Hochschule für Angewandte Wissenschaften Hamburg
Hamburg University of Applied Sciences

Ausarbeitung Masterseminar

Bastian Probst

Personalisierte Vorschläge für Medieninhalte

Fakultät Technik und Informatik
Studiendepartment Informatik

Faculty of Engineering and Computer Science
Department of Computer Science

Bastian Probst

Personalisierte Vorschläge für Medieninhalte

Ausarbeitung Masterseminar

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

Gutachter: Prof. Dr. Bettina Buth
Gutachter: Prof. Dr. Kai von Luck

Betreuer: Prof. Dr. Kai von Luck

Eingereicht am: 28. Februar 2015

Inhaltsverzeichnis

1 Einleitung **1**

2 Methoden und vergleichbare Arbeiten **1**
- 2.1 Übersicht . . . 2
- 2.2 Repräsentation der Eingabedaten . . . 2
- 2.3 Aufbereiten der Daten . . . 3
  - 2.3.1 Kategorisierung der Filmdaten . . . 3
  - 2.3.2 Erstellung von Benutzermodellen . . . 4
- 2.4 Generierung von Vorhersagen . . . 4

3 Vorhaben **4**
- 3.1 Ziel . . . 5
- 3.2 Umsetzung . . . 5
  - 3.2.1 Versuchsaufbau . . . 5
- 3.3 Aktueller Stand . . . 6
- 3.4 Weitere Tätigkeiten . . . 6
  - 3.4.1 Aufbereitung der Daten . . . 6
  - 3.4.2 Zweites Voting . . . 7
  - 3.4.3 Auswertung der Ergebnisse . . . 7

4 Risiken **7**

5 Zusammenfassung und Ausblick **10**

1 Einleitung

Immer mehr digitale Medieninhalte werden verfügbar. Um die Benutzer nicht durch dieses beständige Wachstum zu überfordern, ist eine Möglichkeit zum Filtern der Inhalte die Personalisierung Weiß u. a. (2008) Bellekens u. a. (2009) Fan u. a. (2012).
Hierbei muss unter anderem beachtet werden, dass das Nutzungsverhalten für unterschiedliche Medien divergieren kann Cheng u. a. (2014). Ebenfalls muss beachtet werden, dass Fehler des Systems problematisch sind. Der Benutzer wird durch falsche Vorschläge beeinträchtigt oder es werden ihm Inhalte vorenthalten, welche ihn interessieren El-Arini u. a. (2012).
In dieser Arbeit wird ein Experiment beschrieben, bei welchem die Kategorien der IMDb und die Selbstauskunft der Benutzer verwendet wird, um Filmbewertungen zu generieren. Hierfür wurde eine Webseite erstellt, auf welcher hauptsächlich Studenten Filme und Kategorien bewertetet. Diese Bewertungen werden dazu verwendet werden, um automatisch Bewertungen zu generieren und diese mit den tatsächlichen Votings zu vergleichen. Im Rahmen der Masterarbeit wird die Frage beantwortet werden:

> „Ist es möglich durch Selbstauskunft Benutzermodelle zu erstellen, welche zur Vorhersage für Filmbewertung verwendet werden können?“

Dieses Kapitel gibt eine Übersicht über den Inhalt der Arbeit. Im Kapitel 1 werden Personalisierung und zu verwendende Methoden beschrieben. Das Experiment selbst wird im Kapitel 3 näher betrachtet. Die Risiken werden im Kapitel 4 aufgezeigt. Im Kapitel 5 werden die Arbeit zusammengefasst und mögliche zukünftige Arbeiten beschrieben.

2 Methoden und vergleichbare Arbeiten

In diesem Kapitel wird das grundsätzliche Prinzip von Personalisierung erklärt. Daraufhin wird aufgezeigt, wie die Daten repräsentiert werden. Anschließend wird die Datenbearbeitung und das Erstellen der Benutzerprofile betrachtet. Abschließend wird ein Überblick über die Methoden für die Vorhersage gegeben.
Die Anzahl der Teilnehmer beim Experiment ist zu klein für Methoden wie Kollaboratives Filtern Ahmed u. a. (2013). Daher werden hier nur die Ansätze aufgeführt, welche auch im

Kontext des Experiments verwendet werden sollen. Eine allgemeine Übersicht über Benutzermodelle und Vorhersagesystem bieten bisherige Ausarbeitungen Probst (2014a) und Probst (2014b).

