



Exposé für die geplante Masterarbeit:

Metacharakteristika situativer Musikauswahl -  
Eine Analyse nutzergenerierter Playlists auf Spotify

Vorgelegt von

Tom Potthoff  
t.potthoff@campus.tu-berlin.de

Technische Universität Berlin  
M.Sc. Audiokommunikation und -technologie

Prof. Dr. Stefan Weinzierl  
Dr. Steffen Lepa

## **Inhaltsverzeichnis**

Abbildungsverzeichnis	II
Abstract	III
1. Einleitung und Fragestellung	4
2. Stand der Forschung	4
3. Methoden und Quellen	6
4. Vorarbeiten	7
5. Arbeits- und Zeitplan	7
Literaturverzeichnis	IX

## **Abbildungsverzeichnis**

Abbildung 1- Wochenplan für die Arbeitsschritte zur Erstellung der geplanten Masterarbeit  
in vier Phasen

8

## **Abstract**

Das vorliegende Exposé beschreibt das Forschungsvorhaben für eine geplante Masterarbeit mit dem Titel „Metacharakteristika situativer Musikauswahl - Eine Analyse nutzergenerierter Playlists auf Spotify“. Das Ziel der Forschung ist die Untersuchung von funktionaler Musik bezüglich ihrer jeweiligen musikalischen Charakteristika. Zentraler Untersuchungsgegenstand des Forschungsvorhabens sollen Spotify Playlists sein, in denen Nutzer Musik für eine bestimmte Situation oder Aktivität organisieren. Um über die API von Spotify dafür relevante Playlists zu finden, soll aus einschlägigen Forschungsbeiträgen zum Thema Musikauswahlverhalten recherchiert werden, in welchen alltäglichen Situationen und Aktivitäten typischerweise Musik gehört wird. Anschließend werden systematisch Spotify Playlists gesampelt, die im Titel Begriffe aufweisen, die solche Situationen und Aktivitäten repräsentieren. Aus diesen wird dann eine Stichprobe funktionaler Musik für das Forschungsvorhaben gebildet. Unter Verwendung der Audio-Features der Musiktitel aus der Stichprobe als Indikatoren für eine Latent-Profile-Analyse (LPA) soll untersucht werden, ob sich die Funktionsmusik anhand musikalischer Charakteristika klassifizieren lässt. Für die daraus hervorgehenden Klassen wird in dieser Masterarbeit der Begriff Metacharakteristika eingeführt. Deren Zusammenhänge mit den aus der Forschungsliteratur ermittelten exemplarischen Alltagssituationen und -aktivitäten sowie den Genres der Musik sollen ebenfalls erforscht werden.

## 1. Einleitung und Fragestellung

Ein ständiger Beobachtungsgegenstand in der musikpsychologischen Forschung ist das Musikauswahlverhalten. Im Kontext der zentralen Frage nach der Motivation der Musikauswahl stellt sich zum einen die Frage welche Faktoren die Musikauswahl beeinflussen und zum anderen die Frage nach der Art der Musik, die ausgewählt wird. Bereits oft untersuchte Prädiktoren sind Persönlichkeitsmerkmale und die Auswahl-situation, zu der Musik ausgewählt wird (North und Hargreaves, 1996; Rentfrow und Gosling, 2003; North et al., 2004; Greb et al., 2018; Rentfrow et al., 2011).

Obwohl bereits einige Erkenntnisse auf diesem Gebiet gesammelt wurden, gibt es hier insbesondere Forschungsbedarf hinsichtlich der Kategorisierungskriterien und Bezeichnung solcher Musikkategorien für die Musikauswahl (Bansal et al., 2020). Erkenntnisse zu möglichen Kategorisierungen von Musik gingen klassischerweise aus der Befragung von Probanden bezüglich ihres Musikauswahlverhaltens und ihrer Musikwahrnehmung hervor. Allerdings sind die Antworten einer direkten Befragung von Personen zu ihrem Musikhörverhalten oft durch Eigenwahrnehmung, Befragungssituation und das subjektive Verständnis von Musik verzerrt (Rentfrow und Gosling, 2003). Neue Ansätze dies zu untersuchen ergaben sich mit der Verlagerung des Musikkonsums von der privaten Musiksammlung hin zu den on Demand Streaming Plattformen wie Spotify, YouTube oder Apple Music. Denn mit Application Programming Interfaces (APIs), wie der von Spotify, bieten sich externen Forschern Zugang zu Informationen über Musiktitel und Nutzerverhalten in einer Big-Data Größenordnung (Barone et al., 2017).

