

# Implizites Feedback in Empfehlungssystemen: Eigenschaften, Anwendungen und Herausforderungen<sup>1</sup>

Lukas Lerche<sup>2</sup>

**Abstract:** *Empfehlungssysteme* (engl. recommender systems) werden zur Vermeidung der *Informationüberflutung* auf digitalen Plattformen eingesetzt, indem sie *Nutzern* helfen, relevante *Artikel* aus einer unüberschaubaren Menge zu identifizieren. Die Erzeugung solch *personalisierter Empfehlungen* erfolgt auf Basis von Nutzerfeedback. In dieser Arbeit wird sogenanntes *implizites Feedback* untersucht, typische Anwendungsszenarien beschrieben und aktuelle algorithmische Ansätze vorgestellt. Im Detail werden (i) ein neuartiger *“learning-to-rank“-Algorithmus* eingeführt, der verschiedene Granularitäten von implizitem Feedback differenzieren kann, (ii) kontextualisierte Empfehlungstechniken für die E-Commerce-Domäne präsentiert, welche Empfehlungen an die *kurzfristigen Ziele* der Nutzer anpassen können, (iii) intelligente *Erinnerungsempfehlungen* zur Wiederentdeckung von bekannten Artikeln vorgeschlagen, und (iv) eine tiefgreifende Analyse verschiedener Empfehlungsalgorithmen hinsichtlich ihres *Popularitätsbias* (engl. popularity bias) durchgeführt und Gegenmaßnahmen gezeigt, die dieser Tendenz effektiv entgegenwirken können.

Explizites Feedback

	i1	i2	i3	i4	i5	i6
u1	5★	2★			4★	
u2	4★		1★			

Implizites Feedback

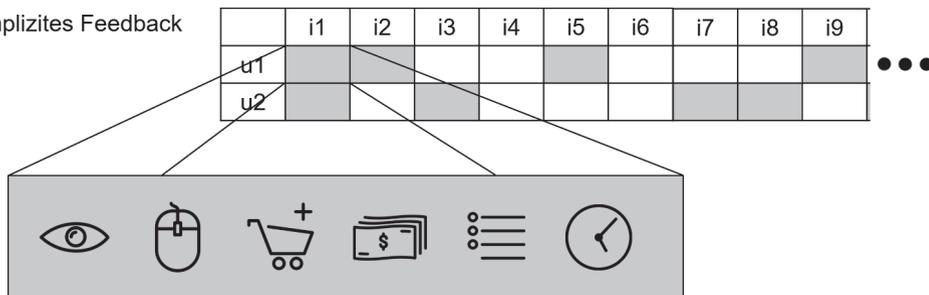


Abb. 1: Explizites und implizites Feedback im Vergleich. Das Feedback ist als Matrix zwischen Nutzern  $u$  und Artikeln  $i$  dargestellt. Implizites Feedback kann verschiedene Ausprägungen haben.

<sup>1</sup> Englischer Titel der Dissertation: “Using Implicit Feedback for Recommender Systems: Characteristics, Applications, and Challenges”

<sup>2</sup> TU Dortmund, lukas.lerche@tu-dortmund.de

# 1 Einleitung

Die Personalisierung der Nutzererfahrung ist im digitalen Zeitalter allgegenwärtig geworden. Im Netz sind Nachrichten, Suchergebnisse und auch Werbung keine statischen, für jeden Nutzer identischen Inhalte mehr, sondern werden dynamisch an die jeweiligen Interessen des Einzelnen angepasst. Hinter dieser persönlichen Informationsaufbereitung stecken zumeist sogenannte Empfehlungssystemen. Ziel eines Empfehlungssystems ist die Bestimmung von passenden Artikeln für einen Nutzer. Die Relevanz der Artikel wird hierbei durch ein sogenanntes *Relevanzmaß* (engl. relevance score) modelliert, welches das jeweilige Interesse eines Nutzers für jeden Artikel quantifizieren soll, etwa basierend auf den persönlichen Präferenzen oder dem aktuellen (zeitlichen, örtlichen, ...) Kontext des Nutzers. Schlussendlich wird eine geordnete Liste der relevantesten Artikel erzeugt, die dem Nutzer in passender Weise mitgeteilt wird, etwa als “Dies könnte ihnen auch gefallen...” oder “Andere Kunden kauften auch...”.