2.1 Übersicht

Vorhersagesysteme bestehen aus drei Hauptkomponenten Sarwar u. a. (2000):

- **Repräsentation der Eingabedaten**
- **Datenaufbereitung**
- **Generierung der Vorhersagen**

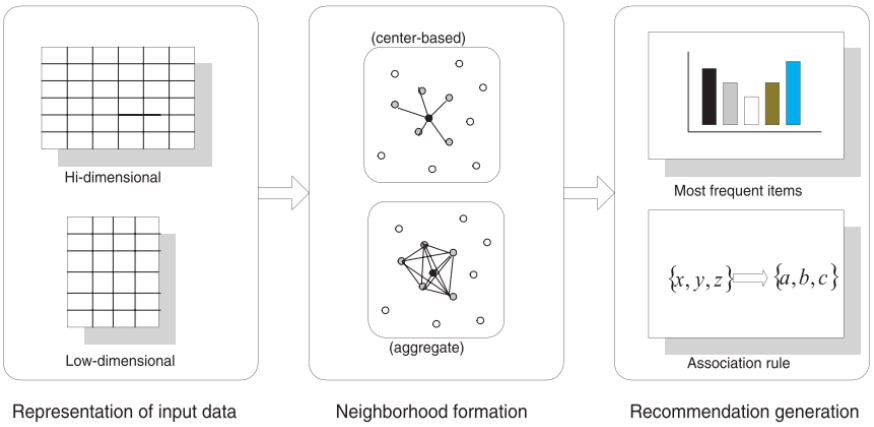

Abbildung 2.1: Hauptkomponenten eines Vorhersagesystems Sarwar u. a. (2000)

Im Folgenden werden diese Komponenten näher betrachtet und es wird dargestellt, wie diese im Rahmen des Experiments umgesetzt werden sollen.

2.2 Repräsentation der Eingabedaten

Die Testpersonen bewerten Filme und Kategorien. Das Konsumverhalten wird nicht näher betrachtet. Somit existieren nur explizite Bewertungen der Benutzer als Eingabedaten. Es wird folgende Beziehung abgespeichert: „Die Bewertung (als konkreter numerischer Wert) eines Benutzers für eine Ressource“. Eine Ressource kann in diesem Zusammenhang ein konkreter Film oder ein Genre sein. Ähnliche Ansätze bieten: Shardanand und Maes (1995) Weiß u. a.

(2008) Bellekens u. a. (2009). Diese werden teilweise durch weitere Daten ergänzt, wie implizite Bewertungen oder Kontextinformationen. In dieser Arbeit wird der genaue Zeitpunkt des Votings als Kontext verwendet. Die Repräsentation der Daten wird im ersten Projektbericht näher beschrieben.

2.3 Aufbereiten der Daten

Die Aufbereitung der Daten bezieht sich zum einen auf die Filmdaten zum anderen auf die Benutzerprofile. Zunächst wird beschrieben wie die Filmdaten kategorisiert werden können. Im Anschluss wird die Erstellung der Benutzerprofile dargestellt.

2.3.1 Kategorisierung der Filmdaten

Bei der Aufbereitung der Filmdaten geht es im Wesentlichen darum, dass ähnliche Daten in Beziehung gebracht werden.Im Kontext dieser Arbeit geschieht dies anhand der Kategorisierung der Internet Movie Database (IMDb). Bei einem ähnlichen Ansatz wurde erfolgreich die Kategorisierung von „The Huffington Post “für die Personalisierung von Nachrichten verwendet O'Banion u. a. (2012). Im Gegensatz dazu ist die Kategorisierung der IMDb nicht hierarchisch aufgebaut.

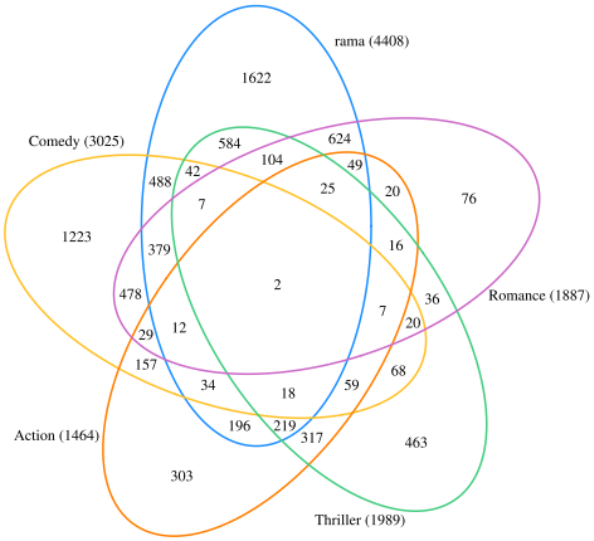

Abbildung 2.2: Mengendiagramm: Hauptgenres (Netflix) Vargas u. a. (2014)

Im Kontext dieser Arbeit wurden die 22 Kategorien der IMDb verwendet, welche bei der Suche nach Filmen genutzt werden können. Ein Film kann mehreren Kategorien zugeordnet werden. Es ist auch geplant, weitere - schon bestehende - Kategorisierungen zu verwenden. Diese Auswahl wird im zweiten Teil des Experiments getroffen werden. Ein weiterer geplanter Ansatz ist es, die Filme im TV-Anytime-Format zu speichern Bellekens u. a. (2009).
Die aufbereiteten Daten werden mit den im nächsten Teil beschriebenen Benutzermodellen zur Vorhersage verwendet.

