

Map-based Visualization of Item Spaces for Increasing Transparency and Control in Recommender Systems

Kartenbasierte Produktraumdarstellung zur Erhöhung von Transparenz und Steuerbarkeit in Empfehlungssystemen

Johannes Kunkel

Universität Duisburg-Essen
Duisburg, Deutschland
johannes.kunkel@uni-due.de

Tamara Feldkamp

Universität Duisburg-Essen
Duisburg, Deutschland
tamara.feldkamp@stud.uni-due.de

Jürgen Ziegler

Universität Duisburg-Essen
Duisburg, Deutschland
juergen.ziegler@uni-due.de

Zusammenfassung

English – Recommender systems (RS) are very common tools designed to help users choose items from a large number of alternatives. While their algorithms are already quite mature in terms of precision, RS cannot unfold their full potential due to a lack of transparency and missing means of control. In this paper we introduce a method aiming at creating recommendations that are comprehensible and controllable by their users while granting an overview over the item domain. To achieve this, the entire item space of a domain is visualized using a map-like interface. Inside, users can express their preferences on which the RS reacts with matching recommendations. To change recommendations, users can alter their preferences expressed, which creates a continuous feedback loop between user and RS. We demonstrate our general method using two prototype applications, located in different item domains and utilizing different forms of visualization and interaction modalities. Empirical user studies with both prototypes show a great potential of our method to increase overview, transparency and control in RS.

Deutsch – Empfehlungssysteme (ES) werden häufig eingesetzt, um Nutzer bei der Auswahl eines Produkts aus vielen Alternativen zu unterstützen. Während Empfehlungsalgorithmen hinsichtlich ihrer Präzision bereits sehr ausgereift

sind, verhindern mangelnde Transparenz der Empfehlungen und fehlende Interaktionsmöglichkeiten, dass ES ihr volles Potential entfalten. In diesem Beitrag stellen wir eine Methode vor, die einerseits auf verständlichere Empfehlungen und mehr Kontrolle durch den Nutzern abzielt, andererseits aber auch dessen Übersicht über die Produktdomäne adressiert. Dabei dient eine Verteilung aller Produkte auf einer zweidimensionalen Fläche als Basis. Innerhalb können Nutzer ihre Präferenzen ausdrücken, woraufhin das ES mit passenden Empfehlungen reagiert. Um die Empfehlungen zu verändern, können Nutzer ihre Präferenzen anpassen, was in einem kontinuierlichen Feedback-Zyklus zwischen Nutzer und ES resultiert. Die Methode wird zudem an zwei Prototypen demonstriert, welche sie in verschiedenen Produktdomänen und mit unterschiedlichen Formen der Visualisierung und Interaktion umsetzen. Empirische Nutzerstudien zu den Prototypen versprechen ein hohes Potential des Ansatzes Übersicht, Transparenz und Kontrolle in ES zu verbessern.

Keywords

Empfehlungssysteme, Nutzerkontrolle, Transparenz, Filterblasen

ACM Reference Format:

Johannes Kunkel, Tamara Feldkamp, and Jürgen Ziegler. 2019. Map-based Visualization of Item Spaces for Increasing Transparency and Control in Recommender Systems. In *Mensch und Computer 2019 (MuC '19), September 8–11, 2019, Hamburg, Germany*. ACM, New York, NY, USA, 6 pages. <https://doi.org/10.1145/3340764.3344893>

1 Einleitung

Empfehlungssysteme (ES) sind vielfach im Internet eingesetzte Werkzeuge, um automatisch Inhalte wie Nachrichten, Musik und Videos gemäß den Bedürfnisse ihrer Nutzer zu filtern. Die zur Generierung von Empfehlungen verwendeten Algorithmen sind bereits sehr präzise, werden jedoch häufig

Permission to make digital or hard copies of all or part of this work for personal or classroom use is granted without fee provided that copies are not made or distributed for profit or commercial advantage and that copies bear this notice and the full citation on the first page. Copyrights for components of this work owned by others than ACM must be honored. Abstracting with credit is permitted. To copy otherwise, or republish, to post on servers or to redistribute to lists, requires prior specific permission and/or a fee. Request permissions from permissions@acm.org.

