

# Kundenorientierte Innovationspotenziale durch KI

Albert Albers,  
Felix Pfaff\*,  
Adrian Braumandl,  
Niklas Frank,  
Leonard Tusch,  
Robert Renz und  
Sascha Ott

Produktprofile sind eine praxisorientierte Hilfestellung, um neue Systemgenerationen zielgerichtet für die Bedürfnisse der Kunden und Anwender zu entwickeln. Dieser Beitrag zeigt anhand von zwei Fallstudien, wie KI bei der Definition von Kunden- und Anwendernutzen unterstützen kann. In Fallstudie 1 werden dazu aus Kundenrezensionen Use Cases und Produktverbesserungsvorschläge abgeleitet. In Fallstudie 2 werden Eigenschaften batterieelektrischer Fahrzeuge basierend auf Verkaufszahlen priorisiert.

## Produktprofile beschreiben Innovationspotenziale lösungs- offen und bedarfsorientiert

Nach Schumpeter [1] ist eine Innovation eine in ein Produkt überführte technische Neuerung (Invention), die sich erfolgreich am Markt durchgesetzt hat. Produkte müssen daher zielgerichtet für die Bedürfnisse der Kunden und Anwender entwickelt werden. Innovationsvorhaben scheitern besonders häufig daran, dass diese nicht den richtigen Kunden-, Anwender- und Anbieternutzen adressieren. Die Differenzierung von Wettbewerbern und Vorgängerproduktgenerationen, die Identifizierung von Zielmärkten und die frühzeitige und kontinuierliche Beachtung der Kundenbedürfnisse sind

entscheidend für den zukünftigen Produkterfolg [2].

Hier können Produktprofile eine praxisorientierte Hilfestellung leisten. Ein Produktprofil ist ein Modell eines Nutzenbündels, welches den Lösungsraum für die Entwicklung einer Produktgeneration explizit vorgibt [3]. Dabei gilt es zu beachten, dass das Produktprofil keine technische Lösung vorgibt, sondern lediglich einen Lösungsraum und somit kundenorientiert und lösungs offen ein Innovationspotenzial beschreibt. Das Produktprofil wird häufig pragmatisch durch ein Produktprofil-schema mit zwölf Modulen dargestellt (Bild 1). Ähnlich der Konzeptentwicklung sollten auch bei der Entwicklung von Produktprofilen diskursive, datenbasierte Methoden und intuitive, kreative Metho-

den kombiniert werden, um eine Vielzahl alternativer Lösungen zu erzeugen.

Die Definition des Kunden- und Anwendernutzens ist einer der wichtigsten Prozessschritte bei der Entwicklung eines Produktprofils [4] und findet idealerweise integriert zwischen Strategie, kundennahen Bereichen, wie z.B. Service und Vertrieb, und produktnahen Bereichen, wie z.B. Innovationsmanagement, Produktmanagement und Produktentwicklung, statt. Dabei gilt es, eine Vielzahl von Eingangsgrößen zu verarbeiten und Produktprofile mit hohem Innovationspotenzial als Ausgangsgröße zu entwickeln. Wichtige Eingangsgrößen sind dabei neben Marktforschung, Umfeld- und Technologievorausschau auch Daten zu Vorgängerproduktgenerationen und weiteren Referenzen. Das Modell der SGE – Systemgenerationsentwicklung beschreibt jedes Produkt als Systemgeneration  $G_i = n$ , die auf der Grundlage von Referenzen bestehender oder bereits geplanter Systeme mithilfe von Übernahme-, Ausprägungs- und Prinzipvariation entwickelt wird [5]. Der Index  $i = n$  bezeichnet dabei die aktuell in der Entwicklung befindliche und als nächstes an den Markt gehende,  $i = n-1$  die aktuell am Markt befindliche Systemgeneration.

