

Ein Vergleich von Datenanalysemethoden für eine Affective Engineering Methode

Susan Gretchen Zöllner, Tina Schröppel, Sandro Wartzack

*Lehrstuhl für Konstruktionstechnik;
Friedrich-Alexander-Universität Erlangen-Nürnberg*

Abstract

Affective Engineering (AE) is an engineering genre that deals with users' subjective value creation in technical product design. Therein, quantitative instruments to map subjective quality criteria are dominant. ACADE is such an instrument that focuses on a long-term alignment of product design impressions to the subjective needs of users. Due to its quantitative backbone, several mathematical analysis methods seem convenient, whereas their specific benefits and drawbacks are not yet clear in the AE context. Therefore, analyses of nonlinear regression, artificial neural networks, fuzzy logic systems and hybrids are examined under the aspect of ACADE applicability. Different quality indicators unveil characteristics which the designer may use to mine their potential for future AE analyses.

Keywords: affective engineering, nonlinear regression, fuzzy logic systems, artificial neural networks

1 Motivation

Affective Engineering (auch: Emotional Engineering) beschäftigt sich mit der Integration subjektiver Qualitätsaspekte in die technische Produktentwicklung. Die subjektive Qualitätswahrnehmung spielt dabei nicht nur eine große Rolle im kurzfristigen Kauf technischer Produkte, sondern auch insbesondere in der langfristigen Entscheidung der Produktnutzung. Subjektive Bewertungen, die unmittelbar nach dem Nutzer-Produkt-Erstkontakt entstehen, zeigen sich darin jedoch nicht immer zielführend [1]. Das Instrumentarium ACADE (engl. „Approach for Computer Aided Design of Emotional impressions“) fokussiert daher den Langzeitwert subjektiver Qualität technischer Produkte [2]. Dieses bedient sich hierzu einem Set wohldefinierter Wortpaare, sogenannter semantischer Differentiale, zur Messung langfristiger einstellungsrelevanter Qualitätskriterien am Produkt. Es setzt diese in Bezug zu den individuellen Wertesystemen einzelner Nutzer und Nutzergruppen. Auf Basis jener Erkenntnisse können anschließend - den üblichen Produktentwicklungsprozess begleitend - gezielt technische Produkte mit höherer subjektiver Qualität entwickelt werden. Unklar ist jedoch, wie hierzu verschiedene mathematische Analyseverfahren genutzt werden können.

2 Stand der Forschung

2.1 Subjektive Qualität und ihre Messbarkeit

Die Qualitätswahrnehmung des Nutzers in den immer satteren Märkten technischer Produkte verschiebt sich zunehmend hin zu subjektiven Qualitätsmerkmalen [3]. Dabei sind diese all jene Aspekte, die über objektive Kriterien wie Funktion, Kosten, Reliabilität usw. hinausgehen und nicht unbedingt durch rationale Entscheidungswege erklärt werden können [4].

Diese subjektiven Qualitätskriterien äußern sich maßgeblich über individuelle Emotionen des Nutzers in der Produkt-Nutzer-Interaktion, sodass diese im Affective Engineering eine herausragende Rolle einnehmen [5]. Dabei kann die Messung menschlicher Emotionen unterschiedlich vorgenommen werden. In der Regel werden hierzu drei Kategorien unterschieden: Antworten auf Befragungen, psycho-physiologische Reaktionen und beobachtbares Verhalten [6]. Da im Bereich der technischen Produktentwicklung quantitative Methoden vorherrschen, sind insbesondere direkte Befragungen von Bedeutung.

Das Kansei Engineering (jap. „kansei“= Gefühl, Eindruck; KE) bedient sich der Emotionsmessung über sogenannte semantische Differentiale [7]. Dieses stellt eine quantitative Form der subjektiven Nutzerbefragung dar, indem es

die Ausprägtheit bestimmter emotionaler Impressionen bestimmt. Auf Basis vordefinierter Sets semantischer Differentiale werden verschiedene Varianten eines Produktes durch mehrere Probanden bewertet. Dadurch ergibt sich eine spezifische, subjektive Charakterisierung der jeweiligen Produktvarianten. So wird beispielsweise ersichtlich, welches Produkt als besonders sportlich, elegant oder innovativ wahrgenommen wird. Dieses errungene Wissen kann anschließend wiederum mit den gestalterischen Merkmalen der jeweiligen Produktvarianten abgeglichen werden, um funktionale Zusammenhänge zwischen Gestaltung und Wirkung herzustellen (siehe Abbildung 1). [7]