MuC '19, September 8–11, 2019, Hamburg, Germany

© 2019 Association for Computing Machinery.

ACM ISBN 978-1-4503-7198-8/19/09...\$15.00

<https://doi.org/10.1145/3340764.3344893>

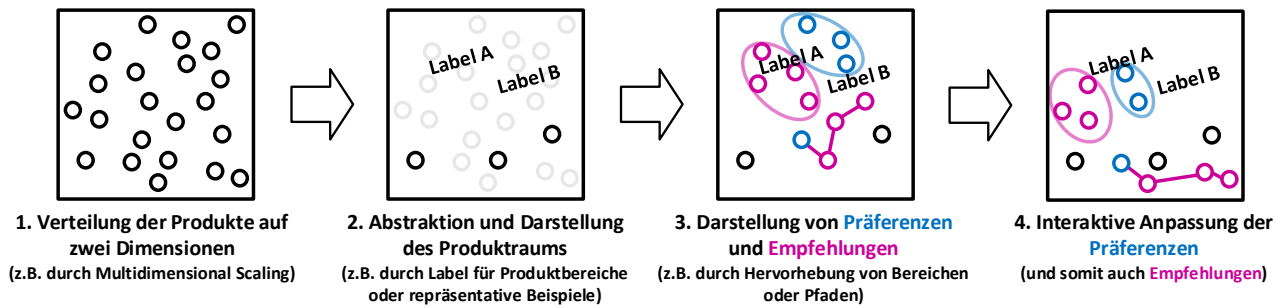


Abbildung 1: Die vier Schritte der hier vorgestellten Methode. Nachdem alle Produkte auf zwei Dimensionen verteilt wurden (1), erfolgt die Darstellung der resultierenden Karte durch Abstraktion von Bereichen (2). Nutzerpräferenzen und Empfehlungen können anschließend direkt in der Karte visualisiert (3) und durch den Nutzer interaktiv angepasst werden (4).

von ihren Nutzern als intransparent wahrgenommen und es mangelt an Interaktionsmöglichkeiten [7, 11, 13].

Bevor personalisierte Empfehlungen für einen bislang unbekanntem Nutzer generiert werden können, müssen dessen Präferenzen bezüglich der Produktdomäne erhoben werden. Einer der geläufigsten Ansätze ist die Erhebung von Präferenzen auf Produktebene, z.B. in Form Bewertungsskalen, was jedoch umständlich und intransparent sein kann [13]. Um dem zu begegnen wurden effizientere Möglichkeiten der Präferenzangabe vorgestellt, welche z.B. auf dem Bewerten von Tags basieren [20, 30].

Erhobene Präferenzen werden häufig auch dazu eingesetzt, um die Transparenz der Empfehlungen zu erhöhen [11, 13]. Die textuellen Erklärungen, die von Amazon verwendet werden, basieren beispielsweise auf anhand von Käufen ermittelten Präferenzen der Kunden. Obwohl solche relativ einfach gehaltenen Erklärungen bereits einen positiven Effekt auf die wahrgenommene Transparenz haben können [29, 31], wurden sie als zu oberflächlich kritisiert [3, 16]. Dem gegenüber stehen Ansätze, die auf umfangreichen Visualisierungen basieren, um die Transparenz von Empfehlungen zu erhöhen. Solche Ansätze verwenden z.B. Graphen [6] oder Venn-Diagramme [24], um die Gründe für Empfehlungen zu veranschaulichen.

