



Hochschule für Angewandte Wissenschaften Hamburg  
*Hamburg University of Applied Sciences*

# **Ausarbeitung**

Max Bahne

Wer sagt mir, was ich will? - Die Grundlagen eines  
Recommendation Systems

# **Max Bahne**

## **Wer sagt mir, was ich will? - Die Grundlagen eines Recommendation Systems**

Ausarbeitung eingereicht im Rahmen des 2. Fachsemesters

im Studiengang Next Media  
am Department Informatik  
der Fakultät Technik und Informatik  
der Hochschule für Angewandte Wissenschaften Hamburg

Betreuender Prüfer : Kai von Luck

Abgegeben am 26.02.16

**Max Bahne**

**Thema der Ausarbeitung**

Die Grundlagen eines Recommendation Systems

**Stichworte**

Recommendation System, Mediathek, Datenbanken, Data Mining

**Kurzzusammenfassung**

Das immer größer werdende Angebot an Content im Netz erfordert einen Mechanismus, der dem Nutzer nur die für ihn relevanten Ergebnisse anzeigt. Die Grundlagen dieser Recommendation Systems sollen in dieser Arbeit näher erläutert werden.

**Max Bahne**

**Title of the paper**

The basics of Recommendation Systems

**Keywords**

Recommendation System, Libraries, Data Mining

**Abstract**

The modern web is full of different services and contents. It's a difficult task for the user to find only the important content. So he needs a system that helps him with his search. This work describes the basics of these systems called Recommendation Systems.

## **Inhaltsverzeichnis**

1. Einleitung .....	5
2. Aufbau eines Recommendation Systems.....	6
2.1 Representation of Input.....	9
2.2 Neighborhood Formation .....	9
3.1 Recommendation Generation .....	10
4. Vorteile eines Recommendation Systems .....	11
5. Probleme bei der Implementierung eines Recommendation Systems .....	12
6. Schluss und Ausblick .....	13
7. Literatur- und Abbildungsverzeichnis.....	14

## 1. Einleitung

Die Welt der Daten wächst unaufhaltsam. So bescheinigen diverse Studien der digitalen Datenmenge in der Zukunft ein nahezu exponentielles Wachstum<sup>1</sup>.

Zusammen mit der Anzahl der Daten steigt auch die Anzahl der Angebote im Internet. Ein exzellentes Beispiel dafür ist Amazon: Gestartet als Online-Buchhändler in den 1990er Jahren, erweiterte das Unternehmen sein Angebotsspektrum beständig: Von DVDs über Kleidung bis hin zu Lebensmitteln – mit einem breiten Angebot wandelte sich der kleine Online-Buchhändler zu einem weltweit agierenden Großunternehmen, das nach eigener Auskunft 2014 weltweit über 260 Millionen aktive Kunden gewinnen und beliefern konnte<sup>2</sup>.

Die steigende Anzahl an Angeboten im Web – egal ob es nun die Warenvielfalt auf Amazon, das Videoangebot auf Netflix oder auch die Artikeldichte auf einem News-Portal ist – hat allerdings nicht nur Vorteile. Für den Konsumenten wird es so immer schwerer, den Überblick zu behalten und den für ihn interessanten Content im Auge zu behalten. Eine Lösung für diese Problematik, die sich in den vergangenen Jahren bewährt hat, sind die Recommendation Systems, die so genannten

Empfehlungssysteme. Sie sorgen dafür, dass der Nutzer auf ihn maßgeschneiderten bzw. personalisierten Content bekommt. So muss er auf Netflix nicht nach einem Actionfilm mit Tom Cruise suchen, sondern das Recommendation System erkennt seine Vorliebe für Actionfilme mit Tom Cruise und schlägt sie ihm vor. Bestenfalls weiß der Nutzer nicht einmal, dass er Actionfilme mit Tom Cruise mag, aber aufgrund der Sehgewohnheiten des Nutzers erkennt das System, dass ihm eigentlich auch Tom Cruise-Filme gefallen sollten und empfiehlt sie ihm vor.