Künstliche Intelligenz (KI) kann dabei helfen, diese Daten zu verarbeiten und für den Menschen im Mittelpunkt des

### \* Korrespondenzautor

Felix Pfaff, M.Sc.; IPEK – Institut für Produktentwicklung am Karlsruher Institut für Technologie (KIT); Kaiserstr. 10, 76131 Karlsruhe; Tel.: +49 (0) 721 608 47725, E-Mail: felix.pfaff@kit.edu

### Weitere Autoren

Prof. Dr.-Ing. Dr. h.c. Albert Albers; IPEK am Karlsruher Institut für Technologie

Dipl.-Ing. Adrian Braumandl; IPEK am Karlsruher Institut für Technologie

Niklas Frank, M.Sc.; IPEK am Karlsruher Institut für Technologie

Leonard Tusch, M.Sc. M.Sc.; IPEK am Karlsruher Institut für Technologie

Robert Renz, M.Sc.; IPEK am Karlsruher Institut für Technologie


Akad. Direktor DI Sascha Ott; IPEK am Karlsruher Institut für Technologie

### Hinweis

Bei diesem Beitrag handelt es sich um einen von den Advisory-Board-Mitgliedern des ZWF-Sonderheftes wissenschaftlich begutachteten Fachaufsatz (Peer-Review).

## Aufbau des Produktprofilschemas

### Beschreibung



■ Das Produktprofilschema ist eine Form der **Modellierung des Produktprofils**

- Es besteht aus **12 Modulen**, die jeweils unterschiedliche textuelle und visuelle **Informationen** zum Produkt enthalten

- Die Informationen beschreiben das Produkt **lösungsorientiert**

Bild 1. Aufbau des  
Produktprofilschemas [3]

Produktentwicklungsprozesses nutzbar zu machen [6]. Das Modell der SGE bietet dabei eine geeignete Grundlage für die Identifizierung und Ausgestaltung von KI-Anwendungsfällen in der Produktentwicklung. Der folgende Beitrag zeigt anhand von zwei Fallstudien, wie Unternehmen mithilfe des Einsatzes von KI schneller und gezielter mit angepassten Produktprofilen auf sich ändernde Kundenbedürfnisse und Branchenumfelder reagieren können.

## Mit KI Use Cases und Verbesserungsvorschläge aus Kundenrezensionen extrahieren


Online-Kundenrezensionen von Vorgängersystemgenerationen stellen eine große Datenquelle dar, welche für die gezielte Entwicklung von Produktprofilen genutzt werden kann. Neben weniger relevanten Aussagen beinhalten diese Rezensionen auch nützliche Informationen, beispielsweise

se über Use Cases oder Verbesserungsvorschläge hinsichtlich Kunden- und Anwendernutzen für die nächste Systemgeneration.


Um Online-Kundenrezensionen nutzen zu können, müssen nützliche Informationen aus einer großen Textmenge extrahiert werden. Die Analyse von solchen Datenmengen durch eine manuelle Aufbereitung ist zeitaufwendig und häufig mit hohen Kosten verbunden, was die Verwendung von effizienteren Ansätzen motiviert. In dieser Fallstudie wird gezeigt, wie mithilfe von Machine Learning und Natural Language Processing Online-Kundenrezensionen automatisiert ausgewertet werden können. Der Fokus liegt hierbei auf der Identifikation von Use Cases sowie Produktverbesserungsvorschlägen anhand des Produktbeispiels Bohrmaschine.

Ein häufig gewählter Ansatz zur Identifikation von Use Cases basiert auf [7]. Dabei liegt die Annahme zugrunde, dass ein Use Case des Produkts durch ein Wortpaar beschrieben werden kann, bei

dem eines der beiden Wörter die Endung „-ing“ aufweist, wie z.B. „*Drilling Metal*“. Nach diesem Vorgehen tritt jedoch häufiger das Problem auf, dass fälschlicherweise auch Wortpaare wie „*One Morning*“ extrahiert werden, welche offensichtlich keinen Use Case darstellen. Es wurde daher ein neuer Ansatz entwickelt, welcher auf grammatikalischen Abhängigkeiten basiert (Bild 2). Dabei werden die bei der Formulierung von Use Cases häufig vorkommenden grammatikalischen Beziehungen genutzt, um die relevanten Satzglieder zu identifizieren. Um ähnliche Use Cases zu gruppieren, werden die extrahierten Satzglieder über sogenannte Word-Embeddings in einen Vektorraum überführt und abschließend durch eine Clusteranalyse zusammengefasst. Im Bohrmaschinen-Beispiel konnten 81 verschiedene Use-Case-Cluster identifiziert werden. Beispielsweise wird in einem Cluster der Gebrauch der Produkte in engen Umgebungen durch Wortkombinationen wie „*Tight Spaces/*



*Bild 2. Ansatz zur Extraktion von Use Cases aus Kundenrezensionen*



Places“ und „Reach Places“ suggeriert. Daraus lässt sich dann wiederum ableiten, dass die Bohrmaschine möglichst kompakt gestaltet werden sollte. Weitere Cluster enthalten Informationen über das Bohren von unterschiedlichen Materialien oder auch über die Verwendung eines Rühraufsatzes, um Mörtel, Putz und Zement durchzumischen.

