

Mensch-Maschine-Kooperation bei der Produktpersonalisierung mit Single Pass Bayesian Reasoning

Manfred DANGELMAIER¹, Katharina HÖLZLE¹, Sabine KRIEG², Erwin GROSS³

¹ *Institut für Arbeitswissenschaft und Technologiemanagement, Universität Stuttgart,
Nobelstr. 12, D-70569 Stuttgart*

² *Fraunhofer IGB,
Nobelstr. 12, D-70569 Stuttgart*

³ *Fraunhofer IPA,
Nobelstr. 12, D-70569 Stuttgart*

Kurzfassung: Bei der Personalisierung von Produkten entlasten nutzerdatenverarbeitende Algorithmen die Kunden von der Qual der Wahl. Die Empfehlungen sind meist probabilistisch. Das idealtypische Single Pass Bayesian Reasoning (SPBR) wird dafür als Algorithmus vorgeschlagen. Dabei muss die probabilistische Natur der Ergebnisse den Nutzenden vermittelt werden, um informierte Entscheidungen zu ermöglichen. Hierfür wird am Beispiel der Personalisierung von Schuhen eine angemessene Interaktion mit Nutzenden anhand von Eignungswahrscheinlichkeiten der Ausprägungen von Produktmerkmalen gezeigt. Die Generalisierbarkeit auf andere Klassen probabilistischer Algorithmen bleibt nachzuweisen, ebenso die korrekte Interpretation und Akzeptanz.

Schlüsselwörter: Mensch-Maschine-Interaktion, KI, Personalisierung, Produktsysteme, Bayessches Theorem

1. Kooperative Produktpersonalisierung

Der Megatrend zur Individualisierung macht auch vor dem Markt und seinen Produkten nicht Halt. Mass Customization bzw. Mass Personalization stellt dem Kunden bzw. der Nutzerin ein maßgeschneidertes Produkt aus der Massenproduktion zur Verfügung (Piller 2006; Bauernhansl et al. 2023). Hierzu verwendet man Produktkonfiguratoren. Die Konfiguration durch den Kunden selbst bedingt bei einer hohen Zahl konfigurierbarer Produktmerkmale und Ausprägungen eine hohe Belastung durch eine Vielzahl von Entscheidungen. Deshalb greift man in Recommendersystemen auf Nutzermodelle und -daten zurück, um mittels Algorithmen geeignete Produktvorschläge anzubieten. Dieser Vorgang ist oft probabilistisch, da nicht alle optimalen Ausprägungen als Funktion der verfügbaren Nutzerdaten deterministisch darstellbar sind. Die Algorithmen empfehlen nur wahrscheinlich geeignete Ausprägungen von Produktmerkmalen. Nicht zuletzt deshalb müssen Kunden als Entscheidende in selbstbestimmtem Umfang in die Konfiguration einbezogen werden. Das kann von der bloßen Kaufentscheidung auf die Empfehlung des Algorithmus hin bis zur vollständig manuellen Konfiguration reichen. Zumindest verfolgt das Stuttgarter Modell für die personalisierte Produktentstehung diesen radikal nutzerzentrierten Ansatz. Dieses im Leistungszentrum Mass Personalization (Held et al. 2018) entstandene Modell (siehe Abbildung 1) wurde bereits mehrfach beschrieben und an verschiedene Anwendungsfälle

angepasst (Hämmerl & Dangelmaier 2018; Briem et al. 2022). Wie die Mensch-Maschine-Kooperation dabei gestaltet werden soll, wurde durch das Modell bislang noch nicht festgelegt.

