



Hauptseminar

Hochschule für Angewandte Wissenschaften Hamburg
Hamburg University of Applied Sciences

News Recommendation with ML

Timo Lange

Hauptseminarvortrag SoSe 2018

HAW Hamburg
Fakultät Technik und Informatik
Studiendepartment Informatik
Studiengang: Master Informatik

05.06.2018



Gliederung

- Einleitung & Motivation
- Forschungsfrage
- Recommendation
 - Verfahren
 - Literatur
- Methodik
- Forschungsrisiko
- Aktueller Stand
- Ausblick



Einleitung & Motivation

Hochschule für Angewandte Wissenschaften Hamburg
Hamburg University of Applied Sciences

- Bachelorarbeit
- Grundseminar
- DPA Datensatz



Einleitung & Motivation

Hochschule für Angewandte Wissenschaften Hamburg
Hamburg University of Applied Sciences

- Deutsche Presse Agentur (DPA)
 - Kunden
 - DPA-Select
 - DPA-Executive
- Nutzen für DPA
 - Relevantere Artikel für Kunden in dessen News-Stream
 - Kunden bekommen evtl. relevante Artikel die sie nach herkömmlicher Methode verpasst hätten
 - DPA kann mehr verkaufen



Einleitung & Motivation

Hochschule für Angewandte Wissenschaften Hamburg
Hamburg University of Applied Sciences

- DPA Datensatz
 - Strukturiert
 - NewsML-G2
 - Hohe Qualität
 - Metadaten
 - Über 200.000 Artikel
 - Über 4 Millionen zu erwarten (plus Bilder)
 - Regelmäßige Updates zu erwarten



Forschungsfrage

- Wie geeignet sind Deep Learning (DL) Modelle für (DPA) News Empfehlungen?
- Welche Algorithmen sind am besten geeignet, um Empfehlungen für den DPA Datensatz zu erzeugen?
- Sind die vorhandenen / noch zu erwartenden Daten von der DPA ausreichend, um gute Empfehlungen zu erzeugen?



Erwartete Ergebnisse

Hochschule für Angewandte Wissenschaften Hamburg
Hamburg University of Applied Sciences

- DL wird sehr nützlich sein, um viele verschiedene Daten für die Empfehlung zu nutzen.
- Die Qualität der Empfehlung wird sehr stark davon abhängen, ob viele Nutzerdaten verwendet werden können.



Recommendation

- Definition von Recommender Systemen
 - „Recommender Systems (RSs) are software tools and techniques providing suggestions for items to be of use to a user“ [2]
 - „The construction of systems that support users in their (online) decision making is the main goal of the field of recommender systems. In particular, the goal of recommender systems is to provide easily accessible, high-quality recommendations for a large user community“ [3]



Recommendation

- Wozu Recommender Systeme
 - Nutzer beeinflussen (z.B. etwas zu kaufen)
 - Information Overload bewältigen

- Nutzen von RS
 - Netflix: 2/3 der Filme wurden aufgrund von Recommendations gesehen.[1]
 - Google News: Recommendations generieren 38% mehr clickthrough.[1]
 - Amazon: 35% sales von Recommendations.[1]
 - Choicestream: 28% der Leute würden mehr Musik kaufen, wenn sie finden würden was sie mögen.[1]

