



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

# Masterthesis

Deniz Örnek

Die Behandlung der Filter Bubble bei  
Recommender Systemen

# Deniz Örnek

Die Behandlung der Filter Bubble bei Recommender Systemen

Masterthesis eingereicht im Rahmen der Masterprüfung

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

Betreuender Prüfer: Prof. Dr. Kai von Luck  
Zweitgutachterin: Dr. Susanne Draheim

Abgegeben am 30.08.2016

**Deniz Örnek**

**Thema der Masterthesis**

Die Behandlung der Filter Bubble bei Recommender Systemen

**Stichworte**

Recommender Systeme, Filter Bubble, Komfortzone, Swap Meet, Foursquare

**Kurzzusammenfassung**

Diese Arbeit handelt von Recommender Systemen im World Wide Web, wobei von einer automatischen Empfehlungsgenerierung durch Algorithmen für Nutzer ausgegangen wird. Ein besonderer Fokus wird dabei auf das Filter Bubble Problem gelegt, wonach die Nutzer in eine Filterblase mit bestimmten Informationen gelangen sollen und dadurch in ihrem bestehenden Weltbild eingeschränkt werden. Die zentrale Frage dieser Arbeit lautet daher "Was macht ein gutes Recommender System unter Berücksichtigung des Filter Bubble Problems aus?".

Zur Beantwortung dieser Frage werden vier verschiedene Recommender Systeme (demografische, inhaltsbasierte, kollaborative und hybride Recommender Systeme) herangezogen. Zudem werden verschiedene Kriterien, die ein gutes Recommender System ausmachen, dargestellt und anhand eines Prototyp Beispiels – der erfundenen innovativen Location App namens Swap Meet – untersucht, welche versucht die Nutzer aus ihrer Filter Bubble herauszulocken. Zum Vergleich wird dieser App ein weltweit etabliertes System – die reale Location App Foursquare – gegenübergestellt, die im Gegensatz zu Swap Meet das Ziel verfolgt, die Nutzer so gut wie möglich in ihrer Filter Bubble zu halten.

Im Rahmen einer Gesamtbeurteilung der einzelnen Recommender Systeme konnte festgestellt werden, dass je nachdem welche Online-Beratung man bevorzugt, das eine beziehungsweise andere System seine jeweiligen Schwerpunkte sowie Vor- und Nachteile mit sich bringt und insofern eine Kombination aus verschiedenen Recommender Systemen mit großer Wahrscheinlichkeit zu einer höheren Zufriedenheit beim individuellen Nutzer führt.

**Deniz Örnek**

**Title of the paper**

The treatment of the Filter Bubble in Recommender Systems

**Keywords**

Recommender Systems, Filter Bubble, Comfort Zone, Swap Meet, Foursquare

**Abstract**

This thesis is regarding Recommender Systems in the world wide web. Recommender Systems are special software, which is recommending the user subjects, which are typical for its user, by using algorithms. Its special view is focussed on the Filter Bubble Problem of Recommender Systems. This Problem is about getting the user in a Filter Bubble of special, user-typical information, which includes the risk, that the user is automatically restricted in its view on the world. That is why the central question of this thesis will be “how does a good Recommender System looks like when you respect the before mentioned Filter Bubble Problem?”.

In reply to this question there will first be represented four different Recommender Systems (demographic, content-based, collaborative and hybrid Recommender Systems) as well as different criteria, which are typically for a good Recommender System. These criteria then will be examined by using a prototype example – the prototype example is an invented innovative Location App called Swap Meet, which is trying to lure the user out of its Filter Bubble. In competition to this before mentioned App Swap Meet there also will be taken reference to the real Location App Foursquare, which is an already worldwide established and existent System. In the opposite of Swap Meet, Foursquare is trying to keep its user in its own Filter Bubble.

At the end of this thesis there will be taken a completed view on the several Recommender Systems with the result, that any of the different Systems has its benefits. Whether the user judges a System as useful or not, especially depends on the focus of the user and which kind of online-consulting the user prefers. Because any System has got benefits as well as disadvantages, the user is held to combine several Systems in order to get the best result.

# I Inhaltsverzeichnis

Seite

<b>I</b>	<b>Inhaltsverzeichnis.....</b>	<b>5</b>
<b>II</b>	<b>Abbildungsverzeichnis.....</b>	<b>8</b>
<b>III</b>	<b>Tabellenverzeichnis.....</b>	<b>9</b>
<b>1</b>	<b>Einleitung.....</b>	<b>10</b>
<b>2</b>	<b>Recommender Systeme.....</b>	<b>13</b>
2.1	Definition von Recommender Systemen.....	13
2.2	Auf welcher Basis werden Empfehlungen generiert?.....	14
2.2.1	Verfahren zur Identifikation des Nutzers.....	14
2.2.2	Sammeln von Nutzerinformationen.....	16
2.2.3	Präferenzstrukturen und Profilbildung des Nutzers.....	17
2.2.4	Kontextsensitive Anwendungen.....	18
2.3	Ziele von Empfehlungen in Recommender Systemen.....	19
2.4	Welche Arten von Empfehlungen gibt es?.....	21
2.4.1	Produktempfehlungen.....	21
2.4.2	Weitere Arten von Empfehlungen.....	31

	Seite
2.5	Welche Arten von Recommender Systemen gibt es?.....32
2.5.1	Klassifizierung von Recommender Systemen.....33
2.5.1.1	Nicht-personalisierte Recommender Systeme.....34
2.5.1.2	Personalisierte Recommender Systeme.....35
2.5.1.2.1	Demografische Recommender Systeme.....35
2.5.1.2.2	Inhaltsbasierte Recommender Systeme.....36
2.5.1.2.3	Kollaborative Recommender Systeme.....37
2.5.1.2.4	Hybride Recommender Systeme.....39
2.5.1.3	Weitere Arten von Recommender Systemen.....40
2.6	Probleme von Recommender Systemen bei der Empfehlungsgenerierung...42
2.7	Nutzerdialog mit Recommender Systemen.....46
2.7.1	Methoden von Recommender Systemen.....47
2.7.2	Interfaces von Recommender Systemen.....48
2.7.3	Recommender Systeme im Online-Marketing.....50
2.8	Eigenschaften von Recommender Systemen.....51
<b>3</b>	<b>Filter Bubble.....54</b>
3.1	Was ist eine Filter Bubble?.....54
3.2	Wie entsteht eine Filter Bubble?.....55
3.3	Was versteht man unter der persönlichen Komfortzone innerhalb einer Filter Bubble?.....56
3.4	Ist eine Filter Bubble nützlich oder schädlich?.....58
3.5	Macht uns das Internet durch die Filter Bubble immer engstirniger?.....60
3.6	Meinungsvielfalt vs. Relevanz – wo liegen eigentlich die Präferenzen von Google und Facebook?.....60
3.7	Warum können einseitige Informationen riskant sein?.....61
3.8	Ist die dialektische Erkenntnis eine Holschuld des Users?.....62
3.9	Wie groß ist die Gefahr der Filter Bubble tatsächlich?.....62
3.10	Algorithmen im Internet und keine Auswege aus der Filter Bubble?.....62

	Seite
3.11 Droht uns die Filter Bubble Online und Offline?.....	63
3.12 Gibt es Auswege aus der Filter Bubble?.....	64
3.13 Förderung von Medienkompetenz und proaktiven Usern.....	65
3.14 Kriterien eines guten Recommender Systems unter Berücksichtigung des Filter Bubble Problems.....	65
<b>4 Beispiel: Swap Meet.....</b>	<b>69</b>
4.1 Projekteinführung: Ideenfindung auf Basis von Foursquare.....	70
4.2 Motivation, Vision und Zielsetzung.....	72
4.2.1 Zusammenhänge der Konzepte Social Graphs und Struktural Holes mit der Filter Bubble.....	72
4.3 Herangehensweise.....	74
4.3.1 Motivation des Einzelnen.....	74
4.3.2 Interaktionsmuster innerhalb der Gruppe.....	77
4.3.3 Technologien: Global Positioning System (GPS) und Near Field Communication (NFC).....	78
4.4 Prototyp Swap Meet.....	79
4.5 Fazit zu den Handlungsschritten – “Next Steps” .....	81
4.6 Ausblick / Swap Meet in der Anwendung.....	82
<b>5 Fazit.....</b>	<b>83</b>
<b>6 Zusammenfassung / Ausblick.....</b>	<b>88</b>
<b>IV Anhang.....</b>	<b>90</b>
1. Infografik von Monetate.....	90
2. Insidertipp – Küchenkonzert im Kölibri.....	91
<b>V Literatur- und Internetquellenverzeichnis.....</b>	<b>92</b>

## II Abbildungsverzeichnis

Seite

Abbildung 1: Vorgang der Empfehlungsgenerierung durch Recommender Systeme.....	13
Abbildung 2: Amazon-Startseite mit personalisierten Empfehlungen.....	22
Abbildung 3: Planet Sports blendet markenbasierte Topseller ein.....	24
Abbildung 4: The Long Tail – Kurvendiagramm einer Verkaufsstrategie.....	25
Abbildung 5: Amazon macht auf relevante Alternativen aufmerksam.....	26
Abbildung 6: Asos empfiehlt dazu passende Produkte.....	27
Abbildung 7: Im Onlineshop von Görtz wird beim Schuhkauf das passende Pflegemittel mit angeboten.....	28
Abbildung 8: H&M Website zeigt zu viele verschiedene Empfehlungsansätze, die den Besucher verwirren können.....	30
Abbildung 9: Klassifizierung von Recommender Systemen.....	34
Abbildung 10: Prozess der Filter Bubble.....	55
Abbildung 11: Prozess zur Überwindung der persönlichen Komfortzone.....	57
Abbildung 12: Prozess der Dialektik.....	61
Abbildung 13: Informationsfluss zwischen dem Nutzer, Foursquare und dem "GetLostBot" .....	70
Abbildung 14: Unser Team.....	71
Abbildung 15: Dreieck zur Motivation, Vision und Zielsetzung.....	72
Abbildung 16: Dreieck zur Herangehensweise.....	74
Abbildung 17: Swap Meet Logo.....	77
Abbildung 18: Swap Meet Anmeldung.....	79
Abbildung 19: Profil anlegen.....	79
Abbildung 20: Komfortzonen werden definiert.....	79



---

	Seite
Abbildung 21: Karte mit Komfortzonen.....	79
Abbildung 22: Insidertipps angeben.....	80
Abbildung 23: Thema und Challenge wählen.....	80
Abbildung 24: Challenge zu einem Thema alleine oder zusammen mit anderen Personen absolvieren.....	80
Abbildung 25: Orte finden, mit NFC einchecken und Punkte sammeln.....	80
Abbildung 26: Insidertipp Börse.....	81
Abbildung 27: Infografik von Monetate.....	90

### **III Tabellenverzeichnis**

Tabelle 1: Sieben Ziele von Empfehlungen in Recommender Systemen.....	20
Tabelle 2: Weitere Arten von Empfehlungen.....	31
Tabelle 3: Weitere Arten von Recommender Systemen.....	41
Tabelle 4: Kriterien eines guten Recommender Systems.....	66
Tabelle 5: Bewertung von Swap Meet und Foursquare im Hinblick auf die einzelnen Recommender Systeme.....	84

# 1 Einleitung

Das World Wide Web (kurz: Web) ist allgegenwärtig geworden, so dass wir dies nicht einmal mehr bemerken. Recommender Systeme (Empfehlungsdienste) sind ein integraler Bestandteil davon, wie Menschen sich heutzutage im Web orientieren. Aktuelle Arbeiten zu Recommender Systemen gehen von Algorithmen<sup>1</sup> aus, die eine automatische Empfehlung für Nutzer aussprechen. Einen guten Überblick bieten hierzu unter anderem [35], [31], [23], an denen ich mich bei der folgenden Darstellung orientiere.

Recommender Systeme helfen Nutzern von Webseiten dabei Informationen, die ihren Vorlieben am meisten entsprechen, leichter im Web zu finden. Die Empfehlungen werden auf der Grundlage des gesammelten Wissens über die Präferenzen von einzelnen Personen oder auch auf Basis einer größeren Gemeinschaft von Systembenutzern generiert und dienen dazu eine überwältigende Menge von Informationen zu verwalten sowie den Nutzern bei ihren Entscheidungsfindungen zu helfen. Die gegenwärtigen Recommender Systeme konzentrieren sich dabei in erster Linie auf Korrelationen<sup>2</sup> beziehungsweise Co-Zählungen, die aus Nutzerverhaltensdaten extrahiert werden.

In den vergangenen Jahren sind eine Vielzahl von automatisierten Recommender Systemen entwickelt und eingesetzt worden. Diese reichen von einfachen Produktempfehlungen (z.B. Leute die dieses Produkt gekauft haben, kauften auch noch ein weiteres anderes Produkt) über dialogbasierte Empfehlungen (z.B. sagen Sie, was für Produkte Sie am liebsten mögen) bis hin zu empfehlungsbasierten Systemen, welche auf langfristige Modelle von

---

<sup>1</sup> Ein Algorithmus ist eine allgemein nachvollziehbare eindeutige Beschreibung einer Folge von Aktionen zur Lösung eines, meist mathematischen Problems. Algorithmen setzen sich aus Entscheidungen, die sich mittels Logiken realisieren lassen, und Berechnungsanteilen zusammen. In der Informatik bilden Algorithmen die Grundlage für das Schreiben von Programmen. (Quelle: [24])

<sup>2</sup> Eine Korrelation misst die Stärke einer statistischen Beziehung von zwei Variablen zueinander. (Quelle: [59])

Benutzereinstellungen zurückzuführen sind (z.B. auf der Basis von 200 Filmen, die Sie bisher gesehen haben, empfehlen wir Ihnen diese fünf Filme).

Demnach tragen Recommender Systeme Inhalte individuell an Nutzer im Web heran, basierend auf deren konkreten Bedürfnissen, Vorlieben und Interessen. Dabei können die Systeme Produkte, Services, Nutzer (mit analogen Interessen) und vieles mehr vorschlagen. In der Zukunft wird daher Recommender Systemen ein tiefes Verständnis abverlangt, um die Beziehungen zwischen verschiedenen Elementen zu modellieren und somit optimale Empfehlungen generieren zu können.

Recommender Systeme stellen – gerade im Web 2.0-Zeitalter – eine besondere Form der Personalisierung<sup>3</sup> sowie des Social Networking<sup>4</sup> dar. Es besteht kein Zweifel, dass derartige Empfehlungsdienste einen erheblichen Mehrwert sowohl für Verbraucher als auch Unternehmen mit sich bringen. Denn sie helfen Verbrauchern dabei, optimale Suchergebnisse zu erzielen und somit schnelle sowie effiziente Entscheidungen zu treffen. Zudem genießen sie einen starken kommerziellen Erfolg, indem sie Online-Händlern dabei helfen, eine Form von hohem personalisierten Service zu geringen Kosten zur Verfügung zu stellen. Damit bieten Recommender Systeme Online-Händlern einen entscheidenden Marktvorteil, weshalb die Auswertung der Kundendaten bei großen Unternehmen eine hohe Priorität besitzt.

Daher treiben sowohl Google, Amazon und Facebook als auch eine Vielzahl anderer großer Plattformen die Entwicklung zur Personalisierung massiv voran, wozu unter anderem [16] einen guten Überblick bietet, auf dem die folgende Darstellung basiert.

Die Nutzer bekommen im Internet nur noch Dinge zu sehen, welche zu ihren persönlichen Präferenzen beziehungsweise ihrem Profil passen. Das kann durchaus sinnvoll sein: Denn bei der Eingabe des Stichwortes "Golf" erfährt der passionierte Golfer alles über seine Lieblings Sportart, während der Autofan nur Informationen zum VW Golf geliefert bekommt.

Doch politisch können die Folgen auch gravierend sein: Denn die Nutzer erhalten nur noch Nachrichten, die zu ihren Überzeugungen passen und abweichende Standpunkte gehen komplett an ihnen vorbei und weil die Nutzer nicht wissen welche Informationen gefiltert werden, merken sie es nicht einmal.

---

<sup>3</sup> Unter Personalisierung im Web versteht man die User-spezifische Anpassung der Inhalte einer Website, die durch die Sammlung und Auswertung von Informationen über das Nutzungsverhalten und Präferenzen der Anwender ermöglicht wird. (vgl. [28])

<sup>4</sup> Social Networks sind soziale Netzwerke im Internet, in denen Freunde, Bekannte oder Fremde mit gleichen Interessen aufeinander treffen und sich digital miteinander vernetzen. (vgl. [13])

Der Internetaktivist Eli Pariser wendet sich daher mit seinem Buch "Filter Bubble: Wie wir im Internet entmündigt werden" gegen die Big Player des Internets, die gegebenenfalls Meinungsvielfalt sowie politische Diskussionen zu Gunsten ihres Profits opfern und die Nutzer somit in einer Filter Bubble (Filterblase) mit bestimmten Informationen gefangen halten. Andererseits ist es den Nutzern nicht möglich alle Informationen im Web aufzunehmen und diese zu verarbeiten, weshalb immer eine Form von Filterung nötig sein wird.

In der vorliegenden Arbeit wird daher auf die Ansätze von Recommender Systemen, welche auf unterschiedliche Weise die Bedürfnisse der Nutzer aufgreifen beziehungsweise "vorausahnen" und ihnen Vorschläge (aus verschiedenen Bereichen) unterbreiten – und diese somit in eine Filter Bubble lenken – eingegangen. (vgl. [23])

Dazu werden vier verschiedene Recommender Systeme (demografische, inhaltsbasierte, kollaborative und hybride Recommender Systeme) dargestellt. Zudem werden verschiedene Kriterien, die ein gutes Recommender System ausmachen, erläutert und anhand eines Prototyp Beispiels – der erfundenen innovativen Location App namens Swap Meet – untersucht, welche versucht die Nutzer aus ihrer Filter Bubble herauszulocken, um somit an Lebenserfahrungen zu gewinnen und den persönlichen Horizont zu erweitern. Zum Vergleich wird dieser App ein weltweit etabliertes System – die reale Location App Foursquare – gegenübergestellt, die im Gegensatz zu Swap Meet das Ziel verfolgt, die Nutzer so gut wie möglich in ihrer Filter Bubble zu halten.

Dies soll dazu dienen zukünftige Trends besser einschätzen zu können und abschließend die zentrale Frage dieser Arbeit zu beantworten:

***"Was macht ein gutes Recommender System unter Berücksichtigung des Filter Bubble Problems aus?"***

## 2 Recommender Systeme

Im Folgenden werden Recommender Systeme näher erläutert.

### 2.1 Definition von Recommender Systemen

Recommender Systeme empfehlen dem Anwender aus einer Menge von Inhalten diejenigen Inhalte, die den Anwender am meisten interessieren könnten. Einen guten Überblick bietet hierzu unter anderem [41], an dem ich mich bei der folgenden Darstellung orientiere.

Um interessante Inhalte zu finden, sammelt jedes Recommender System zunächst Informationen über den Anwender und nutzt diese, um aus der Menge aller Inhalte, möglichst relevante Informationen an den Nutzer zurückzuliefern. Abbildung 1 verdeutlicht den Vorgang der Empfehlungsgenerierung durch Recommender Systeme.

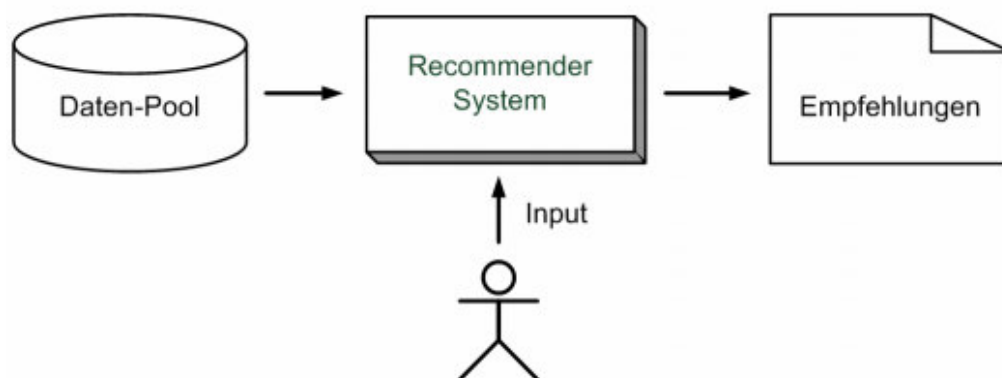


Abb. 1: Vorgang der Empfehlungsgenerierung durch Recommender Systeme

Zu den gesammelten Informationen zählen zum Beispiel Alter, Größe, Gewicht, Hobbies oder auch der Verlauf der besuchten Webseiten des Anwenders. Die gewonnenen Nutzerdaten werden dann in einem Daten-Pool gespeichert. Der Anwender kann nun eine Anfrage an das System stellen und das Recommender System berechnet auf Basis der Anfrage und den vorhandenen Nutzerinformationen aus dem Daten-Pool eine Menge von zu empfehlenden Inhalten.

## **2.2 Auf welcher Basis werden Empfehlungen generiert?**

Jedes Recommender System benötigt also eine entsprechende Datenbasis, aus welcher es dann die Empfehlungen generiert (vgl. [4]), wozu der jeweilige Nutzer in der Regel als erstes identifiziert werden muss. Einen guten Überblick bietet hierzu unter anderem [6], auf dem die folgende Darstellung basiert.

### **2.2.1 Verfahren zur Identifikation des Nutzers**

Idealerweise sollte ein Recommender System einen Nutzer bei betreten einer Website sofort erkennen und dessen Profil abrufen können. Ein Nutzerprofil über mehrere Sessions hinweg aufzubauen und zu vervollständigen kann jedoch nur dann erfolgen, wenn die Möglichkeit besteht den Nutzer eindeutig zu identifizieren. Dabei können folgende Verfahren unterschieden werden:

#### **Public Key Verfahren**

Die sicherste Methode einen Nutzer eindeutig zu identifizieren bietet das Public Key Verfahren. Dabei meldet sich der User bei einer Website durch Austausch von Schlüsseln an, wodurch die Identität eindeutig festgestellt werden kann. Die hohe Sicherheit bringt jedoch einen sehr hohen administrativen Aufwand für die Zertifizierungsstelle mit sich, da mit diesem Verfahren auch digitale Signaturen erstellt werden können. Es kann also nicht wie beim Login ein beliebiger anonymer Deckname vergeben werden, sondern es muss die reale Identität der betreffenden Personen vor der Schlüsselvergabe sichergestellt werden.

#### **Login und Passwort**

Eine weitere Variante Personen zu identifizieren besteht darin von den Anwendern explizit die Eingabe von Nutzernamen und Passwort zu verlangen. Allerdings bringt diese Methode wiederum einigen Aufwand für die User mit sich. Viele Anwender scheuen davor zurück sich mit Hilfe eines Anmeldeprozesses zu registrieren und für jede neue Sitzung Nutzernamen und Passwort einzugeben.

Anonymität kann in diesem Fall jedoch gewährt werden, indem der User einen Decknamen verwendet und das System beim Registrierungsprozess ansonsten keine persönlichen Daten verlangt. Ein Sicherheitsrisiko stellen bei diesem Verfahren aber Browser dar, die sich Passwörter merken. So könnte sich jeder beliebige Nutzer des internetfähigen Gerätes als eine bestimmte Person ausgeben.

## **Cookies**

Eine Möglichkeit die Erkennung des Anwenders zu automatisieren ist die Verwendung von Cookies, die beim ersten Besuch eines Nutzers lokal auf dessen Gerät gespeichert werden. Problematisch ist dabei jedoch, dass eigentlich nur der Browser identifiziert wird und nicht zwischen den einzelnen Nutzern selbst unterschieden wird. Wechselt ein User das Gerät, erkennt ihn das System nicht mehr als dieselbe Person, sondern stuft ihn als neuen Nutzer ein. Außerdem bieten neue Systeme den Nutzern häufig die Möglichkeit die Speicherung von Cookies zu deaktivieren. Werden Cookies also deaktiviert, ist keine Identifikation des Nutzers mehr möglich.

## **IP-Adresse**

Geräte können im Internet über ihre IP-Adressen erkannt werden. Der Nachteil liegt dabei jedoch darin, dass heutzutage die meisten Internet Provider die IP-Adressen beim Einwählen eines Gerätes dynamisch vergeben. Das heißt, dass ein und dasselbe Gerät, an dem eine bestimmte Person arbeitet, nach jeder neuen Einwahl ins Internet mit einer neuen IP-Adresse erscheint. Auf Seiten eines Recommender Systems bedeutet dies, dass dieselbe Person als eine Vielzahl unterschiedlicher Personen interpretiert wird, was natürlich zu einer Sinnlosigkeit der Personalisierung führen würde.

Das andere Extrem dazu wäre, dass ein System eine Vielzahl an verschiedenen Nutzern als ein und denselben interpretiert. Die Netzwerke von Unternehmen sind meist zum Schutz vor Angriffen durch Viren oder Hacker mittels Firewalls geschützt. Dadurch kommunizieren die User einer Firma nur indirekt über einen Proxy Server<sup>5</sup> mit dem Internet, wodurch sie als nur ein einziger Nutzer erkannt werden. Aus diesen Gründen eignet sich die Nutzererkennung mittels IP-Adresse nur sehr beschränkt zur Identifikation von Personen.

---

<sup>5</sup> Ein Proxy Server ist ein Kommunikationsvermittler in einem Computernetzwerk. Er leitet über seine eigene Adresse Anfragen (des Clients), etwa zum Aufruf einer Website oder zum Download einer Datei, an den entsprechenden Empfänger (Server) weiter, ohne dass beide direkt miteinander verbunden sein müssen. (vgl. [34])

## Browser Fingerprint

Alle Daten, die sich über ein Betriebssystem und den Browser ermitteln lassen, sind mehr oder weniger einzigartig. Aus allen gewonnenen Daten lässt sich eine Art digitaler Fingerabdruck (Fingerprint) erstellen, wozu [52] einen guten Überblick bietet, auf dem diese Darstellung basiert.

Ein Fingerprint lässt sich nutzen, um den jeweiligen Browser beim erneuten Besuch einer Webseite zu identifizieren und diese Information dann für die Empfehlungsgenerierung zu nutzen. Die Seiten können für den Fingerprint relativ einfache Funktionen verwenden, wie den User-Agent<sup>6</sup> des Browsers, die Bildschirmauflösung, die Sprache und die installierten Plug-ins<sup>7</sup>. Solange sich daran nichts verändert, bleibt der Fingerprint gleich. Es genügt jedoch eine neue Version eines Plug-ins zu installieren und der Fingerprint verändert sich.

### 2.2.2 Sammeln von Nutzerinformationen

Nachdem der Nutzer von dem System identifiziert wurde, kann es mit dem Sammeln von Nutzerinformationen beginnen. Einen guten Überblick bietet hierzu unter anderem [41], an dem ich mich bei der folgenden Darstellung orientiere.

Die benötigten Informationen können dabei von unterschiedlicher Art sein. Beim Sammeln dieser Informationen unterscheidet man zwischen zwei verschiedenen Methoden: Dem expliziten und impliziten Sammeln von Nutzerinformationen.

#### Explizites Sammeln von Nutzerinformationen

Bei der expliziten Methode wird der Anwender mit direkten Fragen oder Formularen konfrontiert. Er wird beispielsweise nach seinem Geburtsdatum, seinem Familienstatus, seinen Hobbies und Interessen sowie einigen anderen Informationen gefragt. Daraufhin erstellt das System ein Nutzerprofil und speichert die gesammelten Daten darin ab.

Eine andere Art des expliziten Sammelns von Informationen ist die Bewertung (z.B. von Produkten) durch den Nutzer. Die vergebenen Bewertungen durch einen Anwender können ebenfalls in einer Art Nutzerprofil gespeichert werden.

---

<sup>6</sup> Neben der IP-Adresse wird bei jeder Anfrage an einen Webserver auch übergeben, welcher Browser und welches Betriebssystem der anfragende Nutzer einsetzt. Diese Browser/Betriebssystem-Kombination – sowie noch weitere dazugehörige Informationen – wird als User Agent bezeichnet. (vgl. [17])

<sup>7</sup> Plug-ins sind Zusatzprogramme, welche über eine vordefinierte Schnittstelle in ein Basisprogramm eingebunden werden und dessen Funktionsumfang erweitern. (vgl. [29])



## **Implizites Sammeln von Nutzerinformationen**

Ein Recommender System, das seine Informationen über den Anwender implizit sammelt, erhält seine Daten, indem es sich zum Beispiel zu jedem Nutzer merkt, welche Internetseiten er wie lange in seinem Browser betrachtet hat sowie welche Seiten er anschließend aufgerufen hat. Die Historie der besuchten Webseiten oder häufig auftretende Verhaltensmuster bei der Informationssuche innerhalb einer Website können gespeichert und zur Generierung von Empfehlungen verwendet werden.

### **2.2.3 Präferenzstrukturen und Profilbildung des Nutzers**

Im Zuge des Sammelns von Nutzerinformationen kann das System ein Profil über den jeweiligen Nutzer erstellen, worin sich all seine Präferenzen widerspiegeln. Hierzu bietet unter anderem [4] einen guten Überblick, an dem ich mich bei der folgenden Darstellung orientiere.

Es werden die Möglichkeiten verdeutlicht, wie Datenbestände aufgebaut, gepflegt und erweitert werden können. Dabei stehen insbesondere die Kundendaten im Mittelpunkt, da diese – im Gegensatz zu den Produkten vom Verkäufer – nicht direkt greifbar und beim ersten Kontakt für das System weitestgehend unbekannt sind. Insbesondere die Bewertungen von Käufern sind für die Empfehlungsgenerierung von höchster Relevanz und werden daher durch verschiedene Recommender Systeme verfolgt.

### **Initiale Profilbildung des Nutzers**

Beim ersten Kontakt zwischen einem neuen Kunden und dem System stehen dem System zunächst erst keine persönlichen Daten der jeweiligen Person zur Verfügung. Daher bieten gängige Technologien heutzutage die Möglichkeit, Daten über die verwendete Soft- und Hardware eines Besuchers auf einer Website, wie zum Beispiel einem Onlineshop, festzustellen und zu speichern sowie diese auszuwerten. Wie zuvor unter Kapitel 2.2.1 dargestellt wurde, können für ein Recommender System beispielsweise der verwendete Browser und dessen Version, Prozessorgeschwindigkeit, Bandbreite seines Zugangs oder Anzeigeeinstellungen interessant sein.

Zu Beginn ist es dem System am ehesten möglich, den neuen Kunden mit einem Minimum an Informationen in eine demografische Gruppe einzuordnen, da bereits die Navigation im System, die ersten Suchanfragen und die verfügbaren Informationen über die verwendeten Technologien des Nutzers erste Rückschlüsse zulassen. Ein weiterer Ansatz lässt den Kunden zunächst in einer Trainingsphase eine Reihe von Bewertungen vornehmen, um diese als Grundlage für ein einleitendes Nutzerprofil zu verwenden.

