

# 10 Themenfeld Themenvielfalt

---

*Kristin Kutzner, Anna Maskvina, Ralf Knackstedt, Ulrich Heid*

## 10.1 Einleitung

In rezensiven Texten sprechen Rezensent\_innen unterschiedliche Themen an und teilen so mit anderen Plattform-Nutzer\_innen die eigenen Erfahrungen zum rezipierten Artefakt. In einer Buchrezension werden beispielsweise Themen wie das Genre, die Handlung, der Sprachstil oder der Unterhaltungswert angesprochen. Dass es hier eine sehr große Spannweite unterschiedlicher Themen gibt, zeigt das im Rez@Kultur-Projekt entwickelte Kategoriensystem (siehe Teil II, Kapitel 4). Wie viele verschiedene solche Themen in rezensiven Texten angesprochen werden, kann zur Charakterisierung kultureller Bildungsprozesse von Individuen beitragen (siehe Teil III). Die Untersuchung der Themenvielfalt rezensiver Texte liegt im Fokus dieses Kapitels und wird auf Korpus- und Textebene differenziert behandelt. Die Korpusebene berücksichtigt die Themenvielfalt auf ein gesamtes Korpus bezogen, während auf Textebene die Vielfalt an Themen in einzelnen rezensiven Texten von Interesse ist. Entsprechend verfolgen wir im Wesentlichen die Beantwortung von zwei Forschungsfragen:

**Forschungsfrage 1:** Wie lässt sich die Vielfalt an Themen eines Korpus rezensiver Texte kultureller Artefakte charakterisieren (Korpusebene)?

**Forschungsfrage 2:** Wie lässt sich die Vielfalt an Themen rezensiver Texte kultureller Artefakte charakterisieren (Textebene)?

Im Folgenden werden computergestützte Methoden zur Analyse der Themenvielfalt herangezogen, um erste Antworten auf die Forschungsfragen zu geben. Zunächst findet die Methode Topic Modeling Verwendung, um die Themen in

den Texten zu identifizieren sowie die Häufigkeit ihres Vorkommens in einem Korpus zu untersuchen und damit Antworten auf die erste Forschungsfrage zu liefern (siehe Abschnitt 10.2). Zur Beantwortung der zweiten Forschungsfrage werden anhand überwachter Klassifikationsverfahren des maschinellen Lernens und regelbasierter Extraktionen 20 ausgewählte Themen identifiziert, um auf deren Grundlage die Themenvielfalt pro rezensivem Text zu untersuchen (siehe Abschnitt 10.3). Weiterhin werden diese identifizierten Themen genutzt, um in rezensiven Texten nach Mustern in der Ansprache von Themen zu suchen. Hierzu werden die Methoden der Netzwerkanalyse (siehe Abschnitt 10.4) sowie der Clusteranalyse (siehe Abschnitt 10.5) herangezogen.

## 10.2 Topic Modeling

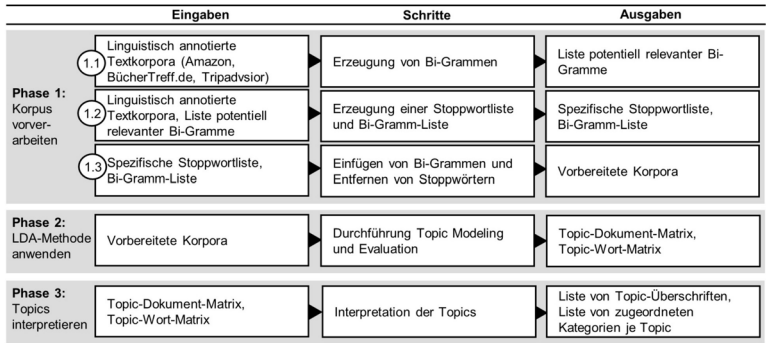
### 10.2.1 Vorgehen

Um zu untersuchen, welche Themen (d. h. Topics) in den betrachteten Textsammlungen angesprochen werden, erfolgt eine semiautomatische Inhaltsanalyse der rezensiven Texte unter Verwendung der Topic Modeling-Methode. Hierfür wählen wir den LDA-Ansatz (engl. **L**atent **D**irichlet **A**llocation) aus, eine auf Wahrscheinlichkeitsrechnung basierende Methode, die bereits häufig zur Analyse von Online-Rezensionen verwendet wurde (vgl. z. B. Lappas/Sabnis/Valkanias 2016; Seutter/Neumann 2019). LDA ist eine unüberwachte Methode des maschinellen Lernens, welche induktiv Topics, die unterschiedlichen Texten gemeinsam sind, identifiziert und Dokumente in mehrere Topics klassifiziert (vgl. Blei/Ng/Jordan 2003; Blei 2012). Die Idee, welche dem LDA-Ansatz zugrunde liegt, unterstellt, dass Rezensent\_innen  $d$  rezensive Texte (d. h. Dokumente) verfassen und dabei  $t$  Topics thematisieren. Dafür verwenden sie  $w$  Wörter aus einer diskreten Verteilung von Wörtern, die für jedes Topic typisch sind. Daher ist jedes Dokument durch eine Wahrscheinlichkeitsverteilung über eine festgelegte Menge von Topics und jedes Topic durch eine Wahrscheinlichkeitsverteilung über eine begrenzte Menge von Wörtern charakterisiert. Jedem rezensiven Text ist eine Wahrscheinlichkeit zwischen null und eins für die Zugehörigkeit zu jedem Topic zugeordnet (vgl. Debortoli et al. 2016), was in der *Topic-Dokument-Matrix* beschrieben wird. Für jedes Topic werden die Wörter, welche mit der größten Wahrscheinlichkeit dem Topic angehören, in der *Topic-Wort-Matrix* festge-

halten. Die Wörter ›Bruder‹, ›Schwester‹, ›Vater‹ und ›Mutter‹ erhalten beispielsweise eine hohe Wahrscheinlichkeit für das Topic ›Familie‹, während Wörter wie ›Fahrstuhl‹ oder ›Tasse‹ eher nicht in die Topic-Wort-Matrix Eingang finden.

Um Topics auf Korpusebene zu untersuchen, wird ein dreistufiger Ansatz verfolgt: (1) Zunächst werden die ausgewählten Korpora vorverarbeitet. (2) Anschließend dienen die vorverarbeiteten Korpora als Eingabe für die LDA-Methode. (3) Zuletzt erfolgt eine Interpretation der Topic Modeling-Ergebnisse (siehe Abbildung 10.1).

Abbildung 10.1: Methodisches Vorgehen – Topic Modeling, 2020



Quelle: Kristin Kutzner/Universität Hildesheim

**Phase 1: Korpus vorverarbeiten. (Schritt 1.1)** Als Datengrundlage werden die *linguistisch annotierten Textkorpora* von Amazon (27.636 rezensive Texte), *BücherTreff.de* (194.067 rezensive Texte) und *Tripadvisor* (6.396 rezensive Texte) ausgewählt. Auf Basis der drei Korpora werden zunächst N-Gramme von Wörtern der Länge zwei (d. h. *Bi-Gramme*) erzeugt, sodass eine *Liste potentiell relevanter Bi-Gramme* entsteht. In einem Bi-Gramm werden zwei aufeinanderfolgende Wörter kombiniert, wie zum Beispiel das Bi-Gramm »nicht gut« für die Wörter »nicht« und »gut«, sodass ein größerer Anteil der Textbedeutung erfasst wird, als bei Verwendung einzelner Wörter (vgl. Kawamae 2014). **(Schritt 1.2)** Um die Qualität der Topic Modeling-Ergebnisse zu erhöhen, sind ferner Wörter aus den Korpora zu entfernen, die keine Informationen zu den tatsächlichen Inhalten der rezensiven Texte liefern. Hierzu werden entsprechende Wörter identifiziert und einer *spezifischen Stoppwortliste* je Korpus hinzugefügt (vgl. Bo-

yd-Graber/Mimno/Newman 2014): Auf Grundlage der lemmatisierten Wörter werden häufig genutzte Wörter festgehalten, die keine Information zum Inhalt der rezensiven Texte liefern. Bei der Analyse von rezensiven Texten zu Büchern kommt beispielsweise das Wort ›Buch‹ sehr häufig vor, liefert für die Analyse jedoch keinen inhaltlichen Mehrwert. Außerdem werden häufig genutzte buch- oder museumsspezifische Wörter identifiziert, um buch(reihen)- und museumsübergreifende Topic-Ergebnisse zu erhalten. Rezensive Texte zu Büchern enthalten beispielsweise Namen, wie die Wörter ›Harry‹, ›Ron‹, ›Hogwarts‹ und ›Rowlings‹, die zu buchspezifischen Topic-Ergebnissen führen würden. Weiterhin werden häufig verwendete Wörter auf Basis der zugeordneten grammatikalischen Kategorien der Stoppwortliste hinzugefügt, die wenig Bedeutung mit sich bringen. Es werden zum Beispiel Pronomina, Artikel und Konjunktionen von der weiteren Analyse ausgeschlossen. Auch werden selten vorkommende Wörter (Vorkommen < 20 Mal) identifiziert, um den Einfluss von Ausreißern auf die Ergebnisse zu reduzieren. Neben einer Stoppwortliste ist weiterhin eine sogenannte *Bi-Gramm-Liste* je Korpus zu erzeugen. Hierfür werden die potentiell relevanten Bi-Gramme gesichtet, um diejenigen Bi-Gramme festzuhalten, die besonders inhaltsreich sind. **(Schritt 1.3)** Auf Grundlage der Stoppwortliste und der Bi-Gramm-Liste werden die *Korpora* als Textgrundlage für die Topic Modeling-Methode *vorbereitet*: Die Bi-Gramme werden in die Korpora eingefügt, indem nach den einzelnen aufeinanderfolgenden Wörtern gesucht und diese mit dem jeweiligen Bi-Gramm ersetzt werden. Des Weiteren werden die Wörter der Stoppwortliste aus den Korpora entfernt.

**Phase 2: LDA-Methode anwenden.** Bevor der LDA durchgeführt werden kann, ist zunächst die Anzahl der Topics festzulegen (vgl. Blei/Ng/Jordan 2003; Boyd-Graber/Mimno/Newman 2014). Da die Topic-Ergebnisse anschließend von Personen interpretiert werden sollen, ist grundsätzlich eine eher geringe Anzahl an Topics zu wählen (vgl. Debortoli et al. 2016) – hier zwischen zehn und 100 Topics. Anschließend wird die Interpretierbarkeit der Topic-Modelle mit unterschiedlicher Topic-Anzahl evaluiert, indem der Grad der semantischen Ähnlichkeit zwischen Wörtern eines Topics (d. h. die Topic-Kohärenz) nach dem Ansatz von Röder, Both und Hinneburg (2015) bestimmt wird. Für das Topic-Modell wird diejenige Topic-Anzahl mit dem höchsten Kohärenz-Wert ausgewählt. Weitere Parameter sind für das Topic-Modell festzulegen, wie die Hyperparameter  $\alpha$  und  $\beta$ , welche die Topic-Verteilung je Dokument und die Wortverteilung je Topic beeinflussen. Hierfür wird auf etablierte Standardwerte zurückgegriffen (vgl. Debortoli

et al. 2016). Zur Durchführung des LDA wurde die Open Source Bibliothek Gensim genutzt. Führt man die Topic Modeling-Methode durch, so können bedeutungslose Wörter in den Topic-Ergebnissen enthalten sein, wenn diese in der vorherigen Phase nicht als Stoppwort identifiziert wurden. Daher werden die Topic Modeling-Methode und die Korpusanpassungen (siehe Schritt 1.3 in Phase 1) mehrfach wiederholt. Beispielsweise können Rezensent\_innen in rezensiven Texten häufig spezifische Ausrufe wie ›omg‹ oder ›yeah‹ verwenden, die keine Information bezüglich des im Text behandelten Themas liefern und daher aus den Korpora entfernt werden sollten. Ergebnis dieser Phase ist eine *Topic-Dokument-Matrix*, die für alle Topics die Wahrscheinlichkeiten der Topic-Zugehörigkeit für alle rezensiven Texte aufzeigt, und eine *Topic-Wort-Matrix*, die für alle Topics die dazugehörigen Wörter mit der Wahrscheinlichkeit des Vorkommens für das Topic umfasst.

**Phase 3: Topics interpretieren.** In der letzten Phase geht es darum, den identifizierten Topics Bedeutungen zuzuschreiben. Diese Bedeutung wird mittels einer Analyse der wahrscheinlichsten Wörter je Topic in Kombination mit den dazugehörigen wahrscheinlichsten Dokumenten hergeleitet (vgl. Debortoli et al. 2016). Dazu betrachten drei Personen je Topic unabhängig voneinander eine geordnete Liste von Wörtern mit den dazugehörigen Wahrscheinlichkeiten. Je weiter vorne sich ein Wort in der Liste befindet, desto wahrscheinlicher ist dessen Zugehörigkeit zu dem jeweiligen Topic. Weiterhin werden Beispieltex te, die mit einer hohen Wahrscheinlichkeit einem Topic zugeordnet werden, betrachtet. Auf diese Weise bestimmen die Personen, sofern möglich, Überschriften für die Topics, welche die Bedeutung der Wörter zusammenfassen. Um zu prüfen, ob die Personen bei der Zuordnung der Überschriften übereinstimmen, wird das Maß der Übereinstimmung zwischen den Personen (›inter-coder agreement‹) berechnet (vgl. Lombard/Snyder-Duch/Bracken 2002). Dazu werden die Überschriften der Topics miteinander verglichen und mit einer ›1‹ markiert, sofern die Überschriften inhaltlich das Gleiche bezeichnen oder andernfalls mit einer ›0‹ markiert. Sofern die Übereinstimmung für eine Überschrift groß ist, wird eine Überschrift ausgewählt, welche von den involvierten Personen bestätigt bzw. verbessert wird. Ist die Übereinstimmung gering, bedarf es einer Diskussion der Personen bis eine gemeinsame Überschrift gefunden ist. Diese Schritte werden in einem Workshop durchgeführt, sodass je Korpus eine *Liste von Topic-Überschriften* resultiert. Um die Topic-Ergebnisse mit dem entwickelten Kategoriensystem (siehe Teil II, Kapitel 4) zu verschränken, werden

die resultierenden Topics außerdem von zwei unabhängigen Personen interpretiert und den Kategorien des Kategoriensystems zugeordnet. Wie zuvor beschrieben, wird auch hier das Maß der Übereinstimmung bestimmt und ein Workshop zur gemeinsamen Kategorienzuordnung durchgeführt. Es resultiert eine *Liste von zugeordneten Kategorien je Topic* für jedes Korpus.

10.2.2 Ergebnisse

Im Folgenden werden die Ergebnisse der Topic Modeling-Methode auf Grundlage der Daten von rezensiven Texten zu Büchern (*Amazon* und *BücherTreff.de*) sowie zu Museen (*Tripadvisor*) dargestellt.

Topics in rezensiven Amazon-Texten

Es wurden 14 Topics in den *Amazon*-Texten identifiziert, die jeweils mit den zehn wahrscheinlichsten Wörtern in einer Wortwolke dargestellt werden (siehe Abbildung 10.2). Je größer das Wort in einer Wortwolke, desto wahrscheinlicher ist dessen Zugehörigkeit zu dem Topic. Beispielsweise charakterisieren die Wörter ›kind‹, ›erwachsene‹ und ›klassiker‹ mit einer hohen Wahrscheinlichkeit das Topic To.


Abbildung 10.2: Wort-Topic-Verteilung Amazon, 2020



Quelle: Kristin Kutzner/Universität Hildesheim

Um die Topic-Verteilung über das gesamte *Amazon*-Korpus hinweg zu bestimmen, wird die Summe aller Wahrscheinlichkeiten der rezensiven Texte (in %) je Topic  $T_n$  bestimmt. Je höher die Summe der Wahrscheinlichkeiten eines Topics, desto mehr rezensive Texte thematisieren somit das Topic und desto prominenter ist das Topic für das gesamte Korpus (siehe Abbildung 10.3).

Abbildung 10.3: Topic-Verteilung Amazon, 2020



\* Prominentes Topic des Korpus aufgrund der hohen Summe der Wahrscheinlichkeiten des Vorkommens.