Abbildung 1: Beispiel einer KE Logik - Gestaltparameter-Kombinationen rufen ein spezifisches emotionales Impressionsprofil hervor, ausgedrückt durch semantische Differentiale mit gegensätzlichen Begriffspaaren (nach [8])

2.2 ACADE

Ausgehend vom Grundprinzip des KE wurde am Lehrstuhl für Konstruktionstechnik (KTmfk) der Friedrich-Alexander-Universität das Instrument ACADE entwickelt. Dessen Prämisse ist es, dass ein erfolgreiches subjektives Produkterlebnis nur dann stattfindet, wenn die wahrgenommenen subjektiven Qualitätskriterien denen der persönlichen Wertorientierung des Nutzers entsprechen. Um dies zu gewährleisten, werden in ACADE nutzerindividuelle präferierte emotionale Impressionen mit den vom Produkt suggerierten abgeglichen (siehe Abbildung 2). Über diesen Abgleich der spezifischen subjektiven Profile, bestehend aus einem Set einschlägiger semantischer Differentiale, kann über die subjektive Charakterisierung hinaus auch eine Vorhersage der individuellen Produkt-Präferenz des zukünftigen Nutzers getroffen werden. [2]




Abbildung 2: Prozessabbild des ACADE Vorgehens

Ein Vorteil dieses Verfahrens ist die mathematische Verarbeitung quantifizierter Daten. So wurden bereits von KETT, SCHMITT UND WARTZACK wichtige mathematische Ansätze zur systematischen subjektiven Nutzersegmentierung erarbeitet [9].

3 Forschungsproblem und Forschungsziel

In der Anwendung dieses Instruments erfolgt u.a. eine mathematische Analyse aufgenommener Umfragerückläufe in Bezug zu den vordefinierten Produkt-Gestaltparametern. So wird zum Beispiel i.d.R. die Impression „komfortabel“ tendenziell eher den Gestaltparametern „Rundheit“ zugeordnet. Zur effizienten und zielführenden Auswertung dieser Daten stehen dem Produktentwickler heutzutage vielfältige Analysemethoden zur Verfügung. Unklar ist jedoch, wie diese Methoden im Kontext subjektiver Qualitätsbeurteilung optimal eingesetzt werden können.

Die unterschiedlichen mathematischen Analysemethoden weisen jeweils individuelle Stärken, aber auch Schwächen und obligatorische Vorbedingungen auf. Gerade für die Anwendung im Affective Engineering könnten die Potenziale einzelner Verfahren gezielt genutzt sowie Schwächen konsequent kompensiert werden. Hierzu ist eine genaue Methoden- und Verhaltenskenntnis erforderlich. Ziel einer eingehenden Beschäftigung mit den unterschiedlichen mathematischen Analysemethoden ist also die Ableitung spezifischer, messbarer Gütekriterien und deren Anwendung anhand praktischer Beispiele. Durch das Studium können Handlungsempfehlungen für zukünftige Anwendungen sowie spezifische Stärken und Schwächen besser erkannt und genutzt bzw. umgangen werden.

4 Verwendete Methoden und Vorgehensweise der Untersuchung

Zur Umsetzung der Untersuchungen werden Datensätze vergangener ACADE Studien herangezogen. Diese wurden mit einfachen technischen Produkten wie z.B. Tastaturen und Fernbedienungen durchgeführt, um die Transparenz einer wissenschaftlichen Studie zu gewährleisten.

