

Implementierungskonzept:
Einsatz von Recommender Systems
zur Förderung eines nachhaltigen
Online-Konsums

Inhaltsverzeichnis

Inhaltsverzeichnis	2
I. Einleitung.....	3
II. Möglichkeiten des Einsatzes von Recommender Systems für nachhaltigen Konsum	4
III. Relevanz von RS in der Praxis für einen nachhaltigen Online-Konsum.....	6
IV. Daten	7
A. Anforderungen an die Daten und Format.....	7
B. E-Commerce Beispieldatensätze	7
V. Algorithmen.....	8
VI. Code Beispiele	9
A. Produktbasiertes Collaborative Filtering: Cosinus-Ähnlichkeit und Korrelation.....	9
B. Kundenbasiertes Collaborative Filtering: Cosinus-Ähnlichkeit und Korrelation	10
VII. Weiterführende Literatur	11
VIII. Mechanismen für eine nachhaltigere KI	12
IX. Ethische, soziale und rechtliche Folgen von Recommender Systems.....	13
A. Relevanz der ELSI-Kriterien im Kontext der Algorithmus-/KI-Entwicklung	13
B. Anwendung von ELSI-Kriterien für die zukünftige Entwicklung von Recommender Systems ..	13
Literaturverzeichnis	16

I. Einleitung

KI-Verfahren spielen im Online-Handel eine immer größere Rolle. Meist werden sie derzeit dazu eingesetzt, um Werbung zu personalisieren, Kundenservice mittels Chatbots zu optimieren oder Bewertungen oder Texte zu generieren. Doch welches Potenzial haben sie für mehr Nachhaltigkeit im Online-Handel?

Ziel dieses Implementierungskonzepts ist es aufzuzeigen, in wie und unter welchen Bedingungen KI und im Speziellen Recommender Systems (RS) in der Kommunikation zu einem nachhaltigeren Konsum im Online-Handel beitragen können. In Kapitel II werden zunächst RS und zwei grundsätzliche Möglichkeiten zum Einsatz im Online-Handel beschrieben. In Kapitel III geht es dann um die Experteneinschätzung zur Relevanz von RS im Online-Handel. Kapitel IV beschäftigt sich mit der Datenstruktur für RS.

Kapitel V beschreibt einige der bewährten RS-Algorithmen. Das nächste Kapitel VI gibt dann einige Code-Beispiele dazu. Danach wird eine kurze Übersicht über relevante Literatur zu RS in Kapitel VII gegeben. Im Kapitel VIII geht es um die Nachhaltigkeitsbewertung von RS und KI. Im letzten Kapitel IX werden dann RS anhand der ELSI-Kriterien auf ihre ethischen, sozialen und rechtlichen Folgen untersucht.

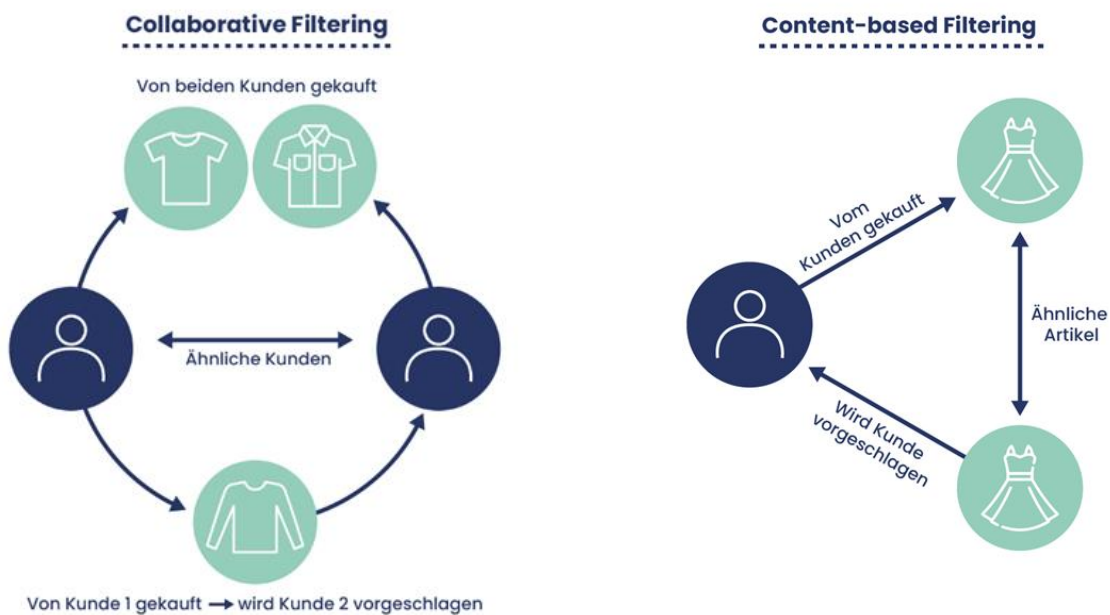
II. Möglichkeiten des Einsatzes von Recommender Systems für nachhaltigen Konsum

Recommender Systems (RS) sind Algorithmen, die basierend auf bestehenden Daten, Empfehlungen vorschlagen (Goldberg et al., 1992). Im Kontext des Online-Handels können ähnliche Produkte zu einem Produkt, das eine Kundin oder ein Kunde gerade ansieht, vorgeschlagen werden. Dabei können sowohl die Produktdaten als auch die Kundendaten bzw. Verhaltensdaten mit einbezogen werden.

RS haben sich in den letzten Jahren zu unverzichtbaren Werkzeugen für Händler entwickelt, um ihre Kundenerfahrung zu personalisieren und ihre Umsätze zu steigern. Durch den gezielten Einsatz von Empfehlungen können Händler ihren Kund:innen maßgeschneiderte Produktempfehlungen bieten, die deren individuellen Bedürfnissen und Vorlieben entsprechen. Dies führt nicht nur zu einer höheren Kundenzufriedenheit, sondern auch zu einer gesteigerten Kundenbindung und einem langfristigen Erfolg für das Unternehmen.