Quelle: Kristin Kutzner/Universität Hildesheim

Auf diese Weise lassen sich neun Topics identifizieren, die nur mit einer sehr geringen Summe der Wahrscheinlichkeiten (< 5 %) im Korpus adressiert werden: T0 (1,39 %), T3 (1,86 %), T4 (4,32 %), T5 (4,49 %), T7 (1,87 %), T10 (1,35 %), T11 (1,28 %), T12 (1,25 %) und T13 (4,51 %). Die restlichen fünf Topics T1 (7,39 %), T2 (25,50 %), T6 (8,90 %), T8 (24,27 %) und T9 (11,60 %) weisen die größten Summen der Wahrscheinlichkeiten auf, werden daher in besonders vielen rezensiven Texten thematisiert und sind prominente Topics des Korpus. Die Themenvielfalt zeichnet sich somit dadurch aus, dass besonders viele rezensive Texte diese fünf (von insgesamt 14 identifizierten) Topics aufgreifen. Dies führt zur folgenden Hypothese:

*Hypothese A1:* In rezensiven *Amazon*-Texten zu Büchern werden wenig prominente Themen angesprochen (geringe Themenvielfalt).

Die Interpretation der Topics durch die involvierten Personen (siehe Abbildung 10.1, Phase 3) liefert eine Liste an Überschriften, welche die Bedeutung der in den Wortwolken dargestellten Wörter je Topic beschreibt, sowie eine Liste an zugeordneten Kategorien des Kategoriensystems je Topic (siehe Tabelle 10.1). Die Topic-Überschriften sowie die zugeordneten Kategorien liefern Anhaltspunkte für adressierte Themen, die mit Hilfe der Topic Modeling-Methode in den rezensiven *Amazon*-Texten identifiziert werden konnten. Das Topic T<sub>0</sub> wird beispielsweise mit der Überschrift ›Ein Klassiker für Kinder und Erwachsene‹ betitelt und den Kategorien ›Rezeption/Wirkung/Erfolg des Rezensionsobjektes (4.2)‹, ›Bildungseffekt (Denkanstoß) (5.6.3)‹ sowie ›Zielgruppe des Rezensionsobjektes (5.10)‹ zugeordnet. Aufgrund des wahrscheinlichkeitsbasierten Ansatzes kommt es vor, dass Topics nicht interpretierbar sind und damit auch keine Überschrift oder Kategorienzuordnung erhalten – hier konnte dem Topic T<sub>11</sub> keine Überschrift und dem Topic T<sub>2</sub> sowohl keine Überschrift als auch keine Kategorie zugeordnet werden (siehe Tabelle 1).



Tabelle 10.1: Überschriften und Kategorien je Topic Amazon, 2020

Topic-Überschrift	Kategorien
(T0) Ein Klassiker für Kinder und Erwachsene	Rezeption/Wirkung/Erfolg des Rezensionsobjektes (4.2) Bildungseffekt (Denkanstoß) (5.6.3) Zielgruppe des Rezensionsobjektes (5.10)
(T1)* Figur und Handlung des Werks	Genre/Gattung (1.2.1) Figur (1.4.3)
(T3) Terrorismus in der Vergangenheit Amerikas	Handlung (1.4.2)
(T4) Familie	Handlung (1.4.2) Figur (1.4.3)
(T5) Gesellschaftliche Fragen und Themen in den USA	Thema/Sujet (1.4.1) Metadiskurs (politisch, ästhetisch, gesellschaftlich) (1.4.12)
(T6)* Gute Erklärungen zu verschiedenen Themen	Bezug auf das Rezensionsojekt insgesamt (holistischer Bezug) (1.3) Aufbau/Gliederung/Struktur des Rezensionsobjektes (1.4.7) Positive Wertung/Zustimmung (10.3.1) Thema/Sujet (1.4.1)
(T7) Hörbuch über deutsche Politik	Handlung (1.4.2) Bezug zur CD/Hörspiel/-buch/Comicbuch (3.1.2)
(T8)* Inhaltsbeschreibung mit Bezug zur Buchstruktur	Handlung (1.4.2) Aufbau/Gliederung/Struktur des Rezensionsobjektes (1.4.7) Bezug zu anderen Rezensionsobjekten (punktuel- ler Bezug, echte Intertextualität) (2.2)
(T9)* Empfehlung eines Films	Bezug auf das Erscheinungsbild/die Ausstattung des Rezensionsobjektes (1.5) Bezug zum Film (3.1.1) Rezensent_in-Beschreibung (Selbstthematisierung) (6) Positive Wertung/Zustimmung (10.3.1) Rezeptionsanweisung geben (10.4.7)

(T10) Unterhaltung	Metadiskurs (politisch, ästhetisch, gesellschaftlich) (1.4.12) Bezug zum Rezensionsobjekt in einem anderen Medium (3.1) Spannung, Unterhaltung (5.6.1) Bildungseffekt (Denkanstoß) (5.6.3) Erklären/erläutern/kontextualisieren (10.1.3)
(T11) –	Handlung (1.4.2) Danken (10.4.2)
(T12) Kaufempfehlung für einen gut gestalteten Comic	Genre/Gattung (1.2.1) Bezug auf das Erscheinungsbild/die Ausstattung des Rezensionsobjektes (1.5) Bezug zur CD/Hörspiel/-buch/Comicbuch (3.1.2) Rezeptionsanweisung geben (10.4.7)
(T13) Empfehlung und positive Bewertung des Buchs aufgrund der Sprache	Übersetzer_in (1.1.3) Sprache/Sprachstil (1.4.5) Zielgruppe des Rezensionsobjektes (5.10) Positive Wertung/Zustimmung (10.3.1) Rezeptionsanweisung geben (10.4.7)
T2* konnte weder eine Überschrift noch eine Kategorie zugeordnet werden. * Prominentes Topic des Korpus aufgrund der hohen Summe der Wahrscheinlichkeiten des Vorkommens.	

Quelle: Kristin Kutzner/Universität Hildesheim

## Topics in rezensiven *BücherTreff.de*-Texten

Die Analyse der rezensiven *BücherTreff.de*-Texte liefert 13 Topics, die wieder jeweils mit den zehn wahrscheinlichsten Wörtern in einer Wortwolke dargestellt werden (siehe Abbildung 10.4). Beispielsweise charakterisieren die Wörter ›thriller‹, ›falk‹ und ›krimi‹ mit einer hohen Wahrscheinlichkeit das Topic T2.


Abbildung 10.4: Wort-Topic-Verteilung BücherTreff.de, 2020



Quelle: Kristin Kutzner/Universität Hildesheim

Um die Topic-Verteilung über das gesamte BücherTreff.de-Korpus hinweg zu bestimmen und damit Topics mit einer hohen Summe der Wahrscheinlichkeiten des Vorkommens im Korpus zu identifizieren (»prominente Topics«), wird wieder die Summe aller Wahrscheinlichkeiten eines Topics bestimmt (siehe Abbildung 10.5).

Abbildung 10.5: Topic-Verteilung BücherTreff.de, 2020



\* Prominentes Topic des Korpus aufgrund der hohen Summe der Wahrscheinlichkeiten des Vorkommens.

Quelle: Kristin Kutzner/Universität Hildesheim

Vier Topics weisen jeweils eine geringe Summe der Wahrscheinlichkeiten ( $< 5\%$ ) im Korpus auf und werden in wenigen Texten thematisiert: T0 (2,59 %), T1 (1,04 %), T3 (2,70 %) und T12 (2,59 %). Die restlichen neun Topics – und somit die Mehrheit aller 13 identifizierten Topics – werden in vielen rezensiven Texten aufgegriffen. Demnach zeigt sich eine Themenvielfalt, die durch die folgenden neun prominenten Topics charakterisiert ist: T2 (5,23 %), T4 (5,90 %), T5 (13,45 %), T6 (5,13 %), T7 (5,23 %), T8 (8,93 %), T9 (19,03 %), T10 (6,41 %) und T11 (21,77 %). Dies führt zu einer weiteren Hypothese:

*Hypothese B1:* In rezensiven *BücherTreff.de*-Texten zu Büchern werden viele prominente Themen angesprochen (hohe Themenvielfalt).

Die Interpretation der Topics durch ausgewählte Personen liefert wieder eine Liste an Topic-Überschriften sowie eine Liste an zugeordneten Kategorien des Kategoriensystems (siehe Tabelle 10.2). Das Topic T2, mit den zuvor beschriebenen charakteristischen Wörtern (siehe oben und Abbildung 10.4), erhält beispielsweise die Überschrift ›Inhaltbeschreibung einer Kriminalgeschichte‹ und die Kategorien ›Genre/Gattung (1.2.1)‹, ›Handlung (1.4.2)‹ sowie ›Figur (1.4.3)‹ sind diesem Topic zugeordnet.

Tabelle 10.2: Überschriften und Kategorien je Topic BücherTreff.de, 2020

Topic-Überschrift	Kategorien
(T0) Danksagung für eine Vampir-Buchreihe	Bezug zu anderen Rezensionenobjekten des gleichen Urhebers (2.2.1) Entstehungs- und Veröffentlichungskontext (4.1) Danken (10.4.2)
(T1) Bezugnahme zu anderen Personen und zu sich selbst	Rezeptionsvorhaben/Rezeptionspläne (5.4) Bezug zu anderen Personen (8.2) Bezug zur Online-Plattform (8.3) Danken (10.4.2)
(T2)* Inhaltsbeschreibung einer Kriminalgeschichte	Genre/Gattung (1.2.1) Handlung (1.4.2) Figur (1.4.3)
(T3) Historischer Roman über Frankreich und England	Genre/Gattung (1.2.1) Handlung (1.4.2)
(T5)* Familienleben	Handlung (1.4.2) Figur (1.4.3)
(T6)* Allgemeine Buchinformationen	Bezug auf Meta-Daten des Rezensionenobjektes (1.1) Bezug zur Online-Plattform (8.3)
(T7)* Hintergründe zur Bucherscheinung	Genre/Gattung (1.2.1) Urheber_in (1.1.2) Veröffentlichungsdatum/Ausstellungszeitraum (1.1.8)
(T8)* Darstellung des Themas vom Autoren aus einer anderen Perspektive	Urheber_in (1.1.2) Thema/Sujet (1.4.1)
(T9)* Reflektion des Endes der Geschichte	Urheber_in (1.1.2) Handlung (1.4.2) Figur (1.4.3)
(T10)* Inhalt einer Abenteuergeschichte	Handlung (1.4.2)
(T12) Thematisierung des Originals und der Übersetzung	Titel (1.1.1) Übersetzer_in (1.1.3) Bezug auf das Erscheinungsbild/die Ausstattung des Rezensionenobjektes (1.5) Entstehungs- und Veröffentlichungskontext (4.1) Bezug zur Online-Plattform (8.3)
T4*, T11* konnte weder eine Überschrift noch eine Kategorie zugeordnet werden. * Prominentes Topic des Korpus aufgrund der hohen Summe der Wahrscheinlichkeiten des Vorkommens.	

Quelle: Kristin Kutzner/Universität Hildesheim

Topics in rezensiven *Tripadvisor*-Texten

Die Analyse der rezensiven *Tripadvisor*-Texte liefert 12 Topics, die wieder jeweils mit den zehn wahrscheinlichsten Wörtern in einer Wortwolke abgebildet werden (siehe Abbildung 10.6). Das Topic T0 wird beispielweise insbesondere durch die Wörter »gut«, »klein«, »café« und »essen« charakterisiert oder das Topic T1 durch die Wörter »sammlung«, »besuch«, »ausstellung« und »kunst«.


Abbildung 10.6: Wort-Topic-Verteilung *Tripadvisor*, 2020



Quelle: Kristin Kutzner/Universität Hildesheim

Zur Identifikation prominenter Topics des gesamten *Tripadvisor*-Korpus wird wieder die Summe der Wahrscheinlichkeiten aller rezensiven Texte für jedes Topic betrachtet (siehe Abbildung 10.7).

Abbildung 10.7: Topic-Verteilung Tripadvisor, 2020



\* Prominentes Topic des Korpus aufgrund der hohen Summe der Wahrscheinlichkeiten des Vorkommens.

Quelle: Kristin Kutzner/Universität Hildesheim

Lediglich das Topic T0 (4,46 %) weist eine geringe Summe der Wahrscheinlichkeiten ( $< 5$  %) auf und wird daher in wenigen Texten thematisiert. Die anderen elf Topics kommen in vielen Texten vor, sind damit prominent und tragen zur erhöhten Themenvielfalt bei: T1 (6,99 %), T2 (5,47 %), T3 (8,13 %), T4 (11,46 %), T5 (7,30 %), T6 (7,42 %), T7 (8,45 %), T8 (9,54 %), T9 (11,94 %), T10 (11,61 %) und T11 (7,24 %). Dies führt zu einer weiteren Hypothese:

*Hypothese T1:* In rezensiven Tripadvisor-Texten zu Museen werden viele prominente Themen angesprochen (hohe Themenvielfalt).

Weiterhin liefert die Interpretation der Topics durch ausgewählte Personen wieder eine Liste an Topic-Überschriften sowie eine Liste an zugeordneten Kategorien je Topic (siehe Tabelle 10.3). Das Topic T0 mit den zuvor beschriebenen charakteristischen Wörtern (siehe oben und Abbildung 10.6) erhält zum Beispiel die Überschrift ›Gastronomie‹ und die Kategorie ›Off-Topic (ohne Bezug zum Rezensionsojekt) (9)‹. Diese Kategorie wird aufgrund des scheinbar nicht vorhandenen Bezugs zum Museum diesem Topic zugeordnet. Das Topic T1 erhält die Überschrift ›Besuch einer Kunstausstellung und positive Bewertung‹ und die Kategorien ›Bezug auf das Rezensionsojekt insgesamt (holistischer Bezug) (1.3)‹, ›Ort der Rezeption (5.7)‹ und ›Positive Wertung/Zustimmung (10.3.1)‹ sind dem Topic zugeordnet.

Tabelle 10.3: Überschriften und Kategorien je Topic Tripadvisor, 2020

Topic-Überschrift	Kategorien
(T0) Gastronomie	Off-Topic (ohne Bezug zum Rezensionsobjekt) (9)
(T1)* Besuch einer Kunstausstellung und positive Bewertung	Bezug auf das Rezensionsobjekt insgesamt (holistischer Bezug) (1.3) Ort der Rezeption (5.7) Positive Wertung/Zustimmung (10.3.1)
(T2)* Thematisierung verschiedener Werke und Künstler*innen	Urheber_in (1.1.2) Bezug auf das Rezensionsobjekt insgesamt (holistischer Bezug) (1.3) Handlung (1.4.2) Bezug auf das Erscheinungsbild/die Ausstattung des Rezensionsobjektes (1.5)
(T3)* Kunstsammlung	Bezug auf das Rezensionsobjekt insgesamt (holistischer Bezug) (1.3) Bezug auf das Erscheinungsbild/die Ausstattung des Rezensionsobjektes (1.5) Ort der Rezeption (5.7)
(T4)* Positive Wertung der Umgebung der Kunstausstellung	Ort der Rezeption (5.7) Zeit der Rezeption (5.3) Positive Wertung/Zustimmung (10.3.1)
(T5)* Besuchenswerte Ausstellung zum Jahresende	Bereitstellungsgeschichte des Rezensionsobjektes (5.2) Zeit der Rezeption (5.3) Positive Wertung/Zustimmung (10.3.1) Rezeptionsanweisung geben (10.4.7)
(T6)* Immer wieder besuchenswerte Ausstellung	Bereitstellungsgeschichte des Rezensionsobjektes (5.2) Zeit der Rezeption (5.3) Positive Wertung/Zustimmung (10.3.1) Rezeptionsanweisung geben (10.4.7)
(T7)* Sonderausstellung für Moderne Kunst und Fotografie	Genre/Gattung (1.2.1) Bezug auf das Rezensionsobjekt insgesamt (holistischer Bezug) (1.3) Ort der Rezeption (5.7)
(T8)* Mit Genuss und Weile durch eine schöne Ausstellung	Zeit der Rezeption (5.3) Rezeptionsdauer (5.3.1) Positive Wertung/Zustimmung (10.3.1)



(T9)* Schön zu begehende Gartenanlage mit Fußläufigkeit zum Hotel	Zeit der Rezeption (5.3) Ort der Rezeption (5.7) Rezensent_in-Beschreibung (Selbstthematization) (6) Rezeptionsanweisung geben (10.4.7)
(T10)* Besuch einer Kunstausstellung	Rezensent_in-Beschreibung (Selbstthematization) (6)
(T11)* Beschreibung der Erreichbarkeit der Örtlichkeit	Ort der Rezeption (5.7) Rezensent_in-Beschreibung (Selbstthematization) (6) Positive Wertung/Zustimmung (10.3.1)
* Prominentes Topic des Korpus aufgrund der hohen Summe der Wahrscheinlichkeiten des Vorkommens	

Quelle: Kristin Kutzner/Universität Hildesheim

### 10.2.3 Zusammenfassung

Die Topic Modeling-Methode erlaubt die Identifikation von Themen in rezensiven Texten und eine Untersuchung dahingehend, inwiefern diese Themen in vielen Texten angesprochen werden und damit besonders prominent für ein gesamtes Korpus sind. Je mehr prominente Themen, desto vielfältiger ist die Ansprache von Themen in einem Korpus. Die hier beschriebene Untersuchung verdeutlicht dies beispielhaft für drei Korpora. In unserem Datenausschnitt zeigt sich in den rezensiven Texten von *BücherTreff.de* und *Tripadvisor* eine hohe Themenvielfalt, in den *Amazon*-Texten hingegen eine geringe Themenvielfalt. Die Interpretation der Topic-Ergebnisse, insbesondere die Zuordnung von Kategorien zu Topics, verdeutlicht, dass die Topics durchaus weiter differenziert werden können und nicht ausschließlich einem einzelnen Thema zuzuordnen sind: Weitestgehend wurden den Topics mehrere Kategorien zugeordnet. Somit können die Topics selbst mehrere Themen einschließen, was Auswirkungen auf die Bewertung der Themenvielfalt haben kann. Außerdem ordnet die Topic Modeling-Methode jedem rezensiven Text eine Wahrscheinlichkeit für die Zugehörigkeit zu jedem Topic zu (vgl. Debortoli et al. 2016). Dabei kommt es oft vor, dass einem Text vorrangig ein oder zwei Topics zugeordnet werden, da diese mit Abstand die größten Wahrscheinlichkeiten aufweisen. Wurde beispielsweise ein Topic-Modell mit 14 Topics erzeugt, so kann die Wahrscheinlichkeit für die Zugehörigkeit eines Topics zu einem Dokument bei 40 % liegen, während

sich die restlichen 60 % der Wahrscheinlichkeiten auf die anderen 13 Topics aufteilen und damit sehr gering ausfallen. Somit identifiziert die Methode oft nur wenig verschiedene Themen für ein Dokument, was eine Analyse der Themenvielfalt bezogen auf einzelne rezensiven Texte nicht umfassend erlaubt, sodass in den folgenden Abschnitten weitere Methoden zur Untersuchung herangezogen werden.