Kernprozess der subjektiven Qualitätsbeurteilung mit ACADE ist die Ableitung bzw. Beschreibung des funktionalen Zusammenhanges zwischen Produktdesign-Variationen und der subjektiven Wahrnehmung, wie Nutzer die jeweils veränderten Produktdesigns beurteilen. Hierzu kann die reine nichtlineare Regressionsanalyse (rNLR) als Standardverfahren der Statistik herangezogen werden. Aber auch die Verwendung künstlicher neuronaler Netze (KNN) oder Fuzzy Logic Systeme (FLS) bieten Potenziale. KNN wird generell

eine gute Vorhersagefähigkeit zugesprochen [10], FLS eignen sich besonders für die Verarbeitung vagen Wissens [11], wie es bei der subjektiven Produktbewertung der Fall ist.

Die Funktionsweisen der Methoden unterscheiden sich in diesem Kontext wesentlich. Bei der rNLR wird eine mathematische Funktion modelliert und optimiert [12], die den Zusammenhang zwischen Produktgestalt und Produktbeurteilung abbildet. Im Gegensatz dazu bilden KNN biologische neuronale Netze nach, indem mehrere künstliche Neuronen zusammengeschaltet und gewichtet werden [13]. Durch eine Anpassung der Gewichte lernt das Netz bestimmte Aufgaben zu lösen [14]. Hierfür wird dem Netz ein Trainingsdatensatz übergeben, der sowohl Eingangs- als auch Ausgangswerte beinhaltet [15]. Bei der Anwendung von KNN in ACADE wird die Beurteilung der Nutzer als Eingabe und das Produktdesign als Ausgabe eingesetzt. Innerhalb der FLS werden reelle Eingabewerte mithilfe sogenannter Zugehörigkeitsfunktionen μ zu einem gewissen Grad Termen linguistischer Variablen zugeordnet [16]. Abbildung 3 zeigt diesen Vorgang beispielhaft anhand der linguistischen Variable Geschwindigkeit. Der reelle Geschwindigkeitswert $V_1 = 18 \text{ km/h}$ wird hierbei z. B. zu 65% dem Term „sehr niedrig“ und zu 25% dem Term „niedrig“ zugeordnet.




Abbildung 3: Umwandlung reeller Werte durch FLS am Beispiel Geschwindigkeit (nach [17])

Die Datenverarbeitung findet anschließend durch eine Entscheidungslogik statt, bestehend aus mehreren WENN/DANN-Regeln. Die unscharfe Ausgabe wird in einem letzten Schritt in einen reellen Wert rückgeführt. [18] Die Erstellung der FLS erfolgt dabei unter Zuhilfenahme zusätzlicher Instrumente wie dem RapidMiner (RM), einer strukturentdeckenden Datenanalyse-Software, oder einer eingebetteten nichtlinearen Regressionsanalyse (NLR), um die erforderliche Aufstellung von Fuzzy Regeln abzubilden.

Um die unterschiedlichen Analysemethoden einer vergleichenden Beurteilung zu unterziehen, wurden vorab die in Tabelle 1 aufgeführten Gütekriterien identifiziert und getestet. Anschließend wird eine Vielzahl von Systemen, Netzen und Regressionsmodellen aufgestellt. Untersucht werden die Auswirkungen verschiedener Parametereinstellungen, das Verhalten bei veränderten Datensätzen, z. B. eine Reduktion oder Erweiterung der Daten sowie die allgemeine Handhabung bei Verwendung der Methoden.

5 Ergebnisse und Diskussion

Zentrale Erkenntnisse der Untersuchung sind die grundsätzlich sehr gute Anwendbarkeit unterschiedlicher Analysemethoden für die subjektive Qualitätsbeurteilung sowie das Aufzeigen signifikanter Unterschiede zwischen ihnen. So erfordern FLS beispielsweise – ähnlich wie KNN – ein hohes Maß an vorbereitenden Maßnahmen wie die formale Datenaufbereitung, die Datenstrukturierung sowie die Vorgabe einer Datenarchitektur. Weiterhin haben viele einzelne Gestalt-Parameter einen großen Einfluss in der Güte des generierten funktionalen Zusammenhangs. Statistische Verfahren wie die rNLR hingegen punkten durch eine einfache und transparente Anwendbarkeit bei vergleichsweise hoher Ergebnisgüte. Andererseits sind die generierten funktionalen Zusammenhänge nicht reversibel-selbstoptimierend, sodass eine direkte Produktdesign-Ableitung nicht möglich ist. Tabelle 1 zeigt einen qualitativen Vergleich der Methoden hinsichtlich ausgewählter Gütekriterien.