Angesichts der zunehmenden Bedeutung von Nachhaltigkeit ist es für Händler von entscheidender Bedeutung, nachhaltige Empfehlungen in ihre RS zu integrieren. Indem Händler nachhaltige Empfehlungen fördern, leisten sie einen aktiven Beitrag zum Umweltschutz und unterstützen die Umsetzung nachhaltigerer Konsumgewohnheiten. Auch kann dies langfristig Vorteile für Image und Rentabilität des Shops haben.

Bei der Umsetzung eines RS im Online-Handel wird häufig eine dieser Möglichkeiten genutzt:



- **Collaborative Filtering:** Erstens besteht die Möglichkeit, **kundenbasierte Empfehlungen zu geben**. Dabei werden Kund:innen Artikel vorgeschlagen, die von Kund:innen mit ähnlichem Kaufinteresse gekauft wurden. In der Abbildung haben Kunde 1 und Kunde 2 vorher Oberteile in derselben Farbe gekauft. Nachdem Kunde 1 ein weiteres Oberteil in der Farbe gekauft hat, wird es Kunde 2 vorgeschlagen. Indikatoren zur Bestimmung der Präferenzen sind z.B. Dauer der Betrachtung von Produkten, Produkte im Warenkorb bzw. Abverkaufszahlen sowie positive Bewertungen. Es können aber auch andere Daten miteinbezogen werden, zum Beispiel die Demographik. Bezogen auf Nachhaltigkeit, könnte das bedeuten, dass sich Kund:innen mit nachhaltigem Interesse ähnlich sind und ihnen weitere nachhaltige Produkte empfohlen werden, sofern sich ähnliche Kunden auch für weitere nachhaltige Produkte

interessiert haben. Allerdings besteht hierbei die Herausforderung, nachhaltige Vorschläge an nicht-nachhaltigkeitsinteressierte Kund:innen auszuspielen. Neben der Ähnlichkeit der Nutzer:innen basierend auf ihren Interaktionen mit Produkten, können beim Collaborative Filtering auch die Ähnlichkeit der Produkte basierend auf den Kundeninteraktionen mit ihnen benutzt werden.

- **Content-based Filtering:** Zweitens besteht die Möglichkeit **produktbasierte Empfehlungen** zu geben, die auf Produktmerkmalen basieren. Der Unterschied ist, dass hier keine anderen Nutzer:innen miteinbezogen werden. In der Abbildung hat ein Kunde ein Kleid gekauft, woraufhin ihm ein Kleid im selben Schnitt mit einer anderen Farbe vorgeschlagen wird. Es sind viele Merkmale als Grundlage für die Empfehlung von Alternativen möglich, so kann auch die Nachhaltigkeit eines Produkts verwendet werden. In Bezug auf das Attribut Nachhaltigkeit, besteht die Möglichkeit basierend auf einem bestimmten Produkt eine ähnliche, aber nachhaltige Alternative vorzuschlagen. Dabei sollten die anderen Merkmale, wie Preis oder Farbe, so ähnlich wie möglich sein und sich im besten Fall nur die Nachhaltigkeit unterscheiden. In diesem Fall könnten Vorschläge auch dazu genutzt werden, nicht-nachhaltigkeitsinteressierte Kund:innen dazu anzustoßen, eine nachhaltige Entscheidung zu treffen. Das Produktmerkmal Nachhaltigkeit könnte zudem noch detaillierter spezifiziert werden, in Merkmale wie CO₂-Fußabdruck oder faire Löhne. Beispielsweise können Kund:innen eine besondere Präferenz für einen niedrigen CO₂-Fußabdruck haben, jedoch weniger ausgeprägte Präferenzen hinsichtlich fairer Löhne. In diesem Fall könnte ein Produkt mit niedrigerem CO₂-Fußabdruck vorgeschlagen werden.

III. Relevanz von RS in der Praxis für einen nachhaltigen Online-Konsum

Im Rahmen des Projekts wurden Expertengespräche mit fünf deutschen Online-Händlern im Textilbereich und der E-Commerce-Beratung geführt, um das Potenzial von RS für den nachhaltigen Online-Konsum einzuschätzen. Die Einschätzungen zum Potenzial von RS fielen unterschiedlich aus. Kleinere Händler sahen vor allem die Schwierigkeit in der Umsetzung, da sie oftmals nicht genügend Produkte oder nicht genügend Traffic auf ihren Webseiten haben, um ein RS sinnvoll nutzen zu können. Größere Händler wiederum schätzten das Potenzial der Idee als hoch ein, da oftmals schon RS existieren, und Nachhaltigkeit als weiteres Attribut gut eingebunden werden kann. Grundsätzliche Bedenken waren allerdings oft strategischer Natur, da viele Händler mit Nachhaltigkeitsinformationen zu Produkten bisher nicht offensiv umgehen und deshalb nur den Kund:innen, die bereits ein Interesse an Nachhaltigkeit haben auch nachhaltige Produkte vorschlagen möchten. Eine andere Problematik, die angesprochen wurde, könnte die Priorisierung von Lieferanten sein, wenn RS, die nachhaltigere Substitute vorschlagen, Lieferanten gegeneinander ausspielen. Das Vorschlagen von Komplementärprodukten ist aus Sicht der Händler eher vorstellbar, birgt jedoch aus wissenschaftlicher Sicht auch das Risiko zusätzlichen Konsum anzuregen.

Insgesamt fällt die Experteneinschätzung zum Einsatz von RS zur Förderung positiv aus und es wird als grundsätzlich interessantes Mittel zur Förderung eines nachhaltigen Konsums betrachtet, wenngleich die konkreten Modalitäten der Umsetzung von Fall-zu-Fall beurteilt werden müssen.