Heutzutage sind solch personalisierte Empfehlungen auf vielen Webseiten und in mobilen Anwendungen anzutreffen, beispielsweise in Domänen wie E-Commerce und Multimedia oder in sozialen Netzwerken. Dabei werden verschiedenste Arten von “Artikeln” empfohlen, etwa Produkte in Online-Shops, Filme und Musik auf Streaming-Portalen oder gar Personen im Sinne von möglichen Freundesbeziehungen in Netzwerken. Auch gewinnen Empfehlungssysteme aufgrund der zunehmenden Nutzung von Online-Angeboten auf mobilen Geräten an Bedeutung, da sie den Interaktionsprozess des Nutzers mit dem System vereinfachen und beschleunigen können.

## 1.1 Historische Entwicklung von Empfehlungssystemen

Historisch werden Empfehlungssysteme in die Gruppen des *kollaborativen Filterns* (engl. collaborative filtering, CF) und des *inhaltsbasierten Filterns* (engl. content-based filtering, CB) eingeteilt, wobei auch feingranularere Einteilungen existieren [Ri11]. Kollaboratives Filtern hat das im Allgemeinen das Ziel, Gruppen von Nutzern mit ähnlichem Verhalten, auch *Nachbarn* (engl. neighbors) genannt, zu finden. Dies können beispielsweise Nutzer sein, die gleiche Artikel positiv bewertet haben. Sollen nun Empfehlungen für einen Nutzer generiert werden, so werden die Artikel vorgeschlagen, die auch von den Nachbarn des Nutzers gemocht wurden. Inhaltsbasiertes Filtern dagegen nutzt zur Erstellung von Empfehlungen die Charakteristika der Artikel, etwa deren Klassifikation, Metadaten oder textuelle Beschreibung, um jene Artikel zu identifizieren, die inhaltlich möglichst ähnlich sind zu den Artikeln, die ein aktuell Nutzer präferiert. In der Praxis werden beide Ansätze oft kombiniert und es entsteht ein sogenanntes *hybrides Empfehlungssystem* [Ja11].

Um überhaupt personalisierte Empfehlungen erzeugen zu können, müssen dem Empfehlungssystem bestimmte Informationen über die Nutzer bekannt sein. Dieses sogenannte *Nutzerprofil* enthält normalerweise die vergangenen Interaktionen eines Nutzers mit einer Plattform, beispielsweise die Browsing-Historie in einem Online-Shop oder die Bewertungen, die der Nutzer bestimmten Artikeln gab. Klassischerweise konzentrierte sich die

Forschung im Bereich Empfehlungssysteme auf Fragestellungen, in denen das Nutzerprofil vollständig aus *explizitem Feedback* (auch: explizite Signale, engl. explicit feedback) besteht, also bewusst abgegebenen *Bewertungen* (engl. ratings, vgl. Sterne-Bewertung bei Amazon) oder “Like/Dislike”-Angaben (vgl. Facebook) [JWK14]. Abbildung 1 zeigt solch explizite (Sterne-)Bewertungen in einer Bewertungsmatrix. Basierend auf diesen Signalen kann ein Empfehlungssystem die Relevanz der für einen Nutzer noch nicht bekannten Artikel ermitteln. In der Praxis zeigt sich jedoch, dass in vielen Anwendungsdomänen kein oder wenig explizites Feedback von Nutzern vorkommt. Selbst in Domänen, in denen explizite Bewertungen durch Nutzer möglich sind, geben meist nur wenige Nutzer Bewertungen ab und diese konzentrieren sich oftmals auf eine kleine Menge populärer Artikel. Die Nutzerprofile sind daher im Allgemeinen spärlich bestückt und für Empfehlungen eines breiten Produktspektrums wenig hilfreich [JH09, JKG12].

## 1.2 Herausforderungen

Anstatt sich nur auf explizites, von den Nutzern bewusst abgegebenes Feedback zu verlassen, kann auch das Verhalten von Nutzern beobachtet und analysiert werden, um indirekt auf die Nutzerinteressen zu schließen. Empfehlungssysteme müssen hierfür dazu übergehen, dieses sogenannte *implizite Feedback* (auch: implizite Signale, engl. implicit feedback) zu nutzen, welches indirekt aus dem Verhalten der Nutzer und ihrer Interaktion mit der entsprechenden Plattform abgeleitet wird. Aus diesem Grund ist implizites Feedback in vielen Domänen vorhanden, sei es Online-Shopping, soziale Netzwerke oder Multimedia, da es etwa aus Navigations- oder Transaktionslogs der Webseiten extrahiert werden kann.