## Erweiterung und Pflege des Nutzerprofils

Je nachdem welcher Empfehlungsansatz verwendet wird, werden verschiedene Daten benötigt und als relevant betrachtet. Das Nutzerprofil sollte jedoch bei jedem Ansatz um zusätzliche relevante Information erweitert werden.

Beispielsweise gibt es bei dem Online-Händler Amazon ([www.amazon.de](http://www.amazon.de)) für Kunden die Möglichkeit zu entscheiden, ob die Bewertung eines anderen Kunden zu einem Produkt hilfreich war oder nicht. Je nachdem, wie das Ergebnis einer Bewertung ausfällt, kann ein Kunde relativ schnell erkennen, wie der Durchschnitt der Käufer diese Bewertung empfindet und entscheiden, ob er ihr vertraut oder nicht und wie relevant sie für die Beeinflussung seiner Entscheidung ist. Sobald er seine Stimme abgibt, mit der er beurteilt, ob er die Bewertung des anderen Kunden als hilfreich empfand, macht er zusätzlich eine Aussage über seine persönliche Präferenz, welche für die Konkretisierung seines Nutzerprofils verwendet werden kann. Mit jeder zusätzlichen Information wird so das Profil zwar aussagekräftiger, aber auch komplexer.

Viele Systeme speichern einfach jede gewonnene Information, dennoch sollte bedacht werden, dass sich die Präferenzen eines Nutzers im Zeitverlauf auch ändern können. Eine äußerst wichtige Methode, die von vielen Systemen nicht verwendet wird, ist das graduelle Vergessen von Informationen, bei dem aktuellen Informationen über die Präferenzen des Nutzers eine höhere Relevanz und somit Gewichtung beigemessen wird, als länger zurückliegenden. Dies führt zu einer verbesserten Empfehlungsqualität, da aktuellere Bewertungen die gegenwärtigen Interessen eines Nutzers weitaus authentischer abbilden.

### 2.2.4 Kontextsensitive Anwendungen

Neben der unter Kapitel 2.2.3 dargestellten Möglichkeit, aus den Präferenzstrukturen von Anwendern ein Nutzerprofil zu erstellen sowie dies fortlaufend zu erweitern und zu pflegen, gibt es ebenso die Option die Empfehlungen auf der Grundlage von Kontext zu bilden. Einen guten Überblick bietet hierzu unter anderem [68], auf dem die folgende Darstellung basiert.

Kontext im IT-Umfeld meint jede Art von Information, welche dazu verwendet werden kann, die Situation einer Entität<sup>8</sup> in Interaktion mit anderen Entitäten zu charakterisieren. Da Kontext von der jeweiligen Interaktion abhängt, kann man für eine Information nicht pauschal beantworten, ob es sich bei ihr um Kontext handelt oder nicht. Kontext kann dabei eine einzelne Information sein oder eine Kombination aus vielen Informationen

---

<sup>8</sup> In einer Datenbank werden Informationen über interessierende eindeutig identifizierbare Objekte oder Sachverhalte gespeichert. Diese werden Entitäten genannt und können z.B. eine Person, ein Subjekt, ein Ereignis, ein Prozess oder ein Begriff sein. (vgl. [21])

verschiedener Quellen oder unterschiedlicher Zeitpunkte. Kontext bildet somit die Grundlage für kontextsensitive Anwendungen<sup>9</sup>.

Ein Beispiel für diese Definition von Kontext ist eine Person, die mit ihrem Smartphone interagiert, wobei sowohl die Person als auch das Smartphone miteinander agierende Entitäten darstellen. Kontext meint in dem Zusammenhang jede Information, welche die Interaktion zwischen beiden Entitäten beeinflusst. Beispiele für solche kontextuellen Informationen könnten der Ort, der Zeitpunkt, Personen in der Umgebung, gerade laufende Applikationen oder auch die Person und ihr Smartphone sein. All diese Daten könnte sich nun eine kontextsensitive Anwendung zunutze machen und basierend auf diesen kontextuellen Informationen Services anbieten.

### 2.3 Ziele von Empfehlungen in Recommender Systemen

Wie in den vorangegangenen Kapiteln dargestellt wurde, sind eine Menge an Aufwendungen (Identifikation des Nutzers, Sammeln von Nutzerinformationen, Erstellung, Ausbau und permanente Pflege des Nutzerprofils) erforderlich, um personalisierte Empfehlungen für die Nutzer generieren zu können.

Doch was sollen die Empfehlungen eigentlich bewirken beziehungsweise benötigen die Nutzer diese überhaupt zur Bewältigung der Informationsflut im Web? Um die vorangestellte Frage zu beantworten, wurde eine Vielzahl von Möglichkeiten zur Einrichtung von Empfehlungen in Recommender Systemen untersucht und diskutiert, wozu unter anderem [62] einen guten Überblick bietet, an dem ich mich bei der folgenden Darstellung orientiere.

Gute Empfehlungen tragen unter anderem zur Inspiration der Nutzer sowie zur Erhöhung von Vertrauen und Loyalität bei. Empfehlungen machen den Suchvorgang im Web für den Nutzer schneller und einfacher. Zudem können Nutzer durch Empfehlungen eher davon überzeugt werden etwas zu probieren oder zu kaufen.

Es hat sich jedoch herausgestellt, dass Recommender Systeme nur teilweise genaue Empfehlungen liefern können. Die Zufriedenheit der Nutzer und deren Derivate, wie Serendipität<sup>10</sup>, Vielfalt und Vertrauen werden daher zunehmend bei der Empfehlungsgenerierung als wichtig angesehen.

---

<sup>9</sup> Kontextsensitivität (auch Kontextabhängigkeit, englisch context awareness) bezeichnet das Verhalten von Anwendungsprogrammen, die Informationen über ihren "Kontext" – also ihre Umgebung – nutzen, um ihr Verhalten darauf abzustimmen. (vgl. [69])

<sup>10</sup> Serendipität bezeichnet das Phänomen, zu einer Erkenntnis zu gelangen oder etwas zu finden, nach dem man explizit nicht gesucht oder geforscht hat. (Quelle: [2])

Empfehlungen können zwar eine wichtige Rolle bei der Verbesserung von Nutzererfahrungen spielen, dennoch ist die Definition einer guten Empfehlung noch weitgehend offen und hängt zudem von dem allgemeinen Ziel des Empfehlungssystems ab.

Dieser Aspekt, dass es bislang keinen Konsens darüber gibt, wie eine Empfehlung in einem Recommender System zu bewerten ist, spiegelt bis heute die Tatsache wider, dass Empfehlungen in verschiedenen Recommender Systemen unterschiedliche Ziele zu erreichen versuchen.

Tabelle 1 definiert sieben Ziele von Empfehlungen in Recommender Systemen, wobei es bei der Auswahl und dem Vergleich von Empfehlungstechniken sehr wichtig ist, sich darauf zu einigen, was die jeweilige Empfehlung erreichen soll.

<b>Ziel</b>	<b>Definition</b>
<b>Transparenz</b>	Erklären wie das System funktioniert
<b>Kontrollfähigkeit</b>	Nutzern die Macht zur Kontrolle des Personalisierungsprozesses gewähren
<b>Vertrauenswürdigkeit</b>	Vertrauen der Nutzer in das System schaffen
<b>Wirksamkeit</b>	Nutzern dabei helfen gute Entscheidungen zu treffen
<b>Überzeugungskraft</b>	Nutzer davon überzeugen etwas zu probieren oder zu kaufen
<b>Leistungsfähigkeit</b>	Nutzern dabei helfen schneller zu entscheiden
<b>Zufriedenheit</b>	Die einfache Bedienbarkeit und den Genuss das Angebot zu nutzen erhöhen

Tab. 1: Sieben Ziele von Empfehlungen in Recommender Systemen

Die Wahl des Ziels ist meist nicht bewusst und führt zu Kompromissen, was bedeutet, dass die Empfehlungen durch den Grad an Interaktivität untrennbar miteinander verbunden sind. Trotz dieser Erkenntnis ist es jedoch eher unwahrscheinlich, dass eine Komponente in einem Recommender System zur Optimierung aller sieben Ziele beiträgt.

Es wird daher darüber nachgedacht, wie die "Güte" der Empfehlungen für jedes der Ziele in Tabelle 1 am besten gemessen werden kann (z.B. wäre eine Möglichkeit die Vorliebe für einen empfohlenen Artikel vor und nach dem Gebrauch zu messen).

## 2.4 Welche Arten von Empfehlungen gibt es?

Zu Beginn dieses Kapitels stellt sich die folgende Frage: "Was soll dem Nutzer eigentlich empfohlen werden?". Es gibt im Internet eine Vielzahl von Informationen, die dem Nutzer vorgeschlagen werden können, um ihm bei seiner Entscheidungsfindung zwischen der Informationsflut im Web zu helfen.

Die Empfehlungen reichen von Produktempfehlungen (z.B. durch Amazon, Ebay, Otto und Co.), über Textempfehlungen und Bildempfehlungen (z.B. durch Google), Videoempfehlungen (z.B. durch Netflix), Audioempfehlungen (z.B. durch Spotify), bis hin zu Personenempfehlungen (z.B. durch XING, LinkedIn, Parship, Tinder) und viele mehr.

Im Folgenden werden die verschiedenen Arten von Empfehlungen anhand von Praxisbeispielen erläutert, wobei insbesondere auf die Produktempfehlungen näher eingegangen wird, da diese eine der meist angewandten Form von Empfehlungen im Online-Handel darstellt. Einen guten Überblick zu den Produktempfehlungen bietet unter anderem [36], an dem ich mich bei der folgenden Darstellung orientiere.

### 2.4.1 Produktempfehlungen

Produktempfehlungen sind aus dem Online-Handel schon lange nicht mehr wegzudenken. Es ist schon eine Kunst, überhaupt einen Shop ohne Recommendations zu finden. Auf den Seiten der meistbesuchten Shops in Deutschland wie Amazon, Otto, Tchibo und Co. wird man dabei jedenfalls wenig Erfolg haben.

Ein Blick auf die Amazon-Startseite zeigt deutlich, welchen Stellenwert das Thema mittlerweile einnimmt. Im eingeloggten Zustand sind circa zwei Drittel der Seite mit personalisierten Vorschlägen gefüllt.

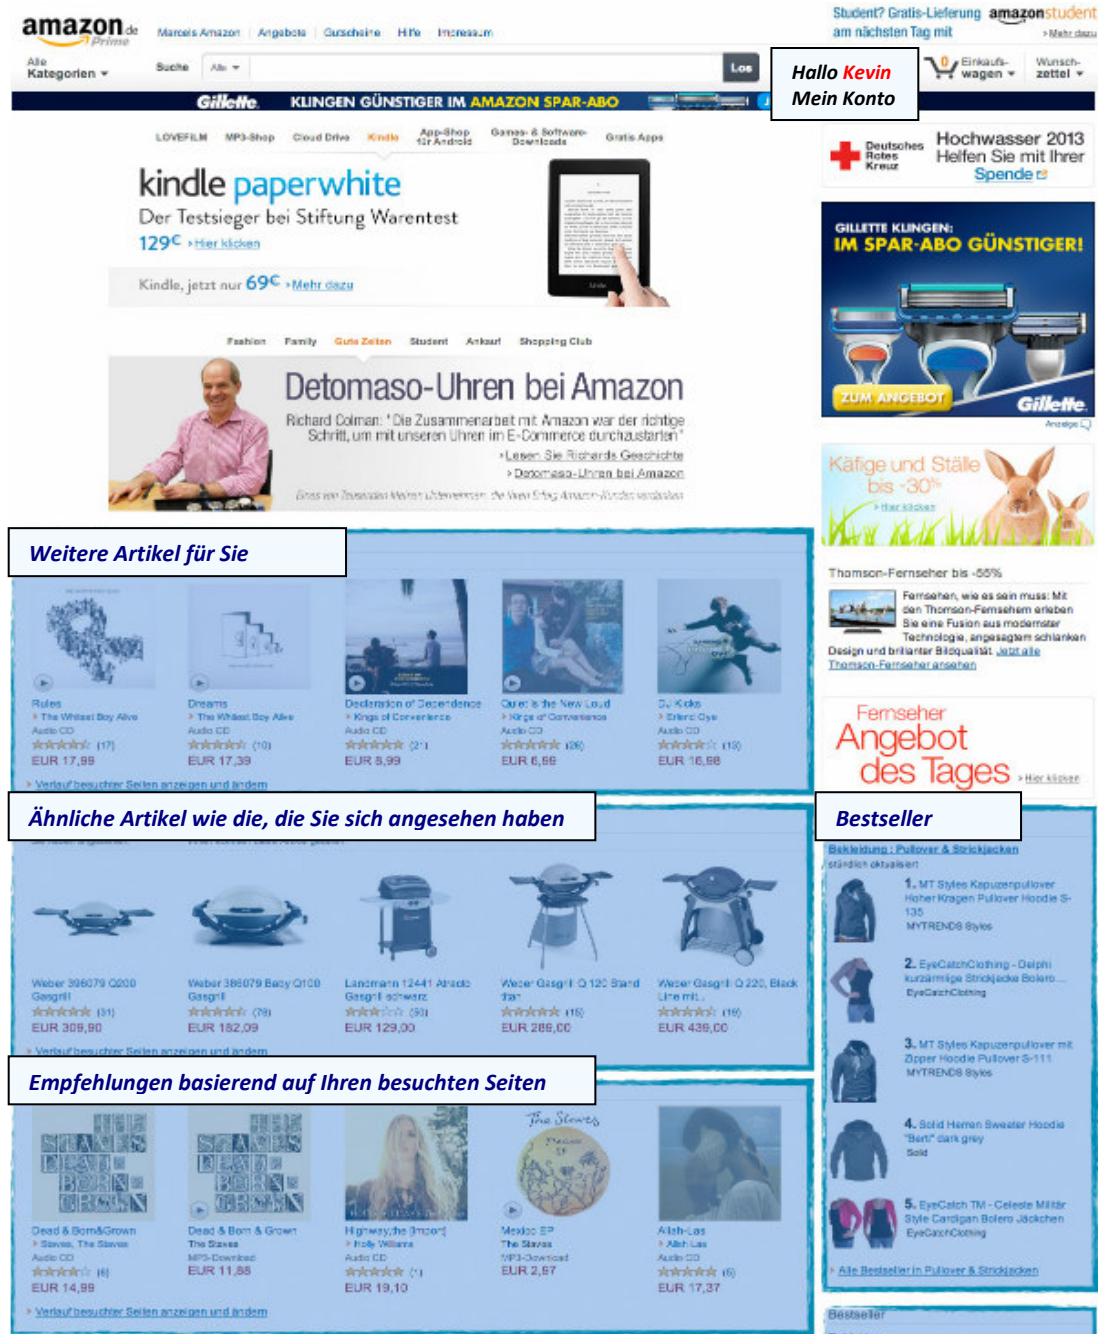


Abb. 2: Amazon-Startseite mit personalisierten Empfehlungen

Ein großer Teil der Startseite wird von Empfehlungen eingenommen, wobei sich mit einem Klick auf das Bild die komplette Seite öffnet.

Die wirtschaftlichen Ziele dieser Maßnahmen liegen dabei klar auf der Hand:

- ⇒ Höhere Warenkorbwerte
- ⇒ Höhere Konversionsrate<sup>11</sup>
- ⇒ Mehr Wiederkäufer
- ⇒ Bessere Kundenbindung
- ⇒ Mehr Umsatz

Eine Infografik von Monetate (siehe IV Anhang 1.) zeigt, dass Empfehlungen so den Warenkorbwert um 50% und den Umsatz sogar um 300% steigern können.

Natürlich klingt das jetzt hervorragend und warum sollte man nicht einfach jeden freien Pixel der Website mit weiteren Produkten zupflastern und sich zurücklehnen sowie sich auf die neuen Umsatzzahlen freuen – leider ist das Ganze aber nicht so einfach.

Man stolpert immer noch viel zu häufig über Onlineshops, in denen Kaufvorschläge und Cross-Selling<sup>12</sup>-Artikel scheinbar wahllos und zufällig eingeblendet werden. Dies geht von völlig irrelevanten und unpassenden Empfehlungen bis hin zu Produkten, die schon ausverkauft sind, wodurch ein riesiges Potenzial verschenkt wird.

## **Fünf Möglichkeiten für erfolgreiche Produktempfehlungen**

Im Folgenden werden fünf Möglichkeiten anhand von Praxisbeispielen vorgestellt, wie Empfehlungen auch tatsächlich zum gewünschten Erfolg führen können.

### **1. Topseller**

Unter den Produktempfehlungen ist die Auflistung der beliebtesten Artikel sicherlich der Klassiker. Nach dem Motto “Was viele kaufen, muss ja auch gut sein” funktioniert dieses Prinzip des Social Proof<sup>13</sup> nach wie vor hervorragend. Beispiele hierfür sind Alben- oder

---

<sup>11</sup> Die Konversionsrate (englisch conversion rate) bezeichnet den Prozentsatz der Personen, die eine nachgelagerte Ebene in einem Bestell- beziehungsweise Kaufprozess erreicht haben. Konversionsraten sind wichtige Kennzahlen zur Messung des Werbeerfolgs und der Effizienz einer Website. (vgl. [45])

<sup>12</sup> Cross-Selling (Querverkauf) ist ein Begriff aus dem Marketing und bezeichnet das Bemühen eines Händlers, zusätzlich zu einem nachgefragten Artikel weitere Produkte oder Dienstleistungen zu verkaufen. (vgl. [47])

<sup>13</sup> Social Proof (soziale Bewährtheit) bedeutet, dass sich Menschen in ihrem Verhalten oftmals am Verhalten anderer Menschen orientieren. (vgl. [37])

Büchercharts, aber auch bei vielen weiteren Produktkategorien ist das ohne Weiteres möglich.

Die Darstellung der meistgekauften Artikel durch Händler mit sehr breitem Produktportfolio würde beim individuellen Besucher aber kaum Relevanz erzeugen. Daher sind Topseller erst auf einer tieferen Entscheidungsebene, die näher am gesuchten Artikel liegen, wirklich sinnvoll.

So zeigt Planet Sports beispielsweise beim Einstieg über die Marke (hier: Nike) zunächst die beliebtesten Artikel des jeweiligen Herstellers und erst darunter die weiteren Angebote.

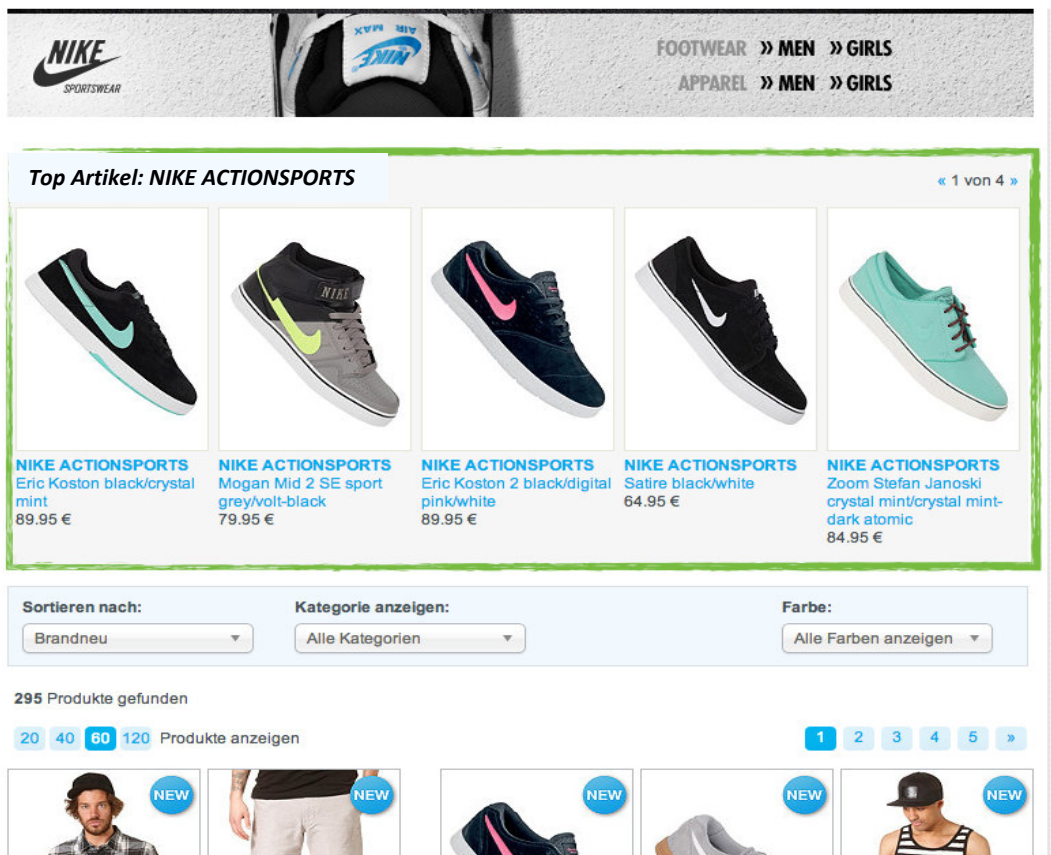


Abb. 3: Planet Sports blendet markenbasierte Topseller ein

Bei der Betrachtung der Topseller sollte jedoch die Theorie Long Tail nicht außer Acht gelassen werden. Hierzu bieten unter anderem [12], [9] einen guten Überblick, an denen ich mich bei der Darstellung des Long Tail orientiere.



Die Long Tail Theorie wurde von Malcom Gladwell ins Leben gerufen. Allerdings trug der US-Journalist Chris Anderson vom Wired Magazin einen bedeutsamen Teil zu ihrer Bekanntheit bei.

Im Zeitalter des Webs sollen demnach Massenmärkte beziehungsweise Topseller an Bedeutung verlieren, während Nischenprodukte immer weiter aufstreben. Dies liege daran, dass im Internet jeder mit geringem Kostenaufwand alle nur denkbaren Produkte anbieten kann – und durchaus auch spezielle Produkte im Regelfall Abnehmer finden. Das Internet bietet somit die ideale Grundlage für den Erfolg von Nischenprodukten.

Angeblich führe der Verkauf von vielen Nischenprodukten im internationalen Kontext wohl sogar zu einem höheren Umsatz als wenige Topseller. Zum Beispiel ist es im Gegensatz zu einem Online-Handel für einen klassischen Musik- oder Buchladen häufig zu teuer, CDs oder Bücher mit geringen Verkaufsquoten anzubieten. Auch die geografisch begrenzte Nachfrage spielt hier eine bedeutende Rolle.

Wie die Theorie Long Tail zu ihrem Namen kam? Dies wird deutlich, wenn man das Kurvendiagramm einer Verkaufsstrategie betrachtet.

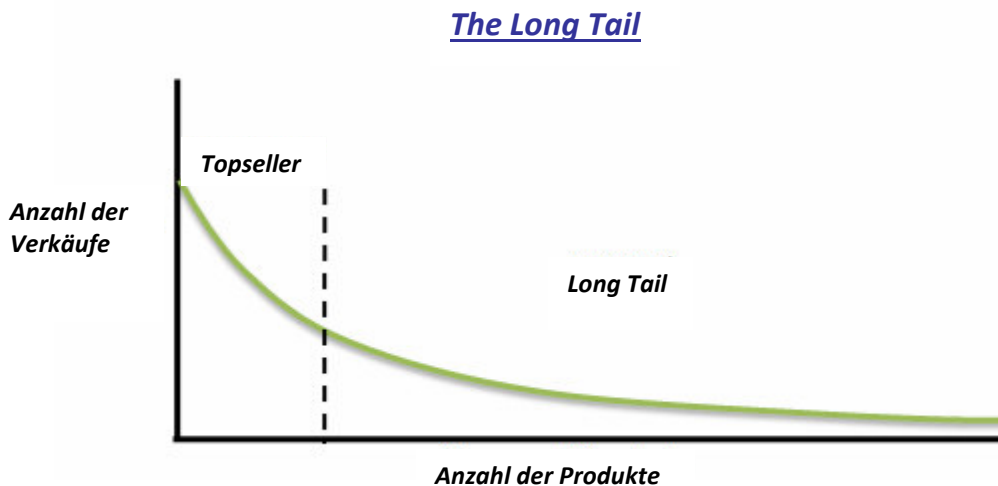


Abb. 4: The Long Tail – Kurvendiagramm einer Verkaufsstrategie

Links reicht die Kurve weit nach oben, denn hier befinden sich die Topseller. Die Verkaufskurve fällt dann jedoch sehr stark ab, um an die X-Achse geschmiegt auszulaufen. Dieser Teil stellt die Verkaufsquote der Nischenprodukte dar und ähnelt einem Rattenschwanz, weshalb die Theorie als Long Tail bezeichnet wird.

## 2. Andere Kunden kauften auch

Mindestens genauso häufig, wie die zuvor genannten Topseller, sieht man Empfehlungen wie “Kunden, die diesen Artikel gekauft haben, kauften auch”. Ob der Einsatz dieser Vorschlagsliste sinnvoll ist, hängt sehr stark von der Positionierung des Anbieters und dessen Sortiment ab. Hier stellt sich zum Beispiel die Frage, wann und ob “von anderen Kunden gekaufte Artikel” überhaupt von Bedeutung sind. Insbesondere bei exklusiven und hochpreisigen Produkten kann dies auch negative Effekte haben. Dort erzeugen eventuell andere Ansätze wie “Unsere Experten (Stylisten) empfehlen” oder “Das könnte Ihnen auch gefallen” beim individuellen Nutzer mehr Aufmerksamkeit.

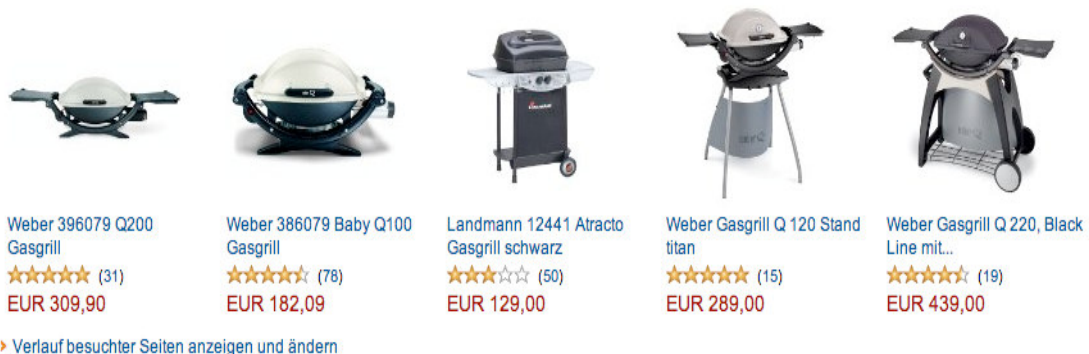
Generell gilt jedoch, dass ein besonders hoher Wert auf die Relevanz gelegt werden sollte. Vollautomatisierte Engines<sup>14</sup> erzeugen dabei oft sehr zufällige und teilweise manipuliert anmutende Produktlisten.






## 3. Basierend auf dem, was Sie sich angesehen haben, könnte Ihnen auch das gefallen

Im Idealfall werden solche personalisierten Listen aus dem individuellen Surfverhalten in Kombination mit dem Kaufverhalten der Gesamtkundschaft generiert. Dies kann sowohl auf Kategorie- und Produktebene eingesetzt werden und hilft, wie hier im Beispiel von Amazon, auf wirklich relevante Alternativen aufmerksam zu machen.

### Ähnliche Artikel wie die, die Sie sich angesehen haben

Sie haben angesehen Ihnen könnten diese Artikel gefallen



				
Weber 396079 Q200 Gasgrill	Weber 386079 Baby Q100 Gasgrill	Landmann 12441 Atracto Gasgrill schwarz	Weber Gasgrill Q 120 Stand titan	Weber Gasgrill Q 220, Black Line mit...
★★★★★ (31)	★★★★★ (78)	★★★☆☆ (50)	★★★★★ (15)	★★★★★ (19)
EUR 309,90	EUR 182,09	EUR 129,00	EUR 289,00	EUR 439,00

[Verlauf besuchter Seiten anzeigen und ändern](#)

Abb. 5: Amazon macht auf relevante Alternativen aufmerksam

<sup>14</sup> Eine Engine (Motor) stellt einen Teil des Programms dar, die Berechnungen durchführen oder Aktionen simulieren soll. Es handelt sich dabei also um ein Software-Paket um Software entwickeln zu können. (vgl. [58])

#### 4. Dazu passende Produkte

Diese Möglichkeit kann besonders bei Modehändlern zu höheren Umsätzen führen. Die Voraussetzung dafür ist natürlich, dass die gezeigten Artikel auch wirklich zum Look passen.

Bei Asos wurde dies sehr gut umgesetzt, so wird zum Beispiel die Hose des Models direkt auf der rechten Seite angezeigt. Hier entsteht der positive Eindruck, dass die Empfehlungen wirklich mit Bedacht und eventuell sogar von Hand eingepflegt wurden.

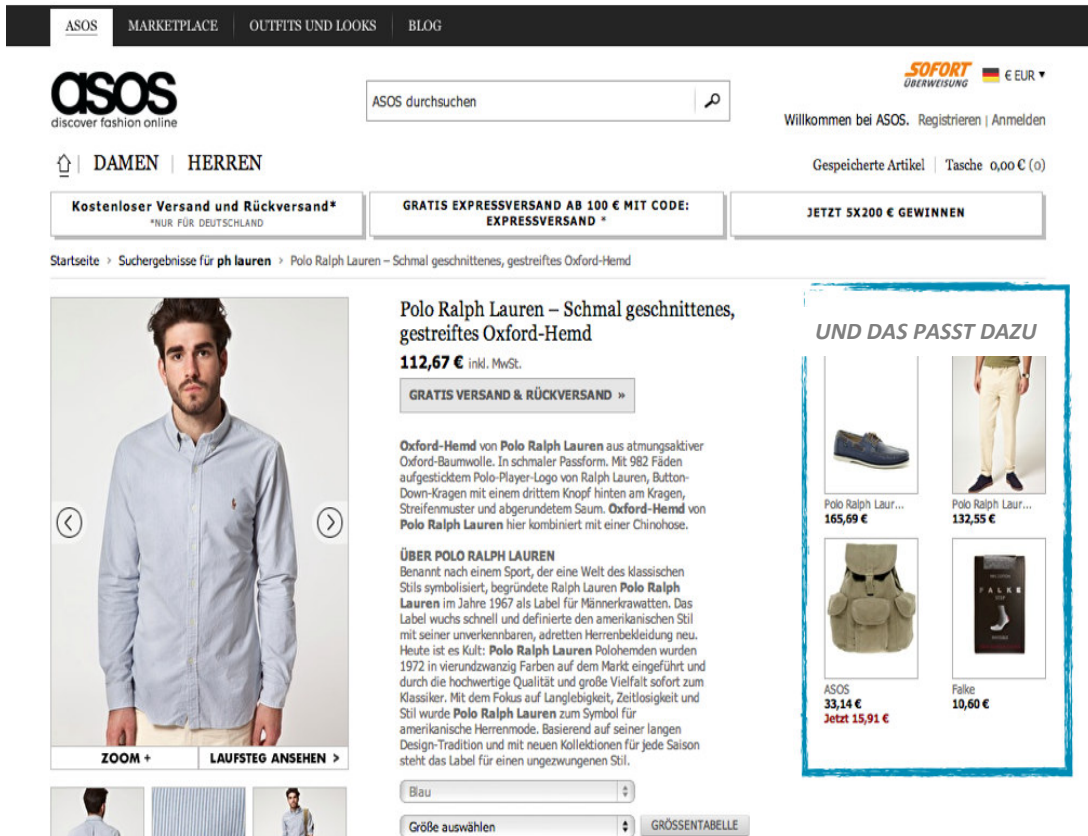


Abb. 6: Asos empfiehlt dazu passende Produkte

#### 5. Produkte kombinieren beziehungsweise komplettieren

Dieser Ansatz führt sogar noch einen Schritt weiter und verfolgt primär das Ziel, ergänzende Käufe zu fördern. Dies funktioniert besonders gut bei technischen Produkten, wo das nötige Zubehör (z.B. die Batterie) gleich mitverkauft wird.