IV. Daten

Um selbst ein RS zu implementieren, gibt es verschiedene Möglichkeiten. Im Folgenden wird aufgezeigt, welche Voraussetzungen es an die Daten gibt und wir geben ein paar Beispieldatensätze es aus dem E-Commerce.

A. Anforderungen an die Daten und Format

Voraussetzung für ein RS sind eine große Menge Daten. Für ein Collaborative Filtering System basierend auf Kundendaten können zum Beispiel die sogenannten Sitzungsdaten (Englisch: Session Data) verwendet werden mit der Information welche Nutzer:innen welche Produkte angeklickt, in den Warenkorb gelegt hat oder gekauft haben (siehe Tabelle 1). Hierbei können auch andere Kundeninformationen, wie z. B. das Alter oder Produktbewertungen einbezogen werden. Für Content-based Filtering werden Produktinformationen bzw. spezifische Merkmale benötigt (siehe Tabelle 2). Dabei könnten Nachhaltigkeitsinformationen auch ein Merkmal sein.

	Produkt 1	Produkt 2	Produkt 3	Produkt 4	...
Besucher 1	geklickt		gekauft		
Besucher 2	Warenkorb	geklickt		gekauft	
Besucher 3	geklickt		gekauft		
Besucher 4		Warenkorb		geklickt	
...					

Tabelle 1: Session History

	Produkt 1	Produkt 2	Produkt 3	Produkt 4	...
Preis	5.00	9.99	8.95	7.30	
Marke	Marke A	Marke B	Marke C	Marke D	
Material	Seide	Baumwolle	Baumwolle	Seide	
Siegel	Blauer Engel		OekoTex		
Zahlt Mindestlohn	ja		ja		
...					

Tabelle 2: Produktmerkmale

B. E-Commerce Beispieldatensätze

Falls keine Daten zur Verfügung stehen oder nur Algorithmen verglichen werden sollen, gibt es einige frei verfügbare Beispieldatensätze aus dem E-Commerce, die genutzt werden können. Jedoch enthalten diese Datensätze keine Nachhaltigkeitskriterien. Dieses sind einige Beispiele:

- Philipp Normann, T. W., Sophie Baumeister. (2022 November 1). *OTTO Recommender Systems Dataset: A real-world e-commerce dataset for session-based recommender systems research.*: [Link zum Datensatz](#)
- R. He, J. McAuley (2016). *Ups and downs: Modeling the visual evolution of fashion trends with one-class collaborative filtering.* and J. McAuley, C. Targett, J. Shi, A. van den Hengel (2015). *Image-based recommendations on styles and substitutes.* SIGIR.: [Link zum Datensatz](#)
- Roman Zykov, Noskov Artem, & Anokhin Alexander. (2022). *Retailrocket recommender system dataset* [Data set]. Kaggle.: [Link zum Datensatz](#)

V. Algorithmen

Im Folgenden werden einige bewährte RS-Methoden und deren Nutzung im Online-Handel kurz erklärt und es werden einige Programmierbeispiele gegeben. Dabei wird nur Bezug auf personalisierte Empfehlungen genommen, Algorithmen wie solche zur Empfehlung der beliebtesten Produkte jedoch außer Acht gelassen.

Einfache RS basierend auf Kundendaten nutzen solche Daten, die strukturiert sind wie jene in Tabelle 1, und berechnen die Ähnlichkeit der Reihen, also die Ähnlichkeit der Besucher:innen, oder die Ähnlichkeit der Spalten, also der Produkte, mit einem sogenannten „Similarity Score“. Das wird auch „memory-based“ Collaborative Filtering (CF) genannt (Su & Khoshgoftaar, 2009). Auf Produktebene können die Top Produkte, die nach Nutzerinteraktion am ähnlichsten sind als Empfehlung gegeben werden. Auf Nutzerebene können die Produkte von ähnlichen Nutzer:innen vorgeschlagen werden. Weitergehend können die empfohlenen Produkte noch sortiert werden, z. B. nach Gewinnmarge. Für Content-based Filtering funktioniert das genauso, nur dass die Empfehlungen hier auf den Produktmerkmalen basieren, statt den Kundeninteraktionen.

Nachteil davon, den Similarity Score für jeden Besucher mit jedem anderen Besucher zu berechnen ist, dass die Berechnung sehr aufwändig ist.. Bei der Anwendung von Content-based Filtering ist der Rechenaufwand zwar durch die Anzahl der Produkte im Shop begrenzt, aber bei einem großen Angebot kann das auch ressourcenaufwändig werden. Deshalb wird neben den „memory-based“ CF Methoden, häufig modellbasiertes CF genutzt (Su & Khoshgoftaar, 2009). Ein simpler Algorithmus dafür ist die sogenannte Matrix Faktorisierung. Dabei wird eine Matrix, in diesem Falle die Kunden-Produkt Matrix, in zwei oder mehr kleinere Matrizen zerlegt, die multipliziert wieder ungefähr die ursprüngliche Matrix ergeben. So wird die Dimension der ursprünglichen Matrix reduziert und der Algorithmus muss nur auf einer der reduzierten Matrizen berechnet werden. Das spart Rechenaufwand. (Zhang et al., 2023)

Die modelbasierten CF Methoden lassen sich auch mit Neuronalen Netzen erweitern. Dabei können dann auch noch weitere Daten miteinbezogen werden. Diese Methoden können auch wieder für Content-based Filtering angewandt werden. Eine gute Übersicht über die RS-Methoden, die auf Neuronalen Netzen basieren, findet sich in (Zhang et al., 2019).

Im Folgenden werden Beispielcodes in Python gegeben für produktbasiertes CF mithilfe der Cosinus-Ähnlichkeit zwischen den Produkten oder alternativ die Korrelation der Produkte. Das gleiche wird auch einmal für das kundenbasiertes CF gezeigt. Zwei Python-Pakete, die verschiedene RS-Algorithmen implementieren sind CaseRecommender ¹und TorchRec².