2.3.2 Erstellung von Benutzermodellen

Die Votings der Benutzer werden für die Erstellung der Benutzermodelle verwendet. Anhand dieser werden die Benutzer und die Daten wie Filme, Kategorien, Schauspieler usw. in Beziehung gesetzt. Shardanand und Maes (1995) Weiß u. a. (2008) Bellekens u. a. (2009). Eine andere Möglichkeit bietet das Zusammenfassen der Benutzer in Stereotypen Rich (1998). Diese Stereotypen können durchaus hierarchisch aufgebaut sein. Im Kontext dieser Arbeit könnten solche Stereotypen zum Beispiel „Actionfilmliebhaber“ oder „Witzige-Liebesfilme-Fan“sein. Dies wird im Rahmen der zweiten Projektarbeit durchgeführt werden. Es werden für die jeweiligen Vorhersagemethoden die entsprechenden Benutzerprofile erstellt. Die Vorhersagemethoden werden im nächsten Absatz genauer beschrieben.

2.4 Generierung von Vorhersagen

Für die Generierung der Vorhersagen wird betrachtet wie gut noch nicht bewertete Filme zu den jeweiligen Benutzerprofilen passen Shardanand und Maes (1995) Weiß u. a. (2008) Bellekens u. a. (2009). Im Kontext dieser Arbeit bedeutet dies, dass ein Film hoch bewertet wird, wenn dessen Genres vom Benutzer bisher direkt oder indirekt hoch bewertet wurden. Eine weitere Methode ist die Verwendung von Graphen Kumar und Kulkarni (2013) oder Hypergraphen Tan u. a. (2011) Bu u. a. (2010) Li und Li (2013). Hierfür müssen die zugrunde liegenden Daten in einen Hypergraphen strukturiert werden. Die Bewertung neuer Filme wird somit zu einem Rankingproblem in diesem Hypergraphen.
Das Experiment wird im nächsten Kapitel genauer beschrieben.

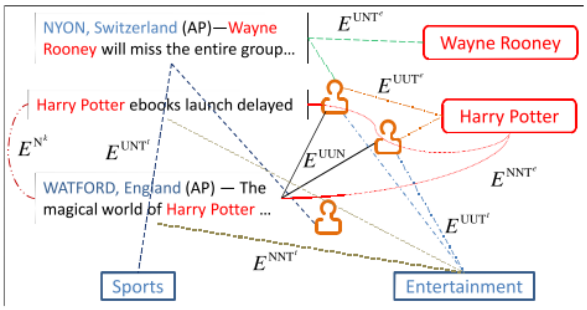

Abbildung 2.3: Hypergraphen Datenmodell Li und Li (2013)

3 Vorhaben

In diesem Kapitel wird zunächst das Ziel des Experiments beschrieben. Als nächstes wird die Umsetzung des Experiments dargestellt. Dies beinhaltet den Versuchsaufbau mit den

unterschiedlichen Phasen. Abschließend werden der aktuelle Stand und kommende Schritte beschrieben.

3.1 Ziel

In dieser Arbeit soll die Frage geklärt werden, ob es möglich ist, anhand von Selbstauskunft und mit der Kategorisierung der IMDb Filmvorschläge zu generieren. Hierfür wurden zunächst Informationen über die Testpersonen gesammelt und diese gebeten, Filme und Kategorien zu bewerten. Das Ziel ist, anhand dieser Selbstauskunft vorherzusagen, wie weitere Filme von diesen Personen bewertet werden.

3.2 Umsetzung

Für die Umsetzung wurde zunächst eine Webseite für das Bewerten der Filme eingerichtet. Die Teilnehmer machten Angaben zu sich selbst und bewerteten dort 50 Filme und 22 Kategorien. Im zweiten Schritt müssen diese Bewertungen und Angaben ausgewertet werden. Schließlich wird im Rahmen der Masterarbeit ein System entwickelt, welches Vorhersagen über die Filme für bestimmte Benutzer trifft. Diese müssen mit den tatsächlichen Votings verglichen werden.