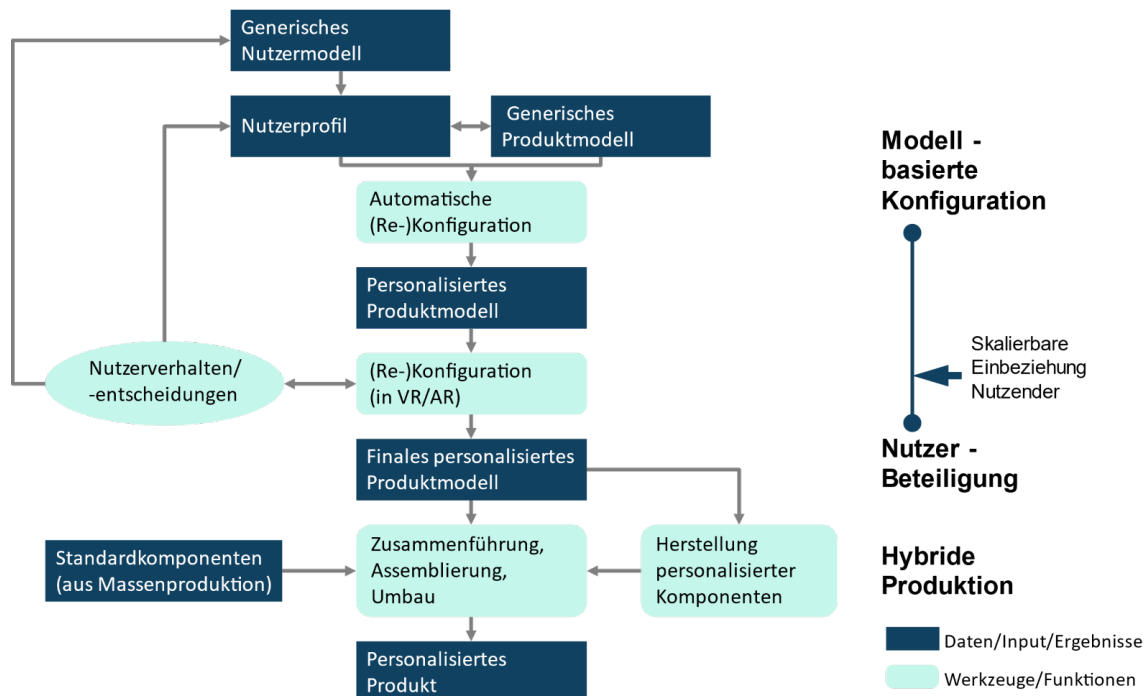


Abbildung 1: Stuttgarter Modell der personalisierten Produktentstehung

Wir suchen daher nach einem Algorithmus für die kooperative Personalisierung, der vom Menschen verstanden wird und von einem probabilistischen digitalen Konfigurator ausführbar ist.

2. Interaktion mit probabilistischen Assistenzsystemen

Durch die Fortschritte im Bereich der lernenden Systeme bzw. der künstlichen Intelligenz (KI) stellt sich generell die Frage, wie Mensch und Maschine künftig zusammenarbeiten. Eine derzeit im Raum stehende Antwort für eine anzustrebende Zukunft ist: durch natürliche Sprache (Groß et al. 2020). Der Mensch redet bzw. chattet mit der Maschine wie mit einem Menschen. Eine auf dem Stand der Technik beruhende Antwort ist: über eine grafische Benutzungsschnittstelle (GUI), die sich durch KI dynamischer und adaptiver verhält als bisher.

Beide Modalitäten erzeugen beim Menschen kein adäquates mentales Modell über die probabilistische Natur der Algorithmen. Natürliche Sprachinteraktion befördert das Modell eines menschlichen Gegenübers. Eine adaptive GUI vermittelt den Eindruck einer unvorhersehbar und willkürlich agierenden Maschine. Beides ist falsch. Ein angemessenes Modell für viele Anwendungen ist das des probabilistischen Entscheidungsassistenten. Man kann ein angemessenes mentales Modell für solche Systeme wie folgt charakterisieren:

- Probabilistische Assistenzsysteme sind mit Unsicherheit behaftet.
- Ihre Ergebnisse sind als Empfehlungen zu verstehen.

- Die Nutzenden entscheiden und tragen dafür die Verantwortung.