## 10.3 Automatische und manuelle Methoden

### 10.3.1 Vorgehen

In Abschnitt 10.2 wurden drei Korpora rezensiver Texte (rezensive Texte zu Büchern aus *Amazon* und *BücherTreff.de* sowie zu Kunstwerken und Ausstellungen aus *Tripadvisor*) mit Hilfe von Topic Modeling auf Themenvielfalt hin untersucht. Im vorliegenden Abschnitt wird das Untersuchungsfeld auch auf Literatur- und Kulturblogs erweitert, und die rezensiven Texte werden nicht als drei große Textmengen, sondern auf der Ebene je einzelner rezensiver Texte betrachtet. Gleichzeitig werden Methoden des maschinellen Lernens angewandt, unterstützt durch korpuslinguistische Suchverfahren.

Wie in Abschnitt 10.2 werden die Themen über den Zusammenhang mit den Kategorien des Kategoriensystems aus Kapitel 4 charakterisiert. Während aber bei der Topic Modeling-Methode automatisch zu »Topics« gruppierte Wörter den Kategorien zugeordnet wurden, also ein *datengetriebener* Ansatz verfolgt wurde, wird hier umgekehrt vorgegangen: Wir nehmen in einem *hypothesengesteuerten* Ansatz (vgl. zu diesen zwei Ansätzen Dipper 2008) an, dass es in den rezensiven Texten jeweils bestimmte Indikatorwörter gibt, die für eine bestimmte Kategorie aus dem Kategoriensystem charakteristisch sind, und von denen ausgehend sich die Kategorien in den Texten identifizieren lassen.

Um die Vielfalt der Themenbehandlung in einzelnen rezensiven Texten zu ermitteln, werden zwei Ansätze zur Identifikation der Kategorien verfolgt: Einerseits überwachte Klassifikationsverfahren des maschinellen Lernens, mit denen zunächst sechs Kategorien identifiziert werden – *automatisierte Themenidentifikation* (AT). Andererseits werden in der Tradition semi-automatischer korpuslinguistischer Arbeiten oder diktionsär-basierter Methoden aus den digitalen Geisteswissenschaften durch Suchanfragen (regelbasierte

Extraktion mit manuell erstellten Anfragen) weitere 14 Kategorien identifiziert – *manuelle Themenidentifikation (MT)*. In Tabelle 10.4 ist zusammengefasst, welche Kategorien mit welchem Ansatz identifiziert wurden.

Die beiden Ansätze haben unterschiedliche Vorbedingungen und unterschiedliche erwartbare Limitationen: Der automatisierte Ansatz (Ansatz 1) erfordert eine große Sammlung an Trainingsdaten, also Textzonen mit manuell korrekt zugeordneten Kategorien, aber er ermöglicht nach erfolgreicher Modellentwicklung die automatisierte Themenidentifikation: Überwachtes maschinelles Lernen setzt voraus, dass typische Beispiele für eine Kategorie ebenso wie Gegenbeispiele bereitgestellt werden, die diese Kategorie nicht aufweisen. Die manuelle Themensuche dagegen (Ansatz 2) erfordert die Bestimmung von lexikalischen Indikatoren, nach denen man in den Texten sucht. Gefunden werden dabei nur Stellen, die einen Indikator enthalten – die Kreativität der Rezensent\_innen bei der Themenformulierung kann aber durch die (endliche) Indikatorenliste nicht vollständig erfasst werden. Gleichmaßen ist zu berücksichtigen, dass beide Verfahren nur einen Ausschnitt aus den durch das Kategoriensystem beschriebenen Themen erfassen (vgl. Tabelle 10.4). Beide Ansätze werden im Folgenden dargestellt.

Tabelle 10.4: Überblick über die extrahierten Kategorien, 2020

Extrahierte Kategorie	Ansatz
Verlag/Museum (1.1.4)*	MT
Kaufpreis (1.1.6)	MT
ISBN-Angabe (1.1.7)	MT
Thema/Sujet (1.4.1)	MT
Handlung (1.4.2)	MT
Figur (1.4.3)	MT
Im Rezensionsobjekt dargestellte Emotionen (1.4.4)**	MT
Sprache/Sprachstil (1.4.5)	AT
(Erzähl-)Perspektive (1.4.6)	AT
Erscheinungsbild/Ausstattung des Rezensionsobjektes (materiell, visuell, taktil, olfaktorisch etc.)(1.5)	MT
Bezug zum Rezensionsobjekt in einem anderen Medium (3.1)	MT
Eigene Emotionen (5.6.4)**	MT
Verständlichkeit (5.8)	AT
Erforderliche Kompetenz für das Rezensionsobjekt (5.9)	AT
Zielgruppe des Rezensionsobjektes (5.10)	AT
Eigene Kompetenz (6.2)	AT
Bezug zu anderen rezensiven Texten (8.1)	MT
Bezug auf eine Einzelperson (8.2.1)	MT
Bezug zur Online-Plattform (8.3)	MT
Rezeptionsanweisung geben (10.4.7)	MT
AT = automatisierte Themenidentifikation; MT = manuelle Themenidentifikation	
* Diese Kategorie wurde zweigeteilt in Verlag (1.1.4) und Museum (1.1.4).	
** Diese Kategorie wurde mit einer anderen Kategorie zusammengefasst und generalisiert zu Emotion im Allgemeinen (1.4.4/5.6.4).	

Quelle: Kristin Kutzner/Universität Hildesheim

**Ansatz 1: Automatisierte Themenidentifikation (AT).** Um ein auf überwach-  
ten maschinellen Lernverfahren beruhendes Themenidentifikationssystem  
zu entwickeln, wurden zwei sich ergänzende Prinzipien zur Gewinnung der  
nötigen Trainingsdaten verfolgt: Einerseits (a) die *manuelle Annotation* von

Textstücken (Sätzen oder Wortfolgen) mit Kategorien, also die klassische Herangehensweise bei überwachtem maschinellen Lernen, andererseits (b) die *Extraktion von Indikatoren* ähnlich wie bei Ansatz 2 aus dem manuell annotierten Material und deren Nutzung für die Korpusuche, zur Gewinnung weiteren Trainingsmaterials.

(a) *Lernen aus manuellen Annotationen*. Tabelle 10.5 stellt die Kennzahlen der manuellen Annotation zusammen. Sie wurde in drei Iterationen (Tabelle 10., Spalte: *Iteration*) zu verschiedenen Zeitpunkten (*Datum*) durchgeführt, jeweils mit anderem Textmaterial (*Korpus*) und anderen Teilmengen des Kategoriensystems ( $n_k$ ). Studierende unterschiedlicher Disziplinen und Forscher\_innen des Projektteams (*Annotierende*) analysierten hier manuell eine erhebliche Anzahl an rezensiven Texten ( $n_r$ ).

*Tabelle 10.5: Kennzahlen der manuellen Annotation von Kategorien zur Gewinnung von Trainingsdaten, 2020*

Iteration	Datum	Korpus	$n_k$	$n_r$	Annotierende
1	05/2018	Amazon	150	430	Studierende der Informationswissenschaft
2	05/2019	BücherTreff.de	40	90	Studierende der Literaturwissenschaft
3	01/2020	Kunstoffblogs	alle	20	Forscher_innen des Projektteams

Quelle: Ulrich Heid/Universität Hildesheim

Die erste Iteration zielte auf eine satzweise Annotation (Bedeutung: »Satz enthält einen Indikator für Kategorie X«), die nachfolgenden auf Wörter und Wortsequenzen (Bedeutung: »die markierten Wörter zeigen die Kategorie X an«). Es zeigte sich, dass die Ausnutzung des gesamten Kategoriensystems aufgrund der Vielzahl an Kategorien die manuelle Annotationsaufgabe schwierig machte, sodass in Iteration 2 jeweils nur eine Teilmenge des Kategoriensystems annotiert wurde.

Die experimentellen Annotationsrunden dienten neben der Erhebung von Trainingsmaterial auch der Überprüfung und Stabilisierung des Kategoriensystems; wegen der Verschränkung beider Aufgaben und der Tatsache, dass von satzweiser auf wortgruppenweise Annotation übergegangen wurde, konnte keine durchgängige Evaluation der Annotationsqualität realisiert

werden, die für alle Runden gezeigt hätte, wie groß die Übereinstimmung zwischen den einzelnen Annotator\_innen ist (vgl. z. B. Cohen 1960, Fleiß 1971 oder Hayes und Krippendorff 2007); für die erste Annotationsrunde finden sich aber Angaben dazu in Kutzner et al. 2018.

Das Kategoriensystem aus Kapitel 4 enthält über 100 Kategorien, und viele davon sind nur in wenigen rezensiven Texten annotiert worden (»sparse data-Problem«), sodass für sie Trainingsmaterial fehlt. Für ein erstes Experiment zum maschinellen Lernen wurden daher sechs Kategorien ausgewählt (siehe Tabelle 10.6), für die (i) jeweils mehr als 30 eindeutig annotierte Belege vorhanden waren, und die (ii) von Relevanz für die Frage sind, ob und wie Rezensent\_innen über eigene oder fremde kulturelle Bildungsereignisse schreiben. Diese sechs Kategorien sind: *Sprache/Sprachstil* (1.4.5), *(Erzähl-)Perspektive* (1.4.6), *Verständlichkeit* (5.8), *erforderliche Kompetenz für das Rezensionsobjekt* (5.9), *Zielgruppe des Rezensionsobjektes* (5.10) und *eigene Kompetenz* (6.2).

Tabelle 10.6: Suchmuster ( $n_M$ ), Anzahl gefundene Sätze ( $n_S$ ) und positive Belege ( $n_{PB}$ ) für ausgewählte Kategorien, 2020

Kategorie	$n_M$	$n_S$	$n_{PB}$	(%)
Sprache/Sprachstil (1.4.5)	26	1644	643	39 %
(Erzähl-)Perspektive (1.4.6)	2	867	418	48 %
Verständlichkeit (5.8)	9	1680	407	24 %
Erforderliche Kompetenz für das Rezensionsobjekt (5.9)	10	204	59	29 %
Zielgruppe des Rezensionsobjektes (5.10)	9	2124	361	17 %
Eigene Kompetenz (6.2)	39	87	49	56 %

Quelle: Anna Moskvina/Universität Hildesheim

Für diese sechs Kategorien wurden die Annotationen aus der ersten Iteration als Trainingsdaten für das maschinelle Lernen aufbereitet, und es wurden sechs binäre Klassifikatoren trainiert. Jeder Klassifikator soll entscheiden, ob die entsprechende Kategorie vorliegt oder nicht. Das verfügbare Textmaterial wurde im Verhältnis 9:1 in Trainingsdaten (aus denen das System lernt) und Validierungsdaten (zum Test der Klassifizierungsqualität) aufgeteilt. Für jede Kategorie wurden jeweils drei Klassifizierungsalgorithmen in der

scikitLearn-Implementierung in Kombination mit eigenen Python-Skripten trainiert: (Support Vector Machines (Cortes/Vapnik 1995), Logistic Regression (Cramer 2002), Entscheidungsbaumklassifizierer (Breiman et al. 1984).

(b) *Extraktion von Indikatoren als weiteres Trainingsmaterial.* Aus der manuellen Annotation ergeben sich nur relativ wenige Belege, die eine der sechs Kategorien repräsentieren. Dem stehen aber sehr viele Sätze als Gegenbeispiele gegenüber, also solche, wo die gesuchte Kategorie nicht vorliegt. Um gute automatische Klassifikationsergebnisse zu erhalten, benötigt man aber möglichst viele Belege und ein ausgeglicheneres Verhältnis zwischen positiven und negativen Belegen. Um mehr positive Belege zu finden, wurden die manuell annotierten Textstellen daher (i) von Hand auf lexikalische Indikatoren durchsucht, wurden (ii) für diese Indikatoren jeweils symbolische Korpusanfragen formuliert und (iii) die Suchergebnisse manuell nach ihrer Relevanz für die jeweilige Kategorie bewertet. Die so gefundenen positiven Belege wurden zur Trainings- bzw. Validierungsmenge für die maschinellen Lernverfahren hinzugenommen.

Bei der Erstellung der Indikator-Suchanfragen zeigt sich die Variationsbreite der Ausdrucksweisen, mit denen z. B. eine Kategorie wie die Beschreibung der eigenen Kompetenz (6.2) verbalisiert werden kann: für diese Kategorie wurden nicht weniger als 39 Suchmuster auf Basis von Wörtern, Wortverbindungen und Wortartannotationen implementiert. Ein Beispiel ist das Textstück *»ich...mich...auskenne«*; es findet z. B. *»dabei hätte ich das eigentlich wissen müssen, nachdem ich mich in Safiers Karmawelt doch schon recht gut auskenne«* (Amiras Bibliothek, Rez 132). Weil die Suchmuster aber wortstellungsabhängig sind, braucht es eine zweite Anfrage für *»kenne ich mich ... aus«*. Tabelle 10.6 stellt für die untersuchten Kategorien zusammen, wie viele Suchmuster ( $n_M$ ) entwickelt wurden, wie viele Sätze ( $n_S$ ) sie extrahiert haben und wie viele davon positive Belege ( $n_{PB}$ ) sind. Nahezu alle Muster finden auch irrelevantes Material (noise), das manuell entfernt werden muss, damit die Trainingsdaten ein möglichst klares Bild typischer Fälle ergeben, aus denen das System trennscharfe Abgrenzungen lernen kann. Sucht man z. B. nach *»aus ... Sicht«*, so findet man neben positiven Belegen für die Kategorie Erzählperspektive (1.4.6: *»wird aus der Sicht Mirandas [...] erzählt«*, *Bücher-Treff.de*, Rez 14710) auch unbrauchbare Textstücke, wie z. B. *aus meiner Sicht*, *aus politischer Sicht*.

Durch die Nutzung der Suchmuster konnte die Menge an positiven Belegen, die für die Entwicklung der Klassifikationswerkzeuge genutzt werden konnten, vergrößert werden.