¹ <https://github.com/caserec/CaseRecommender>

² <https://pytorch.org/torchrec/>

VI. Code Beispiele

A. Produktbasiertes Collaborative Filtering: Cosinus-Ähnlichkeit und Korrelation

```
# Bibliotheken importieren
import pandas as pd
from sklearn.metrics.pairwise import cosine_similarity
import numpy as np

# Datensatz: die „events.csv“ Datei von „Retailrocket recommender system
dataset“ (siehe oben)

# Daten einlesen
df = pd.read_csv('events.csv')

# überflüssige Spalten löschen
df = df.drop(columns = ['transactionid', 'timestamp'])

# events zu Zahlen konvertieren
df['event'] = df['event'].factorize()[0]

# die Besucher-Produkt-Matrix erstellen
df_pivot = df.pivot_table(index='itemid', columns='visitorid', values='event').fillna(0)

# Similarity berechnen und Spalten und Reihen nach itemids benennen
similarity_matrix = pd.DataFrame(cosine_similarity(df_pivot))
similarity_matrix.index = df_pivot.index
similarity_matrix.columns = df_pivot.index

# Für ein bestimmtes Produkt die Top 9 Empfehlungen erhalten
item_id = 546
score = list(enumerate(similarity_matrix[item_id]))
recommendations = sorted(score, key=lambda x:x[1], reverse= True)[1:10]
print(recommendations)

# Alternativ zur Cosine Similarity kann auch die Correlation berechnet werden
correlation_matrix = df_pivot.corr()

# Für ein bestimmtes Produkt Empfehlungen erhalten
score = correlation_matrix.loc[item_id].dropna()
recommendations = score.sort_values(ascending=False)
print(recommendations)
```

B. Kundenbasiertes Collaborative Filtering: Cosinus-Ähnlichkeit und Korrelation

```
# Bibliotheken importieren
import pandas as pd
from sklearn.metrics.pairwise import cosine_similarity
import numpy as np

# Datensatz: die „events.csv“ Datei von „Retailrocket recommender system
dataset“ (siehe oben)

# Daten einlesen
df = pd.read_csv('events.csv')

# überflüssige Spalten löschen
df = df.drop(columns = ['transactionid', 'timestamp'])

# events zu Zahlen konvertieren
df['event'] = df['event'].factorize()[0]

# die Besucher-Produkt-Matrix erstellen (itemid und visotruid sind diesmal
andersrum)
df_pivot = df.pivot_table(index='visitorid', columns='itemid', val-
ues='event').fillna(0)

# Simialrity berechnen und Spalten und Reihen nach itemids benennen
similarity_matrix = pd.DataFrame(cosine_similarity(df_pivot))
similarity_matrix.index = df_pivot.index
similarity_matrix.columns = df_pivot.index

# Für einen bestimmten Besucher Empfehlungen erhalten
visitor_id = 1185
score = similarity_matrix.loc[visitor_id].sort_values(ascend-
ing=False).head(5)

# Alle Produkte für die 5 ähnlichsten Besucher erhalten
similar_visitors_items = df[df['visitorid'].isin(score.in-
dex)][['itemid']].unique()

# Alle Produkte des Besuchers erhalten
visitor_items = df[df['visitorid']==visitor_id]['itemid'].unique()

# Die Produkte des Besuchers von den Produkten der ähnlichen Besucher sub-
trahieren und die Differenz als Empfehlungen ausgeben
recommendations = set(similar_visitors_items) - set(visitor_items)
print(recommendations)

# Alternativ kann die Correlation berechnet werden
correlation_matrix = df_pivot.corr()

# Für einen bestimmten Besucher die Empfehlungen erhalten
score = similarity_matrix.loc[visitor_id].sort_values(ascend-
ing=False).head(5)

# Genau wie oben
similar_visitors_items = df[df['visitorid'].isin(score.index)][['item-
id']].unique()
visitor_items = df[df['visitorid']==visitor_id]['itemid'].unique()
recommendations = set(similar_visitors_items) - set(visitor_items)
print(recommendations)
```

VII. Weiterführende Literatur

RS sind ein offenes Forschungsfeld. Interessierte Leser:innen, können sich auf die Übersichtsarbeiten von (Lü et al., 2012) und (Beel et al., 2016) beziehen, um sich einen allgemeinen Überblick über das Feld zu verschaffen. Bei Interesse an aktuellen Deep Learning Methoden, sind die Übersichtsarbeiten zu Deep Learning zu RS von (S. Zhang et al., 2019) und (Li et al., 2023) empfehlenswert.

Des Weiteren können Kund:innen und deren Kaufpräferenzen gut als Graphen dargestellt werden, daher können graphbasierte Methoden hier sinnvoll zum Einsatz kommen. Konkreter können die Arbeiten von (Guo et al., 2022) zu Knowledge Graph basierten RS und (Wu et al., 2022) zu Graph Neural Networks für RS gute Hinweise bieten. RS im E-Commerce als Digital Nudging wird von (Jesse & Jannach, 2021) besprochen. In Bezug auf digital Nudging mit RS, um nachhaltigere Kaufentscheidungen anzuregen haben (De Bauw et al., 2022) einen Artikel veröffentlicht. Interessant ist auch die Arbeit von (Jannach et al., 2021) die sich mit sprachbasierten RS beschäftigt.

VIII. Mechanismen für eine nachhaltigere KI

Seit einigen Jahren wird im Kontext der Künstlichen Intelligenz vermehrt auch der Faktor Ressourcenverbrauch betrachtet, denn der Energieverbrauch für den Betrieb komplexer KI-Modelle ist immens³. Aus diesem Grund sollten KI-Modelle nicht nur auf eine gute Vorhersagegenauigkeit optimiert werden, sondern auch darauf, möglichst wenig Ressourcen zu verbrauchen. Das Forschungsfeld, das sich mit solchen Fragestellungen beschäftigt, nennt sich Green AI (Schwartz et al., 2020). Insbesondere das Training einer KI verbraucht viel Energie, aber auch der Einsatz von KI.