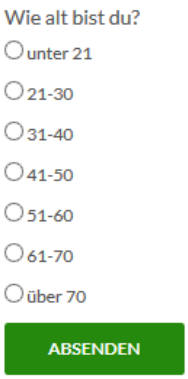

Abbildung 3.1: Altersabfrage

3.2.1 Versuchsaufbau

Das Experiment besteht im Wesentlichen aus vier Phasen: der Votingphase, der Auswertungs- und Vorhersagephase, der zweiten Votingphase und der Auswertungsphase.

- Die **Votingsphase** beginnt mit der Entwicklung einer Webseite. Diese Webseite bietet einen Login für die Identifizierung der Benutzer. Darüber hinaus existiert ein Votingsystem, welches das Bewerten der Filme und der Kategorien ermöglicht. Der Projektbericht 1 beschreibt die einzelnen Komponenten und ihre Funktionsweise genauer.
- In der **Auswertungs- und Vorhersagephase** werden die Bewertungen analysiert und in ein Format gebracht, sodass sie für die Vorhersagen verwendet werden können. Auf diese Datenstruktur werden unterschiedliche Algorithmen angewendet, um deren Tauglichkeit zu vergleichen.

- In der **zweiten Votingphase** werden die Teilnehmer gebeten zehn weitere Filme zu bewerten.
- Am Ende in der **Auswertungsphase** werden die Bewertungen des Systems und der Benutzer miteinander verglichen.

3.3 Aktueller Stand

Die erste Phase des Experiments ist durchlaufen. An dem Voting haben 315 Personen teilgenommen. Von diesen haben zum aktuellen Zeitpunkt 89 Personen alle Fragen beantwortet. Für das Voting wurde eine Skala von -3 bis +3 verwendet, da mehr als sieben Auswahlmöglichkeiten keinen Mehrwert liefern Rosenthal und Rosnow (1991) nach Shardanand und Maes (1995). Die Bewertung geht dabei von „sehr schlecht“ bis „sehr gut“.
Zur Akquirierung der Teilnehmer wurde ein Aufruf über den Verteiler der Hochschule für Angewandte Wissenschaften (HAW) gestartet. Ebenfalls wurden in einigen Veranstaltungen, um Teilnahme gebeten. Einige Teilnehmer sind nicht aus dem Umfeld der HAW. Es ist davon auszugehen, dass der größte Teil der Teilnehmer Studenten in dem Altersbereich von 21 - 30 Jahren sind. Dies muss in der Auswertung betrachtet werden. Eine detaillierte Analyse der Teilnehmer wird im zweiten Projekt durchgeführt werden. Dies gehört zu den anstehenden Tätigkeiten, welche im folgenden Kapitel aufgezeigt werden.

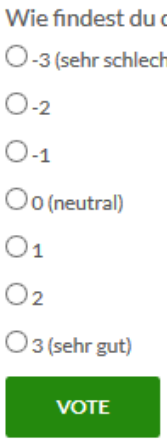

Abbildung 3.2: Filmbewertung auf der Webseite

3.4 Weitere Tätigkeiten

Nachdem die Votingphase abgeschlossen ist, müssen die Daten aufbereitet werden. Danach müssen Vorhersagen generiert und ein zweites Voting durchgeführt werden. Schließlich müssen die gewonnenen Erkenntnisse ausgewertet werden.

3.4.1 Aufbereitung der Daten

Um die bei der ersten Votingphase gesammelten Daten für Vorhersagen nutzen zu können, müssen die Daten aufbereitet werden. Dies kann, wie in Kapitel 2.3.2 beschrieben, durch

die Erstellung von Benutzermodellen realisiert werden. Für die Filmdaten wird die Kategorisierung der IMDb verwendet (siehe 2.3.1). Für die Vorhersage durch ein Ranking in einem Hypergraphen müssen die Daten in ein entsprechendes Format gebracht werden. Die genaue Datenaufbereitung wird im Rahmen des zweiten Projekts erarbeitet und im Projektbericht 2 beschrieben werden.

3.4.2 Zweites Voting

Für das zweite Voting werden die Testpersonen gebeten zehn weitere Filme zu bewerten. Dafür wird eine weitere Webseite zur verfügung gestellt werden. Hier werden die Teilnehmer die Filme auf die gleiche Weise, wie beim ersten Voting, bewerten. Ebenfalls werden vom System automatisch Bewertungen für die jeweiligen Teilnehmer erstellt. Die generierten und tatsächlichen Votings müssen, wie im nächsten Kapitel beschrieben, verglichen und ausgewertet werden.