Neben den Trainingsdaten spielen aber auch die Eigenschaften (Merkmale, Features) der Wörter eine Rolle, aus denen die Klassifizierer entscheidungsrelevantes Wissen ableiten sollen. Der üblichen Vorgehensweise im Machine Learning folgend wurden für alle Kategorien die untersuchte Wortform, ihr Lemma (d. h. ihre Grundform aus dem Lexikon) und ihre Wortart berücksichtigt. Ebenso für das Wort links von der untersuchten Wortform, also für ihr Vorgänger-Wort im Kontext. Weitere berücksichtigte Merkmale sind Angaben zur grammatischen Funktion (Subjekt, direktes bzw. indirektes Objekt usw.) und zur semantischen Klasse im Wörternetz GermaNet (Hamp/Feldweg 1997), einem nach Themen geordneten deutschen elektronischen Wörterbuch.

Man misst dann die Ergebnisqualität, die verschiedene Klassifikationsalgorithmen mit verschiedenen Kombinationen der Features liefern und bestimmt so die beste Konfiguration aus Algorithmus und Featurekombination. Für die Kategorien *Eigene Kompetenz* (6.2), *Erforderliche Kompetenz für das Rezensionsojekt* (5.9) und *Zielgruppe des Rezensionsojektes* (5.10) erwiesen sich Support Vector Machines (SVM, Cortes/Vapnik 1995) als besonders geeignet, die zusätzlich zu den eben genannten Merkmalen auch Segmente aus drei Wörtern (sog. Trigramme) berücksichtigen, also etwas mehr »Kontext« bzw. typische Wortverbindungen. Für die Kategorie *(Erzähl-)Perspektive* (1.4.6) erwies sich SVM mit Wort-Paaren als optimal, für die Kategorien *Sprache/Sprachstil* (1.4.5) und *Verständlichkeit* (5.8) wiederum Ansätze, die Trigramme benutzen, und zwar Logistic Regression (Cramer 2002) für *Sprache/Sprachstil* (1.4.5) und Entscheidungsbaumklassifizierer (Breiman et al. 1984) für *Verständlichkeit* (5.8). Die optimalen Konfigurationen wurden dann auf Trainings- und Validierungsdaten zusammen trainiert und die entstandenen Modelle auf Daten aller Korpora angewandt<sup>15</sup>.

**Ansatz 2: Manuelle Themenidentifikation (MT).** Neben den sechs automatisiert identifizierten Kategorien wurden 14 weitere Kategorien in den rezensiven Texten gesucht, die auf einfache Weise regelbasiert mit Suchan-

15 Die Kategorien *(Erzähl-)Perspektive* (1.4.6) und *Sprache/Sprachstil* sind natürlich nur für Literaturrezensionen relevant, wurden also nur auf die 10 Literatur-Blogs, *BücherTreff.de* und *Amazon* angewandt.



fragen über lexikalische Indikatoren zu finden sind. Zum Teil genügt eine Suche mit einzelnen Wörtern, die die Kategorie benennen. So z. B. die Wörter *Thema*, *thematisieren*, *Thematik*, *Sujet* für die Kategorie *Thema/Sujet* (1.4.1); ähnliches gilt für *Handlung* (1.4.2), *Erscheinungsbild/Ausstattung des Rezeptionsobjektes* (materiell, visuell, taktil, olfaktorisch, 1.5), *Bezug zu anderen rezensiven Texten* (8.1). Für andere Kategorien wurden Listen von Indikatorwörtern angelegt oder publizierte solche Listen benutzt (z. B. für Emotionen eine Liste aus Klinger et al. 2016). Beispiele sind *Verlag/Museum* (1.1.4), *eigene Emotionen* (5.6.4) bzw. im *Rezeptionsobjekt dargestellte Emotionen* (1.4.4), *Rezeptionsanweisung geben* (10.4.7), *Bezug zur Online-Plattform* (8.3), *Bezug zum Rezeptionsobjekt in einem anderen Medium* (3.1). Für den *Kaufpreis* (1.1.6), die *ISBN-Angabe* (1.1.7) und den *Bezug auf eine Einzelperson* (8.2.1) wurden lexikalisch-strukturelle Regeln geschrieben.

### 10.3.2 Ergebnisse

Auf Grundlage der zwei oben beschriebenen Ansätze sind 20 Kategorien unseres Systems identifizierbar geworden (siehe Tabelle 10.4). Für diese 20 Kategorien geben wir zunächst rein quantitativ einige Kennzahlen an (vgl. Tabelle 10.7): die mittlere Anzahl an Kategorien, die in einem rezensiven Text vorkommt ( $\bar{k}_r$ ), die Standardabweichung der mittleren Anzahl der Kategorien je rezensivem Text  $St(\bar{k}_r)$ , die Anzahl an Kategorien, welche in der größten Teilmenge der rezensiven Texte jeder Plattform ( $n_k$ ) vorfindlich sind, sowie die maximale und die minimale Anzahl von Kategorien je rezensivem Text ( $n_{k\_max,r}$ ,  $n_{k\_min,r}$ ). Die Zahlen für *BücherTreff.de* erklären sich z. B. wie folgt: Über alle rezensiven Texte gemittelt finden sich sechs Themen je Text ( $\bar{k}_r = 6$ ) mit einer Standardabweichung von 3,38 Kategorien  $St(\bar{k}_r) = 3,38$ . Rezensive Texte mit drei Themen machen aber, wenn man die rezensiven Texte danach gruppiert, wie viele Themen sie enthalten, die größte Teilmenge aus ( $n_k = 3$ ). Insgesamt gibt es große Unterschiede hinsichtlich der Anzahl an Themen aus der Stichprobe der 20 ausgewählten Kategorien: einzelne rezensive Texte enthalten bis zu 17 der 20 Kategorien, andere gar keine. Das heißt natürlich nicht, dass solche rezensiven Texte nicht ebenfalls verschiedene Themen besprechen würden – nur eben keines aus der Stichprobe. Hier ist also daran zu erinnern, dass (a) die 20 Themen weniger als 20 % der Kategorien des Kategoriensystems ausmachen (siehe Kapitel 4) und (b) die drei

Kategorien (*Erzähl-*)*Perspektive* (1.4.6), *Sprache/Sprachstil* (1.4.5) und *ISBN-Angabe* (1.1.7) ausschließlich für Buchrezensionen relevant sind.

Tabelle 10.7: Kennzahlen zu den extrahierten Kategorien je Korpus, 2020

Korpus	$\bar{k}_r$	$St(\bar{k}_r)$	$n_k$	$n_{k,max,r}$	$n_{k,min,r}$
Amazon	5	1,95	5	14	0
BücherTreff.de	6	3,38	3	17	0
Tripadvisor	4	1,36	3	10	0
Literaturblogs (gesamt)	9	2,04	9	17	0
Kunstablogs (gesamt)	7	2,11	7	13	1

Quelle: Anna Moskвина/Universität Hildesheim

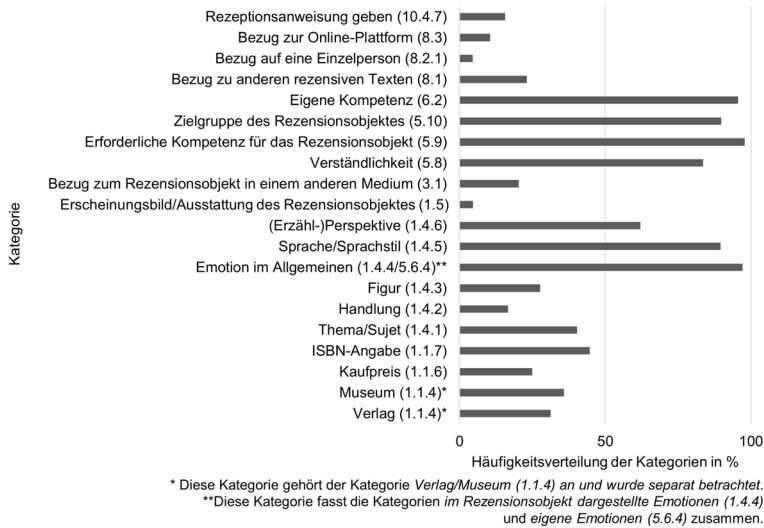
Es zeigt sich, dass auf Blogs verfasste rezensive Texte im Mittel mehr Themen umfassen als solche, die auf den Online-Plattformen *Amazon*, *BücherTreff.de* und *Tripadvisor* veröffentlicht wurden. Gruppiert man die rezensiven Texte jeder Quellenart danach, wie viele der 20 ausgewählten Kategorien in der jeweils größten Teilmenge (derjenigen mit den meisten Einzeltexten) angesprochen werden ( $n_k$ ), so erscheinen Literatur- und Kunstblogs ebenfalls als thematisch vielfältiger als die großen Plattformen ( $n_{K\_Literaturblogs} = 9$ ,  $n_{K\_Kunstablogs} = 7$ ,  $n_{K\_Amazon} = 5$ ,  $n_{K\_Büchertreff} = 3$ ,  $n_{K\_Tripadvisor} = 3$ ). Zusammenfassend können wir also – mit den wegen des Stichprobencharakters der Untersuchung nötigen Einschränkungen – als erstes Zwischenergebnis annehmen, dass rezensive Texte, die auf Blogs zu Themen von Literatur und Kunst verfasst werden, mehr verschiedene Themen adressieren (also thematisch vielfältiger sind) als solche auf den großen Plattformen *Amazon*, *BücherTreff.de* und *Tripadvisor*.

Bisher wurden die Texte der einzelnen Quellenarten danach untersucht, wieviele der 20 Kategorien sie jeweils durchschnittlich enthalten. Man kann aber auch fragen, ob bestimmte Kategorien in sehr vielen Texten präsent sind, andere aber nur in relativ wenigen Texten thematisiert werden. Das würde für eine gewisse Gleichförmigkeit der rezensiven Texte in Bezug auf das Themenspektrum sprechen.

Dazu wird betrachtet, in welchem Prozentsatz der rezensiven Texte die 20 Kategorien jeweils nachgewiesen werden konnten. Abbildung 10.8 stellt

solche Angaben für das Gesamtkorpus zusammen, also gemittelt über alle Texte aller Quellen. In Abbildung 10.9 sind die Zahlen für die drei Online-Plattformen *Amazon*, *BücherTreff.de* und *Tripadvisor* aufgeteilt.

Abbildung 10.8: Häufigkeitsverteilung extrahierter Kategorien (in %) über alle Korpora hinweg, 2020




Quelle: Kristin Kutzner/Universität Hildesheim

Die in Abbildung 10.8 zusammengestellten Daten zeigen, dass viele der extrahierten Kategorien auch relativ häufig in den Texten identifiziert werden konnten – 15 der 20 betrachteten Kategorien kommen jeweils mit über 20 % in den rezensiven Texten vor, 7 von 20 in mehr als 50 % der Texte. Besonders häufig konnten die Kategorien *erforderliche Kompetenz für das Rezensionsobjekt* (5.9, 98 %), *Emotion im Allgemeinen* (1.4.4/5.6.4, 97 %), *eigene Kompetenz* (6.2, 96 %), *Zielgruppe des Rezensionsobjektes* (5.10, 90 %) sowie *Sprache/Sprachstil* (1.4.5, 90 %) identifiziert werden. Besonders selten zeigten sich hingegen die Kategorien *Bezug auf eine Einzelperson* (8.2.1, 5 %), *Erscheinungsbild/Ausstattung des Rezensionsobjektes* (1.5, 5 %) und *Bezug zur Online-Plattform* (8.3, 10 %).

Um darüber hinaus die Themenvielfalt plattformspezifisch zu untersuchen, betrachten wir beispielhaft die Häufigkeitsverteilung der Kategorien

in rezensiven Texten aus *Amazon*, *BücherTreff.de* und *Tripadvisor* (siehe Abbildung 10.9).

Abbildung 10.9: Häufigkeitsverteilung extrahierter Kategorien für Amazon, BücherTreff.de und Tripadvisor, 2020



\* Diese Kategorie gehört der Kategorie *Verlag/Museum (1.1.4)* an und wurde separat betrachtet.

\*\* Diese Kategorie fasst die Kategorien im Rezensionsobjekt dargestellte Emotionen (1.4.4) und eigene Emotionen (5.6.4) zusammen.

Quelle: Kristin Kutzner/Universität Hildesheim

Über alle drei Plattformen hinweg prominent (d. h. in mehr als 50 % der Texte nachweisbar) sind die Kategorien *eigene Kompetenz* (6.2), *Zielgruppe des Rezensionsobjektes* (5.10), *erforderliche Kompetenz für das Rezensionsobjekt* (5.9) und *Emotion* (1.4.4./5.6.4). Jeweils für Literatur bzw. Kunst relativ prominent sind *Sprache/Sprachstil* (1.4.5) und die Angabe des *Museums* (1.1.4), in dem eine Ausstellung besucht wurde. Die 14 anderen Kategorien treten eher selten auf; das betrifft sowohl formale Aspekte der Rezensionsobjekte (z. B. *Kaufpreis* (1.1.6) oder *Erscheinungsbild/Ausstattung des Rezensionsobjektes* (1.5)), als auch inhaltliche (*Thema* (1.4.1), *Handlung* (1.4.2)) oder auf die Interaktion mit anderen Plattformnutzer\_innen bezogene Themen (z. B. *Rezeptionsanweisungen geben* (10.4.7)); in rezensiven Texten von *Amazon* findet sich das letztgenannte

Thema proportional häufiger als bei den zwei anderen Plattformen (vgl. auch Kapitel 12 dazu, wie Rezensent\_innen in den Texten in Erscheinung treten).

Insgesamt scheint die Themenvielfalt, speziell bei den drei untersuchten Plattformen, eher eingeschränkt zu sein: einige der 20 Themen sind sehr prominent und treten in den meisten der untersuchten Texte auf, die Mehrheit der untersuchten Kategorien findet sich aber eher selten in den Texten. Das führt zu dem Eindruck, dass innerhalb von *Amazon*, *BücherTreff.de* und *Tripadvisor* häufig dieselben Themen angesprochen werden, andere aber eher sporadisch.

### 10.3.3 Zusammenfassung

Es ist nicht trivial, die in rezensiven Texten behandelten Themen zu identifizieren. Wir haben das in diesem Abschnitt dadurch versucht, dass wir Versprachlichungen ausgewählter Kategorien des in Kapitel 4 dargestellten Kategoriensystems in den einzelnen rezensiven Texten identifiziert haben. Zu beachten ist hierbei, dass es (a) sehr viele unterschiedliche Themen gibt, die in Texten besprochen werden (können) – die Untersuchung behandelt nur eine Stichprobe aus dem Kategoriensystem –, und dass (b) die Versprachlichung mancher Themen sehr variabel ist. Während im Abschnitt 10.2 versucht wurde, prominente lexikalische Items mit der Topic Modeling-Methode zu erheben, manuell zu etikettieren und auf die Kategorien unseres Kategoriensystems abzubilden, sind wir im vorliegenden Abschnitt den umgekehrten Weg gegangen: Für ausgewählte Themenbereiche wurden Extraktionswerkzeuge entwickelt und angewandt, welche die Textdaten thematisch klassifizieren. Dabei haben wir Verfahren des maschinellen Lernens mit Ansätzen aus der Korpuslinguistik kombiniert.

Die Arbeiten, die wir im vorliegenden Abschnitt dargestellt haben, unterliegen sowohl prinzipiellen als auch einzelnen technischen Validitätsgefährdungen. Prinzipiell wäre es besser, wenn mehr Themenbereiche, d. h. eine größere Anzahl von Kategorien des Kategoriensystems aus Kapitel 4 hätten berücksichtigt werden können. Wir haben 20 Kategorien ausgewählt, mit Blick auf Bildungsprozesse, aber auch nach Datenverfügbarkeit, bzw. nach automatischer Identifizierbarkeit. Insofern sind unsere Ergebnisse ggf. von der Auswahl beeinflusst. Aus technischer Sicht hat sich gezeigt, dass die eingesetzten maschinellen Lernverfahren so viel Trainingsmaterial benötigen, dass über die manuell annotierten Belege hi-

naus auch eine Beschaffung von Trainingsdaten auf der Basis von korpuslinguistischen Suchverfahren notwendig war; da diese Suchverfahren auf manuell festgelegten Wörtern und Wortgruppen aufsetzen, ist nicht auszuschließen, dass das Trainingsmaterial in stärkerem Maß die Intuition der beteiligten Wissenschaftler\_innen widerspiegelt, als das der Fall wäre, wenn ausreichende Mengen an Trainingsdaten vorgelegen hätten, die ganz regelrecht von je drei Bewerter\_innen unabhängig voneinander annotiert worden wären. Dieser Punkt verweist auch auf zukünftigen Forschungsbedarf: mit mehr annotiertem Material wären besser abgesicherte Aussagen zur Themenvielfalt möglich.

