





Forschungsberichte



Marc Albrecht

## **Modellierung der Komfortbeurteilung aus Kundensicht am Beispiel des automatisierten Anfahrens**

Modelling of Comfort Ratings from a Customer's Point of View on the Example of  
the Automated Start-Up Procedure

Band 18

Herausgeber: o. Prof. Dr.-Ing. Dr. h.c. A. Albers

Copyright:            Institut für Produktentwicklung  
                              Universität Karlsruhe (TH), 2005

Alle Rechte vorbehalten

Druck:                 Schnelldruck Ernst Grässer, Karlsruhe  
                              Tel.: (0721) 61 50 50

ISSN                    1615-8113

# **Modellierung der Komfortbeurteilung aus Kundensicht am Beispiel des automatisierten Anfahrens**

Zur Erlangung des akademischen Grades eines  
**Doktors der Ingenieurwissenschaften**  
von der Fakultät für Maschinenbau der  
Universität Karlsruhe (TH)

genehmigte  
**Dissertation**  
von

Dipl.-Ing. Marc Albrecht  
aus Angelbachtal

Tag der mündlichen Prüfung:

29. April 2005

Hauptreferent:

o. Prof. Dr.-Ing. Dr. h.c. A. Albers

Korreferent:

Prof. Dr.-Ing. F. Küçükay



## **Vorwort des Herausgebers**

Wissen ist einer der entscheidenden Faktoren in den Volkswirtschaften unserer Zeit. Der Unternehmenserfolg wird in der Zukunft mehr denn je davon abhängen, wie schnell ein Unternehmen neues Wissen aufnehmen, zugänglich machen und verwerten kann. Die Aufgabe eines Universitätsinstitutes ist es, hier einen wesentlichen Beitrag zu leisten. In den Forschungsarbeiten wird ständig Wissen generiert. Dieses kann aber nur wirksam und für die Gemeinschaft nutzbar werden, wenn es in geeigneter Form kommuniziert wird. Diese Schriftenreihe dient als eine Plattform zum Transfer und macht damit das Wissenspotenzial aus aktuellen Forschungsarbeiten am Institut für Produktentwicklung Karlsruhe (ehemals: Institut für Maschinenkonstruktionslehre und Kraftfahrzeugbau) verfügbar.

Die Forschungsfelder des Institutes sind die methodische Entwicklung und das Entwicklungsmanagement, die rechnergestützte Optimierung von hochbelasteten Strukturen und Systemen, die Antriebstechnik mit einem Schwerpunkt auf den Gebieten Antriebsstrangengineering und Tribologie von Lager- und Funktionsreibungssystemen sowie die Mechatronik. Die Forschungsberichte werden aus allen diesen Gebieten Beiträge zur wissenschaftlichen Fortentwicklung des Wissens und der zugehörigen Anwendung – sowohl den auf diesen Gebieten tätigen Forschern als auch ganz besonders der anwendenden Industrie – zur Verfügung stellen. Ziel ist es, qualifizierte Beiträge zum Produktentwicklungsprozess zu leisten.

Albert Albers





## Vorwort zu Band 18

Die Entwicklungsprozesse im Bereich der Automobilindustrie haben sich in den letzten Jahren drastisch verändert. Der Zwang zur Verkürzung der Entwicklungszeiten bei gleichzeitiger hoher Qualitätsanforderung führt zu einem verstärkten Einsatz von Simulationsmethoden, die bereits in frühen Phasen der Produktentwicklung valide Aussagen ableiten. Dabei ist dieser Entwicklungsprozess – wie ganz aktuelle Qualitäts- und Zuverlässigkeitsprobleme in der Automobilindustrie zeigen – hoch komplex und mit Risiken behaftet. Ein entscheidender Punkt im Bereich der Entwicklungsprozesse für Automobile ist die Einbindung des Kunden. Kaufentscheidungen werden wesentlich durch subjektive Beurteilungen des Endkunden im Fahrzeug bestimmt. Diese subjektiven Beurteilungen des Kunden können im Bereich der Produktentwicklung zur Zeit nur abgebildet werden, wenn man im Bereich der späteren Phase des Entwicklungsprozesses Prototypen für Fahrzeuge aufbaut und diese von erfahrenen Versuchingenieuren testen und beurteilen lässt. Damit erhält man die kundenrelevanten Aussagen zu entwickelten Strukturen erst in einem sehr späten Bereich des Entwicklungsprozesses. Ziel muss es daher sein, bereits in den frühen Phasen, wo Fahrzeuglösungen nur virtuell vorhanden sind, erste Aussagen über die kundenrelevanten Aspekte von gewählten Lösungen zu bekommen. Dies gilt insbesondere für dynamische Eigenschaften und Geräuschbeurteilungen, dem sog. NVH-Verhalten. Im Rahmen von Virtual-Reality-Laboren wird heute bereit versucht, Subjektivbeurteilungen, z. B. bzgl. der Innenraumgestaltung, mit virtuellen Fahrzeugmodellen in entsprechenden Einrichtungen zu ermitteln. Für antriebstechnische Fragestellungen sind diese Vorgehensweisen allerdings nicht geeignet, da die dynamischen Aspekte im Allgemeinen nicht berücksichtigt werden können. Die Lösungen, dynamische Aspekte – insbesondere Beschleunigungen – mit sog. Fahrzeugdomen in beschränktem Ausmaß abzubilden, haben nicht zu einer breiten Akzeptanz und Verbreitung geführt. Insbesondere für die Antriebstechnik wäre es von entscheidender Bedeutung, bereits aus physikalisch messbaren und damit natürlich auch in Modellen theoretisch simulierbaren Größen eine Abschätzung für die subjektive Kundenbeurteilung durch „Kundenmodelle“ zu gewinnen. Diese sog. Objektivierung ist Gegenstand der Forschung.

An dieser Stelle setzt die Arbeit von Herrn Dr.-Ing. Marc Albrecht an. Er entwickelt auf der Basis neuronaler Netze am Beispiel des Anfahrens eine Methode zur Objektivierung von Komfortbeurteilungen durch Fahrermodellbildung und validiert diese experimentell in umfangreichen Fahrversuchen mit Kundenkollektiven. Er greift mit seiner Dissertation ein äußerst wichtiges Thema im Bereich der Produktentstehungsprozesse für Automobile auf. Eine weitere Verkürzung der Entwicklungspro-

zesse bei steigender Qualität ist nur durch einen verstärkten Einsatz von Simulationen und virtueller Produktentwicklung möglich. Um hierbei die im Zielsystem geforderten kundenrelevanten Kenngrößen bereits in einer frühen Phase bei unterschiedlichen Konzeptvarianten beurteilen zu können, müssen Modellbildungen für die Komfortobjektivierung erforscht und entwickelt werden. Herr Albrecht zeigt mit seiner Arbeit, wie man dieses Thema mit einem Modellansatz auf der Basis künstlicher neuronaler Netze erfolgreich angehen kann.

Albert Albers

## Kurzfassung

Die zuverlässige Bewertung von Simulationsdaten eines virtuellen Fahrzeuges hinsichtlich des von einem Benutzer empfundenen Komforts ist von großem Interesse, da sie bereits in einer frühen Phase des Produktentstehungsprozesses im Simulationsmodell eine Voroptimierung von Bauteilen ermöglicht und dadurch Entwicklungszeit und -kosten eingespart werden können. Hierzu sind Bewertungsmodelle notwendig, die eine Berechnung subjektiver Komforturteile aus objektiven charakteristischen Größen erlauben.

Neben der Modellierung durch Regression als Standardmethode sind künstliche neuronale Netze (KNN) ein sehr vielversprechendes Werkzeug, um auf Basis objektiv messbarer Größen subjektive Komforturteile vorherzusagen<sup>1</sup>. Am Beispiel des automatisierten Anfahrvorgangs werden Bewertungsmodelle mittels multipler linearer Regression sowie Feed-Forward Backpropagation Netzen entwickelt und angewendet. Grundlage der Modellierung bilden Fahrversuche mit Laienbewertern in einem eigens für diesen Zweck aufgebauten Versuchsfahrzeug, dessen Anfahr-eigenschaften im kundenrelevanten Bereich variierbar sind. Die Komfortbeurteilung erfolgt anhand eines für Laienbewerter geeigneten Bewertungsschemas. Es wird eine Überprüfung der Modelle hinsichtlich Approximations- und Prognosegüte anhand eines Gütekriteriums, basierend auf dem Vergleich von berechneten und tatsächlich in Fahrversuchen ermittelten Komfortwerten, durchgeführt. Außerdem werden Richtlinien zum effektiven Umgang mit KNN für die Objektivierung von Komfortbeurteilungen erarbeitet, welche auf die Behandlung ähnlicher Problemstellungen übertragbar sind. U. a. werden speziell Maßnahmen aufgezeigt, die ein „Auswendiglernen“ der Trainingsdaten – und den damit einhergehenden Verlust an Generalisierungsfähigkeit – unterbinden. Beim Methodenvergleich ist festzustellen, dass die KNN- den Regressionsmodellen in punkto Prognosegenauigkeit überlegen sind. Es wird gezeigt, dass die objektivierete Beurteilung sowohl realer, als auch virtueller (simulierter) Anfahrten aus Kundensicht möglich ist. Somit ist eine Abschätzung der Komforteigenschaften real vorhandener Anfahrten erreichbar, was den Applikationsaufwand, speziell für automatisierte Anfahrssysteme, beherrschbarer macht. Darüber hinaus ist bereits in einer frühen Phase des Produktentstehungsprozesses eine Komfortabschätzung für virtuelle Fahrzeuge möglich. Dies stellt einen entscheidenden Baustein für die Verkürzung von Entwicklungszeiten und die Reduktion von Entwicklungskosten mittels virtueller Methoden, bei gleichzeitiger Erhöhung der Kundenakzeptanz, dar.

---

<sup>1</sup> Albers / Albrecht 2002, 2003a, 2003b, 2004a, 2004b, 2005



## Abstract

The reliable evaluation of simulation data of a virtual vehicle, with respect to the comfort felt by a user, is of great interest because it enables a pre-optimization of construction parts at a very early stage of the product development process and therefore economizes development time and costs. For this purpose, evaluation models are necessary that allow a calculation of subjective comfort ratings from objective characteristic quantities.

Besides the standard method of modelling by regression, artificial neural networks (ANN) are a very promising tool for predicting subjective comfort ratings on the basis of objectively measurable quantities<sup>2</sup>. On the example of the automated start-up procedure, evaluation models are developed and applied by means of multiple linear regressions and feed-forward back propagation networks. The basis for the modelling are drive tests with laymen evaluators in a test vehicle especially built for this purpose, with start-up properties which can be varied in the customer-relevant range. The comfort rating is realized with an evaluation scheme suitable for laymen evaluators. By means of a performance index based on the comparison of calculated and real comfort values determined in the drive test, a check of the models concerning approximation and prediction quality is carried out. Furthermore, guidelines are determined that deal with the effective application of ANN for the objectification of comfort ratings that are transferable to similar problems. Among others, measures are demonstrated that prevent a "memorizing" of the training data and the consequent loss of generalization ability. By comparing the methods, it can be established that the ANN are superior to the regression models with respect to prediction accuracy. It is shown that the evaluation from the customer's point of view can be applied for real as well as for virtual (simulated) start-up procedures. As a result, it is possible to achieve estimations beyond those of the comfort properties of real start-up procedures, a fact which makes the application effort more manageable, especially for start-up systems. It is also possible to estimate the comfort for virtual vehicles at an early state of the product development process. This represents a significant element for the reduction of development time and costs by means of virtual methods, and at the same time increased customer acceptance.

---

<sup>2</sup> Albers / Albrecht 2002, 2003a, 2003b, 2004a, 2004b, 2005



## Danksagung

Meinem Doktorvater, Herrn o. Prof. Dr.-Ing. Dr. h.c. Albert Albers, Leiter des Instituts für Produktentwicklung der Universität Karlsruhe (TH), gilt mein besonders herzlicher Dank für die wissenschaftliche Betreuung meiner Arbeit. Insbesondere möchte ich mich für das mir stets entgegengebrachte Zutrauen und auch Vertrauen bedanken, was maßgeblich zu meiner persönlichen und beruflichen Weiterentwicklung am Institut beitrug.

Herrn Prof. Dr.-Ing Ferit Küçükay, geschäftsführender Leiter des Instituts für Fahrzeugtechnik der Technischen Universität Braunschweig, danke ich für das Interesse an dieser Arbeit und die Übernahme des Korreferats.

Mein Dank gilt auch der DaimlerChrysler AG für die Bereitstellung des Versuchsfahrzeugs, sowie der Abteilung Entwicklung Elektronische Systeme der LuK GmbH & Co. oHG für die Unterstützung bei der Modifikation der Anfahrcharakteristik des verwendeten automatisierten Kupplungssystems.

Für die freundliche und sehr angenehme Arbeitsatmosphäre möchte ich mich bei allen Mitarbeitern des Instituts für Produktentwicklung bedanken. Sie haben durch Ihre freundschaftliche Kollegialität wesentlich dazu beigetragen, dass ich mich sehr positiv an meine Zeit am Institut zurückerinnere. Den Leitern der Forschungsgruppe Antriebstechnik, Herrn Dr.-Ing. Arne Krüger und Herrn Dipl.-Ing Sascha Ott danke ich für das Interesse an diesem Forschungsgebiet und die geschaffenen Freiräume.

Ausdrücklich bedanken möchte ich mich bei Herrn Dipl.-Ing. Björn Stehle für die fruchtbaren Diskussionen und Anregungen.

Weiterhin gebührt mein Dank den Teilnehmern der zahlreichen Fahrversuche und auch den Studien- und Diplomarbeitern, die zum Gelingen dieser Arbeit beigetragen haben.

Danken möchte ich auch meiner lieben Jeanette für ihre Unterstützung.

Schließlich möchte ich an dieser Stelle auch einmal meinen Eltern danken, die mich während meines Werdegangs gefördert und letztendlich den Grundstock für die Entstehung dieser Arbeit gelegt haben.





# Inhalt

1	Einleitung.....	1
2	Stand der Forschung und Technik.....	5
2.1	Subjektive Fahrkomfortbeurteilung.....	5
2.1.1	Subjektive Wahrnehmung und Urteilsbildung .....	5
2.1.2	Subjektive Komfortbeurteilung im Produktentstehungsprozess .....	7
2.1.3	Bewertungssysteme zur subjektiven Komfortbeurteilung.....	8
2.2	Objektivierung durch Modellbildung .....	12
2.2.1	Objektive Kennwerte für den Anfahrvorgang .....	13
2.2.2	Objektivierung mittels Korrelations- und Regressionsstatistik.....	18
2.2.3	Objektivierung mittels künstlicher neuronaler Netze .....	25
3	Ziele der Arbeit .....	35
4	Entwicklungsumgebung.....	39
4.1	Reale Umgebung – Versuchsfahrzeuge und Messtechnik.....	41
4.2	Virtuelle Umgebung – Mehrkörpersimulationsmodelle .....	45
5	Definition von Kundenzielgruppen .....	51
5.1	Datengewinnung im Fahrversuch.....	51
5.1.1	Versuchsteilnehmer .....	51
5.1.2	Versuchsbeschreibung .....	52
5.1.3	Ableitung charakteristischer Größen.....	55
5.2	Fahrerklassierung und Auswahl repräsentativer Fahrer.....	55
6	Untersuchungen zum Anfahrkomfort .....	57
6.1	Begriffsklärung Anfahrkomfort.....	57
6.2	Datengewinnung im Fahrversuch.....	60
6.2.1	Versuchsteilnehmer .....	60
6.2.2	Versuchsbeschreibung .....	61
6.2.3	Bewertungsmethodik .....	63
6.3	Überprüfung der Anfahrvarianten auf Kundenrelevanz .....	65
6.4	Vergleich der Bewertungstreue von Laien und Experten .....	66

---

6.5	Zusammenhang zwischen Kundenzielgruppe und Komforturteil .....	68
7	Modellierung der Anfahrkomfortbeurteilung .....	71
7.1	Ableitung charakteristischer Größen für den Anfahrvorgang .....	71
7.1.1	Subjektivdaten .....	71
7.1.2	Objektivdaten.....	72
7.2	Bildung von Arbeitsdatensätzen .....	76
7.3	Signifikanzanalyse .....	77
7.3.1	Anfahrten mit Gaspedalvorgabe .....	77
7.3.2	Anfahrten ohne Gaspedalvorgabe.....	82
7.4	Maß für die Modellgüte .....	83
7.5	Modellierung mittels multipler linearer Regression .....	86
7.5.1	Methodenbeschreibung .....	86
7.5.2	Approximations- und Prognosegüte für Einzelpersonen.....	86
7.6	Modellierung mittels künstlicher neuronaler Netze .....	88
7.6.1	Methodenbeschreibung .....	89
7.6.2	Approximations- und Prognosegüte für Einzelpersonen.....	94
7.6.3	Einfluss der Netzparameter .....	102
7.6.4	Variation des Messorts des Beschleunigungssignals .....	115
7.6.5	Approximations- und Prognosegüte für Kundenzielgruppen.....	118
7.7	Ergebnisdiskussion.....	119
8	Modellanwendung .....	121
8.1	Beurteilung realer Anfahrvorgänge .....	121
8.2	Beurteilung virtueller (simulierter) Anfahrvorgänge.....	124
8.2.1	Simulation und Beurteilung von Anfahrvarianten.....	124
8.2.2	Simulation und Beurteilung von Parametervariationen.....	129
8.3	Ergebnisdiskussion.....	132
9	Zusammenfassung und Ausblick.....	135
10	Literaturverzeichnis .....	139

## Formelzeichen

$a_j$	-	Regressionskoeffizient
$a(t)$	$m/s^2$	Zeitlicher Verlauf der Beschleunigung
$a_w(t)$	$m/s^2$	Zeitlicher Verlauf der frequenzbewerteten Beschleunigung
$a_{max}$	$m/s^2$	Maximale Beschleunigung
$\bar{a}$	$m/s^2$	Effektivwert der Beschleunigung
$\bar{a}_{wT}$	$m/s^2$	Zeitlicher Effektivwert der frequenzbewerteten Beschleunigung über die Schwingungsdauer
$\bar{a}_w$	$m/s^2$	Effektivwert der frequenzbewerteten Beschleunigung
$\hat{a}(\omega)$	$m/s^2$	Amplitude der Beschleunigung
$\hat{a}_w(\omega)$	$m/s^2$	Amplitude der frequenzbewerteten Beschleunigung
$b_j$	-	Modellparameter der Regressionsgleichung
$B_1$	-	Erste Bewertung
$B_2$	-	Zweite Bewertung
$c$	-	Konstante
$e$	-	Euler-Zahl
$F$	-	F-Wert
$FL$	-	Flächenindex
$G$	-	Güte
$G_A$	-	Approximationsgüte Einzelmodell
$G_{A,M}$	-	Mittelwert der mittleren Approximationsgüten
$G_P$	-	Prognosegüte Einzelmodell
$G_{P,M}$	-	Mittelwert der mittleren Prognosegüten
$\hat{G}_A$	-	Maximale Approximationsgüte Einzelmodell
$\hat{G}_{A,M}$	-	Mittelwert der maximalen Approximationsgüten
$\hat{G}_P$	-	Maximale Prognosegüte Einzelmodell
$\hat{G}_{P,M}$	-	Mittelwert der maximalen Prognosegüten
$i_i$	-	Eingangssignal

$m, n$	-	Anzahl
$M$	-	Mittelwert (arithmetisch)
$\max(PW)$	%	Maximaler Pedalwert
$M(PW)$	%	Mittlerer Pedalwert
$\max(\text{Grad}(PW))$	%/s	Maximale Pedalwertänderung
$M(\text{Betr}(\text{Grad}(PW)))$	%/s	Mittlerer Betrag der Pedalwertänderung
$n(t)$	1/min	Zeitlicher Verlauf der Drehzahl
$n_{oHK}(t)$	1/min	Obere Hüllkurve des zeitlichen Drehzahlverlaufs
$n_{uHK}(t)$	1/min	Untere Hüllkurve des zeitlichen Drehzahlverlaufs
$\text{net}$	-	Netto-Input eines Neurons
$n_B$	-	Anzahl Beobachtungen
$n_D$	-	Anzahl unabhängiger Datensätze
$n_F$	-	Anzahl Freiheitsgrade
$n_{NA}$	-	Anzahl Neuronen in der Ausgabeschicht
$n_{NE}$	-	Anzahl Neuronen in der Eingabeschicht
$n_{NV}$	-	Anzahl Neuronen in der verdeckten Schicht
$n_P$	-	Anzahl Prädiktorvariablen
$\hat{n}_{NV}$	-	Grenzanzahl verdeckter Neuronen
$\hat{n}_{NV1}$	-	Grenzanzahl verdeckter Neuronen bei einer verdeckten Schicht
$o$	-	Ausgangssignal
$\text{PSD}(\Delta\omega)$	(m/s <sup>2</sup> )/Hz	Objektivwert für modifiziertes Leistungsspektrum
$\text{PSD}_{BP\_x\_y}$	(m/s <sup>2</sup> )/Hz	Objektivwert für das Frequenzintervall xy
$R^2$	-	Bestimmtheitsmaß
$R^2_{\text{korr}}$	-	Korrigiertes Bestimmtheitsmaß
$SA$	-	Standardabweichung
$s(t)$	m	Zeitlicher Verlauf des Wegs
$T$	s	Messdauer
$T_{\text{ges}}$	s	Objektivwert entspr. 1/10 der Anfahrtdauer

$T(a_{\max})$	s	Relativer Zeitpunkt von $a_{\max}$
$T(\max(PW))$	s	Relativer Zeitpunkt von $\max(PW)$
$T(\max(\text{Grad}(PW)))$	s	Relativer Zeitpunkt von $\max(\text{Grad}(PW))$
VDV	$\text{m/s}^{1.75}$	Vibration Dose Value
$W(\omega)$	-	Gewichtungsfunktion
$W_c(\omega)$	-	Frequenzbewertung für translatorische Schwingung bei Einleitung über die Rückenlehne
$W_d(\omega)$	-	Frequenzbewertung für translatorische Schwingung bei Einleitung über den Sitz
$w_i$	-	Verbindungsgewicht
$x_{ij}$	-	Prädiktorvariable / unabhängige Variable
$y_i$	-	Kriteriumsvariable / abhängige Variable
$\hat{y}_i$	-	Berechneter Wert der Kriteriumsvariablen
$\bar{y}$	-	Mittelwert der Kriteriumsvariablen
$\alpha_j$	-	Standardisierte Regressionskoeffizienten
$\Delta\omega$	Hz	Filterbandbreite
$\Delta_M$	-	Mittlere arithmetische Abweichung
$\Delta_{MB}$	-	Mittlere Bewertungsabweichung
$\varepsilon_i$	-	Fehlerwert
$\Phi_a(\omega)$	$(\text{m/s}^2)^2/\text{Hz}$	Leistungsdichtespektrum



# 1 Einleitung

Im Rahmen einer methodischen Produktentwicklung erfolgt die Bewertung von Produkteigenschaften durch den Vergleich der Eigenschaften des aktuellen Ergebnisses in den einzelnen Phasen des Produktentstehungsprozesses (PEP) mit den zu Beginn im Zielsystem festgelegten Produkthanforderungen. Bei den meisten Anforderungen, wie z. B. Geometrie oder Gewicht, ist dieser Vergleich leicht möglich, da sich diese Größen einfach mathematisch beschreiben lassen und meist leicht objektiv bestimmbar, d. h. messbar sind. Jene Eigenschaften jedoch, welche beim Benutzer rein subjektive Eindrücke auslösen sind schwer zu formulieren, zu erfassen und zu vergleichen. Hierzu zählen im Automobilbau die Fahreigenschaften und damit auch der Anfahrkomfort. Im Allgemeinen verlangt der Kunde beim Anfahren eine gute Dosierbarkeit des Anfahrlements bzw. – bei automatisierten Systemen – eine hervorragende Dosierung des Abtriebsdrehmoments unter Berücksichtigung der unterschiedlichen Anfahrtsituationen (Ebene, Berg, Rangieren, Anhänger, etc.), sowie die Vermeidung von Beeinträchtigungen des Komforteindrucks durch Geräusche, Vibrationen und Zugkraftschwankungen. Der Komfortanspruch und damit das Komfortempfinden des Menschen ist jedoch individuell verschieden, denn bei der Urteilsbildung verknüpft eine Person die ihr präsentierten Muster an Sinneseindrücken mit ihren individuellen Erfahrungen und Erwartungen. Wie lässt sich demnach ein ideales Anfahrverhalten beschreiben? Unter Berücksichtigung wirtschaftlicher Aspekte muss ein – aus der Sicht der Fahrzeugentwickler – optimal gestaltetes Gesamtfahrzeug so geschaffen sein, dass es die Komfortschwelle des jeweiligen Fahrers gerade übertrifft, dessen Empfinden nicht negativ beeinflusst, und so eine Minimierung von Kostenaufwand zu Nutzen erreicht wird. Diese Grenze zu ermitteln ist jedoch schwierig, da Komfort, wie beschrieben, individuell unterschiedlich empfunden wird und darüber hinaus kaum objektiv messbar ist.

Um die Fahreigenschaften möglichst optimal an die Kundenwünsche anzupassen, werden die dynamischen Eigenschaften von Kraftfahrzeugen in der Validierungsphase des PEP in Fahrversuchen mit Prototypen von Ingenieuren ermittelt und überprüft. Dadurch, dass dies erst relativ spät im PEP stattfinden kann, sind viele Lösungsansätze zu diesem Zeitpunkt schon festgelegt. Die Simulation hilft

hier, die Eigenschaften des Produkts möglichst frühzeitig zu erkennen und ggf. zu verändern. Durch die Parallelität von Versuch (Fahrversuche, Prüfstandsversuche) und rechnergestützter Simulation wird es überdies möglich, Eigenschaften von übergeordneten Systemen (z. B. Gesamtfahrzeug) aus Eigenschaften von Teilsystemen (z. B. Antriebsstrang) zu bestimmen. Durch die Simulation und die Verlagerung „from-road-to-rig“ ist es also möglich, bereits in früheren Phasen des PEP auf spätere Eigenschaften des Produkts zu schließen. Die zuverlässige Bewertung von Simulationsdaten eines virtuellen Fahrzeuges hinsichtlich des Komforts ist demnach von großem Interesse, da somit im Sinne des „Frontloadings“ bereits im Simulationsmodell eine Voroptimierung von Bauteilen bezüglich des Komforts durchgeführt werden kann, wodurch sich Entwicklungszeit und -kosten einsparen lassen. Dazu notwendig sind Modelle, welche die Verknüpfung objektiver physikalischer Daten mit einem subjektiven Komforturteil erlauben. Man spricht hierbei von Objektivierung, da subjektive Komfortbewertungen anhand objektiv messbarer Kriterien definiert werden können. Diese Modellierung der Komfortbewertung ist jedoch bis dato noch nicht vollständig gelöst und es gibt bis jetzt – mit Ausnahme der Erfahrung der Entwickler – kaum zuverlässige Methoden, den späteren Anfahrkomfort direkt zu planen und schon im frühen Entwicklungsstadium eines Fahrzeuges vorauszusagen. Es ist also ein Werkzeug erforderlich, das es ermöglicht, aus im Versuch oder der Simulation ermittelten objektiven Messdaten subjektive Komfortbewertungen abzuleiten.