Die geplante Masterarbeit will dies nutzen, um Spotify Playlists, die von Nutzern für alltägliche Hörsituationen angelegt wurden, zu erforschen. Die Analyse soll auf die Frage eingehen, ob die für Alltagssituationen und -aktivitäten ausgewählten Musiktitel durch ihre unterschiedlich ausgeprägte Klangbeschaffenheit, Rhythmik, Dynamik, Gestaltung und psychologische Stimmung kategorisierbar sind. Solche Kategorien werden in dieser Masterarbeit als Metacharakteristika bezeichnet. Deren Zusammenhang mit exemplarischen Alltagssituationen und -aktivitäten wird ebenfalls untersucht, wie auch deren Zusammenhang mit gängigen Musikgenres.

Anhand der Ergebnisse soll diskutiert werden, ob und in welchem Umfang Metacharakteristika für Forschung und Musikwirtschaft eine weitere Möglichkeit zur Einordnung von Musik bieten.

## 2. Stand der Forschung

Musikauswahl und -präferenzen werden im Alltäglichen oft durch das Musikgenre abgegrenzt. Die Autoren Rentfrow und Gosling (2003) konnten mit dem STOMP -Modell 14 Hauptgenres ermitteln die in vier übergeordneten Dimensionen *Reflective & Complex*, *Intense & Rebellious*, *Upbeat & Conventional*, *Energetic & Rhythmic* eingeordnet werden. Große Kritikpunkte dieser Studie waren jedoch das interpersonell und interkulturell unterschiedliche Verständnis der Musikgenres, bedingt durch Faktoren wie Alter, Geschlecht und Provenienz der Befragten. Hierzu konnten die Autoren Bansal et al. (2020) auch zeigen, dass die Persönlichkeit Einfluss auf die eigenen Genre-Vorlieben hat. Die Abgrenzung zwischen den Genres durch Probanden bleibt damit schwierig, zumal diese auch von der sozialen Situation abhängt, in der ein Genre gewählt wird (Rentfrow und Gosling, 2007). Oft widersprechen sich deswegen die Ergebnisse der Genre Bewertung durch Menschen und die computer-basierte Genre Klassifizierung (Lippens et al., 2004) . Später haben die Autoren Rentfrow et al. (2011) mit dem MUSIC -Modell ein neues Konzept zur Klassifizierung vorgestellt, das Musik unabhängig des Genres in die fünf Faktoren *Mellow*, *Unpretentious*, *Sophisticated*, *Intense* und *Contemporary* einteilt. Dieser explorative Ansatz zeigte mittels Faktoranalyse, dass sich latente Klassen von Musik

auf Basis der Wahrnehmung ihrer musikalischen Charakteristik finden lassen. Eine andere Studie der Autoren Greb et al. (2018) konnte ebenfalls mittels einer explorativen Faktoranalyse 5 Faktoren feststellen, von denen jeder eine psychologische Funktion von Musik beschreibt: *Intellectual Stimulation*, *Mind Wandering & Emotional Involvement*, *Motor Synchronization & Enhanced Well-being*, *Updating One's Musical Knowledge* und *Killing Time & Overcoming Loneliness*. Diese Analyse basiert auf den Aussagen zur Motivation des Musikhörens, wie die Autoren Schäfer et al. (2013) sie in ihrer Studie erklären. Für die 5 Faktoren der Funktion der Musik konnten auch Zusammenhänge mit bestimmten Situationen oder Aktivitäten gezeigt werden. Somit kamen die Autoren Greb et al. (2018) zu dem Erkenntnis, dass die Situation den größeren Einfluss auf die Musikauswahl hat, noch vor Persönlichkeitsmerkmalen wie Alter, Geschlecht, Herkunft, IQ oder der Ausprägung der Big-Five einer Persönlichkeit. Jedoch ist es schwierig die Auswahl-situation als einzelnen Prädiktor einer Untersuchung zu erfassen, weshalb die Autoren die Tageszeit und Aktivität als Indikatoren für das Vorherrschen einer bestimmten Situation vorschlagen. Den Einfluss der Situation auf die Musikauswahl von Personen beschäftigte bereits die Autoren North et al. (2004). Neben den psychologischen Funktionen, wie in den Studien von Hargreaves und North (1999), Schäfer und Sedlmeier (2009) und Schäfer et al. (2013) beschrieben, sprechen sie auch von einer praktischen Funktion von Musik zur Begleitung einer Aktivität.