Es gibt viele Methoden, um ein Modell effizienter zu machen. Dafür können zum Beispiel kleine Netzwerkarchitekturen genutzt werden, die an sich weniger rechenintensiv sind. Des Weiteren können Mechanismen während des Trainings genutzt werden, wie zum Beispiel das „Early Stopping“, welches das Training frühzeitig beendet, wenn die Performance sich nicht verbessert, oder „Mixed Precision“, welches teilweise mit 16 statt 32 Bit rechnet, um Rechenaufwand einzusparen. Außerdem gibt es Methoden, die eingesetzt werden können, nachdem ein Modell fertig trainiert ist, z. B. „Model Compression“ oder „Model Pruning“, welche nichtgenutzten Teile aus dem Model weglässt. Aber auch bei der Auswahl der Hardware sollte auf den CO₂-Verbrauch geachtet werden. Das Cluster, auf dem die Modelle trainiert werden, und auch der Server, auf dem sie laufen, sollten bestenfalls mit erneuerbaren Energien betrieben werden. Wenn neue Daten vorliegen, sollte abgewogen werden, ob es sich das Re-Trainieren aus Sicht der Energieeffizienz lohnt, oder ob das bestehende Modell ausreichend ist (Kuo & Madni, 2023; Verdecchia et al., 2023).

Im Kontext von RS sind die Ressourcenverbräuche stark abhängig davon, für welche Methode sich entschieden wird. Bei der Auswahl der Methode sollte neben den verfügbaren Daten und der Vorhersagegenauigkeit auch darauf geachtet werden, wie hoch der Energieverbrauch der jeweiligen Methode ist und ob es möglich ist, diesen durch die erwähnten Green AI-Methoden zu senken. Beispielsweise ist die Matrix Faktorisierung bereits eine Methode, die durch die Dimensionalitätsreduktion den Rechenaufwand verringert. Um den Ressourcenaufwand von KI zu messen, kann als einfacher Indikator die Zeit genommen werden. Es gibt aber auch Tools, die den tatsächlichen Energieverbrauch und die CO₂ Äquivalente abzuschätzen, z. B. CodeCarbon (Lacoste et al., 2019; Luccioni & Hernandez-Garcia, 2023).

³ <https://www.mdr.de/wissen/kuenstliche-intelligenz-experte-warnt-vor-hohem-stromverbrauch-100.html>

IX. Ethische, soziale und rechtliche Folgen von Recommender Systems

A. Relevanz der ELSI-Kriterien im Kontext der Algorithmus-/KI-Entwicklung

Technologische Neuerungen können nicht nur auf ihren technischen oder ökonomischen Nutzen beschränkt werden. So gewinnt die ganzheitliche Betrachtung der Folgen von Technologie für die Gesellschaft an Bedeutung. In diesem Sinne entstanden im Zuge des Human Genome Projects und der Auseinandersetzung mit ethischen, rechtlichen und sozialen Auswirkungen der Gen- und Genomforschung die sogenannten ELSI-Kriterien (siehe Yesley, 1993). ELSI ist die Abkürzung für „Ethical, Legal and Social Issues“, was übersetzt so viel bedeutet wie ethische, rechtliche und soziale Fragen oder Belange.

Im Laufe der Zeit haben die drei Kriterien auch in anderen Bereichen an Relevanz zugenommen, wie z. B. im Rahmen von Big Data (Tractenberg, 2016), künstlicher Intelligenz (Özdemir & Hekim, 2018) oder anderen Technologien (Greenbaum, 2015). Die nicht-trennbare Verknüpfung und Wechselwirkung von ethischen, rechtlichen und sozialen Dimensionen, wie in Boden et al. (2018) herausgestellt, unterstreicht die Notwendigkeit einer ganzheitlichen Betrachtung der ELSI-Kriterien bei der Anwendung und Umsetzung von Technologien sowie Forschungsergebnissen.

Im spezifischen Kontext der Entwicklung und des Einsatzes von Algorithmen und KI, einschließlich RS auf der Basis von Collaborative Filtering und Content-based Filtering, gewinnen die ELSI-Kriterien ebenfalls an Bedeutung. Die Systeme benötigen umfangreiche Datensätze, die nicht nur Informationen über das Kaufverhalten und die Demographie der Kund:innen enthalten, sondern auch sensible Daten, die tiefe Einblicke in persönliche Präferenzen und Verhaltensweisen erlauben (Mühlhoff, 2021). Die damit verbundenen Konsequenzen sind vielfältig und umfassen die Verbreitung unangemessener Inhalte, die Verletzung der Privatsphäre, die Bedrohung der individuellen Autonomie sowie der persönlichen Identität, die Intransparenz der Systeme und Fragen der Fairness (Milano et al., 2020).

Die Antizipation dieser Herausforderungen in der Entwicklungsphase von IT-Systemen stellt eine signifikante Herausforderung dar, da viele der mit den ELSI-Kriterien assoziierten Aspekte oft erst in der praktischen Anwendung und im dynamischen Zusammenspiel zwischen Menschen, Technologie und dem jeweiligen Kontext vollständig erkennbar werden (Introna & Wood, 2004). Dies betont die Notwendigkeit einer proaktiven und kontinuierlichen Auseinandersetzung mit diesen Kriterien durch alle Beteiligten aus Forschung, Entwicklung und Anwendung sowie durch regulierende Instanzen.

B. Anwendung von ELSI-Kriterien für die zukünftige Entwicklung von Recommender Systems

Die ELSI-Kriterien (ethische, soziale und legale Dimensionen) sind von hoher Bedeutung für die Gestaltung und den Einsatz von RS. Vor dem Hintergrund der Bewertung nach ELSI-Kriterien werfen die Systeme, die darauf abzielen, Nutzer:innen personalisierte Empfehlungen zu bieten, wichtige Fragen auf. Diese Fragen müssen vor der Ableitung von Empfehlungen für die Entwicklung und Nutzung von ELSI-konformen RS adressiert werden.