Abstrakt formuliert verknüpft ein Beurteiler die auf ihn einwirkenden Randbedingungen zu einem subjektiv empfundenen Komforteindruck. Aus der Analogie der Verknüpfung von objektiven Messdaten mit subjektivem Urteil liegt der Einsatz künstlicher neuronaler Netze (KNN) zu diesem Zweck nahe. Ähnlich wie bei der Urteilsbildung durch den Menschen werden hier Eingangsdaten (entsprechend den Sinneseindrücken) durch „gelernte“ Zusammenhänge mit einem Ausgangswert (dem Komforturteil) verknüpft. Sind solche Verknüpfungsmuster in Form trainierter KNN vorhanden, können diese zur Bewertung ungelerner, d. h. dem Netz nicht bekannter Eingangsdaten mit einer den Trainingsdaten ähnlichen Struktur, herangezogen werden. Diese Methode wird am Institut für Produktentwicklung als entscheidender Baustein für eine virtuelle Produktentwicklung erforscht<sup>3</sup> und ist Inhalt dieser Arbeit. Mit ihr ist es möglich, subjektive Fahrkomforteindrücke aus objektiven Daten, welche reale oder auch virtuelle Anfahrvorgänge beschreiben, individuell zu berechnen und damit tatsächlich eine Prozentzahl der zufriedenen Kunden anzugeben. Hierdurch können reale Anfahrvorgänge reproduzierbar aus Kundensicht beurteilt werden, darüber hinaus können zudem bereits in einer frü-

---

<sup>3</sup> Albers / Albrecht 2002, 2003a, 2003b, 2004a, 2004b, 2005



hen Phase des PEP aus Simulationsergebnissen erste Aussagen über die späteren Komforteigenschaften eines Fahrzeugs abgeschätzt werden. Durch die Auswahl der Personen, deren Komforturteile die Grundlage der Modellierung bilden, ist eine Anpassung an eine beliebige Kundenzielgruppe möglich.

In Kapitel 2 ist der Stand der Forschung und Technik im Bereich der Komfortbestimmung, mit dem Hauptaugenmerk auf der Beurteilung dynamischer Eigenschaften von Fahrzeugen, dargestellt. Zudem werden die zum Verständnis der Arbeit notwendigen Grundlagen der in Kapitel 5 und 6 eingesetzten Verfahren zur Objektivierung (Modellbildung) kurz erläutert und beispielhafte Anwendungen aus dem relevanten Bereich erörtert. Die sich aus dem Stand der Forschung und Technik ergebenden Ziele der vorliegenden Arbeit werden in Kapitel 3 genannt. Kapitel 4 zeigt die reale und die virtuelle Entwicklungsumgebung, in der diese Arbeit durchgeführt wurde. In Kapitel 5 werden die Methode und das Ergebnis der Bildung von Kundenzielgruppen anhand objektiver fahrphysikalischer Kennwerte beschrieben. Inhalt von Kapitel 6 sind die durchgeführten Untersuchungen zum Anfahrkomfort und die dabei verwendeten Methoden, sowie die hieraus für die weitere Arbeit abgeleiteten Ergebnisse. Kapitel 7 beschreibt die Methoden und Ergebnisse der Modellbildung mittels multipler linearer Regression und mittels künstlicher neuronaler Netze. Anhand eines eingeführten Gütekriteriums erfolgt der Vergleich der mit diesen Methoden erreichten Approximations- und Prognosegüten, also der Fähigkeit, Komfortwerte aus zur Modellbildung verwendeten, als auch aus nicht zur Modellbildung verwendeten Objektivdaten, zu berechnen. Anhand der Variation der KNN-Parameter werden die wesentlichen Einflussfaktoren und deren Auswirkungen auf die Leistungsfähigkeit der KNN aufgezeigt und allgemeingültige Schlussfolgerungen formuliert. Die Anwendung der Modelle zur Beurteilung sowohl realer, als auch virtueller (simulierter) Anfahrten wird im Kapitel 8 gezeigt und diskutiert. Im abschließenden Kapitel 9 wird eine Zusammenfassung der Arbeit und ein Ausblick für die weitere Forschung gegeben.



## 2 Stand der Forschung und Technik

### 2.1 Subjektive Fahrkomfortbeurteilung

Im Bereich der Automobilentwicklung wird neben der Beurteilung aus technisch-wirtschaftlicher Sicht eine Beurteilung aus Komfortsicht im Hinblick auf eine möglichst optimale Erfüllung der Kundenwünsche – und die daraus resultierende Kundenzufriedenheit – immer wichtiger. Dies ist jedoch schwierig, da Komfort subjektiv unterschiedlich empfunden wird und ihn beschreibende Größen oftmals schwierig zu messen oder gar nicht bekannt sind. Aspekte der Komfortmessung im Innenraum eines Fahrzeugs bezüglich Klimakomfort, Luftqualität, Geräusch- und Schwingungskomfort (Noise Vibration Harshness, kurz NVH) beschreibt beispielsweise Gameiro Silva<sup>4</sup>.

#### 2.1.1 Subjektive Wahrnehmung und Urteilsbildung

Neben den vom Fahrzeug selbst erzeugten Störungen hat die Übertragungsfunktion des Fahrzeugs bezüglich der Umwelteinwirkungen einen Einfluss auf den von den Passagieren empfundenen Fahrkomfort. Solch eine Umwelteinwirkung ist beispielsweise die aus der Fahrbahnbeschaffenheit resultierende Anregung, welche über das Fahrwerk inklusive der Reifen und die Karosserie auf den Sitz, das Lenkrad, die Pedalerie und andere Bedienelemente übertragen wird und somit auf die Passagiere einwirkt.

Die Kombination der Ausprägung dieser Faktoren ist die Bewertungsgrundlage für die Fahrzeugnutzer. Der endgültige, subjektiv empfundene Komforteindruck ist dabei durch die Erfahrung und die persönlichen Neigungen der bewertenden Person geprägt. Mather<sup>5</sup> beschreibt den Gesamteindruck als multisensorische Wahrnehmung durch alle fünf Sinne. Diese sind das Sehen, Hören, chemische Sinne (Riechen und Schmecken), das vestibuläre System (Gleichgewicht) und das so-

---

<sup>4</sup> Gameiro Silva 2002

<sup>5</sup> Mather 2002

matische System (Berührung und Körperposition). Wie Bild 2.1 illustriert, stellt jedes System an sich einen eigenständigen Prozess dar, der eine komplexe Abfolge neuronaler Signalverarbeitungsschritte umfasst<sup>6</sup>.

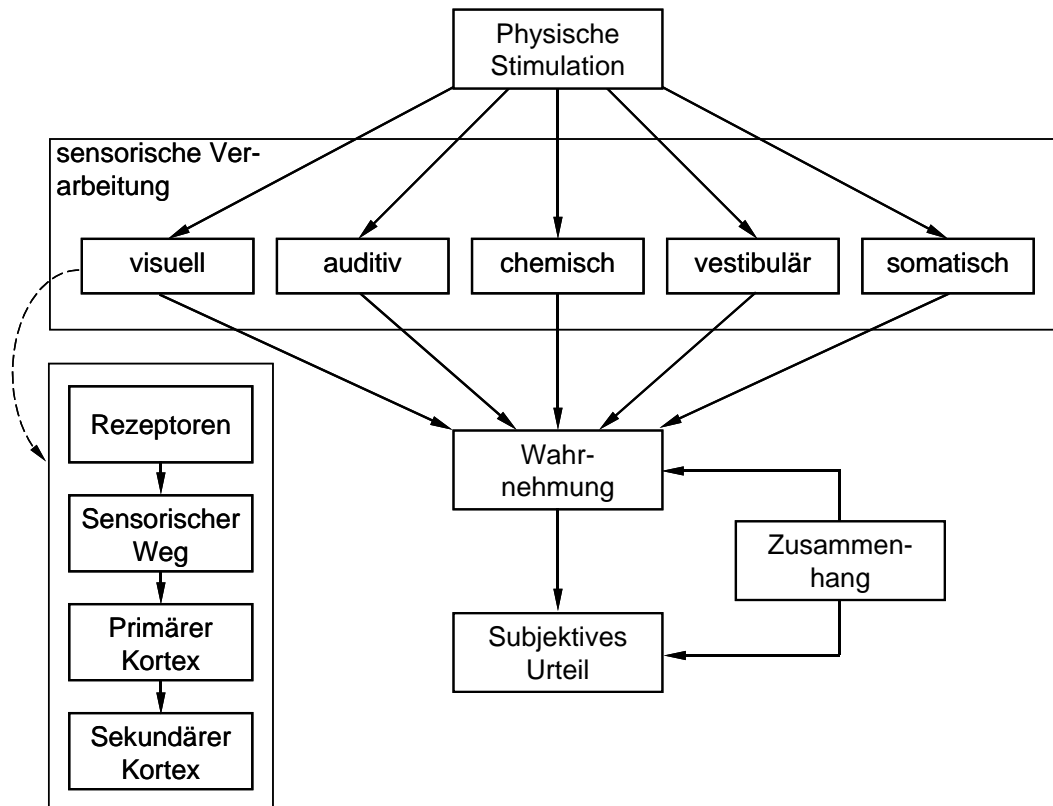


Bild 2.1: Phasen der Signalverarbeitung<sup>7</sup>

Beim Anfahrvorgang interessieren hauptsächlich die vestibuläre und die somatische Wahrnehmung. Speziell die visuelle und auditive Wahrnehmung sollen im Rahmen dieser Arbeit nicht in die Modellierung der Bewertung eingehen. Eine chemische Stimulation findet beim hier beschriebenen Anfahrvorgang höchstens in Extremfällen – durch Geruchsbildung bei Überbeanspruchung der Kupplung – statt und wird deshalb ebenso nicht betrachtet.

Küçükay und Gebert<sup>8</sup> geben für die Beurteilung des Schaltkomforts von PKW-Automatikgetrieben eine erfahrungsgemäße Gewichtung der verschiedenen Einflussfaktoren an und schreiben dem Verlauf der Fahrzeuglängsbeschleunigung während des Gangwechsels mit 50% den Hauptanteil zu. Als weitere Einflussfaktoren werden die Akustik (30%), die Schalthäufigkeit und das Ansprechverhalten (je 10%) quantifiziert. Da die beiden letztgenannten Kriterien für den hier untersuchten Anfahrvorgang nicht zutreffen darf vermutet werden, dass der prozentuale

<sup>6</sup> Siehe hierzu Purves et al 2001 - Unit II: Sensation and Sensory Processing

<sup>7</sup> Vgl. Mather 2002

<sup>8</sup> Küçükay / Gebert 1997

Einfluss der Fahrzeuglängsbeschleunigung hierbei eher noch höher liegt. Die in Kapitel 7 durchgeführte Modellierung der Anfahrkomfortbeurteilung basiert deshalb neben Objektivwerten für die Fahrereingabe ausschließlich auf Objektivwerten, welche die Fahrzeuglängsbeschleunigung charakterisieren.

### 2.1.2 Subjektive Komfortbeurteilung im Produktentstehungsprozess

Der hohe Aufwand, die Streuung der Subjektivität des menschlichen Komfortempfindens und die eingeschränkte Reproduzierbarkeit im Fahrversuch (Erreichen der Fahrvorgabe, Umwelteinflüsse, etc.) kennzeichnen die Schwierigkeiten der Ermittlung von Komforteigenschaften. Außerdem ist es nicht oder zumindest nur teilweise und mit sehr viel Erfahrung möglich, aus Messschrieben Komforteigenschaften abzuleiten. Aufgrund dieser Tatsachen gilt es, mittels geeigneter Methoden Ansätze zu entwickeln, welche die genannten Probleme kompensieren und den Produktentwicklungsprozess vereinfachen und beschleunigen.

Da Versuche mit Kunden oft schwierig und zur Erreichung einer statistisch gesicherten Aussage sehr aufwendig sind, übernimmt bei der Fahrzeugabstimmung üblicherweise ein Versuchsingenieur als „Experte“ die Beurteilungsfunktion des Kunden und versucht, das Komfortempfinden der jeweiligen Kundengruppe abzubilden. In der Praxis erfolgt die Komfortbewertung häufig im Rahmen einer Punktbewertung, welche die Beurteilung aus Kundensicht repräsentieren soll<sup>9</sup>. Ein wesentlicher Nachteil der beschriebenen Vorgehensweise ist die Tatsache, dass der bewertende Spezialist die zu repräsentierende Kundengruppe nur bedingt abbilden kann, da es schwierig ist, das individuelle Beurteilungsmuster des Experten gezielt an die Komfortschwelle eines Kunden anzupassen. Es darf angenommen werden, dass hierdurch zum Teil eine Optimierung in Bereichen und auf Anspruchsniveaus stattfindet, die nur noch von so wenigen Kunden überhaupt als störend wahrgenommen werden, dass die entstehenden Kosten sowie die zusätzlich benötigte Entwicklungszeit eventuell nicht gerechtfertigt sind.

Wie Riedel und Arbiger<sup>10</sup> zeigen, hat die Expertenbewertung im Gegensatz zur Laienbewertung durch Kunden jedoch den Vorteil der höheren Reproduzierbarkeit<sup>11</sup>. Weiterhin ist dem Experten zusätzlich zur reinen Komfortbewertung aufgrund seines Systemverständnisses eine differenziertere Bewertung möglich, indem er z. B. auch Einflüsse auf die Dauerhaltbarkeit eines Systems erkennen und

---

<sup>9</sup> Aigner 1982; Seebacher /Fidlin 2005. Siehe hierzu auch Bild 2.2 bis Bild 2.4

<sup>10</sup> Riedel / Arbiger 1997

<sup>11</sup> Die in Kapitel 6.4 vorgestellten Untersuchungen bestätigen dies ebenfalls

entsprechende Schlussfolgerungen ziehen kann. Außerdem ist der Experte eher als ein Laie in der Lage zu fokussieren, d. h. nur ein bestimmtes Phänomen zu beurteilen und andere Eindrücke auszublenden.

Nicht zu vergessen bei der Interpretation von Komfortbewertungen ist der Aspekt, dass eine Experten-Bewertung eine Markteinordnung zu einer bestimmten Zeit darstellt. Marktveränderungen und steigender Komfortanspruch führen dazu, dass ein Fahrzeug, das etwa vor 10 Jahren als akzeptabel beurteilt wurde, heute eventuell den Komforterwartungen nicht mehr gerecht wird.

### 2.1.3 Bewertungssysteme zur subjektiven Komfortbeurteilung

Die Erfassung eines Komfort- bzw. Diskomforturteils<sup>12</sup> kann auf unterschiedliche Arten erfolgen. In diesem Kapitel werden kurz einige gängige Verfahren genannt und die Vor- und Nachteile bezüglich ihrer Eignung zum Einsatz der im Rahmen dieser Arbeit durchgeführten Untersuchungen erläutert.

Indirekte Beurteilungsverfahren versuchen, Veränderungen des Beurteilers – etwa dessen Konzentrationsfähigkeit – zu erfassen und daraus auf den Einfluss der Störung, die durch das eigentlich zu bewertende komfortrelevante Phänomen entsteht, zu schließen. Meloni<sup>13</sup> untersucht beispielsweise mittels eines Simulators für Ganzkörperschwingungen den Einfluss von kombinierten Vibrations- und Schalleinwirkungen auf den Menschen. Aus der Auswirkung auf die feinmotorische Leistungsfähigkeit, die in Form einer Trackingaufgabe (Einfangen eines sich bewegenden Kreises am Monitor) sowie Nebenaufgaben (Gedächtnistest, Aufmerksamkeitsaufgabe) erfasst wird, werden indirekt Rückschlüsse auf die Beeinflussung des Wohlbefindens durch die eingeleitete Vibrations- und Schallanregung gezogen. Vorteil der indirekten Verfahren ist, dass sie kaum vom Beurteiler manipuliert werden können und sie somit ein unverfälschtes Urteil liefern. Nachteilig ist im Rahmen dieser Arbeit – neben dem enormen Aufwand – die Ablenkung von der Aufgabe, einen Anfahrvorgang als Fahrer aktiv auszuführen. Dies lässt sie für die vorgestellten Untersuchungen ungeeignet erscheinen.

Bei der Verwendung direkter Verfahren wird der Beurteiler gezielt nach seiner Empfindung bezüglich des untersuchten Phänomens befragt. Die Beurteilung in Form verbaler Aussagen kommt dem Menschen entgegen, da sie der gewohnten Art der Äußerung einer Beurteilung eines Eindrucks entspricht. Dieses Verfahren hat jedoch den entscheidenden Nachteil, dass die Beurteilungen nicht in einer für

---

<sup>12</sup> Eine tiefergehende Betrachtung und Definition findet sich in Kapitel 6.1

<sup>13</sup> Meloni 1991

die numerische Weiterverarbeitung brauchbaren Form vorliegen. Die persönliche Bewertung muss über eine Schätzsкала in eine verwendbare Form – also einen Zahlenwert – umgewandelt werden. Diese Vorabinterpretation und damit Vorabbewertung durch das Wandlungsverfahren nimmt jedoch Einfluss auf die Beurteilung. Für den klassischen Fragebogen, bei dem die Äußerung der Beurteilung in schriftlicher Form stattfindet, gilt dies ebenso. Durch die Verwendung von Fragebögen können die Beschreibungen aber auch z. B. in Form von Adjektiven vorgegeben und vom Beurteiler ausgewählt werden. Dies stellt den Übergang zur Verwendung von Punkte- oder Notenskalen dar. Eine Zuordnung von Punkten bzw. Noten ist jedoch stark von der Subjektivität der Beurteilung und vom Erfahrungsschatz des Bewerter abhängig. In der Praxis der Komfortbeurteilung eines Automobils in der Validierungsphase des PEP erfolgt die Bewertung von NVH-Phänomenen häufig durch Ingenieure als Experten im Rahmen einer Punktebewertung nach einer einfachen unipolaren 10-Anker-Skala. Diese soll die Beurteilung aus Kundensicht repräsentieren, wie dem folgenden Bild 2.2 entnommen werden kann. Nach Aigner<sup>14</sup> sind hier dem Bewertungsindex als Punktezahl die den jeweiligen Zustand beschreibenden Adjektive für Geräusch- bzw. Vibrationsbewertung, sowie der Grad der Feststellbarkeit durch Kunden, gegenübergestellt.

Bewertungsindex	nicht annehmbar				Grenzfall	annehmbar				
	1	2	3	4	5	6	7	8	9	10
Geräusche, Vibrationen	nicht annehmbar			unannehm	Verbesserung erforderlich	mäßig	leicht	sehr leicht	Spuren	keine
Festgestellt von	allen Kunden	Durchschnittskunden			kritischen Kunden			ausgebildeten Beobachtern	nicht wahrnehmbar	

Bild 2.2: Bewertungssystem mit einer zehnstelligen Skala<sup>15</sup>

Diese Skala ist Grundlage der Beurteilungsschemata vieler Automobil- und Komponentenhersteller, die oft firmenspezifisch angepasst sind. Im Folgenden werden hierfür in Bild 2.3 und Bild 2.4 beispielhaft zwei Bewertungsskalen dargestellt. Bild 2.3 zeigt ein Bewertungsschema der Fa. Freudenberg<sup>16</sup> zur Beurteilung von Schwingungsphänomenen, das sich in der Beschreibung eher an Schulnoten orientiert, sowie die sich daraus ergebende Kundenrelevanz.

<sup>14</sup> Aigner 1982

<sup>15</sup> Vgl. Aigner 1982

<sup>16</sup> Freudenberg Dichtungs- und Schwingungstechnik KG, Weinheim

Bewertungsindex	1	2	3	4	5	6	7	8	9	10
Bewertung	sehr schlecht	schlecht	unge-nügend	mangelhaft	unbe-friedigend	noch ak-zeptabel	be-friedigend	gut	sehr gut	ausge-zeichnet
Kundenrelevanz	Nicht mehr funktions-fähig	Nur noch bedingt funktionstüchtig	Von allen Kunden als schwerer Fehler reklamiert	Von allen Kunden als Fehler empfunden	Von allen Kunden als störend empfunden	Von einigen Kunden als störend empfunden	Von allen Kunden feststellbar	Nur von kritischen Kunden feststellbar	Nur von kritischen Beurteilern feststellbar	Von geübten Beobachtern nicht feststellbar

Bild 2.3: Bewertungssystem mit einer zehnstelligen Skala<sup>17</sup> (Quelle: Freudenberg)

Bei dem in Bild 2.4 dargestellten Beurteilungsschema der Fa. LuK<sup>18</sup> für Lastwechselschwingungen wird für die Kundenrelevanz ein prozentualer Anteil an zufriedenen Kunden als sehr exakte Definition angegeben.

Bewertungsindex	1	2	3	4	5	6	7	8	9	10
Lastwechselschwingungen	unerträglich	sehr schlecht	schlecht	minderwertig; mittelmäßig	an der Grenze	ausreichend	be-friedigend	gut	sehr gut	exzellent
Kundenrelevanz	Anteil der unzufriedenen Kunden (Fordern Reparatur; Kaufablehnung)			Anteil der durch den Fehler gestörten Kunden		Spezialisten				
	100%	80%	10%	50%	10%	üben noch Kritik	festzustellen, i. A. ohne zu kritisieren	nur einige machen noch Bemerkung	keine Kritik	

Bild 2.4: Bewertungssystem mit einer zehnstelligen Skala<sup>19</sup> (Quelle: LuK)

Die Grenzen variieren bei den gezeigten Bewertungsskalen leicht. Prinzipiell wird ein Kunde durch einen Bewertungsindex im Bereich bis 8 Punkte abgedeckt. Üblich ist es demnach, einen Bewertungsindex von 8 oder mehr Punkten anzustreben, da ab dieser Grenze selbst von kritischen Kunden keine Beeinträchtigungen mehr wahrgenommen werden.

Zwar ist ein Kunde (Laie) durchaus in der Lage, Komforteigenschaften aus seiner Sicht und anhand seines individuellen Anspruchs zu beurteilen, der Einsatz eines Experten-Bewertungsschemas ist hier jedoch nicht sinnvoll, da ein Erfahrungsschatz vorausgesetzt wird, der dem Laien i. A. nicht zugänglich ist und ihm somit die Referenzen zur Einordnung der Komforteigenschaften fehlen.

Jürgensohn<sup>20</sup> stellt unterschiedliche Bewertungsskalen vor, die sich in der Anzahl der Anker, in den verbalen Beschreibungen der Ankerpunkte und in der Visualisie-

<sup>17</sup> Freudenberg Dichtungs- und Schwingungstechnik KG, Weinheim

<sup>18</sup> LuK GmbH & Co. oHG, Bühl

<sup>19</sup> Vgl. auch Albers 1994

<sup>20</sup> Jürgensohn et al. 1996



rung unterscheiden. Als ein eher auf Funktionalität ausgerichtetes Beurteilungsschema nennt er die von Cooper und Harper<sup>21</sup> entwickelte Skala, die zur Beurteilung der Handlungseigenschaften von Verkehrsflugzeugen eingesetzt wird. Wie Bild 2.5 veranschaulicht erfolgt die Urteilsfindung hier in mehreren Stufen.

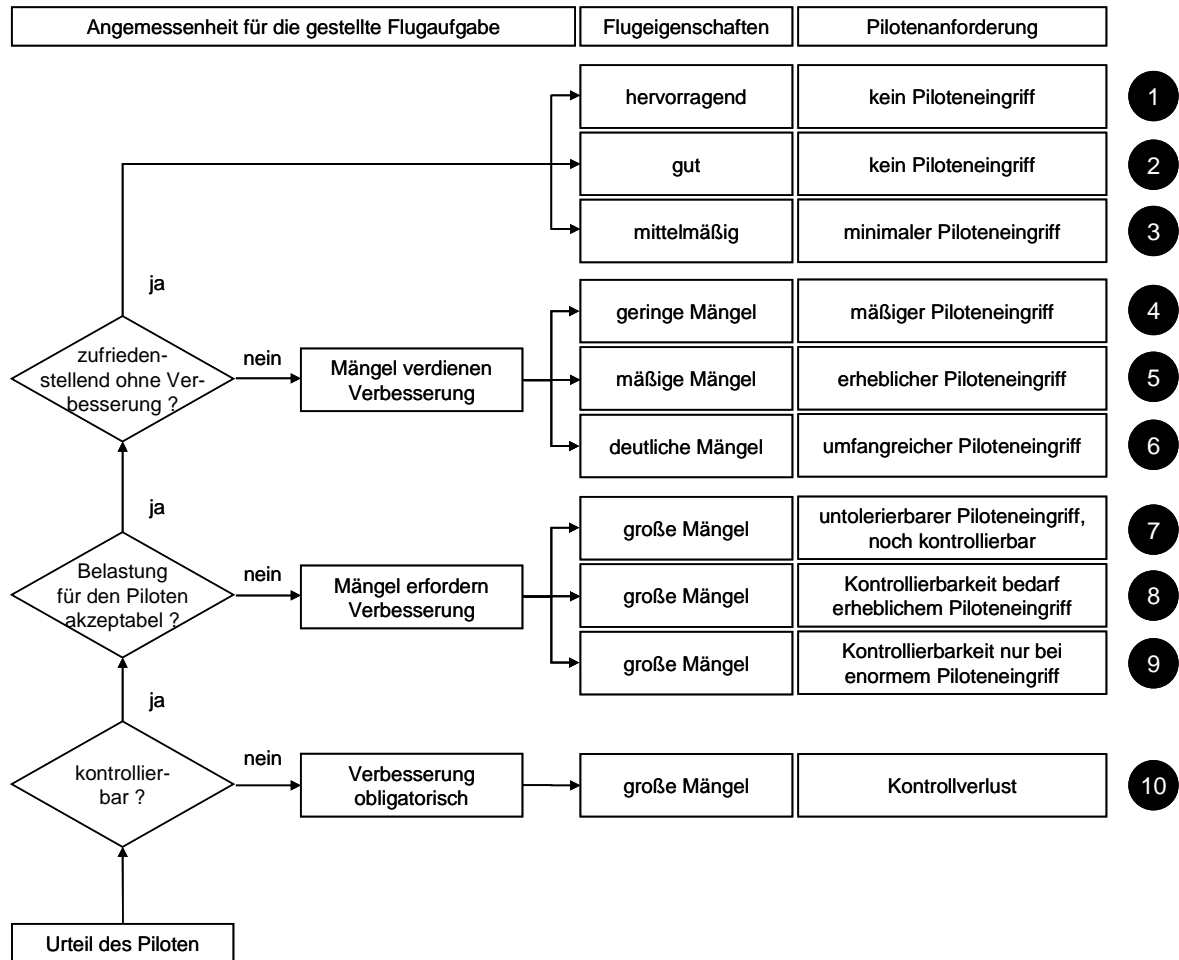


Bild 2.5: Bewertungssystem zur Flugzeugbeurteilung<sup>22</sup>

Zu beachten ist, dass hier im Gegensatz zu den zuvor gezeigten Bewertungsschemata eine niedrige Punktezahl den anzustrebenden Bereich beschreibt.

Daraus abgeleitet ist eine Zwei-Ebenen-Intensitätsskala (ZEIS), wie sie von Käßler<sup>23</sup> für die Fahrverhaltensbeurteilung durch Normalfahrer benutzt wird. Wie Bild 2.6 verdeutlicht erfolgt die Urteilsfindung hier durch eine erste Einteilung in einer übergeordneten und einer anschließende Konkretisierung in einer weiteren Ebene.

<sup>21</sup> Cooper / Harper 1969

<sup>22</sup> Vgl. Cooper / Harper 1969

<sup>23</sup> Käßler 1993




Bild 2.6: Zwei-Ebenen-Intensitätsskala ZEIS<sup>24</sup>

Die im Rahmen der vorliegenden Arbeit entwickelte Methode zur Beurteilung von Anfahrkomfort (siehe Kapitel 6.2.3) übernimmt die der ZEIS zugrunde liegende Idee der Gliederung der Skala in zwei Ebenen mit einer groben Einordnung im ersten und einer differenzierteren Beurteilung im zweiten Schritt.