Dabei ist die Idee der Empfehlung keine Erfindung des Internet-Zeitalters. Seit jeher informiert man sich vor dem Kauf eines Produktes, was dessen Vor- und Nachteile sind und ob dessen Preis angemessen ist – idealerweise fragt man jemanden, den man kennt oder dem man vertraut. Schon die ersten Zeitungen entdeckten die Empfehlungen für sich: Bis heute hat sich dort eine breite Kritikerschaft entwickelt,

---

<sup>1</sup> Vgl. Gantz, John; Reinsel, David: The Digital Universe in 2020: Big Data, Bigger Shadows, and Biggest Growth in the Far East, 2012, S. 1. Laut der Studie soll das „digital universe“, also die gesamte digitale Welt, bis 2020 um den Faktor 300 wachsen, von 130 Exabytes auf 40.000 Exabytes.

<sup>2</sup> Vgl. Amazon. n.d. Anzahl aktiver Kunden-Accounts von Amazon weltweit in den Jahren 1997 bis 2014 (in Millionen). Statista. Zugriff am 17. Januar 2016. Verfügbar unter <http://de.statista.com/statistik/daten/studie/297615/umfrage/anzahl-weltweit-aktiver-kunden-accounts-von-amazon/>, zuletzt eingesehen am 17.01.16 um 17:24 Uhr.

die Videospiele, Bücher oder Filme bespricht und empfiehlt oder nicht empfiehlt. Dieses „Empfehlungssystem“ übernahmen auch die ersten Internetfirmen. Zum Beispiel Amazon: James Marcus, ein amerikanischer Literaturkritiker, kam 1996 als 55. Mitarbeiter zu Amazon und war dort Teil einer Redaktion, die Bücher auf der Webseite des Unternehmens empfahl<sup>3</sup>. Im Jahr 2003 musste er Amazon verlassen, da der Online-Buchhändler einen Algorithmus einführte, der automatisiert Bücher an die Kunden empfahl<sup>4</sup> – auf Basis ihrer Interessen, die aus dem bisherigen Nutzungsverhalten gewonnen wurden. Somit war Amazon eines der ersten Unternehmen, das ein automatisiertes Recommendation System einsetzte und gleichzeitig ein Vorbote für die digitale Disruption in News-Redaktionen. Bis heute sind die Recommendation Systems wesentlich komplexer, ausgefeilter und präziser geworden – außerdem können sie auf einen viel größeren Datensatz zugreifen, als die frühen digitalen Empfehlungssysteme. Aus diesem Grund sollen in dieser Arbeit die Grundlagen eines modernen Recommendation Systems erarbeitet werden - als Basis für die Masterarbeit in Kooperation mit der NDR Mediathek, wo ein Konzept für ein Empfehlungssystem ausgearbeitet werden soll. Deshalb ist die Leitfrage dieser Ausarbeitung: Was sind die Grundelemente sowie die Vor- und Nachteile eines Recommendation Systems?

Dementsprechend unterteilt sich die Arbeit in folgende Abschnitte: 1. Der Aufbau eines Recommendation Systems. Hier sollen die drei Hauptbestandteile eines Empfehlungssystems genauer vorgestellt werden. 2. Die Vorteile eines Recommendation Systems. In diesem Abschnitt wird erklärt, warum es sinnvoll ist, solch ein System zu nutzen. 3. Die Probleme beim Aufbau eines Recommendation Systems. Dieser Abschnitt beleuchtet, welche Problematiken bei der Konzeption eines Empfehlungssystems zu beachten sind. Der Schluss fasst die Ergebnisse dieser Arbeit zusammen und gibt einen ersten Ausblick auf die Masterarbeit.

## **2. Aufbau eines Recommendation Systems**

Da es unterschiedliche Anforderungen an ein Recommendation System gibt, existiert nicht *das* eine System, das für jedes Vorhaben geeignet ist. Francesco Ricci, Professor für Computer Science an der Universität Bozen, unterteilt die

---

<sup>3</sup> Vgl. Marcus, James: Amazonia . Fünf Jahre im Epizentrum der E-Commerce-Revolution, Berlin, 2006.