Ein Ziel von ES kann darin liegen, Nutzern einen Überblick über den Produktraum zu verschaffen und sie bei dessen Exploration zu unterstützen. Dies kann unter anderem das Vertrauen in die Entscheidung [12], das Bewusstsein von Alternativen [14] und die Kenntnis über die eigenen Präferenzen [26] adressieren. Wird der Produktraum dafür graphisch dargestellt, kann dies zudem die Transparenz steigern, indem Beziehungen zwischen Präferenzen und Empfehlungen visualisiert werden [10, 18]. Darüber hinaus kann es auch weitere Vorteile mit sich bringen, wenn Nutzer sich des Produktraums bewusst sind. So laufen Nutzer, welchen stets eine auf ihre Bedürfnisse zugeschnittene Teilmenge des gesamten

Produktraums präsentiert wird, Gefahr in eine *Filterblase* zu geraten [23]. Solche Filterblasen wurden unter anderem mit dem Erstarken von populistischen Bewegungen [9] und der Verbreitung von Verschwörungstheorien [8] in Verbindung gebracht.

Obwohl es bereits Lösungen gibt, die Transparenz, Kontrolle und Übersicht über die Produktdomäne adressieren, wurden diese Aspekte bislang noch nicht systematisch verbunden. Um dem zu begegnen, stellen wir in diesem Beitrag eine Methode vor, die Nutzerpräferenzen zusammen mit den vom ES generierten Empfehlungen in einer zweidimensionalen Visualisierung des gesamten Produktraumes darstellt. Die Methode wurde mit Hilfe von zwei Prototypen exemplarisch umgesetzt: *MovieLandscape* [17, 18] und *MusicPaths*. Ergebnisse von Nutzerstudien mit beiden Anwendungen zeigen, dass die hier vorgestellte Methode zu einem hohen Maß an Übersicht, Transparenz und Kontrollierbarkeit der Empfehlungen führen kann.

2 Kartenbasierte Produktraumdarstellung

Unsere hier vorgestellte Methode setzt sich aus vier Schritten zusammen, die generell von Produktomäne und der konkreten Visualisierung unabhängig sind (Abbildung 1):

- (1) Verteilung aller Produkte auf zwei Dimensionen
- (2) Abstraktion und Darstellung des Produktraums als zweidimensionale Karte
- (3) Visualisierung der Präferenzen des Nutzers und dessen Empfehlungen innerhalb der Karte
- (4) Interaktive Anpassung der Präferenzen durch den Nutzer und Neuberechnung der Empfehlungen

Diese Schritte werden nachfolgend einzeln beschrieben und deren Umsetzung jeweils anhand der zwei Prototypen *MovieLandscape* und *MusicPaths* veranschaulicht.



Abbildung 2: *MovieLandscape* [17, 18] mit Darstellung des Produktraums (1), welcher durch repräsentative Filme abstrahiert wurde (2); Nutzerpräferenzen als Geländeerhöhungen und Empfehlungen mit magenta-farbenen Rahmen (3); und einer Palette (4) mit Werkzeugen, um die Höhenstruktur der Landschaft zu verändern.

(1) Verteilung der Produkte auf zwei Dimensionen

Bevor die Darstellung des Produktraums als zweidimensionale Karte erfolgen kann, müssen alle Produkte sinnvoll auf zwei Dimensionen¹ verteilt werden. Dieser Schritt hängt stark von den zur Verfügung stehenden Daten zu den Produkten ab. Zur Veranschaulichung verwenden die implementierten Prototypen grundlegend verschiedene Datensätze aus unterschiedlichen Domänen. Die Anwendung *MovieLandscape* (Abbildung 2) verwendet einen Datensatz, welcher 27 000 Filme und 20 Millionen numerische Nutzerbewertungen enthält². Für die Darstellung als zweidimensionale Karte, werden alle Filme zunächst mittels *Matrix Factorization* [15] in einem latenten Faktorraum verteilt. Anschließend wird die Dimensionalität dieses multidimensionalen Raums mit Hilfe von *Multi Dimensional Scaling* [5] auf zwei Dimensionen reduziert. Somit kann die in dem Faktormodell inhärente, jedoch zunächst verborgene, Semantik [19, 21, 22] ausgenutzt werden, um die Filme sinnvoll zu positionieren. Im Gegensatz dazu, basiert *MusicPaths* (Abbildung 3) auf inhaltlichen Daten der Produkte. Grundlage bildet dabei ein Datensatz, der 630 000 Musiktitel enthält, welche der *Spotify Web API*³ entnommen wurden. Jeder Titel ist zudem mit zwei Stichworten zu emotionalen Stimmungen versehen. Diese stammen von der *Gracenote API*⁴. Alle Stimmungen können auf einem Kontinuum zwischen *Calm* und *Energetic* bzw. *Dark*