In dem Onlineshop von Görtz werden ebenfalls bekannte Verkaufsprinzipien aus dem klassischen Handel genutzt, um den Gesamtumsatz zu steigern.

Wie beim Schuhkauf im Ladengeschäft bekommt man auch hier das passende Pflegemittel direkt mit angeboten, wodurch sowohl der Warenkorbwert als auch die Kundenzufriedenheit erhöht werden können. Schließlich hat der Anbieter gleich für seinen Kunden mitgedacht.

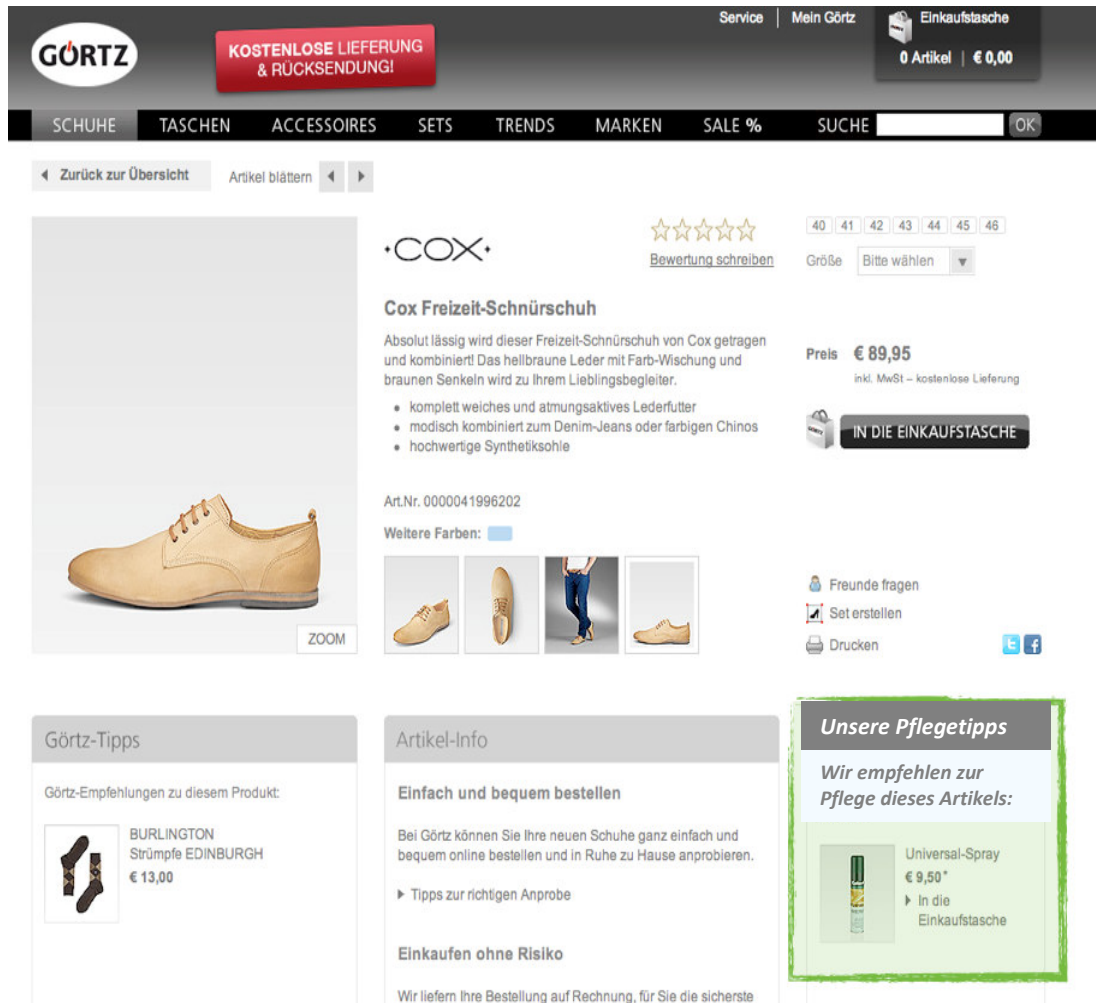


Abb. 7: Im Onlineshop von Görtz wird beim Schuhkauf das passende Pflegemittel mit angeboten

## Fazit zu den fünf Möglichkeiten für erfolgreiche Produktempfehlungen

Schon aus den wenigen Beispielen wird sehr schnell deutlich, dass sich mittlerweile unzählige Formen von Empfehlungen etabliert haben. Es gibt sicherlich noch viele weitere Formen wie zum Beispiel individuelle Konfiguratoren<sup>15</sup> oder Echtzeit-Meldungen, was sich gerade andere Nutzer auf der Website anschauen, um somit die Dringlichkeit zu erhöhen.

Andere Techniken nutzen Targeting<sup>16</sup> und liefern den Content personalisiert und individuell aus. Zum Beispiel könnten dies "Topseller" für neue Besucher und "neu eingetroffene Produkte" für wiederkehrende Besucher sein. Beim Thema Relevanz spielen Keywords natürlich auch eine tragende Rolle.

Unabhängig von der Einsatzform sollte jedoch stets im Mittelpunkt stehen, dass das System kontinuierlich und individuell an die Kundenwünsche, an das Sortiment und an die Positionierung des Shops anzupassen ist.

Auch die Frage, an welchen Stellen der Website Empfehlungen die besten Ergebnisse erzielen, ist nicht pauschal zu beantworten. A/B-Tests<sup>17</sup> zeigen so immer wieder, dass Cross- beziehungsweise Up-Selling<sup>18</sup> an der falschen Stelle auch kontraproduktiv sein kann. Diese zeigen aber natürlich auch, wo es besonders gut funktioniert.

---

<sup>15</sup> Unter Konfigurator ist ein Verkaufswerkzeug im Web zu verstehen, das den Kunden ermöglicht eigene Produkte zu kreieren. Da die Kunden das konfigurierte Produkt sofort sehen können, erhöht sich ihr Interesse an zusätzlichen Informationen und die Webseitenbetreiber haben die Möglichkeit mehr zu verkaufen. (vgl. [30])

<sup>16</sup> Als Targeting bezeichnet man im Online-Marketing-Kontext alle Strategien und Werbekampagnen möglichst genau bestimmten passenden Nutzern zu zeigen und damit Streuverluste zu vermeiden sowie Conversionwahrscheinlichkeiten zu erhöhen. (vgl. [44])

<sup>17</sup> A/B-Testing bietet Unternehmen die Möglichkeit ihre Webseite durch den Vergleich zweier Webseite-Varianten (A und B) Stück für Stück zu optimieren. (vgl. [46])

<sup>18</sup> Unter Up-Selling versteht man das Angebot höherwertiger Produkte zu höheren Preisen im bereits vorhandenen Kundenbestand. (vgl. [64])

Es sollte allerdings vermieden werden alle Techniken gleichzeitig auszuspielen. Dies kann wie hier im Beispiel von H&M möglicherweise eher verwirrend wirken und ablenken, anstatt wie gewünscht weiterzuhelfen.

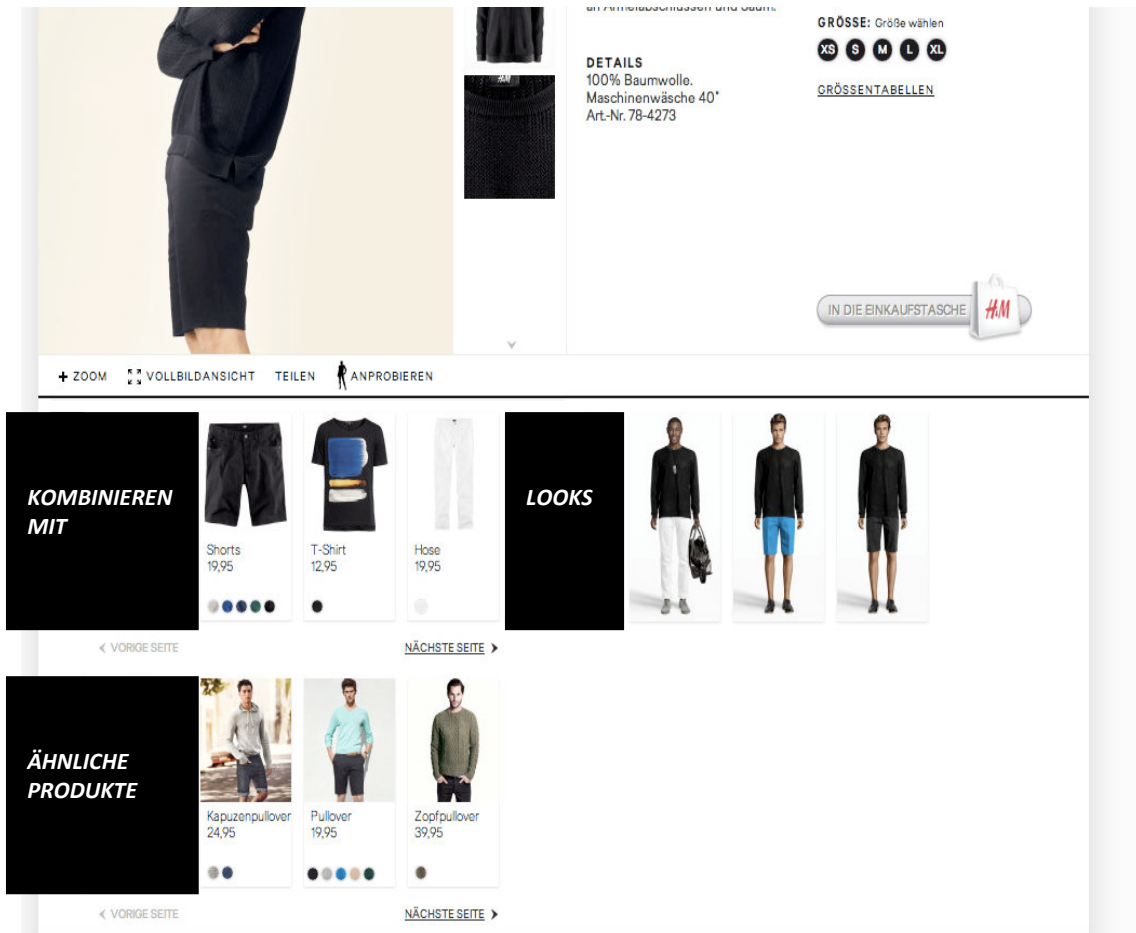


Abb. 8: H&M Website zeigt zu viele verschiedene Empfehlungsansätze, die den Besucher verwirren können

Das gesamte Thema ist ohne Zweifel mit einem hohen Pflegeaufwand verbunden – laut einer Infografik von Monetate (siehe IV Anhang 1.) verbringen Onlinehändler damit im Durchschnitt 25% ihrer Zeit. Das sind mit Sicherheit einige Stunden, die sich aber bei richtiger Herangehensweise definitiv auszahlen werden.

## 2.4.2 Weitere Arten von Empfehlungen

Neben den oben beschriebenen Produktempfehlungen gibt es noch eine Vielzahl weiterer Arten von Empfehlungen. Einen guten Überblick zu sechs weiteren Empfehlungsarten bietet unter anderem [27] anhand von Praxisbeispielen, auf dem die folgende Tabelle 2 basiert.

Empfehlungsart	Beispiel
<b>Textempfehlungen</b>	Die Website der Handwerkszeitung ( <a href="http://www.handwerkszeitung.de">www.handwerkszeitung.de</a> ) empfiehlt dem Nutzer in Abhängigkeit vom aktuell betrachteten Artikeltext ähnliche Texte.
<b>Bildempfehlungen</b>	Bei photoree.com werden dem Nutzer Empfehlungen für Bilder, die auf den Bewertungen anderer Nutzer, die dem eigenen Bewertungsprofil ähnlich sind, vorgeschlagen.
<b>Videoempfehlungen</b>	Movielens ( <a href="http://movielens.umn.edu">http://movielens.umn.edu</a> ) empfiehlt dem Nutzer Filme, die den besten der eigenen Filmbewertungen entsprechen. Die Profile anderer Nutzer werden dabei ausgewertet um entsprechende Filme zu finden.
<b>Audioempfehlungen</b>	Bei Last.fm ( <a href="http://www.lastfm.de">www.lastfm.de</a> ) werden dem Nutzer Musikstücke empfohlen, deren Interpreten ähnlich zu einem gewählten Interpreten sind. Hierbei werden die Profile anderer Nutzer ausgewertet um ähnliche Interpreten zu finden.
<b>Prozessempfehlungen</b>	Bei Foodio54 ( <a href="http://foofio54.com">http://foofio54.com</a> ) werden dem Nutzer nach Eingabe einer Suchanfrage für Restaurants die zum Suchbegriff passenden Restaurants in Anhängigkeit von der Bewertung durch andere Nutzer vorgeschlagen.
<b>Personenempfehlungen</b>	Biomedexperts ( <a href="http://www.biomedexperts.com">www.biomedexperts.com</a> ) liefert dem Nutzer, nach Angabe eines Sachgebietes aus der Medizin, Experten auf Basis der Häufigkeit von wissenschaftlichen Abhandlungen. Dabei kann auch eine geobasierte Visualisierung abgerufen werden um Experten zum Thema zu selektieren.

Tab. 2: Weitere Arten von Empfehlungen

## 2.5 Welche Arten von Recommender Systemen gibt es?

Wie in den zuvor dargestellten Kapiteln deutlich wurde, sind seit dem Problem der Informationsüberflutung im Web zahlreiche Empfehlungsansätze entstanden und vorgeschlagen worden. Die Empfehlungen werden auf der Basis von verschiedenen Algorithmen generiert, wodurch eine neue Art von Problem verursacht wurde: Eine Empfehlungsalgorithmus Überlastung. Einen guten Überblick bietet hierzu unter anderem [7], an dem ich mich bei der folgenden Darstellung orientiere.

Empfehlungsalgorithmen sind typischerweise auf einer Basis von Daten in Kategorien aufgeteilt. Kollaborative Algorithmen geben eine Bewertung über das Verhalten einer Gemeinschaft (z.B. über andere Nutzer), bei dem Prozess der inhaltsbasierten Algorithmen stehen Inhaltsdaten (z.B. Merkmale eines Artikels) zur Verfügung und bei demografischen Algorithmen werden demografische Merkmale genutzt, um den Nutzer in eine bestimmte Gruppe einzuordnen. Demnach versucht jeder dieser Algorithmen auf seine eigene Art, die Nutzer auf relevante Inhalte aufmerksam zu machen.

Bislang hat man sich dabei hauptsächlich auf mathematisch klassische Algorithmen und die Verbesserung von Empfehlungsgenauigkeiten fokussiert, wobei ständig neue Arten von Algorithmen festgestellt wurden.

Neue Trends, wie Social Media und Smartphones, stellen zunehmend neue und komplexe Nutzerdaten bereit. Dies können zum Beispiel Sozialdaten (Verbindungen mit Freunden) oder auch Kontext (Standort, Tageszeit, Stimmung, etc. (siehe hierzu Kapitel 2.2.4)) sein, welche wiederum neue Kategorien in den Empfehlungsalgorithmen bilden und speziell auf diese Daten abzielen.

Während all diese Empfehlungsalgorithmen gegeneinander konkurrieren, wurde jedoch allgemein die Tatsache akzeptiert, dass jeder Algorithmus seinen eigenen Schwerpunkt hat, um optimale Anwendungen zu ermöglichen.

Im Folgenden wird dargestellt, welche verschiedenen Arten von Recommender Systemen es zur Empfehlungsgenerierung gibt. Bevor es jedoch zur Generierung von Empfehlungen kommen kann, bedarf es zunächst erst einmal bei allen Recommender Systemen einer Ähnlichkeits- beziehungsweise Distanzmessung zwischen verschiedenen Objekten.



## Ähnlichkeits- und Distanzmessung

Die Grundlage für jedes Recommender System stellt die Messung der Ähnlichkeit beziehungsweise Distanz zwischen zwei Objekten dar. Einen guten Überblick bieten hierzu unter anderem [10], [8], auf denen die folgende Darstellung basiert.

Die Ähnlichkeit zwischen Objekten wird meist durch eine Distanzfunktion modelliert, die für Paare von Objekten definiert ist. Zur Definition der Distanz zwischen zwei Objekten werden direkte oder abgeleitete Eigenschaften der Objekte verwendet.

In der Literatur wird alternativ zu einer Distanzfunktion manchmal auch eine sogenannte Ähnlichkeitsfunktion verwendet (im Englischen: “similarity function” im Gegensatz zu einer “dissimilarity distance function”). Die Abstände zwischen zwei Objekten werden bei den Funktionen folgendermaßen interpretiert:

Für eine Distanzfunktion gilt folgendes:

⇒ ***Je ähnlicher zwei Objekte sind, desto kleiner ist der Wert.***

Für eine Ähnlichkeitsfunktion lautet die Interpretation umgekehrt:

⇒ ***Je ähnlicher zwei Objekte, desto größer ist der Wert.***

Verwendet man eine Ähnlichkeitsfunktion anstelle einer Distanzfunktion, dann ändert sich die Darstellung der Algorithmen lediglich geringfügig: Im Wesentlichen werden Vergleichsoperatoren umgedreht und vorhandene Minimumsbildungen durch Maximumsbildungen ersetzt und umgekehrt.

Die Definition einer Funktion, die den intuitiven Ähnlichkeitsbegriff geeignet widerspiegelt, kann jedoch sehr schwierig sein. Die Wahl einer konkreten Definition der Distanz beziehungsweise Ähnlichkeitsfunktion zur Repräsentation der (Un-)Ähnlichkeit zwischen Objekten hängt somit stark vom Datentyp der Objekte und der jeweiligen Anwendung ab.

### 2.5.1 Klassifizierung von Recommender Systemen

Im Folgenden werden die unterschiedlichen Arten von Recommender Systemen klassifiziert, die zur Empfehlungsgenerierung verwendet werden. Einen guten Überblick bieten hierzu unter anderem [4], [23], [22], [1], an denen ich mich bei der folgenden Darstellung orientiere.

Empfehlungen können durch Recommender Systeme entweder allgemein (nicht-personalisiert) oder individuell (personalisiert) für jeden Nutzer erstellt werden. Abbildung 9 stellt eine Einordnung von nicht-personalisierten und personalisierten Recommender Systemen dar, wobei die personalisierten Empfehlungsdienste wiederum in Unterklassen (demografische, inhaltsbasierte, kollaborative und hybride Recommender Systeme) aufgeteilt werden können.

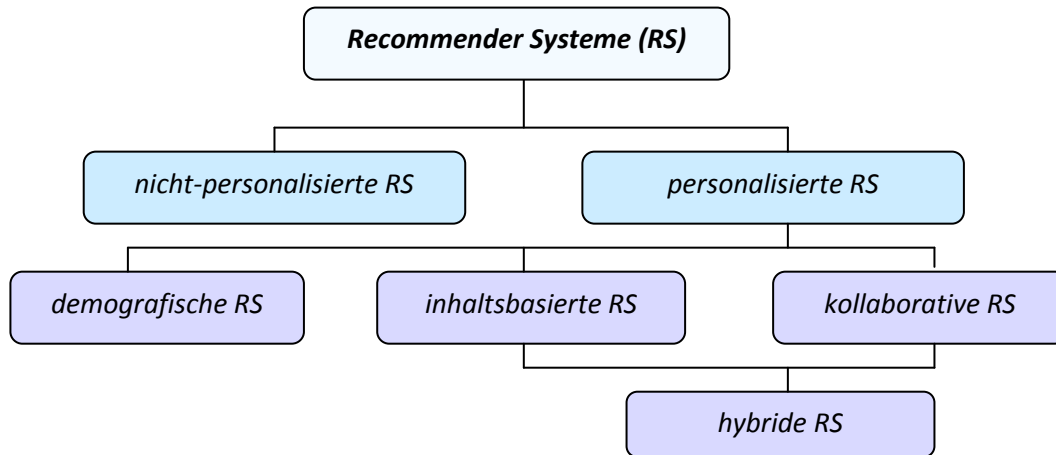


Abb. 9: Klassifizierung von Recommender Systemen

### 2.5.1.1 Nicht-personalisierte Recommender Systeme

Die einfachste Form eines Recommender Systems stellt diese Art dar. Der Nutzer wird durch seine Eingaben zu allgemein gültigen Empfehlungen geführt, bei denen seine individuellen Bedürfnisse unberücksichtigt bleiben. Nicht-personalisierte Systeme bieten daher allen Nutzern identische Empfehlungen an. Die Datenbasis des Systems besteht dementsprechend ausschließlich aus Produktdaten.

Je nachdem, ob eine gezielte Suchanfrage gemacht oder die Produktdatenbank durchforstet wird, unterscheidet sich der Empfehlungsprozess. Der Kunde gibt bei der gezielten Suche Suchdaten in eine Suchmaske ein, woraufhin ihm eine Ergebnisliste (z.B. mit potenziell passenden Produkten) empfohlen wird. In der Regel kann diese nach verschiedenen Kriterien (wie z.B. dem Preis) sortiert oder weiter eingeschränkt werden. Dies kann beispielsweise durch die Eingabe einer Preisspanne oder durch die Festlegung anderer relevanter Produktmerkmale erfolgen. Der Kunde stöbert beim Durchforschen durch vordefinierte Listen, wie beispielsweise Produktkategorien, in welchen wiederum oft Unterkategorien, also weitere Filter gewählt werden können. Dieses Vorgehen erweist sich, je nach Umfang des Produktangebots und Granularität der Filter, für den Kunden als mehr oder weniger zeitaufwändig.

### **2.5.1.2 Personalisierte Recommender Systeme**

Im Gegensatz zu den nicht-personalisierten, werden bei personalisierten Recommender Systemen Kaufempfehlungen vor allem auf Basis des Wissens über den Nutzer (wie z.B. Präferenzen oder Kaufverhalten) generiert. Es werden hierbei also Empfehlungsansätze verfolgt, bei denen Nutzerprofile in die Suche (z.B. nach Produkten) einfließen, um dem Anwender Vorschläge zu liefern, welche für ihn persönlich möglichst relevant sind.

Dieses Verfahren setzt neben dem Einsatz von statistischen, mathematischen sowie wissensbasierten Methoden und Algorithmen insbesondere die Wissens- und Datenbasis voraus, welche sich aus Informationen zum einen über Produkte und zum anderen über Nutzer zusammensetzt. Vor allem stehen dabei die Informationen über den Nutzer im Fokus, da deren Qualität und Quantität entscheidend für die "Güte" der auf das Individuum zugeschnittenen Empfehlungen ist.

Bei personalisierten Recommender Systemen werden entweder direkte Beziehungen zwischen Anwender- und Produktcharakteristika hergestellt (user profile – item matching) oder Ähnlichkeiten und Unterschiede zwischen verschiedenen Nutzern verwendet (user profile matching), um Empfehlungen abzuleiten. Dabei bilden die demografischen (demographic), inhaltsbasierten (content-based) und kollaborative (collaborative) Filter (filtering) die drei Hauptkategorien. In der Praxis wird jedoch auch häufig eine Kombination aus verschiedenen Filtern (z.B. den inhaltsbasierten und kollaborativen Filtern) verwendet, die als hybrides System bezeichnet wird.

#### **2.5.1.2.1 Demografische Recommender Systeme**

Ein demografisches Recommender System erstellt Empfehlungen auf Grundlage der Einordnung eines Nutzers in eine von mehreren demografischen Gruppen, welche auf Basis verschiedener spezifischer Charakteristika (z.B. Alter, Geschlecht, verfügbares Einkommen, etc.) von Bevölkerungsgruppen (z.B. Jugendliche, Studenten, Rentner, etc.) im System durch den Betreiber implementiert werden. Zum Beispiel findet die Einordnung eines Nutzers über die bei der Registrierung im System getroffenen Pflichteingaben (üblicherweise Alter, Wohnort, Beruf, Einkommensklasse, etc.) statt.

#### **Methodische Umsetzung demografischer Recommender Systeme**

Für die Empfehlungserstellung kann beispielsweise eine Regressionsanalyse angewandt werden, bei welcher der Zusammenhang zwischen dem Kaufverhalten einer demografischen Gruppe als unabhängige Variable und der Produktwahl oder auch -nichtwahl als abhängige Variable ermittelt wird. Als Resultat werden dann solche Produkte empfohlen, die auf Basis des Kaufverhaltens einer Gruppe am häufigsten gekauft wurden, aber der konkrete Nutzer selbst noch nicht erwarb.

## **Einschränkungen demografischer Recommender Systeme**

Der unsichere Zusammenhang zwischen den Merkmalen einer demografischen Gruppe und der Produktpräferenz kann sich mitunter als problematisch erweisen. Denn die demografische Datenbasis ist vordefiniert, was zur Folge hat, dass das System statistisch reagiert und sich nur einseitig bezüglich der Produktpräferenzen einer demografischen Gruppe weiterentwickeln kann.

### **2.5.1.2.2 Inhaltsbasierte Recommender Systeme**

Inhaltsbasierte Recommender Systeme funktionieren ähnlich wie demografische Systeme, nur dass das Bilden von Zusammenhängen granularer erfolgt, indem das konkrete Nutzerprofil auf Produkte und deren Eigenschaften bezogen wird. Wie zuvor unter den Kapiteln 2.2.2 und 2.2.3 erläutert wurde, wird das Nutzerprofil anhand von impliziten oder expliziten Feedbacks des Anwenders generiert, modifiziert und erweitert. Implizite Feedbacks werden vom System selbst erhoben, indem das Verhalten (unter anderem Suchverhalten, Kaufverhalten, Bewertungen von Produkten) des Nutzers beobachtet und analysiert wird, während explizite Feedbacks durch Nutzerbefragungen erlangt werden.

### **Methodische Umsetzung inhaltsbasierter Recommender Systeme**

Die Standard Cosine Similarity Function ist grundlegend, denn diese untersucht, inwieweit ein Zusammenhang zwischen einem Produkt und dem Präferenzprofil eines Nutzers besteht, indem die Eigenschaften eines Produktes mit den gewichteten Eigenschaften des Präferenzprofils verglichen werden. Die Tatsache, dass es für gleiche Eigenschaften synonyme Bezeichnungen gibt (z.B. "Computer" gleichzusetzen "PC" oder "Play Station 3" gleichzusetzen "PS3") ist dabei jedoch problematisch. Dieser Problematik kann durch das Latent Semantic Indexing Abhilfe verschafft werden, welches Schlagworten ihren verborgenen Bedeutungsgehalt zuordnet, so dass begrifflich verschiedene Eigenschaften sinngemäß miteinander verknüpft werden. Würde also nach der Eigenschaft "Computer" gesucht werden, so resultierten aus der Suchanfrage ebenfalls Ergebnisse mit "PC".

### **Einschränkungen inhaltsbasierter Recommender Systeme**

Auch wenn dieser Ansatz noch so individuumsbezogen ist, bringt er essentielle Probleme mit sich, da vor allem komplexe Produkte schwierig zu beschreiben sind. Dazu kommt das Problem der Überspezialisierung, bei welchem dem Nutzer Produkte empfohlen werden, die den bereits gekauften sehr ähnlich sind, während andere potenziell für den Nutzer interessante Produkte, die auf Grund von Divergenzen gegenüber dem Nutzerprofil niedriger bewertet wurden, nicht angezeigt werden.

Des Weiteren wird vorausgesetzt, dass ein Anwender das System häufiger benutzt, da ansonsten kein Nutzerprofil aufgebaut werden kann. Hieraus wird auch das sogenannte Kaltstartproblem (siehe hierzu unter Kapitel 2.6 Cold Start Problem) verdeutlicht, wonach ein Recommender System zu Beginn keine individuellen Empfehlungen aussprechen kann, da es keine Kenntnis über das noch unbekannte Individuum hat. Die Produktdaten müssen wiederum sehr genau über ihre Merkmale definiert werden, was ununterbrochen – also für jedes vorhandene, aber auch neue Produkt – einen hohen Aufwand bedeutet. Zudem können dabei lediglich objektive Merkmale hinterlegt werden, während subjektive außen vor bleiben.

Zur Verdeutlichung der objektiven und subjektiven Eigenschaften dient ein Beispiel anhand eines MP3-Players: Beispiele für objektive Eigenschaften sind "Kann OGG-Dateien abspielen, hat ein SVGA-Display", während subjektive Kriterien "sehr hochwertige Verarbeitung, sehr guter Klang und besser als der von Produkt XY, problemlose sowie schnelle Hilfe an der Hotline" wären, welche glaubhaft und vergleichsweise günstig durch die Erfahrungen von Nutzern eingepflegt werden können.

### **2.5.1.2.3 Kollaborative Recommender Systeme**

Die kollaborativen Recommender Systeme berechnen Ähnlichkeiten zwischen Nutzern beziehungsweise zwischen den Bewertungsprofilen der in Beziehung gesetzten Anwender. Hierbei werden also einem Nutzer Produkte empfohlen, die bereits andere Nutzer mit einem ähnlichen Profil positiv beurteilt haben. Diese Art des Empfehlens kann man auch mit der aus dem täglichen Leben bekannten "Mundpropaganda" vergleichen, wobei man sich auf die Empfehlungen von anderen Personen verlässt, die ähnliche Präferenzen besitzen.