<sup>4</sup> Vgl. Ebd., S. 248.

Empfehlungssysteme grob in sechs verschiedene Kategorien. Sein Unterscheidungskriterium hierbei ist die Herangehensweise der Systeme bei der Generierung der Empfehlung.

- „*Content-Based*“: Das Content-basierte Recommendation System spricht seine Empfehlungen auf Basis des bisherigen Nutzerverhaltens aus<sup>5</sup>. Wenn dem Nutzer zum Beispiel ein Film aus der Kategorie Action gefällt, lernt das System daraus, dass ihm womöglich auch weitere Filme aus diesem Genre gefallen könnten. Problematisch bei dieser Herangehensweise ist vor allem das Kaltstartproblem, das im Kapitel vier dieser Arbeit ausführlicher beschrieben wird.
- „*Collaborative filtering*“: Auch das kollaborative Filtern basiert auf den Gewohnheiten des Nutzers. Bei dieser Herangehensweise werden jedoch nicht nur die Eingaben des Nutzers mit einbezogen, sondern die aller Nutzer mit ähnlichen Interessen; deshalb wird das kollaborative Filtern auch oft als „people-to-people-correlation“<sup>6</sup> bezeichnet. Durch diese Methode ist vor allem eine präzisere Vorhersage der Nutzerinteressen möglich. Das kollaborative Filtern ist momentan die erfolgreichste Methode bei Recommendation Systems. Unter anderem setzen Amazon, Netflix, Google oder auch Apple diese Methode in ihren Empfehlungssystemen ein.  
Das Problem des kollaborativen Filterns ist, dass ein recht großer Datensatz benötigt wird, um brauchbare Ergebnisse zu erzielen. Auch damit beschäftigt sich Kapitel vier ausführlicher.
- „*Demographic*“: Diese Sorte von Recommendation Systems empfiehlt Content oder Konsumgüter auf Basis der demografischen Daten des Nutzers. Dem liegt die Annahme zugrunde, dass für unterschiedliche demografische Nischen auch verschiedene Empfehlungen generiert werden sollten<sup>7</sup>.
- „*Knowledge-based*“: Die Wissens- bzw. Erfahrungs-basierten Empfehlungssysteme bauen – ähnlich wie die Content-Based-Systeme – auf den aufgezeichneten Nutzergewohnheiten auf. Sie gehen aber noch ein Stück weiter und bestimmen mit einer „similarity function“, ob die „user needs“ den bisher gemachten Empfehlungen entsprachen. Über diese Funktion lässt sich ein

---

<sup>5</sup> Vgl. Ricci, Francesco u.a.: Introduction to Recommender Systems Handbook, In: Recommender System Handbook, hrsg. von ebendiesen, New York, 2011, S. 11.

<sup>6</sup> S. Ebd., S. 12.

<sup>7</sup> Vgl. Ebd. So zeigt Amazon zum Beispiel einem männlichen, älteren User andere Produkte als Empfehlung an, als einer jungen Frau.

„similarity score“ errechnen, der die Nützlichkeit der Empfehlung für den Nutzer angibt.<sup>8</sup> Problematisch kann auch hier das Kaltstartproblem sein.

- „*Community based*“: Dieses Empfehlungssystem basiert auf den Vorlieben der Freunde des Nutzers. Sie folgen der Annahme, dass befreundete Menschen gleiche Interessen haben und dem Nutzer so zu ihm passende Empfehlungen gemacht werden können, gemäß dem Leitsatz: „Tell me who your friends are, and I will tell you who you are“<sup>9</sup>. Dabei profitiert das System von dem immer dichter werdenden Netz in den sozialen Medien. Das Problem dieses Ansatzes ist das Ausbrechen aus der von Eli Pariser erkannten „Filter Bubble“: Wenn ich nur Vorschläge auf Basis dessen bekomme, was meine Freunde mögen, verengt sich mein Blick auf die Welt. Auch dazu gibt es ausführlichere Erläuterungen in Kapitel vier dieser Arbeit.
- „*Hybrid recommender systems*“: Die hybriden Empfehlungssysteme sind eine Mischform von einer oder mehreren der oben genannten Ansätze. Der Sinn einer Mischform ist, dass der Nachteil von System A durch die Implementierung reduziert oder komplett wett gemacht werden kann<sup>10</sup>. Großer Vorteil dieser Systeme ist die Kontextualisierung, die zum Beispiel möglich wird, wenn der demografische Ansatz mit einer anderen Methode gemischt wird. Nachteil der hybriden Modelle ist der hohe Rechenaufwand – dieses Problem wird in Kapitel vier weiter ausgeführt.