Tabelle 1: Vergleich der Datenanalysemethoden anhand ausgewählter, relevanter Gütekriterien (schwarz=schlecht, grau=ausreichend, weiß=gut)

	FLS(RM)	FLS(NLR)	rNLR	KNN
Schnittstellenaufwand				
Aufbau/Komplexität				
Nachvollziehbarkeit				
Gezielte Optimierung				
Robustheit				
Flexibilität				
Vorhersageaufwand				

Im Zuge der Beurteilung der Analysemethoden wird vorrangig die in Ingenieurskreisen etablierte Software MATLAB eingesetzt. Sowohl KNN, rNLR als auch FLS(NLR) lassen sich damit problemlos ganzheitlich und automatisiert abbilden. **Aufwendige Schnittstellen** zu anderen Programmen entfallen. Anders verhält es sich bei FLS(RM). Hier werden die Regeln der Entscheidungslogik durch den in RapidMiner verfügbaren RIPPER-Algorithmus (Repeated Increment Pruning to Produce Error Reduction) aufgestellt. Eine einfache automatische Softwareschnittstelle gibt es initial nicht, sodass sich ein manuelles Eingreifen des Produktentwicklers nicht vermeiden lässt. Der Schnittstellenaufwand ist dementsprechend sichtlich erhöht.

Neben dem Schnittstellenaufwand sind der prinzipielle **Aufbau** der Methode und die damit einhergehende **Komplexität** für den Anwender ein weiteres Gütekriterium. Beide Ansätze der FLS schneiden hierbei weniger gut ab. Der Grund liegt in der Beschaffenheit der Daten. Die Entscheidungslogik innerhalb der FLS kann lediglich mit unscharfen Werten arbeiten. Die durch die eingebettete NLR bzw. den RIPPER-Algorithmus aufgestellten Regeln beziehen sich anfangs jedoch auf reelle, also scharfe Werte. Um eine Auswertung zu ermöglichen, bedarf es deshalb einer zusätzlichen Datenaufbereitung, was die Komplexität der Methode erhöht. Die rNLR hingegen lässt sich bereits durch einige wenige Schritte anwenden und ist als Standardverfahren der klassischen Statistik dem Anwender häufig schon bekannt. Auch KNN sind gut zu bewerten, da bereits mit simplen Netzarchitekturen und gängigen Parametereinstellungen brauchbare Netze erzeugt werden können. Die beiden letztgenannten Methoden lassen sich zudem komplett automatisieren, wodurch die Komplexität bei der Nutzung reduziert wird.

Damit eine Methode langfristig erfolgreich eingesetzt wird, ist auch die Akzeptanz durch den Nutzer von Bedeutung. Diese wird v. a. durch **Nachvollziehbarkeit** erreicht. Insbesondere die rNLR kann hier punkten, denn bei den Regressionsmodellen handelt es sich um funktionale Zusammenhänge, die bereits mit einem grundlegenden mathematischen Verständnis erfasst werden können. Bei einem FLS(NLR) sinkt die Verständlichkeit durch die unscharfe Datenverarbeitung. Die Entscheidungslogik selbst ist durch die sprachliche Darstellung der WENN/DANN-Regeln jedoch gut nachzuvollziehen. Weniger eindeutig ist der verborgene Prozess des RIPPER-Algorithmus beim FLS(RM), was sich negativ auf die Transparenz der Methode auswirkt. Ähnlich verhält es sich bei KNN, denn diese gleichen einer Blackbox und sind für den Laien in ihren Einzelheiten nur schwer zu begreifen.