Klassischerweise ist die direkte Befragung eine gängige Methode, um Daten über Musikpräferenz, Funktion der Musik und Hörsituation bzw. Aktivität zu erheben. Jedoch birgt die Selbstauskunft von Probanden die bereits erwähnten Artefakte. Neuste Forschungsarbeiten nutzen deshalb den externen Zugang zu Download- oder Streaming Portalen, um indirekt Auskunft über Musikauswahlverhalten von Nutzern zu erhalten (Barone et al., 2017; Bansal et al., 2020; Fricke et al., 2019). Das Music Information Retrieval (MIR) trägt mit den Audio-Features eines Musikstücks zusätzliche Informationen zur Musik bei. Diese stammen aus der Analyse der Musikdatei mit Methoden der digitalen Signalverarbeitung und versprechen deshalb eine objektive Beschreibung der musikalischen Inhalte. Feature-basierte Ansätze haben zwar öfter noch explorativen Charakter, zeigen aber interessante Forschungsmöglichkeiten auf (Fricke et al., 2019, 2018). So konnten Barone et al. (2017) auf Basis der Spotify Audio Features belegen, dass die musikalischen Charakteristika der individuell präferierten Musik auch beeinflussen, welche Musik man außerhalb der Präferenzgenres auswählt. Das veranlasst die Autoren zu vermuten, dass auch direkte Zusammenhänge zwischen den Ausprägungen der Audio-Features präferierter Musik und den Persönlichkeitsmerkmalen bestehen könnten.

Ein anderes, wenn auch nicht völlig neues, Untersuchungsobjekt im Zusammenhang mit der Musikauswahl ist die Playlist. Sie gilt als beliebtes Mittel Musik zu organisieren (Kamalzadeh et al., 2012). Bereits das Mixtape war eine Playlist, wenn gleich es auch nicht die momentanen Freiheiten der flexiblen Playlistpflege und randomisierten Wiedergabefolge bot (Cunningham et al., 2006). Auch auf den aktuell beliebten digitalen Streaming Plattformen werden Playlists viel genutzt, weshalb sie auch von kommerziellem Interesse sind. Für die Forschung stehen aber besonders die nutzergenerierten Playlists im Fokus, da sie Aufschluss über Musikpräferenz und deren Auswahlkontext und damit Hinweise auf die Funktion der Musik in der Playlist geben können (Park und Kaneshiro, 2021).

### 3. Methoden und Quellen

Das methodische Vorgehen für die geplante Abschlussarbeit lässt sich grob in vier Abschnitte einteilen. Als erstes soll aus einschlägiger musikpsychologischer Fachliteratur identifiziert werden, in welchen Alltagssituationen und -aktivitäten typischerweise Musik gehört wird. Beispiele für richtungsweisende Untersuchungen sind zum Beispiel die Forschungsbeiträge von North und Hargreaves (1996), Rentfrow und Gosling (2003), North et al. (2004), Krause et al. (2014) oder Greb et al. (2018).

Ziel ist es kurze Betitelungen oder Schlagwörter von alltäglichen Situationen oder Aktivitäten aus den Quellen herauszuarbeiten, die für die situative Musikauswahl als maßgeblich befunden wurden.

Da der Großteil der einschlägigen Literatur in englischer Sprache verfasst ist, werden auch diese Aktivitäts- und Situationsbezeichnungen in englischer Sprache erfasst. Um die Validität der ermittelten Begriffe nicht durch eine unzureichende Übersetzung zu gefährden, soll diese Arbeit Playlists von Nutzern aus dem US-amerikanischen Marktgebiet von Spotify untersuchen. Dies bietet sich auch an, um die Ergebnisse dieser Arbeit leichter im Kontext der internationalen Forschung betrachten zu können. Für eine gründlichere Suche nach Playlists mit Bezug zu einer Alltagssituation oder -aktivität soll mit Hilfe eines Thesaurus nach Synonymen für die gefundenen Bezeichnungen gesucht werden.

