik dengan preferensi yang wajar berdasarkan popularitas <i>item</i>
8	Model JUST lebih baik daripada model pembandingan dalam merekomendasikan <i>item</i> dengan efek <i>long tail</i>
9	Metode HPCF mengungguli metode berbasis SVD dan metode berbasis popularitas <i>item</i>
10	Metode HPop mengungguli metode pembandingan secara keseluruhan
11	<i>User Profile Learning</i> meningkatkan kualitas rekomendasi pada data yang memiliki <i>sparsity</i> yang tinggi
12	Pengguna umumnya tertarik pada <i>item</i> yang populer. Pengguna yang tertarik pada <i>item</i> yang tidak populer (LowMS) mendapatkan rekomendasi yang lebih rendah kualitasnya dibandingkan dengan pengguna yang tertarik pada <i>item</i> yang populer (HighMS)
13	Metode P-HTCL memiliki indeks relevansi yang lebih baik dan rekomendasi yang lebih beragam dibandingkan metode pembandingan
14	Metode CP efektif mengatasi bias popularitas untuk berbagai pengguna dan meningkatkan hasil evaluasi yang berpusat pada <i>item</i>
15	Metode Popcorn mampu meningkatkan kualitas rekomendasi dan menurunkan bias popularitas lebih baik daripada metode pembandingan
16	Metode DICE dapat mengungguli metode pembandingan, Metode DICE juga dapat bekerja efektif pada data non-IID
17	Metode PDA efektif dalam mengidentifikasi preferensi pengguna, menyesuaikan inferensi dengan bias popularitas, dan meningkatkan akurasi rekomendasi secara keseluruhan
18	Metode PopHybrid dapat mengurangi bias popularitas dengan lebih baik jika dibandingkan metode pembandingan

19	Metode Debias dapat mengurangi bias popularitas dalam CRS dan meningkatkan kinerja rekomendasi secara keseluruhan.
20	Metode AWING-APS dapat mengidentifikasi preferensi pengguna dengan lebih baik dibandingkan dengan metode pembandingan



Gambar 6. Luaran dalam literatur penerapan teknik popularitas *item* pada sistem rekomendasi

3.5 Luaran Rekomendasi

Luaran pada sistem rekomendasi dapat berupa prediksi rating dan/atau rekomendasi top-*N*. Prediksi rating merupakan prediksi nilai yang akan diberikan oleh pengguna kepada *item*. Sedangkan rekomendasi top-*N* merupakan daftar rekomendasi *item* (sejumlah *N*) yang memiliki nilai prediksi rating paling tinggi untuk pengguna. Bentuk luaran menentukan jenis metrik evaluasi yang digunakan untuk mengukur performa sistem rekomendasi. Gambar 6 memperlihatkan sebaran luaran dalam literatur yang didominasi oleh luaran berupa rekomendasi top-*N*, yaitu 90% dari keseluruhan literatur.

4. Kesimpulan

Penelitian ini melakukan studi untuk mengetahui tren dari penelitian yang menerapkan teknik popularitas *item* dalam sistem rekomendasi. Jumlah literatur yang digunakan adalah sebanyak 20 dari penelitian yang dilakukan dalam rentang waktu mulai dari tahun 2012 sampai 2022. Hasil studi menunjukkan bahwa topik popularitas *item* sedang populer diteliti pada kurun waktu 2018 hingga 2022, yaitu sebanyak 16 literatur. Jenis literatur didominasi oleh prosiding yaitu sebanyak 15 literatur berbentuk prosiding, dan sisanya berupa jurnal. *Dataset* yang paling banyak digunakan dalam literatur adalah MovieLens dan LastFM, yaitu untuk sistem rekomendasi film dan lagu. Fokus masalah yang paling mendominasi dalam literatur penerapan teknik popularitas *item* adalah penyelesaian permasalahan bias popularitas, yaitu sebanyak 12 literatur. Sedangkan luaran rekomendasi dalam literatur didominasi oleh luaran berupa rekomendasi top-*N*, yaitu sebanyak 18 literatur.