Trotz der unterschiedlichen Ansätze bei der Erstellung eines Recommendation Systems funktionieren sie auf ähnliche Art und Weise. Im ersten Schritt zeichnen sie das Verhalten, die Gewohnheiten und die Vorlieben des Nutzers auf. Im zweiten Schritt werden diese Daten in Beziehung zueinander gesetzt, woraus dann im dritten Schritt die Empfehlung generiert wird<sup>11</sup>. So ergibt sich eine Dreiteilung: 1. Representation of Input (Datenerfassung). 2. Neighborhood Formation (Datenverarbeitung). 3. Recommendation Generation (Empfehlungsgenerierung).

---

<sup>8</sup> Vgl. Ricci, Francesco u.a.: Introduction to Recommender Systems Handbook, S. 12.

<sup>9</sup> S. Ebd., S. 13.

<sup>10</sup> Vgl. Ebd.

<sup>11</sup> Besonders die Methode des kollaborativen Filterns läuft auf diese Art und Weise ab. Doch auch bei den anderen Herangehensweisen finden sich Elemente des kollaborativen Filterns.



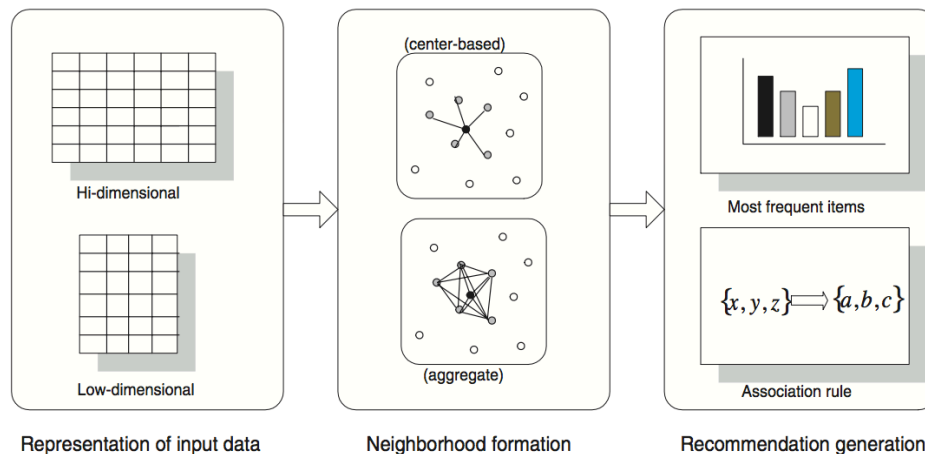


Abbildung 1: Aufbau eines Collaborative Filter-Recommendation Systems

Diese drei Teile sollen in den folgenden Abschnitten näher erläutert werden.

## 2.1 Representation of Input

Im Schritt Representation of Input bzw. der Datenerfassung werden alle Interaktionen des Nutzers mit der Webseite aufgezeichnet. Der Inhalt des Datensatzes variiert je nach Anbieter. So erfasst Netflix als Videostreamingdienst zum Beispiel andere Daten als ein Online-Shop und der Online-Shop wiederum andere Daten als der Musikstreamingdienst Spotify<sup>12</sup>. Trotzdem lässt sich der erste Schritt auf dem Weg zur Empfehlung auf eine simple Interaktion herunterbrechen: „The input data is a collection of historical purchasing of  $n$  customers on  $m$  products.“<sup>13</sup> Das ermöglicht die Aufspannung einer großen Matrix, die im Aufsatz von Sarwar und Kollegen „original presentation“<sup>14</sup> genannt wird.