Obwohl implizite Signale deutlich besser und häufiger verfügbar sind als explizites Feedback, führt ihr Einsatz nichtsdestotrotz zu weiteren Herausforderungen und offenen Fragestellungen. Beispielsweise kann implizites Feedback mehrdeutig sein, d.h. es können verschiedene Signale (etwa “Ansehen”, “Anklicken”, “In den Warenkorb legen”, “Kaufen”, “Auf die Wunschliste setzen”) existieren, siehe Abbildung 1. Daher ist nicht immer klar, wie eine Interaktion eines Nutzers mit einem Artikel interpretiert werden muss, d.h. ob sie positiv, negativ oder irrelevant war. Auch kann der zeitliche Kontext bei impliziten Signalen eine wichtige Rolle spielen und es müssen oft große Datenmengen verarbeitet werden, in denen auch ein gewisses Rauschen auftritt. In den vergangenen Jahren wurden viele Ansätze zur Nutzung von implizitem Feedback für Empfehlungssysteme in der Forschung vorgestellt und auch einige der klassischen Techniken für explizites Feedback wurden angepasst, um mit impliziten Signalen umgehen zu können.

## 1.3 Ziele

Dieser Artikel basiert auf der kumulativen Dissertation [Le16]. In dieser untersucht der Autor verschiedene offene Fragestellungen und Herausforderungen, die in der Forschung von implizitem Feedback für Empfehlungssysteme bisher noch nicht abgedeckt wurden. Die Dissertation ist in zwei Teile gegliedert.

Im ersten Teil werden vorhandene Forschungsarbeiten untersucht, die sich mit implizitem Feedback und Empfehlungssystemen, die diese Signale verarbeiten, befassen. Ein besonderer Schwerpunkt wird auf Arbeiten aus der Forschungsdomäne des *Social Information Access* gelegt, in der die Schwarmintelligenz in sozialen Netzwerken zur Erzeugung von Empfehlungen genutzt wird. Im Verlauf der Arbeit werden verschiedene Anwendungsszenarien für implizites Feedback diskutiert und eine Kategorisierung von verschiedenen Typen von Nutzerverhalten für implizites Feedback vorgenommen. Außerdem werden aktuelle algorithmische Ansätze für die Nutzung von implizitem Feedback vorgestellt, etwa um implizite Signale direkt für Empfehlungen zu interpretieren und weiterzuverarbeiten, oder um implizites Feedback zu explizitem Feedback zu konvertieren, sodass etablierte Empfehlungstechniken für explizite Signale angewendet werden können.

Der zweite Teil der Dissertation umfasst einige der Publikationen des Autors, welche sich ausgewählten Herausforderungen von Empfehlungen basierend auf implizitem Feedback widmen. Hierzu zählen (i) ein spezialisierter "learning-to-rank"-Algorithmus, der verschiedene Granularitäten von impliziten Signalen differenzieren kann, (ii) kontextualisierte Empfehlungstechniken für die E-Commerce-Domäne, welche Empfehlungen an die *kurzfristigen Ziele* (engl. short-term shopping goals) und langfristigen Nutzerinteressen anpassen können, und (iii) intelligente *Erinnerungen* (engl. reminders), deren Ziel die Wiederentdeckung von relevanten Produkten in der Shopping-Historie von Nutzern ist. Schließlich wird in einer weiteren Publikation, die in der Dissertation enthalten ist, eine tiefgreifende Analyse verschiedener Empfehlungsalgorithmen hinsichtlich Tendenzen bestimmte Artikel zu empfehlen durchgeführt. Insbesondere das sogenannte *Popularitätsbias* (engl. popularity bias), also die Tendenz zumeist populäre Artikel vorzuschlagen, kann in praktischen Einsatzszenarien problematisch sein und es werden Gegenmaßnahmen vorgestellt, die dieser Tendenz entgegenwirken können.

Diese Arbeit fasst die Erkenntnisse der kumulativen Dissertation [Le16] zusammen. Sie enthält einen Überblick über Empfehlungen basierend auf implizitem Feedback (Kapitel 2), betrachtet E-Commerce-Empfehlungssysteme (Kapitel 3) und diskutierte die Evaluations- und spezielle Bias von Empfehlungssystemen (Kapitel 4).

## **2 Empfehlungen basierend auf implizitem Feedback**

Wie in der Einleitung bereits erwähnt, führt die Nutzung von implizitem Feedback für Empfehlungssysteme zu neuen Herausforderungen. Insbesondere in der Forschungsdomäne des *Social Information Access*, die sich auf die Informationsgewinnung mithilfe der "Schwarmintelligenz" des *Social Web* fokussiert [Br08], sind Empfehlungssysteme zu wichtigen Werkzeugen geworden. In dieser Domäne ist explizites Feedback, etwa Bewertungen, eher spärlich vorhanden verglichen mit der Menge an impliziten Signalen, die auf Nutzerinteraktionen wie dem Browsen, Teilen, Taggen und Kommentieren in sozialen Netzwerken basieren.