## 2.2 Objektivierung durch Modellbildung

Ziel der Fahrzeugentwickler ist es, den Komforteindruck eines Beurteilers zu „objektivieren“, bzw. objektiv zu beschreiben, indem mittels mathematischer Verfahren Zusammenhänge zwischen subjektiv empfundenem Fahrkomfort und objektiv messbaren Größen hergestellt werden. „Objektivierung“ bedeutet in diesem Zusammenhang also Modellierung der menschlichen Komfortbeurteilung durch die Verknüpfung zweier Datenmengen, nämlich die der objektiven Messwerte mit der Menge der zugehörigen subjektiven Komforturteile, welche in komplexer Weise von diesen Größen abhängen. Untersucht wird das Vorliegen gesetzmäßiger Beziehungen zwischen den objektiven Variablen und der jeweiligen subjektiven Variable mit dem Ziel, diese modellhaft in Form von mathematischen Gleichungssystemen zu beschreiben. Mit Hilfe der Modellgleichungen wird es möglich, die Ausprägung der Kriteriumsvariablen (hier: Komforturteile) zu erschließen, obwohl man von diesen nur die Ausprägungen in den Prädiktorvariablen (hier: objektive Kennwerte) kennt. Ziel aller statistischen Analyseverfahren ist es, die Variation einer

<sup>24</sup> Käßler 1993

Kriteriumsvariablen durch eine Anzahl von Prädiktorvariablen zu erklären. Der Begriff „erklären“ bedeutet jedoch zunächst nicht, eine inhaltlich-kausale Begründung für den Zusammenhang zu geben – vielmehr ist gemeint, dass die Ausprägungen des Kriteriums mit den Ausprägungen der Prädiktorvariablen mit einer gewissen Genauigkeit vorhergesagt werden können. Dies gelingt umso besser, je besser der korrelative Zusammenhang zwischen Prädiktorvariablen und Kriteriumsvariablen ist.

In den Unterkapiteln 2.2.2 und 2.2.3 werden die allgemeinen Grundlagen und beispielhafte Untersuchungen der Objektivierung mittels des Standardverfahrens der schrittweisen multiplen linearen Regression, sowie mittels künstlicher neuronaler Netze beschrieben. Bevor jedoch eine Objektivierung stattfinden kann müssen Kenngrößen definiert werden, die das jeweilige untersuchte Phänomen objektiv beschreiben.

### **2.2.1 Objektive Kennwerte für den Anfahrvorgang**

Der Anfahrvorgang eines Fahrzeugs stellt einen meist schwingungsbehafteten Beschleunigungsvorgang dar, bei dem die entstehenden Fahrzeuglängsschwingungen in erster Linie über die Fahrzeugsitze und deren Sitzlehne auf die Insassen übertragen werden. Als Basis für die Ableitung charakteristischer Kennwerte, die einen schwingungsbehafteten Bewegungsvorgang beschreiben, dient üblicherweise das Beschleunigungssignal. Explizite Untersuchungen zur Objektivierung bzw. zur objektiven Beschreibung von Anfahrkomfort werden in der Literatur nicht erwähnt, es finden sich jedoch allgemeine Untersuchungen zum Thema Schwingungseinwirkung auf den Menschen, deren Erkenntnisse auf den hier untersuchten Anfahrvorgang übertragbar sind.

Bezüglich Ganzkörperschwingungen lassen sich einerseits Ansätze zur Beschreibung aus Sicht der Wirkung auf die Gesundheit (Arbeitsschutz), andererseits bezüglich der Wirkung auf das Wohlbefinden (Schwingungskomfort) unterscheiden. Untersuchungen hierzu finden häufig auf speziellen Prüfständen/Schwingstühlen statt, mit deren Hilfe die Impedanzfunktion des Menschen bezüglich der eingeleiteten Schwingungen ermittelt wird. Auf Basis umfangreicher experimenteller Untersuchungen mit ausschließlich sinusförmiger Anregung werden Maßstäbe in Form von Fühlschwellen und Frequenzbewertungsfunktionen angegeben, die sich auf die Einwirkung unterschiedlicher Schwingungsrichtungen und -arten sowie unterschiedliche Einleitungsstellen in den menschlichen Körper beziehen. Nationaler

Standard ist die Schwingungsbewertung mittels VDI-Richtlinie 2057<sup>25</sup>, weitere internationale Standards werden von Griffin<sup>26</sup> beschrieben. Am häufigsten werden Äquivalenzkurven vertikaler Schwingungen untersucht. Die Ergebnisse dieser Untersuchungen werden beispielsweise von Bellmann et al.<sup>27</sup> mit dem Schluss verglichen, dass hier „erhebliche Unterschiede der Literaturdaten untereinander zu erkennen“ sind. Bröde und Griefahn<sup>28</sup> untersuchen inter-axiale Schwingungen und kommen zu dem Ergebnis, dass ein Interaktionseffekt von Frequenz und Vibrationsrichtung besteht. Während sie keinen Einfluss des Geschlechts der Versuchspersonen feststellen, kommen beispielsweise Hintz et al.<sup>29</sup> zu der Erkenntnis, dass eine Unterscheidung in weibliche und männliche Probanden durchaus unterschiedliche Impedanzfunktionen liefert.

Die Bewertung einer Schwingung erfolgt im Frequenzbereich. Die in Bild 2.7 dargestellten Gewichtungskurven basieren auf den in der VDI-Richtlinie 2057 angegebenen Werten für die Frequenzbewertung einer sinusförmigen Anregung über einen ungedämpften und ungedämpften Sitz ( $W_d$ ) bzw. eine Rückenlehne ( $W_c$ ) in horizontaler x-Richtung, entsprechend der Fahrtrichtung eines Fahrzeugs. Diese Frequenzbewertungskurven sind Versuchsergebnisse, welche die Wahrnehmungsstärke der Schwingungen im Beanspruchungsbereich „Wohlbefinden“ beschreiben.

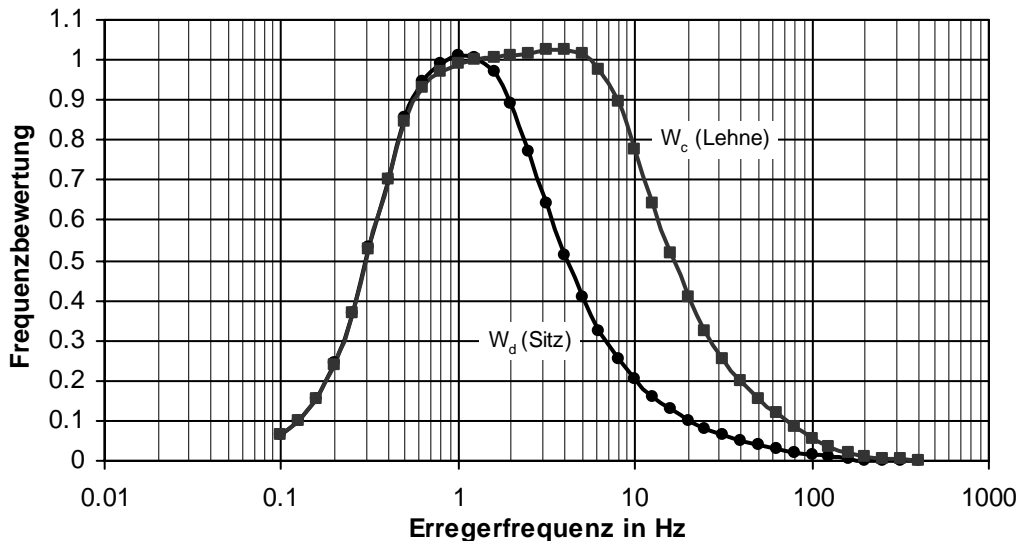


Bild 2.7: Frequenzbewertungen für Anregungen in x-Richtung<sup>30</sup>

<sup>25</sup> VDI-Richtlinie 2057 Blatt 1 (November 1999)

<sup>26</sup> Griffin 1990

<sup>27</sup> Bellmann et al. 2004

<sup>28</sup> Bröde / Griefahn 1996

<sup>29</sup> Hintz et al. 2004

<sup>30</sup> VDI-Richtlinie 2057 Blatt 1 (November 1999)

Legt man die für die Empfindlichkeit eines Messgeräts zur Messung einer Feldgröße als Abfall auf - 3 dB (entsprechend  $1/\sqrt{2} \approx 0.71$ ) definierte Grenzfrequenz zu Grunde, ist ein sitzender Mensch nach Bild 2.7 für Schwingungen, die über den Sitz mit einer Frequenz im Bereich um 0.4 bis 3 Hz eingeleitet werden, besonders empfindlich. Für die Empfindlichkeit gegenüber Schwingungen, die über die Lehne eingeleitet werden, gilt entsprechend der Frequenzbereich von 0.4 Hz bis 11 Hz als empfindlich.

Die Belastung des Körpers über eine definierte Schwingungsdauer wird allgemein durch den zeitlichen Effektivwert  $\tilde{a}_{wT}$  der frequenzbewerteten Beschleunigung  $a_w(t)$  als quadratischer (energieäquivalenter) Mittelwert berechnet zu

$$\tilde{a}_{wT} = \sqrt{\frac{1}{T} \int_0^T a_w^2(t) dt}, \quad \text{Gl. 2.1}$$

wobei T die Dauer der Messung ist. Die frequenzbewertete Beschleunigung  $\hat{a}_w(\omega)$  wird aus der in den Frequenzbereich transformierten Beschleunigung mit  $\hat{a}(\omega)$  als unbewerteter Beschleunigungsamplitude der Erregerkreisfrequenz  $\omega$ , durch Multiplikation mit der jeweiligen Gewichtungsfunktion  $W(\omega)$  zu

$$\hat{a}_w(\omega) = W(\omega) \cdot \hat{a}(\omega), \quad \text{Gl. 2.2}$$

berechnet und anschließend in den Zeitbereich zurücktransformiert.

Als Anhaltswerte für den Zusammenhang zwischen dem Effektivwert der frequenzbewerteten Beschleunigung und der subjektiven Wahrnehmung gelten nach VDI-Richtlinie 2057 die in Tabelle 2.1 angegebenen Grenzen.

$\tilde{a}_w$ in $\text{m/s}^2$	Beschreibung der Wahrnehmung
< 0.01	nicht spürbar
0.015	Wahrnehmungsschwelle
0.02	gerade spürbar
0.08	gut spürbar
0.315	stark spürbar
> 0.315	sehr stark spürbar

Tabelle 2.1: Zusammenhang zwischen bewerteter Beschleunigung und Beschreibung der Wahrnehmung<sup>31</sup>

<sup>31</sup> VDI-Richtlinie 2057 Blatt 1 (November 1999)

Die Effektivwertberechnung erfolgt aus dem Leistungsdichtespektrum  $\Phi_a(\omega)$  der unbewerteten Beschleunigung nach der Formel

$$\tilde{a}_w^2 = \int_0^{\infty} W^2(\omega) \cdot \Phi_a(\omega) d\omega. \quad \text{Gl. 2.3}$$

Das Leistungsdichtespektrum, oft auch als Spektrale Dichte (engl.: Power Spectral Density, kurz PSD) bezeichnet, stellt ein Maß für den Energieinhalt einer Schwingung dar<sup>32</sup>. Grundlage der Spektralen Dichte  $\Phi_a(\omega)$  ist der quadratische Mittelwert oder Effektivwert der Schwingungen. Theoretisch berechnet sich die spektrale Dichte der Funktion  $a(\omega)$  mit der reellen Amplitude  $\hat{a}(\omega)$  für die Versuchsdauer  $T$  nach der Formel

$$\Phi_a(\omega) = \lim_{T \rightarrow \infty} \frac{1}{T} [\hat{a}(\omega)]^2. \quad \text{Gl. 2.4}$$

Eine Möglichkeit zur Bildung der PSD ist es, die Funktion mit Hilfe der FFT in den Frequenzbereich zu transformieren und dort nach obiger Formel zu berechnen. Eine andere Möglichkeit – wie sie bereits in Voruntersuchungen zu dieser Arbeit vorgestellt wurde<sup>33</sup> – ist die Zerlegung der Zeitbereichskurve mit Bandpassfiltern der Filterbandbreite  $\Delta\omega$  in harmonische Schwingungen mit nachfolgender Bildung der einzelnen Effektivwerte nach

$$\Phi_a(\omega) = \lim_{\Delta\omega \rightarrow 0} \frac{1}{\Delta\omega} \left[ \lim_{T \rightarrow \infty} \frac{1}{T} \int_0^T a^2(t, \omega, \Delta\omega) dt \right]. \quad \text{Gl. 2.5}$$

Weiter gilt, dass für ein ausreichend kleines  $\Delta\omega$  das Leistungsspektrum  $\Phi_a(\omega)$  annähernd gleich dem Quadrat des Effektivwerts  $\tilde{a}(\omega, \Delta\omega)$  geteilt durch die Filterbandbreite  $\Delta\omega$  ist

$$\Phi_a(\omega) \approx \frac{\tilde{a}^2(\omega, \Delta\omega)}{\Delta\omega}. \quad \text{Gl. 2.6}$$

Wird nun die Filterbandbreite konstant gehalten, so ist das Quadrat des Effektivwerts annähernd gleich dem diskreten Leistungsspektrum mit der gewählten Filterbandbreite.

---

<sup>32</sup> Griffin 1990

<sup>33</sup> Albers / Albrecht 2002

Neben den genannten Effektivwerten wird in der Industrie zum Vergleich von Schwingungsbelastungen bei instationären Ereignissen häufig der von Griffin<sup>34</sup> vorgeschlagene Vibration Dose Value verwendet<sup>35</sup>. Dieser berechnet sich aus der frequenzbewerteten Beschleunigung nach dem „4. Potenz-Gesetz“ zu

$$\text{VDV} = \sqrt[4]{\int_0^T a_w^4(t) dt} . \quad \text{Gl. 2.7}$$

Mohr<sup>36</sup> nennt und diskutiert neben den genannten noch weitere Signalkennwerte zur Charakterisierung von Schwingungen.

Im Rahmen der Optimierung des Schaltkomforts von Automatikgetrieben führt Hagerodt<sup>37</sup> Untersuchungen zum Längsschwingempfinden auf einem Schwingprüfstand mit Fahrzeugsitz. Er kommt zu der Erkenntnis, dass „eine Filterung des Zeitverlaufs der Längsbeschleunigung zur sicheren Bestimmung von Kennparametern mit einem 10 Hz Tiefpassfilter erfolgen“ kann und „Kennparameter, die für eine Objektivierung des Schaltkomforts in der Frequenzebene gebildet werden (z. B. Effektivwerte), zwischen 2 und 9 Hz berechnet werden sollten“, da damit „alle Frequenzen berücksichtigt werden, die sich besonders stark auf die Schwingungswahrnehmung in Längsrichtung auswirken“. Die Bildung objektiver Kennwerte aus dem Längsbeschleunigungssignal erfolgt bei Hagerodt im Zeitbereich durch die Berechnung des negativen und des positiven Gradienten, des Spitze-Spitze Werts des tiefpassgefilterten Beschleunigungssignals, der Verzögerungszeit sowie der Schaltzeit. Im Frequenzbereich werden durch Bildung der Leistungsdichten Teileffektivwerte im Frequenzband zwischen 2 und 9 Hz für die Beschleunigung sowie zwischen 30 und 60 Hz für den Schalldruck gebildet.

Krüger<sup>38</sup> benutzt zur Bewertung von Rupfschwingungen anhand der gemessenen Verläufe der Getriebeeingangsdrehzahl während des Anfahrens die durch die Hüllkurven um die Rupfschwingung erzeugte Fläche, wie in Bild 2.8 dargestellt.

---

<sup>34</sup> Griffin 1990

<sup>35</sup> Vgl. auch Hennecke 1995

<sup>36</sup> Mohr 2004 (VDI-Humanschwingungen)

<sup>37</sup> Hagerodt 2003

<sup>38</sup> Krüger 2003




Bild 2.8: Hüllkurven zur Ermittlung des Flächenindexes<sup>39</sup>

Mit der oberen Hüllkurve  $n(t)_{oHK}$  und der unteren Hüllkurve  $n(t)_{uHK}$  berechnet sich der Flächenindex FL nach

$$FL = \int (n(t)_{oHK} - n(t)_{uHK}) dt. \quad \text{Gl. 2.8}$$

Die Zuordnung eines Flächenindexes zu einem Komforturteil findet hier nicht statt. Der Flächenindex wird vielmehr als einfach zu ermittelnde Größe eingeführt, die dem Ingenieur einen Zahlenwert für die augenscheinliche Beurteilung von Drehzahlverläufen bezüglich Kupplungsrupfen geben soll.

Im Folgenden werden verschiedene Ansätze der Objektivierung bzw. Modellierung im Bereich der Komforteigenschaften von Fahrzeugen erörtert.

## 2.2.2 Objektivierung mittels Korrelations- und Regressionsstatistik

Bei Untersuchungen zur Objektivierung von Fahreigenschaften hat sich eine Vorgehensweise etabliert, die mit Hilfe von Korrelations- und Regressionsstatistik einen Zusammenhang zwischen subjektiven Bewertungen und objektiv messbaren fahrphysikalischen Parametern sucht. Kudritzki<sup>40</sup> beschreibt den Prozess der Verknüpfung von objektiven Kennwerten und subjektivem Urteil allgemein und stellt fest, dass in der Regel einfache statistische Verfahren der ein- oder mehrdimensionalen Regressionsanalyse angewandt werden. Üblicherweise wird die Korrelation einzelner Messgrößen mit einem Fahrerurteil nachgewiesen und danach mittels der Methode der linearen Regression eine Formel aufgestellt, welche die Verknüpfung aller signifikanten Objektivwerte mit dem Fahrerurteil beschreibt. Chal-

<sup>39</sup> Krüger 2003

<sup>40</sup> Kudritzki 1995



len<sup>41</sup> prognostiziert jedoch, dass „wenn das oberste Ziel die exakte Vorhersage menschlicher Reaktionen mittels algorithmischer Analyse ist, wir feststellen sollten, dass dies in absehbarer Zeit wahrscheinlich nicht möglich sein wird.“

### 2.2.2.1 Allgemeine Grundlagen der multiplen linearen Regression

Das Rückführen von Bedingtem auf Bedingendes wird in der Statistik als Regression bezeichnet, wobei die Modellvorstellung über den Zusammenhang des Kriteriums mit den Prädiktorvariablen Regressionsmodell heißt. Die im Folgenden dargestellten Grundlagen sind größtenteils aus Moosbrugger<sup>42</sup> entnommen und stellen den Sachverhalt lediglich auszugsweise dar.

#### Zielvorgabe und Modellvorstellung

Das Bestreben geht dahin, als Regressionsmodell ein möglichst einfaches Modell – das lineare Modell – zu verwenden, welches die Kriteriumsvariable  $y_i$  in eine Linearkombination zu zerlegen versucht, nämlich in eine gewichtete Summe aus einem Sockelbetrag  $a_0x_{i0}$  (mit der Prädiktionskonstanten  $x_{i0} = 1$ ) und den Prädiktorwerten  $a_jx_{ij}$  in der Weise, dass nur ein möglichst geringer Unterschied besteht zwischen den tatsächlichen Werten der Kriteriumsvariablen

$$y_i = \sum_{j=0}^m a_j \cdot x_{ij} + \varepsilon_i \quad \text{Gl. 2.9}$$

und den durch das Modell vorhersagbaren Werten

$$\hat{y}_i = \sum_{j=0}^m a_j \cdot x_{ij} \quad \text{Gl. 2.10}$$

Der Unterschied wird als Fehlerwert

$$\varepsilon_i = y_i - \hat{y}_i \quad \text{Gl. 2.11}$$

bezeichnet. Um eine Linearkombination konkret bestimmen zu können, werden Gewichtungszahlen für die  $m+1$  Prädiktorvariablen  $x_j$  (mit  $j = 0, 1, \dots, m$ ) benötigt, welche als Modellparameter  $a_j$  bezeichnet werden. Ziel ist es, die Parameter  $a_j$  so zu berechnen, dass der Fehler  $\varepsilon_i$  – bzw. bei der Methode der kleinsten Quadrate der quadratische Fehler  $\varepsilon_i^2$  – minimal wird. Gesucht wird also

---

<sup>41</sup> Challen 2002

<sup>42</sup> Moosbrugger 1994

$$\sum_{i=0}^n \varepsilon_i^2 = \sum_{i=0}^n (y_i - \hat{y}_i)^2 \rightarrow \min. \quad \text{Gl. 2.12}$$

Der Regressionskoeffizient  $a_j$  gibt formal an, um wie viel sich  $y_i$  ändert wenn  $x_{i,j}$  um eine Einheit verändert wird. Um den Einfluss der einzelnen  $x$ -Variablen auf das Ergebnis zu vergleichen, können diese allerdings nicht benutzt werden, da die unabhängigen Variablen meist verschiedene Maßeinheiten und unterschiedliche Wertebereiche haben. Um deren Einfluss direkt vergleichen zu können werden standardisierte Koeffizienten  $\alpha_j$  eingeführt mit

$$\alpha_j = a_j \cdot \frac{SA_{x_j}}{SA_y}. \quad \text{Gl. 2.13}$$

Im Zähler steht die Standardabweichung  $SA_{x_j}$  der zu  $\alpha_j$  gehörenden  $x_j$ , im Nenner die Standardabweichung  $SA_y$  der abhängigen Variable  $y$ . Auf diese Weise lässt sich der Einfluss der einzelnen Koeffizienten auf einen Blick feststellen – größere  $\alpha_j$  bedeuten dabei größeren Einfluss auf das Endergebnis  $y$ . Leider wird aber der Einfluss dieser neuen Koeffizienten genau dann übermäßig stark gewichtet, wenn überdurchschnittlich starke Schwankungen der dazugehörigen Beobachtungen auftreten. In diesem Fall ist nämlich die Standardabweichung ungerechtfertigt hoch, und damit auch  $\alpha_j$ . Dies ist zugleich der Hauptkritikpunkt an der Standardisierung.

### Modellüberprüfung / Maß für die Modellgüte

Die Beurteilung der Güte des erstellten Modells (Regressionsgleichung) erfolgt anhand der zur Modellbildung verwendeten Daten. Als Gütemaß wird der Determinationskoeffizient<sup>43</sup>  $R^2$  verwendet, der sich mit dem Mittelwert  $\bar{y}$  berechnet zu

$$R^2 = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2}. \quad \text{Gl. 2.14}$$

Der Determinationskoeffizient nimmt Werte zwischen null und eins an, wobei die Vorhersage der  $y$ -Werte umso besser erfolgt, je näher er sich dem Wert eins nähert. Durch Heranziehen von neuen unabhängigen Variablen kann das Bestimmtheitsmaß erhöht werden, ohne dass sich die Modellqualität tatsächlich erhöht. Um dies zu vermeiden wird das korrigierte Maß  $R^2_{\text{korrr}}$  eingeführt, welches sich wie folgt berechnet zu

---

<sup>43</sup> Auch Bestimmtheitsmaß genannt

$$R^2_{\text{korrr}} = R^2 - \frac{n_p \cdot (1 - R^2)}{n_B - n_p - 1} . \quad \text{Gl. 2.15}$$

Hierbei beschreibt  $n_B$  die Anzahl der Beobachtungen und  $n_p$  die Anzahl der unabhängigen Variablen. Dieses korrigierte Bestimmtheitsmaß verliert die Tendenz von  $R^2$ , bei Hinzunahme einer unabhängigen Variable unabhängig von einer Erhöhung der Modellqualität größer zu werden. Für dieses Maß gilt ebenso, dass die Approximation der tatsächlichen  $y$ -Werte umso besser ist, je näher es dem Wert eins ist.

### **Modellwahl / Schrittweise Regression**

Vor allem die „schrittweise Regression“ hat sich zur Findung robuster Regressionsmodelle bewährt. Man unterscheidet hierbei zwei prinzipielle Vorgehensweisen. Die Rückwärtselimination beginnt mit einer vollständigen Regressionsgleichung, in der alle Variablen enthalten sind. „Es wird dann überprüft, welche Prädiktorvariable gegenüber den restlichen Prädiktorvariablen die geringste Nützlichkeit aufweist<sup>44</sup>.“ „Bei der Vorwärtsselektion werden die Prädiktorvariablen sukzessive in die Regressionsgleichung aufgenommen, wobei sich die Abfolge der Variablen nach ihrer Nützlichkeit richtet, „und zwar so, dass zunächst keine, zum Schluss entweder alle Prädiktorvariablen oder alle diejenigen, die ein bestimmtes Aufnahmekriterium erfüllen, in der Gleichung enthalten sind<sup>45</sup>.“ Die Relevanz (Nützlichkeit) wird über den Umweg der Nullhypothese bestimmt. „Die Nullhypothese ist eine Negativhypothese, mit der behauptet wird, dass die zur Alternativhypothese komplementäre Aussage richtig sei. Sie stellt in der klassischen Prüfstatistik die Basis dar, von der aus entschieden wird, ob die Alternativhypothese akzeptiert werden kann oder nicht“<sup>46</sup>. Die Daten werden daraufhin untersucht, wie groß die Wahrscheinlichkeit ist, dass die Nullhypothese zutrifft. Ist sie zu gering, wird sie zugunsten der alternativen Hypothese verworfen. Dies bedeutet, man gibt die Nullhypothese auf, sobald die maximale Irrtumswahrscheinlichkeit für ihre Gültigkeit weniger als ein gewähltes Signifikanzniveau  $\alpha$  (in der Regel 5%) beträgt. Die Wahrscheinlichkeit für die Gültigkeit der Alternative wird hierbei nicht untersucht! Sie kann irgendwo zwischen 100% und  $\alpha$  liegen. Üblicherweise wird die Überprüfung für die Vorhersagekraft der gesamten Regressionsfunktion mittels eines F-Tests durchgeführt. Dabei wird getestet, ob alle im Modell enthaltenen unabhängigen Variablen gemeinsam keinen Einfluss auf die abhängige Variable ausüben. Dies geschieht durch den Vergleich der beiden Stichproben nach folgender Gleichung

---

<sup>44</sup> Bortz 1997

<sup>45</sup> Werner 1997

<sup>46</sup> Bortz 1993

$$F = \frac{R^2 / n_p}{(1 - R^2) / (n_D - n_p - 1)} \quad \text{Gl. 2.16}$$

Dabei ist  $R^2$  das Bestimmtheitsmaß,  $n_D$  die Anzahl der unabhängigen Datensätze und  $n_p$  die Anzahl der Prädiktorvariablen.

Die Überprüfung der Nützlichkeit kann für jede Prädiktorvariable mittels eines t-Tests erfolgen. Alternativ kann der Regressionkoeffizient der zu überprüfenden Prädiktorvariablen auf null gesetzt werden und dann der t-Wert für diese durch den Zusammenhang  $t^2 = F$  berechnet werden. Übersteigt der berechnete t-Wert den „kritischen t-Wert“, entsprechend dem gewählten Signifikanzniveau  $\alpha$ , so wird die Prädiktorvariable als nützlich eingestuft. Für die Nützlichkeit wird in Statistikprogrammen häufig der p-Wert angegeben. Dieser gibt für die betrachtete Prädiktorvariable an, wie hoch die Wahrscheinlichkeit ist, dass das Regressionsmodell das Kriterium vorhersagen kann, wenn der zugehörige Regressionskoeffizient den Wert null annimmt. Damit ist der p-Wert ein Indikator für die Wichtigkeit der Prädiktorvariablen für die Regressionsvorhersage.