Für optimale Entscheidungen muss das System dem Menschen den Grad der Unsicherheit bzw. des Risikos auf der Grundlage der genutzten Daten mitteilen. Dies geschieht durch Verwendung einer probabilistischen Sprache. Wenn die Maschine eine Wahrscheinlichkeit von 90 % angibt, verstehen die Nutzenden, dass sie sich nur zu 90 % sicher sein können. Wenn die Chancen für die Eignung einer Alternative 10:3 stehen, dann assoziiert man damit ebenfalls ein gewisses Maß von Gewissheit oder Ungewissheit. Die Interaktion seitens der Maschine muss klarmachen, dass es um Wahrscheinlichkeiten oder Chancenverhältnisse geht und wie hoch diese sind.

3. Anforderungen an einen kooperativen Konfigurator

Die Aufgabe eines Recommendersystems ist es, für ein Produktsystem verfügbare Nutzerdaten und Präferenzen zu verwenden, um die beste Kombination von Ausprägungen von Merkmalen eines Produkts für die Nutzenden zu finden. Wir suchen also nach der Produktvariante, die mit höchster Wahrscheinlichkeit zum Nutzenden passt oder die Kaufentscheidung mit höchster Wahrscheinlichkeit prognostiziert. Wir nennen solche Wahrscheinlichkeiten Präferabilitäten oder, für Nutzende verständlicher, Eignungswahrscheinlichkeiten.

Die Konfiguration soll möglichst effizient sein. Der Algorithmus soll für Mensch und Maschinen geeignet sein. Er soll für den Menschen verständlich und nachvollziehbar sein und von Maschinen auf der Basis vorliegender Daten ausgeführt werden können. Er soll sowohl normative Vorgaben im Sinne von Anforderungen bei Empfehlungen berücksichtigen können als auch subjektive oder kollektive Nutzerpräferenzen. Ferner soll er eine datenbasierte Entscheidungsunterstützung liefern und Empfehlungen auf der Basis von Daten aus Nutzerprofilen und vorausgegangenem Nutzerverhalten ermöglichen.

4. Single Pass Bayesian Reasoning als idealtypischer Algorithmus

Wir betrachten hier den Fall im Wesentlichen unabhängiger konfigurierbarer Produktmerkmale mit diskreten Ausprägungen und voneinander unabhängige Informationen über die Nutzenden für die Produktauswahl.

Hier bietet sich aus der Sicht des Bayesianismus (Bovens et al. 2006; Bartelborth 2017) als Modell das Single Pass Bayesian Reasoning (SPBR) an, das man für Recommendersysteme wie folgt formulieren kann:

Es soll eine Menge von erhobenen Nutzerdaten \mathbf{E} auf Ausprägungen einer Menge von Produktmerkmalen \mathbf{M} abgebildet werden, um sich für die geeignetsten Ausprägungen zu entscheiden. Wir nummerieren die konfigurierbaren Merkmale mit dem Index k . Der Verständlichkeit halber gehen wir zunächst von unabhängigen Produktmerkmalen M_k aus, die an die Nutzenden angepasst werden sollen. Im Falle eines Schuhkaufs können diese Merkmale die Schuhgröße und die Schuhweite sein, das Schuhmodell, das Vorhandensein einer Aussparung für einen Fersensporn oder die Dämpfungseigenschaften der Sohle. Die verschiedenen hypothetisch optimalen Ausprägungen pro Produktmerkmal bezeichnen wir mit dem Index j . Die möglichen Ausprägungen von M_k heißen also H_{kj} . Die dazu jeweils passenden relevanten N_k Informationen bzw. Daten über den Menschen bezeichnen wir mit E_{ki} . Dann ergeben sich die

Wahrscheinlichkeiten $P(H_{kj})$, dass H_{kj} die beste Ausprägung für das Merkmal M_k ist, nach dem Bayesschen Theorem (Laplace 1814; Bayes & Price 1763) in seiner Verhältnisform zu:

$$P(H_{kj}) = \prod_{i=0}^{N_k} \frac{P(E_{ki}|H_{kj})}{P(E_{ki}|\neg H_{kj})} \quad (1)$$