¹Wir beschränken uns auf zwei Dimensionen, da das Hinzufügen weiterer Dimensionen kaum Vorteile birgt, speziell wenn die Darstellung auf einem zweidimensionalen Bildschirm erfolgt [1, 27].

²<https://grouplens.org/datasets/movielens/20m/>

³<https://developer.spotify.com/documentation/web-api/>

⁴<http://www.gracenote.com/music/music-discovery/>



Abbildung 3: *MusicPaths* mit Darstellung des Produktraums als Insel (1); Abstraktion des Produktraums mit Hilfe von Labeln (2); einer empfohlenen Sequenz von Musikstücken (3), welche als Pfad auf der Karte dargestellt wird; und einem interaktiven Kompass (4), um die Richtung zu steuern, in der sich die automatische Playlist entwickelt.

und *Positive* verteilt werden. Diese Verteilung wird in *MusicPaths* direkt auf die X- und Y-Achse der Ebene übertragen, wodurch sich eine Verteilung ergibt, die von eher dunklen aber ruhigen Musiktiteln im Südwesten der Karte bis zu sehr energiegeladenen und positiven Stücken in ihrem Nordosten reicht.

(2) Abstraktion und Darstellung des Produktraums

Da die gesamte Produktdomäne in aller Regel zu groß ist, um direkt übersichtlich dargestellt werden zu können, muss eine Abstraktion gewählt werden, die die Anordnung der Produkte adäquat vermittelt. In *MusicPaths* ist die Karte in Bereiche gegliedert, welche gemäß den Stimmungen, der an dieser Stelle liegenden Musikstücke, benannt sind (Abbildung 3, (2)). In *MovieLandscape* hingegen ist aufgrund der gewählten Verteilung eine solche inhaltliche Abstraktion nicht möglich. Stattdessen werden mit einem Cluster-Verfahren (*k-means*) Gruppen ähnlicher Filme identifiziert und anschließend für jedes Cluster ein populärer Film aus dessen Zentrum als Repräsentant angezeigt (Abbildung 2, (2)).

(3) Darstellung von Präferenzen und Empfehlungen

Sowohl Hintergrunddaten als auch Darstellung des Produktraums geben vor wie Nutzerpräferenzen und Empfehlungen dargestellt werden können. So wird z.B. Musik in der Regel als Sequenz konsumiert, was eine Pfadmetapher nahe legt. Dieser Metapher folgend, wird in *MusicPaths* die aktuelle Nutzerpräferenz als Punkt innerhalb der Karte repräsentiert, während die Sequenz der empfohlenen Playlist, als Pfad dargestellt wird (Abbildung 3, (3)). Diese Metapher passt zudem

Tabelle 1: Deskriptive Evaluationsergebnisse der beiden Prototypen. Die hier dargestellten Konstrukte stammen aus [25]. Alle Items verwendeten eine 5-stufige Likert-Skala.

	<i>MovieLandscape</i>		<i>MusicPaths</i>	
	<i>M</i>	<i>SD</i>	<i>M</i>	<i>SD</i>
Overall satisfaction	3,94	0,76	3,27	1,05
Transparency	3,91	1,09	3,30	0,95
Interaction adequacy	3,47	0,88	3,01	0,83

gut zu der verwendeten Verteilung basierend auf Stimmungen: Beginnend in einer aktuellen Stimmung, legt ein Pfad fest zu welcher Stimmung die Playlist verläuft. Nutzer sind somit eingeladen, ausgehend von einer aktuellen Stimmung die Musikkarte und die damit verbundenen Stimmungen zu erkunden. Dieses Szenario ist hingegen weniger für *MovieLandscape* geeignet. Präferenzen werden hier als Höhenzüge der dreidimensionalen Landschaft dargestellt, auf welchen die Empfehlungen als diskrete Landmarken zu sehen sind (Abbildung 2, (3)).