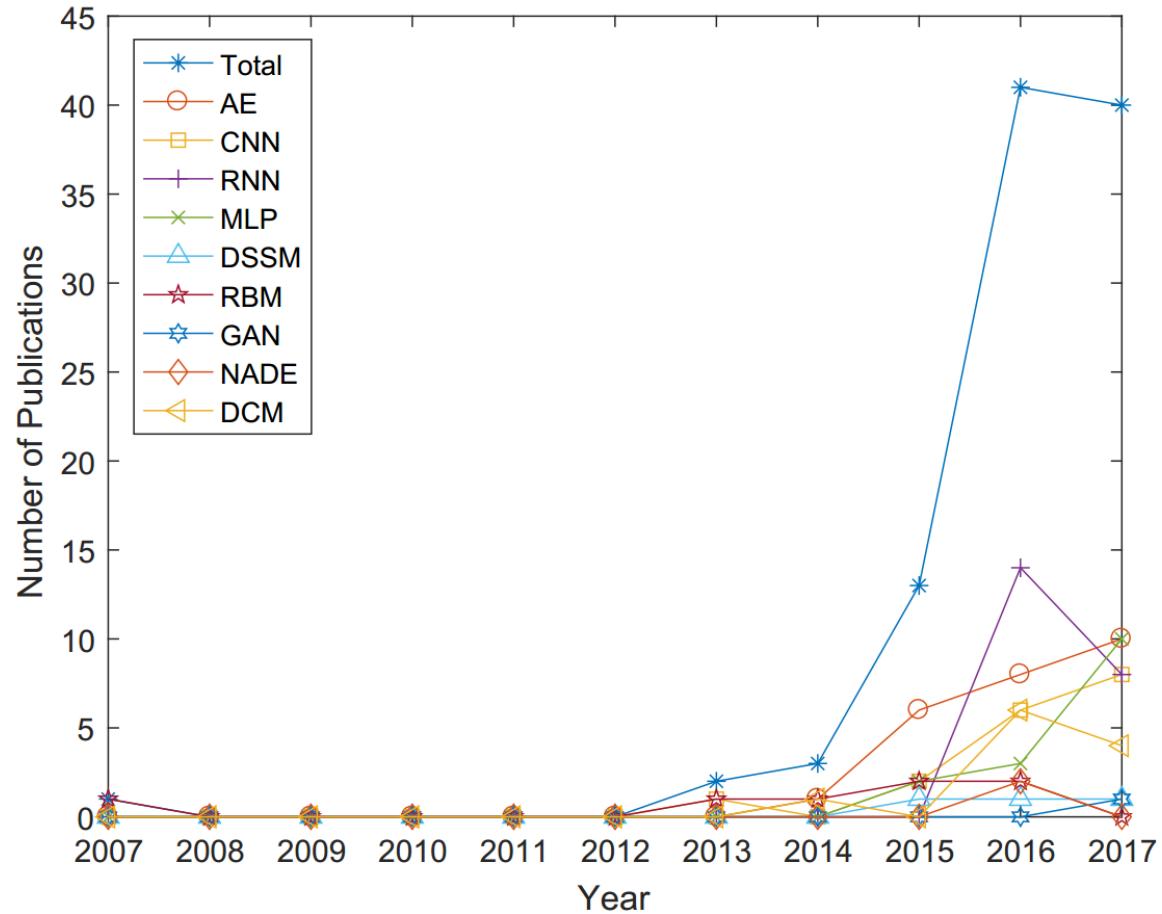


Recommendation

Hochschule für Angewandte Wissenschaften Hamburg
Hamburg University of Applied Sciences

- CNN Money, “The race to create a 'smart' Google”:
 - “The Web, they say, is leaving the era of search and entering one of discovery. What's the difference? Search is what you do when you're looking for something. Discovery is when something wonderful that you didn't know existed, or didn't know how to ask for, finds you.” [1]
- Eli Pariser: The Filter Bubble: What the Internet Is Hiding from You. Penguin Press, New York, 2011

- Hat durch Netflix Preis von 2006 stark zugenommen
 - 1\$ Million Preisgeld für 10% Verbesserung (RMSE)
- DL in RS Community relativ neu
 - Vermehrte Forschung seit ca. 2016
 - Relativ geringe Anzahl an Paper für News RS mit DL im Gegensatz zu E-Commerce/Filme/Musik



[5]



Recommendation Verfahren

Hochschule für Angewandte Wissenschaften Hamburg
Hamburg University of Applied Sciences

- Grobe Unterteilung in
 - Collaborative Filtering
 - Content-Based
 - Knowledge-Based
 - Hybrid Systems