Ethische Dimensionen von RS umfassen den Umgang mit Nutzerdaten in Bezug auf Privatsphäre, Transparenz und Fairness. Es besteht Potenzial für Voreingenommenheit und Diskriminierung, die sich aus den verwendeten Daten, den Algorithmen oder den Nutzer:innen selbst ergeben (Färber et al., 2023). Entscheidend sind zum einen demografische Ungleichgewichte in den Daten, da die dem System zur Verfügung stehenden Daten bestehende soziale Muster widerspiegeln, die eine

Verzerrung gegenüber bestimmten Gruppen ausdrücken können (Farnadi et al., 2018). Wenn ein Algorithmus auf Basis verzerrter Daten trainiert wird, kann er diese Verzerrungen sogar weiter verstärken und institutionalisieren. Im schlimmsten Fall kann dies zu systematischen Fehlentscheidungen führen, z. B. bei der Kreditvergabe, der Jobsuche oder bei juristischen Entscheidungen. So könnte ein Bewerbungssystem, das keine angemessenen Daten über bestimmte Bewerbergruppen besitzt, systematisch deren Bewerbungen niedriger einstufen, weil es deren Qualifikationen und Erfahrungen nicht korrekt bewerten kann. Neben demografischen Ungleichgewichten in den Daten ist der sogenannte Beobachtungsbias zu beachten, der sich aus Rückkopplungsschleifen ergibt, die durch Empfehlungen des Systems an bestimmte Nutzergruppen entstehen. Diese potenziellen Quellen von Verzerrungen unterstreichen die Notwendigkeit, Fairness und Erklärbarkeit in den Algorithmen zu gewährleisten (Friedman et al., 2015; Koene). Um eine ethisch fundierte Gestaltung von algorithmischen Systemen sicherzustellen, ist es entscheidend, ein breites Spektrum an Interessen und potenziellen Risiken zu berücksichtigen, die sich für unterschiedliche Stakeholder ergeben können. Dies umfasst nicht nur die direkten Nutzer:innen dieser Systeme, sondern auch die Anbieter:innen, sowie die breitere Gesellschaft. Konkret kann dies durch verschiedene Maßnahmen erreicht werden, z. B. die Einbindung von Stakeholder-Gruppen in den Entwicklungsprozess, die Entwicklung ethischer Richtlinien für die Praxis, die Etablierung von Mechanismen zur kontinuierlichen Überwachung und Anpassung oder die Förderung der Transparenz und des öffentlichen Diskurses.

- ! **Handlungsempfehlung:** Für einen möglichst ethischen Einsatz von RS muss sichergestellt werden, dass Kund:innen über die Nutzung ihrer Daten im Rahmen von RS informiert sind und die Möglichkeit, ihre Zustimmung zu erteilen oder zu verweigern, besitzen. Zudem sollten diskriminierende oder manipulative Empfehlungen, die auf Verzerrungen zurückzuführen sind, vermieden werden, z. B. durch den Einsatz von Algorithmen, die auf Fairness und Anti-Diskriminierung ausgelegt sind, oder durch die Diversifizierung der Datenbasis mit vielfältigen und repräsentativen Daten.

Legale Dimensionen beim Einsatz von RS erfordern in erster Linie die konsequente Einhaltung relevanter Datenschutzgesetze und -vorschriften, z. B. der Datenschutz-Grundverordnung (DSGVO) oder der Digital Services Act (DSA). Diese Gesetzgebungen definieren Anforderungen an den Schutz personenbezogener Daten und die Gestaltung von RS. Ziel ist es, die Rechte der Verbraucher:innen zu wahren und die Anwendung manipulativer Techniken, die zum Kauf bestimmter Produkte verleiten, zu unterbinden (Sartor et al., 2020). Auch wird gesteigerte Transparenz der betreffenden Systeme angestrebt und es soll ermöglicht werden, dass Nutzer:innen eine erhöhte Kontrolle über ihre persönlichen Daten haben (Goddard, 2017).

Insbesondere legt Artikel 70 des DSA fest, dass Online-Plattformen ihre Nutzer:innen umfassend über die Funktionsweisen und Auswirkungen ihrer Empfehlungssysteme aufklären müssen (DSA, 2022, Art. 70, S.19). Dies schließt eine offene Darlegung der maßgeblichen Parameter und Hauptkriterien ein, welche die Darstellung und Priorisierung von Informationen steuern, unter besonderer Berücksichtigung des Profilings und des Online-Verhaltens. RS, die auf undurchsichtige Weise operieren und gezielt auf Entscheidungsschwächen der Nutzer:innen ausgerichtet sind, könnten die selbstbestimmte Entscheidungsfindung gefährden und bedürfen daher einer rechtlichen Regulierung zum Schutz der individuellen Autonomie (Grise, 2023).

- ! **Handlungsempfehlung:** Für einen legal abgesicherten Einsatz von RS sollten die Daten der Nutzer:innen sicher verarbeitet und geschützt werden, und es sollten klare Regeln für die Verwendung der Daten festgelegt werden. Zudem sollte es ausgeschlossen sein, dass mit Empfehlungen für Kund:innen Produkte oder Inhalte beworben werden, die gegen geltendes Recht verstoßen.

Soziale Dimensionen betrachten die Auswirkungen von RS auf Individuen und die Gesellschaft. Autonomie, Privatsphäre, Vertrauen und das Wohlbefinden der Nutzer:innen stehen dabei im Zentrum dieser Überlegungen. RS im Online-Handel können unbeabsichtigt zu einer Einschränkung der Informations- und Produktvielfalt führen, indem sie Nutzer:innen überwiegend Angebote präsentieren, die ihre bereits vorhandenen Vorlieben spiegeln (Elahi et al., 2022; Färber et al., 2023). Die sozialen Auswirkungen der Datenverarbeitung durch RS betreffen auch die gesellschaftliche Wahrnehmung von Privatsphäre, die Entstehung neuer Machtverhältnisse durch Datenkontrolle und deren Effekte auf soziale Gerechtigkeit. Diese Dynamiken beeinflussen, wie Privatsphäre gesellschaftlich verstanden wird und unterstreichen die Bedeutung des Vertrauens der Nutzer:innen in solche Systeme (Yang, 2018). Zudem sind negative soziale oder gesundheitliche Auswirkungen, z. B. durch die Verstärkung von Vorurteilen oder Suchtverhalten, zu vermeiden (Elahi et al., 2022).