Dieser Teil der Arbeit basiert auf einem Kapitel [JLZ17] des Buches *Social Information Access* [BH17], an dem der Autor mitgewirkt hat. Es führt in die Thematik und Unterscheidung des expliziten und impliziten Feedbacks ein und zeigt, dass die beiden Arten von

Signalen sich oftmals nicht eindeutig trennen lassen. Vielmehr gibt es verschiedene Abstufungen, etwa, wenn sich aus explizitem Feedback auch implizite Präferenzen ableiten lassen. Ebenfalls wird eine historische Kategorisierung verschiedener Typen von implizitem Feedback aus der Literatur aufgegriffen und Herausforderungen bei der Nutzung von impliziten Signalen für Empfehlungen diskutiert, beispielsweise die schon erwähnte Ambiguität der impliziten Signale. Das Kapitel gibt weiterhin eine Literaturübersicht über aktuelle Forschungsergebnisse zu implizitem Feedback und betrachtet im Kontext von aktuellen Trends einzelne Domänen, in denen implizite Signale präsent sind, etwa soziale Netzwerke, neue E-Commerce-Entwicklungen und allgegenwärtige digitale Services, sowie mobile Geräte. Die vorher aufgegriffene Kategorisierung von implizitem Feedback wird anhand der neuen Erkenntnisse erweitert, um den technologischen Fortschritt der letzten Jahre adäquat abzubilden. Im Anschluss werden aktuelle algorithmische Ansätze vorgestellt, die zur Erzeugung von Empfehlungen aus implizitem Feedback eingesetzt werden können. Neben grundlegenden Techniken um implizites zu explizitem Feedback zu konvertieren, werden auch Ansätze des *Association Rule Mining* und spezialisierte *one-class* Algorithmen des kollaborativen Filterns aus der aktuellen Literatur diskutiert. Schließlich befasst sich das Kapitel mit hybriden Ansätzen, die explizite und implizite Signale intelligent kombinieren können.

In diesem Zusammenhang wird der BPR+ Algorithmus vertieft, den der Autor erstmals in [LJ14] als Erweiterung des bekannten *Bayesian Personalized Ranking* Algorithmus (BPR) [Re09] vorstellte. BPR ist ein im Kontext von Empfehlungssystemen sehr bekannter Ansatz zur Nutzung von unserem impliziten Feedback bei der Erzeugung von Empfehlungen. Dies sind implizite Signale, die nur anzeigen, ob ein Nutzer mit einem Artikel interagiert hat oder nicht. Die neue Erweiterung BPR+ unterstützt im Vergleich zu BPR sogenanntes *abgestuftes* implizites Feedback (engl. *graded implicit feedback*). Somit können im Algorithmus implizite Signale verschiedener Stärken unterschieden werden, etwa, wenn Nutzerinteraktionen häufiger oder zeitnaher aufgetreten sind. Durch diese genauere Interpretation des impliziten Feedbacks und den dadurch gewonnenen Informationen ermöglicht es BPR+ Empfehlungen zu erzeugen, die deutlich genauer sind als die Vorschläge von BPR.

### 3 E-Commerce-Empfehlungssysteme

E-Commerce ist eine typische Anwendungsdomäne, in der implizites Feedback anzutreffen ist. Mit dem Aufkommen des Online-Handels fingen Unternehmen an, Empfehlungssysteme einzusetzen, um das Einkaufserlebnis für ihre Kunden zu personalisieren ähnlich einer persönlichen Beratung im Ladenlokal. Welche Artikel in der Praxis empfohlen (oder beworben) werden sollen hängt stark vom jeweiligen Geschäftsziel des Unternehmens ab [Sa13, Sa14]. Ein Empfehlungssystem könnte beispielsweise dazu dienen, besonders neue Artikel hervorzuheben oder Artikel aus bestimmten Produktkategorien [Di08] zu präsentieren. Ebenfalls könnte es dazu eingesetzt werden, möglichst die Dinge zu empfehlen, die sehr homogen zu den jeweiligen Nutzerinteressen passen [JLJ15] oder den Nutzer an Produkte erinnern, die er vor kurzem betrachtet hat [LJL16]. Diese letzten beiden Publikationen sind auch ein Teil der kumulativen Dissertation des Autors und werden im Folgenden kurz vertieft.