Collaborative Filtering

Hochschule für Angewandte Wissenschaften Hamburg
Hamburg University of Applied Sciences

- Methoden
 - Neighborhood Methoden
 - Latent Factor Models
 - Deep Learning

Collaborative Filtering

Neighborhood Methode

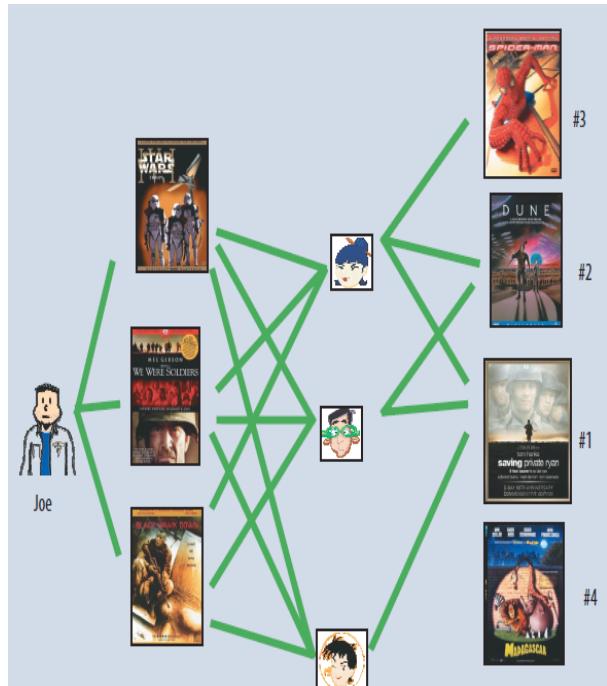


Figure 1. The user-oriented neighborhood method. Joe likes the three movies on the left. To make a prediction for him, the system finds similar users who also liked those movies, and then determines which other movies they liked. In this case, all three liked *Saving Private Ryan*, so that is the first recommendation. Two of them liked *Dune*, so that is next, and so on.

Latent Factor Methode

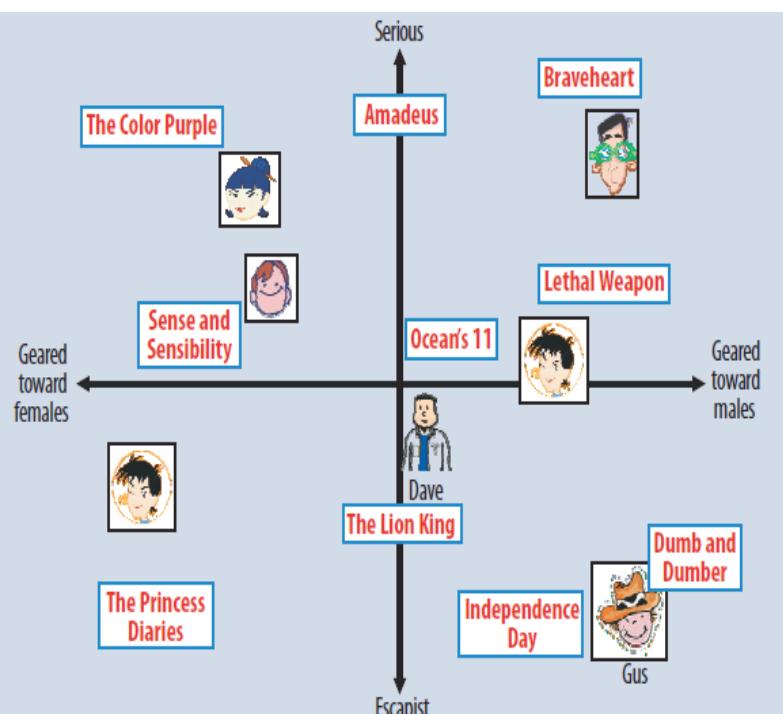


Figure 2. A simplified illustration of the latent factor approach, which characterizes both users and movies using two axes—male versus female and serious versus escapist.