(4) Interaktive Anpassung der Präferenzen

Abhängig von der Darstellungsform von Präferenzen und Empfehlungen, müssen die interaktiven Elemente zur Steuerung des ES gewählt werden. Der zuvor gewählten Metapher des Wanderns über eine Karte mit Musik folgend, können Nutzer in *MusicPaths* die Richtung, in der sich das personalisierte Radio entwickeln soll, durch einen interaktiven Kompass bestimmen (Abbildung 3, (4)). Beim Klick auf eine der acht Himmelsrichtungen folgt, ausgehend vom aktuellen Standpunkt, die zukünftige Entwicklung der Playlist dieser Himmelsrichtung. In *MovieLandscape* hingegen findet die Nutzerinteraktion in Form von Veränderung der dreidimensionalen Landschaft statt. Mit einer virtuellen Schaufel, kann die Landschaft gemäß der eigenen Präferenzen gestaltet werden. Hügel und Täler, die virtuell aufgeschüttet bzw. ausgehoben werden, signalisieren Bereiche von großem bzw. geringem Interesse. Wie in *MusicPaths*, führt auch in *MovieLandscape* jede Veränderung der Präferenzen des Nutzers zu einer unmittelbaren Aktualisierung der dargestellten Empfehlungen.

3 Evaluation der Prototypen

Um die vorgestellten Prototypen und die dahinter liegende generelle Methode zu testen, wurden zwei voneinander getrennte Laborstudien für *MovieLandscape* ($N = 32$) und *MusicPaths* ($N = 30$) durchgeführt. In beiden Studien wurden Probanden gebeten mit Hilfe der Prototypen, initial ihre Präferenzen einzugeben, die resultierenden Empfehlungen zu bewerten, das Präferenzprofil zu verändern und erneut eine Bewertung der Empfehlungen abzugeben. Bei *MusicPaths*

sollten die empfohlenen Musikstücke konsumiert werden, bevor Empfehlungen evaluiert wurden. Schlussendlich sollten die Probanden noch den *ResQue*-Fragebogen [25] zu Transparenz, Kontrolle und genereller Zufriedenheit ausfüllen. Einige Ergebnisse befinden sich in Tabelle 1, weitere zu *MovieLandscape* in [17] und [18].

Diskussion

Insgesamt zeigen die Ergebnisse in Tabelle 1, dass Studienteilnehmer zufrieden mit den vorgestellten Ansätzen waren (*Overall satisfaction*), sie Kontrolle über den Empfehlungsprozess empfanden (*Interaction adequacy*) und dabei die Systeme als transparent hinsichtlich der Empfehlungen einschätzten (*Transparency*). Jedoch kann auch beobachtet werden, dass die deskriptiven Ergebnisse zu *MusicPaths* konsequent unter jenen für *MovieLandscape* liegen. Obwohl Probanden in der Studie zu *MusicPaths* mit hoher Zustimmung auf das von uns generierten Fragebogen-Item „Generell halte ich die Verwendung von Karten zur Orientierung in der Domäne Musik für sinnvoll.“ ($M = 3,83$, $SD = 0,95$) reagierten, wurde das ebenfalls eigens erstellte Item „Die dargestellte Karte hat mir geholfen einen Überblick über die Musik zu bekommen.“ hingegen niedriger bewertet ($M = 2,93$, $SD = 1,20$). Wir folgern daraus, dass unsere generelle Methode zwar von Probanden angenommen, diese in *MusicPaths* jedoch nicht ideal umgesetzt wurde (besonders Schritte 1 und 2, also Verteilung und Darstellung des Produktraums). Vermutlich mangelte es speziell an Möglichkeiten zur Interaktion mit der Produktraumdarstellung, was wir aus textuellen Kommentaren der Probanden entnehmen. So wünschten sie sich weitere Interaktionsmöglichkeiten zur freien Exploration der Musikkarte und konnten teilweise die Positionierung der Songs nicht nachvollziehen. Optionen zum Hinein- und Herauszoomen sowie zum Aufdecken von weiteren Produkten in freien Bereichen der Karte (wie sie in *MovieLandscape*, jedoch nicht in *MusicPaths* zur Verfügung standen), könnten hier potentiell eine Verbesserung bieten. Empfehlungen der Informationsvisualisierung, wie sie z.B. im *Information Seeking Mantra* [28] oder der *Grafischen Semiologie* nach Bertin [4] formuliert sind, sollten zudem explizit Berücksichtigung finden. Eventuell können die Ergebnisse der zwei Studien auch so interpretiert werden, dass die verständliche Darstellung von Musikdomänen generell schwieriger ist, als dies z.B. für Filme der Fall ist. Beispielsweise wurde kürzlich herausgefunden, dass Musiktitel im Gegensatz zu Filmen tatsächlich konsumiert werden müssen, bevor Nutzer deren Passung zu den eigenen Präferenzen einschätzen können [2]. Eine Darstellung der Produktraumkarte durch repräsentative Beispiele, wie in *MovieLandscape*, kann daher vermutlich schlecht auf die Domäne Musik übertragen werden, da zunächst alle Titel