- ! **Handlungsempfehlung:** Um den negativen Effekten der eingeschränkten Informations- und Produktvielfalt entgegenzuwirken, sollten RS im Online-Handel gezielt diversifizierte Empfehlungen bieten, die über die bisherigen Präferenzen der Nutzer:innen hinausgehen. Dies kann durch die Integration von Diversitätsmaßen in Algorithmen, transparente Personalisierungspraktiken und die Bereitstellung von Explorationsmöglichkeiten erreicht werden.

Zusammenfassend zeigt sich, dass die Berücksichtigung der ELSI-Kriterien in der Algorithmen- und KI-Entwicklung, z. B. für RS, nicht nur eine Frage der ethischen Verantwortung ist, sondern auch ein entscheidender Faktor für die soziale Akzeptanz, die gesetzliche Legitimität und den langfristigen Erfolg technologischer Innovationen. Eine umfassende und vorausschauende Auseinandersetzung mit diesen Themen trägt dazu bei, Risiken zu minimieren und gleichzeitig das Potenzial der Technologie zum Wohle der Gesellschaft zu maximieren. Die Evaluation eines konkreten RS hinsichtlich der ELSI-Kriterien bedarf einer Multi-Stakeholder-Analyse, um die Interessen und Bedürfnisse aller an der Funktionsweise beteiligten Akteure zu verstehen und mögliche Risiken des Systems, aber auch unentdeckte Potentiale für eine oder mehrere Stakeholder-Gruppen sowie für die Gesellschaft im Allgemeinen aufzuzeigen.

Literaturverzeichnis

- Beel, J., Gipp, B., Langer, S., & Breiting, C. (2016). Research-paper recommender systems: A literature survey. *International Journal on Digital Libraries*, 17(4), 305–338. <https://doi.org/10.1007/s00799-015-0156-0>
- Boden, A., Liegl, M., & Büscher, M. (2018). Ethische, rechtliche und soziale Implikationen (ELSI). In C. Reuter (Ed.), *Sicherheitskritische Mensch-Computer-Interaktion* (pp. 163–182). Springer Fachmedien Wiesbaden. https://doi.org/10.1007/978-3-658-19523-6_9
- Burke, R. (2017). *Multisided Fairness for Recommendation*. <https://doi.org/10.48550/ARXIV.1707.00093>
- De Bauw, M., De La Revilla, L. S., Poppe, V., Matthys, C., & Vranken, L. (2022). Digital nudges to stimulate healthy and pro-environmental food choices in E-groceries. *Appetite*, 172, 105971. <https://doi.org/10.1016/j.appet.2022.105971>
- Elahi, M., Jannach, D., Skjærven, L., Knudsen, E., Sjøvaag, H., Tolonen, K., Holmstad, Ø., Pipkin, I., Thronsen, E., Stenbom, A., Fiskerud, E., Oesch, A., Vredenberg, L., & Trattner, C. (2022). Towards responsible media recommendation. *AI and Ethics*, 2(1), 103–114. <https://doi.org/10.1007/s43681-021-00107-7>
- Färber, M., Coutinho, M., & Yuan, S. (2023). *Biases in Scholarly Recommender Systems: Impact, Prevalence, and Mitigation*. <https://doi.org/10.48550/ARXIV.2301.07483>
- Farnadi, G., Tang, J., De Cock, M., & Moens, M.-F. (2018). User Profiling through Deep Multimodal Fusion. *Proceedings of the Eleventh ACM International Conference on Web Search and Data Mining*, 171–179. <https://doi.org/10.1145/3159652.3159691>
- Friedman, A., Knijnenburg, B. P., Vanhecke, K., Martens, L., & Berkovsky, S. (2015). Privacy Aspects of Recommender Systems. In F. Ricci, L. Rokach, & B. Shapira (Eds.), *Recommender Systems Handbook* (pp. 649–688). Springer US. https://doi.org/10.1007/978-1-4899-7637-6_19
- Goddard, M. (2017). The EU General Data Protection Regulation (GDPR): European Regulation that has a Global Impact. *International Journal of Market Research*, 59(6), 703–705. <https://doi.org/10.2501/IJMR-2017-050>
- Goldberg, D., Nichols, D., Oki, B. M., & Terry, D. (1992). Using collaborative filtering to weave an information tapestry. *Communications of the ACM*, 35(12), 61–71.
- Greenbaum, D. (2015). Expanding ELSI to all areas of innovative science and technology. *Nature Biotechnology*, 33(4), 425–426. <https://doi.org/10.1038/nbt.3193>
- Grise, K. (2023). Recommender Systems, Manipulation and Private Autonomy: How European Civil Law Regulates and Should Regulate Recommender Systems for the Benefit of Private Autonomy. In S. Genovesi, K. Kaesling, & S. Robbins (Eds.), *Recommender Systems: Legal and Ethical Issues* (Vol. 40, pp. 101–128). Springer International Publishing. https://doi.org/10.1007/978-3-031-34804-4_6
- Guo, Q., Zhuang, F., Qin, C., Zhu, H., Xie, X., Xiong, H., & He, Q. (2022). A Survey on Knowledge Graph-Based Recommender Systems. *IEEE Transactions on Knowledge and Data Engineering*, 34(8), 3549–3568. <https://doi.org/10.1109/TKDE.2020.3028705>
- Introna, L., & Wood, D. (2004). Picturing algorithmic surveillance: The politics of facial recognition systems. *Surveillance & Society*, 2(2/3), 177–198. <https://doi.org/10.1.1.117.7338&rep=rep1&type=pdf>
- Jannach, D., Manzoor, A., Cai, W., & Chen, L. (2021). A Survey on Conversational Recommender Systems. *ACM Computing Surveys*, 54(5), 105:1-105:36. <https://doi.org/10.1145/3453154>
- Jesse, M., & Jannach, D. (2021). Digital nudging with recommender systems: Survey and future directions. *Computers in Human Behavior Reports*, 3, 100052. <https://doi.org/10.1016/j.chbr.2020.100052>
- Koene, A., Perez, E., Carter, C. J., Statache, R., Adolphs, S., O'Malley, C., Rodden, T., & McAuley, D. (2015). Ethics of Personalized Information Filtering. In T. Tiropanis, A. Vakali, L. Sartori, & P.