Bei diesem Ansatz muss eine entsprechende Datenbasis vorhanden sein, die ebenfalls in Form von expliziten oder impliziten Bewertungen (siehe hierzu Kapitel 2.2.2) aufgebaut wird. Die expliziten Beurteilungen stellen sich dabei in Form von Produktbewertungen dar, wie beispielsweise Rezensionen parallel mit der Bewertung verschiedener Produkteigenschaften (z.B. Komplexitätsgrad und Spiellänge bei Computerspielen). Implizite Informationen lassen sich durch Navigationsverhalten, durch die Auswertung der Verweilzeiten von Nutzern bei einem Produkt, aber selbstverständlich auch durch einen Kauf, da dieser automatisch als positive Bewertung aufgefasst wird, etc., erschließen.

Konkrete Eigenschaften von Produkten bleiben bei diesem Ansatz – im Gegensatz zu den inhaltsbasierten Recommender Systemen – unberücksichtigt, wobei hier zusätzlich subjektive Produkteigenschaften durch die Nutzer selbst abgebildet werden. Die Vorteile dieses Systems liegen darin, dass komplexe Produkteigenschaften wesentlich besser abgebildet werden können und dem Nutzer Produkte empfohlen werden, die nicht seinen bereits gekauften ähneln, da nicht die objektiven Eigenschaften eines Produktes ins

Gewicht fallen (siehe hierzu unter Kapitel 2.5.1.2.2 Problem der Überspezialisierung), sondern die subjektiven.

### **Methodische Umsetzung kollaborativer Recommender Systeme**

Bei den kollaborativen Recommender Systemen ist einer der ersten Ansätze die Memory-based Methode zur Ermittlung von sich ähnelnden Profilen (z.B. unter Verwendung des empirischen Korrelationskoeffizienten). Hierbei wird die gemeinsame Schnittmenge der bewerteten Produkte des aktiven Nutzerprofils mit den jeweils anderen Nutzerprofilen analysiert. Dazu wird das spezifische Nutzerprofil mit jeweils jedem anderen verfügbaren Profil verglichen, wobei je Profil das arithmetische Mittel der vorhandenen Produktbewertungen gebildet und deren lineare Abhängigkeit erschlossen wird. Der Korrelationskoeffizient von zwei verglichenen Profilen kann zwischen -1 und 1 liegen, wobei ein Wert von 1 auf vollkommen identische und ein Wert von -1 auf vollkommen entgegengesetzte Präferenzprofile schließen lässt. Ein Wert von 0 sagt aus, dass gänzlich keine lineare Abhängigkeit der beiden verglichenen Profile besteht, diese also vollkommen unterschiedlich sind. Demnach sollten idealerweise jene Nutzerprofile für die Erstellung von Empfehlungen herangezogen werden, deren Korrelationskoeffizient mit dem Profil des zu beratenden Nutzers möglichst nahe bei 1 liegt. Dazu kommt, dass die Nutzerbewertungen nicht absolut verglichen werden, sondern relativ in Bezug auf die Art und Weise, wie der jeweilige Nutzer bewertet. So mag beispielsweise mancher Käufer in einem Bewertungssystem auf Basis von Schulnoten eine durchschnittliche Note für ein als durchschnittlich empfundenes Produkt vergeben, während ein sehr kritischerer Käufer ebenfalls nur eine durchschnittliche Note für ein als sehr gut oder gut empfundenes Produkt vergibt.

Der Model-based-Ansatz ist hingegen weniger rechenintensiv, welcher Clustering basiert funktioniert. Dabei werden aus einzelnen Kundenprofilen Gemeinsamkeiten ermittelt und über diese Kundensegmente definiert, welche dann entsprechende Modelle darstellen. Bei diesem Verfahren wird dem Einzelprofil des zu beratenden Nutzers das passendste Kundensegment zugeordnet und auf dessen Basis die Empfehlungen generiert. Der Vorteil dieses Ansatzes liegt in seiner Schnelligkeit, da Nutzerprofile lediglich mit Segmenten zu vergleichen sind, welche wiederum offline berechnet werden – im Gegensatz zu den online zu berechnenden Übereinstimmungen des zuvor erläuterten Memory-based Ansatzes. Da jedoch Daten verdichtet und Einzelprofile verallgemeinert werden, leidet die Qualität der Empfehlungen unter diesem Umstand. Es gilt also generell: Je detaillierter ein Segment, desto besser sind tendenziell die generierten Empfehlungen. Damit steigt jedoch auch der rechnerische Aufwand, was letztendlich wieder die Austauschbeziehungen zwischen Qualität und Performanz von Empfehlungen herausstellt.

## **Einschränkungen kollaborativer Recommender Systeme**

Es ergeben sich jedoch auch bei den kollaborativen Recommender Systemen diverse Probleme (siehe hierzu Kapitel 2.6), die teilweise unter das bereits zuvor genannte Kaltstartproblem (Cold Start Problem) fallen. Neue Produkte, bei denen noch keine Bewertungen vorliegen, können auch nicht weiterempfohlen werden (Early Rater Problem). Beim Start des Systems müssen wiederum sowohl die Datenbasen der Nutzer, als auch die der Produkte groß genug sein, damit das System sinnvoll funktionieren kann (Critical Mass Problem). Bei einer sehr großen Datenbasis von Produkten mit relativ wenigen Nutzern, welche die gleichen Produkte beurteilt haben, findet man kaum Nutzer, die ähnliche Präferenzprofile haben (Sparsity Problem). Insbesondere gilt dies für Nutzer, die ein sehr exzentrisches Präferenzprofil besitzen. Dazu kommt, dass die Anwender häufig nicht nachvollziehen können, wie Empfehlungen zustande gekommen sind, was in einigen risikobehafteten Bereichen (z.B. Kapitalanlagen, Medikamente) durchaus kritisch sein kann.

Darüber hinaus können implizit erworbene Informationen das Kundenprofil verfälschen, wenn sie tatsächlich gar nicht zutreffen. Insbesondere die als positiv verstandenen Käufe können sich erst im Nachhinein für den Kunden als enttäuschende Fehlkäufe herausstellen oder gegebenenfalls sind diese gar nicht für den Kunden selbst bestimmt gewesen, da dieser für eine andere Person (z.B. einen Bekannten ohne Internetzugang) den Kauf getätigt hat.

Bei der Memory-based Methode ist der sehr hohe Rechenaufwand jedoch am problematischsten, welcher sich darin begründet, dass sämtliche Profile und die jeweils dahinterstehenden Präferenzdaten untersucht werden müssen. Modifizierte Modelle dieser Methode bieten zwar eine bessere Performanz, jedoch auf Kosten der Empfehlungsqualität.

### **2.5.1.2.4 Hybride Recommender Systeme**

Zuletzt sind die hybriden Recommender Systeme zu nennen, um die Möglichkeit aufzuzeigen, dass die vorhergehenden Ansätze auch sinnvoll miteinander kombiniert werden können, um die vorhandenen Schwächen gegenseitig zu kompensieren und Synergien zu nutzen, was den Kern der hybriden Systeme darstellt.

## Methodische Umsetzung hybrider Recommender Systeme

Als Beispiel sei der weitverbreitete Collaborative via Content Ansatz genannt, bei dem zuerst der Einfluss von Produkteigenschaften auf das Kaufverhalten des Nutzers untersucht wird. Dieser Zusammenhang bildet die Grundlage für das darauf folgende kollaborative Filtern, bei dem Profile von denjenigen Nutzern ausgewertet werden, die sich ähnlich von den Produkteigenschaften beeinflussen lassen. Zum einen wird dadurch das Early Rater Problem (siehe hierzu unter Kapitel 2.6) eliminiert, da gekaufte, aber noch nicht bewertete Produkte weiterempfohlen werden können. Zum anderen erweitert sich das Spektrum an Empfehlungen und verringert das Problem der Überspezialisierung (siehe hierzu unter Kapitel 2.5.1.2.2), da hierbei dank des kollaborativen Anteils dieses Ansatzes nicht ausschließlich die objektiven Produkteigenschaften betrachtet werden.

## Einschränkungen hybrider Recommender Systeme

Problematisch bei dem Collaborative via Content Ansatz ist, dass sich das Sparsity Problem (breite Produktbasis, wenige Nutzer mit ähnlichen Präferenzprofilen (siehe hierzu unter Kapitel 2.6)) im besonderen Maße auswirkt, da die Suche nach passenden Präferenzprofilen anderer Nutzer noch mehr eingeschränkt wird.

### 2.5.1.3 Weitere Arten von Recommender Systemen

Wie in den zuvor dargestellten Kapiteln deutlich wurde, sind seit Beginn der Forschungen zu Recommender Systemen verschiedene Verfahren zur Generierung von Empfehlungen vorgeschlagen und getestet worden, von denen sich das kollaborative Filtern (collaborative filtering) und das inhaltsbasierte Filtern (content-based filtering) als Standards durchgesetzt haben.

Spätestens durch den Netflix Wettbewerb im Jahre 2006, durch den ein verbesserter Filmempfehlungsalgorithmus für die Onlinemediathek Netflix gefunden werden sollte, kam wieder Bewegung in die Forschung und es wurden eine Reihe weiterer Ansätze vorgestellt, die aber größtenteils nicht im großen Stil eingesetzt werden. Einen guten Überblick bieten hierzu unter anderem [53], [22], [5], [18], [38], auf denen die Darstellung dieses Kapitels basiert.



Die folgende Tabelle 3 liefert einen Überblick über fünf weitere Arten von Recommender Systemen.

<b>Recommender Systeme (RS)</b>	<b>Definition</b>
<b>Wissensbasierte RS (knowledge-based filtering)</b>	Wissensbasierte Systeme basieren auf Fachwissen über ein bestimmtes Spezialgebiet und empfehlen basierend auf diesem Wissen Artikel, die den Nutzerbedürfnissen entsprechen.
<b>Nutzenbasierte RS (utility-based filtering)</b>	Beim nutzenbasierten Filtern wird der potentielle Nutzen eines Objektes für einen User errechnet. Die Objekte mit dem höchsten Nutzenfaktor werden dann empfohlen.
<b>Dialogbasierte RS (dialogue-based filtering)</b>	Dialogbasierte Empfehlungssysteme konfrontieren den Nutzer beispielsweise mit einer Reihe von Fragen zu seinem Suchziel und generieren anschließend passende Empfehlungen.
<b>Regelbasierte RS (rule-based filtering)</b>	Regelbasierten Systemen liegt ein starres Regelwerk ("wenn – dann") zugrunde, das die Inhalte den Vorgaben entsprechend für die Nutzer anpasst. Die Empfehlungen sind sehr generalisiert und lassen sich nicht effizient für einzelne Nutzer personalisieren.
<b>Emotionsbasierte RS (emotion-based filtering)</b>	Einen vielversprechenden und bislang nur relativ wenig erforschten Ansatz stellen emotionsbasierte Systeme dar. Emotionen, die mit der Umsetzung bestimmter relevanter Verhaltensweisen einhergehen, sollen dabei erkannt und beeinflusst werden. Dies soll als ein wirkungsvolles Mittel zur Verhaltensmodifikation dienen und im Marketing mit großem Erfolg genutzt werden.

Tab. 3: Weitere Arten von Recommender Systemen

## 2.6 Probleme von Recommender Systemen bei der Empfehlungsgenerierung

Im Folgenden werden die einhergehenden Probleme von Recommender Systemen bei der Empfehlungsgenerierung charakterisiert und analysiert sowie mögliche Lösungsansätze zur Überwindung von Filterproblemen vorgeschlagen. Einen guten Überblick bieten hierzu unter anderem [33], [53], [55], an denen ich mich bei der folgenden Darstellung orientiere.

### Cold Start Problem

Unabhängig davon, welches der zuvor dargestellten Recommender Systeme zur Empfehlungsgenerierung verwendet wird, kann es mit sogenannten Cold Start Problems (Kaltstartproblemen) zu kämpfen haben. Diese treten immer dann auf, wenn noch nicht genügend Informationen über einen Nutzer vorliegen, um für ihn sinnvolle Empfehlungen generieren zu können. Diese Form von Problemen ist daher nicht auf eine bestimmte Art von Recommender System beschränkt.

Nicht-personalisierte Empfehlungen (siehe Kapitel 2.5.1.1) für neue Nutzer sind unproblematisch. Es kommt bei der Anzeige nur darauf an, dass eine genügend große Nutzeranzahl das Produkt überhaupt schon betrachtet, gekauft oder bewertet hat. Informationen über den neuen Nutzer sind dabei nicht notwendig. Sollen dem Nutzer ähnliche Produkte zum gerade betrachteten oder häufig mit diesem zusammen gekauften Produkt empfohlen werden, dann funktioniert dies auch bei neuen Nutzern problemlos, wenn zur Ähnlichkeitsbestimmung (siehe hierzu unter Kapitel 2.5) inhaltliche Kriterien herangezogen werden.

Bei inhaltsbasierten Recommender Systemen (siehe Kapitel 2.5.1.2.2) sind es jedoch die neuen Nutzer, über deren Präferenzen noch nichts bekannt ist und für die das System deshalb keine sinnvollen Empfehlungen generieren kann. Wer noch keine Bewertungen abgegeben und/oder sein Profil vervollständigt hat, für den können keine personalisierten Vorschläge gemacht werden. Je mehr Informationen über die Vorlieben und Abneigungen des Nutzers vorliegen, desto besser sind tendenziell die generierten Empfehlungen. Dies bedeutet jedoch auch, dass Gelegenheitsnutzer unter Umständen nie in den vollen Genuss der Fähigkeiten eines inhaltsbasierten Recommender Systems kommen, weil über ihre Vorlieben zu wenig bekannt ist.

Ebenso wie inhaltsbasierte Recommender Systeme können auch kollaborative Filter (siehe Kapitel 2.5.1.2.3) unter Kaltstartproblemen leiden. Dies ist immer dann der Fall, wenn ein Nutzer noch zu wenige Bewertungen abgegeben hat, um ihn sinnvoll in eine "Nachbarschaft" einzuordnen oder wenn für ein Produkt noch nicht genug Bewertungen vorliegen.

Die demographischen Ansätze (siehe Kapitel 2.5.1.2.1) kommen ohnehin selten als alleiniger Empfehlungsansatz zum Einsatz. Falls doch, setzt ihr erfolgreicher Einsatz zum einen das Vorliegen demographischer Informationen über die Nutzer voraus, zum anderen einen genügend großen Bestand an Bewertungs- beziehungsweise Kaufdaten, der die statistische Auswertung anhand demographischer Kriterien erlaubt.

Generell liegt eine wesentliche Stärke von Filtertechniken darin, dass Inhalte auf besondere Art und Weise extrahiert werden, weil in den Empfehlungsprozess durch eine ständige Neubildung von Informationen veränderte Interessen einfließen. So können zum Beispiel spezifische Produkte empfohlen werden, ohne dass nach ihnen gesucht wurde. Je länger das System besteht und je größer die Menge an Nutzern ist, desto treffsicherer werden Empfehlungen, da die Wahrscheinlichkeit ähnliche Nutzer zu finden steigt.

Da es grundlegend notwendig ist, über ein Minimum an Nutzerprofilen zu verfügen, um sinnvolle Empfehlungen abgeben zu können, schafft die Anzahl der Anwender und das Minimum an Nutzerprofilen eine der größten Schwachstellen in der initialen Phase des Systems. Daher leidet eine Vielzahl der Filtersysteme an den Kaltstartproblemen, da bei neuen Nutzern noch keine Daten für ein Nutzerprofil vorhanden sind. Das System muss somit erst "trainiert" werden, was bedeutet, dass es einige Zeit benötigt bis es die Vorlieben und Abneigungen eines neuen Nutzers kennt und diese effektiv filtern sowie auswerten kann.

### **Critical Mass Problem**

Bevor ein personalisiertes Recommender System angewendet werden kann, bedarf es daher einer kritischen Masse für die ersten Vorschläge. Dazu müssen zunächst sowohl eine möglichst große Anzahl von Nutzerpräferenzen erhoben werden als auch eine ausreichende Anzahl von Produktbewertungen durch den aktiven Anwender abgegeben werden, da das System ansonsten nicht sinnvoll funktionieren kann. In diesem Zusammenhang könnte eine weitere Schwachstelle sein, dass der Nutzer zu Beginn viel zu unpräzise Empfehlungen von einem Recommender System bekommt, sodass er relativ schnell das Interesse an einer solchen Seite verliert und keine weiteren Mühen in die Präzisierungen seines Profils investiert.

### **Sparsity Problem**

Der Begriff Sparsity bedeutet "Spärlichkeit" und spielt auf die Problematik der geringen Ausgangs- beziehungsweise Grunddaten in einer Matrix an. Recommender Systeme werden meist in Bereichen genutzt, in denen eine große Auswahl an Items besteht. Die sogenannte User Item Rating Matrix ist im Allgemeinen sehr spärlich gefüllt, was die Auffindung von Korrelationen zwischen Nutzern sehr schwierig macht. Dieser Aspekt wird auch als

“Leerfeld” Problem in der User Item Rating Matrix bezeichnet, worin jeder Eintrag eine Nutzerbewertung für einen speziellen Artikel darstellt. Gewöhnlich ist diese Matrix spärlich gefüllt, weil einige Felder in der Matrix leer sind. Die Aufgabe der Empfehlungsvorhersage beinhaltet daher auch das Vervollständigen beziehungsweise Füllen der leeren Räume in der Matrix.

Das Problem der Spärlichkeit an Daten kann nicht komplett eliminiert werden, jedoch kann mithilfe von Navigation oder Kaufhistorie eines Nutzers oder Schlüsselwörtern für Objekteigenschaften versucht werden die Auswertung zu erleichtern. Auf der einen Seite ist das Problem der “Spärlichkeit” an Informationen und Bewertungen die treibende Kraft für die Nutzung der Filtersysteme, denn die Kunden möchten einfach keine langwierigen Informationen und Bewertungen lesen. Auf der anderen Seite stellt es eine Herausforderung dar, weil es schwieriger wird ähnliche Nutzer zu finden und Objekte weiterzuempfehlen, dadurch dass nur eine geringe Anzahl an Kunden Bewertungen abgibt.

### **New Item Problem**

Ein signifikantes Problem von Recommender Systemen ist die Vorhersage von Empfehlungen für neu hinzugefügte Artikel. Die Bewertung eines Nutzers über einen neuen Artikel kann nicht mit anderen Bewertungen verglichen werden. Ebenso wenig ist es für das System möglich, Vorhersagen für neue Artikel zu treffen, die bis zu diesem Zeitpunkt von einer ausreichenden Nutzeranzahl weder besucht noch bewertet wurden.

### **New User Problem**

Ein neuer Nutzer gibt Bewertungen über Produkte ab, anhand dieser wird sein Profil erstellt und Empfehlungen für ihn generiert. Zur Lösung dieses Problems sollten dem neuen Nutzer von Anfang an Produkte zur Bewertung vorgeschlagen werden, die ein hohes Maß an Informationen beinhalten, da aus diesen wenigen Bewertungen ein möglichst qualitativ hochwertiges Profil erstellt werden muss. Dazu sollte vor allem eine explizite Datenauswahl erfolgen, die im weiteren Verlauf von den Nutzern gesammelt werden.

Ein Lösungsansatz für das Problem des neuen Nutzerzuganges sind zum Beispiel vordefinierte Nutzerkategorien und die schnelle Zuordnung von neuen Nutzern zu diesen Gruppen. Hierzu erfolgen Fragestellungen an den Nutzer anhand vordefinierter Fragen, um eine Präferenzstruktur aufzeichnen zu können. Dies spiegelt sich in einem sogenannten “Jump-start” des Nutzers wider, ohne dass dieser eine Anzahl an Bewertungen abzugeben hat.

Die ersten Fragestellungen an den neuen Nutzer beinhalten einen Satz an Präferenzmodellen, die sich an demografischen Modellen orientieren oder auch auf bestimmte Attribute beziehen. Die Analyse der gestellten Fragen ermöglicht die adäquate Einordnung des Nutzers in ein passendes Model. Wenn diese Modelle gut und spezifiziert korrekt sind, ermöglicht dies eine hohe Qualität der Datenauswertung sowie eine ausgezeichnete Vorhersage von Präferenzen.

Weitere relevante Techniken stellen Filterbots dar, die zur Überwindung der Startprobleme für neu hinzukommende Artikel bei Filtersystemen dienen. Dabei werden Agenten in das System geschleust, die jeden Begriff im System in Zusammenhang mit deren kontextabhängigen Algorithmus bewerten. Diese Filterbots schaffen für jeden einzelnen Artikel im System Bewertungen und Rankings, um bei der Suche von Nutzern zu helfen, welche sie am interessantesten finden. Diese Methode löst jedoch nicht das gesamte New User Problem.

Es existieren ebenso Untersuchungen bei denen Agenten dazu verwendet werden, Nutzerpräferenzen zu extrahieren und Informationen transparent zu machen. Diese Vorgehensweise hat den Vorteil des Sammelns von impliziten Informationen sowie des Unterstützens von Bewertungen und stellt daher schneller Daten für neue Nutzer zur Verfügung. Die Verwendung dieser impliziten Daten mit den existierenden expliziten Informationen stellt einen vielversprechenden Lösungsansatz dar.

### **Early Rater Problem**

Dieses Problem entsteht aufgrund dessen, weil die Aussagefähigkeit von Bewertungen sehr gering eingeschätzt wird und daher noch nicht repräsentativ ist, weil ein Artikel erst ins Netz gestellt wurde. Demnach können neue Produkte, die von noch kaum einem Nutzer bewertet wurden, auch nicht von einem Filtersystem weiterempfohlen werden. Das System liefert nur einen geringen Wert, da der Nutzer einer der Ersten in seiner "Nachbarschaft" ist, der eine Bewertung für einen Artikel abgibt.

Derzeit hängen viele Filtersysteme von der Uneigennützigkeit anderer Nutzer ab, die dazu bereit sind, Artikel zu bewerten ohne dafür Empfehlungen zu erhalten. Analysten nehmen an, dass das Bewerten an sich jedoch kaum einen Aufwand erfordert. Dennoch ziehen Nutzer eine Verzögerung bei der Bewertung von Objekten in Betracht, weil sie häufig auf ihre "Nachbarn" warten, um diese dann erst mit Empfehlungen zu versorgen. Ohne die Existenz von "Selbstlosigkeit" wird es daher wohl nötig sein, diverse Anreizsysteme einzuführen, um frühzeitige Bewertungen zu unterstützen.

## Black Box Charakter

Filter können einen klassischen Black Box Charakter besitzen, dies heißt, dass das System für den Betreiber nicht genügend Transparenz besitzt und daher die Steuerung verloren geht. Folglich kann die Ausgabe eines Empfehlungsdienstes nicht gesteuert werden.

Es kann keine Prognose für neue Objekte erstellt werden, da hierzu zunächst eine Mindestanzahl von Bewertungen abgegeben werden muss. Dazu kommt, dass Objekteigenschaften auch dann nicht in die Prognose mit einbezogen werden, wenn sie verfügbar oder gar relevant sind. Das Risiko schlechter Empfehlungen durch zufällige Zusammenhänge sollte daher hierbei nicht unterschätzt werden, da bestimmte übereinstimmende Präferenzen nicht zwingend eine Übereinstimmung hinsichtlich anderer Kriterien bedeutet. Diese erzeugten Prognosen werden unter dem Begriff Black Box Charakter klassifiziert, was ganz einfach bedeutet, dass der Empfehlungsprozess nicht besonders transparent ist.

## Lösungsansätze zur Überwindung von Filterproblemen

Die Lösungsansätze zur Überwindung von Filterproblemen lassen sich wie folgt darstellen: Einige Systeme versuchen die Anzahl der Bewertungen zu erhöhen, indem sie das Verhalten von Nutzern beobachten, um andere Bewertungskriterien heranzuziehen. Zum Beispiel ist die Zeit, die sich ein Nutzer mit einem Objekt beschäftigt, ein effektives Kriterium zur Bewertung. Zudem kann die Untersuchung von Nutzerhistorien zur Generierung von Empfehlungen herangezogen werden. Wie zuvor dargestellt, gibt es natürlich noch eine Vielzahl weiterer relevanter Lösungsansätze (wie z.B. Navigation, Kaufhistorie, Schlüsselwörter, vordefinierte Nutzerkategorien, Agenten, etc.), um die frühzeitige Vorhersage von Nutzerpräferenzen zu bestärken.

## 2.7 Nutzerdialog mit Recommender Systemen

Neben den in Kapitel 2.5 dargestellten Arten von Recommender Systemen, die zur Generierungen von verschiedenen Empfehlungen verwendet werden, stellt der Nutzerdialog mit Recommender Systemen einen weiteren relevanten Faktor dar. Einen guten Überblick bietet hierzu unter anderem [57], an dem ich mich bei der folgenden Darstellung orientiere.

Sowohl bei personalisierten als auch bei nicht-personalisierten Recommender Systemen kann man in automatische oder manuell erstellte und "einmalige" beziehungsweise dauerhafte Empfehlungen unterteilen. Der Unterschied liegt dabei vor allem bei dem Aufwand, den der Nutzer zu betreiben hat.

Bei automatisch erstellten Empfehlungen hat der Nutzer keine Eingaben vorzunehmen. Dies steht im Gegensatz zu den manuell erstellten, wo der Anwender erst seine Daten preisgeben muss, um Empfehlungen zu erhalten. Dauerhafte Recommender Systeme erfordern einen eingeloggteten Nutzer um die notwendigen Daten (wie z.B. getätigte Einkäufe) abzuspeichern und dem Anwender somit bei seinem nächsten Login neue Empfehlungen präsentieren zu können. Die Eigenschaft "einmalig" besitzen Recommender Systeme dann, wenn sie sich nur auf eine einzige Sitzung und nicht auch auf frühere Sitzungen beziehen.

### **2.7.1 Methoden von Recommender Systemen**

In der Praxis werden verschiedene Methoden von Recommender Systemen verwendet, die im Folgenden kurz vorgestellt werden und auf [57] basieren.

#### **Attribute-based Recommendations**

Attribute-based Recommendations präsentieren dem Nutzer Produkte anhand syntaktischer Eigenschaften der Artikel. Meistens handelt es sich bei dieser Art um eine manuelle Methode, da der Nutzer selbst die gewünschte Eigenschaft des Produktes eingeben muss. Sie können sowohl "einmalig" als auch dauerhaft sein. Dies hängt je nachdem davon ab, ob die Website die Eigenschaftspräferenzen des Nutzers abspeichert oder nicht.

#### **Item-to-Item Correlation**

Recommender Systeme mit Item-to-Item Correlations basieren auf einer kleinen Anzahl von Produkten, an denen der Nutzer Interesse gezeigt hat. Diese Art der Korrelation kann sowohl automatisch, wenn die Empfehlungen auf der Beobachtung des Nutzerverhaltens basieren, als auch manuell, wenn der Nutzer selbst zusätzliche Informationen über seine Präferenzen abgeben kann, sein. Vor allem sind derartige Recommender Systeme als "einmaliges" System im Einsatz, da keine Informationen über das frühere Kaufverhalten erforderlich sind.

#### **People-to-People Correlation**

Auf People-to-People Correlations basierende Recommender Systeme präsentieren Produkte anhand von Zusammenhängen zwischen den Nutzern, die ebenfalls Artikel von der jeweiligen Website erworben haben. Diese Methode erfährt noch bessere Bekanntheit unter dem zuvor dargestellten Collaborative Filtering (siehe hierzu Kapitel 2.5.1.2.3).

## 2.7.2 Interfaces von Recommender Systemen

Durchaus sind die verschiedenen Methoden eine wichtige Determinante, bei der Betrachtung des Systems in Bezug auf Effektivität, jedoch spielt auch die Umgebung in der ein Recommender System verwendet wird eine große Rolle. Gerade wenn es darum geht so viele Nutzer wie möglich zu erreichen, sind die Interfaces ein sehr wichtiger Faktor. Im Folgenden werden die verschiedenen Interfaces dargestellt, welche auf [57] basieren.

### Browsing

Nutzer ohne genaue Vorstellung über das gewünschte Produkt, wenden sich im Offline-Handel an den Verkäufer, dessen Empfehlungen im Laden häufig erst gesucht werden müssen. Empfehlungen im Online-Shop bringen hier eine Menge Vorteile gegenüber dem traditionellen Offline-Handel. Denn die Qualität und Quantität der Empfehlungen ist dabei nicht vom Wissen des Verkäufers abhängig, so können die vorgestellten Artikel unmittelbar zu den Produktinformationen selbst verlinkt sein. Dem Nutzer kann somit die mühsame Suche nach weiteren Produkten erspart werden. Dieses Interface hilft dabei den vermeintlichen "Surfer" in einen potentiellen Kunden zu verwandeln, da der Nutzer nur wenige Mausklücke vom Bestellen entfernt ist und dadurch die Hürde zum Kauf weitaus niedriger gesetzt ist.

### Simliar Item

Amazons "Costumers who Bought" erlaubt individuellere und spezifischere Empfehlungen. Nutzer werden so auf Produkte hingewiesen, die sie eventuell vergessen haben. Durch diese Methode kann die Produktlinie des Nutzers erweitert und im Idealfall die Zahl der verkauften Güter erhöht werden.

### "Likes" mit und ohne Bewertungen

Immer mehr Beliebtheit erfreut sich die Angabe von "Likes", die andere Nutzer mit oder ohne Bewertung für ein Produkt abgegeben haben. Auf diesem Wege wird die Kaufentscheidung entweder stark gefestigt oder komplett verworfen, abhängig davon ob die angegebenen Referenzen viele positive oder negative "Likes" enthalten. Je mehr positive Ratings ein Produkt hat, desto glaubwürdiger sind diese dann auch. Dieses Feature ist mit der Einholung von Empfehlungen von Verwandten und Bekannten vergleichbar, wodurch die Kaufentscheidung gefestigt und das kognitive Dissonanzverhalten<sup>19</sup> geschwächt wird.

---

<sup>19</sup> Kognitive Dissonanz ist ein negativer Gefühlszustand, den man verspürt, wenn man nicht vereinbare Gedanken, Meinungen, Absichten oder Wünsche hat. Diese kann z.B. auftreten, wenn man sich für den Kauf eines Produktes entschieden hat und nach dem Kauf Informationen erhält, welche die Richtigkeit der Kaufentscheidung in Frage stellen. (vgl. [70])



## Average Rating

Das Average Rating stellt eine sehr einfache Methode dar. Die Nutzer müssen dabei keine großartigen Texte eingeben, sondern bewerten das Produkt anhand eines Punktesystems. Der Durchschnitt der vergebenen Punkte erscheint als Rating neben den Produkten. Die Motive dieser Maßnahme sind wiederum die Umwandlung vom "Surfer" zum Käufer und eine bessere Kundenbindung.

## Top-N List

Sobald genügend Daten über die Nutzerinteressen gesammelt worden sind, ist es möglich für jeden Konsumenten eine individuelle Liste der Top-N Produktvorschläge zu erstellen, die nach seinen persönlichen Vorlieben gereiht sind und für den Nutzer interessant sein sollten. Für den Verkäufer ergeben sich dadurch mehrere Vorteile: Zum einen ist es eine Möglichkeit den "Surfer" in einen Käufer zu verwandeln, indem der Nutzer auf das große Warenangebot aufmerksam gemacht wird, allerdings nur auf jene Produkte, die ihn auch wirklich interessieren. Zum anderen kann der Konsument durch diese Empfehlungen etwaige Zweifel gegenüber den Artikeln ausräumen und so seine Kaufentscheidungen festigen.