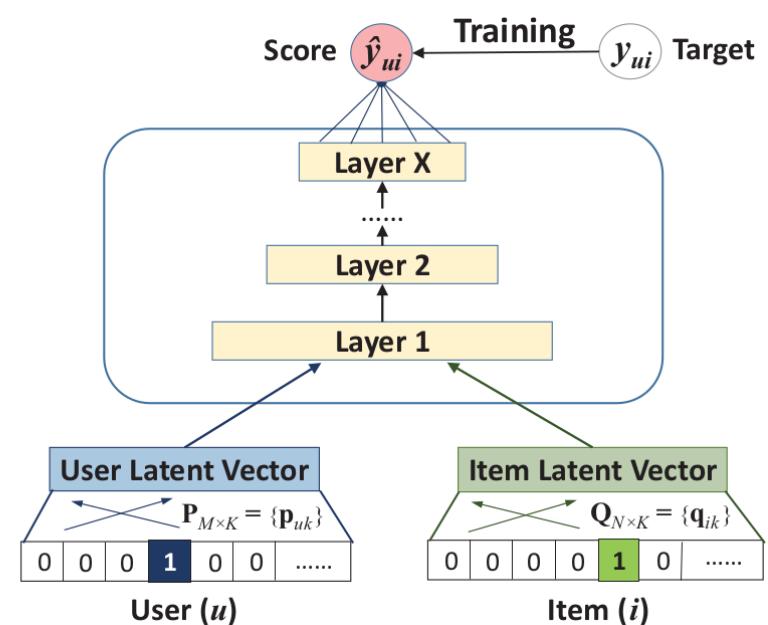
Neural Collaborative Filtering Framework