Trotz dieser Limitationen können erste quantitative Befunde festgehalten werden. Die Zahlen in Tabelle 10.7 legen die Annahme nahe, dass rezensive Texte auf Blogs thematisch etwas vielfältiger sind als diejenigen auf einer der drei untersuchten Plattformen, *Amazon*, *BücherTreff.de* und *Tripadvisor*. Es erscheinen darüber hinaus einige der 20 ausgewählten (Themen-)Kategorien generell als prominenter als die anderen, namentlich auf den drei Plattformen: Die für ein Rezensionsobjekt benötigte und die eigene Kompetenz (5.9; 6.2), sowie im Werk dargestellte bzw. eigene Emotionen (1.4.4; 5.6.4) sind in der überwiegenden Mehrheit der rezensiven Texte erwähnt; ähnlich, aber quantitativ weniger markant, findet sich auch die Zielgruppe des Rezensionsobjekts (5.10); vgl. Abbildung 10.8 und 10.9 für Details. Aus diesen Präferenzen könnte man den – vorläufigen – Schluss ziehen, dass rezensive Texte auf den großen Plattformen häufig dieselben Themen behandeln, sodass eine wirkliche Vielfalt an Themen dort eher in einer Minderheit der Texte auftritt.

## 10.4 Netzwerkanalyse

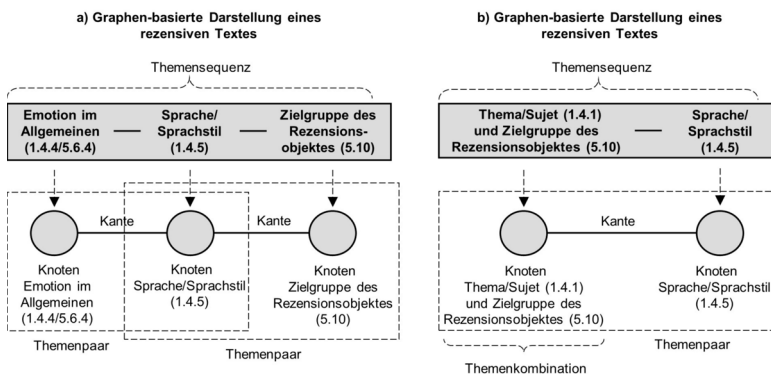
### 10.4.1 Vorgehen

Um das gemeinsame Vorkommen von Themen in rezensiven Texten auf Textebene zu untersuchen, wird die Methode der Netzwerkanalyse herangezogen. In der Netzwerkforschung liegt der Fokus auf der Analyse von Beziehungen zwischen Untersuchungseinheiten (z. B. zwischen Menschen in sozialen Netzwerken oder, wie in diesem Beitrag, zwischen angesprochenen Themen in rezensiven Texten) und auf der Analyse von Strukturen

in diesen Beziehungen (vgl. z. B. Stegbauer/Rausch 2013; Jansen 2003). Ein Netzwerk lässt sich sehr allgemein als »eine abgegrenzte Menge von Knoten oder Elementen und der Menge der zwischen ihnen verlaufenden sogenannten Kanten« (Jansen 2006: 58) beschreiben. Diese Definition basiert auf der grafischen Darstellung von Netzwerken als Graph: Die Knoten stellen die Untersuchungseinheiten dar und die Kanten deren Beziehungen zueinander (vgl. Jansen 2003). Wir übertragen diese Definition auf den rezensiven Text (siehe Abbildung 10.10): Die extrahierten Themen (bzw. Kategorien des Kategoriensystems, siehe Abschnitt 10.3) bilden die Knoten und das sequentielle Vorkommen zweier Themen in einem rezensiven Text bilden die Kanten. Konnte in einem Text beispielsweise das Vorkommen der Themen Emotion im Allgemeinen (1.1.4/5.6.4)<sup>16</sup>, Sprache/Sprachstil (1.4.5), Zielgruppe des Rezensionsobjektes (5.10) in einer Sequenz identifiziert werden, so stellen die einzelnen Themen die Knoten dar. Das sequentielle Vorkommen von zwei Themen (*Themenpaar*) wird jeweils mit einer Kante dargestellt, sodass beispielsweise eine Kante zwischen den Themen Emotion im Allgemeinen (1.1.4/5.6.4) und Sprache/Sprachstil (1.4.5) entsteht (siehe Abbildung 10.10a). Außerdem kommt es vor, dass mehrere Themen innerhalb der gleichen Textpassage identifiziert werden. Beispielsweise umfasst der rezensive Textauschnitt »Dies ist eine mögliche Zukunftsbeschreibung [...] und ich finde für Jugendliche und jung gebliebene Erwachsene ein [sic!] gute Unterhaltung« (Amazon, Rez 1537) zwei Themen, nämlich das Thema/Sujet (1.4.1) und die Zielgruppe des Rezensionsobjektes (5.10). Ist dies der Fall, so bildet die Kombination beider Themen (*Themenkombination*) einen gemeinsamen Knoten Thema/Sujet (1.4.1) und Zielgruppe des Rezensionsobjektes (5.10) (siehe Abbildung 10.10b). Zur Darstellung dieser Beziehungen zwischen den Themen werden grafische Netzwerkmodelle mit ungerichteten Kanten entwickelt. Wir wählen die Darstellung ohne Richtungsangaben der Kanten aus, um die Beziehung »gemeinsames Vorkommen von Themen« abzubilden. Mit Hilfe einer solchen netzwerkanalytischen Betrachtung der rezensiven Texte ist es möglich, die Beziehung von Themen zu anderen Themen und deren strukturelle Einbettung in das »Themen-Netzwerk« zu untersuchen.

<sup>16</sup> Es ist zu berücksichtigen, dass das Thema Emotion im Allgemeinen (1.4.4/5.6.4) Emotionen in den rezensiven Texten an sich identifiziert und damit nicht 1:1 einer einzelnen Kategorie des Kategoriensystems zuzuordnen ist (Details zur Extraktion dieser Kategorie siehe auch Abschnitt 10.3).

Abbildung 10.10: Netzwerkanalytische Darstellung von rezensiven Texten, 2020




Quelle: Kristin Kutzner/Universität Hildesheim

Gegenstand der Analyse ist das gesamte ›Themen-Netzwerk‹ eines Korpus, indem die Anzahl der Knoten ( $n_{Kn}$ ) und Kanten ( $n_{Ka}$ ), die mittlere Kantenzahl je Knoten ( $\bar{k}_a$ ), die Netzwerkdichte ( $d$ ) sowie die Gradzentralität ( $Z_G$ ) der Knoten bestimmt werden. Die Netzwerkdichte stellt die Anzahl aller möglichen Beziehungen zwischen Knoten im Netzwerk ins Verhältnis zu denen, die im Netzwerk tatsächlich vorkommen (vgl. Jansen 1999: 105). Enthalten alle rezensiven Texte eines Korpus beispielsweise die gleichen Themen, so wären alle Themen im Netzwerk miteinander verbunden und die Dichte würde bei 100 % liegen – die rezensiven Texte wären in der Themenwahl alle gleich vielfältig. Das Zentralitätsmaß von Knoten geht grundlegend davon aus, dass diejenigen Knoten im Netzwerk zentral sind, die viele Beziehungen im Netzwerk aufweisen (vgl. Knoke/Burt 1983). Ein Thema ist demnach zentral im ›Themen-Netzwerk‹, wenn es häufig mit anderen Themen gemeinsam in rezensiven Texten vorkommt. Als Zentralitätskennzahl wird die Gradzentralität  $Z_G$  bestimmt, welche die Anzahl der direkten Beziehungen eines Knotens zu anderen Knoten bestimmt. Zentral ist der Knoten, der viele direkte Beziehungen aufweist. Bilden beispielsweise die Knoten ISBN-Angabe (1.1.7), (Erzähl-)Perspektive (1.4.6), Emotion im Allgemeinen (1.1.4/5.6.4) und Sprache/Sprachstil (1.4.5) ein ›Themen-Netzwerk‹ (siehe Abbildung 10.11), so verfügt der Knoten Emotion im Allgemeinen (1.1.4/5.6.4) über die meisten direkten Verbindungen zu anderen Knoten und stellt damit den zentralsten Knoten im Netzwerk dar. Das Thema Emotion im Allgemeinen (1.1.4/5.6.4) kommt am häufigsten gemeinsam mit anderen Themen in den rezensiven Texten vor



(für Details zur Berechnung des Zentralitätsmaßes siehe z. B. Freeman 1978; Jansen 1999: 121ff., 2006: 132ff.). Weiterhin werden die *Beziehungsintensitäten* der Knoten zueinander nach ihrer Häufigkeit bestimmt, d. h. die Häufigkeiten von Themenpaaren im gesamten ›Themen-Netzwerk‹. Auf diese Weise kann untersucht werden, welche Themen besonders oft gemeinsam vorkommen und damit charakteristische Muster in der Themenwahl darstellen.

Abbildung 10.11: Beispielhaftes ›Themen-Netzwerk‹, 2020



Quelle: Kristin Kutzner/Universität Hildesheim

Die Netzwerkanalyse wurde mit Hilfe des Python-Paketes *NetworkX* (<https://networkx.github.io/>) durchgeführt. Als Datengrundlage dienten die drei Korpora von *Amazon*, *BücherTreff.de* und *Tripadvisor* sowie die (semi-)automatisch extrahierten Themen je rezensivem Text (für Details zur Extraktion der Themen siehe Abschnitt 10.2). Zu berücksichtigen ist, dass es sich bei den Themen um einen Ausschnitt handelt und nicht alle im Kategoriensystem identifizierten Themen (siehe Kapitel 4) für die Netzwerkanalyse genutzt werden. Das gemeinsame Vorkommen von Themen in einem rezensiven Text wurde jeweils als Themensequenzen aufbereitet und diente als Eingabe für die drei Netzwerkanalysen je Korpus.

### 10.4.2 Ergebnisse

Die netzwerkanalytische Betrachtung der drei Korpora (siehe Tabelle 10.8) zeigt, dass in den rezensiven *Amazon*- und *BücherTreff.de*-Texten insgesamt deutlich mehr *Knoten* (d. h. Themen und Themenkombinationen,  $n_{Kn}$ ) als in

den *Tripadvisor*-Texten<sup>17</sup> vorliegen. Im *Amazon*- und *BücherTreff.de*-Korpus sind deutlich mehr *Themenpaare* ( $n_{ka}$ ) als im *Tripadvisor*-Korpus zu finden. Zusätzlich bestimmen wir die *mittlere Kantenanzahl je Knoten* ( $\overline{ka}$ ), um aufzuzeigen mit wie vielen verschiedenen Themen/Themenkombinationen ein Thema/eine Themenkombination im Mittel gemeinsam – direkt hintereinander im rezensiven Text – vorkommt. Es zeigt sich, dass im Mittel bei den rezensiven *BücherTreff.de*-Texten ein Thema/eine Themenkombination am häufigsten gemeinsam mit anderen, verschiedenen Themen/Themenkombinationen angesprochen wird. Bei Amazon sind es im Mittel  $\overline{ka}_{Amazon} = 7,91$  Themen/Themenkombinationen und bei *Tripadvisor*  $\overline{ka}_{Tripadvisor} = 4,24$ . Die Ergebnisse weisen darauf hin, dass die gemeinsame Ansprache von zwei Themen/Themenkombinationen demnach in den rezensiven Texten von *BücherTreff.de* am vielfältigsten gestaltet ist, gefolgt von den Texten von Amazon und denen von *Tripadvisor*. Betrachtet man die Netzwerkdichte, so wird deutlich, dass das ›*Tripadvisor*-Themen-Netzwerk‹ die größte Dichte aufweist. Die Netzwerke von *Amazon* und *BücherTreff.de* zeigen geringere, ähnliche Dichtewerte. Die identifizierten Themen/Themenkombinationen der rezensiven *Tripadvisor*-Texte sind daher insgesamt stärker miteinander vernetzt als diejenigen bei den *Amazon*- und *BücherTreff.de*-Texten. Somit werden zwar insgesamt weniger Themen/Themenkombinationen in den *Tripadvisor*-Texten angesprochen (geringere Themenvielfalt), diese werden jedoch häufiger miteinander kombiniert.

Tabelle 10.8: Kennzahlen der ›Themen-Netzwerke‹, 2020

	Amazon	BücherTreff.de	Tripadvisor
Anzahl Knoten ( $n_{kn}$ )	106	146	29
Anzahl Kanten ( $n_{ka}$ )	838	1681	123
Mittlere Kantenanzahl je Knoten ( $\overline{ka}$ )	7,91	11,51	4,24
Netzwerkdichte ( $d$ )	15,06 %	15,88 %	30,30 %

Quelle: Kristin Kutzner/Universität Hildesheim

17 Es ist zu berücksichtigen, dass das *Tripadvisor*-Korpus am wenigsten rezensive Texte umfasst und das *Amazon*-Korpus wiederum deutlich weniger Texte als das *BücherTreff*-Korpus (siehe Kapitel 3), was auf die Anzahl der identifizierten Themen Einfluss nimmt.

Weiterhin wird die zuvor beschriebene Gradzentralität der Knoten bestimmt, um zentrale Themen/Themenkombinationen in den drei ›Themen-Netzwerken‹ zu identifizieren. Abbildung 10.12 stellt absteigend sortiert je Korpus die zehn Themen/Themenkombinationen mit den größten Gradzentralitätswerten dar. Die Markierungen der Themen/Themenkombinationen (Kreis, Dreieck, Quadrat oder Raute) visualisieren jeweils, inwiefern Themen/Themenkombinationen in mehreren Netzwerken zentral sind und damit Korpus-übergreifende Muster ersichtlich werden.

In allen drei ›Themen-Netzwerken‹ stellen die Themen bzw. Themenkombinationen Emotion im Allgemeinen (1.1.4/5.6.4), Zielgruppe des Rezensionsobjektes (5.10), Verständlichkeit (5.8) sowie Emotion im Allgemeinen (1.1.4/5.6.4) und Zielgruppe des Rezensionsobjektes (5.10) besonders zentrale Knoten dar und kommen demnach sehr häufig mit anderen Themen gemeinsam – direkt nebeneinander im rezensiven Text als Themenpaar – vor (siehe Kreis-Markierung in Abbildung 10.12). In den rezensiven Texten zu Büchern (d. h. im *Amazon-* und *BücherTreff.de*-Netzwerk) sind ferner die Themen bzw. Themenkombinationen Sprache/Sprachstil (1.4.5), (Erzähl-)Perspektive (1.4.6), Emotion im Allgemeinen (1.1.4/5.6.4) und Sprache/Sprachstil (1.4.5) sowie Handlung (1.4.2) zentrale Knoten (siehe Dreieck-Markierung in Abbildung 10.12). Das Thema Rezeptionsanweisung geben (empfehlen) (10.4.7) ist darüber hinaus sowohl im *Amazon-* als auch im *Tripadvisor*-Netzwerk zentral (siehe Quadrat-Markierung in Abbildung 10.12). Außerdem ist das Thema Verlag/Museum (1.1.4) im *BücherTreff.de*- und *Tripadvisor*-Netzwerk zentral (siehe Rauten-Markierung in Abbildung 10.12) – dies deutet darauf hin, dass Rezensent\_innen häufig den Verlag beim Rezensieren von Büchern bzw. das Museum bei rezensiven Texten zu Museen gemeinsam mit anderen Themen ansprechen. Folglich werden Korpus-übergreifende, und damit einhergehend Plattform-unabhängig, Muster in der gemeinsamen Ansprache von Themen ersichtlich, was zur folgenden Hypothese führt:

*Hypothese ABT1:* Rezensive Texte umfassen, unabhängig von der betrachteten Online-Plattform, dieselben Themen, die besonders häufig mit anderen Themen gemeinsam angesprochen werden (Online-Plattform-unabhängige Muster in der Ansprache von Themen).