### **Einschränkungen der multiplen linearen Regression**

Der p-Wert ist ein Indikator für die Wichtigkeit der Prädiktorvariablen für die Regressionsvorhersage, in der Objektivierung der Komfortbeurteilung eines Anfahrvorgangs gleichzusetzen mit einer für den Bewerter wichtigen Einflussgröße. An dieser Stelle sei noch einmal darauf hingewiesen, dass „statistische Signifikanz nicht unbedingt auch praktische Relevanz“ bedeutet<sup>47</sup>. Ein geringer p-Wert kann zwar als signifikant angesehen werden, jedoch kann auch eine Prädiktorvariable mit einem sehr hohen p-Wert signifikant sein, wenn der Datensatz multikollinear ist, d. h. zwei oder mehrere Prädiktorvariablen linear voneinander abhängen. „Die Entscheidung darüber, welche Teilmenge von Prädiktorvariablen als die beste anzusehen ist, wird häufig vom Zufall bestimmt. Die Bedeutung einer Prädiktorvariablen bzw. ihre Nützlichkeit ist bei hoher Multikollinearität in starkem Maße davon abhängig, welche Prädiktorvariablen schon (bei der Vorwärts-Technik) oder noch (bei der Rückwärts-Technik) im Regressionsmodell enthalten sind.“<sup>48</sup>

Beim Einsatz der multiplen linearen Regressionsanalyse wird bereits im Voraus die Annahme getroffen, dass auch tatsächlich ein linearer Zusammenhang zwischen Kriterium und Prädiktorvariablen besteht. Dabei ist die Linearität oftmals nicht gegeben und lineare Verfahren eignen sich in diesen Fällen dementsprechend schlecht zur Modellierung. Gerade bei der Abbildung der Komfortbeurtei-

<sup>47</sup> Bender / Lange 2001

<sup>48</sup> Bortz 1993

lung durch den Menschen, also eines hochgradig nichtlinearen Zusammenhangs, ist diese Annahme sicherlich falsch.

### 2.2.2.2 Beispielhafte Untersuchungen

In der Literatur finden sich zahlreiche Arbeiten, die sich mit der Objektivierung querdynamischer Fahreigenschaften beschäftigen.

Dibbern<sup>49</sup> beispielsweise untersucht das Kurvenverhalten von Fahrzeugen (Stationäre/instationäre Kreisfahrt, Bremsen in der Kurve, Lastwechselreaktion in der Kurve), das Übergangsverhalten (Lenkwinkelsprung, Einzelsinus-Lenkwinkeleingabe, Doppelter Fahrspurwechsel), das Geradeausverhalten (Geradeauslauf, Seitenwindverhalten) und das Wechselkurvenverhalten (Dauersinus, stochastische Lenkwinkeleingabe, Dreiecksimpuls). Dabei erfolgt die Beurteilung einzelner Kriterien wie Ansprechverhalten, Zielgenauigkeit, Größe des Lenkrad-Drehwinkels und -moments, Gefühl für Fahrbahnkontakt, Größe des Wankwinkels sowie Nachschwingungen durch 15 „Durchschnittsfahrer“ nach einer Skala ähnlich Schulnoten. Die Parametervariation erfolgt durch Zusatzgewichte an unterschiedlichen Fahrzeugpositionen und eine Variation der Reifengrößen vorne und hinten. Mittels schrittweiser linearer Vorwärts-Regression wird ein sog. KD-Wert (Kennwert Doppelter Fahrspurwechsel) ermittelt, der proportional zur ermittelten Note ist.

Riedel und Arbinger<sup>50</sup>, um ein weiteres Beispiel zu nennen, untersuchen in einer FAT<sup>51</sup>-Studie die Objektivierung der Fahreigenschaften beim doppelten Fahrspurwechsel sowie bei einer realen Überlandfahrt durch 38 „Normalfahrer“ und 12 „Profifahrer“ mit einem aufwendigen Fragebogen. Die Parametervariation am Versuchsfahrzeug besteht in der Verwendung unterschiedlicher Reifen, Reifendrücke und Dachlasten. Mittels schrittweiser linearer Vorwärtsselektion und auch Rückwärtselimination erfolgt die Identifikation der signifikanten Eingangsgrößen als objektive Kennwerte.

Zahlreiche weitere Beispiele für die Objektivierung querdynamischer Fahreigenschaften finden sich u. a. bei Neukum<sup>52</sup>. Sie betrachtet diese Ansätze kritisch und stellt fest, dass „das Ende der 60er Jahre formulierte Ziel, die subjektive Beurteilung von Fahreigenschaften durch objektive fahrdynamische Kriterien zu ergänzen, wenn nicht sogar weitgehend zu ersetzen, bis dato jedoch nicht erreicht“ ist. Sie stellt insbesondere fest, dass Untersuchungen „mit Normalfahrern bisher meist

---

<sup>49</sup> Dibbern 1991

<sup>50</sup> Riedel / Arbinger 1997

<sup>51</sup> Forschungsvereinigung Automobiltechnik e.V. (FAT)

<sup>52</sup> Neukum 2002

nicht die gewünschten Erfolge erzielen“. Als Grund hierfür führt sie an, dass der Einfluss bzw. die Varianz von Beurteiler und Fahrzeug statistisch konfundiert, also vermischt, wird. Ein niedriges Komforturteil kann demnach einerseits durch ein tatsächlich unkomfortables Fahrzeug, andererseits aber auch durch einen sehr kritischen Kunden bzw. einen Kunden, der eine abweichende Komforterwartung hat und demnach nicht zur Zielgruppe gehört, entstehen. Eine gesicherte Aussage ist nur durch die Kenntnis über den Komfortanspruch (kritischer/unkritischer Kunde, Zielgruppe) jedes einzelnen Bewerter und individuelle Betrachtung der Fahrer zu erlangen. Als grundsätzliches Problem bei der Untersuchung von Querdynamikeigenschaften mit Normalfahrern nennt sie zudem, dass die Fahrzeugvarianz vom Fahrer häufig nicht ausgenutzt wird. Ein Normalfahrer kann ein Fahrzeug nur in Ausnahmefällen wie ein Versuchingenieur im Grenzbereich bewegen und wenn doch, so kann er zumindest keine zuverlässige Bewertung über diesen Zustand abgeben. Dieser Kritikpunkt ist beim in dieser Arbeit untersuchten Anfahrvorgang jedoch nicht gültig.

Im Hinblick auf längsdynamische Fahreigenschaften/NVH finden sich Arbeiten zum Thema Objektivierung des Schaltkomforts auf Basis einer Expertenbeurteilung. Küçükay und Gebert<sup>53</sup> stellen ein Verfahren zur Objektivierung der Schaltkomfortbeurteilung vor, das auf einem Modellansatz mit quadratischer Regression beruht. Hagerodt<sup>54</sup> baut hierauf auf und beschreibt die Objektivierung als Grundlage einer automatisierten Optimierung des Schaltkomforts von Automatikgetrieben. Er bezieht sich auf Untersuchungen zum Thema Ruckeln und zum Thema Schalten. Einige grundlegende Überlegungen zur Modellierung der Komfortbeurteilung bezüglich des Schaltkomforts lassen sich auf die Modellierung des Anfahrkomforts übertragen und werden an den entsprechenden Stellen in dieser Arbeit diskutiert.

Allen vorgestellten Untersuchungen ist gemein, dass bei der Betrachtung der erreichten Modellgüten nur die Modellbildung, also die Approximation der zur Modellbildung verwendeten Daten, verwendet werden. Die Modellanwendung auf nicht zur Modellbildung verwendete Daten (Prognose) findet nicht statt. Die Modellüberprüfung erfolgt also immer in Bezug auf Approximationsfähigkeit und nicht auf Prognosefähigkeit, wie sie in der vorliegenden Arbeit untersucht wird.

---

<sup>53</sup> Küçükay / Gebert 1997

<sup>54</sup> Hagerodt 2003

### 2.2.3 Objektivierung mittels künstlicher neuronaler Netze

Während die mathematischen Verfahren der Korrelations- und Regressionsstatistik bereits bewährte Verfahren zur Erstellung von Objektivierungsmodellen darstellen, war der Anwendungsbereich künstlicher neuronaler Netze lange Zeit auf reine Mustererkennungsaufgaben beschränkt.

#### 2.2.3.1 Allgemeine Grundlagen künstlicher neuronaler Netze

In diesem Unterkapitel erfolgt eine allgemeine Beschreibung der Grundlagen künstlicher neuronaler Netze. Eine detailliertere Betrachtung der im Rahmen dieser Arbeit eingesetzten KNN findet sich in Kapitel 7.5.1.

##### Historie und biologische Motivation

Künstliche neuronale Netze entstanden ursprünglich durch stark vereinfachende Analogiebildung zum menschlichen Nervensystem und damit zum menschlichen Gehirn. Die Forschungsaktivitäten lassen sich jedoch in zwei Bereiche unterteilen. Zum einen gibt es den biologisch motivierten Ansatz, der das menschliche Gehirn auf der biophysikalischen Ebene zu modellieren versucht. Dieser originäre Versuch wurde bereits in den 1940er Jahren durch die ersten Untersuchungen von McCulloch und Pitts<sup>55</sup> verfolgt. Zum anderen wird ein Großteil der Anstrengungen darauf verwandt, die Eigenschaften von neuronalen Netzmodellen informationstechnisch zu nutzen und weiterzuentwickeln. Diese Forschungsdisziplin hat daher nicht primär zum Ziel, das Verständnis der Informationsverarbeitung im Gehirn zu vertiefen, weshalb in diesem Zusammenhang auch von künstlichen neuronalen Netzen, KNN (Artificial Neural Nets, ANN) gesprochen wird. Dieser zweite Ansatz hat durch die Arbeiten von Werbos<sup>56</sup>, Hopfield<sup>57</sup>, Rumelhart und McClelland<sup>58</sup> und anderen in den 1970/80er Jahren eine Renaissance erfahren, die bis heute anhält. Ziel war demnach nicht die exakte Nachbildung des biologischen Vorbilds, sondern ein Modell, das die wesentlichen Funktionscharakteristika eines biologischen Neurons erfüllt. Nach heutigen Erkenntnissen ist jedes biologische Neuron ein äußerst komplexes dynamisches System, welches – wenn man es denn vollständig kennen würde – so aufwendig zu simulieren wäre, dass selbst heutige Computer dafür kaum ausreichen würden. Allein schon die geometrische Form einer Zelle genau zu beschreiben, ist fast unmöglich. Bedenkt man ferner, dass ein Mensch in der Größenordnung von  $10^{10}$  bis  $10^{11}$  Neuronen besitzt, wovon jedes Neuron im

---

<sup>55</sup> McCulloch / Pitts 1943

<sup>56</sup> Werbos 1974

<sup>57</sup> Hopfield 1982

<sup>58</sup> Rumelhart / McClelland 1986

Durchschnitt mit  $10^4$  Synapsen verbunden ist, so wird der Abstand bzw. Unterschied zu den künstlichen neuronalen Netzen deutlich. Weiterhin ist auch die Interaktion der neuronalen Zellen untereinander noch nicht endgültig verstanden<sup>59</sup>. Was fehlt ist ein exaktes, quantitativ korrektes, informationsverarbeitendes Modell für neuronale Zellen und für das gesamte Nervensystem. Ansätze zum Verständnis der Informationsverarbeitung und Arbeitsweise des menschlichen Gehirns sind nach wie vor Gegenstand wissenschaftlicher Untersuchungen<sup>60</sup>. Unabhängig von diesen Unzulänglichkeiten kann man KNN aber aus informationstheoretischer Sicht betrachten und sich auf ihre Eigenschaften beschränken, die im folgenden Abschnitt vorgestellt werden.

### Bestandteile neuronaler Netze

Wie sein Vorbild ist auch das KNN aus sog. Neuronen aufgebaut. Das formale künstliche Neuron ist wie das biologische Neuron durch Eingänge (Dendriten), Verbindungen (Synapsen), Aktivierung (Zellkörper) und Ausgang (Axon) gekennzeichnet. Einen direkten Vergleich der Bestandteile biologischer und künstlicher formaler Neuronen zeigt Bild 2.9.




Bild 2.9: Bestandteile des biologischen (links) und des künstlichen Neurons (rechts)

Die Eingangssignale können von der Umgebung oder vom Ausgang eines anderen künstlichen Neurons stammen. Jeder Verbindung in einem KNN ist eine reelle Zahl als Gewicht  $w_i$  zugeordnet, welche die Stärke der Verbindung beschreibt. Der Netto-Input  $\text{net}$  entspricht der Summe der gewichteten Eingangssignale  $i_i$  gemäß

<sup>59</sup> Rojas 1993

<sup>60</sup> Taylor 2000



$$\text{net} = \sum_i w_i \cdot i_i . \quad \text{Gl. 2.17}$$

Die Aktivierungsfunktion  $f(\text{net})$  bestimmt, abhängig vom Netto-Input, den Output  $y$  des Neurons. Dieser Output kann wiederum das Eingangssignal für ein anderes Neuron oder das Ausgangssignal des KNN sein.

Anschaulich lässt sich die Arbeitsweise eines künstlichen Neurons wie folgt beschreiben: „Die Verbindungen eines Neurons nehmen Aktivierungen  $x_i$  mit bestimmten Verstärkungen  $w_i$  auf, summieren diese und lassen am Ausgang  $y$  des Neurons eine Aktivität entstehen, sofern die Summe vorher einen Schwellwert überschritten hat“<sup>61</sup>. Diese Aussage gilt streng nur für binäre Neuronen, die sich – wie biologische Neuronen – gemäß einer Sprungfunktion verhalten. Da die Sprungfunktion jedoch nicht stetig ist und dies bei der Differenziation in einem Trainingsalgorithmus Probleme verursacht, werden üblicherweise sigmoide Funktionen als Aktivierungsfunktion künstlicher Neuronen verwendet. Damit hängt die Ausgabe von einer Verstärkung ab und ist nur im Extremfall null oder eins.

Neuronale Netze, wie sie im Rahmen dieser Arbeit untersucht wurden, bestehen aus einer Zusammenschaltung einzelner Neuronen. Jede Einheit für sich genommen leistet nur eine vergleichbar einfache Rechenoperation. Erst die Kombination vieler Einheiten, gepaart mit einem Algorithmus zur Veränderung der die Einheiten bestimmenden Parameter, gestattet es, sie zur Lösung unterschiedlichster, auch komplexer Probleme, einzusetzen.

### **Eigenschaften neuronaler Netze**

Die wichtigsten Eigenschaften von KNN, welche zum Verständnis der Arbeit notwendig sind, sollen im Folgenden in Anlehnung an Fanghänsel<sup>62</sup> kurz aufgeführt werden:

- Modellfreiheit

Im Gegensatz zu analytischen Verfahren bieten KNN einen modellfreien Ansatz, um Probleme zu lösen. Dieser Umstand wirkt sich als Vorteil aus, wenn entweder kein Wissen existiert, um eine modellbasierte Problemlösung zu erstellen, oder aber ein vorhandenes Modell zu kompliziert oder rechenaufwendig ist. Als Kehrseite ergibt sich, dass man erfolgreich trainierten KNN im Allgemeinen keine Regeln entnehmen kann, um Rückschlüsse auf ein mögliches Modell zu erhalten.

---

<sup>61</sup> Brause 1995

<sup>62</sup> Fanghänsel 2001

- Lernen anhand von Beispielen bzw. Mustern

KNN werden durch einen Trainingsvorgang an das gegebene Problem angepasst, wobei dem Netz bei jedem Trainingsschritt ein Mustervektor präsentiert wird. Es gibt zwei verschiedene Lernparadigmen: Beim überwachten Lernen (Supervised Learning) existiert zu jedem Mustervektor ein Zielvektor, der die Soll-Ausgabe des Netzes angibt und zur Korrektur der internen Netzparameter eingesetzt wird. Beim unüberwachten Lernen (Unsupervised Learning) lässt man das Netz selbsttätig nach Ähnlichkeiten innerhalb der Menge von Mustervektoren suchen. Der Vorteil beim Lernen anhand von Beispielen liegt darin, dass es bei vielen praktischen Applikationen relativ leicht ist, Muster- und Zielvektoren zu erzeugen, wohingegen das Formulieren von charakteristischen Merkmalen innerhalb der Muster nicht oder nur sehr schwer möglich ist.

- Adaption und Generalisierungsfähigkeit

In Erweiterung der oben genannten Eigenschaften bieten KNN nicht nur die Möglichkeit, trainierte Beispiele wieder zu erkennen, sondern auch die Fähigkeit, eine Generalisierung vorzunehmen, d. h. Muster zu klassifizieren, die den Trainingsmustern ähnlich sind.

- Langsame Lern- aber schnelle Arbeitsphase

Als Folge des Lernens anhand von Beispielen ergibt sich, dass der Trainingsvorgang meist sehr rechenintensiv ist und daher vergleichsweise viel Zeit benötigt. Im Gegensatz zu der langsamen Lernphase ist die Arbeitsphase des Netzes, in der das trainierte Netz auf unbekannte Muster angewendet wird, typischerweise um Größenordnungen schneller.

- Implementierung

Wenn auch eine Hardwareimplementierung die eigentlich bessere, weil schnellere Lösung bietet<sup>63</sup>, wird in der Praxis vorwiegend der klassische Universalrechner (PC) eingesetzt, obwohl er von seiner Architektur her nicht besonders gut geeignet ist, um neuronale Netze zu simulieren. Die von ihm zur Verfügung gestellte Rechenleistung, der hohe Verbreitungsgrad und nicht zuletzt die Flexibilität bei der Realisierung unterschiedlicher Arten von neuronalen Netzen geben ihm häufig den Vorzug gegenüber speziellen Hardwareimplementierungen.

- Trial and Error

Für die Anwendung von neuronalen Netzen gibt es kein universelles Vorgehenskonzept. Abhängig von der jeweiligen Aufgabenstellung muss eine problemangepasste Lösung gesucht werden.

---

<sup>63</sup> Riemschneider 1996

## Arbeitsweise und Lernregeln

Die Arbeitsweise eines KNN gliedert sich in das Training und die anschließende Anwendung. Das Training erfolgt mittels Trainingsalgorithmen, welche auf unterschiedlichen Lernregeln basieren. Die wichtigsten von ihnen sind:

- Überwachtes Lernen – korrigierende Lernregel

Dieses Verfahren basiert auf der biologischen Beobachtung, dass Verbindungen zwischen aktiven Neuronen verstärkt werden (Hebbs Lernregel)<sup>64</sup>. Auf das Computermodell übertragen heißt dies, dass Netzwichte zwischen aktiven Neuronen vergrößert und zwischen inaktiven verkleinert werden. Durch diese korrigierende Lernregel lassen sich aus den Vergleichen der Soll- mit den Ist-Ausgaben des Netzes über ein Gradienten-Abstiegsverfahren Fehlerterme berechnen, die zu einer Korrektur der Netzparameter genutzt werden können. Der Backpropagation-Algorithmus ist ein Vertreter, der diese Lernregel verwendet (vgl. Kapitel 7.6.1.4).

- Unüberwachtes Lernen – konkurrierende Lernregel

Bei diesem Lernverfahren konkurrieren alle Neuronen untereinander. Nach dem Prinzip „Winner Take All“ wird nur das stärkste Neuron ausgewählt und angepasst. Als Abwandlung kann auch eine kleine, dem stärksten Neuron benachbarte Menge von Neuronen verändert werden, oder aber die nicht ausgewählten Neuronen werden zusätzlich abgeschwächt.

## Netztopologien

Um einen Überblick über die verschiedenen Arten von KNN zu erlangen, kann man sie nach unterschiedlichen Gesichtspunkten einteilen. Neben der Unterscheidung nach dem zu Grunde liegenden Lernparadigma oder der verwendeten Lernregel kann man sie auch nach deren Topologie klassieren, wie dies in Bild 2.10 dargestellt ist. Danach lassen sich vorwärtsgerichtete und rückgekoppelte Netze unterscheiden. In vorwärtsgerichteten Netzen erfolgt der Signalfluss in der Arbeitsphase nur in eine Richtung, so dass bei der Anordnung der Neuronen in verschiedene Ebenen eine Ebene nur auf die folgenden, nicht aber auf die vorhergehenden einwirken kann. Rückgekoppelte Netze erlauben einen beliebigen Signalfluss, also vor allen Dingen auch eine Rückwirkung auf Neuronen in vorhergehenden Ebenen. Netze mit Verbindungen zu Neuronen in der gleichen Ebene, zählen dabei ebenfalls zu den rückgekoppelten Netzen.

---

<sup>64</sup> Hebb1949

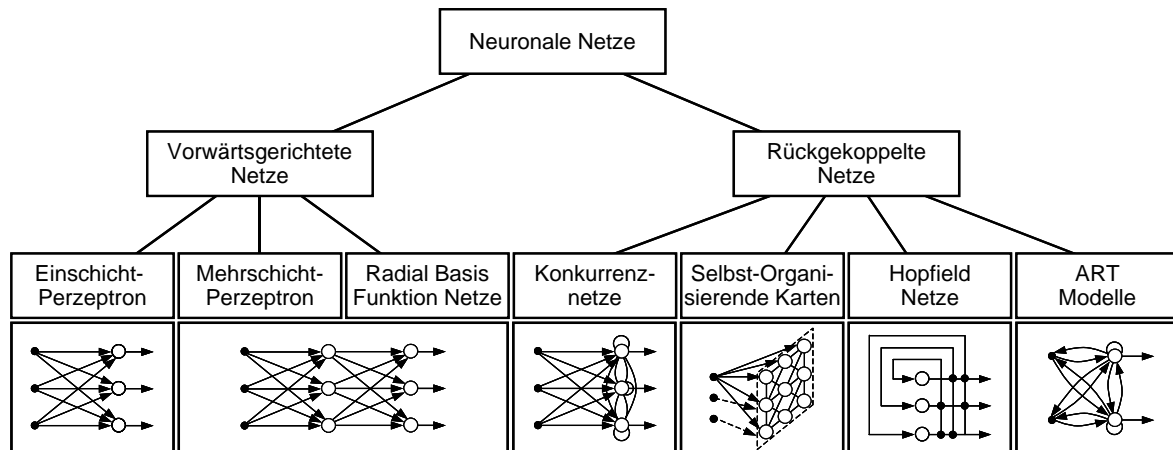


Bild 2.10: Einteilung neuronaler Netze nach Netztopologie (Anil et al. 1996)

Als populäre Vertreter gehören das einschichtige und das mehrschichtige Perzeptron zu den vorwärtsgerichteten Netzen<sup>65</sup>, ebenso wie die Radial Basis Funktion (RBF)-Netze<sup>66</sup>. Im Rahmen der Modellierung der Anfahrkomfortbeurteilung finden in dieser Arbeit ausschließlich einschichtige vorwärtsgerichtete KNN Anwendung.

KNN, die mit einer Konkurrenz-Lernmethode trainiert werden, gehören zu den rückgekoppelten Netzen. Zu ihnen zählen als bekannteste Vertreter die Hopfield-Netze<sup>67</sup>, die ART-Netze<sup>68</sup> und die Selbst-Organisierenden Karten<sup>69</sup>. Neben diesen eigentlichen KNN gibt es noch eine Vielzahl an neuronalen Verfahren, die sich einzelner charakteristischer Methoden von neuronalen Netzen bedienen und hier nur der Vollständigkeit wegen erwähnt werden sollen<sup>70</sup>.

### 2.2.3.2 Beispielhafte Untersuchungen

Willumeit und Jürgenssohn<sup>71</sup> stellen im Bezug auf die Fahrermodellierung fest, dass „menschliches Verhalten auch bei gleichen äußeren Bedingungen stochastischen Schwankungen unterworfen ist. Menschmodellierung bedarf deshalb „weicher“, „unscharfer“ und stochastischer Methoden“. Im Zusammenhang mit der Modellierung des Fahrers haben sich Modelle auf Basis von KNN als leistungstark erwiesen. Ab „Mitte der achtziger Jahre finden wir neue Modellierungsmethoden wie Produktionssysteme, künstliche neuronale Netze oder Petri-Netze.“

<sup>65</sup> Rosenblatt 1958

<sup>66</sup> Powell 1987

<sup>67</sup> Hopfield 1982

<sup>68</sup> Carpenter 1991

<sup>69</sup> Kohonen 1997

<sup>70</sup> Cichocki / Unbehauen 1993

<sup>71</sup> Willumeit / Jürgenssohn 1997

Sie stellen ferner fest, dass „eines der großen Probleme bei der Nachbildung menschlichen Verhaltens seine große Variabilität, Flexibilität und die großen interindividuellen Unterschiede“ sind. Die zitierten Untersuchungen betrachten zwar die Modellierung des Verhaltens und nicht des Empfindens des Fahrers, die grundlegende Aussage der Individualität kann jedoch auch hierfür übernommen werden. Im Bereich der Objektivierung von Komfortbewertungen ist die Theorie der KNN eine vergleichsweise neue und innovative Methode. So gibt es beispielsweise noch keine sicheren Erkenntnisse, welche Netzarchitekturen für welche Probleme am besten geeignet sind, sondern lediglich erste Erfahrungswerte.

Moriwaki et al.<sup>72</sup> setzen künstliche neuronale Netze zur Modellierung der Expertenbeurteilung von Getriebegeräuschen anhand einer zehnstelligen Skala, ähnlich der in Bild 2.2 beschriebenen, ein. Die Studie erfolgt anhand von 420 Datensätzen aus Objektivdaten und zugehöriger Experten-Geräuschbeurteilung. Fokus der Arbeit liegt auf der Aufbereitung der Eingangsdaten und der Wahl der Netzstruktur, um eine sichere Konvergenz in der Trainingsphase zu erreichen. Die Ableitung charakteristischer objektiver Kennwerte für das Geräusch geschieht mittels einer FFT-Zerlegung und einer anschließenden Digitalisierung des Geräuschpegels anhand definierter Grenzen. Die Digitalisierung erfolgt dabei in der Weise, dass z. B. für ein KNN mit 20 Eingangsneuronen 20 Digitalwerte abgeleitet werden. Da sich die Bewertungen ausschließlich zwischen 5.0 und 7.5 Punkten bewegt und eine Auflösung von 0.5 Punkten erreicht werden soll, werden entsprechend drei Ausgangsneuronen verwendet. Es wird gezeigt, dass die Prognosegenauigkeit mit der Anzahl unabhängiger Trainingsdatensätze sowie der Anzahl der Digitalisierungsstufen zunimmt. Das Training erfolgt dabei jeweils mit einer fest vorgegebenen Anzahl Trainingsepochen. Die Beurteilung der Prognosegenauigkeit wird durch den Vergleich von berechneter und tatsächlicher Experten-Geräuschbewertung durchgeführt. Hierzu wird das KNN mit einer bestimmten Anzahl zufällig gewählter Trainingsdaten trainiert und überprüft, wie viele der restlichen Datensätze sinnvoll prognostiziert werden können. Das System erreicht bei 20 Trainingsdatensätzen, einer Netztopologie von 20 Eingangsneuronen, 12 verdeckten Neuronen und drei Ausgangsneuronen für die verbleibenden 400 Verifikationsdatensätze eine Prognosegenauigkeit von 80% „quasi-richtiger“ Antworten im Bereich +/- 0.5 Punkten, was der Genauigkeit der Expertenbewertung entspricht.