### 3.1 Empfehlungen für kurzfristige Ziele

In [JLJ15] werden hybride Strategien für E-Commerce-Empfehlungssysteme vorgestellt, welche Empfehlungen an den aktuellen Kontext des Nutzers anpassen, beispielsweise anhand seiner Navigationshistorie im Online-Shop. Dahinter steht die Annahme, dass Kunden zwar generelle Präferenzen hinsichtlich bestimmter Produkte, Marken oder Produktcharakteristika haben, aber trotzdem oftmals ein *kurzfristiges Ziel* im Sinn haben, wenn sie den Online-Shop besuchen. Dies geschieht durch die Kombination gewisser Basisalgorithmen, die die langfristigen Interessen der Nutzer modellieren, mit *kurzfristigen* Modellen, die die aktuellen Ziele der Einkaufs-Session des Nutzers erkennen. Die in der Publikation vorgestellten Techniken werden auf zwei Datensätzen aus echten E-Commerce-Umgebungen evaluiert, wobei ein neuartiges Evaluationsverfahren genutzt wird, um die zeitlichen Aspekte des Empfehlungsprozesses zu simulieren. Die Ergebnisse zeigen, dass die Wahl des langfristig agierenden Basisalgorithmus besonders am Anfang von neuen Einkaufs-Sessions wichtig ist. Außerdem weisen die untersuchten neuheits- und inhaltsbasierten kurzfristigen Modelle eine hohe Vorhersagegenauigkeit in den untersuchten Domänen auf und können zuverlässig das aktuelle Ziel der Nutzer erkennen.

### 3.2 Erinnerungen als Empfehlungen

Die zweite Publikation [LJL16] führt die Arbeit aus dem vorher diskutierten Werk [JLJ15] fort und erhielt den *James Chen Best Student Paper Award* der Konferenz *UMAP 2016*. Die Konferenzserie *User Modeling, Adaptation and Personalization*<sup>2</sup> zählt zu den führenden internationalen Veranstaltungen im Bereich der Personalisierung.

Der Artikel thematisiert *Erinnerungen* als Empfehlungen in der E-Commerce-Domäne. Klassischerweise schlagen Empfehlungssysteme in Forschungsszenarien immer nur Artikel vor, die einem Nutzer noch unbekannt sind. In der Praxis ist dies allerdings nicht in jedem Fall die sinnvollste Vorgehensweise. Die intelligenten Erinnerungen (*Erinnerungsempfehlungen*), die in dieser Publikation thematisiert werden, haben daher nicht das Ziel, dem Nutzer neue Bereiche des Produktspektrums nahezulegen, sondern sollen bewusst schon bekannte, aber nun wieder relevante Artikel vorschlagen. Im Vergleich zu den schon in [JLJ15] gezeigten Erinnerungsstrategien, werden nun komplexere Techniken vorgeschlagen, die etwa die Ähnlichkeit zwischen Artikeln und Sessions in der Historie des Nutzers auswerten oder die Intensität der Interaktion von Nutzern mit Artikeln bewerten. Außerdem wird das in der vorangegangenen Arbeit vorgestellte Evaluationsverfahren erweitert, um die Anzahl der offensichtlichen Erinnerungsempfehlungen zu modellieren und variieren zu können. Die Ergebnisse zeigen, dass sich Erinnerungsempfehlungen in einem Offline-Evaluationsszenario gut eignen, um Käufe der Nutzer vorherzusagen. Normalerweise ist es schwierig den tatsächlichen Nutzen von Empfehlungen und speziell Erinnerungen in der Praxis zu messen. Durch den Einsatz einer Feldstudie und die Untersuchung der Transaktionslogs zweier E-Commerce-Plattformen konnte jedoch gezeigt

---

<sup>2</sup> <http://www.um.org/umap2016>

werden, dass auch in der Praxis solche Erinnerungsempfehlungen durchaus von großem wirtschaftlichen Nutzen sind.