## Ordered Search Results

Die Ordered Search Results Recommendations stellen eine andere Variante dar, wobei die Anzahl der Empfehlungen nicht limitiert ist. Der Nutzer erhält diese Empfehlungen wieder in Form einer Liste, welche nach der abgeschätzten Wahrscheinlichkeit, dass sie für ihn von Interesse sein könnten, gereiht werden.

## E-Mail

E-Mail Empfehlungen enthalten neue Produkte beziehungsweise spezielle Angebote, welche die Aufmerksamkeit des Nutzers wecken sollen. Viele Nutzer begrüßen diese Art von Empfehlungen, da sie auf einfachem Wege immer am aktuellsten Stand des Produktsortiments sind. Dieses Merkmal erhöht den Umsatz durch eine höhere Kundenbindung und zeigt einen Anstieg der Wiederbesuchsrate.

### 2.7.3 Recommender Systeme im Online-Marketing

Der Einsatz von Recommender Systemen ist im Online-Marketing mittlerweile weit verbreitet. Durch den immer größer werdenden E-Commerce Markt und der damit steigenden Konkurrenz im Internet, haben sich daher einige Arten von Online-Marketingmaßnahmen in der Praxis etabliert, die im Folgenden beschrieben werden und auf [57] basieren.

#### Arten von Online-Marketingmaßnahmen

Von den verschiedenen Marketingmaßnahmen, die im Internet zur Anwendung kommen, sind wohl die Banner am bekanntesten. Diese Form ist vergleichbar mit Werbeplakaten. Genau genommen bezeichnet ein Banner eine Bildschirmfläche, die für Werbezwecke genutzt wird. Es sind Banner mit verschiedenen Formaten und mit oder ohne Animation im Internet üblich.

Eine weitere Möglichkeit der Online-Werbung sind Unterbrechungswerbungen sogenannte Interstitials. Diese kommen in unterschiedlichen Formen vor: Den Fullsreen Interstitial, das Pop-up beziehungsweise Pop-under und den Überlagerer, welche den Inhalt überlagern und diesen erst nach einer gewissen Zeit wieder freigeben.

Interstitials werden genauso wie Werbeunterbrechungen im Fernsehen empfunden und werden während dessen die Seite mit dem gewünschten Inhalt geladen wird angezeigt.

Beim Pop-up beziehungsweise beim Pop-under ist dies anders. Hierbei öffnet sich ein neues Fenster entweder vor oder hinter dem aktuellen Fenster. Der Unterschied liegt darin, dass es für den User keine Unterbrechung beim Besuch der jeweiligen Website darstellt.

Die dritte Form ist eine Mischung aus Intersititals und Pop-ups, da es großformatige Werbeformen sind, welche die aktuelle Website überlagern, aber nicht so einfach wie Pop-ups weggeklickt werden können, sondern manchmal sogar eine Aktion des Nutzers erfordern.

Weitere Erscheinungsformen des Online-Marketings sind Skyscrapers, Content Integration, Textanzeigen, Keywords, Streaming-Werbung und Newsletter Werbung.

Skyscrapers sind hochkantige Rechtecke mit Werbeinhalt, die an der rechten Seite der Homepage positioniert sind und in der Regel die Länge des Browsers überschreiten, wodurch der Nutzer zu scrollen hat, um das Ende des Skyscrapers zu sehen. Unter Content Integration versteht man die Integration von Inhalten des Werbekunden in die Website des Werbeträgers. Textanzeigen im Internet sind ähnlich zu den Textanzeigen in den Tageszeitungen. Keyword-Advertising kommt bei vielen Suchmaschinen zur Anwendung

und erfolgt durch die Platzierung der passenden Werbung abhängig vom eingegebenen Suchbegriff. Audio- beziehungsweise audiovisuelle Werbeeinschaltungen sind im Web nicht mehr nur noch auf Radio- und Fernsehseiten zu sehen. Diese Form der Internet-Werbung wird Streaming-Werbung genannt. Der Unterschied von Newslettern zu anderen Werbeformen ist, dass nicht der Nutzer zur Website kommt, sondern dass diese zum Rezipienten geschickt werden. Die Newsletter können alle möglichen Werbeformen enthalten.

## 2.8 Eigenschaften von Recommender Systemen

Im Folgenden werden nun noch einmal zusammenfassend die Eigenschaften von Recommender Systemen dargestellt. Einen guten Überblick bietet hierzu unter anderem [57], an dem ich mich bei der folgenden Darstellung orientiere.

In der Regel sind die meisten Recommender Systeme in ihrer Programmierung und Implementierung sehr aufwendig und kostspielig. Dennoch gibt es eine Vielzahl von Faktoren, die für ihren Einsatz sprechen. Jedoch besitzt auch der "menschliche" Verkäufer gegenüber diesen Systemen so einige Vorzüge. Daher werden im Folgenden insbesondere die Empfehlungen im Internet mit denen im Offline-Handel durch Verkäufer verglichen und die daraus resultierenden Auswirkungen für die Kunden deutlich gemacht.

### Aktualität von Daten

Aktualisierungen hinsichtlich Daten, die zum Beispiel das Produktangebot im Web betreffen, können leicht und schnell vorgenommen werden. Der Kunde erhält dadurch die neuesten Informationen über das Produkt, allerdings nur dann, wenn die Unternehmen ihre Website auch immer auf dem aktuellsten Stand halten. Ob es sich dabei um entsprechende Angebote oder um Daten über die Spezifikationen handelt, der Kunde kann somit immer davon ausgehen, dass die Daten aktuell und korrekt sind. Im Offline-Handel sind hingegen teilweise umfangreiche Schulungen des Verkaufspersonals im Umgang mit einem Produkt erforderlich.

### Neutralität vs. Manipulation der Online-Beratung

Methoden basieren auf Logiken, was zur Folge hat, dass keine subjektiven Empfehlungen abgegeben werden können. Dennoch sind die Empfehlungen für einen Kauf durch ein Online-Beratungssystem meist vertrauenswürdiger als die eines Verkäufers, weil dabei keine gegenseitigen persönlichen Emotionen aufeinander treffen. Jedoch sollte auch hier beachtet werden, dass die durch Recommender Systeme verwendeten Methoden von Menschen programmiert werden und ebenso die Gefahr besteht, dass Manipulationen vorgenommen werden.

## **Permanente Verfügbarkeit**

Kunden haben die Möglichkeit an jedem Tag der Woche 24 Stunden lang die Beratung von Recommender Systemen zu nutzen. Im Gegensatz zu einem Geschäft gibt es keine Öffnungszeiten und der Kunde ist nicht von der Verfügbarkeit des Verkäufers abhängig.

## **Schnelligkeit der Online-Beratung**

Bei einer Online-Beratung existieren keine Anfahrtswege. Der Kunde kann sich bequem, von einem wunschgemäßen Ort mit einem beliebigen internetfähigen Gerät, einloggen und sich online beraten lassen. Damit erspart der Kunde sich auch Wartezeiten, die durch eine begrenzte Anzahl an Verkäufern entstehen können. Recommender Systeme sind im Vergleich dazu unbeschränkt nutzbar.

## **Auswertbarkeit von Statistiken**

Das Internet bietet eine schnelle und einfache Möglichkeit Statistiken zu erstellen. Über Logfiles<sup>20</sup> lassen sich Kundenbedürfnisse und -präferenzen einfach erfassen und analysieren. Dieser Faktor ist besonders für Unternehmen ein wichtiges Feature, da diese Statistiken gegenüber herkömmlichen Statistikverfahren mit objektiven Daten erstellt werden, weshalb man den Auswertungen auch mehr Glauben schenken darf.

## **Verlust des sozialen Faktors**

Der soziale Faktor geht beim Online-Kauf verloren. Der erhebliche Vorteil bei Verkäufern im Offline-Handel ist nämlich, dass dieser auf den Kunden gezielt reagieren kann. Die meisten Empfehlungssysteme können Emotionen, Gestiken, Mimiken, etc., in der Regel nicht erkennen und dementsprechend auch nicht auf diese eingehen. Während dessen der Verkäufer vielleicht schon das Interesse oder Nicht-Interesse des Kunden an einem Produkt erkannt hat, noch bevor dieser es überhaupt ausgesprochen hat, sind programmierte Recommender Systeme von den Eingaben eines Users abhängig.

---

<sup>20</sup> Ein Logfile ist eine Datei mit der Prozesse, die in Computern und Netzwerken ablaufen, aufgezeichnet werden. Logfiles sind wichtige Informationsquellen, um die aktuelle Situation in einem Netzwerk zu erfassen oder um das Nutzerverhalten von Web-Besuchern zu analysieren. (Quelle: [25])

## **Abhängigkeit von der Kundenaktion**

Bei Recommender Systemen sind die meisten Methoden von den Eingaben der User abhängig. Eine Vielzahl von Konsumenten gibt zum Schutz ihrer persönlichen Daten oder aus anderen persönlichen Motiven falsche Angaben an, was ein Empfehlungssystem stark in seiner Effektivität beeinträchtigen kann. Vielen Kunden fällt es leichter ein System "anzulügen", als einer anderen Person falsche Daten zu geben. Während Online-Beratungssysteme von der User-Aktion abhängig sind, das heißt auf die Eingabe des Users warten, kann der Verkäufer von sich aus auf den Konsumenten zugehen und so bereits verkaufsfördernd handeln.

## **Sicherheit im Internet**

Die Frage der Sicherheit im Internet spielt im Allgemeinen eine große Rolle. Viele Nutzer sind mit der Materie nicht sehr vertraut und lesen häufig in Zeitungen oder anderen Medien, dass das Internet für illegale Handlungen verwendet wird. Daher weigern sich viele Konsumenten persönliche Daten über das Internet Preis zu geben. Nur wenn das notwendige Vertrauen des Kunden gewonnen werden kann, wird er sich sicher fühlen, um korrekte Angaben zu machen.

## 3 Filter Bubble

Das Streben von Internetfirmen, ihre Dienste (z.B. Suchresultate und Nachrichten) auf die persönlichen Vorlieben der Nutzer hin anzupassen, hat laut dem Internetaktivisten Eli Pariser eine gefährliche, nicht intendierte Folge: Die Nutzer werden in einer Filter Bubble eingeschlossen und nicht mehr mit Informationen konfrontiert, die ihre Weltsicht herausfordern oder erweitern könnten. Eli Pariser legt daher in seinem Buch "Filter Bubble: Wie wir im Internet entmündigt werden" dar, dass sich dies letztendlich für die Nutzer als schädlich erweisen würde. Die meisten Nutzer fühlen sich jedoch sehr wohl in einer solchen Filter Bubble, weil sie sich darin nur noch mit bekannten beziehungsweise vertrauten Informationen umgeben und somit ihre "kleine heile Welt" erleben. Einen guten Überblick bieten hierzu unter anderem [51], [61], [54], [15], [32], [66], an denen ich mich bei der Darstellung zur Filter Bubble orientiere.

### 3.1 Was ist eine Filter Bubble?

Im Jahre 2011 prägte der Internetaktivist Eli Pariser den Begriff "Filter Bubble" (Filterblase oder Informationsblase). Seine These lautet, dass Websites und Suchmaschinen dem User vorrangig personalisierte Informationen zeigen, die ihn in seinem bestehenden Weltbild bestätigen – ihm aber keine neuen oder anderen Sichtweisen bieten. Grundlage der Personalisierung seien die bereits zuvor gestellten Suchanfragen des Users, sein Surfverhalten oder auch sein Standort.

## 3.2 Wie entsteht eine Filter Bubble?

Nach Eli Pariser entsteht eine Filter Bubble durch den (exzessiven) Einsatz von Filteralgorithmen zur Personalisierung von Webangeboten. Nimmt man alle Filter aus den gesamten Webangeboten die jemand genutzt hat, so ergibt sich daraus eine persönliche Filter Bubble. In dieser spiegelt sich – wenn die Qualität der Algorithmen tatsächlich funktioniert – der Nutzer mit seinen Interessen und Präferenzen wider. Die Blase enthält nur Informationen, die von den Filteralgorithmen für relevant befunden werden. Diesen Prozess hat Eli Pariser in Abbildung 10 visualisiert.




Abb. 10: Prozess der Filter Bubble

Im Zentrum der Filter Bubble befindet sich der Nutzer, der von unterschiedlich großen Blasen umgeben ist. Die Namen der von ihm genutzten Dienste umschließen die Filterblase und repräsentieren ihm darin lediglich eingegrenzte, personalisierte Informationen. Die individuelle Filter Bubble des Nutzers enthält insofern nur Informationen, welche die Anbieter für ihn als relevant und interessant herausgefiltert haben. Außerhalb der Blase befindet sich der große Rest an Informationen, die für den Nutzer ausgeblendet werden und somit für ihn nicht oder nur über Umwege zugänglich sind.

Es ist jedoch offensichtlich, dass kein Nutzer alle verfügbaren Informationen aus dem Web aufnehmen und verarbeiten kann, weshalb wahrscheinlich immer eine Art der Filterung notwendig sein wird.

Wichtig ist jedoch hierbei zwischen der beschriebenen Filter Bubble, die durch Algorithmen bestimmt wird, und der selbstbestimmten Filterung, die wir selber täglich vornehmen, zu unterscheiden.

Bei der selbstbestimmten Filterung entscheiden die Nutzer selbst, ob sie sich mit einer bestimmten Zeitung, einer bestimmten Fernsehsendung, bestimmten Menschen mit denen sie interagieren, etc., beschäftigen möchten. Daher setzt die selbstbestimmte Filterung Entscheidungen voraus und erlaubt den Nutzern dennoch einen gemeinsamen Bezugsrahmen mit anderen zu teilen.

Bei der durch Algorithmen bestimmten Filter Bubble wissen jedoch vermutlich viele Nutzer nicht, dass ein solcher Prozess überhaupt stattfindet und sie sich ganz alleine in ihrer Filter Bubble befinden.

### **3.3 Was versteht man unter der persönlichen Komfortzone innerhalb einer Filter Bubble?**

Der Nutzer begibt sich sozusagen innerhalb einer Filter Bubble in eine persönliche Komfortzone. Einen guten Überblick bieten hierzu unter anderem [19], [20], an denen ich mich bei der Darstellung zur Komfortzone orientiere.

Doch was versteht man eigentlich genau unter der persönlichen Komfortzone?

*“Die persönliche Komfortzone ist jener Bereich, in dem wir uns sicher fühlen, uns wohlfühlen. Sie ist das Umfeld, das wir kennen und gewohnt sind. Und sie endet dort, wo Überwindung und/oder Anstrengung beginnen und es nicht mehr bequem ist.”*

In vielen Medien wird immer wieder nahegelegt die persönliche Komfortzone zu verlassen. Aber wozu sollte dies eigentlich gut sein? Schließlich bedeutet das Verlassen der Komfortzone nach der oben genannten Definition “Überwindung und/oder Anstrengung”. Diese sollen sich jedoch angeblich auszahlen, indem das Verlassen der Komfortzone wesentlich zur persönlichen Entwicklung beiträgt und somit eine Voraussetzung für den persönlichen Erfolg darstellt.

Jeder Mensch verfügt über eine individuelle Komfortzone, da die Grenzen, wo das sichere Gefühl aufhört und die Überwindung beginnt, unterschiedlich verlaufen. Das Überschreiten dieser Grenzen soll daher ein unwohles Gefühl verursachen, weil das gewohnte Umfeld verlassen wird. Das Komfortzonenmodell unterteilt das menschliche Tun und Handeln, verbunden mit dem Wohlbefinden, in drei relevante Zonen.



Dieser Prozess wird in Abbildung 11 verdeutlicht, wonach jeder Mensch, neben seiner Komfortzone, über eine Lern- oder Wachstumszone sowie eine Gefahren- oder Panikzone verfügt.

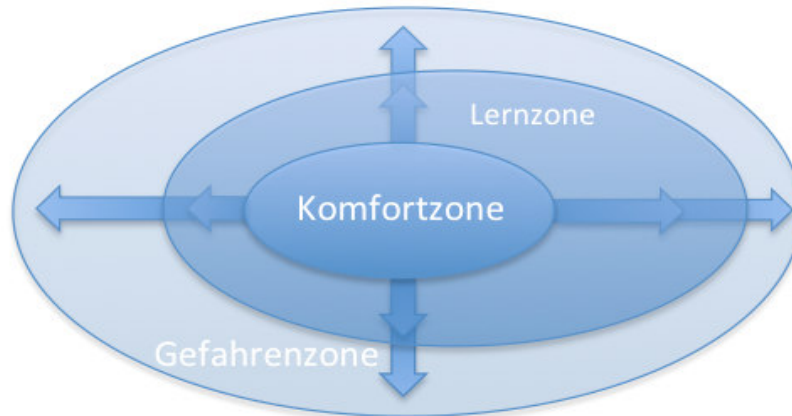


Abb. 11: Prozess zur Überwindung der persönlichen Komfortzone

### **Komfortzone**

In der Komfortzone befinden wir uns in dem Bereich unseres Lebens, der ebenso als der gewohnte oder angenehme Bereich beschrieben werden kann. Hier finden wir unseren gewohnten Tagesablauf vor, aber auch unser Denken in unseren gewohnten Mustern. Da wir uns in dieser gewohnten und für uns als sicher definierten Zone meist sehr wohlfühlen, kommt es häufig vor, dass wir vor dem, was außerhalb unserer Komfortzone liegt, Angst haben.

Das tragische ist, dass wir teilweise unglaublich gut darin sind, diese Angst zu rationalisieren. Das Gehirn verwendet dafür sogenannte Vermeidungsstrategien (Tipp: Vermeidungsstrategien umgehen). Wir beginnen uns Gründe zu überlegen, warum wir dieses oder jenes nicht tun sollten. Das Resultat kann zum Beispiel das Abschieben von Verantwortung oder auch das Ablehnen von Risiken sein, die uns jedoch in unserer Persönlichkeitsentwicklung (Tipp: Persönlichkeitsentwicklung – Der Weg zu einem glücklich Ich) weit voran gebracht hätten.

### **Lernzone**

Sobald wir uns dazu motiviert haben das Sofa zu verlassen und neue Wege zu betreten, sind wir bereits in der Komfortzone unterwegs. Insofern erleben wir bereits in der Lernzone unsere physischen und psychischen Grenzen. Wir beginnen damit unsere alten Denkweisen zu hinterfragen und uns für Neues zu öffnen. Dabei bieten uns unsere Kenntnisse und Fähigkeiten aus der Komfortzone eine solide Basis.

Allerdings ist der Schritt in die Lernzone stets mit einer emotionalen Belastung verbunden, da es einen ungewohnten Schritt ins Ungewisse bedeutet. Die Kunst liegt jedoch allein darin, es zu machen, und es immer wieder zu tun, denn dadurch erweitern wir unsere Komfortzone und lernen dazu. Das hilft uns wiederum, uns für neue Chancen und Wege zu öffnen, die uns ohne diese Veränderung entgangen wären.

## **Gefahrenzone**

Wenn wir uns in der Gefahrenzone befinden, haben wir die Komfortzone bereits so weit verlassen, dass es unser innerstes Verlangen ist, so schnell wie möglich wieder in die Komfortzone zurückzukehren. Die Gefahrenzone wird daher auch häufig als Panikzone beschrieben, da wir in dieser Zone teilweise panikartige Zustände annehmen.

## **Fazit zur Überwindung der persönlichen Komfortzone**

Wenn wir uns selbst soweit kennengelernt haben und verstehen, warum der Körper sich zunächst gegen bestimmte Anstrengungen wehrt und vor allem auf welche Weise, so ist es für uns auch einfacher nachzuvollziehen, dass dies nicht unbedingt bedeutet eine gewisse Sache nicht zu tun. Es ist lediglich ein Signal des Körpers, das uns sagt, dass etwas außerhalb der persönlichen Komfortzone liegt und wir einen Lernprozess zu bestreiten haben.

Wenn wir uns dessen bewusst sind und aktiv versuchen die Komfortzone zu erweitern, dann werden wir beispielsweise nicht nur mehr Respekt von unseren Mitmenschen erhalten, sondern erreichen auch beruflich wesentlich mehr, als wenn wir uns ein Leben lang ständig innerhalb unserer Komfortzone bewegen. Daher sollten wir für uns selbst abwägen, ob wir nicht doch versuchen die persönliche Komfortzone Schritt für Schritt zu erweitern – denn die Belohnung dafür kann unglaublich vielseitig sein.

## **3.4 Ist eine Filter Bubble nützlich oder schädlich?**

Die vorangestellte Frage lässt sich nicht binär beantworten. Wie zuvor unter Punkt 3.2 dargestellt, findet Filterung im Internet nicht nur durch Algorithmen statt, sondern auch durch die Nutzer selbst. Man könnte behaupten, dass es für die Nutzer gar keine Alternative zu einer Filterblase gibt, da die Aufnahme und Verarbeitung aller verfügbaren Informationen aus dem Netz nicht möglich ist. Insofern sollten Filterblasen doch grundsätzlich als nützlich oder gar unverzichtbar eingestuft werden.

Bei den individuellen Filterblasen, die Eli Pariser beschreibt, ist die Einstufung jedoch nicht mehr so trivial. Denn die Kontrolle über die Filter liegt derzeit nur bei den Anbietern, der Nutzer hat in der Regel keinen Einfluss auf die Arbeitsweise oder Kenntnis über die

Faktoren, welche die Filterung beeinflussen. Da die Nutzer für die Filterung voneinander unterschieden werden müssen, besteht wohl derzeit nur die Möglichkeit über Anonymisierung den Personalisierungsfiltren zu entgehen. Die Nutzer haben also nur die Wahl zwischen Personalisierung durch Softwarefilter (von denen sie nicht wissen wie diese arbeiten), keiner Filterung (durch Anonymisierung, sofern eine konsequente Anonymisierung überhaupt noch möglich ist) oder Boykott beziehungsweise Verzicht (was aufgrund der Durchdringung des Alltags durch Webdienste für die meisten Nutzer eine schwere und unrealisierbare Alternative sein dürfte).

Laut Eli Pariser propagieren die Befürworter der Personalisierung eine auf den Kunden maßgeschneiderte, angenehme Welt – in der man sich nur noch mit den Personen, Dingen und Ideen beschäftigt die einem genehm sind. Es lässt sich gut nachvollziehen, wie Filter unsere individuellen Erfahrungen formen, wenn wir uns diese als eine Art Informationsdiät vorstellen. Die Soziologin Danah Boyd sagt in einer Rede der Web 2.0 Expo im Jahre 2009 folgendes:

*“Unsere Körper sind darauf programmiert, Fett und Zucker zu konsumieren, weil diese in der Natur selten vorkommen... Genauso sind wir biologisch darauf programmiert, bestimmte Reize zu beachten: abstoßende oder grausame Inhalte und beleidigendes, beschämendes und bloßstellendes Gerede. Wenn wir nicht aufpassen, entwickeln wir das psychologische Äquivalent zur Fettleibigkeit. Wir konsumieren Inhalte, die für uns selbst und die Gesellschaft als Ganzes höchst unvorteilhaft sind.”*

So wie das System der Nahrungsproduktion beeinflusst, was wir zu uns nehmen, so beeinflusst die Dynamik unserer Medien, welche Informationen wir konsumieren. Derzeit wechseln wir sozusagen zu einer Diät, die reich an persönlichen wichtigen Informationen ist. Dies kann zwar bis zu einem gewissen Grad hilfreich sein, irgendwann aber kann es echte Probleme bereiten und die Menschen in ihrer Entwicklung hindern.

Zudem weist Pariser darauf hin, dass die neuen Gatekeeper<sup>21</sup> in ihrer Macht gestärkt werden würden, jedoch die Theorien der einzelnen Anbieter über das was eine Person beziehungsweise Persönlichkeit ausmacht, zum Beispiel Interessen und Neigungen, bestimmt sehr verschieden sind und allesamt nicht ausreichen, um alle Facetten einer Persönlichkeit zu erfassen. Es bilden sich Doppelgänger von den Nutzern, welche diese jedoch nur unzureichend widerspiegeln, aber auf deren Grundlage die Filter Bubble in der wir leben bestimmt wird. Die Filterblase beeinflusst unseren Blick auf die Welt und unsere Persönlichkeit derartig, dass die Nutzer gegebenenfalls dem digitalen Doppelgänger ähnlicher werden.

---

<sup>21</sup> Ein Gatekeeper wird auch als Torwächter oder Schleusenhüter bezeichnet. Es ist die gängige Beschreibung für die Rolle eines Journalisten im Nachrichtenfluss. Ein Gatekeeper ist demnach ein Entscheidungsträger, der den Nachrichtenfluss kontrolliert. (vgl. [56])

Eli Pariser meint, dass die Filter Bubble in ihrer jetzigen Ausprägung durch die starke Personalisierung sowohl für den Einzelnen als auch für die gesamte Gesellschaft eher schädlich ist. Dennoch sollte an dieser Stelle festgehalten werden, dass die Filteralgorithmen beim richtigen Einsatz (zur Bewältigung der Informationsflut, gesteuert durch die Nutzer) durchaus auch sehr hilfreich sein können.

### **3.5 Macht uns das Internet durch die Filter Bubble immer engstirniger?**

Google nutzt sie und Facebook auch: Die Algorithmen. Im Duden werden sie als Rechenvorgänge mit einem bestimmten, sich wiederholenden Schema definiert. Im Zusammenhang mit diesen Algorithmen haben sich eine Reihe von Fragen aufgetan: Halten sie uns im Internet in einer Filter Bubble mit bestimmten Informationen gefangen? Sorgen sie dafür, dass wir immer engstirniger werden?

Eli Pariser führt ein Beispiel an: Gibt ein liberal eingestellter Zeitgenosse bei Google "BP" ein, so erhielte er eher Treffer zum Thema Ölverschmutzung. Startet jedoch ein konservativer Kollege dieselbe Suchanfrage, so bekäme er vorrangig Treffer zur Finanzsituation eines Unternehmens. Beide User bekommen somit zu der gleichen Suchanfrage völlig unterschiedliche Ergebnisse – je nachdem, wo ihr persönliches Meinungsbild liegt.

Pariser meint, dass dieser isolierende Blaseneffekt negative Folgen für den Einzelnen als Individuum als auch die gesamte Zivilgesellschaft haben könnte, indem Menschen sich in ihren individuellen Filterblasen komplett isolieren und dadurch andere Informationen im Internet, die sich außerhalb ihrer Filter Bubble befinden, nicht mehr wahrnehmen. Dies würde folglich dazu führen, dass uns das Internet durch die Filter Bubble immer engstirniger macht. Es gibt jedoch auch gegenteilige Meinungen, die besagen, dass die Algorithmen nützlich für die User sind und der Filterblaseneffekt minimal und leicht handhabbar sei.

### **3.6 Meinungsvielfalt vs. Relevanz – wo liegen eigentlich die Präferenzen von Google und Facebook?**

Google und Facebook möchten den Nutzern Informationen liefern, die interessant und relevant für sie sind. Deshalb nutzen sie unter anderem Algorithmen: Sie berechnen, was die Nutzer bisher gelikt oder gesucht haben, wo sie gerade sind oder mit wem sie wie häufig online interagiert haben.

Bei Facebook sieht man daher die Posts relevanter Freunde im eigenen Newsfeed<sup>22</sup> öfter, als die von weniger relevanten Freunden. Für Google hat das ganz erhebliche Vorteile: Wohnt man in Hamburg und googelt zum Beispiel "Pizzaservice", bekommt man vorrangig Lieferdienste der Hansestadt angezeigt und eben keine aus einer anderen Stadt. Aber warum können solch einseitige Informationen riskant sein? Um diese Frage zu beantworten, reisen wir im nächsten Kapitel in die Zeit der alten Griechen...

### 3.7 Warum können einseitige Informationen riskant sein?

Doch was haben eigentlich die alten Griechen mit der Filter Bubble zu tun? Und zwar eine ganze Menge, denn die Dialektik ist eine philosophische Methode und kann auf Platon zurückgeführt werden: Eine Meinung wird durch eine gegensätzliche Behauptung infrage gestellt, These ("Ja") trifft auf Antithese ("Nein"). In der Synthese (= Vereinigung) beider Positionen, wird eine höhere Erkenntnis gewonnen, wodurch These und Antithese miteinander verknüpft und ihre Widersprüche aufgehoben werden. Diese höhere Erkenntnis ist jedoch nur möglich, wenn die Antithese sichtbar wird. Abbildung 12 spiegelt den Prozess der Dialektik mit den entsprechenden Komponenten wider.

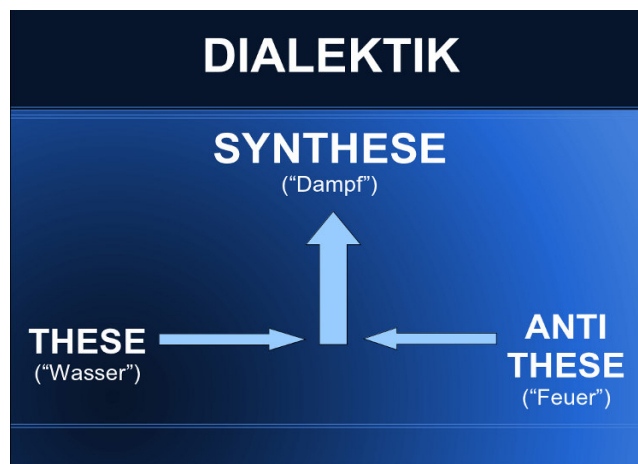


Abb. 12: Prozess der Dialektik

Würde Google also tatsächlich nur Treffer liefern, welche die eigene Meinung stützen, so bliebe der Erkenntnisgewinn auf der Strecke. Die Folge davon wäre einen beschränkten Horizont zu besitzen.

<sup>22</sup> Ein Newsfeed kann frei mit Nachrichtenstrom übersetzt werden. Über ihn stellt ein Anbieter im Internet einem Nutzer fortlaufend Informationen über Neuigkeiten aller Art bereit. (Quelle: [43])

### 3.8 Ist die dialektische Erkenntnis eine Holschuld des Users?

Ob in der digitalen oder in der analogen Welt, die dialektische Erkenntnis ist eine Holschuld und wird dem User daher nicht auf dem Teller serviert. Wer wirklich an höherer Erkenntnis interessiert ist, hat sich für die Antithese zu interessieren. Vermutlich hat bereits jeder von uns eine Filter Bubble bei sich eingebaut, da Menschen in der Regel stärker auf Informationen reagieren, die sie in ihrer Auffassung bestätigen.