Output Layer

Neural CF Layers

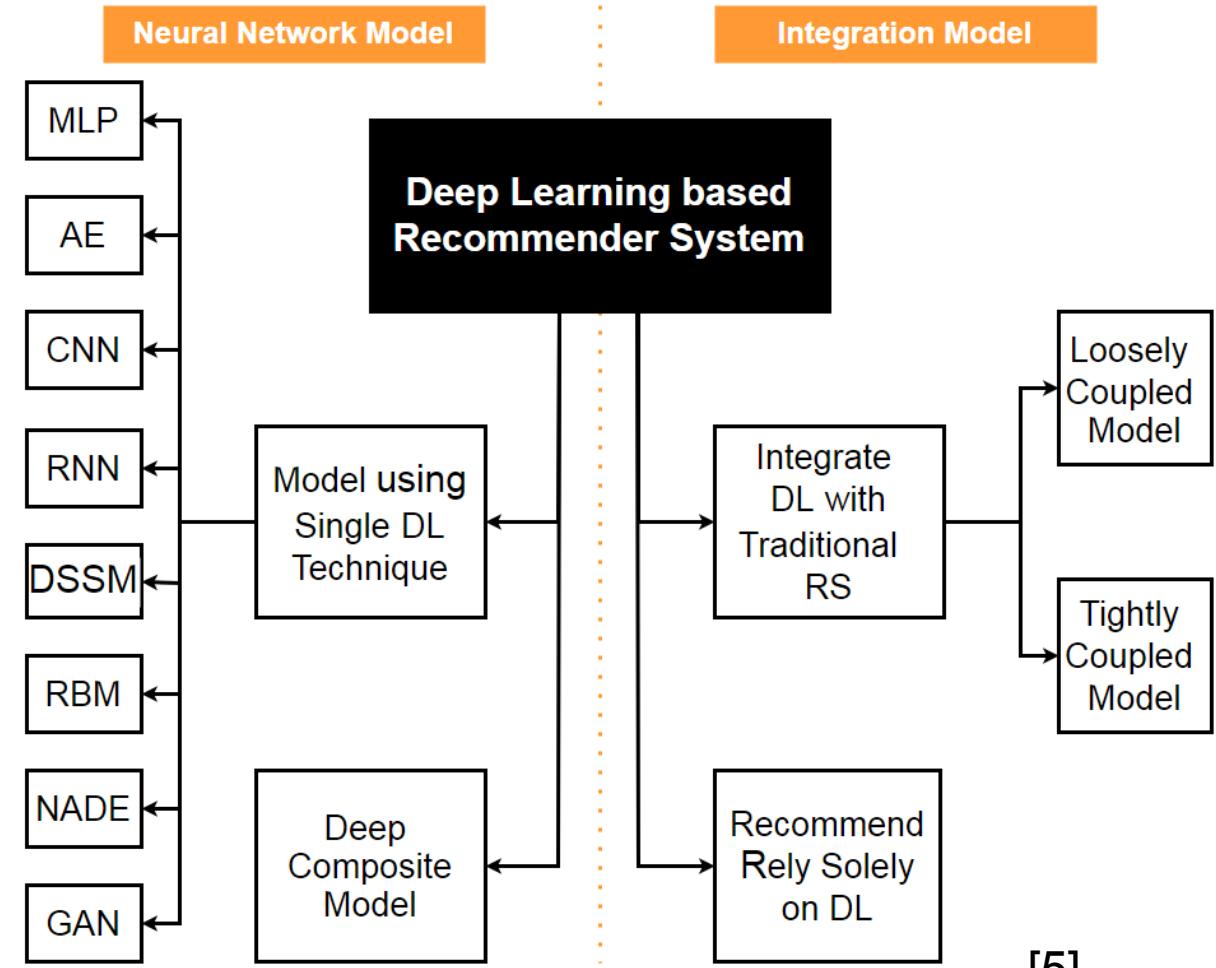
Embedding Layer

Input Layer (Sparse)



DL based Recommender Systems[6]

- Single DL Technik
- Deep Composite Model
 - Verbindung mehrerer DL Verfahren zu einem Modell
- Integration Model
 - DL kombiniert mit traditionellem Recommendation Modell



[5]



DL News Recommendation Literatur 1

Hochschule für Angewandte Wissenschaften Hamburg
Hamburg University of Applied Sciences

- Okura et al. 2017: „Embedding-based News Recommendation for Millions of Users“[7]
 - Integration RS Model (tightly coupled)
 - AE
 - RNN (GRU)
 - Yahoo News (in production)
- Wang et al. 2017: „Dynamic Attention Deep Model for Article Recommendation by Learning Human Editors’ Demonstration“[9]
 - CNN (single DL)
 - Attention Mechanismus



DL News Recommendation Literatur 2

Hochschule für Angewandte Wissenschaften Hamburg
Hamburg University of Applied Sciences

- Song et al. 2016: „Multi-Rate Deep Learning for Temporal Recommendation“[8]
 - Deep Composite Model (RNN & DSSM)
 - DSSM für Item static Features
 - 2 Subnetze für
 - User static Features (MLP)
 - User temporal Features (RNN)
- Chen et al. 2017: „Location-Aware Personalized News Recommendation With Deep Semantic Analysis“[6]
 - DSSM (single DL)
 - Bezieht geographische Position des Nutzers ein



Weitere relevante DL RS Literatur 1

- Chen et al. 2017 „Attentive Collaborative Filtering: Multimedia Recommendation with Item- and Component-Level Attention“[10]
 - Integration RS Model (tightly coupled)
 - MLP
 - Attention
 - Item-Level wählt repräsentativstes Item für den User
 - Component-Level wählt das informativste Feature eines Items
 - Gut interpretierbare Ergebnisse
- Hsieh et al. 2016 „Immersive Recommendation: News and Event Recommendations Using Personal Digital Traces“[11]
 - Nutzt Social Media
 - Tweets
 - Facebook Posts