## 4 Evaluation und Bias von Empfehlungsalgorithmen

Der wirtschaftliche Erfolg in der E-Commerce-Domäne wird normalerweise mit bestimmten Geschäftsmetriken quantifiziert, etwa die Einnahmen oder die Click-Through-Rate (CTR). In der Forschung allerdings werden solche Metriken häufig nicht angewendet und der Fokus liegt eher auf Offline-Experimenten und der Optimierung der Vorhersagegenauigkeit der eingesetzten Modelle. Auf der ACM RecSys Konferenz, einer wichtigen Konferenz im Forschungsbereich Empfehlungssysteme, haben beispielsweise 85% der 63 publizierten *full papers* aus 2014 und 2015 ausschließlich Offline-Experimente eingesetzt [JA16a]. Nur fünf Arbeiten haben Nutzerstudien mit echten Probanden oder Experimenten auf *crowd-sourcing*-Plattformen durchgeführt und gerade einmal drei Publikationen nutzen einen A/B-Test in einer echten Live-Umgebung. Dieser Fokus auf die Optimierung der Vorhersagegenauigkeit in Offline-Szenarien ist dadurch begründet, dass das Forschungsfeld der Empfehlungssysteme ursprünglich aus dem Bereich des *Information Retrieval* hervorging [He04].

### 4.1 Nachteile der Offline-Evaluation

Obwohl die Vorhersagegenauigkeit eines Algorithmus ein Indikator für seine Leistung in der Praxis sein kann [GUH15], zeigt sie jedoch eigentlich nur, wie gut der Algorithmus die versteckten Signale oder Bewertungen in einem statischen Datensatz vorhersagen sagen kann. Dies entspricht allerdings nur dem “Status Quo” der Daten zum Zeitpunkt ihrer Aufnahme in den Datensatz und somit oftmals nicht der Realität [Zh10, CKT10, St11, Ja16b]. Des Weiteren kann die Relevanz von neuen Artikeln nicht beurteilt werden, da sie dem System zur Zeit der Erstellung des Datensatzes noch nicht bekannt waren. Eine weitere Einschränkung tritt in sehr popularitäts- oder neuheitsorientierten Domänen auf, etwa bei Filmen, Nachrichten oder blog-ähnlichen Webseiten: Algorithmen, die eher populäre oder neue Artikel vorschlagen, weisen hier eine sehr hohe Vorhersagegenauigkeit auf, da sie die Trends in den Ausgangsdaten direkt nachbilden. In der Praxis kann dies allerdings nicht erwünscht sein. Im Folgenden wird genau diese Eigenschaft genauer diskutiert.

### 4.2 Das Popularitätsbias und mögliche Gegenmaßnahmen

Das *Popularitätsbias* und mögliche Gegenmaßnahmen wurden in [Ja15] untersucht, einer der Publikationen der kumulativen Dissertation des Autors. Der Artikel wurde mit dem *2015 James Chen Award for UMUAI Best Paper* im renommierten Journal *User Modeling and User-Adapted Interaction*<sup>3</sup> ausgezeichnet.

<sup>3</sup> <http://www.umuai.org>

Der Text umfasst eine multidimensionale Evaluation von bekannten und populären Empfehlungsalgorithmen aus der Forschung hinsichtlich verschiedener Eigenschaften, etwa ihrer Genauigkeit, Katalogabdeckung oder Tendenz, populäre Artikel zu empfehlen (Popularitätsbias). Die Untersuchungen zeigen unter anderem, dass die gemessene Empfehlungsgenauigkeit vieler Empfehlungsstrategien ähnlich ist, die eigentlich vorgeschlagenen Artikel sich aber stark voneinander unterscheiden. Weitere durchgeführte Simulationen und Parametervariationen zeigen außerdem, dass viele der sehr akkuraten Algorithmen eine starke Tendenz haben, vor allem populäre Artikel vorzuschlagen. Da dieses Bias in der Praxis unerwünscht sein kann, stellt die Publikation zwei neuartige Techniken vor, die als Gegenmaßnahmen gegen das Popularitätsbias dienen. Einer dieser Ansätze ist eine Erweiterung des BPR-Algorithmus, der schon in Kapitel 2 angesprochen wurde, und ermöglicht die Reduzierung des Popularitätsbias bei nur kleinen Einbußen in der ursprünglichen Vorhersagegenauigkeit des Algorithmus.

## 5 Zusammenfassung

Lange Zeit fokussierte sich die Forschung im Bereich Empfehlungssystem vor allem auf explizites Feedback. Dies lag vor allem an groß angelegten Wettbewerben wie dem *Netflix Prize*<sup>4</sup> und den dadurch frei verfügbaren Datensätzen mit Nutzerbewertungen. Allerdings ignorierten diese Forschungsarbeiten einige Probleme, die in der Praxis auftreten können. Mit der Verbreitung von sozialen Netzwerken und E-Commerce hat sich dieser Trend in den letzten Jahren teilweise gewendet und der Forschungsfokus verschob sich in Richtung der Herausforderungen von praxisnahen Systemen, für die implizite Signale allgegenwärtig sind. Nach Konstan und Riedl [KR12] gilt es, hier in der Zukunft vor allem die folgenden drei Herausforderungen anzugehen: *Skalierbarkeit*, die bessere *Nutzung von nutzergenerierten Inhalten* und schließlich die Optimierung der *Forschungsinfrastruktur*. Vor allem der letzte Aspekt ist essenziell, denn die Probleme der Evaluation und Vergleichbarkeit von Forschungsergebnissen bestehen weiterhin, wie in Kapitel 4 angesprochen.