Deshalb ist es wichtig, sich ganz bewusst mit anderen Meinungen auseinanderzusetzen, auch wenn sie weit entfernt von der eigenen Auffassung liegen. Ein Beispiel hierfür wäre, dass ein Online-Leser manchmal im "Focus" blättert, obwohl ihm "Der Spiegel" viel besser gefällt.

### 3.9 Wie groß ist die Gefahr der Filter Bubble tatsächlich?

Die Filter Bubble Theorie von Pariser bekam viel Gegenwind zu spüren. Experimente mit politisch völlig unterschiedlich eingestellten Testpersonen zeigten, dass keine gravierenden Unterschiede in den Suchergebnissen existierten.

Auch Google selbst beteuert, vielfältige Suchergebnisse zu garantieren. Es hält sich aber ebenso bis heute die Kritik, dass Google jedes User-Suchverhalten tracken<sup>23</sup> würde, selbst dann, wenn die Person gar kein Google-Konto besitzt.

### 3.10 Algorithmen im Internet und keine Auswege aus der Filter Bubble?

Parisers Idee hinsichtlich der Filter Bubble war, ein freies Internet, in dem die Informationen ungehindert und von jedem gleichermaßen erreicht werden können. Infolge einer unsichtbaren Lenkung des Informationsflusses durch Algorithmen geraten die User jedoch in eine Welt, in der ihnen das Internet Inhalte zeigt, von denen es glaubt, dass sie diese sehen wollen. Neben dem damit einhergehenden Kontrollverlust haben User nur noch eine beschränkte Sicht auf das Internet.

Zum Beispiel können Freunde aus der eigenen Facebook-Timeline verschwinden, die interessanterweise eine konträre Meinung vertreten. Das aber wohl bekannteste Beispiel für algorithmische Veränderungen sind die zuvor dargestellten personalisierten Suchergebnisse bei Google. Eine standardisierte Google-Suche gibt es nicht und dazu

---

<sup>23</sup> Ein Tracker liest, dokumentiert und analysiert das aktuelle Verhalten von Nutzern im Web. Dabei findet "Tracking" vor allem bei Webseiten und mobilen Geräten Anwendung. (vgl. [3])

kommt auch noch, dass Google seine Algorithmen geheim hält – schließlich basiert das Geschäftsmodell des kalifornischen Suchmaschinenbetreibers darauf.

So beschrieb der Wissenschaftssoziologe René König bei einer Wikimedia-Veranstaltung in Berlin, dass die Nutzer von Google oder anderen Suchmaschinen nur die Spitze des Informations-Eisbergs und nicht das Deep Web zu sehen bekommen würden. Das Internet beziehungsweise Google entscheidet häufig auf Basis bereits gespeicherter Informationen was wir sehen und erzeugt damit eine Anpassung an das vorherige Verhalten. Über fünf Jahre hinweg zeigte König anhand einer empirischen Studie zur Suche nach dem Schlagwort "9/11", dass ein Algorithmenwechsel das Ranking stark beeinflusst und die User so gut wie nichts darüber erfahren.

Diese Einschränkung führt laut Pariser zu einer Filter Bubble, die ein kleines persönliches Informationsuniversum darstellt. Wir entscheiden jedoch nicht selbst, was Teil unserer Filterblase ist und sehen nicht, was außerhalb geschieht. Das Ideal wäre daher wohl eine ausbalancierte Zusammenstellung von Themen, die welche wir sehen wollen, solchen außerhalb der eigenen Interessenbereiche und allen anderen verfügbaren Inhalten. Diese Balance kann jedoch durch die aktuell vorhandenen Algorithmen, die auf Grundlage des individuellen Nutzungsverhaltens entscheiden, nicht entstehen. Pariser kritisiert die Einflussnahme durch algorithmische Gatekeeper, die seiner Meinung nach keine journalistische Ethik besitzen. Deshalb fordert er mehr Transparenz für die Nutzer, damit sie die Kontrolle über die Inhalte ihrer eigenen Filter Bubble gewinnen.

### **3.11 Droht uns die Filter Bubble Online und Offline?**

Falls die vorangestellte Frage mit "ja" beantwortet werden würde, so werfen sich erneut Fragen auf: Wie finden wir wieder aus der Filter Bubble heraus? Oder haben die Informationsblasen womöglich auch Vorteile? Unabhängig davon wie die Antworten lauten, eins steht fest: Die gefilterten Inhalte als auch die von den Algorithmen gelenkten User erfordern Mediensouveränität.

Die von Wikimedia initiierte Veranstaltung im Rahmen der Diskussionsreihe Digitale Kompetenzen machte deutlich, dass die Annahmen von Eli Pariser relativiert werden sollten. Denn Parisers Thesen sind sehr stark auf die technische Ebene des Internets fokussiert, obwohl wir ebenso innerhalb von Offline-Filtern agieren.

Die Kommunikationswissenschaftlerin Saskia Sell verdeutlichte mit dem Slogan "Journalismus is watching for you", dass es ebenso in den Offline-Medien Gatekeeper gibt. Dazu kommt die stark selektive Aufmerksamkeit für bestimmte Medien sowie eine individuelle Akzeptanz und Erinnerung an diese. Als Grundlage für die Auswahl der Medien spielen Faktoren wie eigene Interessen, Erfahrungen oder persönliche Betroffenheit eine

Rolle. In der Regel neigen Menschen sehr stark dazu, sich mit Gleichgesinnten zu umgeben und sich dadurch auf das eigene Meinungsbild zu beschränken.

Sell provozierte deshalb bewusst mit der Frage, ob die Filter Bubble eine "Bedrohung" sei. Schließlich hat der algorithmische Filter auch durchaus Vorteile mit sich gebracht: Die Nutzer finden durch Suchmaschinenfilter schnell passende Ergebnisse, erhalten Kaufempfehlungen oder Newsfeeds – alles personalisiert und individuell passend. Daher kann der Aufbau einer solchen Blase insbesondere in sozialen Netzwerken vorteilhaft sein. Laut Sell seien die Alternativen zur algorithmischen Filterung ein Informationsüberfluss oder eine hegemoniale Öffentlichkeit. Ganz so einfach ist dies natürlich nicht, denn wünschenswert ist der umfassend informierte neugierige Bürger, der sich ebenso mit anderen als nur mit der eigenen Position befasst. Dieses Idealbild greift jedoch viel zu selten.

Die Erweiterung oder Zerlegung der Filter Bubble ist auch im politischen Bereich wichtig. Denn die bestehenden Filter können für eine Stärkung der eigenen Position und für soziale Zugehörigkeit sorgen. Die Möglichkeiten der Filter Bubble haben sich im Laufe der Zeit extrem ausgeweitet. Es stellt sich nun vielmehr die Frage, wie die Nutzer mit diesen zwar umfangreichen, aber undurchsichtigen Möglichkeiten umgehen.

### **3.12 Gibt es Auswege aus der Filter Bubble?**

Die Frage, ob es Auswege aus der Filter Bubble gibt, ist bislang nicht zur Genüge beantwortet worden. Es gibt natürlich verschiedene Möglichkeiten, um eine solche Blase zu umgehen: Man könnte die eigene Filter Bubble ausweiten, ihr aus dem Weg gehen oder sie platzen lassen. Der radikalste – und gleichzeitig auch unrealistischste – Ausweg wäre der komplette Online-Entzug. Wie hilfreich dies jedoch wäre, sei dahingestellt.

Zur Ausweitung der Online-Filterblase empfiehlt Saskia Sell, die Blase zumindest zeitweise zu verlassen und sich auch offline umzuschauen, sei es um auf andere Menschen zu treffen oder neue Impulse zu gewinnen. Auch in der medialen Welt ist dieser Weg bereits angekommen: So zeigen spezielle Apps dem Nutzer, wie lange er das Smartphone genutzt hat, oder erinnern ihn daran, Pausen von der digitalen Welt einzuhalten.

Eine weitere Möglichkeit, die Filter Bubble zu umgehen, wäre die Nutzung kleinerer Anbieter von sozialen Medien und Suchmaschinen. Auch gesetzliche Änderungen zur Förderung von mehr Transparenz auf den bekannten Plattformen sind denkbar, die zunächst definiert und durchgesetzt werden müssten. René König rät jedoch von einer gesetzlich verpflichtenden Offenlegung der Algorithmen ab, weil dadurch das Manipulationsrisiko steigen würde.



Es gibt verschiedene Alternativen und Tricks, um die Filter Bubble zu durchlöchern oder sie sogar zum Platzen zu bringen: Diese reichen von grundlegenden Sicherheitseinstellungen (wie dem Deaktivieren der Personalisierung auf Google), über die Nutzung alternativer Suchmaschinen (wie DuckDuckGo), bis hin zum Ausschalten von Trackern durch Add-ons<sup>24</sup> (wie Ghostery).

René König sieht zudem die Förderung von Medienkompetenz als relevanten gesellschaftlichen Faktor an. Denn deren Erwerb führe zu dem wohl am besten und zeitnah praktikierbaren Ausweg: Zu einem souverän handelnden User.

### **3.13 Förderung von Medienkompetenz und proaktiven Usern**

Das Ideal eines aktiv, gebildeten und sich den Auswegen aus der Filter Bubble bewussten Users ist im Internet leider nicht immer gegeben. Schließlich bedeutet dies erst einmal Aufwand zu betreiben, auf bequeme Dienste von Google zu verzichten, alternative soziale Netzwerke zu finden und Tracker auszuschalten. Dazu kommt, dass man diese Möglichkeiten auch kennen muss und in der Lage ist diese anzuwenden – dennoch könnte sich der Weg dahin lohnen.

### **3.14 Kriterien eines guten Recommender Systems unter Berücksichtigung des Filter Bubble Problems**

Im Rahmen dieser Arbeit sollen die Kriterien, welche ein gutes Recommender System – unter Berücksichtigung des Filter Bubble Problems – ausmachen, erarbeitet werden.

Der Einsatz von Recommender Systemen ist jedoch nicht so ganz einfach, weil man dabei eine Reihe von Dingen zu beachten hat. Im Folgenden werden daher lediglich vier der wichtigsten Kriterien eines guten Recommender Systems dargestellt. Einen guten Überblick bietet hierzu unter anderem [57], an dem ich mich bei der folgenden Darstellung orientiere.

---

<sup>24</sup> Ein Add-on ist eine Erweiterung eines Programms. Zum Beispiel erlaubt es den Zugriff auf Funktionen des Programms, erweitert, ergänzt oder nutzt sie. Bei Add-ons handelt es sich also um Unterprogramme, die nur in Zusammenhang mit dem Hauptprogramm funktionieren. (vgl. [71])

Tabelle 4 zeigt die vier wichtigen Kriterien, welche ein gutes Recommender System ausmachen. Die Begründung der Kriterien sowie die Berücksichtigung des Filter Bubble Problems folgen im Anschluss an die Tabelle.

<b>Kriterien eines guten Recommender Systems</b>	
<b>Menge an Daten</b>	Mit dem Datenvolumen über Produkte und Nutzer, die in der Datenbank gespeichert sind, wird die Empfehlungsqualität gesteigert.
<b>Berücksichtigung des Nutzertyps</b>	Durch die Berücksichtigung des Nutzertyps kann eine mögliche Überforderung dessen verhindert werden.
<b>Individualität der Empfehlungen</b>	Durch individuelle Empfehlungen kann die Nutzerbindung gesteigert werden.
<b>Nachvollziehbarkeit der Empfehlungen</b>	Empfehlungen erscheinen glaubwürdiger, wenn sie begründet sind und dadurch nachvollziehbar werden.

Tab. 4: Kriterien eines guten Recommender Systems

### **Menge an Daten**

Ein guter Berater zeichnet sich durch umfassendes Fachwissen, nicht nur mit allgemeinen Informationen, sondern auch im speziellen über die Produkt- und Nutzerdaten, aus. Der Vorteil von Online-Beratungssystemen liegt in der einfachen Anbindung an Datenbanken und somit der Möglichkeit auf einfachem und schnellstem Wege detailliertes Fachwissen abzurufen. Je höher die Qualität und Quantität der Daten über die Produkte und Nutzer aus der Datenbank, umso bessere Empfehlungen können generiert werden. Dadurch können dem Nutzer die besten Produktempfehlungen gegeben werden, wodurch die Wahrscheinlichkeit, dass das Produkt die Anforderungen des Nutzers erfüllt, steigt und somit auch gleichzeitig die Zufriedenheit des Nutzers. Eine hohe Zufriedenheitsrate führt nicht nur zu einer hervorragenden Mundpropaganda und damit vielleicht zu weiteren potentiellen Nutzern, sondern ebenso zu einer höheren Nutzerbindung.

## **Berücksichtigung des Nutzertyps**

Ein Recommender System sollte die unterschiedlichen Nutzertypen beachten. Dadurch kann man folgende zwei Möglichkeiten in Betracht ziehen, die den "Surfer" zum Käufer wandeln und die Nutzerbindung erhöhen können.

Aus der einen Sicht spielt die Berücksichtigung des Nutzertyps vor allem bei Systemen, wo die Anwender selbst eine Eingabe vornehmen müssen, eine große Rolle. Ein Produktlaie wird bei Eingabemasken, die den Vorstellungen eines Produktexperten entsprechen, überfordert sein.

Aus der anderen Sicht kann man durch die Berücksichtigung des Nutzertyps den Verkauf gezielt fördern. Zum einen gibt es Personen, die zum Beispiel eher überlegt handeln und sich vor dem Kauf genau über etwaige Alternativen informieren. Zum anderen gibt es auch jene Personen, die eher impulsiv handeln und der Kauf von speziellen Angeboten abhängig gemacht wird.

## **Individualität der Empfehlungen**

Je höher der Personalisierungsgrad, das heißt je mehr die Empfehlungen auf den jeweiligen Nutzer zugeschnitten sind, desto wohler wird sich der Anwender fühlen. Durch Empfehlungen, die den Vorstellungen des Nutzers entsprechen und auch vor allem bei Systemen, welche die Daten und Gewohnheiten des Nutzers speichern und somit die Empfehlungen auf individueller Basis abgeben, steigern das Interesse und das Vertrauen in das Unternehmen. Die Folge ist eine höhere Wiederbesuchsrates und somit eine Steigerung der Nutzerloyalität.

Unterschieden wird hier vor allem bei Empfehlungen, die sich am Nutzer orientieren, das heißt, denen entweder das Verhalten des Nutzers oder die von dem Anwender eingegebene Daten zugrunde liegen. Vorschläge, die aufgrund von gewählten Produkten ausgegeben werden, sind für jeden Nutzer gleich und besitzen somit keinen individuellen Charakter.

## **Nachvollziehbarkeit der Empfehlungen**

Das System sollte dem Nutzer die Produkte mit einem dazugehörigen Empfehlungsgrund präsentieren, da eine Empfehlung ohne Begründung das Vertrauen in das Produkt nicht stärken kann, erst dann wird die Empfehlung auch glaubwürdig. Laut einer Studie von der University of California konnte so festgestellt werden, dass Empfehlungen, die nachvollziehbar waren und daher begründet waren, eine bessere Anerkennung fanden als jene ohne Begründung.

## **Berücksichtigung des Filter Bubble Problems bei den Kriterien eines guten Recommender Systems**

Die zuvor dargestellten vier Kriterien eines guten Recommender Systems, sollten in jedem Fall berücksichtigt werden, unabhängig davon, ob man eine Filter Bubble als nützlich oder schädlich ansieht. Denn dadurch kann es einem Recommender System gelingen optimal zu funktionieren und seine angestrebten Ziele zu erreichen:

- ⇒ Eine individuelle bzw. nachvollziehbare Empfehlungsgenerierung für die Nutzer
- ⇒ anhand eines umfangreichen Datenvolumens (über die Produkte und Nutzer),
- ⇒ um die Nutzerzufriedenheit/-loyalität zu steigern
- ⇒ und gleichzeitig höhere Unternehmensumsätze zu erzielen.

Somit kann eine Win-Win-Situation<sup>25</sup> für beide Seiten geschaffen werden. Bei der Entscheidung, ob ein Nutzer in seiner Filter Bubble bleiben möchte oder nicht, kommt es lediglich darauf an, welche Art von System der Anwender bevorzugt beziehungsweise verwendet und wie die darin implementierten Algorithmen programmiert sind. In welche Richtung sich der User dann durch die Algorithmen lenken lässt, hängt insofern von seinen individuellen Präferenzen ab.

Mit großer Wahrscheinlichkeit gibt es Systeme, die versuchen einen Nutzer so gut wie möglich in seiner Filter Bubble zu halten. Ein gutes Beispiel hierzu stellt die weltweit etablierte Location App Foursquare dar, die dem Nutzer meist Empfehlungen für bekannte beziehungsweise vertraute Standorte auf Basis seiner Vorlieben, Bewertungen, etc. oder denen seiner Freunde liefert (siehe hierzu Kapitel 4.1).

Durchaus gibt es aber auch Systeme, die versuchen einen Nutzer aus seiner Filter Bubble herauszuholen. Ein gutes Beispiel hierzu stellt die erfundene innovative Location App Swap Meet dar, die versucht, durch neue geheime beziehungsweise unbekannte Standortvorschläge und das Kennenlernen anderer Menschen, den Nutzer so gut wie möglich aus seiner Filter Bubble herauszulockern.

Die innovative Location App Swap Meet wird im folgenden Kapitel 4 näher erläutert und anschließend im Fazit im Hinblick auf die einzelnen Recommender Systeme (aus dem Kapitel 2.5 ff.) anhand der zuvor dargestellten Kriterien untersucht, wobei dieser zum Vergleichszweck die Location App Foursquare gegenübergestellt wird.

---

<sup>25</sup> Der Begriff Win-Win-Situation kommt ursprünglich aus dem Englischen, wobei diese ein Geschäft oder einen Informationsaustausch abbilden kann. Das bedeutet, dass durch das Geschäft für jede Seite ein höherer Nutzen generiert wird, als er an Kosten verursacht hat – beziehungsweise durch eine Zusammenarbeit mehr Vorteile auf beiden Seiten erreicht werden konnten, als ohne Zusammenarbeit. (vgl. [14])

## 4 Beispiel: Swap Meet

Zur Veranschaulichung eines möglichen Lösungsansatzes des Filter Bubble Problems dient ein Beispiel, die erfundene innovative Location App namens Swap Meet, welche im Rahmen eines Projektes im Studiengang Next Media an der Hochschule für Angewandte Wissenschaften Hamburg durch drei Studentinnen (Christin Nax, Svenja Butenschön und mir, Deniz Örnek) erarbeitet wurde. Einen guten Überblick bietet hierzu unter anderem [50], an dem ich mich bei der Darstellung zu Swap Meet orientiere.

Damit Menschen lernen sich aus ihrer alltäglichen Routine und somit ihrer Filter Bubble beziehungsweise persönlichen Komfortzone herauszubekommen und neue Entdeckungen zu machen, entwickelten wir im Team den Prototyp Swap Meet in Form einer App. Dabei sollen sich Menschen digital miteinander vernetzen und über neue Erfahrungen austauschen können. Das Ziel hierbei ist, neue geheime Orte zu entdecken sowie unterschiedliche Menschen kennenzulernen.

Viele Menschen verfallen häufig in ihren Alltag, weshalb der Prototyp Swap Meet geschaffen wurde. Dieser soll jedem Nutzer ein gutes Gefühl beim Entdecken neuer Orte und Kennenlernen anderer Menschen geben und so die Lebensqualität steigern.

In der vorliegenden Arbeit stelle ich zunächst die Ideen unseres Projektteams zu unserem Prototyp Swap Meet vor und erläutere dann dessen Entwicklung. Bei der Entwicklung lag der Fokus des Teams darauf, den Prototyp Swap Meet auf die Bedürfnisse der Zielgruppe auszurichten. Hierzu wurden als erstes die potentiellen Nutzer (drei verschiedene Phänotypen) analysiert und deren Bedürfnisse abgeleitet. Unseren Prototyp Swap Meet richteten wir anschließend auf die Optimierung dieser Bedürfnisse aus.

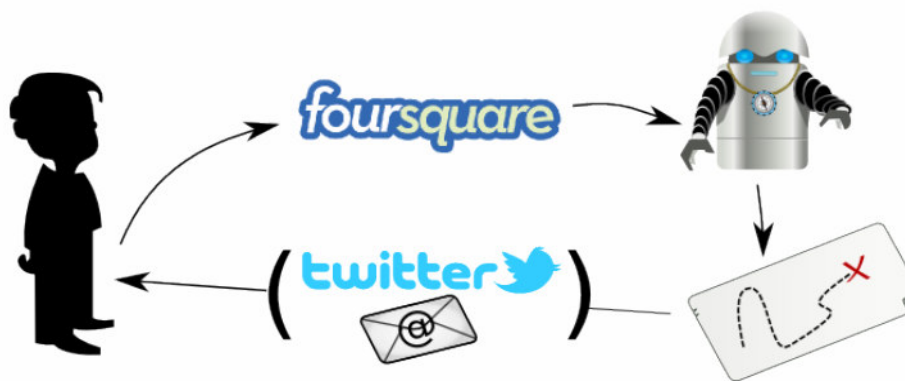
## 4.1 Projekteinführung: Ideenfindung auf Basis von Foursquare

Die meisten Webdienste (z.B. soziale Netzwerke) zielen darauf ab, den Nutzern Empfehlungen vorzuschlagen, die zu den eigenen Vorlieben passen. Ein hervorragendes Beispiel hierfür ist Foursquare, ein ortsbasiertes soziales Netzwerk, welches den Anwendern Empfehlungen für Orte auf Basis von eigenen Vorlieben, Bewertungen und Empfehlungen, oder denen von Freunden, aussprechen kann.

Diese Empfehlungen führen jedoch häufig zu dem Problem, dass Menschen in eine Routine verfallen, welche sie selbst nicht mehr wahrnehmen. Um eine derartige Routine zu durchbrechen, kam unser Team im Projekt Swap Meet auf die Idee, Stadterzählung mal anders zu gestalten und den gegenteiligen Ansatz von Foursquare zu fahren.

Zuvor wurde bereits ein ähnliches Konzept im Hinblick auf Foursquare entwickelt, wobei durch die Integration eines Prototyps namens "GetLostBot" in den Standort-Sharing-Dienst versucht wurde, die Nutzer aus einer Routine herauszulocken, indem dieser ihnen Karten mit unbekanntem Zielen über Twitter oder E-Mail vorschlug. Einen guten Überblick bieten hierzu unter anderem [26], [49], auf denen die Darstellung zu Foursquare basiert.

Abbildung 13 veranschaulicht den Informationsfluss zwischen dem Nutzer, Foursquare und dem "GetLostBot".



Im November 2011 wurde das Konzept über soziale Medien und "The Guardian Website" beworben, 137 Foursquare Nutzer registrierten sich für den Dienst, 5 Wochen Evaluierung (basierend auf Online-Umfrage aktiver Nutzer) endete Anfang Januar 2012.

Abb. 13: Informationsfluss zwischen dem Nutzer, Foursquare und dem "GetLostBot"

Wie zuvor dargestellt, bieten Foursquare und viele andere wichtige Standort-Sharing-Dienste eine integrierte Empfehlungsmechanik für ihre Nutzer, basierend auf den eigenen Bewertungen sowie denen von Freunden und auch Fremden. Dies ist eine exzellente Eigenschaft für den jeweiligen Zweck, jedoch versucht der "GetLostBot" diese Mechanik, durch weitere zufällige und explorative Vorschläge, zu ergänzen.

In erster Linie geschieht dies durch die Analyse der erzielten Kategorien der Orte, an denen die Nutzer einchecken. Während Foursquare Empfehlungen vorschlägt, die der Nutzer wahrscheinlich mögen wird, geht der "GetLostBot" den umgekehrten Ansatz, der darauf hindeutet, ähnliche Locations, an denen der Nutzer eingeklickt hat, vorzuschlagen.

Ebenso wie das Ziel vom "GetLostBot" lag auch das gemeinsame Ziel unseres Teams darin, Menschen aus einer Routine herauszulocken und somit eine Filter Bubble beziehungsweise persönliche Komfortzone zu umgehen.

Dies soll für die Nutzer durch die Möglichkeiten neue geheime Orte zu entdecken sowie andere Menschen kennenzulernen realisiert werden. Wie zuvor dargestellt, planten wir unser Konzept über eine neue innovative Location App namens Swap Meet abzuwickeln, wozu wir einen Prototyp entwickelten. Unser Team setzte sich dabei aus drei Projektmitgliedern (siehe Abbildung 14) zusammen.



Abb. 14: Unser Team

## 4.2 Motivation, Vision und Zielsetzung

Zu Beginn unseres Projektes kamen wir zu der Erkenntnis, dass jeder Mensch in der Regel seinem gewohnten alltäglichen Leben nachgeht, wobei er drei Punkte anläuft: Freizeit, Zuhause und Arbeit. Das folgende Dreieck spiegelt die drei Punkte wider.

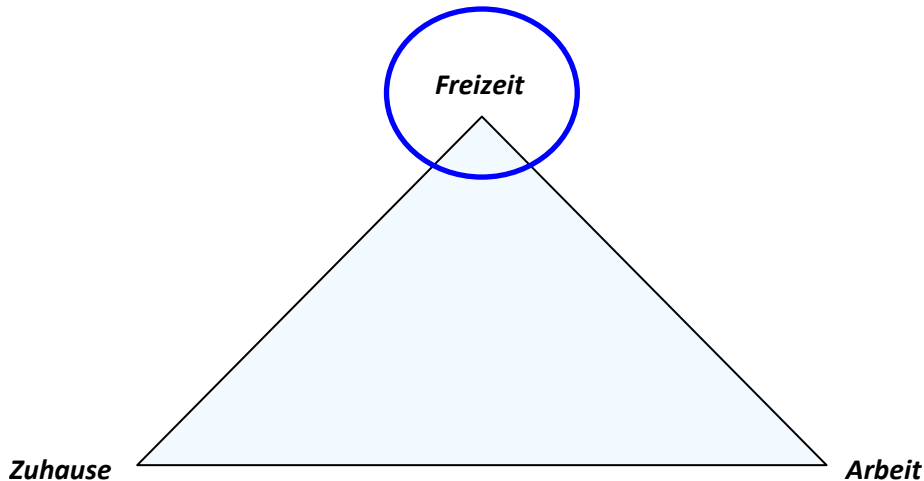


Abb. 15: Dreieck zur Motivation, Vision und Zielsetzung

Die in dem Dreieck dargestellten Punkte sind in der Regel stabil, das heißt, sie verändern sich nicht großartig. Der einzige Punkt, worin eine gewisse Dynamik von außen eingebracht werden kann, ist der Punkt Freizeit und so beschlossen wir das Freizeitleben von Menschen dynamischer zu gestalten.

Natürlich gelingt dies nur, wenn sich die jeweilige Person darauf einlässt und offen für Neues ist, was bedeutet, dass sie reif für unsere geplante App Swap Meet sein sollte. Daher sollte die notwendige Motivation und Durchhaltevermögen mitgebracht werden, denn nur so macht eine Teilnahme an dem Konzept überhaupt Sinn. Wie bei allen anderen Dingen im Leben gilt auch hier die Regel, dass man der Sache bewusst und konsequent nachgehen muss, dann kann man auch erfolgreich sein.

### 4.2.1 Zusammenhänge der Konzepte Social Graphs und Struktural Holes mit der Filter Bubble

Im Folgenden werden die Zusammenhänge der Konzepte Social Graphs und Struktural Holes mit der Filter Bubble näher erläutert, durch welche wir in unserem Projekt besonders motiviert worden sind.



Bei den Social Graphs handelt es sich um unterschiedliche Verbindungen zwischen Personen im Internet, woraus sich verschiedene soziale Netzwerke bilden. Meist existieren innerhalb dieser Netzwerke sehr starke Verbindungen. Die Verbindungen zwischen den verschiedenen Netzwerken hingegen sind jedoch eher schwach.

Innerhalb dieser Netzwerke interessieren sich die Personen beispielsweise nur für ein bestimmtes Thema. So wird zum Beispiel in einem Netzwerk nur über Wintersport, in einem anderem nur über Fußball und in einem weiteren nur über Musik gesprochen. Die Personen innerhalb eines Netzwerkes sehen somit nicht, worüber in den anderen Netzwerken gesprochen wird und begeben sich dadurch in eine Filter Bubble, worin sie nur noch von ihren Vorlieben umgeben sind und nicht mehr sehen, was um sie herum beziehungsweise außerhalb ihrer Netzwerke passiert.

Wie zuvor dargestellt, fühlen sich die meisten Menschen in einer solchen Filter Bubble sehr wohl, weil sie sich darin nur noch mit ihren eigenen Präferenzen beschäftigen und andere Informationen, welche nicht ihrem Interessengebiet beziehungsweise Meinungsbild entsprechen, nicht mehr wahrnehmen. Die Menschen begeben sich somit innerhalb ihrer Filter Bubble in eine persönliche Komfortzone, worin sie nur noch von ihren Vorlieben umgeben sind.

Daher setzten wir uns zum Ziel, Menschen aus ihrer Komfortzone herauszuholen und neue Entdeckungen zu machen (z.B. neue geheime Orte zu entdecken und andere Menschen kennenzulernen). Die neu geschlossenen Kontakte sollten sich dabei jedoch außerhalb ihres Freundeskreises befinden, um abenteuerliche Erlebnisse zu gewährleisten.

Im Zuge dessen stießen wir auf das Konzept der strukturellen Löcher (engl. Structural Holes), welches darauf baut, dass es Personen zwischen den verschiedenen Netzwerken gibt, die sich für unterschiedliche Themengebiete (z.B. Wintersport und Fußball) interessieren und somit eine Verbindung zwischen den verschiedenen Netzwerken herstellen können. In der Regel besitzen solche Personen einen Informationsvorsprung, weil sie nicht nur einseitig Informationen erhalten.

So beschlossen wir Personen aus ihren Netzwerken herauszulocken, um neue Erfahrungen zu sammeln. Die Menschen sollen sozusagen aus der Filter Bubble durch ein strukturelles Loch gelangen und dadurch an Lebenserfahrungen gewinnen.

### 4.3 Herangehensweise

Im Laufe unseres Projektes kristallisierte sich ein weiteres wichtiges Dreieck heraus, an dem wir uns hinsichtlich der Herangehensweise orientierten. Das folgende Dreieck stellt die drei relevanten Punkte dar.




Abb. 16: Dreieck zur Herangehensweise

Die drei aufgeführten Punkte (Motivation des Einzelnen, Interaktionsmuster innerhalb der Gruppe und Technologien) sollten erfüllt werden, damit unser Konzept einwandfrei funktioniert. Denn dies ermöglicht, Personen zur Anmeldung für unseren Service zu motivieren und den Einsatz technischer Systeme optimal zu planen.

#### 4.3.1 Motivation des Einzelnen

Als erstes legten wir dazu drei verschiedene Phänotypen (potentielle Nutzer für unsere App) und deren individuellen Bedürfnisse fest, um unseren Prototyp Swap Meet im weiteren Verlauf unseres Projektes optimal auf die Bedürfnisse auszurichten und somit sicherzustellen, dass unsere App alle drei Typen anspricht.