## 2.2 Neighborhood Formation

Dieser Schritt ist der wichtigste Schritt in der Konzeption eines Recommendation Systems. Hier wird in den aggregierten Daten nach Gemeinsamkeiten zwischen dem anvisierten Nutzer und anderen, gleich gesinnten Nutzern gesucht. Dieser Prozess läuft in zwei verschiedenen Schritten ab: 1. Distanzberechnung zwischen zwei Kunden. 2. Modellierung eines Nachbarschaftsverhältnisses. Im Laufe dieses

<sup>12</sup> So zählen für Netflix vor allem die Wiedergabedauern und die Nutzerbewertungen der einzelnen Videos. Für Online-Shops sind vor allem die Conversions, also die in erfolgreiche Käufe umgewandelten Visits der Seite eine zentrale Maßeinheit.

<sup>13</sup> S. Sarwar, Badrul u.a.: Analysis of Recommendation Algorithms for E-Commerce, In: Proceedings of the 2nd ACM Conference on Electronic Commerce, New York, 2000, S. 161.

<sup>14</sup> Ebd.

Prozesses kann zum Beispiel ein Modell wie in Abbildung 2 entstehen: Dort wurden Nutzerprofile verschiedenen Filmgenres zugeordnet, um zum einen Vorlieben der Nutzer abzubilden, aber auch die Nähe zwischen Filmgenres aufzuzeigen.




Abbildung 2: Zuteilung von Nutzern zu verschiedenen Filmgenres

Am Ende des Prozesses steht idealerweise kein visualisiertes Modell wie in Abbildung 2, sondern ein Rechenmodell, mit dem sich die Nachbarschaft von Nutzerprofilen möglichst präzise bestimmen lassen.

### 3.1 Recommendation Generation

Der letzte Schritt ist die Generierung der Vorhersagen aus dem im vorhergehenden Schritt aufgebauten Nachbarschafts-Modell. Dazu existieren ebenfalls zwei verschiedene Techniken:

- „*Most-frequent Item Recommendation*“: Bei dieser Herangehensweise wird das Verhalten der Interessens-Nachbarn des aktuell betrachteten Nutzers im Modell untersucht. Es werden die am meisten aufgerufenen Produkte gezählt und so eine Übersicht der am meisten besuchten Produkte erstellt, die dem aktuell betrachteten Nutzer nun als Empfehlung präsentiert werden<sup>15</sup>.
- „*Association Rule-based Recommendation*“: Auch bei dieser Methode werden die direkten Nachbarn des aktuell betrachteten Nutzers im Modell untersucht, mit dem Unterschied, dass nur die nächsten Interessens-Nachbarn mit einbezogen werden und nicht alle. Das hat den Vorteil, dass die

<sup>15</sup> Vgl. Sarwar, Badrul u.a.: Analysis of Recommendation Algorithms for E-Commerce, S. 162.

Performance dieses Systems besser ist, jedoch birgt diese Methode das Risiko, dass das ausgewählte Datenset nicht genügend Informationen für eine präzise Empfehlung enthält<sup>16</sup>.

#### 4. Vorteile eines Recommendation Systems

Der vorhergehende Absatz zeigt, dass ein Recommendation Systems kein Zweizeiler an Programmiercode ist. Trotzdem lohnt es sich, die Mühe bei der Implementierung eines solchen Systems in Kauf zu nehmen. Jonathan Herlocker erarbeite mit seinen Kollegen 2003 einen Katalog mit elf Aufgaben, bei denen ein Recommendation System ein praktischer Begleiter sein kann. Der Text wurde zu einer klassischen Referenz im Themenfeld der Empfehlungssysteme<sup>17</sup>, folgende Vorteile des Empfehlungssysteme lassen sich aus den elf Punkten extrahieren:

- „*Empfehlungen für den Nutzer*“: Wie es der Name der Empfehlungssysteme bereits suggeriert, bringen sie dem Nutzer den relevanten oder für ihn interessanten Content direkt zu ihm, ohne dass er danach suchen muss<sup>18</sup>.
- „*Kontextualisierte Empfehlung*“: Recommendation Systems können Produkte oder Content nicht nur innerhalb eines Themenfelds empfehlen, sondern auch über ein Themenfeld hinweg. Kauft ein Nutzer zum Beispiel ein Zelt, wäre für ihn vielleicht auch ein Campingkocher oder eine wasserdichte Jacke interessant<sup>19</sup>.
- „*Orientierung*“: Falls ein User ziellos nach einen Katalog durchsucht, geben ihm Empfehlungssysteme eine Richtung vor, die ihn interessieren könnte<sup>20</sup>.
- „*Transparenz*“: Im Idealfall sind die Empfehlungssysteme für den Benutzer transparent, sodass er eigene Kalibrierungen am System vornehmen kann oder Interessen hinzufügen kann<sup>21</sup>.

Zusätzlich sind noch drei weitere große Vorteile der Empfehlungssysteme zu nennen, die nicht in Herlockers Liste auftauchen:

---

<sup>16</sup> Vgl. Sarwar, Badrul u.a.: Analysis of Recommendation Algorithms for E-Commerce, S. 162.

<sup>17</sup> Vgl. Ricci, Francesco u.a.: Introduction to Recommender Systems Handbook, S. 6.

<sup>18</sup> Vgl. Herlocker, Jonathan u.a.: Evaluating Collaborative Filtering Systems, In: ACM Transaction on Information Systems, New York, 2004, S. 8-9.

<sup>19</sup> Vgl. Ebd., S. 9.

<sup>20</sup> Vgl. Ebd., S. 9-10.

<sup>21</sup> Vgl. Ebd., S. 10.

- „*Dynamik*“: Auch in einer dynamischen Contentlage hilft das Empfehlungssystem dem User, die für ihn interessanten Artikel oder Produkte zu finden.
- „*Zeitersparnis*“: Wenn der User nicht nach Content suchen muss, sondern ihm relevanter Content vorgeschlagen wird, spart der Nutzer Zeit, die er zum Beispiel in die Kaufentscheidung investieren kann.
- „*Automatisierung*“: Das Recommendation System läuft vollkommen automatisiert und benötigt deutlich weniger Pflege als ein „menschliches Empfehlungssystem“, wie das Beispiel der Amazon-Redaktion zeigt.

## 5. Probleme bei der Implementierung eines Recommendation Systems

Bei der Implementierung eines Recommendation Systems können einige Problematiken auftauchen, die zu beachten sind, da sie die Ergebnisse nicht nur beeinträchtigen, sondern die auch gänzlich unbrauchbar machen können. Folgende Problematiken gibt es:

- „*Kaltstartproblem*“: Diese Problematik entsteht, wenn ein Nutzer sich neu in einem System anmeldet und noch keine Daten über die Vorlieben des Nutzers vorliegen. Somit kann das System zu Beginn keine präzisen Empfehlungen geben<sup>22</sup>.
- „*Kontext*“: Bei dieser Problematik geht es darum, nicht nur Empfehlungen aufgrund der Vorlieben des Nutzers zu machen, sondern bei diesem Prozess auch noch andere Variablen wie Zeit oder Ort mit einzubeziehen<sup>23</sup>.
- „*Diversität*“: Dem Nutzer sollen nicht nur monothematische Vorschläge oder Produkte unterbreitet werden, sondern das Empfehlungsbild soll auch Einträge aus anderen Themenbereichen enthalten, damit der Nutzer auch diese erforschen kann<sup>24</sup>.
- „*Performance*“: Auch bei großen Datenbanken oder komplexen Empfehlungssystemen soll die Empfehlung möglichst schnell ausgesprochen

---

<sup>22</sup> Vgl. Probst, Bastian: Verwendung von Benutzermodellen zur Personalisierung von Inhalten, Hamburg, 2014, S. 2.