Zusammenfassend ist festzuhalten, dass die Forschung im Bereich Empfehlungssysteme und speziell für implizites Feedback viele Fortschritte gemacht hat, aber noch lange nicht am Ziel angekommen ist. Die Dissertation [Le16] hilft hierbei, einige der offenen Herausforderungen und Probleme anzugehen und zu lösen.

## Literaturverzeichnis

- [BH17] Brusilovsky, Peter; He, Daqing: Social Information Access, Jgg. 10100 in LNCS. Springer, Heidelberg, 2017.
- [Br08] Brusilovsky, Peter: Social information access: the other side of the social web. In: International Conference on Current Trends in Theory and Practice of Computer Science. Springer, S. 5–22, 2008.

---

<sup>4</sup> <http://www.netflixprize.com>

- [CKT10] Cremonesi, Paolo; Koren, Yehuda; Turrin, Roberto: Performance of Recommender Algorithms on Top-n Recommendation Tasks. In: Proceedings of the 2010 ACM Conference on Recommender Systems. RecSys '10, S. 39–46, 2010.
- [Di08] Dias, M. Benjamin; Locher, Dominique; Li, Ming; El-Deredy, Wael; Lisboa, Paulo J.G.: The Value of Personalised Recommender Systems to E-business: A Case Study. In: Proceedings of the 2008 ACM Conference on Recommender Systems. RecSys '08, S. 291–294, 2008.
- [GUH15] Gomez-Uribe, Carlos A; Hunt, Neil: The Netflix Recommender System: Algorithms, Business Value, and Innovation. *ACM Transactions on Management Information Systems (TMIS)*, 6(4):13, 2015.
- [He04] Herlocker, Jonathan L.; Konstan, Joseph A.; Terveen, Loren G.; Riedl, John T.: Evaluating Collaborative Filtering Recommender Systems. *ACM Transactions on Information Systems*, 22(1):5–53, Januar 2004.
- [Ja11] Jannach, Dietmar; Zanker, Markus; Felfernig, Alexander; Friedrich, Gerhard: *Recommender Systems – An Introduction*. Cambridge University Press, 2011.
- [Ja15] Jannach, Dietmar; Lerche, Lukas; Kamehkhosh, Iman; Jugovac, Michael: What Recommenders Recommend: An Analysis of Recommendation Biases and Possible Countermeasures. *User Modeling and User-Adapted Interaction*, 25(5):427–491, Dezember 2015.
- [JA16a] Jannach, Dietmar; Adomavicius, Gediminas: Recommendations With A Purpose. In: *Rec-Sys 2016*. 2016.
- [Ja16b] Jannach, Dietmar; Resnick, Paul; Tuzhilin, Alexander; Zanker, Markus: *Recommender Systems – Beyond Matrix Completion*. Communications of the ACM, 2016.
- [JH09] Jannach, Dietmar; Hegelich, Kolja: A Case study on the Effectiveness of Recommendations in the Mobile Internet. In: Proceedings of the 2009 ACM Conference on Recommender Systems. RecSys '09, S. 205–208, 2009.
- [JKG12] Jannach, Dietmar; Karakaya, Zeynep; Gedikli, Fatih: Accuracy Improvements for Multi-criteria Recommender Systems. In: Proceedings of the 13th ACM Conference on Electronic Commerce. EC '12, S. 674–689, 2012.
- [JLJ15] Jannach, Dietmar; Lerche, Lukas; Jugovac, Michael: Adaptation and Evaluation of Recommendations for Short-term Shopping Goals. In: Proceedings of the 2015 ACM Conference on Recommender Systems. RecSys '15. ACM, S. 211–218, 2015.
- [JLZ17] Jannach, Dietmar; Lerche, Lukas; Zanker, Markus: Recommending Based on Implicit Feedback. In (Brusilovsky, Peter; He, Daqing, Hrsg.): *Social Information Access*, Jgg. 10100 in LNCS. Springer, Heidelberg, Kapitel 14, 2017.
- [JWK14] Jawaheer, Gawesh; Weller, Peter; Kostkova, Patty: Modeling User Preferences in Recommender Systems: A Classification Framework for Explicit and Implicit User Feedback. *ACM Transactions on Interactive Intelligent Systems*, 4(2):8:1–8:26, 2014.
- [KR12] Konstan, Joseph A.; Riedl, John: Recommender Systems: From Algorithms to User Experience. *User Modeling and User-Adapted Interaction*, 22(1-2):101–123, 2012.
- [Le16] Lerche, Lukas: *Using Implicit Feedback for Recommender Systems: Characteristics, Applications, and Challenges*. Dissertation, TU Dortmund University, 2016.