Hagerodt<sup>73</sup> beschäftigt sich mit der automatisierten Optimierung des Schaltkomforts von Automatikgetrieben. Während die Modellbildung bezüglich Schaltkomfort

---

<sup>72</sup> Moriwaki et al. 2001

<sup>73</sup> Hagerodt 2003

hier mittels Regression erfolgt, beschreiben Böhl und Küçükay<sup>74</sup> darauf aufbauend in weiteren Untersuchungen zu diesem Thema den Einsatz von KNN zur Modellbildung und kommen zu dem Ergebnis, dass KNN hervorragende Ergebnisse bei der Approximation der zur Modellbildung verwendeten Daten liefern. Eine Überprüfung anhand nicht zur Modellierung verwendeter Daten findet jedoch nicht statt.

Cameiro Silva<sup>75</sup> verwendet KNN zur Kombination mehrerer „Stresser“, d. h. um aus Einzelurteilen für z. B. Akustikkomfort, Schwingungskomfort, Klimakomfort, etc. ein Gesamtkomforturteil zu generieren.

Eigene Voruntersuchungen zur vorliegenden Arbeit zeigen die grundsätzliche Anwendbarkeit der beschriebenen Theorie zur Prognose subjektiver Komforturteile beim Anfahren mittels KNN. Die Modellbildung erfolgt für Laienbewerter<sup>76</sup> und für Experten<sup>77</sup> auf der Beifahrerposition als Machbarkeitsstudie. Bei diesen Untersuchungen wird somit der Anfahrkomfort – die Anfahrt an sich – beurteilt und das diesbezügliche Bewertungsmodell untersucht. Hierbei werden ausschließlich objektive Größen aus dem an der Sitzschiene gemessenen Beschleunigungssignal verwendet. Darauf aufbauend erfolgt die Untersuchung der Modellbildung des Experten als Fahrer eines Fahrzeugs mit automatisierter Kupplung<sup>78</sup>. Hier werden auch Messwerte der Fahrereingabe (Gaspedal) betrachtet. Die Modellbildung für Laienbewerter ist Thema der vorliegenden Arbeit.

Die Automobilhersteller und Komponentenentwickler haben interne Systeme zur objektiven Komfortbeurteilung entwickelt. Angaben zur Funktionsweise dieser Systeme sind der Allgemeinheit jedoch nicht zugänglich.

Ein Tool zur Beurteilung des Fahrwerks bezüglich des Schwingungskomforts durch Straßenanregung ist z. B. das interne Entwicklungstool „Ridemeter“ der Fa. Audi<sup>79</sup>. Es dient auch zur Vorhersage des Fahrkomforts anhand von Simulationsmodellen. Das System findet Erwähnung als Entwicklungswerkzeug bei Gläser et al.<sup>80</sup>, es werden jedoch keine Aussagen über die Funktionsweise gemacht.

Ammon et al.<sup>81</sup> beschreiben die Analysekette von der Fahrbahnanregung bis zum Menschen und nennen als entscheidendes Glied der Analysekette das Komfort-

---

<sup>74</sup> Böhl / Küçükay 2004

<sup>75</sup> Gameiro Silva 2004

<sup>76</sup> Albers / Albrecht 2002, 2003

<sup>77</sup> Albers / Albrecht 2004a

<sup>78</sup> Albers / Albrecht 2004b, 2005

<sup>79</sup> Audi AG, Ingolstadt

<sup>80</sup> Gläser et al. 2002

<sup>81</sup> Ammon et al. 2004

bewertungsverfahren, welches im Hause DaimlerChrysler<sup>82</sup> erstellt wurde. Details werden jedoch nicht veröffentlicht.

Ein kommerzielles System zur Beurteilung von manuellen Schaltvorgängen im Kfz ist das System GSQA (Gearshift Quality Assessment System) von Ricardo<sup>83</sup>. Fokus ist hier die Mensch-Maschine-Schnittstelle am Schalthebel. Neben einer Aufzeichnung von Schaltvorgängen mittels der Gearshift Data Acquisition Software (GDAS) ermöglicht die Analysesoftware OGAS (Objective Gearshift Analysis Software) eine Datenaufbereitung, um dem Ingenieur die Beurteilung von Schaltungen anhand von Messdaten zu ermöglichen. Hierbei werden die aufgezeichneten Messungen zum einen visualisiert (z. B. Schaltbild, Schaltkraftverläufe, Hysteresekurven, etc.) aber auch statistisch ausgewertet (z. B. Häufigkeitsverteilung eines Ereignisses). Die Längsschwingung des Fahrzeugs findet hier keine Beachtung. Auch findet keine Berechnung einer Beurteilung in Form einer Punktezahl oder Note statt.

Ein kommerzielles System der Firma AVL List<sup>84</sup> zur Beurteilung von Fahrbarkeit (Driveability) im Sinne einer Gesamtfahrzeugbewertung ist das System AVL-Drive. List und Schoegg<sup>85</sup> stellen das System 1998 erstmals vor. Es besteht aus einem Modul zur Erkennung der Fahrsituation (Zustandserkennung) und dem eigentlichen Bewertungssystem (nichtlineare Fahrersimulation). Das System betrachtet hauptsächlich motorrelevante Zustände wie beispielsweise Leerlauf, Motorstart, Tip-In, Let-Off, etc, aber auch Gangwechsel und das Anfahrverhalten. Für jeden dieser Zustände wird ein eigenes Objektivierungsmodell erstellt. Aus den damit gewonnenen Einzelurteilen wird ein Gesamturteil für das Fahrzeug berechnet. Neben Signalen von Drehzahlen, Pedalposition, Drosselklappenstellung und Motortemperatur ist die Längsbeschleunigung die entscheidende Messgröße. Es erfolgt eine FFT-Zerlegung der Längsbeschleunigung, woraus dann charakteristische Kennwerte wie etwa die Ruckelamplitude, die Amplitude der ersten und zweiten Motorordnung oder der Reifenanregung abgeleitet werden. Als Komfortwert wird ein an einer zehnstelligen Skala<sup>86</sup> orientierter Wert angegeben. Zur Objektivierung werden zwei- oder dreidimensionale analytische Modellgleichungen, vier- oder mehrdimensionale analytische Berechnungen und auch künstliche Intelligenz/neuronale Netze benutzt. Das Netztraining wird hierbei mit 250 Trainingsdatensätzen und einem nicht näher bestimmten genetischen Algorithmus durchge-

---

<sup>82</sup> DaimlerChrysler AG, Stuttgart

<sup>83</sup> Ricardo plc, Warwickshire, England

<sup>84</sup> AVL List GmbH, Graz, Österreich

<sup>85</sup> List / Schoegg 1998

<sup>86</sup> Ähnlich der in Bild 2.2 gezeigten Skala

führt. Details bezüglich Art und Aufbau der Netze, Trainingsalgorithmus und Abbruchbedingung sowie der Netzverifikation sind aus der Literatur<sup>87</sup> jedoch nicht zu entnehmen. Ebenso finden sich keine Angaben, welche charakteristischen Größen genau in die Modellbildung eingehen.

An dieser Stelle setzt die vorliegende Arbeit an und liefert sowohl spezielle Erkenntnisse zum Thema Objektivierung von Anfahrkomfortbeurteilungen aber auch allgemeingültige Erkenntnisse für ähnliche Problemstellungen.

---

<sup>87</sup> Schoeggli et al. 1998, 1999; Schoeggli 2000; Schoeggli / Ramschak 2000a, 2000b



### 3 Ziele der Arbeit

Zu Beginn eines Entwicklungsprojekts wird das Zielsystem durch die Anforderungen und deren Verknüpfungen beschrieben. Konkret bedeutet das für das Zielsystem Automobil beispielsweise die Anforderung, als Objektsystem ein komfortables Fahrzeug zu entwickeln, welches erfolgreich im Markt platziert werden kann. Das Handlungssystem besteht in den Elementen, mit denen ein Objektsystem geschaffen wird, welches das spezifizierte Zielsystem erfüllen soll. Teil des Handlungssystems ist auch die Überprüfung, ob das Objektsystem das Zielsystem erfüllt. In einer frühen Phase des Produktentstehungsprozesses (PEP) liegt das Objektsystem in abstrakter Form vor und wird im Laufe des PEP immer weiter konkretisiert. Zwar ermöglichen es die Methoden der virtuellen Produktentwicklung, bereits in frühen Phasen des PEP spätere Produkteigenschaften wie beispielsweise Geometrien anhand von CAD-Daten zu prüfen, die Überprüfung von Komforteigenschaften durch die Interpretation von Simulationsergebnissen ist hingegen nur sehr eingeschränkt möglich. Die Ermittlung dieser Eigenschaften kann erst spät anhand eines als Prototyp vorliegenden Objektsystems in der Validierungsphase des PEP in Fahrversuchen durch den Menschen stattfinden. Zu diesem Zeitpunkt sind viele Eigenschaften des Objektsystems bereits festgelegt und etwaige weitere Optimierungen sind dann oft nur noch unter sehr großem Aufwand durchführbar. Ziel ist es deshalb, ein Handlungssystem zu schaffen, welches eine Komfortbeurteilung aus objektiv messbaren Kenngrößen ermöglicht. Dadurch gelingt es, bereits in einer frühen Phase des PEP aus Simulationsergebnissen erste Aussagen über die späteren Komforteigenschaften eines Fahrzeugs – wie etwa den Anfahrkomfort – abschätzen zu können.

Es hat sich in den letzten Jahren zudem gezeigt, dass sich das Kupplungssystem mehr und mehr zu einem mechatronischen Aktor entwickelt hat, mit dem aktiv die Dynamik des Antriebsstrangs beeinflusst werden kann<sup>88</sup>. Neben dem klassischen Stufenautomatgetriebe mit Trilok-Wandler findet automatisiertes Anfahren bei vielen in jüngster Zeit auf den Markt drängenden Systemen wie Automatisierten Schaltgetrieben, Doppelkupplungsgetrieben und stufenlosen Getrieben (engl.:

---

<sup>88</sup> Albers et al. 2003

Continuously Variable Transmissions, kurz: CVT) statt. Dieser vermehrte Einsatz von elektronischen Steuerungen ermöglicht viele neue Funktionalitäten, erfordert andererseits jedoch Modelle zur Interpretation von HiL (Hardware-in-the-Loop) Daten, um den Aufwand der Applikation beherrschbar zu machen<sup>89</sup>.

Zusammenfassend lässt sich am recherchierten Stand der Forschung und Technik feststellen, dass das Thema Beurteilung von Anfahrkomfort durch Kunden in der Forschung nicht explizit behandelt wurde. Weiterhin zeigt sich, dass die Objektivierung/Modellierung des Komfortempfindens, gerade aus Sicht des Normalfahrers bzw. Kunden, bisher kaum erfolgreich erforscht wurde. Voruntersuchungen des Autors haben gezeigt, dass künstliche neuronaler Netze (KNN) zu diesem Zweck ein sehr vielversprechendes Werkzeug darstellen<sup>90</sup>. Forschungsansätze mit KNN existieren in angrenzenden Bereichen, wie der Akustik. Eine explizite Anwendung für die Modellierung der Beurteilung niedrigfrequenter NVH-Eigenschaften eines Fahrzeugs, wie sie auch beim Anfahren relevant sind, findet sich jedoch nur in einem kommerziellen System zur Expertenbewertung der Fahrbarkeit von Fahrzeugen. Dieses Know-how ist der Forschung nicht zugänglich und Hinweise zum Einsatz von KNN zu diesem Zweck sind nur in sehr verallgemeinerter Form veröffentlicht<sup>91</sup>.

In der Ergonomie ist es üblich, die Größe eines Produkts nicht im Hinblick auf die Nutzung durch die Gesamtbevölkerung, sondern nur durch eine gewisse Kundenzielgruppe, zu gestalten. Bei Fahrzeugen wird aus den demografischen Daten der Bevölkerung häufig die maximale Körpergröße der Kundenzielgruppe durch den 95% Mann definiert, was bedeutet, dass nur 5% aller Männer größer als diese maximale Zielgröße sind. Das Minimum wird durch die 5% Frau gekennzeichnet, d. h. nur 5% der Frauen in der Gesamtbevölkerung sind kleiner als diese minimale Zielgröße<sup>92</sup>. So wird das Produkt zwar nur im Hinblick auf die Nutzbarkeit durch einen Teil der Menschen gestaltet, was jedoch im Gegensatz zur Berücksichtigung aller Menschen u. a. Vorteile im Hinblick auf die Kosten des Produkts mit sich bringt und somit einen Kompromiss zwischen erreichtem Nutzen und benötigtem Aufwand darstellt. Diese Vorgehensweise ist prinzipiell auch für Komforteigenschaften denkbar und wird hier vorgestellt. Hierzu ist es jedoch erforderlich, den Komfortanspruch einzelner Kunden individuell abzubilden. Sind solche Individualmodelle vorhanden, kann mit ihnen der Prozentsatz zufriedener Kunden ermittelt werden.

---

<sup>89</sup> Siehe hierzu auch Hagerodt 2003

<sup>90</sup> Albers / Albrecht 2002, 2003a, 2003b, 2004a, 2004b, 2005

<sup>91</sup> Schoeggel et al. 1998, 1999; Schoeggel 2000; Schoeggel / Ramschak 2000a, 2000b

<sup>92</sup> Seeger 1992

Das Ziel dieser Arbeit liegt in der Entwicklung und Untersuchung einer Methode, die es ermöglicht, Bewertungsmodelle zu generieren, um aus physikalischen Größen auf das Komforturteil eines Kunden bzw. einer Kundenzielgruppe zu schließen. Die objektiven Kenngrößen können dabei aus im Fahrversuch ermittelten Signalen oder auch aus der Simulation abgeleitet werden, womit die Methode ein wichtiges Werkzeug für die virtuelle Produktentwicklung darstellt. Die Methode wird hier exemplarisch für das Anfahren mit einem automatisierten Kupplungssystem erforscht.

Im Einzelnen ergeben sich folgende Zielsetzungen für die Arbeit:

- Definition von Kundenzielgruppen anhand objektiver Kenngrößen aus fahrphysikalischen Messdaten.
- Begriffsklärung „Anfahrkomfort“.
- Erarbeitung eines für die Anfahrkomfortbeurteilung durch Laien geeigneten Bewertungsschemas.
- Untersuchung und Vergleich der Bewertungstreue für Anfahrkomfortbewertungen von Laien und Experten.
- Ableitung charakteristischer objektiver Kennwerte zur Beschreibung des Anfahrvorgangs im Hinblick auf den Anfahrkomfort.
- Modellierung der Komfortbewertung des Anfahrverhaltens aus Kundensicht mittels mathematischer Methoden. Explizit finden hier die multiple lineare Regressionsanalyse als Standard-Methode sowie KNN Anwendung.
- Vergleich der mittels multipler linearer Regressionsanalyse und KNN erhaltenen Modelle sowohl für die Approximation zur Modellbildung verwendeter Daten als auch für die Prognose nicht zur Modellbildung verwendeter Daten.
- Aufzeigen der wesentlichen Einflussfaktoren auf die Modellierung mittels KNN.
- Anwendung der Modelle zur Komfortbeurteilung realer Anfahrvorgänge.
- Anwendung der Modelle zur Interpretation von Simulationsdaten aus einem Fahrzeugmodell.



## 4 Entwicklungsumgebung

Um den Herausforderungen der immer komplexer werdenden Fahrzeuge und der immer kürzer werdenden Entwicklungszeiten gerecht zu werden, erforscht das Institut für Produktentwicklung (IPEK) der Universität Karlsruhe (TH) einen ganzheitlichen Entwicklungsprozess für Antriebsstränge mit der Parallelität von Experiment und Simulation. Wie Bild 4.1 zeigt, geschieht dies auf verschiedenen Ebenen vom Element (z. B. Reibpaarung der Kupplung) bis zur Gesamtfahrzeugerprobung.



Bild 4.1: Ganzheitliche Antriebsstrangforschung am Institut für Produktentwicklung der Universität Karlsruhe (TH)<sup>93</sup>

Das Hauptaugenmerk liegt hierbei auf der Untersuchung von Komforteigenschaften. Diese ganzheitliche Antriebsstrangforschung wird von Albers et al.<sup>94</sup> am Beispiel der Untersuchungen zum Thema Rupfen von Antriebssträngen beschrieben. Lux et al.<sup>95</sup> und Albers et al.<sup>96</sup> beschreiben den Antriebsbaugruppenprüfstand als

<sup>93</sup> Albers et al. 2001b

<sup>94</sup> Albers et al. 2001a

<sup>95</sup> Lux et al. 1999; Lux 2000

zentralen Teil der Prüfstandsgebung und wie damit in Verbindung mit der MKS-Simulation ein tieferes Systemverständnis von Zweimassenschwungrädern erlangt wird. Albers und Krüger<sup>97</sup> setzen diese Prüfstandsgebung zur Erforschung des Kupplungsrupfens als Komfortproblem beim Anfahren, sowie Maßnahmen zu dessen Unterdrückung, ein. Die Simulation hilft hier jeweils einerseits, das untersuchte System zu verstehen, zusätzlich erlaubt die Simulation es auch, Beeinflussungen der Systeme auf unterschiedlichen Ebenen zu untersuchen. Durch die Simulation können so bereits aus Erkenntnissen von Komponentenversuchen Eigenschaften des übergeordneten Systems abgeleitet werden. Beispielsweise kann aus Untersuchungen des Reibkontakts in der Elementebene auf Systemeigenschaften einer Kupplung, in welcher dieser Reibkontakt stattfindet, geschlossen werden.

In diesem Kontext ist auch die in dieser Arbeit beschriebene Forschung auf dem Gebiet der Objektivierung von Komfortbewertungen angesiedelt. Sie komplettiert die ganzheitliche Entwicklungsumgebung durch die Einbindung des Benutzers/Kunden. Es können Eigenschaften von Systemen bereits vorhergesagt werden, bevor diese real existieren. So kann beispielsweise mittels der im Rahmen dieser Arbeit erforschten Methode der Anfahrkomfort eines Fahrzeugs in der Konzeptphase aus Simulationsdaten (MKS-Modellen) eines virtuellen Fahrzeugs abgeschätzt werden, bevor dieses als Prototyp überhaupt existiert. Seebacher und Fidlin<sup>98</sup> beschreiben diesen Prozess am Beispiel der simulationsgestützten Optimierung von Drehschwingungsdämpfern, wobei „die vorgeschlagenen Konzepte simulationstechnisch geprüft und unter ganzheitlicher Antriebsstrangbetrachtung optimiert“ werden. Im Gegensatz zu einer problemorientierten Optimierung, welche in enger Zusammenarbeit von Versuch und Berechnung oft nur für den jeweiligen Betriebsbereich möglich war, wird durch eine simulationsgestützte Vorgehensweise eine Berücksichtigung aller Betriebsbereiche möglich. Außerdem können Toleranzen und sich daraus ergebende Abweichungen im Simulationsmodell berücksichtigt werden. Der Versuchsaufwand verschiebt sich dabei von der Fahrzeugabstimmung hin zur Validierung der Simulationsmodelle mit dem Ziel, den Gesamtaufwand an Fahrzeugversuchen zu reduzieren.

Durch diese Voroptimierung in einer frühen Phase des PEP kann eine Reduzierung von Entwicklungszeit und -kosten bei gleichzeitiger Erhöhung der Kundenakzeptanz erreicht werden.

---

<sup>96</sup> Albers et al. 2001b, 2002

<sup>97</sup> Albers / Krüger 2002, 2003a, 2003b; Krüger 2003

<sup>98</sup> Seebacher / Fidlin 2005

## 4.1 Reale Umgebung – Versuchsfahrzeuge und Messtechnik

Als Versuchsfahrzeug für die in Kapitel 5 beschriebene Definition von Kundenzielgruppen diene eine Limousine der oberen Mittelklasse, angetrieben von einem 2.5l Sechszylinder-Ottomotor mit einer Leistung von 125 kW, manuellem 5-Gang Schaltgetriebe, konventioneller Kupplung und Hinterradantrieb. Während der Fahrt wurden über ein Datenerfassungssystem<sup>99</sup> kontinuierlich die Zeitverläufe der Motor-, Getriebeeingangs- und Raddrehzahl, der Fahrpedal- und der Kupplungspedalstellung, sowie der an der Fahrersitzschiene triaxial gemessenen Fahrzeugbeschleunigung, aufgezeichnet.

Ein im Rahmen dieser Arbeit entwickelter und für die hier gezeigten Untersuchungen wesentlicher Teil der Entwicklungsumgebung ist ein Versuchsfahrzeug, dessen Anfahrereigenschaften verändert werden können und das somit einen „mobilen Simulator“ für Anfahrereigenschaften darstellt. Basis dieses Versuchsfahrzeugs bildet ein von DaimlerChrysler<sup>100</sup> zur Verfügung gestelltes Fahrzeug der unteren Mittelklasse mit einem automatisierten Kupplungssystem. Das Fahrzeug wird angetrieben von einem front-quer eingebauten 1.7l Vierzylinder-Dieselmotor mit einer Nennleistung von 70 kW. Die Kraftübertragung erfolgt über ein mechanisches 5-Gang Handschaltgetriebe mit automatisiertem Kupplungssystem (EKM) der Fa. LuK<sup>101</sup>. Albers<sup>102</sup> stellt das System 1990 erstmals vor und zeigt dessen Potenziale auf. Grundgedanke des EKM ist es, die Aufgabe des Kuppelns zu automatisieren und dem Fahrer damit einen Gewinn an Sicherheit und Komfort beim Anfahren und Schalten zu bieten.

Wie das in Bild 4.2 dargestellte Prinzipbild des Antriebsstrangs mit automatisierter Kupplung zeigt, entfällt bei diesem System das Kupplungspedal und die Kupplung wird durch eine Aktorik angesteuert.

---

<sup>99</sup> RAMBOX®, AFT Atlas Fahrzeugtechnik GmbH, Werdohl

<sup>100</sup> DaimlerChrysler AG, Stuttgart

<sup>101</sup> LuK GmbH & Co. oHG, Bühl

<sup>102</sup> Albers 1990




Bild 4.2: Antriebsstrang mit automatisierter Kupplung (Quelle: LuK)

Im Steuergerät des EKM-Moduls dieses Versuchsfahrzeugs, welches in Zusammenarbeit mit der Fa. LuK für die hier vorgestellten Untersuchungen modifiziert wurde, sind fünf verschiedene Anfahrvarianten abgelegt. Diese als unterschiedlich komfortabel empfundenen Anfahrvarianten können durch das Applikations- und Kalibriersystem<sup>103</sup> während der laufenden Messung online von Anfahrart zu Anfahrart ausgewählt werden. Somit ist es bei diesem „mobilen Simulator“ möglich, die Anfahrcharakteristik gezielt zu verändern und unterschiedliche Komforteindrücke beim Fahrer zu generieren<sup>104</sup>. Einen weiteren Einfluss auf das Anfahrverhalten hat neben der ausgewählten Anfahrvariante die Eingabe des Fahrers über das Gaspedal.

Die entsprechenden CAN-, Drehzahl- und Analogdaten werden parallel im Datenerfassungssystem<sup>105</sup> gespeichert und stehen zusammen mit den Kalibrierdaten für eine spätere Auswertung zur Verfügung. Das Signal, welches die Fahrereingabe (Fahrerwunsch) charakterisiert ist der Pedalwert des Gaspedals. Dieser wird aus den CAN-Bus Daten des Fahrzeugs ermittelt. Zusätzlich wird die binäre Information über den Zustand des Bremspedals über den Bremslichtschalter abgegriffen. Weitere CAN-Bus-Daten, wie das Motormoment und die Raddrehzahlen, werden für die Validierung des im Kapitel 4.2 vorgestellten Mehrkörper-Simulationsmodells sowie die Zustandserkennung, benutzt. Zur Messung der Fahrzeugreaktionen sind

<sup>103</sup> MARC®, AFT Atlas Fahrzeugtechnik GmbH, Werdohl

<sup>104</sup> Albers / Albrecht 2003b

<sup>105</sup> TORNADO®, AFT Atlas Fahrzeugtechnik GmbH, Werdohl



jeweils triaxiale Beschleunigungssensoren an der Fahrersitzschiene sowie der Kopfstütze des Fahrersitzes angebracht. Die Sensoren sind in der Lage, sowohl den statischen Anteil der Beschleunigung, als auch dynamische Signalverläufe bis zu einer Grenzfrequenz von 250 Hz zu messen.

Die Diagramme auf den folgenden Seiten zeigen beispielhaft typische Zeitverläufe der charakteristischen Messgrößen für die fünf Anfahrvarianten, wobei die Fahrer-eingabe (Gaspedalverlauf) annähernd identisch ist, jedoch unterschiedlich komfortable Fahrzeugreaktionen bewirkt. Bei den hier gezeigten Bildern beträgt der maximale Pedalwert jeweils 50% des Vollgaswerts. Die jeweils linken Diagramme zeigen die Verläufe der Motordrehzahl, gemessen am Anlasserzahnkranz (also vor der Kupplung) und der Drehzahl der Getriebeeingangswelle (also nach der Kupplung), sowie den normierten Weg des Kupplungsaktors. In den jeweils rechts daneben gezeigten Grafiken sind die zugehörige binäre Information des Bremspedals und der Verlauf des Gaspedals als Fahrereingabe, sowie die an der Fahrersitzschiene gemessene Längsbeschleunigung als Fahrzeugreaktion, dargestellt.

Die in Bild 4.3 gezeigte Variante A ähnelt dem Serienstand der EKM-Controllersoftware des Fahrzeugs.




Bild 4.3: Versuch Anfahrvariante A bei max. Pedalwert 50%

Variante B erlaubt beim Einkuppelvorgang deutlich mehr Schlupf als die oben beschriebene Abstimmung, wie in Bild 4.4 anhand der Drehzahlverläufe deutlich zu sehen ist.




Bild 4.4: Versuch Anfahrvariante B bei max. Pedalwert 50%

Bild 4.5 zeigt Messschriebe der Variante C, die durch ein leicht getaktetes Zufahren der Kupplung charakterisiert ist. Hierdurch werden Längsschwingungen im Bereich der Ruckelfrequenz des Fahrzeugs erzeugt, welche i. A. von den Fahrzeuginsassen als störend wahrgenommen werden.

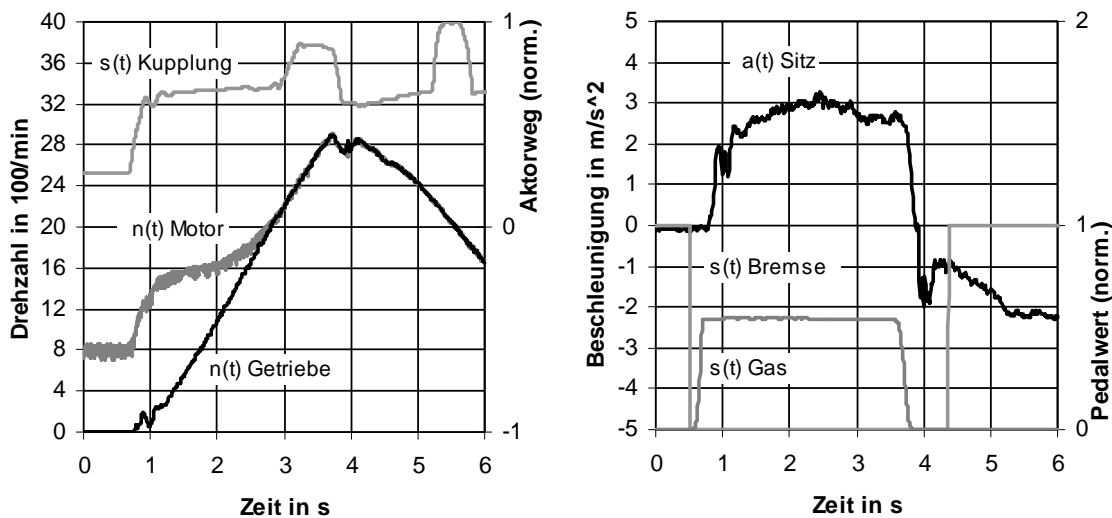


Bild 4.5: Versuch Anfahrvariante C bei max. Pedalwert 50%

Bild 4.6 zeigt die Anfahrvariante D, bei der die Amplitude der Zustellbewegung des Aktors im Vergleich zu Variante C größer ist, was zu deutlicher spürbaren Längsschwingungen führt und demnach eine i. A. als unkomfortabler empfundene Anfahrt erzeugt.