Voraussetzung für die Gültigkeit der Formel aus erkenntnistheoretischer Sicht ist, dass die Nutzerdaten E_{ik} für alle i voneinander unabhängig sind und sich nicht gegenseitig bedingen und dass das alle relevanten Informationen sind, die über die Nutzenden bzw. Kaufenden vorliegen. Außerdem geht man davon aus, dass man sich für alle k Produktmerkmale für genau eine Ausprägung H_{kj} entscheiden muss, sich die H_{kj} also gegenseitig ausschließen.

Die $P(E_{ki}|H_{kj})$ und $P(E_{ki}|\neg H_{kj})$ bezeichnet man als Likelihoods. Ihren Quotienten nennt man Bayesfaktor. Der Bayesfaktor gibt an, wie sehr die Information E_{ki} über die Nutzenden die Eignungswahrscheinlichkeit der Ausprägung H_{kj} gegenüber deren Alternativen stärkt. Das Produkt aller N_k Bayesfaktoren ergibt die Eignungswahrscheinlichkeit der j -ten Ausprägung H_{kj} im Verhältnis zu allen anderen Ausprägungen.

Empfohlen wird das Recommendersystem dann die Ausprägungen mit maximaler Eignungswahrscheinlichkeit für alle Merkmale k .

$$P(H_k) = \max(P(H_{kj})) \quad (2)$$

Woher stammen nun die Likelihoods $P(E_{ki}|H_{kj})$ bzw. Bayesfaktoren? Es gibt mehrere Möglichkeiten. Die wichtigsten sind:

- Direkte und subjektive Einschätzung der Eignungswahrscheinlichkeiten durch Kunden: Das ist der Fall, wenn ein Kunde direkt angibt Schuhmodell Berlin und Schuhmodell Paris im Verhältnis 3 : 2 zu präferieren.
- Parametrisierte Likelihoodfunktionen: Solche Funktionen bilden z. B. die Parameter Fußlänge und Fußbreite auf Schuhgröße und Schuhweite ab. Das sind normative Anforderungen, die von der Kundin formuliert werden oder auch an der Kundin gemessen werden. Mit $P(H_k) = 1$ für ein bestimmtes j kann man auch deterministische parametrische Anforderungen abbilden.
- Likelihoods als Häufigkeiten aus einem Datenbestand: Wenn man weiß, dass Frauen die alternativen Schuhdesigns in einem bestimmten Verhältnis bevorzugen, kann man diese Häufigkeiten bei einer beliebigen Kundin als Likelihoods verwenden. Zudem kann man die Einkaufshistorie einer Kundin als personalisierte Datenquelle verwenden.

Vorteil des bayesschen Ansatzes ist also, dass er subjektive Präferenzen, parametergestützte Anforderungen und datenbasierte Wahrscheinlichkeiten integriert. Damit lässt er sich universell auf Beratungs- bzw. Entscheidungsunterstützungssituationen anwenden (Dangelmaier et al. 2022; Dangelmaier & Hölzle 2023).

5. Nutzergerechte Sprache und Interaktion

Die genannten Formeln beschreiben den idealtypischen Algorithmus exakt. Für die Nutzenden ist ihre Kenntnis jedoch weder erforderlich noch zumutbar. Für eine fundierte Entscheidung müssen sie aber sehr wohl die Eignungswahrscheinlichkeiten aller Ausprägungen kennen. Nur dann können sie die Vorschläge nachvollziehen und hinreichend informiert entscheiden. Tabelle 1 zeigt das am Beispiel.

Tabelle 1: Beispiel einer probabilistischen Schuhkonfiguration durch Eignungswahrscheinlichkeiten P . Es umfasst 6 Merkmale, 30 Ausprägungen und 2912 Produktvarianten. Leere P -Zellen sind als 0 zu interpretieren. 128 Modelle kommen für den Nutzenden infrage. Zwei Modelle „Berlin, Größe 40, Weite H, dünne Sohle, ohne Entlastung Haglundferse entweder mit oder ohne Entlastung Fersensporen“ werden empfohlen. Grau hinterlegt sind die Entscheidungen.