Daftar Pustaka:

- Abdollahpouri, H., & Mansoury, M. (2020). Multi-sided Exposure Bias in Recommendation. *Proceedings of The ACM KDD 1st International Workshop on Industrial Recommendation Systems*, Virtual, 157–165, doi: <https://doi.org/10.48550/arXiv.2006.15772>.
- Abdollahpouri, H., Mansoury, M., Burke, R., Mobasher, B., & Malthouse, E. (2021). User-centered evaluation of popularity bias in recommender systems. *Proceedings of The 29th ACM Conference on User Modeling, Adaptation and Personalization*, Utrecht, Netherlands, 119–129, doi: <https://doi.org/10.1145/3450613.3456821>.
- Bertani, R. M., Bianchi, R. A. C., & Costa, A. H. R. (2020). Combining novelty and popularity on personalised recommendations via user profile learning. *Expert Systems with Applications*, 146, 113149, doi: <https://doi.org/10.1016/j.eswa.2019.113149>.
- Chen, C., Zhang, M., Liu, Y., & Ma, S. (2018). Missing data modeling with user activity and item popularity in recommendation. In Y. Tseng, et al. (Ed.), *Information Retrieval Technology. AIRS 2018. Lecture Notes in Computer Science* (Vol. 11292, pp. 113–125). Switzerland Springer International Publishing, doi: https://doi.org/10.1007/978-3-030-03520-4_11.
- Chen, S.-H., Sou, S.-I., & Hsieh, H.-P. (2020). HPCF: hybrid music group recommendation system based on item popularity and collaborative filtering. *Proceedings of The 2020 International Computer Symposium (ICS)*, Tainan, Taiwan, 43–49, doi: <https://doi.org/10.1109/ICS51289.2020.00019>.
- Chen, T., Tian, H., & Zhu, X. (2014). An Enhanced Collaborative Filtering with Flexible Item Popularity Control for Recommender Systems. *Proceedings of The 2014 International Conference on Social Computing (SocialCom '14)*, Beijing, China, 1–6, doi: <https://doi.org/10.1145/2639968.2640076>.
- de Sousa Silva, D. V., & Durão, F. A. (2020). Dynamic clustering personalization for recommending long tail items. *Proceedings of The 2020 15th Conference on Computer Science and Information Systems (FedCSIS)*, Sofia, Bulgaria, 417–425, doi: <https://doi.org/10.15439/2020F157>.
- Fu, Z., Xian, Y., Geng, S., De Melo, G., & Zhang, Y. (2021). Popcorn: Human-in-the-loop popularity debiasing in conversational recommender systems. *Proceedings of The 30th ACM International Conference on Information & Knowledge Management*, Virtual Event Queensland, Australia, 494–503, doi: <https://doi.org/10.1145/3459637.3482461>.
- Gao, X., Ji, Q., Mi, Z., Yang, Y., & Guo, Y. (2018). Similarity measure based on punishing popular items for collaborative filtering. *Proceedings of The 2018 International Conference on Computer, Information and Telecommunication Systems (CITS)*, Alsace, Colmar, France, 1–5, doi: <https://doi.org/10.1109/CITS.2018.8440147>.
- Hou, L., Pan, X., & Liu, K. (2018). Balancing the popularity bias of object similarities for personalised recommendation. *The European Physical Journal B*, 91, 47, doi: <https://doi.org/10.1140/epjb/e2018-80374-8>.
- Ifada, N., Ummamah, & Sophan, M. K. (2020). Hybrid Popularity Model for Solving Cold-start Problem in Recommendation System. *Proceedings of The 2020 International Conference on Sustainable Information Engineering and Technology (SIET)*, Malang, Indonesia, 40–44, doi: <https://doi.org/10.1145/3427423.3427425>.
- Kowald, D., Schedl, M., & Lex, E. (2020). The unfairness of popularity bias in music recommendation: A reproducibility study. In J. Jose, et al. (Ed.), *Advances in Information Retrieval. ECIR 2020. Lecture Notes in Computer Science* (Vol. 12036, pp. 35–42). Switzerland: Springer International Publishing, doi: https://doi.org/10.1007/978-3-030-45442-5_5.
- Lin, A., Wang, J., Zhu, Z., & Caverlee, J. (2022). Quantifying and mitigating popularity bias in conversational recommender systems. *Proceedings of The 31st ACM International Conference on Information & Knowledge Management*, Atlanta GA, USA, 1238–1247, doi: <https://doi.org/10.1145/3511808.3557423>.
- Steck, H. (2011). Item popularity and recommendation accuracy. *Proceedings of The fifth ACM conference on Recommender systems (RecSys '11)*, Chicago Illinois, USA, 125–132, doi: <https://doi.org/10.1145/2043932.2043957>.
- Sun, C., & Xu, Y. (2019). Topic Model-Based Recommender System for Longtailed Products Against Popularity Bias. *Proceedings of The 2019 IEEE Fourth International Conference on Data Science in Cyberspace (DSC)*, Hangzhou, China, 250–256, doi: <https://doi.org/10.1109/DSC.2019.00045>.
- Valcarce, D., Parapar, J., & Barreiro, Á. (2016). Item-based relevance modelling of recommendations for getting rid of long tail products. *Knowledge-Based Systems*, 103, 41–51, doi: <https://doi.org/10.1016/j.knosys.2016.03.021>.
- Wang, J., & Luo, N. (2016). A New Hybrid Popular Model for Personalized Tag Recommendation. *Journal of Computers*, 11(2), 116–123, doi: <https://doi.org/10.17706/jcp.11.2.116-123>.
- Wei, F., Chen, S., Jin, J., Zhang, S., Zhou, H., & Wu, Y. (2022). Adaptive alleviation for popularity