Weitere relevante DL RS Literatur 2

- Bansal et al. 2016 „Ask the GRU: Multi-task Learning for Deep Text Recommendations“[14]
 - RNN (single DL)
 - Multi-task learning
 - Vermeidet Overfitting
 - Interpretierbarer Output
 - Mindert Sparsity Problem durch implizite Datenaugmentierung
- Zhang et al. 2016 „Collaborative Knowledge Base Embedding for Recommender Systems“[15]
 - Deep Composite Model (CNN & AE)
 - Integration RS Model (tightly coupled)
 - Kann verschiedene Medien wie Text oder Bilder einbinden
- Li et al 2015. „Deep Collaborative Filtering via Marginalized Denoising Auto-encoder“[16]
 - Integration RS Model mit AE (tightly coupled)
 - Nutzt Content Information von Usern und Items



Zu beachtende Besonderheiten bei (DPA) News RS

Hochschule für Angewandte Wissenschaften Hamburg
Hamburg University of Applied Sciences

- Relevanz der Artikel verändert sich stark mit der Zeit
- Metadaten & Bilder die sonst nicht in öffentlichen Datensätzen zu finden sind
- Nutzer sind keine Endnutzer (außer DPA-Executive)
 - Kein implizites Feedback durch Klicks/Views
 - Keine Session History



Methodik

- Erstellung der Modelle in TensorFlow
- Nutzung der bereits vorhandenen Pipeline zur Datenvorverarbeitung
 - Weitere Synergie durch ähnliche Teilaufgaben in ML-AG
- „Interview“ mit DPA-Mitarbeiter
 - Anforderungen an RS erheben
 - Nutzerdaten erhalten?
- Evaluation geeigneter DL Verfahren für DPA Daten und Anforderungen an das RS
- Alternative Nutzerdaten
 - Zeitungsarchive nach veröffentlichten Artikeln durchsuchen
 - Sozial Media Accounts der Nutzer (Zeitungen) heranziehen



Forschungsrisiko

- Risiken
 - Keine Daten über Nutzer?
 - Zu geringe Menge an Nutzerdaten?
 - Evtl. nicht ausreichend für Training
 - In der Literatur wird i.d.R. mit vielen Nutzerdaten gearbeitet
 - „Real-World“ Daten
 - Informationsbeschaffung zu RS Anforderungen
- Chancen
 - „Real-World“ Daten
 - Metadaten werden bisher nicht umfänglich genutzt
 - News RS mit DL relativ neu



Aktueller Stand

- Literatur Review
 - Sichtung möglicher (DL) Verfahren für RS
- Einarbeitung in
 - DL
 - NLP
 - Python libraries wie
 - TensorFlow
 - Pandas
 - Numpy



Ausblick

- Entwicklung einer Recommendation System Architektur
- Aufbau einer Pipeline zur Datenvorverarbeitung
- Implementation der RS Architektur und Integration in Verarbeitungspipeline