#### Drei Phänotypen: Social Typ, Adventure Typ und Foreigner Typ

Bei dem ersten Typ handelt es sich um den sogenannten Social Typ, welcher Interesse daran hat Freunde zu finden, das Gespräch zu anderen Menschen sucht, gemeinsam Zeit verbringen möchte und das Bedürfnis hat neue Kulturen kennenzulernen. Kurz gesagt: Eine Person, die Interesse an den Kontakten zu anderen Menschen hat.

Der zweite relevante Typ ist der sogenannte Adventure Typ, welcher den Reiz besitzt, neue geheime Orte zu entdecken, Abwechslung und die ganz große Freiheit zu erleben, um somit dem Alltag über kurz oder lang zu entfliehen.

Der dritte Typ ist der Foreigner Typ, eine Mischform aus den beiden voran dargestellten Phänotypen (Social Typ und Adventure Typ). Dieser hat sowohl Interesse daran andere Leute kennenzulernen als auch neue Orte zu entdecken. Häufig sind dies Personen, die fremd in einer Stadt sind und keine Menschenseele kennen und daher meist eine Art von Sicherheitsgefühl verspüren möchten. Bei diesem Typ ist die Komfortzone eher klein, da die Umgebung für ihn noch unbekannt ist.

## **Anerkennung über Gamification**

Bei allen drei Phänotypen spielt der Aspekt Gamification (engl. "game" für "Spiel") eine ganz zentrale Rolle. Einen guten Überblick bietet hierzu unter anderem [67], an dem ich mich bei der Darstellung zur Gamification orientiere.

Als Gamification bezeichnet man die Anwendung spieltypischer Elemente und Prozesse in einem spielfremden Kontext. Zu diesen spieltypischen Elementen gehören zum Beispiel Erfahrungspunkte, Fortschrittsbalken, Ranglisten, Highscores, virtuelle Güter oder Auszeichnungen. Durch die Integration dieser spielerischen Elemente soll im Wesentlichen eine Motivationssteigerung von Personen erreicht werden, die ansonsten wenig herausfordernde, als zu monoton empfundene oder auch komplexe Aufgaben zu erfüllen haben. Analysen von Daten gamifizierter Anwendungen zeigen teilweise signifikante Verbesserungen in Bereichen wie Motivation, Lernerfolg, Nutzerbindung, ROI<sup>26</sup> oder Datenqualität.

Um die Motivationssteigerung unserer drei Phänotypen zu erreichen, haben wir uns daher bei der Gamification folgender typischen Elemente bedient:

### **Sichtbarer Status (Fortschrittsanzeige)**

Der Swap Meet Anwender möchte das Voranschreiten der eigenen Arbeit klar erkennen können, etwa in Form von bestimmten Attributen, Punkten oder einer Prozentanzeige. Daher führten wir in unsere App eine Punkteskala von 0-100 ein. Es entsteht somit Transparenz in der Erfüllung einer Teil- oder Gesamtaufgabe, was ein zentrales Element der Motivation ist.

### **Rangliste**

Wenn die Swap Meet Anwender ebenso den Fortschritt und Status anderer Nutzer sehen, kann eine erste Art von Wettbewerb entstehen. Daher führten wir bei Swap Meet eine Rangliste von Personen ein, in der ein Nutzer – entsprechend seiner Anzahl an Check-ins bei Locations – auf- oder absteigen kann. Je häufiger die Person also einen bestimmten Ort besucht, umso höher steigt sie in der Rangliste auf.

---

<sup>26</sup> Der Return on Investment (kurz: RoI) misst den Ertrag/Gewinn im Verhältnis zur Investitionssumme. (Quelle: [65])

**Quest**

Eine Aufgabe, die der Nutzer in einer bestimmten Zeit zu absolvieren hat – oft ein Rätsel<sup>27</sup> oder eine einfache Fleißarbeit, welche von Swap Meet vorgegeben wird. In vielen Fällen bauen bei Swap Meet Quests aufeinander auf, um Erfahrungen und Qualifikationen zu trainieren. Diese Aufgaben können auch mit anderen Swap Meet Teilnehmern zusammen absolviert werden, wodurch nicht nur der reine Kompetenzgewinn gestärkt wird, sondern auch die Teamfähigkeit.

**Resultattransparenz**

Dem Swap Meet Anwender sollte das Ergebnis einer Aktion vorher bekannt sein. Im Falle einer gamifizierten Swap Meet Anwendung wären dies zum Beispiel Erfahrungspunkte oder andere Belobigungen. So kann der Anwender bewerten und auch wertschätzen, was ihm selber die nächste Aktion bringen wird.

**Rückmeldung**

Alle Aktivitäten des Swap Meet Anwenders sollten zu einer sichtbaren Bewertung führen und zwar am besten unmittelbar. Durch das Vermeiden von negativem Feedback und Anstreben positiver Rückmeldung lernt der Anwender permanent dazu.

**Tieferer Sinn (Epic Meaning)**

Da die Swap Meet Anwender zielorientiert handeln, sollten die Ziele zu einer starken Motivation führen und besonders erstrebenswert sein. Bereits die Arbeit innerhalb einer Gruppe kann manchmal schon als sinnstiftend empfunden werden.

**Gruppenarbeit (Community Collaboration)**

Die gemeinsame Arbeit an einer Lösung führt Swap Meet Anwender zusammen. So lassen sich einige Aufgaben nur durch Zusammenarbeit von mehreren Spielern lösen. Dies motiviert die Anwender dazu, miteinander Kontakte zu knüpfen bis hin zur Bildung eines selbstorganisierenden Systems (Swap Meet Online-Community).

**Cascading Information**

Der Swap Meet Anwender sollte bei der aktuell zu lösenden Aufgabe nur die für ihn wichtigen Informationen sehen und nicht durch unverständliche Details abgelenkt oder eventuell sogar überfordert werden. Insbesondere bei Lernspielen verwendet Swap Meet das Element Cascading Information, um Lerninhalte kontinuierlich und aufeinander aufbauend zu vermitteln, ohne spätere Inhalte vorwegzunehmen.

---

<sup>27</sup> Unser Team erstellte ein Rätsel mit der App Actionbound, womit spannende Spiele – zum Beispiel in Form von Schnitzeljagden – an verschiedenen Insiderorten realisiert werden können.

### 4.3.2 Interaktionsmuster innerhalb der Gruppe

Einen weiteren wichtigen Punkt in unserem Dreieck stellen die Interaktionsmuster innerhalb der Gruppe dar, unter dem sich das Phänomen der Tauschbörse gebildet hat, welches im Folgenden näher erläutert wird.

#### Tauschbörse

Das Phänomen der Tauschbörse soll für Interaktionen innerhalb einer Gruppe sorgen, denn zu einem Tausch sind immer mehrere Personen (mindestens zwei) erforderlich und stellt somit eine Interaktion sicher.

Unsere App Swap Meet stellt insofern eine Tauschbörse dar, woraus sich im Übrigen auch der Name Swap Meet abgeleitet hat. Zufällig steckten in Swap Meet auch die Buchstaben ap ähnlich App, was gleichzeitig hervorragend zu unserer geplanten Application passte. Somit entstand unsere neue innovative Location App Swap Meet, über welche die unterschiedlichsten Dinge getauscht werden können, zum Beispiel geheime Orte (Insidertipps), gemeinsame Gespräche, Erfahrungen und vieles mehr. Ein Beispiel für einen tauschwürdigen Insidertipp (Küchenkonzert im Kölibri) befindet sich unter IV Anhang 2. dieser Arbeit.

Aus diesen unendlich vielen Dingen, welche miteinander getauscht werden können, kreierten wird dann auch unser Swap Meet Logo (siehe Abbildung 17).



Abb. 17: Swap Meet Logo (vgl. [39], [40])

Das Logo beinhaltet ein Unendlichkeitszeichen mit Pfeilen und Standortsymbolen, welches darauf hindeutet, dass unendlich viele Orte mit anderen Menschen getauscht werden können.

Im Gegensatz zu anderen sozialen Netzwerken ist es bei Swap Meet nicht möglich sich mit seinen Freunden zu vernetzen, sondern nur mit fremden Menschen. Da man im eigenen Freundeskreis häufig dieselben Orte kennt und gleiche Interessen pflegt, soll somit vermieden werden, dass unabenteuerliche Erlebnisse innerhalb unserer App Swap Meet vorgeschlagen werden.

### 4.3.3 Technologien: Global Positioning System (GPS) und Near Field Communication (NFC)

Den letzten Punkt in unserem Dreieck bilden die Technologien, wobei wir unterschiedliche Systeme analysiert haben und uns im Zuge dessen für die Methoden Global Positioning System (GPS)<sup>28</sup> und Near Field Communication (NFC)<sup>29</sup> entschieden.

Dies kam daher, weil GPS zur Bestimmung der eigenen Komfortzonen benötigt wird, welche anschließend auf einer Google Maps Karte in Form von Heatmaps<sup>30</sup> dargestellt werden. Der Prozess dient dazu, einen Nutzer in die Lage zu versetzen, seine eigenen Komfortzonen (Orte an denen er sich häufig aufhält) wahrzunehmen und diese Gebiete möglichst zu umgehen, um eine Routine zu vermeiden.

Damit Swap Meet sicherstellen kann, dass ein Nutzer sich auch wirklich an einem bestimmten Ort befindet und das System nicht betrogen wird, erfolgt der Check-in von den Anwendern vor Ort über NFC. Für diesen Vorgang gibt es Swap Meet Sticker mit integrierter NFC-Technik, welche vor Ort von Insidern angebracht werden und als eine Art Lesegerät fungieren. Die Teilnehmer der Challenges (Herausforderungen) können über die Sticker mit einem NFC-fähigen Handy vor Ort innerhalb von Sekunden einchecken. Dies erfordert lediglich vorab einen einmaligen Registrierungsprozess, damit der Nutzer anhand einer Tag-ID an dem jeweiligen Ort (über eine Location-ID) von Swap Meet erkannt beziehungsweise authentifiziert werden kann. Dieses System gewährleistet dadurch die physische Anwesenheit eines Nutzers vor Ort und verhindert die Ausnutzung des Systems.

---

<sup>28</sup> Das Global Positioning System (GPS, deutsch Globales Positionsbestimmungssystem) ist ein satellitengestütztes Funknavigationssystem, welches Nutzern ermöglicht ihre Position bei allen Wetterbedingungen rund um die Uhr zu ermitteln. (vgl. [63])

<sup>29</sup> Near Field Communication (NFC, deutsch Nahfeldkommunikation) beschreibt einen genormten Standard zur Übertragung von Daten im Nahbereich (also über eine kurze Distanz von wenigen Zentimetern) per Funktechnik. (vgl. [42])

<sup>30</sup> Eine Heatmap ist eine analytische Darstellungsform zur Visualisierung von Daten. Im Online-Marketing werden Heatmaps verwendet, um das Nutzerverhalten und den Aufbau von Websites zu analysieren. Aus der Analyse ergeben sich meist wichtige Aspekte für die Optimierung einer Internetseite. (vgl. [48])

## 4.4 Prototyp Swap Meet

Im Folgenden werden ein paar wichtige Ansichten unseres Prototyps Swap Meet dargestellt.



Abb. 18: Swap Meet Anmeldung

Der Nutzer meldet sich für den Service über die App Swap Meet an, um neue geheime Orte zu entdecken und andere Menschen kennenzulernen.

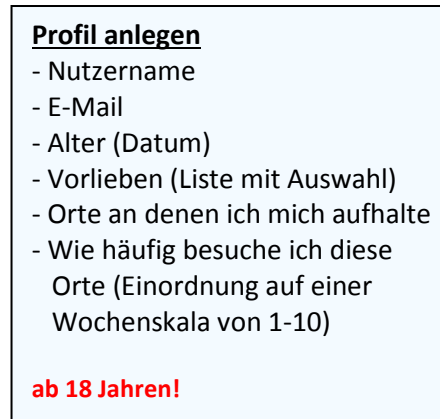


Abb. 19: Profil anlegen

Nach der Anmeldung erfolgt die Erstellung eines persönlichen Profils, worin der Nutzer seine Daten (z.B. Nutzername, E-Mail, Alter, Vorlieben, Orte an denen er sich häufig aufhält, etc.) angibt.




Abb. 20: Komfortzonen werden definiert

Aus den Profilinformatoren werden dann die Komfortzonen des Nutzers definiert.

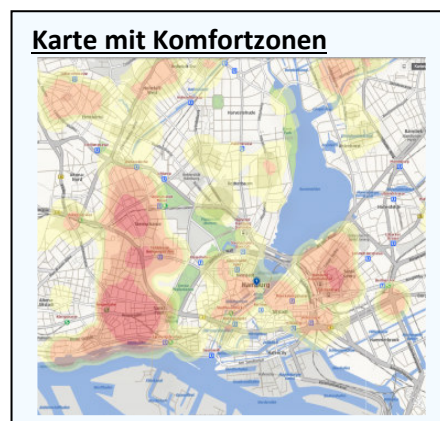


Abb. 21: Karte mit Komfortzonen (vgl. [60])

Die Komfortzonen werden auf einer Google Maps Karte in Form von Heatmaps dargestellt, damit der Nutzer erkennen kann, an welchen Orten er sich häufig befindet. Die Gebiete der Komfortzonen sollten durch Swap Meet hinsichtlich der Empfehlungen umgangen werden, damit der Nutzer nicht in eine Routine verfällt und diese somit vermieden werden kann.

Gebe 2 Insidertipps aus deiner Komfortzone an

Tipp 1: ...

Tipp 2: ...

Abb. 22: Insidertipps angeben

Um an den Challenges teilnehmen zu können, hat jeder Nutzer zunächst erst einmal selbst zwei Tipps abzugeben, um anschließend von anderen Personen Insidertipps freigeschaltet zu bekommen.

alleine

zusammen mit anderen Personen

Abb. 24: Challenge zu einem Thema alleine oder zusammen mit anderen Personen absolvieren

Es gibt die Möglichkeit eine Challenge zu einem Thema alleine oder auch zusammen mit anderen Personen zu absolvieren. Ein Nutzer kann auf diese Weise neue Kontakte knüpfen und ggf. auch neue Freunde finden.

Wähle ein Thema/eine Challenge:

1. Cocktail      Simple Challenge

2. Kaffee

3. Sport      Extrem Challenge

Abb. 23: Thema und Challenge wählen

Je nachdem worauf der Nutzer gerade Lust hat, kann er zwischen unterschiedlichen Themen (z.B. Cocktail, Kaffee, Sport, etc.) wählen. Danach wählt er zwischen zwei Arten von Challenges (Simple Challenge und Extrem Challenge) aus.

**Simple Challenge:** Adresse und Koordinaten werden angezeigt

**Extrem Challenge:** Schnitzeljagd beginnt

**Vor Ort mit NFC einchecken und Punkte sammeln**

Start Level (10 Punkte)

1. Level – Bronze (0-40 Punkte)

2. Level – Silber (41-80 Punkte)

3. Level – Gold (81-100 Punkte)

Abb. 25: Orte finden, mit NFC einchecken und Punkte sammeln

Je nachdem für welche Challenge sich der Nutzer im Vorwege entschieden hat, werden ihm Daten über einen Ort zur Verfügung gestellt. Bei der Simple Challenge erhält er Adresse und Koordinaten. Bei der Extrem Challenge hat er den Ort jedoch via Schnitzeljagd ausfindig zu machen. Vor Ort kann der Nutzer dann per NFC (über Swap Meet Sticker mit integrierter NFC-Technik) einchecken und Punkte sammeln. Die Anzahl der Punkte variiert von Level zu Level. Bei Swap Meet gibt es das Start Level und drei weitere Levels (Bronze, Silber und Gold). Je nach Level und Punktzahl steigt man in einer Rangliste auf oder ab, diese kann ebenso von anderen Personen eingesehen werden, wodurch eine Art Wettbewerb entstehen kann.



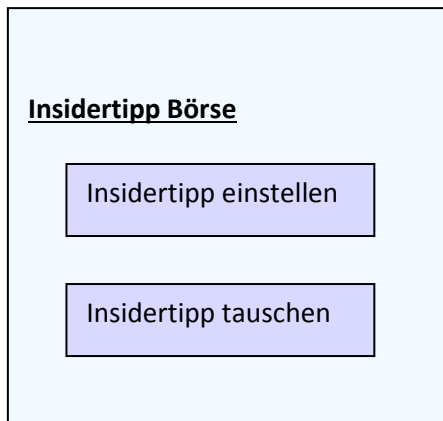


Abb. 26: Insidertipp Börse

Eine weitere Möglichkeit die Swap Meet bietet, ist die Insidertipp Börse, über welche Nutzer Tipps einstellen und tauschen können.

## 4.5 Fazit zu den Handlungsschritten – “Next Steps”

Im Zuge der “Next Steps” könnte der Aspekt der Monetarisierung berücksichtigt werden, wodurch Nutzer für Check-ins an Orten eine monetäre Belohnung erhalten können. Zum Beispiel könnte dies ein kostenloses Stück Kuchen in einem Café sein oder Prozente auf ein bestimmtes Produkt oder eine Marke bei einer Drogeriemarktkette. Der Anreiz einen bestimmten Ort häufiger zu besuchen würde so mit Sicherheit gesteigert werden.

Ein weiterer relevanter Aspekt, welcher Anwendung finden könnte, wäre eine Art Ableger der Tauschbörse – die Swap Meet Singlebörse. Über diese kann man nicht nur neue Leute kennenlernen, sondern gegebenenfalls sogar den Partner fürs Leben finden.

Da die App Swap Meet derzeit noch auf Hamburg beschränkt ist, könnte diese auf andere Städte ausgeweitet werden, um noch mehr Menschen die Möglichkeit zu geben ihre persönliche Komfortzone innerhalb der Filter Bubble zu verlassen und somit eine Routine zu durchbrechen.

## **4.6 Ausblick / Swap Meet in der Anwendung**

Die Voraussetzung für eine erfolgreiche Teilnahme an dem Konzept der neuen innovativen Location App Swap Meet ist selbstverständlich, dass man offen für Neues ist.

Zusammenfassend lässt sich sagen, dass die App genutzt werden kann, um neue geheime Orte zu entdecken, andere Menschen kennenzulernen und vieles mehr. Den Nutzern kann es somit gelingen, sich aus ihrer Filter Bubble beziehungsweise persönlichen Komfortzone herauszubekommen und eine Routine zu durchbrechen, wodurch Lebenserfahrungen in einer Vielzahl von Bereichen gesteigert werden können.

Abschließend ist festzuhalten, dass durch die neue Location App Swap Meet Stadterzählung mal ganz anders und viel innovativer als zuvor erfahren werden kann.

## 5 Fazit

Um die anfängliche Fragestellung “Was macht ein gutes Recommender System unter Berücksichtigung des Filter Bubble Problems aus?” zu beantworten, wurden die Kriterien eines guten Recommender Systems aus dem Kapitel 3.14 herangezogen und anhand der erfundenen innovativen Location App Swap Meet untersucht, die mit ihren Recommender Systemen (aus dem Kapitel 2.5 ff.) versucht, die Nutzer so gut wie möglich aus ihrer Filter Bubble beziehungsweise persönlichen Komfortzone herauszulocken. Da es sich bei Swap Meet um eine erfundene App handelt und hierzu keine Vergleichsdaten vorliegen, anhand derer eine Beurteilung erfolgen konnte, wurde die Bewertung von Swap Meet im Hinblick auf die einzelnen Recommender Systeme auf Basis einer subjektiven Einschätzung in Form von gering, mittel und hoch (in den Farben Bronze, Silber und Gold) vorgenommen.

Um jedoch eine bessere Einschätzung gewähren zu können, wurde dieser als Referenzpunkt das weltweit etablierte System – die reale Location App Foursquare – gegenübergestellt, um somit die Differenzen zu Swap Meet zu verdeutlichen und einen Vergleich der einzelnen Systeme beider Location Apps vornehmen zu können.

Wie zuvor dargestellt, verfolgt die reale Location App Foursquare jedoch – im Gegensatz zu Swap Meet – das Ziel, die Nutzer mit ihren Recommender Systemen (aus dem Kapitel 2.5 ff.) so gut wie möglich in ihrer Filter Bubble beziehungsweise persönlichen Komfortzone zu halten. Foursquare wurde daher ebenso anhand der Kriterien aus dem Kapitel 3.14 im Hinblick auf die einzelnen Recommender Systeme untersucht. Jedoch besteht auch hier eine gewisse Problematik, dass Foursquare keine exakten Daten über seine Recommender Systeme offen legt, da auf diesen ja schließlich das Geschäftskonzept basiert, und insofern dabei ebenso lediglich eine subjektive Einschätzung in Form von gering, mittel und hoch (in den Farben Bronze, Silber und Gold) vorgenommen werden konnte. Die Untersuchungen werden im Folgenden dargestellt, wobei ich mich an [57] orientiere.

## Bewertung von Swap Meet und Foursquare im Hinblick auf die einzelnen Recommender Systeme

Wie zuvor dargestellt, wurde die Bewertung von Swap Meet und Foursquare im Hinblick auf die einzelnen Recommender Systeme (aus dem Kapitel 2.5 ff.) anhand der unter dem Kapitel 3.14 aufgestellten Kriterien vorgenommen.

Um eine Vergleichbarkeit der beiden Systeme zu schaffen, wurde bei der folgenden Untersuchung davon ausgegangen, dass sich das System von Swap Meet bereits in der Anwendung befindet und regelmäßig – wie das System von Foursquare – gepflegt wird. Tabelle 5 zeigt die vier unterschiedlichen Recommender Systeme der Apps Swap Meet und Foursquare im Vergleich anhand der verschiedenen Kriterien, die jeweils durch folgende Ziele beeinflusst werden:

- ⇒ **ZIEL von Swap Meet: Raus aus der Filter Bubble bzw. Komfortzone!**
- ⇒ **ZIEL von Foursquare: In der Filter Bubble bzw. Komfortzone bleiben!**

Bewertung von <i>Swap Meet (S)</i> und <i>Foursquare (F)</i> im Hinblick auf die einzelnen Recommender Systeme (RS)								
	Demografische RS		Inhaltsbasierte RS		Kollaborative RS		Hybride RS	
	<i>S</i>	<i>F</i>	<i>S</i>	<i>F</i>	<i>S</i>	<i>F</i>	<i>S</i>	<i>F</i>
<b>Menge an Daten</b>	mittel	mittel	mittel	mittel	mittel	mittel	hoch	hoch
<b>Berücksichtigung des Nutzertyps</b>	gering	gering	mittel	mittel	mittel	mittel	hoch	hoch
<b>Individualität der Empfehlungen</b>	gering	gering	mittel	mittel	mittel	mittel	hoch	hoch
<b>Nachvollziehbarkeit der Empfehlungen</b>	gering	gering	mittel	mittel	mittel	mittel	hoch	hoch

Tab. 5: Bewertung von Swap Meet und Foursquare im Hinblick auf die einzelnen Recommender Systeme

Bei dem Vergleich der vier unterschiedlichen Recommender Systeme von Swap Meet und Foursquare anhand von verschiedenen Kriterien lässt sich feststellen, dass beide Apps hinsichtlich ihrer Bewertung identisch abschneiden – trotz, dass diese komplett gegensätzliche Ziele verfolgen. Im Folgenden wird die Bewertung beider Location Apps näher erläutert.

### **Menge an Daten**

Swap Meet und Foursquare haben durch ihre umfangreiche Datenmenge die besten Voraussetzungen für qualitativ hochwertige Standortempfehlungen. Vor allem bei den demografischen Recommender Systemen, die nicht ganz so stark von den manuell eingegebenen Daten des Nutzers abhängig sind, liegt das Datenvolumen im mittleren Bereich. Aber auch das Datenvolumen bei den inhaltsbasierten und kollaborativen Systemen würde ich bei beiden Location Apps im mittleren Bereich einstufen, da beide Systeme durch permanenten User Input gepflegt werden.

Bei Swap Meet und Foursquare liegt die Datenmenge jedoch bei den hybriden Systemen am höchsten, weil dabei eine Kombination aus verschiedenen Recommender Systemen zum Einsatz kommt und somit alle vorhandenen Kategorien bei den Empfehlungsprozessen berücksichtigt werden können.

### **Berücksichtigung des Nutzertyps**

Dieses Kriterium wird bei den verschiedenen Recommender Systemen von Swap Meet und Foursquare unterschiedlich berücksichtigt. Eingabemasken und Auswahlmöglichkeiten beziehungsweise Präferenzangaben sind zwar bei beiden Location Apps jeweils für jeden Nutzertypen identisch, dennoch berücksichtigen die demografischen Systeme den Nutzertyp nicht in einem ganz so beachtlichem Maße, wie es die anderen Recommender Systeme tun, und können daher bei beiden Apps als gering eingestuft werden.

Die inhaltsbasierten und kollaborativen Systeme von Swap Meet und Foursquare berücksichtigen zwar die individuellen Verhaltensweisen oder Bewertungen von Nutzern in den Empfehlungsprozessen, jedoch wiederum nicht in einem so hohem Maße, wie es die hybriden Systeme tun, und können insofern im mittleren Bereich eingestuft werden.

### **Individualität der Empfehlungen**

Vor allem bei den hybriden Recommender Systemen ist ein hoher Personalisierungsgrad vorhanden, da hier nur individuelle Empfehlungen für diesen einen Nutzer erscheinen. Dieses Kriterium kann daher bei Swap Meet und Foursquare hinsichtlich der hybriden Systeme im hohen Bereich eingestuft werden.

Es sind jedoch schon Unterschiede zwischen den Recommender Systemen zu erkennen. Während die kollaborativen Recommender Systeme von Swap Meet und Foursquare sich an den Bewertungen von Nutzern orientieren und sehr individuell sind, kann man bei den demografischen Recommender Systemen kaum von Personalisierung sprechen, da jeder Nutzer die gleichen Empfehlungen erhält. Daher würde ich dieses Kriterium bei den demografischen Recommender Systemen beider Location Apps als gering einstufen. Es sind zwar Angaben des Users notwendig, wodurch das System einen individuellen Charakter bekommt, jedoch erfolgt dann eher eine allgemeine Empfehlung. Jeder Nutzer, der dieselben Präferenzen ankreuzt, erhält insofern auch die gleichen Standortvorschläge.

Bei Swap Meet und Foursquare können, aufgrund der umfangreichen Anzahl an Nutzerbewertungen, individuelle Empfehlungen abgegeben werden, deshalb kann dieses Kriterium bei den kollaborativen Systemen beider Location Apps im mittleren Bereich eingestuft werden.

Die inhaltsbasierten Recommender Systeme von Swap Meet und Foursquare orientieren sich etwas weniger am Nutzer, sondern mehr am ausgewählten Standort, weil dabei jedoch das Nutzerverhalten in die Empfehlungsprozesse einfließt, kann die Individualität von Empfehlungen gewährleistet werden und liegt daher bei beiden Apps im mittleren Bereich.

### **Nachvollziehbarkeit der Empfehlungen**

Die Nachvollziehbarkeit ist bei den verschiedenen Recommender Systemen im unterschiedlichen Maße gegeben. Dem Nutzer sollten jedoch generell keine Standorte von Swap Meet und Foursquare empfohlen werden, bei denen er nicht nachvollziehen kann, warum gerade dieser Ort seinen Präferenzen entsprechen soll. Dies kann entweder durch die Auswahl an Standorten erfolgen, die andere Nutzer mit ähnlichen Präferenzen als positiv bewertet haben, oder die Empfehlungen erfolgen basierend auf eigenen Angaben. Beides ist für den Anwender leicht nachzuvollziehen, was die Glaubwürdigkeit der Empfehlungen steigert und den Nutzer dadurch mehr an die jeweilige Location App bindet.

Dieses Kriterium ist jedoch bei den demografischen Systemen von Swap Meet und Foursquare lediglich im geringen Bereich einzustufen, da die generalisierten Empfehlungen wohl kaum die individuellen Nutzerbedürfnisse ansprechen können und diese somit auch nicht wirklich nachvollziehbar sind.

Swap Meet und Foursquare liefern bei den inhaltsbasierten und kollaborativen Systemen, aufgrund der umfangreichen Anzahl an Nutzerverhaltensdaten sowie Bewertungen, und somit der Möglichkeit individuelle Empfehlungen aussprechen zu können, nachvollziehbare Empfehlungen und sind daher im mittleren Bereich einzustufen.

Bei den hybriden Systemen beider Location Apps ist dieses Kriterium, aufgrund des umfangreichen Datenvolumens, am höchsten einzustufen, weil dadurch die Möglichkeit individuelle Vorschläge auszusprechen steigt und somit auch die Nachvollziehbarkeit der Empfehlungen.

### **Gesamtfazit zu der Bewertung von Swap Meet und Foursquare im Hinblick auf die einzelnen Recommender Systeme**

Bei der Gesamtbeurteilung von Swap Meet und Foursquare im Hinblick auf die einzelnen Recommender Systeme kann festgehalten werden, dass je nachdem welche Beratung man bevorzugt, das eine beziehungsweise andere Empfehlungssystem seine jeweiligen Schwerpunkte sowie Vor- und Nachteile mit sich bringt.

Die demografischen Systeme schneiden im Vergleich zu allen anderen Systemen nicht so gut ab. Es ist zwar eine gewisse Datenmenge vorhanden, jedoch werden auf Basis dieser eher generelle Empfehlungen abgegeben.

Die inhaltsbasierten und kollaborativen Systeme orientieren sich hingegen sehr an den Verhaltensweisen oder Bewertungen von Nutzern und können daher auf Basis der bereits vorliegenden Datenmenge individuelle Empfehlungen für die Nutzer gewährleisten. Jedoch berücksichtigen diese wiederum in ihren Empfehlungsprozessen nicht alle vorhandenen Kategorien, wie es die hybriden Systeme tun.

Man kann auf jeden Fall sagen, dass eine Kombination aus verschiedenen Recommender Systemen (hybride Systeme) mit sehr großer Wahrscheinlichkeit zu einer höheren Zufriedenheit bei den Nutzern führen würde, weil dadurch vor allem ihre individuellen Wünsche besser erfüllt werden können. Zudem können die in Kapitel 2.6 genannten Probleme und Schwachstellen optimaler umgangen werden.

Trotz einiger Probleme haben Swap Meet und Foursquare mit Sicherheit einige gute Recommender Systeme implementiert und werden daher voraussichtlich in der Zukunft einen noch höheren Anklang bei den Nutzern finden.