Neben den Use Cases werden in Online-Kundenrezensionen häufig auch Produktverbesserungsvorschläge in Form eines Wunsches oder durch eine Unzufriedenheit gegenüber der aktuell am Markt befindlichen Systemgeneration geäußert. Ein expliziter Vorschlag wird oftmals ausgedrückt durch bestimmte lexikalische Schlüsselwörter oder Phrasen, wie z.B. „Suggest“ oder „I recommend“ [8]. Bisherige Methoden zur Detektion von Vorschlägen nutzen diese Schlüsselwörter als linguistische Merkmale für einen Klassifikator [9, 10]. Für diese Fallstudie wurde stattdessen ein Deep-Learning-basierter Klassifikator entworfen (Bild 3). Die Idee hierbei ist, keine vordefinierten Schlüsselwörter zu verwenden, sondern geeignete Merkmale auf Basis des zugrundeliegenden Datensatzes zu berechnen. Hierzu werden zunächst die in Textform vorliegenden Rezensionen satzweise in eine Vektorrepräsentation überführt (Embedding Layer). Anschließend wird mithilfe von speziellen neuronalen Netzarchitekturen (LSTM-Layer, CNN-Layer) und dem sog. Attention-Mechanismus ein für den Klassifikator möglichst geeigneter Merkmalsvektor berechnet. Der Klassifikator ermöglicht dann eine Einteilung der vorliegenden Sätze nach „Verbesserungsvorschlag“ oder „Kein Verbesserungsvorschlag“.

Durch Anwendung des Klassifikators auf einen neuen Datensatz von Kundenrezensionen zu Bohrmaschinen wurde festgestellt, dass die als „Verbesserungsvorschlag“ identifizierten Sätze sowohl explizite als auch implizite Vorschläge enthalten. Beispielsweise wurden Sätze wie „Would Be nice if the light showed directly on the drill target“ als Vorschlag identifiziert, welche Phrasen wie „Would be“, „needs“ oder „I wish“ enthalten und somit einen expliziten Wunsch äußern. Weiter wurden jedoch auch Sätze wie „With this drill the button is too far back“ als Vorschlag identifiziert, welche ein vorliegendes Problem beschreiben bzw. eine Unzufriedenheit äußern.

Anhand der in dieser Fallstudie gezeigten Beispiele wird ersichtlich, dass durch die Analyse von Online-Kundenrezensionen wichtige Informationen für die Entwicklung von Produktprofilen gewonnen werden können. Insbesondere kann durch die automatisierte Auswertung mithilfe von KI-basierten Ansätzen schneller und gezielter auf sich ändernde Kundenbedürfnisse reagiert werden. Die Fallstudie wurde dabei bereits im Jahr 2020 durchgeführt. Durch die erheblichen Fortschritte im Bereich der KI in den letzten Jahren besteht das Potenzial, die Effektivität des vorgestellten Ansatzes weiter zu steigern oder um zusätzliche Aspekte, wie z.B. eine Trendanalyse, zu erweitern.

### KI unterstützt bei der Priorisierung von Kundennutzen

Eine zentrale Herausforderung bei der Entwicklung von Produktprofilen ist die Definition von Kunden- und Anwender-

nutzen, die tatsächlich kaufentscheidend sind, um die neue Systemgeneration gegenüber Wettbewerb und Vorgängersystemgenerationen zu differenzieren.