Die nutzgenerierten Playlists werden über die Spotify API gesucht. Diese erlaubt eine Fuzzy-String-Suche nach Playlists, die eine der Situations- bzw. Aktivitätsbezeichnungen oder deren Synonym im Titel oder der Beschreibung der Playlist aufweisen. Mithilfe der Implementierung eines API-Wrappers in RStudio sollen 100 zufällige Playlists aus den ersten 1500 Suchergebnissen von Spotify ermittelt werden. Für die gesamte Anzahl der unikalen Musiktitel aus diesen Playlists werden die Metadaten sowie Low-Level und High-Level Audio-Features des Spotify Katalogs abgerufen. Anschließend sollen die Audio-Features der AcousticBrainz Datenbank über deren API für jeden Musiktitel abgerufen werden, sofern diese zur Verfügung stehen (AcousticBrainz, 2020). Ebenso soll die Genre Klassifizierung von der Discogs-API für jeden Musiktitel abgerufen werden (Discogs, 2018). Da die Titel- Kataloge von AcousticBrainz und Discogs nicht so umfangreich sind wie der Spotify Katalog, ist damit zu rechnen, dass die Anzahl der Songs mit vollständigen Metadaten und Audio Features aus allen drei APIs deutlich weniger als 1000 Titel betragen wird. Dementsprechend könnte ein Oversampling oder auch eine unterschiedliche Gewichtung der mit einer Situation oder Aktivität assoziierten Musiktitel in der Stichprobe notwendig werden, um die angestrebte Nettostichprobengröße von ca. 10000 Titeln bei einer Gleichverteilung aller gesuchten Alltagssituationen und -aktivitäten zu erreichen.

Die Stichprobe soll anschließend mittels einer Latent Profile Analysis (LPA) auf Basis der Audio Features von Spotify und AcousticBrainz als Indikatoren auf etwaige latente musikalische Metacharakteristika untersucht werden. Unter Vorgabe von Indikatoren berechnet die LPA die beste Lösung zu Erklärung der multivariaten Verteilung anhand latenter diskreter Klassen, auf Basis des kleinsten Bayesian-Information-Criterion (BIC). Um herauszufinden, mit welchen Audio-Features sich die situative Musikauswahl in Playlists am besten klassifizieren lässt, ist angedacht die verfügbaren Spotify und AcousticBrainz Audio Features iterativ in einer Art Stepwise-Verfahren ins Modell einzubringen, um das beste Klassifizierungsergebnis aus den Ergebnissen aller iterativen LPAs auf Basis der BIC zu bestimmen.

Zum Abschluss der statistischen Analyse sollen sowohl die Zusammenhänge zwischen den Metacharakteristika und den festgestellten exemplarischen Alltagssituationen und -aktivitäten, als auch den Genres der Funktionsmusik untersucht werden. Die Genre Klassifizierung soll titelbasiert einbezogen werden, wofür sich entweder die *Rosamerica* Genre Klassifizierung von AcousticBrainz oder die Genre Tags von Discogs eignen. Hier wird sich erst im Laufe des Datensamplings zeigen, welche Daten ausreichend für eine Analyse zur Verfügung stehen. Da die drei zu untersuchenden Variablen alle kategorial skaliert sind, bieten sich für die Analyse generalisierte lineare Regressionsmodelle an. Der generelle Zusammenhang zwischen Metacharakteristika, Alltagssituationen bzw. -aktivitäten und Genres kann in einem einzigen log-linearen Modell untersucht werden. Um jedoch den Zusammenhang zwischen den jeweils einzelnen Klassen der Metacharakteristika und den jeweiligen alltäglichen Situationen und Aktivitäten bzw. Genres zu beleuchten, sollen binär logistische Regressionsmodelle für jede Metacharakteristik dienen.

#### **4. Vorarbeiten**

Eine explorative Analyse von nutzergenerierten Spotify Playlists in Deutschland wurde im Rahmen einer Seminararbeit im Seminar *Computational Music Studies* von Dr. Steffen Lepa im Sommersemester 2020 durchgeführt. Die erhobenen Musiktitel wurden mittels eines CLARA-Clustering Algorithmus auf Basis der Spotify Audio-Features untersucht, ohne jedoch weitere Zusammenhänge der gefundenen Klassen mit den Alltagssituationen und -aktivitäten oder den Musikgenres zu überprüfen. Die Ergebnisse der CLARA Analyse gaben jedoch die Motivation eine umfassendere Studie in Form einer Masterarbeit zu versuchen. Zur Konzeptionalisierung der Methode für eine solche Arbeit diente der Besuch des Seminars *Music Information Retrieval und Machine Learning mit R* von Dr. Steffen Lepa im Wintersemester 2020/21 als Gasthörer. Daraus hervor gingen die Ideen für die Anreicherung des Informationsgehaltes der Stichprobe mit den Audiofeatures von AcousticBrainz und den Genre Informationen von Discogs sowie der Ansatz der Latent Profile Analyse an Stelle des CLARA Algorithmus.