Bild 4.6: Versuch Anfahrvariante D bei max. Pedalwert 50%

Anfahrvariante E bewirkt, wie in Bild 4.7 dargestellt ist, noch deutlichere Längsschwingungen als die beiden zuvor beschriebenen Varianten.

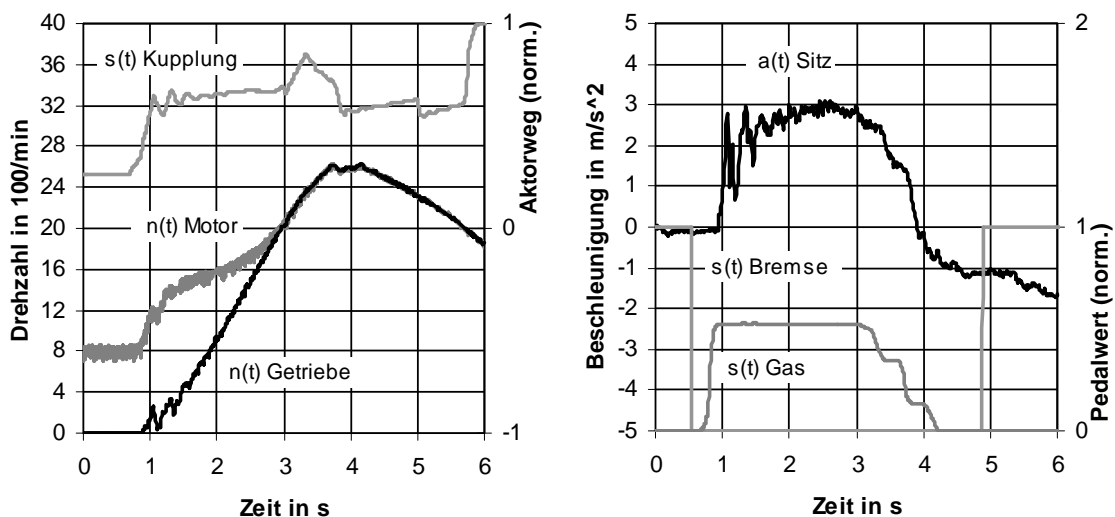


Bild 4.7: Versuch Anfahrvariante E bei max. Pedalwert 50%

## 4.2 Virtuelle Umgebung – Mehrkörpersimulationsmodelle

Ein am Institut für Produktentwicklung vorhandenes, in MATLAB/Simulink<sup>106</sup> implementiertes, dynamisches Mehrkörpersimulationsmodell (MKS-Modell) des heckgetriebenen Versuchsfahrzeugs mit manueller Kupplung<sup>107</sup> wurde so modifiziert, dass es das frontgetriebene Versuchsfahrzeug mit automatisiertem Kupplungssys-

<sup>106</sup> The MathWorks Inc., Natick, MA, USA

<sup>107</sup> Combé et al. 2005

tem abbildet<sup>108</sup>. Neben einer entsprechenden Umdefinition des Antriebsstrangs wurden die Massenträgheitsmomente, Steifigkeiten und Dämpfungen der einzelnen Baugruppen sowie die Kupplungskennlinie (übertragbares Moment über Ausrückweg) anhand der Originalwerte des Versuchsfahrzeugs angepasst, sofern diese Daten verfügbar waren. Unbekannte Parameter, wie beispielsweise die Dämpfungsfaktoren von Getriebe- oder Antriebswellen, wurden zunächst geschätzt. Das verwendete einfache Modell simuliert nicht den Verbrennungsmotor und die Aktuatorik der automatisierten Kupplung des Versuchsfahrzeugs, was bedeutet, dass als Eingangsgröße nicht der Gaspedalverlauf verwendet werden kann. Die Eingangsgrößen sind hier der Motormomentenverlauf und der Verlauf des Kupplungsaktorwegs, deren Signalverläufe anhand realer Fahrversuche generiert werden. Bild 4.8 verdeutlicht die Vorgehensweise zur Simulation der Fahrzeuglängsbeschleunigung.

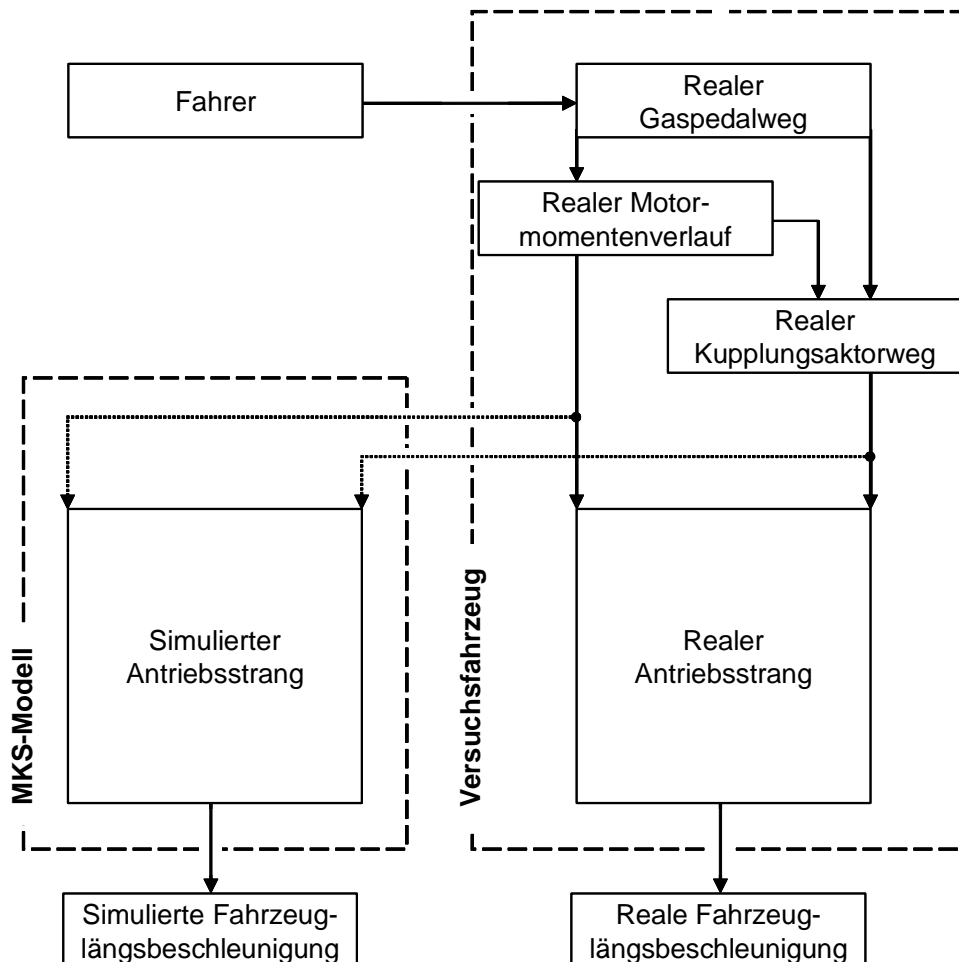


Bild 4.8: Eingangs- und Ausgangssignale im realen Versuchsfahrzeug und im MKS-Modell

<sup>108</sup> Dickerhof 2005

Für die Modellvalidierung diente eine Versuchsserie von insgesamt 20 Anfahrten, wobei für jede der fünf Anfahrvarianten jeweils eine Anfahrt bei einem max. Pedalwert von j 30%, 50%, 70% und 100% gefahren wurde (vgl. Kapitel 6.2.2), wodurch der Betriebsbereich des Fahrzeugs hinsichtlich Anfahren weitestgehend abgedeckt wurde.

Neben den Verläufen von Motormoment<sup>109</sup> und zugehörigem Kupplungsaktorweg wurden die zugehörigen Drehzahlverläufe von Getriebeeingangswelle, Motor und einem nicht angetriebenen Rad sowie die Fahrzeuglängsbeschleunigung gemessen, anhand derer die Modellvalidierung durchgeführt wurde. Leider lagen für die Modellabstimmung nicht alle erforderlichen Daten des Antriebsstrangs des Versuchsfahrzeugs vor. Um für die unbekanntenen Parameter sinnvolle Werte zu finden, mit denen eine hinreichend genaue Abbildung des realen Verhaltens möglich ist, wurde eine simultane Optimierung auf die 20 beschriebenen Anfahrten (fünf Anfahrvarianten bei jeweils 30%, 50%, 70% und 100% max. Pedalwert) durchgeführt. Optimierungsgröße ist hier die über der Zeit aufsummierte absolute Abweichung von realem zu simuliertem Signal der Drehzahlen von Motor, Getriebeeingangswelle und Rädern, sowie der gemessenen und der simulierten Fahrzeuglängsbeschleunigung.

Die Modellparameter stellen einen Kompromiss dar, der für einige Varianten eine bessere, für andere eine schlechtere Übereinstimmung mit der Realität liefert. Der Kompromiss wird hier sowohl für die fünf Anfahrvarianten, als auch für die jeweils vier per maximalem Pedalwert vorgegebenen Betriebsbereiche (30%, 50%, 70% und 100% max. Pedalwert) gebildet. Im Allgemeinen konnte eine zufriedenstellende Anpassung der simulierten Anfahrten an die realen Anfahrvorgänge erreicht werden. Eine Ausnahme stellt Variante B mit verlängerter Schlupfphase bei 30% max. Pedalwert dar. Für diesen Betriebszustand gelang es nicht, eine genügende Abbildung der Realität zu erreichen, ohne erhebliche Einbußen bei der Modellierung der anderen 19 Anfahrten in Kauf zu nehmen. Grund hierfür ist vermutlich, dass bei dieser Anfahrt durch die extrem lange Schlupfphase Temperatureffekte in der Kupplung auftreten, die das einfache Modell nicht nachbilden kann.

Die folgenden Diagramme in Bild 4.9 bis Bild 4.11 zeigen den Vergleich von Messung und Simulation bei einer Fahrereingabe bei, bzw. entsprechend 50% der maximalen Gaspedalstellung.

---

<sup>109</sup> Es wurde das im Motorsteuergerät berechnete und an das Steuergerät der automatisierten Kupplung gesendete Motormomentensignal verwendet




Bild 4.9: Beschleunigung Anfahrvarianten A (links) und B (rechts) max. Pedalwert 50%




Bild 4.10: Beschleunigung Anfahrvarianten C (links) und D (rechts) max. Pedalwert 50%




Bild 4.11: Beschleunigung Anfahrvariante E max. Pedalwert 50%

In den gezeigten Bildern ist deutlich zu erkennen, dass das simulierte Beschleunigungssignal gegenüber dem gemessenen hochfrequente Anteile nicht abbildet, während niedrigfrequente Anteile in der Simulation gut wiedergegeben werden. Mit verantwortlich hierfür ist neben der fehlenden Schwingungsanregung durch Fahrbahnunebenheiten in erster Linie die Beschaffenheit des aus dem Steuergerät der automatisierten Kupplung ausgelesenen Motormomentensignals. Diesem fehlen hochfrequente Anteile des realen Momentenverlaufs eines Verbrennungsmotors, wie sie aus der durch Gas- und Massekräfte hervorgerufenen Ungleichförmigkeit resultieren.





## 5 Definition von Kundenzielgruppen

Die Erwartungen unterschiedlicher Kunden an ein Fahrzeug differieren. Die Anpassung der Eigenschaften eines Fahrzeugs – z. B. der Anfahrcharakteristik – an die Kundenwünsche setzt also voraus, dass eine Kundenzielgruppe definiert wird, die denselben oder zumindest einen ähnlichen Kundenwunsch hat.

Der Fahrstil ist sicherlich ein entscheidendes Merkmal zur Charakterisierung einer Kundenzielgruppe. So wird als Zielkonflikt auch häufig zwischen eher sportlicher oder eher komfortabler Fahrzeugabstimmung unterschieden<sup>110</sup>. Die Einteilung der Versuchsteilnehmer in Fahrerklassen erfolgt deshalb im Rahmen dieser Arbeit anhand objektiver im Fahrversuch ermittelter Daten, die den Fahrstil beschreiben. Hierzu wurde ein vorgegebener Parcours von den Versuchsteilnehmern dreimal durchfahren und dabei physikalische Messgrößen am Fahrzeug erfasst, aus denen charakteristische Kenngrößen abgeleitet werden, welche in Bezug zum Fahrstil stehen. Die Zuordnung eines Fahrers zu einer Kundenzielgruppe im Hinblick auf die Sportlichkeit des Fahrstils erfolgt gemäß dieser Kenngrößen.

### 5.1 Datengewinnung im Fahrversuch

#### 5.1.1 Versuchsteilnehmer

Bei den Versuchsteilnehmern handelt es sich um Personen, welche keine Experten auf dem Gebiet der Fahrzeugerprobung oder -abstimmung sind. Insgesamt nahmen 23 Personen, davon 3 Frauen, an den Versuchen teil. Eine Abbildung der Gesamtbevölkerung durch die Fahrerstichprobe war also nur bedingt möglich. Zum Zeitpunkt der Datenerhebung hatten die Teilnehmer ein Durchschnittsalter von 36 Jahren. Der jüngste Teilnehmer war 23 Jahre, der älteste 57 Jahre alt. Bild 5.1 zeigt die Altersstruktur der Fahrerstichprobe.

---

<sup>110</sup> Schöggli et al. 2001




Bild 5.1: Altersstruktur der Fahrerstichprobe bestehend aus 23 Personen

### 5.1.2 Versuchsbeschreibung

Als Versuchsfahrzeug kam das im ersten Abschnitt von Kapitel 4.1 beschriebene Fahrzeug mit der dort beschriebenen Messtechnik zum Einsatz. Um konstante Randbedingungen zu gewährleisten und Interaktionen mit anderen Verkehrsteilnehmern auszuschließen wurde der Verkehrsübungsplatz der Deutschen Verkehrswacht e.V. in Karlsruhe als Versuchsstrecke gewählt. Die Fahrvorgabe wurde als Rundkurs auf dem in Bild 5.2 als Grundriss dargestellten Gelände mit drei definierten Anhaltstellen (Stopp) ausgearbeitet. Der erste Stopp (S1) und der dritte Stopp (S3) sind an einem Steigungshügel platziert, der zweite Stopp (S2) in der Ebene. Die Länge der Versuchsstrecke beträgt insgesamt 1.6 km. Die nummerierten Pfeile geben den genauen Verlauf der Fahrvorgabe von Anfang (A) bis Ende (E) an.




Bild 5.2: Grundriss des Versuchsparcours und Fahrvorgabe

Jeder Versuchsteilnehmer durchfuhr den Parcours dreimal nach eigenem Ermessen ohne weitere Vorgabe bezüglich Geschwindigkeit oder ähnlichem. Ziel war es, so den typischen Fahrstil der Versuchsperson zu erfassen.

Bild 5.3 zeigt beispielhaft die Zeitverläufe der Hinterraddrehzahlen (oben), der Längsbeschleunigung (Mitte) sowie der Querb beschleunigung (unten) während einer Fahrt.




Bild 5.3: Zeitverläufe der Hinterraddrehzahlen (oben), der Längsbeschleunigung (Mitte) und der Querbeschleunigung (unten)

### 5.1.3 Ableitung charakteristischer Größen

In der nachfolgenden Auswertung wird aus den in 4.1 beschriebenen Messdaten mit imc-FAMOS<sup>111</sup> charakteristische Größen als Mittelwerte der drei Fahrten eines Fahrers zur Beschreibung des Fahrstils berechnet. Tabelle 5.1 nennt die charakteristischen Größen und zeigt die bei den insgesamt 69 Fahrten (jeweils drei Fahrten von 23 Personen) erreichten Mittelwerte (M), die sich jeweils ergebende Standardabweichung (SA), sowie die Minima (Min) und Maxima (Max).

	M	SA	Min	Max
Mittlere Fahrgeschwindigkeit in km/h	28.28	2.47	23.64	34.91
Mittlere Gaspedalstellung in %	12.67	1.55	10.54	18.44
Effektivwert Längsbeschleunigung in $m/s^2$	1.17	0.21	0.77	1.78
Effektivwert Querschleunigung in $m/s^2$	2.48	0.45	1.74	4.08
Anzahl Schaltvorgänge	11.61	3.90	4.00	20.00
Mittlere Schalt- bzw. Kuppelzeit <sup>112</sup> in s	0.79	0.23	0.41	1.46
Mittlere Hochschaltdrehzahl in 1/min	2133	415	798	3084
Mittlere Motordrehzahl in 1/min	1734	168	1379	2218

Tabelle 5.1: Ausprägungen charakteristischer Kenngrößen

## 5.2 Fahrerklassierung und Auswahl repräsentativer Fahrer

Es erfolgt eine Normierung der in 5.1.3 beschriebenen Kenngrößen bezüglich minimal und maximal auftretender Werte. Mit Ausnahme der mittleren Schalt- bzw. Kuppelzeit wird für alle Größen der höchste Wert als 100% und der niedrigste als 0% definiert. Für die mittlere Schaltzeit wird umgekehrt verfahren. Basis der Gruppeneinteilung ist ein Vergleichswert, welcher durch Addition der linear transformierten und normierten Kenngrößen entsteht. Eine hohe Summe repräsentiert somit einen sportlichen Fahrstil, eine niedrige Summe einen gemütlichen.

<sup>111</sup> FAMOS Signalanalyse, imc Meßsysteme GmbH, Berlin

<sup>112</sup> Die Schaltzeit wurde anhand des Verlaufs des Kupplungspedalwegs ermittelt und gibt die Zeit vom Durchgang durch den Modulationspunkt der Kupplung beim Auskuppeln bis zum erneuten Durchgang beim Wiedereinkuppeln an

Die Einteilung der Fahrer erfolgt mit dem Mittelwert (MW)  $\pm$  der halben Standardabweichung (SA) als Einteilungsgrenzen in drei Fahrstilgruppen. Bild 5.4 zeigt die für die Gruppeneinteilung verwendete Summe für die 23 Fahrer normiert und nach Größe sortiert. Die untere sowie die obere Gruppengrenze sind jeweils gestrichelt eingezeichnet. Werte unterhalb der unteren Gruppengrenze charakterisieren demnach gemütliche Fahrer, jene zwischen den Gruppengrenzen durchschnittliche Fahrer und Werte darüber sportliche Fahrer.

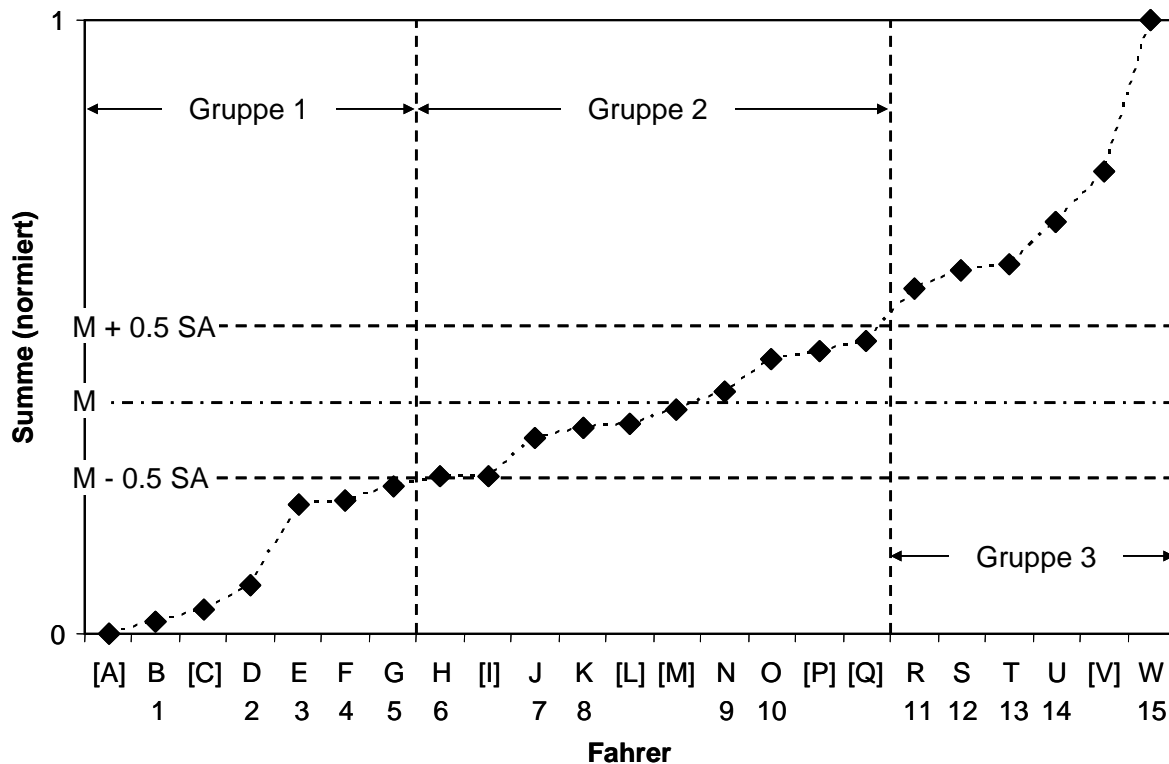


Bild 5.4: Normierte und sortierte Summe für die Fahrer Stichprobe mit Gruppengrenzen

Mit der beschriebenen Vorgehensweise zur Gruppeneinteilung ergibt sich für die 23 Personen, wie aus Bild 5.4 ersichtlich, eine Klassierung in drei Fahrstilgruppen als Kundenzielgruppen derart, dass sieben Personen zur Fahrstilgruppe 1 (gemütlich), zehn Personen zur Fahrstilgruppe 2 (durchschnittlich) und sechs Personen zur Fahrstilgruppe 3 (sportlich) gehören.

Die in Bild 5.4 nicht mit eckigen Klammern versehenen 15 Fahrer, von denen jeweils fünf zu einer der genannten Fahrstilgruppen gehören, standen für die in Kapitel 6.2.1 beschriebenen Untersuchungen zur Komfortbeurteilung als repräsentative Vertreter der jeweiligen Kundenzielgruppe zur Verfügung.

## 6 Untersuchungen zum Anfahrkomfort

Gegenstand der vorgestellten Untersuchung ist der von einem PKW-Fahrer empfundene Anfahrkomfort. Vorab soll hier geklärt werden, was darunter in dieser Arbeit verstanden wird. Weiterhin wird untersucht, wie gut, d. h. wie reproduzierbar Laienbewerter im Vergleich zu Experten (Versuchingenieuren) überhaupt in der Lage sind, Komfortbeurteilungen abzugeben. Auf Basis der im Kapitel 5 anhand ihres Fahrstils definierten Kundenzielgruppen wird außerdem untersucht, welcher Zusammenhang zwischen der Zugehörigkeit der Kunden zu einer Fahrstilgruppe und dem jeweiligen Komfortanspruch besteht.

### 6.1 Begriffsklärung Anfahrkomfort

Beim Anfahrvorgang erfolgt ein Drehzahlausgleich zwischen dem drehenden Motor und dem stillstehenden Antriebsstrang eines Fahrzeugs durch Herstellung eines Kraftschlusses im Anfahrelement. Technisch bzw. physikalisch werden hierbei zwei Massenträgheiten – die des Motors und die des Antriebsstrangs mit all seinen Komponenten sowie letztlich die Fahrzeugmasse an sich – verbunden. Bei einem Fahrzeug mit Handschaltgetriebe erfolgt dies üblicherweise durch eine Kupplung als Anfahrelement, die vom Fahrer über ein Kupplungspedal betätigt wird. Im Falle der automatisierten Kupplung erfolgt diese Betätigung der Kupplung mittels eines mechatronischen Aktors. Beim Automatikgetriebe übernimmt der Tri-lok-Wandler die Überbrückung der Drehzahldifferenz des Motors und des zu Beginn des Anfahrvorgangs stillstehenden Antriebsstrangs.

In Bild 6.1 sind im linken Diagramm die Zeitverläufe des normierten Gas- und Kupplungspedalwegs, im rechten Diagramm die resultierende Motor- und Getriebeeingangsdrehzahl sowie die sich ergebende Raddrehzahl während eines Anfahrvorgangs mit einem Pkw mit Handschaltgetriebe und fußbetätigter Kupplung, dargestellt.




Bild 6.1: Pedalweg- und Drehzahlverläufe beim Anfahrvorgang eines Fahrzeugs mit fußbetätigter Kupplung

Beim Anfahren angeregte rotatorische Schwingungen im Antriebsstrang werden über die Räder in Längsschwingungen der Karosserie umgewandelt und von den Fahrzeuginsassen als mehr oder weniger störend wahrgenommen. Bild 6.2 zeigt die Verläufe des Antriebsmoments in der Kardanwelle, sowie der resultierenden Längsbeschleunigung an der Fahrersitzschiene, welche sich aus den in Bild 6.1 beispielhaft gezeigten Pedalweg- und Drehzahlverläufen ergeben.

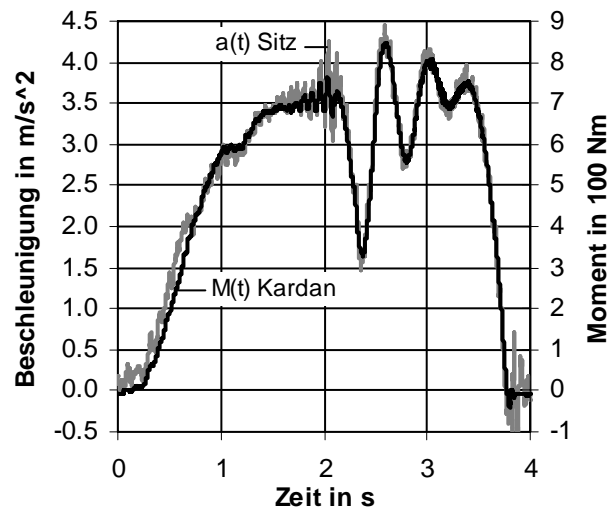


Bild 6.2: Antriebsmoment und Längsbeschleunigung beim Anfahrvorgang gemäß Bild 6.1

Die Betrachtung des Anfahrvorgangs beginnt in dieser Arbeit, sobald der Fahrer diesen einleitet. Im Falle des Anfahrens mit einem manuellen Kupplungssystem also sobald der Fahrer das Gas- und das Kupplungspedal betätigt. Wie Bild 6.1 links zeigt, erfolgt dies üblicherweise weitestgehend zeitgleich. Im Falle eines Wandler-Automatikgetriebes bzw. eines automatisierten Kupplungssystems entfällt das Kupplungspedal. Das im Rahmen dieser Arbeit untersuchte Kupplungs-



system besitzt eine sog. „Ankriechfunktion“, d. h. das Fahrzeug fährt bei eingelegerter Fahrstufe – wie ein Fahrzeug mit Wandler-Automatikgetriebe – auch ohne Betätigung des Gaspedals los, sofern nicht die Bremse betätigt ist. Aus diesem Grund wird hier der Zeitpunkt des Lösens der Bremse als Anfahrbeginn gewählt<sup>113</sup>. Die Betrachtung des Anfahrvorgangs endet beim Nulldurchgang der Längsbeschleunigung, also beim Erreichen einer konstanten Fahrgeschwindigkeit oder Gaswegnahme. Dieses Ende wird vom Fahrer selbst gewählt – in Bild 6.2 ist dies bei ca. 3.7 s der Fall.