Pan et al. [11] entwickelten ein Deep-Learning-Modell, das die ästhetischen Wahrnehmungen von Kunden in heterogenen Marktsegmenten vorhersagen und visualisieren kann. Yuan et al. [12] präsentierten ein KI-Modell zur Vorhersage der Nutzerreaktionen auf neue Produktkonzepte. Diese und weitere Modelle verknüpfen jedoch die Produkteigenschaften nicht mit dem Kaufverhalten der Kunden. Ein in dieser Hinsicht vielversprechender Ansatz von Afrin et al. [13] nutzt Produkt- und Verkaufsdaten aus Vorgängersystemgenerationen zur Vorhersage der Nachfrage und Empfehlung des Differenzierungsgrads der neuen Systemgeneration. Die Einschätzung der Wichtigkeit einzelner Produkteigenschaften für die Kaufentscheidung muss dabei von Experten vorgenommen werden. In dieser Fallstudie von Braumandl et al. [14] wurde ein abstrakterer Ansatz gewählt, um die kaufentscheidenden Produkteigenschaften ohne Expertenwissen zu bestimmen und bei der Entwicklung der neuen Systemgeneration berücksichtigen zu können.

Dazu wurde aus Verkaufsdaten batterieelektrischer Fahrzeuge mithilfe von neuronalen Netzen die Relevanz von Produkteigenschaften evaluiert (Bild 4). Im Fokus der Fallstudie steht dabei die Einschätzung der Relevanz der Produkteigenschaften über Korrelationskoeffizienten und Gradient Based Feature Importance (GFI) zur Ermöglichung der Schätzung der Verkaufszahlen.

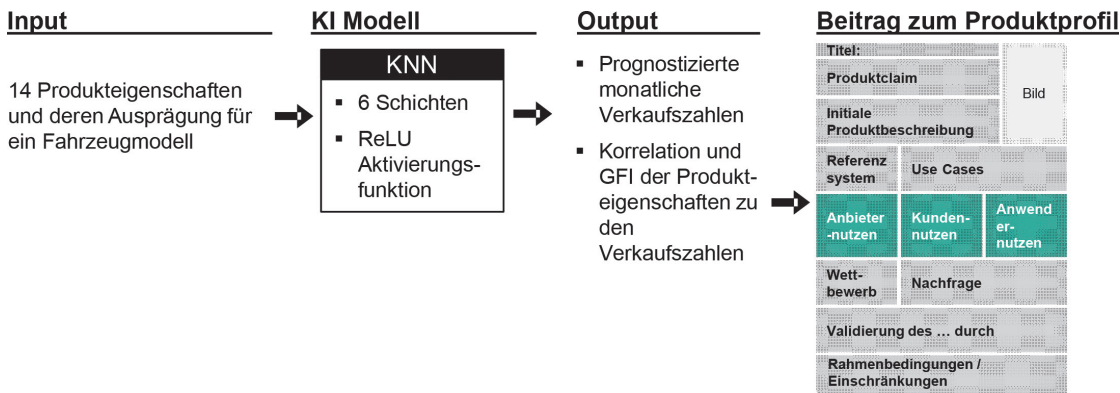


Bild 4. Ansatz zur Relevanzbewertung von Produkteigenschaften. KNN: Künstliches neuronales Netz. ReLU: Rectified Linear Unit. GFI: Gradient Based Feature Importance

Das Netzwerk wurde mit Zulassungsdaten des Kraftfahrt-Bundesamts (KBA) der 60 meistverkauften batterieelektrischen PKW in Deutschland von Januar 2017 bis Dezember 2022 trainiert und mit Daten von Januar bis März 2023 getestet. Zu den betrachteten Fahrzeugattributen gehören Marke, Beschleunigung, Höchstgeschwindigkeit, Reichweite, Ladegeschwindigkeit, Antriebskonfiguration, Kofferraumvolumen, Sitzanzahl, Modellsegment und Preis.

Die Genauigkeit des neuronalen Netzwerks wurde mit einem Root Mean Square Error (RMSE) von 246,4 Fahrzeugen pro Monat bewertet, wobei die Verkaufszahlen zwischen 46 Prozent und 319 Prozent der tatsächlichen Verkaufszahlen vorhergesagt wurden. Die Genauigkeit der Schätzung und damit auch die Einschätzung der Relevanz der Produkteigenschaften über Korrelationskoeffizienten und GFI ist in der betrachteten Fallstudie also vergleichsweise gering. Dies ist auf die unzureichende zum Training des neuronalen Netzwerks zur Verfügung stehende Datenmenge und die stark vereinfachte Beschreibung der Produkteigenschaften zurückzuführen. Die Ergebnisse zeigen aber, dass ein künstliches neuronales Netzwerk prinzipiell geeignet ist, die Beziehung zwischen den Produkteigenschaften und deren Verkaufserfolg zu untersuchen und Produkteigenschaften auch ohne Expertenwissen zu priorisieren.