Modell		Berlin			Paris			Lhasa			Hawaii		
P		0,4			0,3			0,2			0,1		
Schuhgröße	36	37	38	39	40	41	42	43	44	45	46	47	48
P					0,8	0,2							
Schuhweite	F	G	H	J	K	L	M						
P			0,8	0,2									
Sohle				dünn				elastisch					
P				0,7				0,3					
Entlastung Haglundferse				ja				nein					
P				0,1				0,9					
Entlastung Fersensporn unten				ja				nein					
P				0,5				0,5					

Die Entscheidungslast wird durch Ausschluss von Optionen ($P=0$) von 2912 auf 128 Modelle reduziert. Zwei Modelle (P_{\max}) werden empfohlen. Folgt der Nutzende dem Vorschlag, muss er nur noch entscheiden, ob er die Fersensporenentlastung möchte. Er entscheidet in seinem Anwendungsfall sinnvollerweise für das elegantere Modell Paris. Wegen eines optisch schlankeren Fußes wählt er gegen die Empfehlung Schuhweite G bei Schuhgröße 41 statt H bei 40. Das erscheint gemäß Tabelle 1 jedoch irrational und lässt negative Folgen für die Fußgesundheit befürchten.

6. Diskussion

Der vorgestellte idealtypische SPBR-Algorithmus erfüllt konstruktionsbedingt alle in Kapitel 4 an ihn gestellten Anforderungen. In der Praxis treten jedoch Komplikationen wie unverträgliche Ausprägungen auf. So könnte es sein, dass das Modell Paris nicht mit elastischer Sohle hergestellt wird. Oder bei Beschwerden wegen eines Fersensporns verändern sich die Präferenzen für ein paar Monate sehr stark, was man durch ein zeitabhängiges Modell berücksichtigen könnte. Das führt dazu, dass erweiterte Algorithmen besser geeignet sind. Das probabilistische Interaktionsparadigma wird

dadurch aber nicht ungültig, sondern bleibt aus Sicht der bayesschen Erkenntnistheorie bzw. nach dem Grundsatz informierter probabilistischer Entscheidungen weiterhin empfehlenswert.

In weiteren Arbeiten sollten einerseits weitere Anwendungsfälle sowie die Anwendbarkeit der probabilistischen Interaktion bei den bekannten Klassen von Recommenderalgorithmen untersucht werden. Andererseits bleibt empirisch zu klären, wie Nutzende mit der probabilistischen Kommunikation zurechtkommen. Es ist durch unsere mathematisch und normativ begründeten Überlegungen noch nicht nachgewiesen, dass sie angemessen interpretiert und akzeptiert wird.