Das Fremdwort Komfort wurde Anfang des 19. Jahrhunderts aus dem englischen „comfort“ (Behaglichkeit, Bequemlichkeit) entlehnt<sup>114</sup> und wird seither meist in Verbindung mit technischem Fortschritt gebraucht, der dem Menschen das Leben erleichtert. Allgemein werden unter Komfort „auf technisch ausgereiften Einrichtungen beruhende Bequemlichkeiten, Annehmlichkeiten; einen bestimmten Luxus bietende Ausstattung“ verstanden<sup>115</sup>. Somit steht der Begriff Komfort für ein durch Technik erreichtes, menschenfreundliches Umfeld. Dies zeichnet sich einerseits dadurch aus, dass dem Menschen unangenehme und körperlich anstrengende Arbeiten abgenommen werden, andererseits übt eine komfortable Umgebung keine negativen Einflüsse auf den Organismus aus.

Hieraus ergeben sich zwei Standpunkte, von denen aus Komfort – bzw. Diskomfort – bewertet werden kann:

- Die Annahme, dass die Technik dem Menschen ein komfortables Umfeld im kleinen, beeinflussbaren Raum schaffen soll.
- Die Annahme, alles Störende sei unkomfortabel und der ideale Komfortfall sei die Ausschaltung aller die menschlichen Sinne unangenehm reizenden Einflüsse.

Die erste Annahme trifft die Bedeutung des Worts Komfort im historischen Sinn besser. Um zum Beispiel die Klimaanlage eines Automobils zu beschreiben oder zu bewerten, wäre dies auch die zweckmäßigere Beschreibung. Das Bewertungskriterium ist in diesem Fall die Abweichung des erzeugten Klimas von einem gedachten, für den Menschen idealen Klima.

Im Falle des Fahrkomforts ist es aber sinnvoll, von der zweiten Annahme auszugehen. Der Zweck des Fahrzeugs ist die Beförderung des Menschen und diese soll in erster Linie ohne negative Einflüsse auf den Organismus stattfinden. Das bedeutet für den hier untersuchten Anfahrvorgang bzw. das Fahrzeug als techni-

---

<sup>113</sup> Siehe auch Bild 4.3 bis Bild 4.7

<sup>114</sup> Auberle 2001 (DUDEN Herkunftswörterbuch)

<sup>115</sup> Eickhoff 2002 (DUDEN Bedeutungswörterbuch)

ches System, das ihn ausführt, dass es den Menschen in einer ihn nicht störenden Weise auf eine gewünschte Geschwindigkeit beschleunigen und ihm keinen „Diskomfort“<sup>116</sup> bereiten soll.

Bei dieser Betrachtungsweise hat vor allem der Antriebsstrang (Motor, Antriebs-elemente, Reifen und Anbindung an die Karosserie) des Fahrzeugs Einfluss auf den Anfahrkomfort. Das Fahrzeug selbst erregt also Effekte, welche störende Wirkungen auf die Passagiere ausüben. Als typische Komfortprobleme sind beim Anfahren das Kupplungsrupfen<sup>117</sup> während der Schlupfphase und das Anfahrruckeln<sup>118</sup> bei dynamisch verbundenem Antriebsstrang zu nennen. Seebacher und Fidlin<sup>119</sup> führen überdies als weitere komfortrelevante Größen das Geräuschphänomen Rasseln, sowie die Anfahrmodulation an, welche jedoch ausschließlich für Fahrzeuge mit fußbetätigter Kupplung relevant ist. Für diese Systeme gelten nach Zink und Shead<sup>120</sup> außerdem die Pedalvibration und Betätigungsgeräusche als den Komfort beeinträchtigende Erscheinungen.

## 6.2 Datengewinnung im Fahrversuch

Die Untersuchung zur Beurteilung des Anfahrkomforts gliedert sich in zwei Versuchsstaffeln, nämlich zum einen in die Versuche zur Ermittlung der Bewertungsgüte bezüglich Anfahrkomfort sowie zur Untersuchung des Komfortanspruchs der definierten Kundenzielgruppen, zum anderen in die Anfahrversuche zur Modellierung der Komfortbeurteilung.

### 6.2.1 Versuchsteilnehmer

Da nicht alle der in Kapitel 5.1.1 beschriebenen Versuchsteilnehmer für weitere Untersuchungen permanent zur Verfügung standen wurden 15 Personen ausgewählt<sup>121</sup>, welche die drei Kundenzielgruppen repräsentieren. Hiervon gehören jeweils fünf Personen zu einer der drei Kundenzielgruppen. Um nicht betrachtete Einflüsse auf den Komfortanspruch möglichst auszuschließen wurde die Auswahl

---

<sup>116</sup> Vgl. auch Bellemann et al. 2001

<sup>117</sup> Albers / Herbst 1998, Krüger 2003

<sup>118</sup> Mitschke 1994

<sup>119</sup> Seebacher / Fidlin 2005

<sup>120</sup> Zink / Shead 1998

<sup>121</sup> Siehe Bild 5.4

zusätzlich so vorgenommen, dass die betrachteten Personen privat alle ein Fahrzeug der Kleinwagen- bis Mittelklasse mit Handschaltgetriebe fahren. Die Altersstruktur der 15 ausgewählten Laienbewerter, von denen zwei weiblich sind, ist aus dem folgenden Bild 6.3 ersichtlich. Der Mittelwert beträgt 37.5 Jahre.




Bild 6.3: Altersstruktur der Bewerterstichprobe bestehend aus 15 Personen

An den Versuchen zur Ermittlung der Bewertungsgüte nahmen neben den beschriebenen 15 Laienbewertern drei Experten teil. Diese Experten sind Versuchs- bzw. Entwicklungsingenieure, welche im Rahmen ihrer Tätigkeit mit der Beurteilung von Kupplungssystemen betraut sind.

## 6.2.2 Versuchsbeschreibung

Als Versuchsfahrzeug kam das im zweiten Abschnitt von Kapitel 4.1 als „mobiler Simulator“ bezeichnete Fahrzeug mit der dort beschriebenen Messtechnik zum Einsatz. Die Teilnehmer bewerteten die in diesem Kapitel beschriebenen Anfahrvarianten jeweils aus der Sicht des Fahrers. Es wurden zwei Versuchsstaffeln gefahren, wobei einmal mit Hinblick auf eine Vergleichbarkeit der Anfahrten die maximale Gaspedalposition vorgegeben wurde und zum anderen die Fahrereingabe selbst zu wählen war, was eher dem Ablauf einer Probefahrt entspricht.

- Anfahrten mit Gaspedalvorgabe

Es werden für jede der fünf Anfahrvarianten jeweils zwei Anfahrten bei definierter maximaler Gaspedalstellung, durch mechanische Endanschläge bei 30%, 50%, 70% und 100% max. Pedalwert vorgegeben, durchgeführt und bewertet. Somit

ergeben sich je Versuchsperson 40 Anfahrten. Die Versuchsabfolge wird so gewählt, dass zuerst alle fünf Anfahrvarianten einmal bei 30%, danach bei 50%, 70% und schließlich 100% max. Pedalwert bewertet werden. Anschließend wird dieser Ablauf identisch wiederholt. Die genaue Reihenfolge der Anfahrvarianten bei den jeweiligen max. Pedalwerten zeigt Bild 6.4.

Durchgang 1																				
Nr.	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
Variante	A	E	B	C	D	B	A	D	E	C	C	B	E	A	D	D	C	A	E	B
max. PW	30%					50%					70%					100%				

Durchgang 2																				
Nr.	21	22	23	24	25	26	27	28	29	30	31	32	33	34	35	36	37	38	39	40
Variante	A	E	B	C	D	B	A	D	E	C	C	B	E	A	D	D	C	A	E	B
max. PW	30%					50%					70%					100%				

Bild 6.4: Versuchsmatrix der Anfahrten bei definiertem max. Pedalwert

Die selbe Einstellung wurde also nicht zweimal direkt nacheinander gefahren, so dass es den Bewertern praktisch nicht möglich war, sich bei der Wiederholungsbewertung an der erstmaligen Bewertung zu orientieren.

- Anfahrten ohne Gaspedalvorgabe

Es werden von jeder Versuchsperson jeweils pro Variante und Durchgang 10 Anfahrten nacheinander durchgeführt. Hierbei soll möglichst das Anfahren im gesamten möglichen Bereich der Gaspedaleingabe von Ankriechen bis Volllastanfahrt abgedeckt werden, wobei die Reihenfolge innerhalb einer Anfahrvariante frei wählbar ist. Dieses Programm wird von jeder Person zweimal durchgeführt. Bei fünf Varianten ergeben sich somit also insgesamt 100 Anfahrten. Bild 6.5 zeigt den genauen sequenziellen Versuchsablauf.

Durchgang 1																				
Nr.	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
Variante	A										B									
Nr.	21	22	23	24	25	26	27	28	29	30	31	32	33	34	35	36	37	38	39	40
Variante	C										D									
Nr.	41	42	43	44	45	46	47	48	49	50										
Variante	E																			

Durchgang 2																				
Nr.	51	52	53	54	55	56	57	58	59	60	61	62	63	64	65	66	67	68	69	70
Variante	A										B									
Nr.	71	72	73	74	75	76	77	78	79	80	81	82	83	84	85	86	87	88	89	90
Variante	C										D									
Nr.	91	92	93	94	95	96	97	98	99	100										
Variante	E																			

Bild 6.5: Versuchsmatrix der Anfahrten bei frei wählbarem Pedalweg

Die Fahraufgabe wurde den Bewertern in schriftlicher Form gestellt, wie sie im Folgenden beschrieben wird:

- Anfahrten mit Vorgabe:

*Lösen Sie das Bremspedal (Bemerkung: Das Fahrzeug beginnt sich in Bewegung zu setzen, sobald das Bremspedal gelöst wird) und geben Sie zügig Gas bis zum Stopper-Anschlag.*

- Anfahrten ohne Vorgabe:

*Lösen Sie das Bremspedal (Bemerkung: Das Fahrzeug beginnt sich in Bewegung zu setzen, sobald das Bremspedal gelöst wird) und geben Sie entsprechend Ihres Anfahrwunschs Gas. Je Anfahrvariante werden zehn Anfahrten durchgeführt. Variieren Sie den Anfahrwunsch im möglichen Bereich, d. h. von einer gemächlichen Anfahrt bis zur Vollast-Anfahrt.*

*Der Anfahrvorgang gilt als abgeschlossen, wenn Sie vom Gas gehen oder in den zweiten Gang schalten würden. Schalten Sie jedoch nicht, sondern halten Sie unmittelbar an. Das Abbremsen ist nicht Teil des Anfahrvorgangs und wird nicht bewertet. Danach folgt der nächste Anfahrvorgang.*

Die beiden Versuchsstaffeln wurden nicht am selben Tag durchgeführt, um die Probanden nicht in Ihrer Konzentrationsfähigkeit zu überfordern. Die Versuchsstaffel mit Gaspedalstopper wurde hierbei zeitlich vor der Staffel mit freien Anfahrten durchgeführt.

### 6.2.3 Bewertungsmethodik

Für die Komfortbeurteilung durch Laienbewerter wurde eine einfache, leicht anwendbare Beurteilungsmethodik entwickelt. Als zielführendes Verfahren der „gefühlsmäßigen“ Bewertung für den Komferteindruck hat sich in Vorversuchen mit Laienbewertern als Beifahrern das Ankreuzen einer gewissen Position auf einer stufenlosen Skala mit den subjektiven Endwerten „schlecht“ und „hervorragend“ bewährt<sup>122</sup>. Aufbauend auf diesen Voruntersuchungen wurde im Rahmen dieser Arbeit ein Bewertungsverfahren entwickelt, welches an das einer einfachen zweistufigen Skala angelehnt ist, jedoch mit einer kontinuierlichen Skala in der zweiten Ebene, ähnlich dem Ankreuzen auf einer Strecke mit subjektiven Endwerten. Durch eine farbliche Markierung wird eine Voreinteilung in Anlehnung an die Cooper-Harper<sup>123</sup> Skala bzw. an eine hieraus abgeleitete Zwei-Ebenen-Intensitätsskala ZEIS nach Käßler<sup>124</sup> gemäß positiver oder negativer Kaufent-

---

<sup>122</sup> Albers / Albrecht 2002

<sup>123</sup> Cooper / Harper 1969

<sup>124</sup> Käßler 1993

scheidung vorgenommen. Die Differenzierung der Bewertung erfolgt in einer zweiten Ebene. Durch die individuell interpretierbaren Formulierungen der Anker, wie sie Bild 6.6 zu entnehmen sind, kann jeder Proband seinen individuellen Komfortbereich abdecken.




Bild 6.6: Zweistufige Skala zur subjektiven Komfortbewertung

Um die Bewertung elektronisch erfassbar zu machen wird anstatt des Ankreuzens ein analoger Schiebewiderstand zur Erfassung der Bewertung verwendet. Die relative Lage der Markierung für den Komforteindruck von „absolut inakzeptabel“ bis „keine weitere Verbesserung erforderlich“ wird als Zahlenwert (Komfortwert) zwischen null und eins interpretiert. Das beschriebene Verfahren erfüllt die gestellten Anforderungen hinsichtlich der Durchführbarkeit der Bewertung voll und die Akzeptanz unter den Versuchspersonen ist hoch.

Die Bewertungsaufgabe wird dem Fahrer sowohl für die freien Anfahrten als auch für die Anfahrten mit definiertem Gaspedalstopper wie folgt gestellt:

*Versetzen Sie sich bitte in folgende Situation:*

*Sie möchten ein Fahrzeug dieses Typs mit einem automatisierten Kupplungssystem kaufen. Diese grundsätzliche Entscheidung ist bereits gefallen. Die generelle Frage nach dem Fahrzeugtyp, Farbe, Ausstattung, Mehrpreis für die Automatisierung, etc. blenden Sie also bitte aus. Nun sind in einem Autohaus zur Probefahrt eingeladen, um sich Ihre Meinung über das automatisierte Kupplungssystem zu bilden und können unterschiedliche Fahrzeugabstimmungen ausprobieren und Ihr Urteil äußern.*

*Stellen Sie sich dazu zuerst folgende Frage:*

*Würde ich dieses System so akzeptieren?*

Differenzieren Sie Ihre Antwort in einem zweiten Schritt zwischen den beiden Extremwerten "absolut inakzeptabel" und "keine weitere Verbesserung erforderlich", d. h. Sie würden das System genau so akzeptieren. Schieben Sie hierzu den Zeiger auf der Skala an die entsprechende Stelle und drücken Sie die Bestätigungstaste.

### 6.3 Überprüfung der Anfahrvarianten auf Kundenrelevanz

Als Grundlage der Überprüfung der Anfahrvarianten auf Kundenrelevanz dienen die in 6.2.2 beschriebenen acht Anfahrten je Variante (bei vier definierten Pedalstopperpositionen) der 15 Versuchspersonen. Pro Anfahrvariante sind also 120 Anfahrten vorhanden.

Bild 6.7 zeigt die Mittelwerte der Bewertungen je Kundenzielgruppe sowie aller 15 Personen bei jeweils 30%, 50%, 70% und 100% max. Pedalwert. Links dargestellt sind die Mittelwerte der tatsächlich im Intervall [0,1] vergebenen Komfortbewertungen. Das rechte Diagramm zeigt den prozentualen Anteil der Anfahrten, die jeweils mit einer Bewertung im Bereich positiver Kaufentscheidung (Akzeptanz) bewertet wurden.

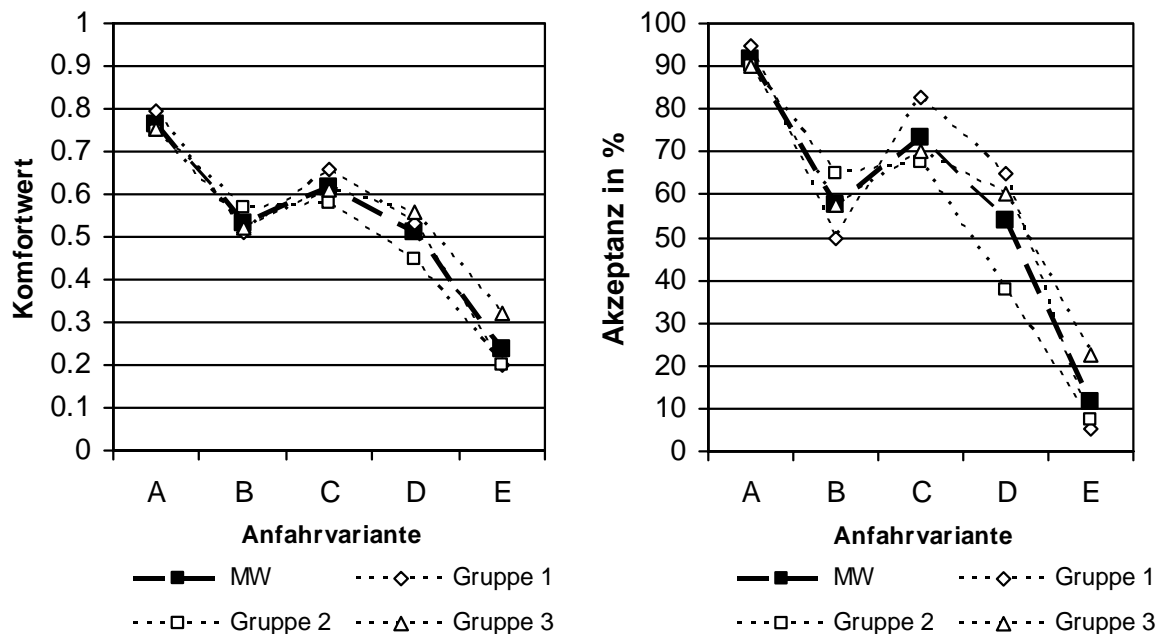


Bild 6.7: Mittelwerte der Beurteilung der Anfahrvarianten durch die Bewerterstichprobe

Wie die beiden Diagramme in Bild 6.7 verdeutlichen, liegen die untersuchten Anfahrvarianten im kundenrelevanten Bereich. Variante A wird im Mittel von 92% der Bewerter akzeptiert, d. h. mit einem Komfortwert größer als 0.5 beurteilt. Variante E hingegen wird nur in 12% der untersuchten Anfahrten akzeptiert.

## 6.4 Vergleich der Bewertungstreue von Laien und Experten

Zur Ermittlung der Bewertungstreue werden von Laien und Experten Anfahrversuche durchgeführt – wie in 6.2.2 als Anfahrten mit Gaspedalvorgabe beschrieben – und bezüglich des Anfahrkomforts bewertet. Durch die identische Wiederholung des Versuchsablaufs ist der paarweise Vergleich der Komfortbewertungen von Anfahrten derselben Anfahrvariante beim selben max. Pedalwert möglich. Zwar handelt es sich bei dem Versuchsfahrzeug um ein reales System mit teilweise nicht reproduzierbaren Eigenschaften – beispielsweise aufgrund von Temperatureinflüssen – was bedeutet, dass sich die beiden Anfahrten trotz identischer Anfahrvariante und max. Pedalwert zwar sehr ähnlich sind, aber nicht gänzlich identisch sein können. Die sich unkontrolliert ergebenden Unterschiede sind gegenüber den durch die unterschiedlichen Anfahrvarianten kontrolliert erzeugten Unterschiede jedoch gering. Da zudem eine exakt definierte Versuchsreihenfolge zu Grunde liegt wird außerdem sichergestellt, dass sich die einstellenden Systemänderungen bei allen Versuchspersonen in gleicher Weise ergeben haben.

Die Bewertungstreue wird hier als Wiederholgenauigkeit der Beurteilung zweier Anfahrten mit identischer Anfahrvariante und identischem max. Pedalwert definiert. Als Maß für die mittlere Bewertungsabweichung  $\Delta_{MB}$  wird der arithmetische Mittelwert der Absolutdifferenz der Bewertung zweier solcher Anfahrten definiert zu

$$\Delta_{MB} = \frac{1}{n} \sum_1^n |B_1 - B_2|. \quad \text{Gl. 6.1}$$

Die Anzahl  $n$  der paarweise verglichenen Anfahrten ist im untersuchten Fall 20. Werden zwei als identisch betrachtete Anfahrten auch mit dem selben Komforturteil bewertet, ergibt sich demnach eine Bewertungsabweichung von null. Die maximale Bewertungsabweichung beträgt 1, nämlich dann, wenn zwei als identisch angesehene Anfahrten einmal mit null und einmal mit eins bewertet werden.

An dieser Stelle sei nochmals auf die Versuchsreihenfolge verwiesen, die vorsieht, dass die verglichenen Anfahrten nicht direkt hintereinander gefahren wurden, sondern in einer Sequenz von 20 Anfahrten, die sich erst danach wiederholt.

Bild 6.8 zeigt jeweils die Komfortbewertung im zweiten Durchgang aufgetragen über der Komfortbewertung im ersten Durchgang links für den Bewerter mit der geringsten Wiederholgenauigkeit (Bewerter 2) sowie rechts für den Bewerter mit der höchsten Wiederholgenauigkeit (Bewerter 15).



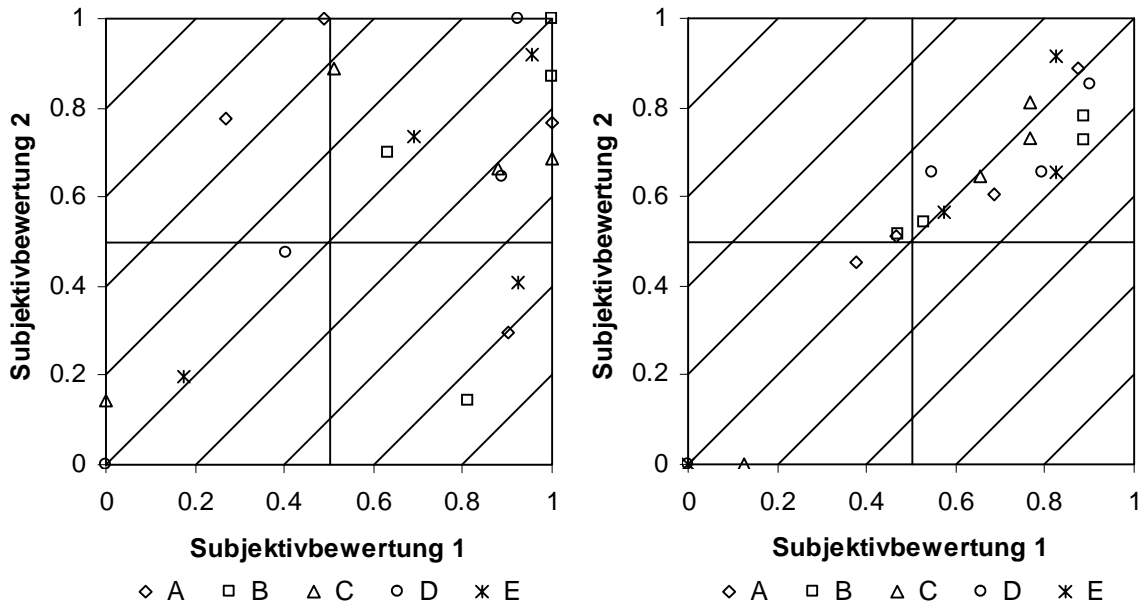


Bild 6.8: Wiederholbewertungen von Bewerter 2 (links) und Bewerter 15 (rechts)

Bild 6.9 zeigt im linken Bereich den jeweiligen Wert der mittleren Wiederholgenauigkeit für die 15 Laien, für die auch die Modellbildung durchgeführt wurde. Rechts sind zum Vergleich die Bewertungsabweichungen für drei Experten (Versuchsingenieure) unter denselben Randbedingungen dargestellt.




Bild 6.9: Mittlere Bewertungsabweichung von Laien und Experten

Wie aus Bild 6.9 ersichtlich ist, bewerten die einzelnen Personen mit deutlich unterschiedlicher Wiederholgenauigkeit. Es fällt auf, dass es durchaus Laienbewerter gibt, die in der Lage sind, Anfahrkomfort im Bereich der Wiederholgenauigkeit eines Experten zu bewerten. Es kann jedoch gezeigt werden, dass dies nur bei sehr wenigen Laienbewertern der Fall ist. Im Mittel bewerten die 15 hier untersuchten Laien zwei „identische“ Anfahrten mit einer Abweichung von  $\Delta_{MB} = 0.166$  und die

drei Experten mit einer Abweichung von  $\Delta_{MB} = 0.078$ . Eine quantitative Deutung dieser Werte fällt schwer, da sie ausschließlich für die hier untersuchten Anfahrten und die verwendete Beurteilungsmethode gelten. Es wird jedoch ersichtlich, dass Experten bei gleichen Randbedingungen mit einer Wiederholgenauigkeit um einen Faktor von rund zwei reproduzierbarer beurteilen als Laien.

Die Verwendung des in Kapitel 7.4 eingeführten Werts für die Modellgüte ist an dieser Stelle nicht sinnvoll, da die hier verglichenen Anfahrten eben nicht exakt identisch sind und demnach eine leicht unterschiedliche Bewertung rechtfertigen.

## 6.5 Zusammenhang zwischen Kundenzielgruppe und Komforturteil

Es erfolgt ein Vergleich der Komfortbeurteilung durch die 15 Personen nach Zugehörigkeit zu einer Kundenzielgruppe, wie sie in Kapitel 5.2.2 beschrieben ist. Als Datengrundlage dienen die in Kapitel 6.2.2 beschriebenen Anfahrten bei definierten max. Pedalwerten. Bild 6.10 zeigt im linken Diagramm die Mittelwerte der pro Person jeweils zweimaligen Komfortbeurteilung jeder Anfahrvariante bei 30%, 50%, 70% und 100% max. Pedalwert, getrennt nach Kundenzielgruppe. Im rechten Diagramm ist die Komfortbeurteilung der zuvor beschriebenen Anfahrten als prozentuale Anzahl zufriedener Kunden dargestellt, d. h. der prozentuale Anteil an Anfahrten, welche mit einem Komfortwert größer als 0.5 bewertet wurden.




Bild 6.10: Mittlere Komfortbeurteilung aller Betriebsbereiche (jeweils bei vier max. Pedalwerten je Anfahrvariante) nach Kundenzielgruppe

Anfahrvariante A (ähnlich der Serienabstimmung) wird im Mittel der über die Pedalwertvorgabe definierten Betriebsbereiche von jeder Kundenzielgruppe als die komfortabelste Variante beurteilt. Die leicht (C), mäßig (D) und stark (E) mit Anfahrerschwingungen behafteten Varianten werden – wenn auch in unterschiedlicher Abstufung – als unkomfortabler bewertet. Als Unterschiede sind zu erkennen, dass Variante C von Bewertern der Kundenzielgruppe 1 mit einem prozentualen Akzeptanzanteil über 80% durchaus noch toleriert wird, während die Bewerber der beiden anderen Gruppen hier kritischer urteilen. Variante B (mit langer Schlupfphase) hingegen wird von Kundenzielgruppe 1 weniger akzeptiert als von Personen der beiden anderen Zielgruppen. Obwohl Variante C mit leichten Längschwingungen von den zur Gruppe 3 gehörenden Versuchsteilnehmern, also den sportlichen Fahrern, weniger häufig akzeptiert wird als von den Personen der Gruppe A, wird die Anfahrvariante E mit starken Anfahrerschwingungen von dieser Kundenzielgruppe etwas weniger kritisch beurteilt als von den beiden anderen.