Dieser datenbasierte Ansatz kann etablierte Methoden zur vergleichenden Bewertung von Produkteigenschaften wie die Conjoint-Analyse und KANO-Befragungen gut ergänzen. In einer 2022 von Deloitte durchgeführten Studie unter deutschen Kunden nannten 24 Prozent die Reichweite des Fahrzeugs als wichtige

Eigenschaft, während die Ladezeit nur von 9 Prozent der Befragten genannt wurde. Die Daten der Fallstudie lassen vermuten, dass die Ladegeschwindigkeit einen höheren Einfluss als die Reichweite auf die tatsächlichen Verkaufszahlen hatte, die wiederum wichtiger war als Beschleunigung, Höchstgeschwindigkeit und das Vorhandensein eines Allradantriebs.

## Zusammenfassung und Ausblick

Beide Fallstudien zeigen, wie KI bei der Entwicklung von Produktprofilen dem Menschen im Mittelpunkt des Entwicklungsprozesses helfen kann, Erkenntnisse aus Daten einfließen zu lassen, die ohne KI nicht oder nur mit hohem Aufwand verarbeitbar wären. Während in der ersten Fallstudie noch aufwendige Architekturen zur Verarbeitung natürlichsprachiger Daten zur Ableitung von Use Cases und Verbesserungsvorschlägen notwendig waren, sind ähnliche KI-Anwendungsfälle mit heutigen Möglichkeiten einfacher umzusetzen. Die zweite Fallstudie zeigt, wie mit relativ einfachen KI-Methoden wertvolle Erkenntnisse zu Kunden- und Anwendernutzen für Produktprofile generiert werden können. In beiden Beispielen waren Referenzen im Sinne des Modells der SGE – Systemgenerationsentwicklung zentral für das Training und die Anwendung der KI-Modelle. In Zukunft sollen weitere KI-Anwendungsfälle basierend auf dem Modell der SGE – Systemgenerationsentwicklung identifiziert und ausgearbeitet werden.

## Literatur

1. Schumpeter, J. A.: The Theory of Economic Development. An Inquiry into Profits,

Capital, Credit, Interest, and the Business Cycle. 10. Aufl., Transaction Publishers, New Brunswick, London 2004

2. Chong, Y. T.; Chen, C.-H.: Customer Needs as Moving Targets of Product Development: a Review. In: The International Journal of Advanced Manufacturing Technology 48 (2010) 1-4, S. 395-406  
DOI:10.1007/s00170-009-2282-6
3. Albers, A.; Heimicke, J.; Walter, B. et al.: Product Profiles: Modelling Customer Benefits as a Foundation to Bring Inventions to Innovations. In: Procedia CIRP 70 (2018), S. 253-258  
DOI:10.1016/j.procir.2018.02.044
4. Wilmsen, M.; Dühr, K.; Heimicke, J.; Albers, A.: The First Steps Towards Innovation: A Reference Process for Developing Product Profiles. In: Proceedings of the 22<sup>nd</sup> International Conference on Engineering Design (ICED19) 2019  
DOI:10.1017/dsi.2019.173
5. Albers, A.; Rapp, S.: Model of SGE: System Generation Engineering as Basis for Structured Planning and Management of Development. In: Krause, D.; Heyden, E. (Hrsg.): Design Methodology for Future Products: Data Driven, Agile and Flexible. Springer, Cham 2022  
DOI:10.1007/978-3-030-78368-6\_2
6. Kharatyan, A.; Humpert, L.; Anacker, H. et al.: Künstliche Intelligenz im Engineering. Zeitschrift für wirtschaftlichen Fabrikbetrieb ZWF 117 (2022) 6, S. 427-431  
DOI:10.1515/zwf-2022-1074
7. Suryadi, D.; Kim, H.: Automatic Identification of Product Usage Contexts from Online Customer Reviews. In: Proceedings of the Design Society: International Conference on Engineering Design 1 (2019) 1, S. 2507-2516  
DOI:10.1017/dsi.2019.257
8. Negi, S.; Rijke, M. de; Buitelaar, P.: Open Domain Suggestion Mining: Problem Definition and Datasets 2018  
DOI:10.48550/arXiv.1806.02179