- Burnap (Eds.), *Internet Science* (Vol. 9089, pp. 123–132). Springer International Publishing. https://doi.org/10.1007/978-3-319-18609-2_10
- Kuo, C.-C. J., & Madni, A. M. (2023). Green learning: Introduction, examples and outlook. *Journal of Visual Communication and Image Representation*, 90, 103685. <https://doi.org/10.1016/j.jvcir.2022.103685>
- Lacoste, A., Luccioni, A., Schmidt, V., & Dandres, T. (2019). *Quantifying the Carbon Emissions of Machine Learning* (arXiv:1910.09700). arXiv. <https://doi.org/10.48550/arXiv.1910.09700>
- Li, Y., Liu, K., Satapathy, R., Wang, S., & Cambria, E. (2023). *Recent Developments in Recommender Systems: A Survey* (arXiv:2306.12680). arXiv. <https://doi.org/10.48550/arXiv.2306.12680>
- Lü, L., Medo, M., Yeung, C. H., Zhang, Y.-C., Zhang, Z.-K., & Zhou, T. (2012). Recommender systems. *Physics Reports*, 519(1), 1–49. <https://doi.org/10.1016/j.physrep.2012.02.006>
- Luccioni, A. S., & Hernandez-Garcia, A. (2023). *Counting Carbon: A Survey of Factors Influencing the Emissions of Machine Learning* (arXiv:2302.08476; Version 1). arXiv. <http://arxiv.org/abs/2302.08476>
- Milano, S., Taddeo, M., & Floridi, L. (2020). Recommender systems and their ethical challenges. *AI & SOCIETY*, 35(4), 957–967. <https://doi.org/10.1007/s00146-020-00950-y>
- Mühlhoff, R. (2021). Predictive privacy: Towards an applied ethics of data analytics. *Ethics and Information Technology*, 23(4), 675–690. <https://doi.org/10.1007/s10676-021-09606-x>
- Özdemir, V., & Hekim, N. (2018). Birth of Industry 5.0: Making Sense of Big Data with Artificial Intelligence, “The Internet of Things” and Next-Generation Technology Policy. *OMICS: A Journal of Integrative Biology*, 22(1), 65–76. <https://doi.org/10.1089/omi.2017.0194>
- Sartor, P. G., Maciejewski, M., & Ratcliff, C. E. M. (2020). *New aspects and challenges in consumer protection Digital services and artificial intelligence*. <https://www.semanticscholar.org/paper/New-aspects-and-challenges-in-consumer-protection-Sartor-Maciejewski/0b467995243b7839beb66a0d2e79e283cf1d1f76>
- Schwartz, R., Dodge, J., Smith, N. A., & Etzioni, O. (2020). Green AI. *Communications of the ACM*, 63(12), 54–63. <https://doi.org/10.1145/3381831>
- Su, X., & Khoshgoftaar, T. M. (2009). A survey of collaborative filtering techniques. *Advances in Artificial Intelligence*.
- Tractenberg, R. E. (2016). Creating a Culture of Ethics in Biomedical Big Data: Adapting ‘Guidelines for Professional Practice’ to Promote Ethical Use and Research Practice. In B. D. Mittelstadt & L. Floridi (Eds.), *The Ethics of Biomedical Big Data* (Vol. 29, pp. 367–393). Springer International Publishing. https://doi.org/10.1007/978-3-319-33525-4_16
- Verdecchia, R., Sallou, J., & Cruz, L. (2023). A systematic review of Green AI. *WIREs Data Mining and Knowledge Discovery*, 13(4), e1507. <https://doi.org/10.1002/widm.1507>
- Verordnung (EU) 2022/2065 des Europäischen Parlaments und des Rates vom 19. Oktober 2022 über einen Binnenmarkt für digitale Dienste und zur Änderung der Richtlinie 2000/31/EG (Gesetz über digitale Dienste), 277 OJ L (2022). <http://data.europa.eu/eli/reg/2022/2065/oj/deu>
- Wu, S., Sun, F., Zhang, W., Xie, X., & Cui, B. (2022). Graph Neural Networks in Recommender Systems: A Survey. *ACM Computing Surveys*, 55(5), 97:1-97:37. <https://doi.org/10.1145/3535101>
- Yang, X. (2018). Influence of informational factors on purchase intention in social recommender systems. *Online Information Review*, 44(2), 417–431. <https://doi.org/10.1108/OIR-12-2016-0360>
- Yesley, M. S. (1993). *ELSI Bibliography: Ethical legal and social implications of the Human Genome Project* (DOE/ER--0591, 10108311; p. DOE/ER--0591, 10108311). <https://doi.org/10.2172/10108311>
- Zhang, A., Lipton, Z. C., Li, M., & Smola, A. J. (2023). *Dive into Deep Learning*. Cambridge University Press.
- Zhang, S., Yao, L., Sun, A., & Tay, Y. (2019). Deep Learning Based Recommender System: A Survey and New Perspectives. *ACM Computing Surveys*, 52(1), 5:1-5:38. <https://doi.org/10.1145/3285029>