- [LJ14] Lerche, Lukas; Jannach, Dietmar: Using Graded Implicit Feedback for Bayesian Personalized Ranking. In: Proceedings of the 2014 ACM Conference on Recommender Systems. RecSys '14, S. 353–356, 2014.
- [LJL16] Lerche, Lukas; Jannach, Dietmar; Ludewig, Malte: On the Value of Reminders within E-Commerce Recommendations. In: Proceedings of the 24th International Conference on User Modeling, Adaptation and Personalization. UMAP '16. ACM, 2016.
- [Re09] Rendle, Steffen; Freudenthaler, Christoph; Gantner, Zeno; Schmidt-Thieme, Lars: BPR: Bayesian Personalized Ranking from Implicit Feedback. In: Proceedings of the Twenty-Fifth Conference on Uncertainty in Artificial Intelligence. UAI '09, S. 452–461, 2009.
- [Ri11] Ricci, F.; Rokach, L.; Shapira, B.; Kantor, P. B.: Recommender Systems Handbook. Springer, 2011.
- [Sa13] Said, Alan; Lin, Jimmy; Bellogín, Alejandro; de Vries, Arjen: A Month in the Life of a Production News Recommender System. In: Proceedings of the 2013 Workshop on Living Labs for Information Retrieval Evaluation. LivingLab '13, ACM, New York, NY, USA, S. 7–10, 2013.
- [Sa14] Said, Alan; Bellogín, Alejandro; Lin, Jimmy; de Vries, Arjen: Do Recommendations Matter?: News Recommendation in Real Life. In: Proceedings of the Companion Publication of the 17th ACM Conference on Computer Supported Cooperative Work & Social Computing. CSCW Companion '14, ACM, New York, NY, USA, S. 237–240, 2014.
- [St11] Steck, Harald: Item Popularity and Recommendation Accuracy. In: Proceedings of the 2011 ACM Conference on Recommender Systems. RecSys '11, S. 125–132, 2011.
- [Zh10] Zheng, Hua; Wang, Dong; Zhang, Qi; Li, Hang; Yang, Tinghao: Do Clicks Measure Recommendation Relevancy?: An Empirical User Study. In: Proceedings of the Fourth ACM Conference on Recommender Systems. RecSys '10, ACM, New York, NY, USA, S. 249–252, 2010.



**Lukas Lerche** erlangte 2008 sein Abitur an der *Leibniz-Gymnasium – Dortmund International School* und wurde im gleichen Jahr als einer der besten Schulabsolventen NRWs geehrt. Im Anschluss studierte er Angewandte Informatik mit Schwerpunkt Dienstleistungsinformatik an der *TU Dortmund*. Nebenbei arbeitete er als MCPD- und MCTS-zertifizierter Softwareentwickler bei der *MATERNA GmbH* im Bereich Dokumentenmanagement und verfasste auch zu diesem Thema 2011 seine Bachelorarbeit. Seine Masterarbeit, die sich mit hybriden Empfehlungssystemen beschäftigt, entstand 2012 am *Lehrstuhl XIII der Fakultät Informatik der TU Dortmund*. Im Anschluss arbeitete Lukas an diesem Lehrstuhl unter Prof. Dr. Dietmar Jannach als wissenschaftlicher Mitarbeiter und vertiefte seine Forschung im Bereich Empfehlungssysteme. Nebenbei sammelte er Erfahrung in Forschung und Lehre, unter anderem durch die Entwicklung von wissenschaftlichen Softwaresystemen, einige Veröffentlichungen und Vorträge auf internationalen Konferenzen, und die Konzeption von Workshops und Lehrveranstaltungen. Er promovierte 2016 mit Auszeichnung zu den Themen *Implicit Feedback Recommendations*, *Learning-to-Rank* und *E-Commerce*. Seit 2016 arbeitet Lukas als IT-Projektleiter, Data Scientist und Fachreferent an der *UB Dortmund*.