Quellen Literatur 1

- [1] Xavier Amatriain, „Introduction to Recommender Systems: A 4-hour lecture“, 2014. Abruf 21.05.2017.
- [2] F. Ricci, L. Rokach, B. Shapira, und P. B. Kantor, Recommender Systems Handbook. Boston, MA: Springer US, 2011.
- [3] D. Jannach, Markus Zanker, Alexander Felfernig, und Gerhard Friedrich, Recommender systems: an introduction. New York: Cambridge University Press, 2011.
- [4] Y. Koren, R. Bell, und C. Volinsky, „Matrix Factorization Techniques for Recommender Systems“, Computer, Bd. 42, Nr. 8, S. 30–37, Aug. 2009.
- [5] Zhang, Shuai, Lina Yao, und Aixin Sun. „Deep Learning based Recommender System: A Survey and New Perspectives“. arXiv:1707.07435 [cs], 24. Juli 2017. <http://arxiv.org/abs/1707.07435>.
- [6] Chen, C., X. Meng, Z. Xu, und T. Lukasiewicz. „Location-Aware Personalized News Recommendation With Deep Semantic Analysis“. IEEE Access 5 (2017): 1624–38. <https://doi.org/10.1109/ACCESS.2017.2655150>.
- [7] Okura, Shumpei, Yukihiro Tagami, Shingo Ono, und Akira Tajima. „Embedding-based News Recommendation for Millions of Users“. In Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 1933–1942. KDD ’17. New York, NY, USA: ACM, 2017. <https://doi.org/10.1145/3097983.3098108>.
- [8] Song, Yang, Ali Mamdouh Elkahky, und Xiaodong He. „Multi-Rate Deep Learning for Temporal Recommendation“. In Proceedings of the 39th International ACM SIGIR Conference on Research and Development in Information Retrieval, 909–912. SIGIR ’16. New York, NY, USA: ACM, 2016. <https://doi.org/10.1145/2911451.2914726>.
- [9] Wang, Xuejian, Lantao Yu, Kan Ren, Guanyu Tao, Weinan Zhang, Yong Yu, und Jun Wang. „Dynamic Attention Deep Model for Article Recommendation by Learning Human Editors’ Demonstration“. In Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 2051–2059. KDD ’17. New York, NY, USA: ACM, 2017. <https://doi.org/10.1145/3097983.3098096>.
- [10] Chen, Jingyuan, Hanwang Zhang, Xiangnan He, Liqiang Nie, Wei Liu, und Tat-Seng Chua. „Attentive Collaborative Filtering: Multimedia Recommendation with Item- and Component-Level Attention“. In Proceedings of the 40th International ACM SIGIR Conference on Research and Development in Information Retrieval, 335–344. SIGIR ’17. New York, NY, USA: ACM, 2017. <https://doi.org/10.1145/3077422.3080734>.



Quellen Literatur 2

- [11]Hsieh, Cheng-Kang, Longqi Yang, Honghao Wei, Mor Naaman, und Deborah Estrin. „Immersive Recommendation: News and Event Recommendations Using Personal Digital Traces“. In Proceedings of the 25th International Conference on World Wide Web, 51–62. WWW ’16. Republic and Canton of Geneva, Switzerland: International World Wide Web Conferences Steering Committee, 2016. <https://doi.org/10.1145/2872427.2883006>.
- [12]He, Xiangnan, Lizi Liao, Hanwang Zhang, Liqiang Nie, Xia Hu, und Tat-Seng Chua. „Neural Collaborative Filtering“. In Proceedings of the 26th International Conference on World Wide Web, 173–182. WWW ’17. Republic and Canton of Geneva, Switzerland: International World Wide Web Conferences Steering Committee, 2017. <https://doi.org/10.1145/3038912.3052569>.
- [13]Zheng, Guanjie, Fuzheng Zhang, Zihan Zheng, Yang Xiang, Nicholas Jing Yuan, Xing Xie, und Zhenhui Li. „DRN: A Deep Reinforcement Learning Framework for News Recommendation“. In Proceedings of the 2018 World Wide Web Conference, 167–176. WWW ’18. Republic and Canton of Geneva, Switzerland: International World Wide Web Conferences Steering Committee, 2018. <https://doi.org/10.1145/3178876.3185994>.
- [14]Bansal, Trapit, David Belanger, und Andrew McCallum. „Ask the GRU: Multi-task Learning for Deep Text Recommendations“. In Proceedings of the 10th ACM Conference on Recommender Systems, 107–114. RecSys ’16. New York, NY, USA: ACM, 2016. <https://doi.org/10.1145/2959100.2959180>.
- [15]Zhang, Fuzheng, Nicholas Jing Yuan, Defu Lian, Xing Xie, und Wei-Ying Ma. „Collaborative Knowledge Base Embedding for Recommender Systems“. In Proceedings of the 22Nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 353–362. KDD ’16. New York, NY, USA: ACM, 2016. <https://doi.org/10.1145/2939672.2939673>.
- [16]Li, Sheng, Jaya Kawale, und Yun Fu. „Deep Collaborative Filtering via Marginalized Denoising Auto-encoder“. In Proceedings of the 24th ACM International on Conference on Information and Knowledge Management, 811–820. CIKM ’15. New York, NY, USA: ACM, 2015. <https://doi.org/10.1145/2806416.2806527>.