Abbildung 10.12: Gradezentralität, 2020


a) Gradzentralität Amazon – Top 10 Themen/Themenkombinationen		
Thema/Themenkombination		$z_G$
Emotion im Allgemeinen (1.4.4/5.6.4)	●	92
Zielgruppe des Rezensionsobjektes (5.10)	●	79
Sprache/Sprachstil (1.4.5)	▲	71
Verständlichkeit (5.8)	●	71
(Erzähl-)Perspektive (1.4.6)	▲	60
Emotion im Allgemeinen (1.4.4/5.6.4) und Sprache/Sprachstil (1.4.5)	▲	53
Rezeptionsanweisung geben (empfehlen) (10.4.7)	■	50
Emotion im Allgemeinen (1.4.4/5.6.4) und Zielgruppe des Rezensionsobjektes (5.10)	●	47
Figur (1.4.3)		45
Handlung (1.4.2)	▲	44
b) Gradzentralität Büchertreff – Top 10 Themen/Themenkombinationen		
Thema/Themenkombination		$z_G$
Emotion im Allgemeinen (1.4.4/5.6.4)	●	132
Zielgruppe des Rezensionsobjektes (5.10)	●	121
Sprache/Sprachstil (1.4.5)	▲	107
Verständlichkeit (5.8)	●	105
(Erzähl-)Perspektive (1.4.6)	▲	95
Verlag/Museum (1.1.4)	◆	89
Emotion im Allgemeinen (1.4.4/5.6.4) und Sprache/Sprachstil (1.4.5)	▲	76
Handlung (1.4.2)	▲	73
Emotion im Allgemeinen (1.4.4/5.6.4) und Zielgruppe des Rezensionsobjektes (5.10)	●	72
Sprache/Sprachstil (1.4.5) und Zielgruppe des Rezensionsobjektes (5.10)		72
c) Gradzentralität Tripadvisor – Top 10 Themen/Themenkombinationen		
Thema/Themenkombination		$z_G$
Emotion im Allgemeinen (1.4.4/5.6.4)	●	28
Zielgruppe des Rezensionsobjektes (5.10)	●	27
Verlag/Museum (1.1.4)	◆	23
Verständlichkeit (5.8)	●	20
(Kauf-)Preis (1.1.6)		16
Rezeptionsanweisung geben (empfehlen) (10.4.7)	■	16
Verlag/Museum (1.1.4) und Zielgruppe des Rezensionsobjektes (5.10)		12
Emotion im Allgemeinen (1.4.4/5.6.4) und Zielgruppe des Rezensionsobjektes (5.10)	●	12
Bezug zum Rezensionsojekt in einem anderen Medium (3.1)		11
Verständlichkeit (5.8) und Zielgruppe des Rezensionsobjektes (5.10)		9
Legende: ● = Thema/Themenkombination ist in allen Netzwerken zentral		
▲ = Thema/Themenkombination ist im Netzwerk von Amazon und Büchertreff zentral		
■ = Thema/Themenkombination ist im Netzwerk von Amazon und Tripadvisor zentral		
◆ = Thema/Themenkombination ist im Netzwerk von Büchertreff und Tripadvisor zentral		

Quelle: Kristin Kutzner/Universität Hildesheim

Außerdem werden die häufigsten Themenpaare der Netzwerke, also diejenigen Themen, die häufig sequentiell zusammen in den rezensiven Texten

vorkommen, auf Basis der Beziehungsintensitäten herausgearbeitet. Abbildung 10.13 stellt die häufigsten Themenpaare der drei Netzwerke dar. Aus Präsentationsgründen werden diejenigen Paare abgebildet, die in mindestens einem Netzwerk einen prozentualen Anteil von mindestens einem Prozent ausmachen. Diejenigen Themenpaare, die in allen drei Netzwerken besonders häufig vertreten sind, werden mit einem Fettdruck hervorgehoben.

Abbildung 10.13: Häufigkeitsverteilung ausgewählter Themenpaare, 2020



Quelle: Kristin Kutzner/Universität Hildesheim

Betrachtet man die Häufigkeitsverteilung der Themenpaare, ist zu beobachten, dass die Paare Emotion im Allgemeinen (1.4.4/5.6.4), Emotion im Allgemeinen (1.4.4/5.6.4) sowie Zielgruppe des Rezensionsobjektes (5.10), Emotion im Allgemeinen (1.4.4/5.6.4) in allen Netzwerken mit einer ähnlichen Häufigkeit vertreten sind. Insbesondere die sequentielle, wiederholte Thematisierung von Emotionen macht den größten Anteil von Themenpaaren in den rezensiven Texte aller Netzwerke aus. Korpus-übergreifende Muster in der Themenwahl und Themenpaarung werden ersichtlich, was zu einer weiteren Hypothese führt:

*Hypothese ABT2:* Rezensive Texte adressieren, unabhängig von der betrachteten Online-Plattform, dieselben Themenpaare, die besonders häufig vorkommen (Online-Plattform-unabhängige Muster in der Ansprache von Themenpaaren).

Bei *Amazon* machen 14 Themenpaare gut 80 % aller Paare aus:

- Emotion im Allgemeinen (1.4.4/5.6.4), Emotion im Allgemeinen (1.4.4/5.6.4),
- Zielgruppe des Rezensionsobjektes (5.10), Emotion im Allgemeinen (1.4.4/5.6.4),
- Sprache/Sprachstil (1.4.5), Emotion im Allgemeinen (1.4.4/5.6.4),
- Zielgruppe des Rezensionsobjektes (5.10), Zielgruppe des Rezensionsobjektes (5.10),
- Emotion im Allgemeinen (1.4.4/5.6.4), Verständlichkeit (5.8),
- Sprache/Sprachstil (1.4.5), Sprache/Sprachstil (1.4.5),
- Emotion im Allgemeinen (1.4.4/5.6.4), (Erzähl-)Perspektive (1.4.6),
- Sprache/Sprachstil (1.4.5), Zielgruppe des Rezensionsobjektes (5.10),
- (Erzähl-)Perspektive (1.4.6), (Erzähl-)Perspektive (1.4.6),
- Verständlichkeit (5.8), Verständlichkeit (5.8),
- Emotion im Allgemeinen (1.4.4/5.6.4), Rezeptionsanweisung geben (empfehlen) (10.4.7),
- Emotion im Allgemeinen, Handlung (1.4.2),
- Emotion im Allgemeinen (1.4.4/5.6.4) und Sprache/Sprachstil (1.4.5), Sprache/Sprachstil (1.4.5) und
- Emotion im Allgemeinen (1.4.4/5.6.4), Emotion im Allgemeinen (1.4.4/5.6.4) und Sprache/Sprachstil (1.4.5).

In den rezensiven *Amazon*-Texten werden somit viele verschiedene Themen miteinander kombiniert – die Themenpaare sind vielfältig, was zur folgenden Hypothese führt:

*Hypothese A3: Amazon-Rezensent\_innen kombinieren vielfältig verschiedene Themen in ihren rezensiven Texten (hohe Vielfalt in den Themenpaaren).*

Bei *BücherTreff.de* machen 18 Paare gut 80 % aller Themenpaare aus:

- Emotion im Allgemeinen (1.4.4/5.6.4), Emotion im Allgemeinen (1.4.4/5.6.4),
- Zielgruppe des Rezensionsobjektes (5.10), Emotion im Allgemeinen (1.4.4/5.6.4),
- Sprache/Sprachstil (1.4.5), Emotion im Allgemeinen (1.4.4/5.6.4),
- Zielgruppe des Rezensionsobjektes (5.10), Zielgruppe des Rezensionsobjektes (5.10),

- Emotion im Allgemeinen (1.4.4/5.6.4), Verständlichkeit (5.8),
- Sprache/Sprachstil (1.4.5), Sprache/Sprachstil (1.4.5),
- Emotion im Allgemeinen (1.4.4/5.6.4), (Erzähl-)Perspektive (1.4.6),
- Sprache/Sprachstil (1.4.5), Zielgruppe des Rezensionsobjektes (5.10),
- Verlag (1.1.4), Bezug zur Online-Plattform (8.3),
- (Erzähl-)Perspektive (1.4.6), (Erzähl-)Perspektive (1.4.6),
- Bezug zur Online-Plattform (8.3), Bezug zu anderen rezensiven Texten (8.1),
- Verständlichkeit (5.8), Verständlichkeit (5.8),
- Emotion im Allgemeinen (1.4.4/5.6.4), Rezeptionsanweisung geben (empfehlen) (10.4.7),
- Kaufpreis (1.1.6), Emotion im Allgemeinen (1.4.4/5.6.4),
- Handlung (1.4.2), Emotion im Allgemeinen (1.4.4/5.6.4),
- Emotion im Allgemeinen (1.4.4/5.6.4) und Sprache/Sprachstil (1.4.5), Sprache/Sprachstil (1.4.5),
- Emotion im Allgemeinen (1.4.4/5.6.4), Emotion im Allgemeinen (1.4.4/5.6.4) und Sprache/Sprachstil (1.4.5) sowie
- Emotion im Allgemeinen (1.4.4/5.6.4), Verlag (1.1.4).

Damit zeigt sich in den rezensiven *BücherTreff.de*-Texten eine große Vielfalt in den Themenpaaren, was zur weiteren Hypothese führt:

*Hypothese B3: BücherTreff.de*-Rezensent\_innen kombinieren vielfältig verschiedene Themen in ihren rezensiven Texten (hohe Vielfalt in den Themenpaaren).

Darüber hinaus machen beim *Tripadvisor*-Netzwerk die folgenden sechs Themenpaare gut 80 % aller Paare aus:

- Emotion im Allgemeinen (1.4.4/5.6.4), Emotion im Allgemeinen (1.4.4/5.6.4),
- Zielgruppe des Rezensionsobjektes (5.10), Emotion im Allgemeinen (1.4.4/5.6.4),
- Zielgruppe des Rezensionsobjektes (5.10), Zielgruppe des Rezensionsobjektes (5.10),
- Emotion im Allgemeinen (1.4.4/5.6.4), Verständlichkeit (5.8),
- Museum (1.1.4), Emotion im Allgemeinen (1.4.4/5.6.4) und
- Museum (1.1.4), Museum (1.1.4).

Es werden in den rezensiven Texten wenig verschiedene Themenpaare genutzt. Dies führt zu einer weiteren Hypothese:

*Hypothese T3: Tripadvisor-Rezensent\_innen kombinieren Themen in ihren rezensiven Texten mit geringer Vielfalt (geringe Vielfalt in den Themenpaaren).*

### 10.4.3 Zusammenfassung

Die netzwerkanalytische Betrachtung der rezensiven Texte erweist sich als eine nützliche Herangehensweise zur Analyse des gemeinsamen Vorkommens von Themen in Texten. Die Untersuchung liefert zum einen – bezogen auf unseren Datenausschnitt – Hinweise für Online-Plattform-unabhängige Muster in der Ansprache von Themenpaaren (Hypothese ABT<sub>1</sub> und ABT<sub>2</sub>). Zum anderen zeigt sich, dass Buch-Rezensent\_innen von *BücherTreff.de* und *Amazon* sehr vielfältig Themen miteinander kombinieren (Hypothese B<sub>3</sub> und A<sub>3</sub>). Die rezensiven *Tripadvisor*-Texte zu Museen hingegen zeigen nur eine sehr geringe Vielfalt in der Ansprache von Themenpaaren (Hypothese T<sub>3</sub>).

Sollen neben vorkommenden Themenpaaren in rezensiven Texten weiterführende Muster, wie Themensequenzen der Länge größer zwei und damit umfassendere Themenpaarungen, untersucht werden, so eignet sich die netzwerkanalytische Betrachtung nur bedingt: Die Graphen-basierte Darstellung als Netzwerk verbindet Themen miteinander, wenn diese als  $S \square qu \square z$  in einem Text vorkommen. Dadurch werden auch Themen im Netzwerk miteinander verbunden, die nicht unmittelbar einem einzelnen rezensiven Text zugeordnet sind, sodass längere Themensequenzen nicht zwangsläufig in einzelnen Texten vorkommen. Weitere Zentralitätsmaßen, wie die Nähezentralität oder Zwischenzentralität, wurden darüber hinaus als Lösungsansätze verworfen, da diese die Zentralität eines Knotens unter Einbezug aller Knoten des gesamten Netzwerks bestimmen und damit eine Themensequenzanalyse auf Textebene nur eingeschränkt ermöglichen. Um Gruppen häufig gemeinsam vorkommender Themen in einzelnen rezensiven Texten zu identifizieren, wird eine weitere Methode – die Clusteranalyse – herangezogen (siehe Abschnitt 10.5).



## 10.5 Clusteranalyse

### 10.5.1 Vorgehen

Um die Themenvielfalt in rezensiven Texten auf Textebene zu untersuchen, wird die Methode Clusteranalyse ausgewählt. Diese Methode stellt ein häufig genutztes Werkzeug dar, um Objekte zu gruppieren. Im Bereich der Rezensionenforchung wurden beispielsweise mit Hilfe dieser Methode Rezensionenplattformen klassifiziert (vgl. Kutzner/Petzold/Knackstedt 2019) oder Gruppen von Konsumenten anhand der individuellen Verarbeitung von Rezensioneninformationen (information processing) unterschieden (vgl. Gottschalk/Mafael 2017). In unserem Kontext nutzen wir die Clusteranalyse, um herauszufinden, inwiefern rezensive Texte sich aufgrund angesprochener Themen unterscheiden. Die Themenvielfalt eines rezensiven Textes definiert sich daher über die identifizierten Themen, sodass wir diejenigen rezensiven Texte gruppieren, welche eine hohe Zahl an gleichen Themen adressieren. Damit einhergehend bilden die *rezensiven Texte* die *Objekte* der Analyse. Die Menge aller *Themen* stellen die *Clustervariablen* dar. Es wird der K-Means-Algorithmus, eine der am gebräuchlichsten Methoden für ein solches Clustering, ausgewählt (vgl. Elkan 2003). Um Rezensionstypen (d. h. Cluster) anhand der vorkommenden Themen zu identifizieren, führen wir zwei wesentliche Schritte durch (vgl. Punj/Steward 1983; Remane et al. 2016): (1) Mit Hilfe der *Ward-Methode* wird zunächst die Anzahl der Cluster, als notwendiger Eingabe-Parameter für den K-Means-Algorithmus, bestimmt. Die Methode bildet hierarchische Cluster von Objektsubmengen auf Grundlage der Ähnlichkeiten der Objekte. Es werden zwei Submengen in einem Cluster zusammengefügt, die sich besonders ähnlich sind. Dieses Verfahren wird solange wiederholt bis alle Submengen in einem Cluster vereint sind (vgl. Ward 1963). Die Anzahl der gleichen Themen der rezensiven Texte bestimmt entsprechend die Ähnlichkeit zweier Submengen. Um nachvollziehen zu können, in welcher Reihenfolge Submengen in Relation zu den Ähnlichkeiten zusammengefügt wurden, wird ein Dendrogramm erzeugt. Die Clusteranzahl wird bestimmt, indem ein signifikanter Sprung in der Ähnlichkeit zusammengeführter Submengen im Dendrogramm identifiziert wird. (2) Anschließend wird der *K-Means-Algorithmus* angewandt, welcher Datenmengen in Cluster aufteilt, indem die Summe der Euklidischen Entfernungen innerhalb jedes Clusters minimiert wird (vgl. Hartigan/Wong 1979). Zur Auswahl initialer Cluster-Zentren wird `k-means++` genutzt, der Al-

gorithmus iteriert 300 Mal und innerhalb jeder Iteration wird der Algorithmus mit zehn verschiedenen Cluster-Zentren ausgeführt.

Zur Implementierung der Clusteranalyse nutzen wird das Python-Modul *Scikit Learn* (vgl. Pedregosa et al. 2011). Als Datengrundlage dienten die (Sub-)Korpora von *Amazon* (27.636 rezensive Texte), *BücherTreff.de* (50.000 rezensive Texte) sowie *Tripadvisor* (6.396 rezensive Texte) sowie die in Abschnitt 10.3 (semi-)automatisch extrahierten Themen und Themenkombination (d. h. es wurden mehrere Themen innerhalb der gleichen Textpassage identifiziert) je rezensiven Text.