Die Befragungsergebnisse vergangener ACADE Studien unterscheiden sich in Quantität und Qualität mitunter signifikant. Auftretende Schwächen der Datengrundlage sollten durch eine **Optimierung** der jeweiligen Methodenparameter ausgeglichen werden können. Neben der Anzahl linguistischer Variablen lassen sich bei FLS auch zahlreiche Operatoren auswählen oder individuell definieren. Zugehörigkeitsfunktionen, die der Datenumwandlung in unscharfe Werte dienen, lassen sich in Anzahl und Form ebenfalls frei gestalten. Um auch den ungeübteren Anwendern eine effiziente Nutzung von FLS zu ermöglichen, ist es deshalb sinnvoll, einige Standardvorlagen bereitzustellen. Die Optimierung verlagert sich damit auf die Entscheidungslogik, insbesondere auf die zusätzlich notwendige Datenverarbeitung. Bei FLS(RM) gestaltet sich dies schwierig, denn der RIPPER-Algorithmus besitzt nur wenige Einstellparameter. Verbesserungen können lediglich durch Anpassung der Datenstrukturierung und Datenarchitektur bei der Umwandlung scharfer in unscharfe Regeln realisiert werden. Die Regelableitung bei FLS(NLR) lässt sich durch die Wahl der richtigen Verarbeitungssystematik positiv beeinflussen. Bei einem Einsatz einer Polynomfunktion als Modell der rNLR kann die Wahl eines höheren oder niedrigeren Grades oder die Erweiterung des Datensatzes zielführend sein. Im Vergleich zu den anderen Methoden gestaltet sich die Findung geeigneter Parametereinstellungen bei KNN oftmals schwierig [19]. Aufgrund schneller Rechenzeiten, bedingt durch einfache Netzarchitekturen, können im Anwendungsfall jedoch kleinere Parameterstudien durchgerechnet werden. Variiert wird dabei der Trainingsalgorithmus, die Berechnungsart des Netzfehlers, die Anzahl an Schichten sowie die Anzahl eingesetzter Neuronen. Der zusätzliche Einsatz von Evaluationsgrößen ermöglicht dann die automatische Auswahl des besten Netzes, ohne dass der Anwender größeren Aufwand betreiben muss.

Die zu verarbeitenden Datensätze bestehen mitunter aus nur einigen wenigen, ähnlichen Einträgen. Positiv auswirken würde sich hier eine Erweiterung der Daten. Dies ist jedoch nicht immer realisierbar. Das Kriterium der **Robustheit** bewertet deshalb, welche Art von Datensätzen durch die Methoden verarbeitet werden können. Der RIPPER-Algorithmus des NLR(RM) benötigt z. B. nur eine geringe Menge Daten um hochwertige Regeln für die Entscheidungslogik abzuleiten. Auch ähnliche Daten werden effizient verarbeitet. KNN sind hingegen stark abhängig von qualitativ hochwertigen Eingabedaten [20] und reagieren negativ auf niedrige oder homogene Datenmengen. Bei der rNLR treten Probleme auf, wenn die gemessenen Produktbewertungen homogen und zentriert sind. Da sich die Regressionsanalyse nicht zur Extrapolation eignet und damit die Validität des Modells auf den vorhandenen Wertebereich beschränkt ist [21], können in diesen Fällen nämlich keine Randbereiche abgebildet werden. Durch die eingebettete NLR im FLS(NLR) kommt es

ebenfalls zu diesem Problem, es kann durch die Umwandlung in unscharfe Werte jedoch zu einem gewissen Grad ausgeglichen werden.

Die **Flexibilität** bezieht sich auf die Art und Weise, wie Daten verarbeitet werden können. Die rNLR erweist sich hierbei als besonders flexibel, da die betrachteten Variablen zu jedem Zeitpunkt frei hinzugefügt oder entfernt werden können. Zudem kann die mathematische Funktion bidirektional eingesetzt werden. Im Gegensatz dazu müssen die Eingabe und Ausgabe bei beiden FLS-Ansätzen bereits im Vorfeld definiert sein. Ein späteres Hinzufügen von Variablen ist nur durch eine Anpassung der Entscheidungslogik möglich. Um eine Ausgabe zu erwirken, müssen zudem stets alle Eingabevariablen mit Werten versehen werden. Bei KNN kann die anfangs eingeführte Datenarchitektur ebenfalls nicht flexibel verändert werden, es besteht jedoch die Möglichkeit, auch unvollständige Eingaben zu verarbeiten. FLS und KNN können außerdem nur unidirektional verwendet werden.