angehört und anschließend kognitiv präsent gehalten werden müssten, um sie mental zu einer übersichtlichen Karte zusammenfügen zu können.

4 Fazit und Ausblick

Durch die hier vorgestellte Methode kann Nutzern von Empfehlungssystemen mit Hilfe einer Kartenmetapher ein intuitiver Überblick über den gesamten Produktraum vermittelt werden. Innerhalb können anschließend Präferenzen eingegeben und unmittelbar deren Auswirkung auf Empfehlungen nachvollzogen werden. Dies führt zu einem hohen Maß an empfundener Transparenz und Kontrolle gegenüber dem System, was anhand von Nutzerstudien mit zwei Prototypen nachgewiesen werden konnte. In den Nutzerstudien wurde ferner deutlich, dass der Verständlichkeit des Kartenlayouts eine zentrale Bedeutung zukommt. Produktraumkarten, welche verwirrend für die Nutzer erscheinen, wirken sich offenbar negativ auf die wahrgenommene Transparenz, Kontrollierbarkeit und die generelle Nutzbarkeit des Systems aus. Zukünftige Entwicklungen werden daher darauf abzielen Faktoren zu erfassen, welche die Verständlichkeit von Produktraumkarten verbessern. Wir planen außerdem Beziehungen zwischen den Phasen unserer Methode systematisch zu analysieren, um z.B. Abhängigkeiten zwischen der Struktur der Hintergrunddaten und einer optimalen Kartendarstellung aufzudecken.