## 10.5.2 Ergebnisse

Für alle drei Korpora wurden jeweils drei Cluster identifiziert. Im Folgenden erläutern wir die Clusterergebnisse und zeigen die prozentuale Verteilung der Themen je Cluster und Korpus. Wir beschränken uns auf die Darstellung der Themen, die gut 80 % bzw. 90 % aller Themen je Cluster ausmachen. Beispielsweise bilden im *Amazon*-Korpus in Cluster 1 drei Themen, nämlich Emotion im Allgemeinen (1.4.4/5.6.4), Sprache/Sprachstil (1.4.5) und Zielgruppe des Rezensionsobjektes (5.10), gut 80 % aller 54 angesprochenen Themen (siehe Abbildung 10.14). Die grau markierten Zellen stellen diejenigen Themen/Themenkombinationen dar, die in allen Clustern des Korpus vorkommen und daher übergreifend für alle Cluster des Korpus charakteristisch sind. Darüber hinaus sind die Anzahl rezensiver Texte ( $n_i$ ), die in einem Cluster  $i$  gruppiert wurden, die mittlere Textlänge der rezensiven Texte eines Clusters  $i$  ( $\bar{r}_i$ ), deren Standardabweichung ( $St(\bar{r}_i)$ ), die mittlere Satzlänge der Texte eines Clusters  $i$  ( $\bar{s}_i$ ) sowie deren Standardabweichung ( $St(\bar{s}_i)$ ) abgebildet. Beispielsweise umfasst das Cluster 1 des *Amazon*-Korpus 16.285 rezensive Texte, die eine mittlere Textlänge von 77,13 Wörtern mit einer Standardabweichung von 73,30 Wörtern aufweisen. Außerdem umfassen die Texte im Mittel eine Satzlänge von 16,61 Wörtern mit einer Standardabweichung von 6,37 Wörtern.

### Rezensionstypen in rezensiven *Amazon*-Texten

Übergreifend sind alle Cluster durch die drei Themen Emotion im Allgemeinen (1.4.4/5.6.4), Sprache/Sprachstil (1.4.5) und Zielgruppe des Rezensionsobjektes (5.10) charakterisiert (vgl. Abbildung 10.14). Das Cluster 0 gruppiert insgesamt 2.069 rezensive Texte und damit die im Vergleich zu den anderen Clustern deutlich geringste Anzahl an Texten. Im Mittel umfassen die Texte

561,57 Wörter ( $\bar{r}_{Co} = 561,57$ ;  $St(\bar{r}_{Co}) = 414,99$ ) und eine Satzlänge von 24,12 Wörtern ( $\bar{s}_{Co} = 24,12$ ;  $St(\bar{s}_{Co}) = 6,98$ ), was im Verhältnis zu den anderen Clustern die jeweils größte Länge ausmacht. Insgesamt konnten 99 Themen bzw. Themenkombinationen in den dazugehörigen rezensiven Texten identifiziert werden – 13 der Themen/Themenkombinationen machen hier gut 80 % aller Themen/Themenkombinationen aus und sind daher besonders charakteristisch für dieses Cluster. Es zeigt sich somit eine gewisse Vielfalt in der Themenwahl, sodass die folgende Hypothese aufgestellt wird:

*Hypothese A4:* Die Minderheit rezensiver *Amazon*-Texte zu Büchern umfasst viele Wörter sowie lange Sätze und adressiert viele verschiedene Themen (hohe Vielfalt in der Themenwahl).

Das *Cluster 1* umfasst mit 16.285 rezensiven Texten im Vergleich zu den anderen beiden Clustern die größte Anzahl an Texten. Im Mittel sind diese kurz gehalten ( $\bar{r}_{C1} = 77,13$ ;  $St(\bar{r}_{C1}) = 73,30$ ) und zeigen eine kurze, mittlere Satzlänge von 16,61 Wörtern ( $\bar{s}_{C1} = 16,61$ ;  $St(\bar{s}_{C1}) = 6,37$ ) – im Verhältnis zu den anderen Clustern betrachtet. Drei Themen, nämlich Emotion im Allgemeinen (1.4.4/5.6.4) Sprache/Sprachstil (1.4.5) und Zielgruppe des Rezensionsobjektes (5.10) liegen hier im Fokus der Thematisierung und machen gut 80 % aller 54 identifizierten Themen/Themenkombinationen aus. Den mit Abstand größten Anteil der adressierten Themen macht Emotion im Allgemeinen (1.4.4/5.6.4) mit 40,84 % aus. Es zeigt sich demnach eine sehr geringe Themenvielfalt, was zur folgenden Hypothese führt:

*Hypothese A5:* Die Mehrheit rezensiver *Amazon*-Texte zu Büchern umfasst wenig Wörter sowie kurze Sätze, und adressiert wenig verschiedene Themen (geringe Vielfalt in der Themenwahl).

Das *Cluster 2* gruppiert 9.282 rezersive Texte und umfasst damit weniger Texte als Cluster 1, aber deutlich mehr Texte als Cluster 0. Die rezensiven Texte weisen im Mittel 201,78 Wörter ( $\bar{r}_{C2} = 201,78$ ;  $St(\bar{r}_{C2}) = 190,74$ ) und eine Satzlänge von 20,62 Wörtern ( $\bar{s}_{C2} = 20,62$ ;  $St(\bar{s}_{C2}) = 7,13$ ) auf – im Vergleich zu den anderen beiden Clustern zeigen sich damit Texte und Sätze mittlerer Längen. Acht Themen/Themenkombinationen machen hier gut 80 % aller 84 identifizierten Themen/Themenkombinationen aus und sind damit besonders charakteristisch für dieses Cluster. Es zeigt sich eine gewisse Vielfalt in der Themenwahl.

Abbildung 10.14: Clusteranalyse-Ergebnisse Amazon, 2020

Cluster 0		
Anzahl rezensiver Texte $n_{rc0}$		2069
Mittlere Textlänge* $\bar{r}_{c0}$		561,57
Standardabweichung der mittleren Textlänge* $St(\bar{r}_{c0})$		414,99
Mittlere Satzlänge* $\bar{s}_{c0}$		24,12
Standardabweichung der mittleren Satzlänge* $St(\bar{s}_{c0})$		6,98
Thema/Themenkombination	Emotion im Allgemeinen (1.4.4/5.6.4)	11,36%
	Sprache/Sprachstil (1.4.5)	10,61%
	Zielgruppe des Rezensionsobjektes (5.10)	10,61%
	Verständlichkeit (5.8)	9,13%
	(Erzahl-)Perspektive (1.4.6)	7,79%
	Emotion im Allgemeinen (1.4.4/5.6.4) und Sprache/Sprachstil (1.4.5)	5,57%
	Handlung (1.4.2) (1.4.2)	4,56%
	Emotion im Allgemeinen (1.4.4/5.6.4) und Zielgruppe des Rezensionsobjektes (5.10)	4,00%
	Rezeptionsanweisung geben (empfehlen) (10.4.7)	3,85%
	Figur (1.4.3)	3,51%
	Thema/Sujet (1.4.1)	3,28%
	Sprache/Sprachstil (1.4.5) und Zielgruppe des Rezensionsobjektes (5.10)	2,77%
	Bezug zum Rezensionsobjekt in einem anderen Medium (5.10)	2,33%
Restliche 86 (von 99) Themen/Themenkombinationen		20,65%
Summe		100,00%
Cluster 1		
Anzahl rezensiver Texte $n_{rc1}$		16285
Mittlere Textlänge* $\bar{r}_{c1}$		77,13
Standardabweichung der mittleren Textlänge* $St(\bar{r}_{c1})$		73,30
Mittlere Satzlänge* $\bar{s}_{c1}$		16,61
Standardabweichung der mittleren Satzlänge* $St(\bar{s}_{c1})$		6,37
Thema/Themenkombination	Emotion im Allgemeinen (1.4.4/5.6.4)	40,84%
	Sprache/Sprachstil (1.4.5)	19,36%
	Zielgruppe des Rezensionsobjektes (5.10)	17,52%
	Restliche 51 (von 54) Themen/Themenkombinationen	22,28%
Summe		100,00%
Cluster 2		
Anzahl rezensiver Texte $n_{rc2}$		9282
Mittlere Textlänge* $\bar{r}_{c2}$		201,78
Standardabweichung der mittleren Textlänge* $St(\bar{r}_{c2})$		190,74
Mittlere Satzlänge* $\bar{s}_{c2}$		20,62
Standardabweichung der mittleren Satzlänge* $St(\bar{s}_{c2})$		7,13
Thema/Themenkombination	Emotion im Allgemeinen (1.4.4/5.6.4)	18,76%
	Sprache/Sprachstil (1.4.5)	14,88%
	Zielgruppe des Rezensionsobjektes (5.10)	14,23%
	Verständlichkeit (5.8)	11,11%
	Rezeptionsanweisung geben (empfehlen) (10.4.7)	6,06%
	(Erzahl-)Perspektive (1.4.6)	5,67%
	Emotion im Allgemeinen (1.4.4/5.6.4) und Sprache/Sprachstil (1.4.5)	5,22%
	Handlung (1.4.2)	2,66%
	Restliche 76 (von 84) Themen/Themenkombinationen	21,41%
Summe		100,00%

graue Markierungen stellen Themen/Themenkombinationen dar, die in allen Clustern vorkommen  
\* gemessen in Wortanzahl

Quelle: Kristin Kutzner/Universität Hildesheim

*Hypothese A6:* Eine Vielzahl rezensiver *Amazon*-Texte zu Büchern mittlerer Wort- und Satzlänge adressiert verschiedene Themen (gewisse Vielfalt in der Themenwahl).

### Rezensionstypen in rezensiven *BücherTreff.de*-Texten

Alle Cluster weisen sieben gemeinsame Themen auf, die jeweils einen hohen prozentualen Anteil der identifizierten Themen/Themenkombinationen ausmachen: Emotion im Allgemeinen (1.4.4/5.6.4), Sprache/Sprachstil (1.4.5), Zielgruppe des Rezensionobjektes (5.10), Verständlichkeit (5.8), Bezug zur Online-Plattform (8.3), Bezug zu anderen rezensiven Texten (8.1) und Verlag (1.1.4) siehe Abbildung 10.15.

Das *Cluster 0* umfasst 7.921 rezersive Texte – die geringste Anzahl an Texten im Vergleich zu den anderen Clustern. Die mittlere Textlänge liegt bei 604,08 Wörtern ( $\bar{r}_{co} = 604,08$ ;  $St(\bar{r}_{co}) = 262,04$ ) und die mittlere Satzlänge bei 19,36 Wörtern ( $\bar{s}_{co} = 19,36$ ;  $St(\bar{s}_{co}) = 4,27$ ) – im Vergleich zu den anderen Clustern sind dies die größten Längen. Insgesamt wurden 110 Themen/Themenkombinationen identifiziert, wobei 13 Themen/Themenkombinationen gut 80 % ausmachen und besonders charakteristisch sind. Dieses Cluster umfasst daher rezersive Texte, welche in der Themenwahl variieren, was zur folgenden Hypothese führt:

*Hypothese B4:* Die Minderheit rezensiver *BücherTreff.de*-Texte umfasst viele Wörter sowie lange Sätze und adressiert viele verschiedene Themen (hohe Vielfalt in der Themenwahl).

Das *Cluster 1* gruppiert mit 29.291 rezensiven Texten die größte Anzahl an Texten. Diese sind im Vergleich zu den anderen Clustern im Mittel eher kurz gehalten ( $\bar{r}_{c1} = 68,06$ ;  $St(\bar{r}_{c1}) = 67,20$ ) und weisen auch eher kurze Sätze auf ( $\bar{s}_{c1} = 13,84$ ;  $St(\bar{s}_{c1}) = 6,57$ ). Trotz der Kürze weisen diese Texte jedoch eine gewisse Vielfalt in der Themenwahl auf – hier machen sieben Themen gut 80 % aller 74 identifizierten Themen/Themenkombinationen aus. Das Thema Emotion im Allgemeinen (1.4.4/5.6.4) liegt hier mit einem prozentualen Anteil von 34,15 % besonders im Fokus. Diese Beobachtungen führen zu einer weiteren Hypothese:

*Hypothese B5:* Die Mehrheit rezensiver *BücherTreff.de*-Texte umfasst wenig Wörter sowie kurze Sätze und adressiert verschiedene Themen (gewisse Vielfalt in der Themenwahl).

Abbildung 10.15: Clusteranalyse Ergebnisse BücherTreff.de, 2020

Cluster 0		
Anzahl rezensiver Texte $n_{rc0}$		7921
Mittlere Textlänge* $\bar{r}_{c0}$		604,08
Standardabweichung der mittleren Textlänge* $St(\bar{r}_{c0})$		262,04
Mittlere Satzlänge* $\bar{s}_{c0}$		19,36
Standardabweichung der mittleren Satzlänge* $St(\bar{s}_{c0})$		4,27
Thema/Themenkombination	Emotion im Allgemeinen (1.4.4/5.6.4)	9,02%
	Zielgruppe des Rezensionsobjektes (5.10)	8,75%
	Sprache/Sprachstil (1.4.5)	8,67%
	Verlag (1.1.4)	7,86%
	Verständlichkeit (5.8)	7,76%
	Bezug zu anderen rezensiven Texten (8.1)	7,69%
	Bezug zur Online-Plattform (8.3)	7,65%
	(Erzähl-)Perspektive (1.4.6)	6,27%
	Emotion im Allgemeinen (1.4.4/5.6.4) und Sprache/Sprachstil (1.4.5)	4,56%
	Handlung (1.4.2)	3,91%
	Emotion im Allgemeinen (1.4.4/5.6.4) und Zielgruppe des Rezensionsobjektes (5.10)	3,42%
	Figur (1.4.3)	2,52%
	Sprache/Sprachstil (1.4.5) und Zielgruppe des Rezensionsobjektes (5.10)	2,37%
	Restliche 97 (von 110) Themen/Themenkombinationen	19,55%
Summe		100,00%
Cluster 1		
Anzahl rezensiver Texte $n_{rc1}$		29291
Mittlere Textlänge* $\bar{r}_{c1}$		68,06
Standardabweichung der mittleren Textlänge* $St(\bar{r}_{c1})$		67,20
Mittlere Satzlänge* $\bar{s}_{c1}$		13,84
Standardabweichung der mittleren Satzlänge* $St(\bar{s}_{c1})$		6,57
Thema/Themenkombination	Emotion im Allgemeinen (1.4.4/5.6.4)	34,15%
	Sprache/Sprachstil (1.4.5)	11,71%
	Zielgruppe des Rezensionsobjektes (5.10)	10,28%
	Verständlichkeit (5.8)	7,53%
	Bezug zur Online-Plattform (8.3)	6,63%
	Verlag (1.1.4)	5,93%
	Bezug zu anderen rezensiven Texten (8.1)	4,86%
	Restliche 67 (von 74) Themen/Themenkombinationen	18,91%
Summe		100,00%
Cluster 2		
Anzahl rezensiver Texte $n_{rc2}$		12788
Mittlere Textlänge* $\bar{r}_{c2}$		323,62
Standardabweichung der mittleren Textlänge* $St(\bar{r}_{c2})$		197,42
Mittlere Satzlänge* $\bar{s}_{c2}$		18,24
Standardabweichung der mittleren Satzlänge* $St(\bar{s}_{c2})$		5,03
Thema/Themenkombination	Emotion im Allgemeinen (1.4.4/5.6.4)	14,33%
	Sprache/Sprachstil (1.4.5)	12,24%
	Zielgruppe des Rezensionsobjektes (5.10)	12,16%
	Verständlichkeit (5.8)	9,51%
	Bezug zur Online-Plattform (8.3)	7,76%
	Bezug zu anderen rezensiven Texten (8.1)	7,63%
	Verlag (1.1.4)	7,61%
	(Erzähl-)Perspektive (1.4.6)	5,37%
	Emotion im Allgemeinen (1.4.4/5.6.4) und Sprache/Sprachstil (1.4.5)	3,66%
	Restliche 88 (von 97) Themen/Themenkombinationen	19,72%
Summe		100,00%
graue Markierungen stellen Themen/Themenkombinationen dar, die in allen Clustern vorkommen		
* gemessen in Wortanzahl		

Quelle: Kristin Kutzner/Universität Hildesheim

Das Cluster 2 umfasst mit 12.788 rezensiven Texten deutlich weniger Texte als Cluster 1, aber mehr Texte als Cluster 0. Im Vergleich zu den anderen Clustern weisen die Texte ferner eine mittlere Text- und Satzlänge auf ( $\bar{r}_{C_2} = 323,62$ ;  $St(\bar{r}_{C_2}) = 197,42$ ;  $\bar{s}_{C_2} = 18,24$ ;  $St(\bar{s}_{C_2}) = 5,03$ ) Neun Themen/Themenkombinationen machen gut 80 % der 97 identifizierten Themen/Themenkombinationen aus – auch hier zeigt sich demnach eine gewisse Vielfalt in der Themenwahl, was zur folgenden Hypothese führt:

*Hypothese B6:* Eine Vielzahl rezensiver *BücherTreff.de*-Texte mittlerer Wort- und Satzlänge adressiert verschiedene Themen (gewisse Vielfalt in der Themenwahl).