Der Anwender soll mit ACADE letztlich in der Lage sein, technische Produkte hinsichtlich der individuellen, subjektiven Bedürfnisse der Nutzer zu optimieren bzw. ein ansprechendes Produktdesign abzuleiten. Der hierfür benötigte Aufwand geht als Gütekriterium **Vorhersageaufwand** in die Untersuchung ein. Sowohl beide FLS als auch KNN sind in der Lage eine Eingabe in Form von Nutzerbeurteilungen direkt in eine Produktdesign-Ausgabe zu überführen. Die mit der rNLR generierten funktionalen Zusammenhänge sind hingegen nicht reversibel-selbstopimierend. Für eine Produktdesign-Ableitung sind ergänzende Maßnahmen nötig, z. B. eine mehrdimensionale Optimierung.

6 Handlungsempfehlung und Fazit

Obwohl alle Methoden eine grundsätzliche Eignung für die subjektive Qualitätsbeurteilung aufweisen, unterscheiden sie sich dennoch. Mit FLS(RM) können kleine Datensätzen zwar robust verarbeitet werden, jedoch fehlt es an geeigneten Optimierungsmöglichkeiten oder automatisierten Programmschnittstellen. Eine hohe Komplexität bei gleichzeitig intransparenten Prozessen stellt den Anwender zusätzlich vor Herausforderungen. Der Einsatz einer eingebetteten Regressionsanalyse bei FLS(NLR) gleicht diese Schwächen aus, ist aufgrund der abstrakten Entscheidungslogik und aufwendigen Datenaufbereitung jedoch fehleranfällig. KNN sind einerseits schlecht nachvollziehbar, schneiden im Vergleich allerdings sehr gut ab, was v. a. an der einfachen Netzarchitektur und der damit einhergehenden Möglichkeit zur gezielten Optimierung durch integrierte Parameterstudien liegen mag. Positiv hervorheben kann sich insbesondere die rNLR. Mit transparenten und verständlichen Prozessen werden gängige Datensätze flexibel und gewinnbringend verarbeitet.

Dass die funktionalen Zusammenhänge nicht reversibel-selbstoptimierend sind, stellt zwar einen Nachteil gegenüber den anderen Methoden dar, kann jedoch durch nachgelagerte Prozesse kompensiert werden.

Für eine nutzbringende Datenanalyse in ACADE wird, basierend auf dem vorgestellten Methodenvergleich, das in Abbildung 4 dargestellte allgemeine Vorgehen empfohlen. Die Modellgüte gibt dabei an, wie gut die Zusammenhänge zwischen Produktdesign und Produktbewertung abgebildet werden. Sie basiert auf einem Testdatensatz und bedient sich geeigneter Evaluationsgrößen. Sind diese zu schlecht, kann zunächst eine iterative Optimierung der betrachteten Methode durchgeführt werden, bevor ein alternatives Datenanalyseverfahren eingesetzt wird. Wird grundsätzlich keine hohe Modellgüte erreicht, ist der Datensatz anzupassen. Dieser sollte viele heterogene Daten umfassen – ggf. ist eine Erweiterung der Umfragen-Stichprobengröße durchzuführen.




Abbildung 4: Empfohlenes Vorgehen für Datenanalyse in ACADE

Auch der Wissensstand des Anwenders muss Berücksichtigung finden. Für den Laien bietet sich vorrangig die rNLR an, da der Einarbeitungsaufwand für ein umfassendes Methodenverständnis sehr niedrig ist. KNN und FLS sind im Vergleich komplexer, können mithilfe von Standardvorlagen jedoch vereinfacht werden. Eine gezielte Einstellung der Parameter auf den Anwendungsfall ist damit allerdings nur noch bedingt möglich. Bestehen bereits fundierte Methodenkenntnisse, können KNN und FLS jedoch fachgerecht eingestellt und ungenutzte Potenziale gewinnbringend ausgeschöpft werden.

Anhand der Untersuchung konnten letztlich nicht nur die Stärken der mathematischen Analysemethoden aufgezeigt, sondern auch grundlegende Schwächen für einen zielgerichteten Einsatz in ACADE identifiziert werden. Langfristig sind diese Erkenntnisse ganzheitlich und erfolgreich in den Kernprozess des Instrumentariums zu integrieren, um die Qualität der Produktdesign-Ableitung sukzessive zu steigern und damit die Attraktivität des Instrumentariums für einen Einsatz in der Produktentwicklung zu erhöhen.