<sup>23</sup> Vgl. Ricci, Francesco u.a.: Introduction to Recommender Systems Handbook, S. 6.

<sup>24</sup> Vgl. Ebd., S. 26.

werden, daher ist auch auf die Performance oder die „scalability“<sup>25</sup> des Systems zu achten.

- „*Disruption*“: Das Konsumverhalten kann sich durch ein Ereignis schlagartig verändern, weshalb auch dieser Punkt bei der Konzeption eines Recommendation Systems beachtet werden muss<sup>26</sup>.

## 6. Schluss und Ausblick

Die vorliegende Arbeit, in der die grundlegenden Elemente, Vorteile und Problematiken von Recommendation Systems erarbeitet wurden, zeigt vor allem eines: *Das* Empfehlungssystem, das sich problemlos auf jede Datenbank aufsetzen lässt, gibt es nicht. Stattdessen muss vor der Implementierung ein Konzept erarbeitet werden, welches die Anforderungen genauer beschreibt, die das Recommendation System erfüllen muss. Darunter fallen nicht nur technische, sondern auch konzeptionelle Anforderungen, die dem Empfehlungssystem eine solide Basis geben, auf dem die Entwickler schließlich aufbauen können.

Bezogen auf die anstehende Masterarbeit für die NDR Mediathek müssen also in einem ersten Schritt die Anforderungen für ein Empfehlungssystem erarbeitet werden. Darunter fallen nicht nur die verschiedenen technische Anforderungen, also zum Beispiel, welche Filtermethode das System benutzt, sondern auch die Problematiken, die speziell der NDR hat. Darunter fällt zum Beispiel, dass nur bestimmte Nutzerdaten gesammelt und getrackt werden dürfen oder dass sich der Content der Mediathek aufgrund von kurzen Verweildauern recht schnell verändert. Diese Herausforderungen gilt es in der Masterarbeit zuerst zu bestehen.

---

<sup>25</sup> S. Ricci, Francesco u.a.: Introduction to Recommender Systems Handbook. S. 26.

<sup>26</sup> Vgl: Probst, Bastian: Verwendung von Benutzermodellen zur Personalisierung von Inhalten, S. 2-3.

## 7. Literatur- und Abbildungsverzeichnis

Amazon. n.d. Anzahl aktiver Kunden-Accounts von Amazon weltweit in den Jahren 1997 bis 2014 (in Millionen). Statista. Zugriff am 17. Januar 2016. Verfügbar unter <http://de.statista.com/statistik/daten/studie/297615/umfrage/anzahl-weltweit-aktiver-kunden-accounts-von-amazon/>, zuletzt eingesehen am 17.01.16 um 17:24 Uhr.

*Gantz, John; Reinsel, David*: The Digital Universe in 2020: Big Data, Bigger Shadows, and Biggest Growth in the Far East, 2012.

*Herlocker, Jonathan u.a.*: Evaluating Collaborative Filtering Systems, In: ACM Transaction on Information Systems, New York, 2004.

*Marcus, James*: Amazonia . Fünf Jahre im Epizentrum der E-Commerce-Revolution, Berlin, 2006.

*Probst, Bastian*: Verwendung von Benutzermodellen zur Personalisierung von Inhalten, Hamburg, 2014.

*Ricci, Francesco u.a.*: Introduction to Recommender Systems Handbook, In: Recommender System Handbook, hrsg. von ebendiesen, New York, 2011.

*Sarwar, Badrul u.a.*: Analysis of Recommendation Algorithms for E-Commerce, In: Proceedings of the 2nd ACM Conference on Electronic Commerce, New York, 2000, S. 158-167.

*Abbildung 1: Sarwar, Badrul u.a.*: Analysis of Recommendation Algorithms for E-Commerce, In: Proceedings of the 2nd ACM Conference on Electronic Commerce, New York, 2000, S. 158-167.

*Abbildung 2: Vargas, Saul u.a.*: Coverage, Redundancy and Size-awareness in Genre Diversity for Recommender Systems, In: Proceedings of the 8th ACM Conference on Recommender Systems, New York, 2014, S. 209-216.