Literatur

- [1] 2015. Blocked: When the information is hidden by the visualization. *Journal of the Association for Information Science and Technology* 67, 5 (2015), 1033–1051. <https://doi.org/10.1002/asi.23479>
- [2] 2018. Impact of Item Consumption on Assessment of Recommendations in User Studies. In *Proceedings of the 12th ACM Conference on Recommender Systems*. ACM, New York, NY, USA, 49–53. <https://doi.org/10.1145/3240323.3240375>
- [3] Shlomo Berkovsky, Ronnie Taib, und Dan Conway. 2017. How to Recommend?: User Trust Factors in Movie Recommender Systems. In *Proceedings of the 22nd International Conference on Intelligent User Interfaces (IUI '17)*. ACM, New York, NY, USA, 287–300. <https://doi.org/10.1145/3025171.3025209>
- [4] Jacques Bertin. 1983. *Semiology of Graphics*. University of Wisconsin Press.
- [5] Ingwer Borg und Patrick J. F. Groenen. 2005. *Modern Multidimensional Scaling: Theory and Applications* (2 ed.). Springer New York. <https://doi.org/10.1007/0-387-28981-X>
- [6] Svetlin Bostandjiev, John O'Donovan, und Tobias Höllerer. 2012. TasteWeights: A Visual Interactive Hybrid Recommender System. In *Proceedings of the Sixth ACM Conference on Recommender Systems (RecSys '12)*. ACM, New York, NY, USA, 35–42. <https://doi.org/10.1145/2365952.2365964>
- [7] André Calero Valdez, Martina Ziefle, und Katrien Verbert. 2016. HCI for Recommender Systems: The Past, the Present and the Future. In *Proceedings of the 10th ACM Conference on Recommender Systems (RecSys '16)*. ACM, New York, NY, USA, 123–126. <https://doi.org/10.1145/2959100.2959158>
- [8] Michela Del Vicario, Alessandro Bessi, Fabiana Zollo, Fabio Petroni, Antonio Scala, Guido Caldarelli, H. Eugene Stanley, und Walter Quattrociocchi. 2016. The spreading of misinformation online. *Proceedings of the National Academy of Sciences of the United States of America* 113, 3 (2016), 554–559. <https://doi.org/10.1073/pnas.1517441113>
- [9] Dominic DiFranzo und Kristine Gloria-Garcia. 2017. Filter Bubbles and Fake News. *XRDS* 23, 3 (2017), 32–35. <https://doi.org/10.1145/3055153>
- [10] Emden Gansner, Yifan Hu, Stephen Kobourov, und Chris Volinsky. 2009. Putting Recommendations on the Map - Visualizing Clusters and Relations. In *Proceedings of the Third ACM Conference on Recommender Systems (RecSys '09)*. ACM, New York, NY, USA, 345–348. <https://doi.org/10.1145/1639714.1639784>
- [11] Chen He, Denis Parra, und Katrien Verbert. 2016. Interactive recommender systems: A survey of the state of the art and future research challenges and opportunities. *Expert Systems with Applications* 56 (2016), 9–27. <https://doi.org/10.1016/j.eswa.2016.02.013>
- [12] Dietmar Jannach und Gediminas Adomavicius. 2016. Recommendations with a Purpose. In *Proceedings of the 10th ACM Conference on Recommender Systems (RecSys '16)*. ACM, New York, NY, USA, 7–10. <https://doi.org/10.1145/2959100.2959186>
- [13] Michael Jugovac und Dietmar Jannach. 2017. Interacting with Recommenders—Overview and Research Directions. *ACM Transactions on Interactive Intelligent Systems (TiiS)* 7, 3 (2017), 10:1–10:46. <https://doi.org/10.1145/3001837>
- [14] Mandy Keck und Dietrich Kammer. 2018. Exploring Visualization Challenges for Interactive Recommender Systems. In *VisBIA 2018*. <http://ceur-ws.org/Vol-2108/paper3.pdf>
- [15] Yehuda Koren, Robert M. Bell, und Chris Volinsky. 2009. Matrix Factorization Techniques for Recommender Systems. *IEEE Computer* 42, 8 (2009), 30–37. <https://doi.org/10.1109/MC.2009.263>
- [16] Johannes Kunkel, Tim Donkers, Lisa Michael, Catalin-Mihai Barbu, und Jürgen Ziegler. 2019. Let Me Explain: Impact of Personal and Impersonal Explanations on Trust in Recommender Systems. In *CHI Conference on Human Factors in Computing Systems Proceedings*. ACM, New York, NY, USA, to appear. <https://doi.org/10.1145/3290605.3300717>
- [17] Johannes Kunkel, Benedikt Loepp, und Jürgen Ziegler. 2015. 3D-Visualisierung zur Eingabe von Präferenzen in Empfehlungssystemen. In *Mensch und Computer 2015: Gemeinsam – Arbeit – Erleben*.
- [18] Johannes Kunkel, Benedikt Loepp, und Jürgen Ziegler. 2017. A 3D Item Space Visualization for Presenting and Manipulating User Preferences in Collaborative Filtering. In *Proceedings of the 22nd International Conference on Intelligent User Interfaces (IUI '17)*. ACM, New York, NY, USA, 3–15. <https://doi.org/10.1145/3025171.3025189>
- [19] Johannes Kunkel, Benedikt Loepp, und Jürgen Ziegler. 2018. Understanding Latent Factors Using a GWAP. In *Proceedings of the Late-Breaking Results track part of the Twelfth ACM Conference on Recommender Systems (RecSys'18)*. <https://arxiv.org/pdf/1808.10260.pdf>
- [20] Benedikt Loepp, Tim Donkers, Timm Kleemann, und Jürgen Ziegler. 2018. Interactive recommending with Tag-Enhanced Matrix Factorization (TagMF). *International Journal of Human-Computer Studies* (2018). <https://doi.org/10.1016/j.ijhcs.2018.05.002>
- [21] Benedikt Loepp, Tim Donkers, Timm Kleemann, und Jürgen Ziegler. 2019. Interactive recommending with Tag-Enhanced Matrix Factorization (TagMF). *International Journal of Human-Computer Studies* (2019), 21–41. Issue 121. <https://doi.org/10.1016/j.ijhcs.2018.05.002>
- [22] B. Németh, G. Takács, I. Pilászy, und D. Tikl. 2013. Visualization of movie features in collaborative filtering. In *2013 IEEE 12th International Conference on Intelligent Software Methodologies, Tools and Techniques (SoMeT)*. 229–233. <https://doi.org/10.1109/SoMeT.2013.6645674>
- [23] Eli Pariser. 2011. *The filter bubble: What the Internet is hiding from you*. Penguin UK.
- [24] Denis Parra und Peter Brusilovsky. 2015. User-controllable personalization: A case study with SetFusion. *International Journal of Human-Computer Studies* 78 (2015), 43–67. <https://doi.org/10.1016/j.ijhcs.2015>