#### **5. Arbeits- und Zeitplan**

Der Zeitraum für die Erstellung der Masterarbeit ist auf 6 Monate begrenzt und wird voraussichtlich zwischen Anfang April 2021 und Ende September 2021 liegen. Der gesamte Prozess kann in vier Phasen eingeteilt werden, angefangen mit einer vertiefenden Literatur Recherche. Daraus sollen in Phase 1 zunächst die für die Musikauswahl exemplarischen Alltagssituationen und -aktivitäten und dafür möglichst valide Suchbegriffe herausgearbeitet werden. Darüber hinaus soll in Phase 1 der Stand der Forschung umfassender beleuchtet werden, um das Konzept der Arbeit theoretisch zu unterfüttern. Sobald zu Beginn von Phase 1 die Suchbegriffe für die Playlists festgelegt sind, kann bereits Phase 2 mit dem Daten-Sampling beginnen. Dazu zählen die Suche nach passenden Playlists und den darin gelisteten Musiktiteln über die Spotify API und die Anreicherung der Titelinformationen mit den Audio-Features von Spotify und AcousticBrainz sowie den Genre Informationen von Discogs. Anschließend werden in Phase 2 die Latent Profile Analyse und die generalisierten Regressionsanalysen durchgeführt. In Phase 3 soll die Arbeit in Gänze zu Papier gebracht werden. Hier sind abschließend auch 2 Wochen Urlaub eingeplant, bevor die letzte Phase beginnt. Phase 4 dient zunächst der inhaltlichen und sprachlichen Überarbeitung des Geschriebenen. Abschließend sollen das Korrekturlesen und die formale Überprüfung, voraussichtlich Ende September, die Masterarbeit für die Abgabe fertigstellen. Eine Wochen-Übersicht aller 4 Phasen und den darin geplanten Arbeitsschritten zeigt die Abbildung 1.



<b>Kalenderwochen:</b>		KW11	KW12	KW13	KW14	KW15	KW16	KW17	KW18	KW19	KW20		
		15. Mrz	22. Mrz	29. Mrz	05. Apr	12. Apr	19. Apr	26. Apr	03. Mai	10. Mai	17. Mai		
<b>Wochen in der offiziellen Bearbeitungszeit:</b>			1	2	3	4	5	6	7				
<b>Arbeitsschritte</b>	<b>Beginn</b>	<b>Ende</b>											
Phase 1	05. Apr	23. Mai											
vertiefte Literatur Recherche	15. Mrz	23. Mai											
Identifizierung der Situationen, Aktivitäten und Suchbegriffe	05. Apr	18. Apr											
vorrussichtliche Fristvergabe	05. Apr	05. Apr	◆										
Phase 2	26. Apr	23. Mai											
Daten Sampling	26. Apr	09. Mai											
Datenanalyse: LPA und GLMs	10. Mai	23. Mai											
<b>Kalenderwochen:</b>		KW21	KW22	KW23	KW24	KW25	KW26	KW27	KW28	KW29	KW30	KW31	KW32
		24. Mai	31. Mai	07. Jun	14. Jun	21. Jun	28. Jun	05. Jul	12. Jul	19. Jul	26. Jul	02. Aug	09. Aug
<b>Wochen in der offiziellen Bearbeitungszeit:</b>		8	9	10	11	12	13	14	15	16	17	18	19
<b>Arbeitsschritte</b>	<b>Beginn</b>	<b>Ende</b>											
Phase 3	24. Mai	15. Aug											
Schreiben der Masterarbeit	24. Mai	01. Aug											
Urlaub	02. Aug	15. Aug											
<b>Kalenderwochen:</b>		KW33	KW34	KW35	KW36	KW37	KW38	KW39					
		16. Aug	23. Aug	30. Aug	06. Sep	13. Sep	20. Sep	27. Sep					
<b>Wochen in der offiziellen Bearbeitungszeit:</b>		20	21	22	23	24	25						
<b>Arbeitsschritte</b>	<b>Beginn</b>	<b>Ende</b>											
Phase 4	16. Aug	27. Sep											
Überarbeitung der Masterarbeit	16. Aug	12. Sep											
Korrekturlesen (spätestens)	13. Sep	19. Sep											
Abgabe vorbereiten	20. Sep	26. Sep											
vorrussichtliches Ende der Abgabefrist	27. Sep	27. Sep											◆

Abbildung 1- Wochenplan für die Arbeitsschritte zur Erstellung der geplanten Masterarbeit in vier Phasen