3.4.3 Auswertung der Ergebnisse

Im Anschluss an das zweite Voting werden die Bewertungen des Systems und der Benutzer miteinander verglichen. Es wird betrachtet, ob geringe Informationen ausreichen, um erfolgreiche Vorhersagen zu treffen. Als erfolgreich werden in dieser Arbeit die Vorhersagen angesehen, welche nicht zu einer der beiden folgenden Kategorien gehören: „false positive“ oder „false negative“. Als „false positive“ werden Vorhersagen betrachtet, bei denen das System davon ausgeht, dass der Benutzer diese präferiert, die der Benutzer aber nicht mit der höchsten oder zweithöchsten Bewertung bewertet. Diese sind aus dem Grund für ein Vorhersagesystem problematisch, da der Benutzer auch Vorschläge bekommt, welche ihm nicht gefallen. Es ist davon auszugehen, dass Benutzer einem System mit zu vielen „false positives“ eher distanziert gegenüberstehen. Vorhersagen gelten als „false negative“ unter der Voraussetzung, dass der Benutzer diese positiv bewertet und das System sie als neutral oder schlecht einstuft. Diese Fehler haben den Effekt, dass dem Benutzer Filme nicht vorgeschlagen werden, welche ihm gefallen. Dies bedeutet ein „entgangenes Geschäft“. Daher ist auch dieser Fehler problematisch. Somit wird das System daran bewertet, wie viele richtige und falsche Bewertungen es findet. Eine weitere Möglichkeit ist, die Frage zu klären, wie die Testpersonen selbst Vorhersagen bewerten Pu u. a. (2011). Ebenfalls könnten die Vorsagen des Systems mit Vorhersagen verglichen werden, die von einem Experten erstellt worden sind Pu u. a. (2011).
Die Risiken des Vorgehens werden im nächsten Kapitel betrachtet.

4 Risiken

In diesem Kapitel werden die Risiken betrachtet, die bei der Umsetzung des Experiments zu beachten sind. Folgende Risiken wurden für den Kontext dieser Arbeit identifiziert:

- Zum einen gibt es das Risiko, dass einige der Teilnehmer fehlerhafte Angaben machen. Dies kann der Tatsache geschuldet sein, dass der Umfang der Fragen und der damit verbundene Zeitaufwand deutlich zu hoch gewesen ist. Es ist nicht überprüfbar, welche Intention die Teilnehmer motiviert hat, teilzunehmen. Ebenfalls ist auch nur schwer zu überprüfen, ob die Teilnehmer die Bewertungen gewissenhaft durchgeführt haben. Hier können zwar die Aufzeichnungen über das zeitliche Verhalten beim Voting zu Hilfe genommen werden. Doch ist ein Zeitabstand zwischen zwei Votings nicht zwangsläufig ein Beweis für Gewissenhaftigkeit, die Testperson kann auch schlichtweg andere Tätigkeiten nebenbei erledigt haben. Auch muss eine schnelle Folge von Votings kein Beweis für ein „Betrügen“ sein, da die Testperson die Filme auch kennen kann.

- Ein weiteres Risiko ist, dass die Testpersonen nur die Trailer bewertet haben. Vom Umfang her wäre es unmöglich gewesen, die Personen alle Filme schauen zu lassen bevor sie diese bewerten. Somit bestehen die Votings zum einen aus Filmbewertungen, zum anderen aus Bewertungen der Trailer. Filme anhand der Trailer zu bewerten hat eine ganz andere Qualität, als diese direkt zu bewerten. Außerdem werden Trailer in unterschiedlichen Ländern auch anders geschnitten, um regionsspezifisch die höchste Begeisterung zu erzielen. Da nicht alle Trailer in Deutsch zu finden waren, sind somit auch Trailer dabei die für diese Region eher untypisch geschnitten sind. Um diesem Problem entgegen zu wirken, wurden die am besten bewerteten Filme der Kategorien gewählt. Ebenfalls wurde darauf geachtet, dass kein Film älter als fünf Jahre ist. Diese Zeitspanne wurde bewusst so kurz gewählt, da die Teilnehmer hauptsächlich Studenten sind. Es ist zu erwarten, dass das Durchschnittsalter der Teilnehmer relativ niedrig ist. Durch die Auswahl erhöht sich die Wahrscheinlichkeit, dass die Teilnehmer diese Filme gesehen haben. Trotzdem werden nicht alle Filme von jedem gesehen worden sein. Somit besteht hier eine Gefahr, dass die Ergebnisse durch Trailerbewertungen „verfälscht“ werden