01.007

- [25] Pearl Pu, Li Chen, and Rong Hu. 2011. A User-centric Evaluation Framework for Recommender Systems. In *Proceedings of the Fifth ACM Conference on Recommender Systems (RecSys '11)*. ACM, New York, NY, USA, 157–164. <https://doi.org/10.1145/2043932.2043962>
- [26] Neil Rubens, Mehdi Elahi, Masashi Sugiyama, and Dain Kaplan. 2015. Active Learning in Recommender Systems. In *Recommender Systems Handbook*, Francesco Ricci, Lior Rokach, and Bracha Shapira (Hrsg.). Springer US, Boston, MA, 809–846. https://doi.org/10.1007/978-1-4899-7637-6_24
- [27] M. Sedlmair, T. Munzner, and M. Tory. 2013. Empirical Guidance on Scatterplot and Dimension Reduction Technique Choices. *IEEE Transactions on Visualization and Computer Graphics* 19, 12 (2013), 2634–2643. <https://doi.org/10.1109/TVCG.2013.153>
- [28] Ben Shneiderman. 1996. The eyes have it: a task by data type taxonomy for information visualizations. In *Proceedings 1996 IEEE Symposium on Visual Languages*. Boulder, CO, USA, 336–343. <https://doi.org/10.1109/VL.1996.545307>
- [29] Nava Tintarev und Judith Masthoff. 2015. Explaining Recommendations: Design and Evaluation. In *Recommender Systems Handbook*, Francesco Ricci, Lior Rokach, und Bracha Shapira (Hrsg.). Springer US, Boston, MA, 353–382. https://doi.org/10.1007/978-1-4899-7637-6_10
- [30] Jesse Vig, Shilad Sen, und John Riedl. 2011. Navigating the Tag Genome. In *Proceedings of the 16th International Conference on Intelligent User Interfaces*. 93–102. <https://doi.org/10.1145/1943403.1943418>
- [31] Jingjing Zhang und Shawn P. Curley. 2018. Exploring Explanation Effects on Consumers' Trust in Online Recommender Agents. *International Journal of Human-Computer Interaction* 34, 5 (2018), 421–432. <https://doi.org/10.1080/10447318.2017.1357904>