7. Literatur

- Bartelborth T (2017) Die erkenntnistheoretischen Grundlagen induktiven Schließens. Universität Leipzig Institut für Philosophie, Leipzig.
- Bauernhansl T, Groß E, Mais F, Schrader P, Briem A-K, Dangelmaier M, Hildebrandt N, Krieg S, Ulmer J (2023) Herausforderungen der personalisierten Produktion: Expert interviews on personalization in the DACH Region. *wt* 113:177–181.
- Bayes T, Price R (1763) An essay towards solving a problem in the doctrine of chances, London.
- Bovens L, Hartmann S, Bülow C von (2006) Bayesianische Erkenntnistheorie. Mentis, Paderborn.
- Briem A-K, Ziegler D, Mathis L-A, Wehner D (2022) Sustainable product development by means of personalization – paradox or solution? *E3S Web Conf.* 349:7001.
- Dangelmaier M, Bauer W, Chen Z (2022) Interdisciplinary Communication and Advice under Uncertainty in a Pandemic Global Issues: Disease Control and Pandemic Prevention. *AHFE International*: 29–36.
- Dangelmaier M, Hölzle K (2023) Probabilistisch entscheiden in der Produktentwicklung. *Stuttgarter Symposium für Produktentwicklung*: 330–341.
- Groß E, Finkbeiner S, Siegert J, Bauernhansl T (2020): Sprachsteuerung für die Mensch-Roboter-Kollaboration in der Montage. Gestaltung von Regeln und Implementierung. In: *wt Werkstattstechnik online* 110 (1/2): 73–79.
- Hämmerl R, Dangelmaier M (2018) Mass Personalization und die Erfolgsfaktoren nach dem Stuttgarter Modell. *ZWF* 113:730–733.
- Held M, Wehner D, Hämmerl R, Dangelmaier M, Briem A-K, Reiff C, Wulle F (2018) Personalization in the automotive and building sector – research program of the High-Performance Center »Mass Personalization« in Stuttgart, Novi Sad, Serbia. 8th International Conference on Mass Customization and Personalization (MCP – CE 2018), <https://mcp-ce.org/proceedings-2018/>.
- Laplace PS de (1814) Essai Philosophique Sur Les Probabilités. Courcier Imprimeur-Libraire pour les Mathématiques, Paris.
- Piller FT (2006) Mass customization: Ein wettbewerbsstrategisches Konzept im Informationszeitalter. Dt. Univ –Verl., Wiesbaden.



Gesellschaft für Arbeitswissenschaft e.V.

Arbeitswissenschaft in-the-loop

**Mensch-Technologie-Integration
und ihre Auswirkung auf Mensch,
Arbeit und Arbeitsgestaltung**

70. Kongress der
Gesellschaft für Arbeitswissenschaft e.V.

Institut für Arbeitswissenschaft und
Technologiemanagement IAT
Universität Stuttgart

In Zusammenarbeit mit dem Fraunhofer-Institut für
Arbeitswirtschaft und Organisation IAO

06. – 08. März 2024

GfA-Press

Bericht zum 70. Arbeitswissenschaftlichen Kongress vom 06. – 08. März 2024

Institut für Arbeitswissenschaft und Technologiemanagement (IAT), Universität Stuttgart

In Zusammenarbeit mit: Fraunhofer-Institut für Arbeitswirtschaft und Organisation (IAO), Stuttgart

Herausgegeben von der Gesellschaft für Arbeitswissenschaft e.V.

Sankt Augustin: GfA-Press, 2024

ISBN 978-3-936804-34-8

NE: Gesellschaft für Arbeitswissenschaft: Jahresdokumentation

Als Manuskript zusammengestellt. Diese Jahresdokumentation ist nur in der Geschäftsstelle (s. u.) erhältlich.

Alle Rechte vorbehalten.

© **GfA-Press, Sankt Augustin, Schriftleitung: Prof. Dr. Rolf Ellegast**

im Auftrag der Gesellschaft für Arbeitswissenschaft e.V.

Ohne ausdrückliche Genehmigung der Gesellschaft für Arbeitswissenschaft e.V. ist es nicht gestattet:

- den Kongressband oder Teile daraus in irgendeiner Form (durch Fotokopie, Mikrofilm oder ein anderes Verfahren) zu vervielfältigen,
- den Kongressband oder Teile daraus in Print- und/oder Nonprint-Medien (Webseiten, Blog, Social Media) zu verbreiten.

Die Verantwortung für die Inhalte der Beiträge tragen alleine die jeweiligen Verfasser; die GfA haftet nicht für die weitere Verwendung der darin enthaltenen Angaben.

Geschäftsstelle der GfA

Simone John, Tel.: +49 (0)30 1300-13003, Alte Heerstraße 111, D-53757 Sankt Augustin

info@gesellschaft-fuer-arbeitswissenschaft.de · www.gesellschaft-fuer-arbeitswissenschaft.de

Screen design und Umsetzung

© 2024 fröse multimedia, Frank Fröse,

office@internetkundenservice.de, www.internetkundenservice.de