- Auch die gewählten Kategorien sind ein Risiko. Es kann sich herausstellen, dass diese nicht aussagekräftig genug sind, um Vorhersagen zu treffen. Um diesem Problem entgegen zu wirken, wurden die Kategorien möglichst unterschiedlich gewählt. Ein großes Risiko ist auch, dass die Kategorisierung der ImdB sich nicht für die Vorhersagen eignet. So kann sich im Laufe der Masterarbeit herausstellen, dass es nicht möglich ist, unter der Verwendung dieser Kategorien sinnvolle Ergebnisse zu erzielen. Es kann sich herausstellen, dass die Bewertung von Filmen weniger mit der Kategorie als mit anderen Attributen der Filme korreliert. So kann es sein, dass Schauspieler, Regisseur oder Drehorte eine viel höhere Bedeutung bei der Bewertung haben. Das größte Problem dieses Risikos besteht darin, dass es schwer möglich ist dieses zu überprüfen, da die Testpersonen keine Angabe darüber tätigten, warum sie einen Film gut oder schlecht finden. Dies konnte aufgrund des Umfangs nicht mit in die Befragung aufgenommen werden. Ebenfalls kann sich herausstellen, dass die Kategorien nicht feingranular genug sind. So ist es durchaus möglich, dass zum Beispiel bei der Kategorie „Sport“ Filme über „Autorennen“ ganz anders bewertet werden als solche, in denen das Thema „Golf“[] ist. Auch dies kann zur Folge haben, dass die Kategorien sich als nicht brauchbar herausstellen.

- Ein weiteres Risiko ist, dass die Informationen, welche über die Teilnehmer gesammelt wurden, nicht ausreichend sind. Es kann sich herausstellen, dass die Kenntnis weitere Attribute von den Teilnehmern erforderlich ist, um sinnvolle Ergebnisse zu erzielen. Hier wurden ganz bewusst so wenig Informationen wie nötig gesammelt. Es bestand die Befürchtung, dass bei zu persönlichen Fragen, viele potentielle Teilnehmer das Voting ablehnen würden.

- Auch die Schwellenwerte können zu einem Problem werden. Wenn zum Beispiel als Grenzen -3 bis -2, -1 bis +1 und +2 bis +3 gesetzt werden, liegt das System nicht erheblich falsch, wenn es bei einem tatsächlichen Voting von +2 mit +1 bewertet. Es wäre aber problematisch dies als genauso fehlerhaft wie eine Bewertung von -1 zu betrachten. Hier ist es wesentlich bei den Bewertungsfunktionen auch die Schwellenwertproblematik zu berücksichtigen. Somit kann der Gefahr entgegen gewirkt werden, dass aufgrund von Grenzwerten Algorithmen als schlecht bewertet werden, welche in Wirklichkeit nur gering abweichen.

- Schließlich ist es auch ein Risiko, dass der Umfang der gesammelten Daten für Vorhersagen nicht ausreicht. Es besteht die Möglichkeit, dass nicht genügend Personen bis zum Ende mitmachen. Offensichtlich ist, dass Methoden wie Kollaboratives Filtern bei so kleinen Teilnehmerzahlen nicht verwendet werden können. Es kann sich darüber hinaus

herausstellen, dass weitere Informationen erforderlich gewesen wären, um erfolgreich Vorherzusagen. Um diesem Problem entgegen zu wirken, werden weitere Attribute der Filme der ImbD entnommen. Auch die Verwendung anderer Quellen ist vorgesehen. Ebenfalls werden unterschiedliche Algorithmen verwendet und verglichen.