Literatur

- [1] Kujala, S.; Miron-Shatz, T.: "The evolving role of expectations in long-term user experience." Proceedings of the 19th International Academic Mindtrek Conference, ACM, 2015.
- [2] Zöller, S. G.; Wartzack, S.: "Considering Users' Emotions in Product Development Processes and the Need to Design for Attitudes." Emotional Engineering, Vol. 5, Springer International Publishing, 2017, S. 69-97.
- [3] Huang, C.; Guan, S.: "A Case study of Kansei Image Survey System Based on Generational Differences" In: Proceedings of the International Symposium on Computer, Consumer and Control (IS3C 2014), Taichung, Taiwan, 2014.
- [4] Kurosu, M.; Hashizume, A.: "Concept of satisfaction" In: KEER2014. Proceedings of the 5th Kansei Engineering and Emotion Research, International Conference; no. 100, Linköping. Linköping, University Electronic Press, 2014, S. 1103–1112.
- [5] Desmet, P. M. A. & Pohlmeier, A. E.: "Positive design: An introduction to design for subjective well-being" In: International Journal of Design, 7(3), 2013, S. 5-19.
- [6] Foscht, T.; Swoboda, B.; Schramm-Klein, H.: "Käuferverhalten. Grundlagen - Perspektiven - Anwendungen", 5. Auflage, Springer Gabler, Wiesbaden, 2015.
- [7] Schütte, S.: "Engineering Emotional Values in Product Design: Kansei Engineering in Development", PhD thesis, Linköping, 2005.
- [8] Osgood, C. E.: "The nature and measurement of meaning". Psychological Bulletin 49, 1952, S. 197–237.
- [9] Kett, S. G.; Schmitt, B; Wartzack, S.: "What the statistics tell us—How to use empiric data in design for emotional impressions." International Conference on Research into Design. Springer, Singapore, 2017.
- [10] Shmueli, G.; Patel, N. R.; Bruce, P. C.: "Data Mining In Excel: Lecture Notes and Cases", 2005.

-
- [11] Altrock, C. von: "Fuzzy Logic", 2. Auflage, Oldenbourg, München, 1995.
- [12] Backhaus, K.; Erichson, B.; Weiber, R.: "Fortgeschrittene Multivariate Analysemethoden. Eine Anwendungsorientierte Einführung", 3. Auflage, Springer Gabler, Berlin, 2015.
- [13] Zaun, D. P.: "Künstliche neuronale Netze und Computerlinguistik", Niemeyer, Tübingen, 1999.
- [14] Adamy, J.: "Fuzzy Logic, Neuronale Netze und Evolutionäre Algorithmen", Shaker, Aachen, 2005.
- [15] Rey, G. D.; Wender, K. F.: "Neuronale Netze. Eine Einführung in die Grundlagen, Anwendungen und Datenauswertung", Huber, Bern, 2008.
- [16] Sivanandam, S. N.; Sumathi, S.; Deepa, S. N.: "Introduction to Fuzzy Logic using MATLAB", Springer, Berlin, 2007.
- [17] Kahlert, J.; Frank, H.: "Fuzzy Logic und Fuzzy-Control. Eine anwendungsorientierte Einführung mit Begleitsoftware", 2. Auflage, Vieweg, Braunschweig, 1994.
- [18] Lippe, W.: "Soft-Computing mit Neuronalen Netzen, Fuzzy-Logic und Evolutionären Algorithmen", Springer, Berlin, 2006.
- [19] Dallmüller, K.: "Neuronale Netze zur Unterstützung von Matchingprozessen. Konzeption – Modellierung – Implementierung", Springer Gabler, Wiesbaden, 1998.
- [20] Beale, M. H.; Hagan, M. T.; Demuth, H. B.: "Neural Network Toolbox Users's Guide. R2014a", The Mathworks, Inc., 2013.
- [21] Backhaus, K. et al: "Multivariate Analysemethoden. Eine anwendungsorientierte Einführung", 14. Auflage, Springer Gabler, Berlin, 2016.