Swap Meet besitzt vor allem Empfehlungssysteme, die den Nutzern neue geheime Standorte (Insidertipps) vorschlagen, während Foursquare eher konservativ nur bekannte Standortempfehlungen liefert. Bei der Entscheidung welches der beiden Systeme vom User genutzt wird, ist maßgeblich, inwieweit der jeweilige Anwender tatsächlich offen für Neues ist und bereit dafür ist aus seiner Filter Bubble herauszutreten. Möchte er seine Interessen vertiefen, so sollte er bei dem System von Foursquare bleiben, möchte er jedoch andere Menschen kennenlernen und neue Impulse schaffen, so würde die Nutzung von Swap Meet diesem Begehren des Users gerecht werden.

## 6 Zusammenfassung / Ausblick

In der vorliegenden Arbeit wurde auf die Ansätze von Recommender Systemen, welche auf unterschiedliche Weise die Bedürfnisse der Nutzer aufgreifen beziehungsweise "vorausahnen" und ihnen Vorschläge (aus verschiedenen Bereichen) unterbreiten eingegangen. (vgl. [23]) Dabei wurde der Fokus insbesondere auf das Filter Bubble Problem gelegt.

Es stellte sich zu Beginn dieser Arbeit die folgende zentrale Frage: "Was macht ein gutes Recommender System unter Berücksichtigung des Filter Bubble Problems aus?" Um die zentrale Frage dieser Arbeit zu beantworten und zukünftige Trends besser einschätzen zu können, wurde ein Prototyp Beispiel – die erfundene innovative Location App namens Swap Meet – vorgestellt und im Hinblick auf vier unterschiedliche Recommender Systeme (demografische, inhaltsbasierte, kollaborative und hybride Recommender Systeme) anhand von verschiedenen Kriterien, welche ein gutes Recommender System ausmachen, untersucht. Zum Vergleich wurde dieser die weltweit etablierte reale Location App Foursquare gegenübergestellt. Trotz der Tatsache, dass beide Location Apps komplett gegensätzliche Ziele verfolgen – Swap Meet versucht den Nutzer aus seiner Filter Bubble herauszulocken und Foursquare möchte den Anwender darin festhalten – schneiden bei der Bewertung beide Location Apps jeweils identisch ab.

Im Rahmen einer Gesamtbeurteilung der Apps Swap Meet und Foursquare konnte hinsichtlich der einzelnen Recommender Systeme festgehalten werden, dass je nachdem welche Beratung man bevorzugt, das eine oder andere System seine wesentlichen Schwerpunkte sowie Vor- und Nachteile mit sich bringt. Um diese abzuwägen und Synergien zu nutzen, könnte jedoch eine Kombination aus verschiedenen Recommender Systemen (hybride Systeme) mit sehr großer Wahrscheinlichkeit zu einer höheren Zufriedenheit bei den Nutzern führen. (vgl. [57])



Generell gilt jedoch, dass alle Systeme einen hohen Grad an Personalisierung erfordern, um die Vorlieben und Abneigungen des jeweiligen Nutzers zu kennen, um somit für ihn anhand einer möglichst großen Datenmenge individuelle Empfehlungen generieren zu können, wodurch die Nachvollziehbarkeit der Empfehlungen gesteigert werden kann. Dies führt folglich nicht nur zu zufriedenen und loyalen Kunden, sondern gleichzeitig auch zu höheren Unternehmensumsätzen.

Zu dem Filter Bubble Problem bei Recommender Systemen gibt es durchaus unterschiedliche Auffassungen:

- ⇒ Einerseits gibt es Nutzer, die gerne mit Recommender Systemen arbeiten, welche konservative Standortempfehlungen ausgeben und sie somit in ihrer Filter Bubble festhalten – allerdings ist ihnen dieser Prozess häufig nicht bewusst und sie haben keine Kenntnis darüber, dass sie sich in einer solchen Filterblase befinden.
- ⇒ Andererseits gibt es Anwender, die gerne Recommender Systemen nutzen, welche neue Standortempfehlungen ausgeben – allerdings ist ein wesentlicher Faktor dafür, inwieweit der jeweilige Nutzer offen für Neues ist, und bereit dazu ist aus seiner Filter Bubble hervorzutreten. (vgl. [57])

Lösungsansätze zur Behandlung des Filter Bubble Problems bei Recommender Systemen:

- ⇒ Sollte sich der Nutzer lieber innerhalb seines vertrauten beziehungsweise bekannten Umfeldes bewegen und in seiner Bubble bleiben wollen, so sollte dieser eher das System von Foursquare nutzen.
- ⇒ Sollte sich der Nutzer jedoch lieber mit fremden beziehungsweise unbekanntem Informationen auseinandersetzen und aus seiner Filter Bubble heraustreten wollen, um andere Menschen kennenzulernen und neue Impulse zu schaffen, so würde die Nutzung des Systems von Swap Meet diesem Begehren des Users gerecht werden.

Es können daher die Systeme beider Apps genutzt werden, um auf unterschiedliche Art und Weise auf Standortempfehlungen aufmerksam gemacht zu werden. Für welches der beiden Systeme der jeweilige Nutzer sich entscheidet, hängt insofern von seinen individuellen Präferenzen ab.

***Was ein gutes Recommender System unter Berücksichtigung des Filter Bubble Problems ausmacht, hängt insofern von den individuellen Präferenzen des jeweiligen Nutzers ab.***

Unabhängig davon für welches der beiden Systeme sich der Nutzer entscheidet, ein Faktor ist mit Sicherheit wesentlich und von überaus großer Relevanz: Die bewusste Auseinandersetzung mit bestimmten Informationen, welche durch den Anstieg von Medienkompetenz und proaktiven Usern (z.B. durch zunehmende Medientransparenz) gefördert werden kann, um somit die Kontrolle über die Inhalte seiner eigenen ganz persönlichen Filter Bubble zu gewinnen. (vgl. [66])

## IV Anhang

### 1. Infografik von Monetate



Abb. 27: Infografik von Monetate (vgl. [11])

## **2. Insidertipp – Küchenkonzert im Kölibri**

Das Küchenkonzert im Kölibri ist ein Beispiel für einen Insidertipp, der bei Swap Meet getauscht werden könnte. Einen guten Überblick bietet hierzu unter anderem [50], an dem ich mich bei der folgenden Darstellung orientiere.

### **Gesprächsskizze mit der Organisatorin Rike Salow vom Küchenkonzert im Kölibri (27.11.2015)**

#### **Wie bist du auf die Idee gekommen?**

Es wurde im Kölibri eine neue Küche gebaut. Dann hatten viele Mitarbeiter gesagt, dass man mal eine Veranstaltung mit der Küche machen sollte und daraufhin fielen mir Küchenkonzerte ein. Ich hatte früher zur Studentenzeit selbst bei der Organisation von Konzerten mitgemacht und ein Freund von mir hatte Küchenkonzerte in WGs organisiert. Das fand ich witzig, so entstand die Idee vom Küchenkonzert.

#### **Seit wann organisierst du die Küchenkonzerte?**

Seit Mai 2015.

#### **Man hat das Gefühl, dass hier ein Nachbarschaftstreffen stattfindet – trotz der Nähe zur Reeperbahn. Es kommen schon eher Leute her, die hier wohnen oder?**

Ja, hauptsächlich. Ich glaube, die meisten sind aus der Ecke St. Pauli und Altona.

#### **Wie erfahren die Leute vom Küchenkonzert?**

Eher durch Mundpropaganda. Es sind auch viele bekannte Gesichter dabei, die regelmäßig kommen. Es kommt kein "typisches Reeperbahnpublikum" hierher. Vielleicht liegt es an der Uhrzeit, da das Konzert relativ früh anfängt. Das Küchenkonzert kennt man eigentlich nur, wenn man hier wohnt.

#### **Wie wählst du die Bands aus?**

Die Bands schicken uns ihre Musik zu, welche ich mir zusammen mit meiner Kollegin anhöre. Wir versuchen eine Mischung aus Profis und Nachwuchsmusikern zu kreieren. Kuriositäten sind auch willkommen. Es sind hauptsächlich Hamburger, aber wir hatten auch schon Anfragen aus anderen Bundesländern, sogar aus Dänemark und Holland. Fand ich enorm, dafür, dass es bei uns relativ klein ist und dann auch noch auf Hut gespielt wird.

Die Nachbarn kochen auch mit. Das Kochangebot ist partizipativ. Freitags ab 16.00 Uhr kann man ins Kölibri kommen und mitkochen. Einer denkt sich immer das Rezept aus, wobei sich mittlerweile eine Kochgruppe von 8 bis 10 Leuten etabliert hat, aber diese Gruppe ist immer offen für neue Leute. Auch die Leute, die hinter dem Tresen stehen, sind hauptsächlich aus dem Viertel.

## V Literatur- und Internetquellenverzeichnis

- [1] Aggarwal, Charu C.: *Recommender Systems – The Textbook*, New York (Springer International Publishing AG), 2016, S. 8 ff.
- [2] Angermeier, Georg: ProjektMagazin – Das Fachportal für Projektmanagement: *Serendipität*, 2004,  
<https://www.projektmagazin.de/glossarterm/serendipit%C3%A4t> (15. Aug. 2016).
- [3] Aschermann, Tim: CHIP: *Was ist ein Tracker? Einfach und verständlich erklärt*, 2015,  
[http://praxistipps.chip.de/was-sind-tracker-einfach-und-verstaendlich-erklaert\\_41058](http://praxistipps.chip.de/was-sind-tracker-einfach-und-verstaendlich-erklaert_41058) (30. Juli 2016).
- [4] Boldt, Peter et al.: WinfWiki: *Recommender Systeme*, 2009,  
[http://winfwiki.wi-fom.de/index.php/Recommender\\_Systeme](http://winfwiki.wi-fom.de/index.php/Recommender_Systeme) (01. Juli 2016).
- [5] Boll, Susanne; Maaß, Susanne; Malaka, Rainer (Hrsg.): *Mensch & Computer 2013 – Tagungsband: 13. fachübergreifende Konferenz für interaktive und kooperative Medien*, München (Oldenbourg Wissenschaftsverlag GmbH), 2013, S. 18,  
[https://books.google.de/books?id=u1fpBQAAQBAJ&pg=PA18&lpg=PA18&dq=dialo gbasierte+empfehlungen&source=bl&ots=9LSODjyt55&sig=aj3OD1koMYnps9PzFDC VZz2MCN0&hl=de&sa=X&ved=0ahUKewjgpsK30%20K\\_NAhWCXCwKHUqFDzIQ6AEI JzAC#v=onepage&q=dialogbasierte%20empfehlungen&f=false](https://books.google.de/books?id=u1fpBQAAQBAJ&pg=PA18&lpg=PA18&dq=dialo gbasierte+empfehlungen&source=bl&ots=9LSODjyt55&sig=aj3OD1koMYnps9PzFDC VZz2MCN0&hl=de&sa=X&ved=0ahUKewjgpsK30%20K_NAhWCXCwKHUqFDzIQ6AEI JzAC#v=onepage&q=dialogbasierte%20empfehlungen&f=false) (04. Juli 2016).
- [6] Brand-Haushofer, Richard: *Recommender Systeme in digitalen Bibliotheken*, S. 10-12,  
<http://michael.hahsler.net/SE/SS2005/papers/Brand.pdf> (12. Juni 2016).
- [7] Doods, Simon: *Dynamic generation of personalized hybrid recommender systems*. In Proceedings of the 7th ACM conference on Recommender systems (RecSys '13). ACM, New York, 2013, page 443-446.
- [8] Ester, Martin; Sander, Jörg: *Knowledge Discovery in Databases – Techniken und Anwendungen*, Berlin, Heidelberg, New York (Springer-Verlag), 2000, S. 47,  
<https://books.google.de/books?id=rD3BQAAQBAJ&pg=PA47&lpg=PA47&dq=distanzfunktion+definition&source=bl&ots=aV-V-CWT&sig=vTI8dV06LxBbkYcntLV41Q5WNTc&hl=de&sa=X&ved=0ahUKewiNto3ejqz NAhVkd5oKHf9nAdk4ChDoAQgsMAQ#v=onepage&q=distanzfunktion%20definition&f=false> (30. Juni 2016).

- [9] Expert Program Management – The #1 Website for Program Management: *What is the Long Tail?*,  
<http://www.expertprogrammanagement.com/2012/01/what-is-the-long-tail/>  
(18. Juni 2016).
- [10] Fahrmeir, Ludwig; Hamerle, Alfred; Tutz, Gerhard (Hrsg.): *Multivariate statistische Verfahren*, 2. erweiterte Auflage, Berlin, New York (Walter de Gruyter & Co.), 1996, S. 440 ff.,  
<https://books.google.de/books?id=qdC7A2nnpn4cC&pg=PA441&lpg=PA441&dq=distanzfunktion+definition&source=bl&ots=gV2ylZx5um&sig=vWFm8bQslaDj7772iVJ-FNocnd0&hl=de&sa=X&ved=0ahUKEwjRqN-6iKzNAhXMJ8AKHVvYDYIQ6AEITTAG#v=onepage&q=distanzfunktion%20definition&f=false> (30. Juni 2016).
- [11] Gilbreath, Robert: *Monetate: Put Product Recommendations in the Hands of Merchandisers, Not Machines*,  
<http://www.monetate.com/blog/put-product-recommendations-in-the-hands-of-merchandisers-not-machines/> (17. Juni 2015).
- [12] GRÜNDERSZENE: *Long Tail – Was bedeutet Long Tail?*,  
<http://www.gruenderszene.de/lexikon/begriffe/long-tail> (18. Juni 2016).
- [13] GRÜNDERSZENE: *Social Network – Was ist ein Social Network?*,  
<http://www.gruenderszene.de/lexikon/begriffe/social-network> (27. Juni 2016).
- [14] GRÜNDERSZENE: *Win-Win-Situation – Was ist eine Win-Win-Situation?*,  
<http://www.gruenderszene.de/lexikon/begriffe/win-win-situation> (17. Aug. 2016).
- [15] Haiderzadah, Abdul-Wahed: *Social Monitoring*,  
Ausarbeitung an der Hochschule für Angewandte Wissenschaften Hamburg (HAW) im Studiengang Informatik (Master), 2014, S. 2 ff.,  
<https://users.informatik.haw-hamburg.de/~ubicomp/projekte/master2014-aw2/haiderzadah/bericht.pdf> (13. Juli 2016).
- [16] HANSER LITERATURVERLAGE: *Filter Bubble – Eli Pariser*,  
<https://www.hanser-literaturverlage.de/buch/filter-bubble/978-3-446-43034-1/>  
(10. Juni 2016).

- [17] Hassler, Marco: Web Analytics nutzen – Interessantes über Web Analytics und der Optimierung von Websites für Business und Benutzer: *Was ist eigentlich ein "User Agent"*, 2008,  
[http://www.web-analytics-nutzen.de/web\\_analytics/2008/03/was-ist-eigentl.html](http://www.web-analytics-nutzen.de/web_analytics/2008/03/was-ist-eigentl.html)  
(15. Aug. 2016).
- [18] Hebeisen, Benedikt: *Entwicklung eines Recommender Systems auf Basis von Indoor-Tracking-Daten zur Generierung personalisierter Informationssysteme*, 2009, S. 10 ff.,  
<http://inka.htw-berlin.de/Sieck/Abschlussarbeiten/Hebeisen.pdf> (04. Juli 2016).
- [19] Heidenberger, Burkhard: zeitblüten – zeitmanagement/zielmanagement – arbeitsmethodik: *Raus aus der Komfortzone! Wozu soll das gut sein?*,  
<http://www.zeitblueten.com/news/komfortzone/> (16. Juli 2016).
- [20] Heimarbeit.de: *Endlich was tun – die Komfortzone verlassen*,  
<http://www.heimarbeit.de/endlich-was-tun-die-komfortzone-verlassen/>  
(16. Juli 2016).
- [21] Hempel, Tino: Informatikmaterialien von Tino Hempel:  
*Grundbegriffe Entität und Attribut*,  
<http://www.tinohempel.de/info/info/datenbank/begriffe.htm> (15. Aug. 2016).
- [22] Höfeld, Stefanie; Kwiatkowski, Melanie: *Der Aufbau eines themenspezifischen Internetportals unter Verwendung von Recommender Systemen und Wikis und dem Einsatz von Ontologien*, 2007, S. 123 ff.,  
<https://www.phil-fak.uni-duesseldorf.de/fileadmin/Redaktion/Institute/Informationswissenschaft/forschung/1182411681masterarbe.pdf> (04. Juli 2016).
- [23] Höfeld, Stefanie; Kwiatkowski, Melanie: *Empfehlungssysteme aus informationswissenschaftlicher Sicht – State of the Art*, 2007, S. 265-276,  
<https://www.phil-fak.uni-duesseldorf.de/fileadmin/Redaktion/Institute/Informationswissenschaft/forschung/1189509550empfehlung.pdf> (01. Juli 2016).
- [24] IT Wissen – Das große Online-Lexikon für Informationstechnologie:  
*Algorithmus – algorithm*, 2016,  
<http://www.itwissen.info/definition/lexikon/Algorithmus-algorithm.html>  
(16. Juni 2016).

- [25] IT Wissen – Das große Online-Lexikon für Informationstechnologie: *logfile – Log-Datei*, 2016, <http://www.itwissen.info/definition/lexikon/logfile-Log-Datei.html> (12. Juli 2016).
- [26] Kirman, Ben; Linehan, Conor; Lawson, Shaun: *Get lost: facilitating serendipitous exploration in location-sharing services*. In CHI '12 Extended Abstracts on Human Factors in Computing Systems (CHI EA '12). ACM, New York, 2012, page 2303-2308.
- [27] Klahold, André: *Empfehlungssysteme, Recommender Systems – Grundlagen, Konzepte und Lösungen*, 1. Auflage, Wiesbaden (GWV Fachverlage GmbH), 2009, S. 4 ff., <https://books.google.de/books?hl=de&lr=&id=YQh-W9UrgCsC&oi=fnd&pg=PA1&dq=empfehlungssysteme:+recommender+systems+-+grundlagen,+konzepte+und+l%C3%B6sungen&ots=WT6S-76Wp4&sig=smSD17e6oBg2PGmjPcPkVAKHaPA#v=onepage&q=empfehlungssysteme%3A%20recommender%20systems%20-%20grundlagen%2C%20konzepte%20und%20l%C3%B6sungen&f=false> (30. Juni 2016).
- [28] Kollmann, Tobias: GABLER WIRTSCHAFTSLEXIKON: *Personalisierung*, <http://wirtschaftslexikon.gabler.de/Definition/personalisierung.html> (15. Aug. 2016).
- [29] Kollmann, Tobias: GABLER WIRTSCHAFTSLEXIKON: *Plug-in*, <http://wirtschaftslexikon.gabler.de/Definition/plugin.html> (15. Aug. 2016).
- [30] KONFIGURATOR: *Was ist Konfigurator? – Virtuelle Web-Werkzeuge, die für Sie arbeiten!*, <http://www.konfigurator-tuer.de/was-ist-konfigurator> (14. Juni 2016).
- [31] Konstan, Joseph A.: *Introduction to recommender systems*. In Proceedings of the 2008 ACM SIGMOD international conference on Management of data (SIGMOD '08). ACM, New York, 2008, page 1373-1374.
- [32] Kucklick, Christoph: *DIE GRANULARE GESELLSCHAFT – Wie das Digitale unsere Wirklichkeit auflöst*, Berlin (Ullstein Buchverlage GmbH), 2014, S. 10-11.
- [33] Kuzdas, Sabine: *Schwachstellen von Recommender Systemen*, 2005, S. 10 ff., <http://michael.hahsler.net/SE/SS2005/papers/Kuzdas.pdf> (06. Juli 2016).
- [34] Lebrun, Peter: CHIP: *Definition: Was ist ein Proxy Server?*, 2013, [http://praxistipps.chip.de/wozu-braucht-man-proxy-server\\_19572](http://praxistipps.chip.de/wozu-braucht-man-proxy-server_19572) (12. Juni 2016).

- [35] Leskovec, Jure: *New Directions in Recommender Systems*. In Proceedings of the Eighth ACM International Conference on Web Search and Data Mining (WSDM '15). ACM, New York, 2015, page 3-4.
- [36] Licht, Marcel: *konversationsKRAFT: 5 Ansätze für erfolgreiche Produktempfehlungen*, 2013, <http://www.konversionskraft.de/tipps/5-ansaetze-fur-erfolgreiche-produktempfehlungen.html> (17. Juni 2016).
- [37] Licht, Marcel: *konversationsKRAFT: Social Proof als Hebel für mehr Konversion*, 2011, <http://www.konversionskraft.de/conversion-optimierung/social-proof-als-hebel-fur-mehr-konversion.html> (17. Juni 2016).
- [38] Linneweber, Volker; Lantermann, Ernst-Dieter; Kals, Elisabeth: *Spezifische Umwelten und umweltspezifisches Handeln*, Göttingen, Bern, Wien, Paris, Oxford, Prag, Toronto, Cambridge MA, Amsterdam, Kopenhagen, Stockholm (Hogrefe Verlag GmbH & Co. KG), 2010, S. 661, [https://books.google.de/books?id=A7PDOK\\_N0UwC&pg=PA661&lpg=PA661&dq=emotionsbasierte+empfehlungen&source=bl&ots=vXGBjXvR2D&sig=XclhOKzCSqelqX8sbSj2TvKzMQ&hl=de&sa=X&ved=0ahUKewjtv6w6\\_NAhUFwxQKHb5yC-%20YQ6AEIRTAJ#v=onepage&q=emotionsbasierte%20empfehlungen&f=false](https://books.google.de/books?id=A7PDOK_N0UwC&pg=PA661&lpg=PA661&dq=emotionsbasierte+empfehlungen&source=bl&ots=vXGBjXvR2D&sig=XclhOKzCSqelqX8sbSj2TvKzMQ&hl=de&sa=X&ved=0ahUKewjtv6w6_NAhUFwxQKHb5yC-%20YQ6AEIRTAJ#v=onepage&q=emotionsbasierte%20empfehlungen&f=false) (04. Juli 2016).
- [39] Logo "Standortsymbole", [https://www.aral.de/content/dam/aral/Images/ratio%201-1/icons/location-icon-vector-location\\_map\\_pin\\_blue5.png](https://www.aral.de/content/dam/aral/Images/ratio%201-1/icons/location-icon-vector-location_map_pin_blue5.png) (20. Juli 2016).
- [40] Logo "Unendlichkeitszeichen mit Pfeilen", <http://hsg-badwim.de/www314.your-server.de/archiv/bis2014/images/stories/sonstiges/logo-tb-40.x24.jpg> (20. Juli 2016).
- [41] Muno, Stefan: *Recommender-Systeme*, 2008, S. 3/4, [http://www.is.informatik.uni-duisburg.de/courses/sem\\_ss08/papers/p06\\_recommendersystems.pdf](http://www.is.informatik.uni-duisburg.de/courses/sem_ss08/papers/p06_recommendersystems.pdf) (11. Juni 2016).
- [42] NFC-Handy – Bargeldloses Bezahlen der Zukunft: *Was ist NFC eigentlich?*, <http://www.nfc-handy.eu/nfc-basisinformationen/was-ist-nfc-eigentlich/> (20. Juli 2016).



- [43] Omkt.de: *Was ist ein Newsfeed?*,  
<http://www.omkt.de/newsfeed/> (19. Juli 2016).
- [44] ONLINE MARKETING.DE / LEXIKON: *Targeting*,  
<http://onlinemarketing.de/lexikon/definition-targeting> (21. Juni 2016).
- [45] Onlinemarketing-Praxis – Mehr Wissen für mehr Erfolg im Internet. Tipps, Tricks, Know-How: *Definition Conversation Rate (Konversionrate, Umwandlungsrate)*,  
<http://www.onlinemarketing-praxis.de/glossar/conversion-rate-konversionrate-umwandlungsrate> (17. Juni 2016).
- [46] OnPageWiki – Digitales Marketing Lexikon: *AB-Testing*,  
<https://de.onpage.org/wiki/A/B-Testing> (21. Juni 2016).
- [47] OnPageWiki – Digitales Marketing Lexikon: *Cross-Selling*,  
<https://de.onpage.org/wiki/Cross-Selling> (17. Juni 2016).
- [48] OnPageWiki – Digitales Marketing Lexikon: *Heatmap*,  
<https://de.onpage.org/wiki/Heatmap> (20. Juli 2016).
- [49] Örnek, Deniz: *Foursquare "Der digitale Reiseführer von Morgen"*,  
Hausarbeit an der Hochschule für Angewandte Wissenschaften Hamburg (HAW)  
im Studiengang Next Media (Master), Hamburg, 2016, S. 6-11.
- [50] Örnek, Deniz: *Swap Meet "Stadterzählung mal anders"*,  
Hausarbeit an der Hochschule für Angewandte Wissenschaften Hamburg (HAW)  
im Studiengang Next Media (Master), Hamburg, 2016, S. 3-17.
- [51] Pariser, Eli: *Filter Bubble – Wie wir im Internet entmündigt werden*, München  
(Carl Hanser Verlag), 2012, S. 22.
- [52] PC-WELT: *Fingerprint*,  
<http://www.browsercheck.pcwelt.de/fingerprint> (14. Juni 2016).
- [53] Roes, Anna: *Recommender Systeme mit Elasticsearch*, 2015, S. 16, 32/33,  
[https://www.inovex.de/fileadmin/files/Fachartikel\\_Publikationen/Theses/empfehlungsgenerierung-mit-elasticsearch-anna-roes-03-2015.pdf](https://www.inovex.de/fileadmin/files/Fachartikel_Publikationen/Theses/empfehlungsgenerierung-mit-elasticsearch-anna-roes-03-2015.pdf) (06. Juli 2016).
- [54] Sauer mann, Mathias: *Der Onliner – Marketing & Wirtschaft 4.0 – Ein Blog rund um die Themen Internet, Online-Marketing & Digitalisierung: Filter Bubble: Macht uns das Internet immer engstirniger?*, 2014,  
<http://der-onliner.blogspot.de/2014/06/filter-bubble-bei-google-und-facebook.html> (13. Juli 2016).

- [55] Schneider, Tobias: *Preference-Based-Recommender-Systeme – Individuelle neuronale Präferenzmodellierung am Beispiel von Investmentfonds*, 1. Auflage, Wiesbaden (Deutscher Universitäts-Verlag GmbH), 2005, S. 14/15, <https://books.google.de/books?id=ogUbvFft1hAC&pg=PA14&lpg=PA14&dq=Critical+Mass+Problem+bei+recommender+systemen&source=bl&ots=Waimp6jKJm&sig=P00SMVQ0622A0ifCQpXR13gUNxo&hl=de&sa=X&ved=0ahUKewjf9diQpfXMAhWBliwKHQltCslQ6AEIHzAA#v=onepage&q=Critical%20Mass%20Problem%20bei%20recommender%20systemen&f=false> (06. Juli 2016).
- [56] Simon, Kristin: Hausarbeiten.de: *Gatekeeperforschung*, 2004, <http://www.hausarbeiten.de/faecher/vorschau/35059.html> (30. Juli 2016).
- [57] Spitzer, Ursula: *Recommender Systeme im E-Commerce*, 2005, S. 7-14, 21 ff., <http://michael.hahsler.net/SE/SS2005/papers/Spitzer.pdf> (01. Juli 2016).
- [58] Stamm, Henrik: MOBILE THINGS: *Was ist eigentlich eine Engine?*, <http://mobilethings.de/2015/was-ist-eigentlich-eine-engine/> (15. Aug. 2016).
- [59] Statista – Das Statistik-Portal: *Statistik-Lexikon: Definition Korrelation*, <http://de.statista.com/statistik/lexikon/definition/77/korrelation/> (10. Juni 2016).
- [60] Stecher, Jakob: PC-MAX: *Ausgehen und Einkaufen in fremden Städten mit Nokia Maps*, 2011, <http://www.pc-max.de/news/internet/ausgehen-und-einkaufen-in-fremden-staedten-mit-nokia-maps> (20. Juli 2016).
- [61] TED – Ideas worth spreading: *Eli Pariser: Vorsicht vor "Filter-Blasen" im Internet*, 2011, [https://www.ted.com/talks/eli\\_pariser\\_beware\\_online\\_filter\\_bubbles?language=de](https://www.ted.com/talks/eli_pariser_beware_online_filter_bubbles?language=de) (13. Juli 2016).
- [62] Tintarev, Nava: *Explanations of recommendations*. In Proceedings of the 2007 ACM conference on Recommender systems (RecSys '07). ACM, New York, 2007, page 203-206.
- [63] TOMTOM SUPPORT: *WAS IST GPS?*, [http://de.support.tomtom.com/app/answers/detail/a\\_id/3252/~was-ist-gps%3F](http://de.support.tomtom.com/app/answers/detail/a_id/3252/~was-ist-gps%3F) (20. Juli 2016).

- [64] Wagner, Fred: GABLER WIRTSCHAFTSLEXIKON: *Up Selling*, <http://wirtschaftslexikon.gabler.de/Definition/up-selling.html> (21. Juni 2016).
- [65] Welt der BWL – Betriebswirtschaft in der Praxis: *Return on Investment (ROI) Definition*, <http://www.welt-der-bwl.de/ROI-Return-on-Investment> (20. Juli 2016).
- [66] Wiesner, Franziska: politik-digital.de: *Filter Bubble, Algorithmen und keine Auswege?*, 2014, <http://politik-digital.de/news/filter-bubble-algorithmen-und-kein-ausweg-142731/> (11. Juni 2016).
- [67] WIKIPEDIA – Die freie Enzyklopädie: *Gamification*, 2016, <https://de.wikipedia.org/wiki/Gamification> (17. Juli 2016).
- [68] WIKIPEDIA – Die freie Enzyklopädie: *Kontext (IT-Umfeld)*, 2015, [https://de.wikipedia.org/wiki/Kontext\\_\(IT-Umfeld\)](https://de.wikipedia.org/wiki/Kontext_(IT-Umfeld)) (15. Juni 2016).
- [69] WIKIPEDIA – Die freie Enzyklopädie: *Kontextsensitivität (Informatik)*, 2016, [https://de.wikipedia.org/wiki/Kontextsensitivit%C3%A4t\\_\(Informatik\)](https://de.wikipedia.org/wiki/Kontextsensitivit%C3%A4t_(Informatik)) (16. Juni 2016).
- [70] Wolf, Doris: Lebenshilfe ABC – Psychologie Lexikon: *Kognitive Dissonanz*, <http://www.lebenshilfe-abc.de/kognitive-dissonanz.html> (11. Juli 2016).
- [71] Ziemer, Tim: CHIP: *Was ist ein Plugin bzw. ein Addon?*, 2013, [http://praxistipps.chip.de/was-ist-ein-plugin-bzw-ein-addon\\_2863](http://praxistipps.chip.de/was-ist-ein-plugin-bzw-ein-addon_2863) (30. Juli 2016).

# Versicherung über Selbstständigkeit

*Hiermit versichere ich, dass ich die vorliegende Arbeit ohne fremde Hilfe selbstständig verfasst und nur die angegebenen Hilfsmittel benutzt habe.*

A handwritten signature in purple ink, reading "Janis Oinck".

Hamburg, den 30.08.2016

---