### Rezensionstypen in rezensiven *Tripadvisor*-Texten

Übergreifend enthalten alle drei Cluster die zwei Themen Emotion im Allgemeinen (1.4.4/5.6.4) sowie Zielgruppe des Rezensionsobjektes (5.10) siehe Abbildung 10.16. Das Cluster 0 umfasst 2.352 rezersive Texte, die im Vergleich zu den anderen Clustern – auch Korpus übergreifend – ganz besonders kurz gehalten sind ( $\bar{r}_{C_0} = 47,07$ ;  $St(\bar{r}_{C_0}) = 37,18$ ;  $\bar{s}_{C_0} = 14,07$ ;  $St(\bar{s}_{C_0}) = 5,51$ ) Die Texte dieses Clusters sind mit einem prozentualen Anteil von 71,26 % vorrangig durch das Thema Emotion im Allgemeinen (1.4.4/5.6.4) charakterisiert und weisen demnach eine geringe Vielfalt in der Themenwahl auf. Dies führt zu einer weiteren Hypothese:

*Hypothese T4:* Einige rezersive *Tripadvisor*-Texte zu Museen mit besonders kurzer Wort- und Satzlänge adressieren kaum verschiedenen Themen (geringe Vielfalt in der Themenwahl).

Cluster 1 gruppiert 2.685 rezersive Texte, die im Mittel kurz gehalten sind ( $\bar{r}_{C_1} = 65,89$ ;  $St(\bar{r}_{C_1}) = 41,00$ ) und eine kurze mittlere Satzlänge von 15,61 Wörtern ( $\bar{s}_{C_1} = 15,61$ ;  $St(\bar{s}_{C_1}) = 5,78$ ) aufweisen. Auch diese rezensiven Texte fokussieren sich auf eine geringe Anzahl verschiedener Themen, nämlich auf die drei Themen Museum (1.1.4), Emotion im Allgemeinen (1.4.4/5.6.4) und Zielgruppe des Rezensionsobjektes (5.10). Bereits die zuerst genannten zwei Themen machen einen hohen prozentualen Anteil von 81,70 % aller Themen/Themenkombinationen aus, sodass sich eine sehr geringe Themenvielfalt zeigt, was zur folgenden Hypothese führt:

*Hypothese T5:* Einige rezensive *Tripadvisor*-Texte zu Museen umfassen wenig Wörter sowie kurze Sätze und adressieren kaum verschiedene Themen (geringe Vielfalt in der Themenwahl).

Das Cluster 2 fasst 1.359 rezensive Texte zusammen, die zwar im Vergleich zu den anderen Clustern eine etwas längere Text- und Satzlänge aufzeigen, im Korpus-übergreifenden Vergleich jedoch immer noch kurz gehalten sind ( $\bar{r}_{C_2} = 94,37$ ;  $St(\bar{r}_{C_2}) = 87,74$ ;  $\bar{s}_{C_2} = 87,74$ ;  $St(\bar{s}_{C_2}) = 5,66$ ). Sieben Themen/Themenkombinationen machen hier gut 90 % aller 29 identifizierten Themen/Themenkombinationen aus, sodass eine gewisse Vielfalt in der Themenwahl ersichtlich wird. Dies führt zu einer weiteren Hypothese:

*Hypothese T6:* Einige rezensive *Tripadvisor*-Texte zu Museen umfassen wenig Wörter sowie kurze Sätze und adressieren verschiedene Themen (gewisse Vielfalt in der Themenwahl).

Abbildung 10.16: Clusteranalyse-Ergebnisse  
*Tripadvisor*, 2020

Cluster 0		
Anzahl rezensiver Texte $n_{rC_0}$		2352
Mittlere Textlänge* $\bar{r}_{C_0}$		47,07
Standardabweichung der mittleren Textlänge* $St(\bar{r}_{C_0})$		37,18
Mittlere Satzlänge* $\bar{s}_{C_0}$		14,07
Standardabweichung der mittleren Satzlänge* $St(\bar{s}_{C_0})$		5,51
Thema/ Themen- kombi	Emotion im Allgemeinen (1.4.4/5.6.4)	71,26%
	Zielgruppe des Rezensionsobjektes (5.10)	18,23%
	Restliche 13 (von 15) Themen/Themenkombinationen	10,51%
	Summe	100,00%
Cluster 1		
Anzahl rezensiver Texte $n_{rC_1}$		2685
Mittlere Textlänge* $\bar{r}_{C_1}$		65,89
Standardabweichung der mittleren Textlänge* $St(\bar{r}_{C_1})$		41,00
Mittlere Satzlänge* $\bar{s}_{C_1}$		15,61
Standardabweichung der mittleren Satzlänge* $St(\bar{s}_{C_1})$		5,78
Thema/ Themen- kombi	Museum (1.1.4)	42,14%
	Emotion im Allgemeinen (1.4.4/5.6.4)	39,56%
	Zielgruppe des Rezensionsobjektes (5.10)	12,59%
	Restliche 13 (von 16) Themen/Themenkombinationen	5,71%
Summe		100,00%
Cluster 2		
Anzahl rezensiver Texte $n_{rC_2}$		1359
Mittlere Textlänge* $\bar{r}_{C_2}$		94,37
Standardabweichung der mittleren Textlänge* $St(\bar{r}_{C_2})$		87,74
Mittlere Satzlänge* $\bar{s}_{C_2}$		16,84
Standardabweichung der mittleren Satzlänge* $St(\bar{s}_{C_2})$		5,66
Thema/ Themenkombination	Zielgruppe des Rezensionsobjektes (5.10)	23,65%
	Emotion im Allgemeinen (1.4.4/5.6.4)	22,19%
	Museum (1.1.4)	18,28%
	Verständlichkeit (5.8)	11,72%
	Rezeptionsanweisung geben (empfehlen) (10.4.7)	6,13%
	(Kauf-)Preis (1.1.6)	5,94%
	Emotion im Allgemeinen (1.4.4/5.6.4) und Zielgruppe des Rezensionsobjektes (5.10)	5,06%
	Restliche 22 (von 29) Themen/Themenkombinationen	7,01%
Summe		100,00%
grau markierungen stellen Themen/Themenkombinationen dar, die in allen Clustern vorkommen		
* gemessen in Wortanzahl		

Quelle: Kristin Kutzner/Universität Hildesheim



### 10.5.3 Zusammenfassung

Die Anwendung der Clusteranalyse erlaubte die Ableitung von Rezensionstypen auf Grundlage der gemeinsamen Ansprache von Themen in rezensiven Texten. Für alle betrachteten Korpora zeigen sich Cluster-übergreifende Themen bzw. Themenkombinationen. In den *Amazon*-Texten sind dies drei Themen, in den *BücherTreff.de*-Texten sieben und in den *Tripadvisor*-Texten zwei Themen, die gemeinsam in allen Clustern vorkommen. Die herausgestellten Rezensionstypen geben ferner Auskunft über die Vielfalt in der Themenwahl und erlauben Korpus-übergreifende Schlüsse: Es zeigt sich, dass die *BücherTreff.de*-Rezensionstypen insgesamt alle eine gewisse Vielfalt in der Themenwahl aufweisen, die *Amazon*-Rezensionstypen hier mehr variieren – von einer hohen bis zur geringen Themenvielfalt – und die *Tripadvisor*-Rezensionstypen insgesamt eher geringfügig vielfältig in der Themenansprache sind.

### 10.6 Fazit

Bevor wir ausgewählte Ergebnisse diskutieren und einen Ausblick für zukünftige Forschungsarbeiten geben, zeigen wir die wesentlichen *Limitationen* unserer Analysen auf.

(1) Unsere Untersuchungen beschränken sich auf die ausgewählten Daten von *Amazon*, *BücherTreff.de* sowie *Tripadvisor*. Da die Datenauswahl gemeinsam im Projektteam vor dem Hintergrund kultureller Bildungsprozesse diskutiert und festgelegt wurde, stellt unser Datenausschnitt einen ersten und wichtigen Anfang zur Beantwortung unserer Forschungsfragen dar. Eine allgemeine Validität für alle Online-Plattformen kann aber nicht garantiert werden. (2) Die ausgewählten Methoden zur Analyse verschiedener Perspektiven der Themenvielfalt sind ferner aufgrund der jeweiligen Funktionsweise selbst bzw. aufgrund der Art der Anwendung limitiert: Die *Topic Modeling-Methode* liefert Ergebnisse auf Basis der Wahrscheinlichkeitsrechnung. Nicht alle Topic-Ergebnisse waren interpretierbar. Unter Umständen konnten nicht alle Themen in den rezensiven Texten identifiziert werden. Darüber hinaus erfordert die Topic Modeling-Methode subjektive Entscheidungen, wie die Bestimmung der Anzahl an Topics oder die Zuordnung von Überschriften und Kategorien zu den Topics. Um zur Robustheit der Ergebnisse beizutragen, untersuchten wir die Topic-Kohä-

renz und involvierten mehrere unabhängige Personen in die Interpretation der Topics, die ihre Ergebnisse in einem anschließenden Workshop diskutierten. *Maschinelle Lernverfahren* sind ebenfalls von statistischen Gegebenheiten abhängig; außerdem stand nur eine begrenzte Menge an Trainingsmaterial zur Verfügung, sodass nur 20 verschiedene Kategorien des in Kapitel 4 vorgestellten Kategoriensystems getestet werden konnten; wir konnten hier also die Themenvielfalt nur mit einer Stichprobe aus der Kategoriensammlung überprüfen. Die *korpuslinguistischen Methoden* beruhen auf manuell ausgewählten Indikatoren – auch hier können Lücken entstanden sein. Die *netzwerkanalytische Betrachtung* der Themen basiert auf den Kategorien, welche (semi-)automatisch mit computerlinguistischen Verfahren extrahiert wurden. Da es sich hierbei nur um einen Ausschnitt aller möglichen Themen handelt, könnte sich eine andere Kategorienausswahl entsprechend auf die Daten zur Vielfalt an Themenpaaren auswirken. Insgesamt zeigt unsere Untersuchung jedoch, dass der Ansatz sich zur Untersuchung von Themenpaaren eignet und unserer Meinung nach erste, interessante Einblicke in das gemeinsame Vorkommen von Themen in rezensiven Texten liefert. Die *Clusteranalyse* zur Identifikation von Rezensionstypen basiert, wie bei der netzwerkanalytischen Betrachtung, auf den (semi-)automatisch extrahierten Themen und ist damit auch in der betrachteten Themenauswahl limitiert. Ferner werden die Ergebnisse durch die Angabe der Clusteranzahl und die Interpretation des Dendrogramms beeinflusst. Obwohl wir etablierten Ansätzen, wie der Ward-Methode und der K-Means-Methode, gefolgt sind, könnte die Bestimmung einer anderen Clusteranzahl Einfluss auf die Ergebnisse der Clusteranalyse nehmen.

Die vier verschiedenen Forschungsmethoden untersuchen die Themenvielfalt aus unterschiedlichen Perspektiven und liefern entsprechende Erkenntnisse für die drei betrachteten Korpora (siehe Abbildung 10.17). Inwiefern die Ergebnisse miteinander in Beziehung stehen oder sich gegenseitig ergänzen diskutieren wir im Folgenden.

Die *Topic-Modeling-Methode* untersucht die Prominenz von Themen auf Korpusebene (siehe Abschnitt 10.2). In den rezensiven *Amazon*-Texten zeigten sich wenig prominente Themen und damit eine geringe Themenvielfalt, in den *BücherTreff.de*- und *Tripadvisor*-Texten konnte eine Vielzahl prominenter Themen sowie eine hohe Vielfalt an Themen identifiziert werden. Die *Themenextraktion* auf Einzeltextebene mit Verfahren des maschinellen Lernens und der Korpuslinguistik identifiziert rund ein halbes Dutzend

Abbildung 10.17: Ergebnisse zur Themenvielfalt im Überblick, 2020

	Topic Modeling (Abschnitt 10.2)	Themenextraktion (Abschnitt 10.3)	Netzwerkanalyse (Abschnitt 10.4)	Clusteranalyse (Abschnitt 10.5)
Rezensive Amazon- Texte zu Büchern	Wenig prominente Themen, geringe Themenvielfalt (A1)	Wenig prominente Themen, eher geringe Themenvielfalt (A2)	Hohe Vielfalt in den Themenpaaren (A3)	Lange Texte mit hoher Themenvielfalt (A4); Kurze Texte mit geringer Themenvielfalt (A5); Texte mittlerer Länge mit Themenvielfalt (A6)
Rezensive BücherTreff- Texte zu Büchern	Viele prominente Themen, hohe Themenvielfalt (B1)	Wenig prominente Themen, eher geringe Themenvielfalt (B2)	Hohe Vielfalt in den Themenpaaren (B3)	Lange Texte mit hoher Themenvielfalt (B4); Kurze Texte mit Themenvielfalt (B5); Texte mittlerer Länge mit Themenvielfalt (B6)
Rezensive Tripadvisor- Texte zu Museen	Viele prominente Themen, hohe Themenvielfalt (T1)	Wenig prominente Themen, geringe Themenvielfalt (T2)	Geringe Vielfalt in den Themenpaaren (T3)	Sehr kurze Texte ohne Themenvielfalt (T4); Kurze Texte mit geringer Themenvielfalt (T5); Kurze Texte mit Themenvielfalt (T6)

Quelle: Kristin Kutzner/Universität Hildesheim

Themen als sehr prominent, die anderen als eher sporadisch auftretend; die Unterschiede zwischen den Plattformen sind eher gering, sodass der Eindruck entsteht, dass auf den drei Plattformen sehr oft über dieselben Themen geschrieben wird, andere (und damit eine große Themenvielfalt) eher Randerscheinungen sind (siehe Abschnitt 10.3). Die *Netzwerkanalyse* untersucht das gemeinsame Vorkommen von Themen auf Textebene (siehe Abschnitt 10.4) und ergänzt die bisherigen Erkenntnisse zur Themenvielfalt. Einzelne rezensive *Amazon*- und *BücherTreff.de*-Texte zeichnen sich durch eine hohe Vielfalt in der gemeinsamen Ansprache von Themen aus, während sich in den *Tripadvisor*-Texten eine geringe Vielfalt in den Themenpaaren zeigt. Die *Clusteranalyse* identifiziert Rezensionstypen auf Basis gemeinsam vorkommender Themen in rezensiven Texten und erlaubt eine differenzierte Betrachtung der Themenvielfalt in Abhängigkeit von der Textlänge (siehe Abschnitt 10.5).

Die Themenvielfalt von rezensiven Texten konnte mit den hier aufgezeigten Methoden untersucht und charakterisiert werden, erfordert jedoch weitere Forschungsarbeiten. Im Folgenden zeigen wir daher anzustrebende, ausgewählte *Forschungsrichtungen für die Zukunft* auf.

(1) Die exemplarische Anwendung der Methoden lieferte uns für die drei ausgewählten Korpora von *Amazon*, *BücherTreff.de* und *Tripadvisor* erste Erkenntnisse zur Themenvielfalt. In einem nächsten Schritt sind weitere

Korpora von rezensiven Texten zu Büchern und Museen verschiedener Online-Plattformen hinzuzuziehen, um unsere Erkenntnisse zu bestätigen, zu verwerfen oder weiter zu entwickeln. Es erscheint beispielsweise, als seien Literatur- und Kunstblogs thematisch vielfältiger als die drei Online-Plattformen. (2) Zur Identifikation von Rezensionstypen anhand der angesprochenen Themen und damit zur Ableitung von Hypothesen, nutzen wir eine Vielzahl an rezensiven Texten unterschiedlicher Länge als Objekte für die Clusteranalyse. Zur Überprüfung und weiteren Differenzierung unserer bisherigen Hypothesen wäre es interessant, die Clusteranalyse für rezersive Texte ähnlicher Längen durchzuführen. Beispielsweise verweist die Hypothese B5 auf kurze Texte mit einer gewissen Themenvielfalt in den *Bücher Treff.de*-Daten. Zur Überprüfung dieser Hypothese wäre eine erneute Clusteranalyse mit besonders kurzen rezensiven Texten als Objekte erforderlich. Dies würde ein differenziertes Bild für kurze Texte liefern und zeigen, ob hier ein Fokus auf die gleichen Themen gelegt wird oder auch hier unterschiedliche Themen adressiert werden.