- bias in recommender systems with knowledge graph. *Security and Communication Networks*, 2022, 4264489, doi: <https://doi.org/10.1155/2022/4264489>.
- Yalcin, E. (2022). PopHybrid: a novel item popularity-aware hybrid approach for long-tail recommendation. *Proceedings of The 2022 International Congress on Human-Computer Interaction, Optimization and Robotic Applications (HORA)*, Ankara, Turkey, 1-6, doi: <https://doi.org/10.1109/HORA55278.2022.9800006>.
- Yin, H., Cui, B., Li, J., Yao, J., & Chen, C. (2012). Challenging the long tail recommendation. *Proceedings of The VLDB Endowment (The 38th International Conference on Very Large Data Bases)*, Istanbul, Turkey, 896-907, doi: <https://doi.org/10.48550/arXiv.1205.6700>.
- Yomeldi, H. (2020). Decision Making in Internet of Things (IoT): A Systematic Literature Review. *ITEJ (Information Technology Engineering Journals)*, 5(1), 51-65, doi: <https://doi.org/10.24235/itej.v5i1.40>.
- Zhang, Y., Feng, F., He, X., Wei, T., Song, C., Ling, G., & Zhang, Y. (2021). Causal intervention for leveraging popularity bias in recommendation. *Proceedings of The 44th International ACM SIGIR Conference on Research and Development in Information Retrieval*, Virtual Event Canada, 11-20, doi: <https://doi.org/10.1145/3404835.3462875>.
- Zheng, Y., Gao, C., Li, X., He, X., Li, Y., & Jin, D. (2021). Disentangling user interest and conformity for recommendation with causal embedding. *Proceedings of The Web Conference 2021 (WWW)*, Ljubljana, Slovenia, 2980-2991, doi: <https://doi.org/10.1145/3442381.3449788>.

Halaman ini sengaja dikosongkan