5 Zusammenfassung und Ausblick

Im Rahmen der Masterarbeit soll die Frage geklärt werden, ob es möglich ist, anhand von Selbstauskunft Vorschläge zu generieren. Hierfür wurde ein Votingsystem geschaffen, bei dem Benutzer 50 Filme und 22 Kategorien bewertet haben. Diese Bewertungen werden als Grundlage genommen, Benutzerprofile zu erstellen. Mit diesen Benutzerprofilen wird versucht, Vorhersagen zu treffen, wie die Teilnehmer 10 weitere Filme bewerten werden. Die Bewertungen werden mit den Vorhersagen unterschiedlicher Algorithmen verglichen. Es werden unterschiedliche Bewertungsmetriken verwendet, um die Qualität der jeweiligen Algorithmen zu bewerten. Schließlich wird die Frage geklärt werden, ob und wie es möglich ist, anhand der gesammelten Informationen über die Teilnehmer vorherzusagen, wie die jeweiligen Benutzer Filme bewerten.
Im Erfolgsfall kann diese Arbeit dazu beitragen das „Kaltstartproblem“ anzugehen. Zum einen geht es um die Situation, wenn es erst wenige Informationen über einen Benutzer gibt, zum anderen den Fall, dass ein von keinem Benutzer bewerteter Film durch das System bewertet werden muss. Es wird die Frage geklärt werden, ob wenige. bzw. wie viele Informationen ausreichen, eine sinnvolle Vorhersage zu treffen.
In zukünftigen Arbeiten kann ein Experiment durchgeführt werden, welches eine bedeutend höhere Teilnehmerzahl hat. Dies würde es ermöglichen, Methoden des Kollaborativen Filterns zu verwenden. Diese könnten mit den in dieser Arbeit verwendeten Methoden verglichen werden.
Eine weitere Herausforderung für kommende Forschungen könnte es sein, dass der Kontext in die Vorhersagen einbezogen wird. Dabei kann es sich um Personen handeln, mit denen zusammen Filme geschaut werden, um Lebensumstände und deren Veränderungen, um Wetter, Tageszeit oder saisonale Bedingungen, wie zum Beispiel bei einem Studenten die Phasen: Prüfungs-, Semester-, Vorlesungsfreie Phase.

Literaturverzeichnis

[Ahmed u. a. 2013] Ahmed, Amr ; Kanagal, Bhargav ; Pandey, Sandeep ; Josifovski, Vanja ; Pueyo, Lluis G. ; Yuan, Jeff: Latent Factor Models with Additive and Hierarchically-smoothed User Preferences. In: *Proceedings of the Sixth ACM International Conference on Web Search and Data Mining*. New York, NY, USA : ACM, 2013 (WSDM '13), S. 385–394. – URL http://doi.acm.org/10.1145/2433396.2433445. – ISBN 978-1-4503-1869-3

[Bellekens u. a. 2009] Bellekens, Pieter ; Houben, Geert-Jan ; Aroyo, Lora ; Schaap, Krijn ; Kaptein, Annelies: User Model Elicitation and Enrichment for Context-sensitive Personalization in a Multiplatform Tv Environment. In: *Proceedings of the Seventh European Conference on European Interactive Television Conference*. New York, NY, USA : ACM, 2009 (EuroITV '09), S. 119–128. – URL http://doi.acm.org/10.1145/1542084.1542106. – ISBN 978-1-60558-340-2

[Bu u. a. 2010] Bu, Jiajun ; Tan, Shulong ; Chen, Chun ; Wang, Can ; Wu, Hao ; Zhang, Lijun ; He, Xiaofei: Music Recommendation by Unified Hypergraph: Combining Social Media Information and Music Content. In: *Proceedings of the International Conference on Multimedia*. New York, NY, USA : ACM, 2010 (MM '10), S. 391–400. – URL http://doi.acm.org/10.1145/1873951.1874005. – ISBN 978-1-60558-933-6

[Cheng u. a. 2014] Cheng, Jian ; Yuan, Ting ; Wang, Jinqiao ; Lu, Hanqing: Group Latent Factor Model for Recommendation with Multiple User Behaviors. In: *Proceedings of the 37th International ACM SIGIR Conference on Research & Development in Information Retrieval*. New York, NY, USA : ACM, 2014 (SIGIR '14), S. 995–998. – URL http://doi.acm.org/10.1145/2600428.2609493. – ISBN 978-1-4503-2257-7

[El-Arini u. a. 2012] El-Arini, Khalid ; Paquet, Ulrich ; Herbrich, Ralf ; Van Gael, Jurgen ; Arcas, Blaise Agüera y: Transparent User Models for Personalization. In: *Proceedings of the 18th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. New York, NY, USA : ACM, 2012 (KDD '12), S. 678–686. – URL http://doi.acm.org/10.1145/2339530.2339639. – ISBN 978-1-4503-1462-6

[Fan u. a. 2012] Fan, Xiangyu ; Mostafa, Javed ; Mane, Ketan ; Sugimoto, Cassidy: Personalization is Not a Panacea: Balancing Serendipity and Personalization in Medical News Content Delivery. In: *Proceedings of the 2Nd ACM SIGHIT International Health Informatics Symposium*. New York, NY, USA : ACM, 2012 (IHI '12), S. 709–714. – URL http://doi.acm.org/10.1145/2110363.2110445. – ISBN 978-1-4503-0781-9

[Kumar und Kulkarni 2013] Kumar, Saurabh ; Kulkarni, Mayank: Graph Based Techniques for User Personalization of News Streams. In: *Proceedings of the 6th ACM India Computing Convention*. New York, NY, USA : ACM, 2013 (Compute '13), S. 12:1–12:7. – URL http://doi.acm.org/10.1145/2522548.2523129. – ISBN 978-1-4503-2545-5