## Literaturverzeichnis

- AcousticBrainz (2020): „API - AcousticBrainz.“ Online. URL [HTTPS://ACOUSTICBRAINZ.ORG/DATA](https://acousticbrainz.org/data). Zugriff am 05.03.2021.
- Bansal, Jotthi; Flannery, Maya B. und Woolhouse, Matthew H. (2020): „Influence of personality on music-genre exclusivity.“ In: *Psychology of Music*, 00(0) S.1-16.
- Barone, Michael D; Bansal, Jotthi und Woolhouse, Matthew H. (2017): „Acoustic Features Influence Musical Choices Across Multiple Genres.“ In: *Frontiers in psychology*, 8(931) S. 1–14.
- Cunningham, Sally Jo; Bainbridge, David und Falconer, Annette (2006): „More of an art than a science": Supporting the creation of playlists and mixes.“ In: *In Proceedings of the 7th Conference of the International Society of Music Information Retrieval (ISMIR), Victoria, Canada*.
- Discogs (2018): „Discogs API Documentation.“ Online. URL [HTTPS://WWW.DISCOGS.COM/DEVELOPERS](https://www.discogs.com/developers). Zugriff am 05.03.2021.
- Fricke, Kai R; Greenberg, David M; Rentfrow, Peter J. und Herzberg, Philipp Y. (2018): „Computer-based music feature analysis mirrors human perception and can be used to measure individual music preference.“ In: *Journal of Research in Personality*, 75 S. 94–102.
- Fricke, Kai R; Greenberg, David M; Rentfrow, Peter J. und Herzberg, Philipp Y. (2019): „Measuring musical preferences from listening behavior: Data from one million people and 200,000 songs.“ In: *Psychology of Music*.
- Greb, Fabian; Schlotz, Wolff und Steffens, Jochen (2018): „Personal and situational influences on the functions of music listening.“ In: *Psychology of Music*, 46(6) S. 763–794.
- Hargreaves, David J. und North, Adrian C. (1999): „The Functions of Music in Everyday Life: Redefining the Social in Music Psychology.“ In: *Psychology of Music*, (27) S. 71–83.
- Kamalzadeh, Mohsen; Baur, Dominikus und Möller, Torsten (2012): „A survey on music listening and management behaviours.“ In: *Proceedings of the 13th International Society for Music Information Retrieval Conference (ISMIR), Porto, Portugal*.
- Krause, Amanda; North, Adrian C. und Hewitt, Lauren (2014): „Music Selection Behaviors in Everyday Listening.“ In: *Journal of Broadcasting & Electronic Media*, 58(2) S. 306–323.
- Lippens, Stefaan; Martens, Jean-Pierre. und Mulder, Tom de (2004): „A comparison of human and automatic musical genre classification.“ In: *Acoustics, Speech, and Signal Processing, 2004. Proceedings. (ICASSP '04). IEEE International Conference on*, Volume: 4, iv-233 - iv-236.
- North, Adrian C. und Hargreaves, David J. (1996): „Situational influences on reported musical preference.“ In: *Psychomusicology: A Journal of Research in Music Cognition*, 15 S. 30–45.
- North, Adrian C; Hargreaves, David J. und Hargreaves, Jon J. (2004): „Uses of Music in Everyday Life.“ In: *Music perception*, 22(1) S. 41–77.
- Park, So Yeon und Kaneshiro, Blair (2021): „Social Music Curation That Works: Insights from Successful Collaborative Playlists.“ In: *Association for Computing Machinery*, 5No. CSCW1 S. 1–27.
- Rentfrow, Peter J; Goldberg, Lewis R. und Levitin, Daniel J. (2011): „The structure of musical preferences: a five-factor model.“ In: *Journal of Personality and Social Psychology*, 100(6) S. 1139–1157.
- Rentfrow, Peter J. und Gosling, Samuel D. (2003): „The do re mi's of everyday life: The structure and personality correlates of music preferences.“ In: *Journal of Personality and Social Psychology*, 84(6) S. 1236–1256.

- Rentfrow, Peter J. und Gosling, Samuel D. (2007): „The content and validity of music-genre stereotypes among college students.“ In: *Psychology of Music*, 35(2) S. 306–326.
- Schäfer, Thomas und Sedlmeier, Peter (2009): „From the functions of music to music preference.“ In: *Psychology of Music*, 37(3) S. 279–300.
- Schäfer, Thomas; Sedlmeier, Peter; Städtler, Christine und Huron, David (2013): „The psychological functions of music listening.“ In: *Frontiers in psychology*, 4 S. 1–33.