9. Dong, L.; Wei, F.; Duan, Y. et al: The Automated Acquisition of Suggestions from Tweets. In: Proceedings of the AAAI Conference on Artificial Intelligence 27 (2013) 1, S. 239–245  
DOI:10.1609/aaai.v27i1.8630
10. Moghaddam, S.: Beyond Sentiment Analysis: Mining Defects and Improvements from Customer Feedback. In: Hanbury, A.; Kazai, G.; Rauber, A.; Fuhr, N. (Hrsg.): Advances in Information Retrieval. 37<sup>th</sup> European Conference on IR Research, ECIR 2015  
DOI:10.1007/978-3-319-16354-3\_44
11. Pan, Y.; Burnap, A.; Hartley, J. et al.: Deep Design. In: 23<sup>rd</sup> ACM SIGKDD International Conference 2017  
DOI:10.1145/3097983.3098176
12. Yuan, C.; Marion, T.; Moghaddam, M.: Leveraging End-User Data for Enhanced Design Concept Evaluation: A Multimodal Deep Regression Model. *Journal of Mechanical Design* (2021), S. 1–20  
DOI:10.1115/1.4052366
13. Afrin, K.; Nepal, B.; Monplaisir, L.: A Data-driven Framework to New Product Demand Prediction: Integrating Product Differentiation and Transfer Learning Approach. *Expert Systems with Applications* 108 (2018), S. 246–257  
DOI:10.1016/j.eswa.2018.04.032
14. Braumandl, A.; Ponnraj, A.; Brückel, J. et al.: Utilising Artificial Intelligence to Investigate the relevance of Customer Benefits. In: *International Journal of Innovation Management* 27 (2023) 05  
DOI:10.1142/S1363919623400066

### Die Autoren dieses Beitrags

Univ.-Prof. Dr.-Ing. Dr. h. c. Albert Albers ist Sprecher der Institutsleitung des IPEK – Institut für Produktentwicklung am Karlsruher Institut für Technologie (KIT).

Akad. Direktor DI Sascha Ott ist Mitglied der Institutsleitung und Geschäftsführer des IPEK – Institut für Produktentwicklung am Karlsruher Institut für Technologie (KIT).

Felix Pfaff, M.Sc., und Leonard Tusch, M.Sc. M.Sc., sind Wissenschaftliche Mitarbeiter der Forschungsgruppe Entwicklungsmethodik und -management (EMM) am IPEK – Institut für Produktentwicklung am Karlsruher Institut für Technologie (KIT).

Niklas Frank ist Leiter der Forschungsgruppe CAE/Optimierung am IPEK – Institut für Produktentwicklung am Karlsruher Institut für Technologie (KIT) und steuerte Fallbeispiel 1 bei.

Robert Renz, M.Sc., ist Wissenschaftlicher Mitarbeiter der Forschungsgruppe CAE/Optimierung am IPEK – Institut für Produktentwicklung am Karlsruher Institut für Technologie (KIT) und steuerte Fallbeispiel 1 bei.

Dipl.-Ing. Adrian Braumandl ist Wissenschaftlicher Mitarbeiter der Forschungsgruppe Antriebssystemtechnik (AST) am IPEK – Institut für Produktentwicklung am Karlsruher Institut für Technologie (KIT) und steuerte Fallbeispiel 2 bei.

### Abstract

**Customer-Oriented Innovation Potentials through AI.** Product profiles are a practical method to develop new system generations

that are tailored to the needs of customers and users. This paper demonstrates, through two case studies, how AI can assist in defining customer and user benefits. In Case Study 1, use cases and product improvement suggestions are derived from customer reviews. In Case Study 2, the attributes of battery electric vehicles are prioritized based on sales figures.

### Schlüsselwörter

Produktentwicklung, Künstliche Intelligenz, Innovationsmanagement, Produktprofil, SGE – Systemgenerationsentwicklung, Kundenorientierung

### Keywords

Product Development, Artificial Intelligence, Innovation Management, Product Profile, SGE – System Generation Engineering, Customer Orientation

### Bibliography

DOI:10.1515/zwf-2024-0126

ZWF 120 (2025) Special Issue; page 85–89

Open Access. © 2025 bei den Autoren,

publiziert von De Gruyter. 

Dieses Werk ist lizenziert unter der Creative Commons Namensnennung 4.0 International Lizenz.

ISSN 0947-0085 · e-ISSN 2511-0896