[Li und Li 2013] Li, Lei ; Li, Tao: News Recommendation via Hypergraph Learning: Encapsulation of User Behavior and News Content. In: *Proceedings of the Sixth ACM International Conference on Web Search and Data Mining*. New York, NY, USA : ACM, 2013 (WSDM '13), S. 305–314. – URL http://doi.acm.org/10.1145/2433396.2433436. – ISBN 978-1-4503-1869-3

[O'Banion u. a. 2012] O'Banion, Shawn ; Birnbaum, Larry ; Hammond, Kristian: Social Media-driven News Personalization. In: *Proceedings of the 4th ACM RecSys Workshop on Recommender Systems and the Social Web*. New York, NY, USA : ACM, 2012 (RSWeb '12), S. 45–52. – URL http://doi.acm.org/10.1145/2365934.2365943. – ISBN 978-1-4503-1638-5

[Probst 2014a] Probst, Bastian: Personalisierung von interaktiven Second Screen Anwendungen mithilfe von Benutzermodellen. (2014a)

[Probst 2014b] Probst, Bastian: Personalisierte Vorschläge für Medieninhalte. (2014b)

[Pu u. a. 2011] Pu, Pearl ; Chen, Li ; Hu, Rong: A User-centric Evaluation Framework for Recommender Systems. In: *Proceedings of the Fifth ACM Conference on Recommender Systems*. New York, NY, USA : ACM, 2011 (RecSys '11), S. 157–164. – URL http://doi.acm.org/10.1145/2043932.2043962. – ISBN 978-1-4503-0683-6

[Rich 1998] Rich, Elaine: Readings in Intelligent User Interfaces. San Francisco, CA, USA : Morgan Kaufmann Publishers Inc., 1998, Kap. User Modeling via Stereotypes, S. 329–342. – URL http://dl.acm.org/citation.cfm?id=286013.286035. – ISBN 1-55860-444-8

[Rosenthal und Rosnow 1991] Rosenthal, R. ; Rosnow, R.: *Essentials of Behavioral Research: Methods and Data Analysis*. McGraw-Hill, second edition, 1991. – ISBN 978-0070539297

[Sarwar u. a. 2000] Sarwar, Badrul ; Karypis, George ; Konstan, Joseph ; Riedl, John: Analysis of Recommendation Algorithms for e-Commerce. In: *Proceedings of the 2Nd ACM Conference on Electronic Commerce*. New York, NY, USA : ACM, 2000 (EC '00), S. 158–167. – URL http://doi.acm.org/10.1145/352871.352887. – ISBN 1-58113-272-7

[Shardanand und Maes 1995] Shardanand, Upendra ; Maes, Pattie: Social Information Filtering: Algorithms for Automating &Ldquo;Word of Mouth&Rdquo;. In: *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems*. New York, NY, USA : ACM Press/Addison-Wesley Publishing Co., 1995 (CHI '95), S. 210–217. – URL http://dx.doi.org/10.1145/223904.223931. – ISBN 0-201-84705-1

[Tan u. a. 2011] Tan, Shulong ; Bu, Jiajun ; Chen, Chun ; Xu, Bin ; Wang, Can ; He, Xiaofei: Using Rich Social Media Information for Music Recommendation via Hypergraph Model. In: *ACM Trans. Multimedia Comput. Commun. Appl.* 7S (2011), November, Nr. 1, S. 22:1–22:22. – URL http://doi.acm.org/10.1145/2037676.2037679. – ISSN 1551-6857

[Vargas u. a. 2014] Vargas, Saúl ; Baltrunas, Linas ; Karatzoglou, Alexandros ; Castells, Pablo: Coverage, Redundancy and Size-awareness in Genre Diversity for Recommender Systems. In: *Proceedings of the 8th ACM Conference on Recommender Systems*. New York, NY, USA : ACM, 2014 (RecSys '14), S. 209–216. – URL http://doi.acm.org/10.1145/2645710.2645743. – ISBN 978-1-4503-2668-1

[Weiß u. a. 2008] Weiss, Diana ; Scheuerer, Johannes ; Wenleder, Michael ; Erk, Alexander ; Gülbahar, Mark ; Linnhoff-Popien, Claudia: A User Profile-based Personalization System for Digital Multimedia Content. In: *Proceedings of the 3rd International Conference on Digital Interactive Media in Entertainment and Arts*. New York, NY, USA : ACM, 2008 (DIMEA '08), S. 281–288. – URL http://doi.acm.org/10.1145/1413634.1413687. – ISBN 978-1-60558-248-1