Eine differenziertere Betrachtung der Beurteilung der Anfahrvarianten bei unterschiedlichen Pedalwerten und damit Betriebsbereichen liefert deutlichere Erkenntnisse. In Bild 6.11 sind die Komfortbeurteilungen für max. Pedalwerte von 30% und in Bild 6.12 für Volllastanfahrten getrennt nach Kundenzielgruppe dargestellt. Auffällig ist, dass während Anfahrvariante B bei Anfahrten im Bereich niedriger Pedalwerte von den Fahrern der Kundenzielgruppen 2 und 3 wohl aufgrund der sehr mäßigen Beschleunigung als absolut inakzeptabel (siehe Bild 6.11 rechts) beurteilt wird, diese Anfahrvariante bei hohen Pedalwerten von den sportlicheren Fahrern der Gruppe 2 und 3 durchaus gute Beurteilungen erhält, während die Fahrer der Gruppe 1 hier keine guten Beurteilungen vergeben (siehe Bild 6.12).




Bild 6.11: Mittlere Komfortbeurteilung bei max. Pedalwert 30% nach Kundenzielgruppe

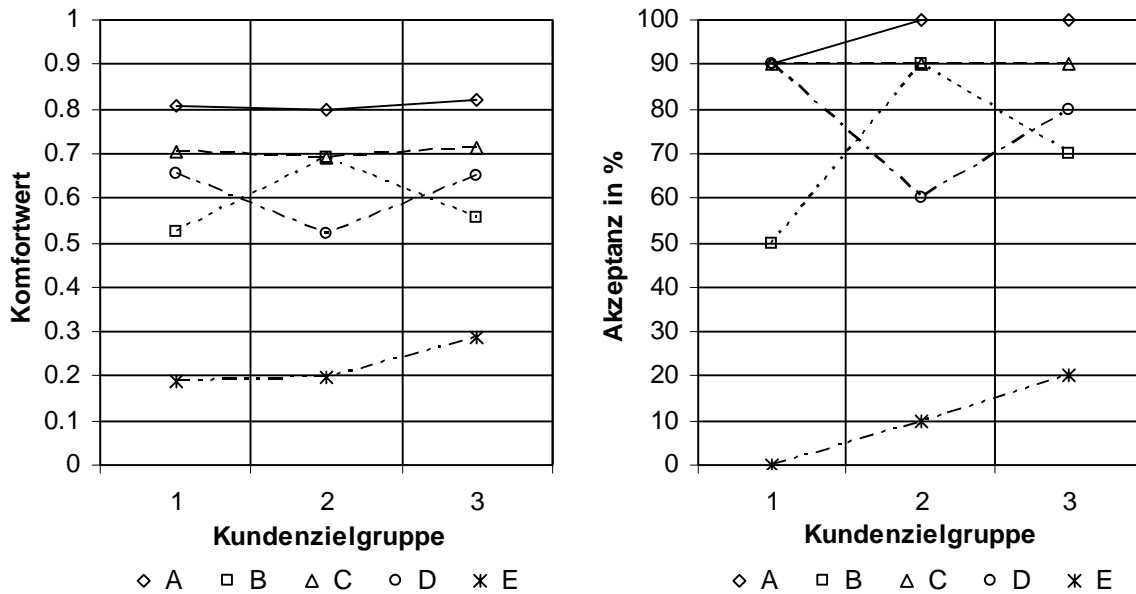


Bild 6.12: Mittlere Komfortbeurteilung bei max. Pedalwert 100% nach Kundenzielgruppe

Als Schlussfolgerung der Untersuchung ergibt sich, dass der Komfortanspruch der untersuchten Personen bezüglich Anfahrkomfort in weiten Bereichen recht ähnlich ist und Längsschwingungen während des Anfahrvorgangs von keiner Kundenzielgruppe akzeptiert werden. Ein sportlicher Fahrer ist vermutlich bereit, im Tausch gegen mehr Sportlichkeit bei einem Fahrzeug auf Komfort zu verzichten, hat aber bei der Betrachtung ein und desselben Fahrzeugs nicht grundsätzlich einen geringeren Komfortanspruch als andere Fahrer. Bei differenzierterer Betrachtung der Anfahrvariante B mit langer Schlupfphase bestätigt sich, dass eine solche Anfahrvariante vor allem von eher sportlichen Fahrer (Gruppe 2 und 3), bei hohen Pedalwerten teilweise durchaus gewünscht ist, bei niedrigen Pedalwerten allerdings nicht.

Wen sich die vorgestellte Methodik zur Untersuchung des Zusammenhangs von Kundenzielgruppe und Komfortbewertung als zielführend erwiesen hat, besitzen die in diesem Unterkapitel gezeigten Ergebnisse aufgrund der geringen Anzahl von fünf Versuchspersonen je Kundenzielgruppe sicherlich keinen Anspruch auf Allgemeingültigkeit. Außerdem ist zu vermuten, dass die hier untersuchte Personengruppe zu homogen ist, als dass allzu deutliche Unterschiede im Komfortanspruch erkennbar wären. Diese Untersuchungen stellen jedoch nicht den Fokus der vorliegenden Arbeit dar und eine höhere Anzahl an Versuchspersonen sowie eine marktgerechtere Auswahl typischer Kundengruppen war unter den gegebenen Randbedingungen nicht möglich.

## 7 Modellierung der Anfahrkomfortbeurteilung

Gegenstand dieses Kapitels ist die Modellierung und damit die Objektivierung des von PKW-Fahrern subjektiv empfundenen Anfahrkomforts. Als Datengrundlage dienen die in Kapitel 6.2 beschriebenen Fahrversuche.

### 7.1 Ableitung charakteristischer Größen für den Anfahrvorgang

Zunächst wird der Anfahrvorgang über das Bremssignal und das Signal der an der Fahrersitzschiene gemessenen Längsbeschleunigung identifiziert. Wie in Kapitel 6.1 beschrieben, beginnt der Anfahrvorgang mit dem Lösen der Bremse<sup>125</sup> und endet beim Nulldurchgang der tiefpassgefilterten Längsbeschleunigung, also beim Erreichen einer konstanten Fahrgeschwindigkeit oder Gaswegnahme. Die Identifikation der Anfahrvorgänge und die Ableitung charakteristischer Werte erfolgt mittels der Signalanalysesoftware imc-FAMOS<sup>126</sup>.

#### 7.1.1 Subjektivdaten

Das subjektive Komforturteil des Fahrers wird gemäß der in Kapitel 6.2.3 beschriebenen Bewertungsmethodik durch Einstellen eines Zeigers auf einem analogen Schiebewiderstand erzeugt. Die Ableitung eines Werts im Intervall  $[0,1]$  erfolgt durch Division der ermittelten Schieberstellung in mm durch die Gesamtskalenlänge. Werte für die Kaufentscheidung bzw. Akzeptanz oder Inakzeptanz des Systems werden als binäre Entscheidung um den Wert 0.5 gebildet.

---

<sup>125</sup> Das Fahrzeug besitzt eine Ankriechfunktion, d. h. sobald die Bremse gelöst wird beginnt die Zustellbewegung des Kupplungsaktors

<sup>126</sup> FAMOS Signalanalyse, imc Meßsysteme GmbH, Berlin

### 7.1.2 Objektivdaten

Die Ermittlung der charakteristischen objektiven Kennwerte erfolgt für die Fahrereingabe aus dem Gaspedalwertverlauf, sowie für die Fahrzeugantwort aus der Längsbeschleunigung. Diese Vorgehensweise wurde bereits in Vorversuchen entwickelt und überprüft<sup>127</sup>.

#### 7.1.2.1 Fahrereingabe

Aus dem Gaspedalweg abgeleitete Größen, welche die Fahrereingabe charakterisieren, sind die mittlere und die maximale Gaspedalposition, sowie der Zeitpunkt der max. Gaspedalposition relativ zur Anfordauer. Außerdem wird aus der zeitlichen Ableitung des Signals des Gaspedalwegs der maximale Gradient – also die maximale Pedalgeschwindigkeit, der relative Zeitpunkt des maximalen Gradienten, sowie der Mittelwert des Betrags des Gradienten, berechnet. Diese sechs Werte charakterisieren die Fahrereingabe und damit den Fahrerwunsch.

#### 7.1.2.2 Fahrzeugantwort

Während des Anfahrvorgangs wird die Längsbeschleunigung an der Sitzschiene und an der Kopfstütze des Fahrersitzes gemessen. Aus den Beschleunigungssignalen in Fahrtrichtung werden Eingangsdaten für die Objektivierungsmodelle im Zeit- und im Frequenzbereich ermittelt.

Im Zeitbereich werden vom jeweiligen Beschleunigungssignal drei Werte als Eingangsdaten für das KNN abgeleitet. Diese sind die Dauer des Anfahrvorgangs, welche aus dem Bremssignal als Indikator für den Beginn und dem Nulldurchgang des tiefpassgefilterten Beschleunigungssignals als Indikator für das Ende der Anfahrt ermittelt wird, das Maximum der erreichten Längsbeschleunigung und der Zeitpunkt des Auftretens dieser Maximalbeschleunigung relativ zur Anfordauer. Der Wert für die Anfordauer sowie der Wert für die Maximalbeschleunigung werden mittels Division durch zehn auf das Intervall  $[0,1]$  angepasst.


Die Ableitung charakteristischer Größen im Frequenzbereich geschieht in Anlehnung an die Bildung der modifizierten Spektralen Dichte mittels einer Bandpassfilterung, wie in Kapitel 2.2.1, Gl. 2.5 beschrieben. Aufgrund der Proportionalität kann im Rahmen dieser Untersuchungen auf das Quadrieren in Gl. 2.6 verzichtet werden. Hieraus ergibt sich die Formel für einen Objektivwert, im Folgenden als modifizierter PSD-Wert  $PSD(\Delta\omega)$  bezeichnet, der den Energieinhalt der Anfahrerschwingung in einem Frequenzintervall  $\Delta\omega$  charakterisiert, zu

---

<sup>127</sup> Albers / Albrecht 2004b

$$\text{PSD}(\Delta\omega) = \tilde{a}(\omega, \Delta\omega) = \frac{1}{T} \sqrt{\int_0^T a^2(\Delta\omega) dt} . \quad \text{Gl. 7.1}$$

Die Betrachtung des Frequenzbereichs von 0 Hz bis 100 Hz liefert mit der hier gewählten Filterbandbreite von 1 Hz 100 Werte. Zum Vergleich sind in Bild 7.1 das Ergebnis der Berechnung mittels Bandpassfilterung und mittels FFT für Anfahrvariante E bei einem maximalen Gaspedalwert von 50% gegenübergestellt. Die qualitativen Aussagen der beiden Berechnungsmethoden sind demnach weitestgehend gleichwertig.



*Bild 7.1: Vergleich der Objektivwert-Berechnung mittels Bandpassfilterung (schwarz) und mittels FFT (grau)*

Es erfolgt keine Gewichtung der Werte, wie sie in Kapitel 2.2.1 am Beispiel der VDI-Richtlinie 2057 beschrieben ist, da die Objektivwerte in den Bewertungsmodellen sowieso mit einem Verbindungsgewicht multipliziert werden, das einem Gewichtungsfaktor gleichkommt. Allerdings findet eine Datenreduktion durch die Bildung arithmetischer Mittelwerte in Anlehnung an die menschliche Empfindlichkeit statt, wie sie auch in Bild 2.7 beschrieben wird. Im Intervall von 0 Hz bis 10 Hz werden die Einzelwerte der modifizierten Spektralen Dichte übernommen, oberhalb von 10 Hz erfolgt eine Datenreduktion durch arithmetische Mittelwertbildung über Intervalle der Breite 10 Hz. Somit werden in Bereichen geringerer Empfindlichkeit des Menschen gegenüber Schwingungen Daten zusammengefasst, wodurch im Frequenzbereich über 10 Hz eine Verringerung der Information stattfindet. Im für den Anfahrkomfort relevanteren Frequenzbereich bis 10 Hz findet keine Datenreduktion statt und die Informationsdichte bleibt hoch.

Der sich ergebende modifizierte PSD-Wert im Bereich 0 - 1 Hz wird mittels Division durch den Faktor zehn auf das Intervall [0,1] angepasst. Bild 7.2 bis Bild 7.4 zeigen die aus dem an der Fahrersitzschiene gemessenen Signal abgeleiteten Objektivwerte der in Bild 4.3 bis Bild 4.7 als Zeitsignalverläufe dargestellten Anfahrten. Wenn diese Diagramme die unterschiedliche Schwingungsanregung bei den verschiedenen Anfahrvarianten auch anschaulicher visualisieren als die Zeitbereichswerte, so wird es dennoch selbst einem erfahrenen Versuchingenieur nicht möglich sein, hieraus einen exakten Komfortwert abzuleiten.

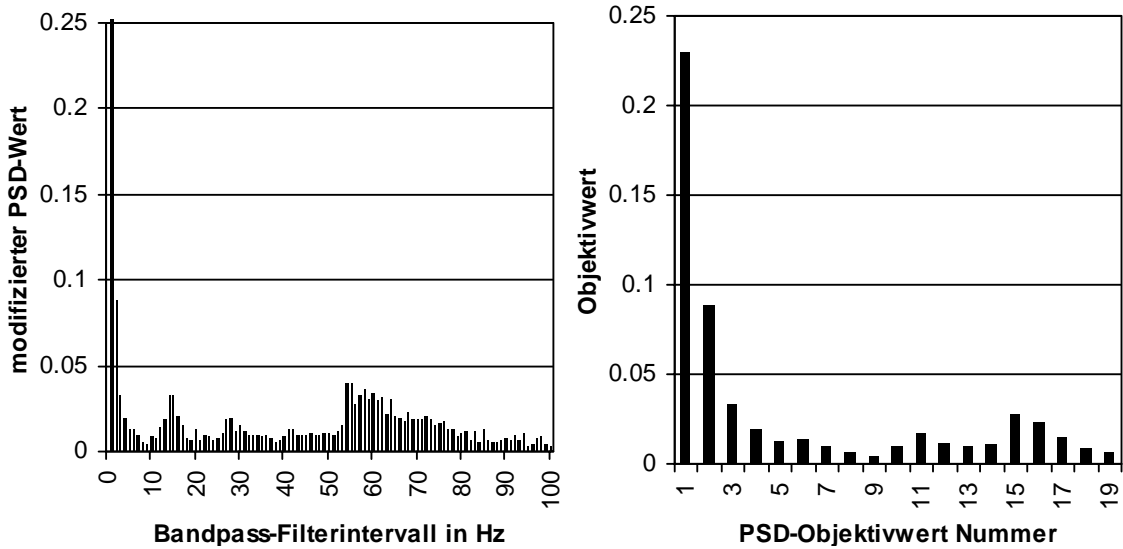


Bild 7.2: Objektivwerte im Frequenzbereich Anfahrvariante A bei max. Pedalwert 50%




Bild 7.3: Objektivwerte im Frequenzbereich Anfahrvariante B bei max. Pedalwert 50%



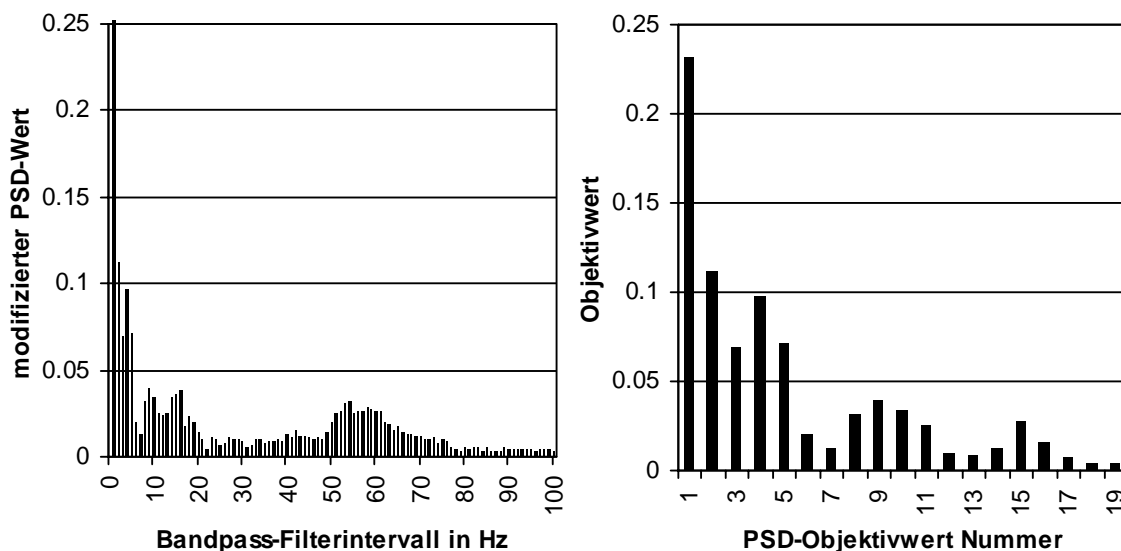


Bild 7.4: Objektivwerte im Frequenzbereich Anfahrvariante C bei max. Pedalwert 50%




Bild 7.5: Objektivwerte im Frequenzbereich Anfahrvariante D bei max. Pedalwert 50%




Bild 7.6: Objektivwerte im Frequenzbereich Anfahrvariante E bei max. Pedalwert 50%

## 7.2 Bildung von Arbeitsdatensätzen

Die 15 Personen, für welche die Modellbildung durchgeführt wird, haben sowohl an den in Kapiteln 5 vorgestellten Versuche zur Fahrerklassierung, als auch an den in Kapitel 6 beschriebenen Versuchen zur Ermittlung der Bewertungsgüte, teilgenommen. Es handelt sich zudem ausschließlich um Personen, die privat einen Klein bis Mittelklassewagen mit Handschaltgetriebe fahren.

Basierend auf den beschriebenen Fahrversuchen stehen für jede dieser Personen Datensätze, bestehend aus subjektiven Komforturteilen sowie den zugehörigen Objektivwerten, zur Verfügung. Als Grunddatensätze für die Modellierung der Anfahrkomfortbeurteilung dienen die Datensätze der 100 von jedem Versuchsteilnehmer ohne Gaspedalvorgabe bewerteten Anfahrten (siehe Kapitel 5.3). Es erfolgt eine Aufteilung dieser Grunddatensätze in Datensätze, die zur Modellbildung verwendet werden und Datensätze, die zur Überprüfung der Modelle eingesetzt werden. Die 100 Datensätze jeder Versuchsperson werden hierzu innerhalb der Sortierung bezüglich Anfahrvariante nach maximal erreichtem Pedalwert geordnet.

Für die Bildung der Regressionsmodelle erfolgt eine Aufteilung nach folgendem Schema: Jeder fünfte Datensatz, also insgesamt 20 Datensätze, werden für die Modellbeurteilung bezüglich Prognosegüte entnommen, die verbleibenden 80 Datensätze dienen der Modellbildung mittels Regression (R80-P20).

Für die Modellierung mittels KNN erfolgt die Aufteilung in Datensätze zur Modellbildung und Datensätze zur Modellüberprüfung prinzipiell identisch, jedoch werden zwei unterschiedliche Vorgehenseisen für die Modellvalidierung während der Trainingsphase verwendet (siehe Kapitel 7.6.1.5). Die Datenaufteilung T60-V20-P20 entspricht der Aufteilung, die den direkten Vergleich der Prognose der KNN-Modelle mit der der Regressionsmodelle erlaubt, d. h. die Überprüfung der Prognosegüte findet bei beiden Modellierungsverfahren exakt anhand der selben Datensätze statt, welche in keiner Weise für die Modellbildung im Rahmen des Netztrainings verwendet werden. Wie Bild 7.7 am Beispiel der Anfahrten einer Anfahrvariante veranschaulicht, werden zusätzlich zu jedem fünften Datensatz – der als Verifikationsdatensatz zur Überprüfung der Prognosegüte dient – der vierte und davon ausgehend jeder fünfte Datensatz als Validierungsdatensatz entnommen. Die verbleibenden 60 Datensätze dienen als Trainingsdaten.




Bild 7.7: Aufteilung in Trainings- (T), Validierungs- (V) und Prognosedaten (P)

Die T80-VP20 Datensätze hingegen sind identisch mit den R80-P20 Datensätzen, d. h. es erfolgt keine zusätzliche Abspaltung von Validierungsdaten aus den Trai-

ningsdaten. Die Validierung in der Trainingsphase erfolgt hier mit den Verifikationsdaten. Obwohl die 20 Verifikationsdatensätze nicht zum eigentlichen Training, also der Fehlerminimierung verwendet werden, findet somit implizit dennoch eine Optimierung der Modelle im Hinblick auf die Prognose dieser Daten statt, da diese indirekt in die Modellbildung im Rahmen der Modellvalidierung während des Trainings eingehen.

## 7.3 Signifikanzanalyse

Vorab wird für die pro Person vorhandenen 40 Grunddatensätze mit Gaspedalvorgabe (siehe Kapitel 5.3) mittels der Statistik-Analysesoftware SPSS<sup>128</sup> eine schrittweise Regressionsanalyse nach den Verfahren der Rückwärtselimination sowie der Vorwärtsselektion durchgeführt, um signifikante Objektivwerte zu identifizieren und zu prüfen, ob die entstehenden Regressionsmodelle für jeden einzelnen Bewerter die jeweils selben Objektivwerte als signifikant einstufen. Die Grunddatensätze mit Pedalvorgabe werden an dieser Stelle verwendet, da hier gewährleistet ist, dass jede Versuchsperson das identische Versuchsprogramm durchlaufen hat und der Einfluss einer unterschiedlichen Fahrereingabe praktisch ausgeschlossen werden kann. Die Werte der unabhängigen Variablen (Objektivwerte), die der Regression zu Grunde liegen, sind somit für die unterschiedlichen Bewerter jeweils weitestgehend identisch.

### 7.3.1 Anfahrten mit Gaspedalvorgabe

#### 7.3.1.1 Rückwärtselimination

Die schrittweise Rückwärtselimination startet mit der Berücksichtigung aller 28 Objektivwerte. Im ersten Schritt wird überprüft, wie groß der jeweilige p-Wert (vgl. Kapitel 2.2.2.1) eines Objektivwerts als unabhängige Variable ist, d. h. wie gut durch ihn der Zusammenhang mit der abhängigen Variablen – dem Komfortwert – erklärt werden kann. Hierbei wird durch einen F-Test (vgl. Gl. 2.16) getestet, ob alle im Modell enthaltenen unabhängigen Variablen gemeinsam keinen Einfluss auf die abhängige Variable ausüben. Es wird eine schrittweise Modellanpassung durchgeführt, indem sukzessive jeweils die unabhängige Variable mit dem größten p-Wert aus dem Modell eliminiert wird. Diese Vorgehensweise wird so lange wiederholt, bis nur noch Variablen mit einem p-Wert kleiner als das Signifikanzniveau

---

<sup>128</sup> SPSS Software GmbH, München

$\alpha = 0.05$  übrig sind, d. h. die Nullhypothese, dass der jeweilige Objektivwert keinen Einfluss hat, zu mehr als 95% verworfen werden kann. Die Signifikanz einmal eliminiertes Variablen wird nicht weiter überprüft.

Bild 7.8 zeigt das qualitative Ergebnis der Regressionsanalyse nach dem Verfahren der Rückwärtselimination. Die schwarz eingefärbten Felder signalisieren, dass die jeweilige unabhängige Variable signifikanten Einfluss auf das Modell hat. Die durch weiße Felder gekennzeichneten Objektivwerte wurden im Rahmen der schrittweisen Rückwärtselimination aus dem Modell entfernt.

	T_ges	max(PW)	T(max(PW))	M(PW)	max(Grad(PW))	T(max(Grad(PW)))	M(Betr(Grad(PW)))	a_max	T(a_max)	PSD_BP_000_001	PSD_BP_001_002	PSD_BP_002_003	PSD_BP_003_004	PSD_BP_004_005	PSD_BP_005_006	PSD_BP_006_007	PSD_BP_007_008	PSD_BP_008_009	PSD_BP_009_010	PSD_BP_010_020	PSD_BP_020_030	PSD_BP_030_040	PSD_BP_040_050	PSD_BP_050_060	PSD_BP_060_070	PSD_BP_070_080	PSD_BP_080_090	PSD_BP_090_100
Bewerter_01																												
Bewerter_02																												
Bewerter_03																												
Bewerter_04																												
Bewerter_05																												
Bewerter_06																												
Bewerter_07																												
Bewerter_08																												
Bewerter_09																												
Bewerter_10																												
Bewerter_11																												
Bewerter_12																												
Bewerter_13																												
Bewerter_14																												
Bewerter_15																												

Bild 7.8: Signifikante unabhängige Variablen bei Rückwärtselimination der 40 Anfahrten mit Pedalwertvorgabe

Es ist deutlich erkennbar, dass für unterschiedliche Bewerter jeweils unterschiedliche Objektivwerte als signifikante unabhängige Variablen (Prädiktorvariablen) in die einzelnen Regressionsmodelle eingehen.

### 7.3.1.2 Vorwärtsselektion

Die Signifikanzanalyse wird für dieselben Datensätze auch mittels schrittweiser Vorwärtsselektion durchgeführt. Hierbei werden ausgehend von einem leeren Modell schrittweise einzelne Objektivwerte zum Modell hinzugenommen, wenn sie signifikanten Einfluss haben. Konkret wird im ersten Schritt derjenige Objektivwert aufgenommen, der alleine beim F-Test den niedrigsten p-Wert liefert. Im nächsten Schritt wird überprüft, welcher der übrigen Objektivwerte zusammen mit dem bereits im Modell befindlichen den kleinsten p-Wert besitzt. Dieser Wert wird als nächstes zum Modell hinzugenommen. Dieser Prozess wird so lange wiederholt, bis keiner der übrig bleibenden Werte in Kombination mit den bereits im Modell aufgenommenen Prädiktorvariablen die Signifikanzschwelle unterschreitet, also

einen p-Wert kleiner gleich 0.05 besitzt. Einmal aufgenommene Variablen werden nicht mehr ausgeschlossen, auch wenn ihr p-Wert über 0.05 steigt. In Bild 7.9 sind die bei schrittweiser Vorwärtsselektion als signifikant eingestuftem Objektivwerte durch schwarze Felder gekennzeichnet, während weiße Felder nicht signifikante Variablen anzeigen.

	T_ges	max(PW)	T(max(PW))	M(PW)	max(Grad(PW))	T(max(Grad(PW)))	M(Betr(Grad(PW)))	a_max	T(a_max)	PSD_BP_000_001	PSD_BP_001_002	PSD_BP_002_003	PSD_BP_003_004	PSD_BP_004_005	PSD_BP_005_006	PSD_BP_006_007	PSD_BP_007_008	PSD_BP_008_009	PSD_BP_009_010	PSD_BP_010_020	PSD_BP_020_030	PSD_BP_030_040	PSD_BP_040_050	PSD_BP_050_060	PSD_BP_060_070	PSD_BP_070_080	PSD_BP_080_090	PSD_BP_090_100	
Bewerter_01																													
Bewerter_02																													
Bewerter_03																													
Bewerter_04																													
Bewerter_05																													
Bewerter_06																													
Bewerter_07																													
Bewerter_08																													
Bewerter_09																													
Bewerter_10																													
Bewerter_11																													
Bewerter_12																													
Bewerter_13																													
Bewerter_14																													
Bewerter_15																													

Bild 7.9: Signifikante unabhängige Variablen bei Vorwärtsselektion der 40 Anfahrten mit Pedalwertvorgabe

Auch hier zeigt sich, dass für unterschiedliche Bewerter häufig jeweils andere Objektivwerte signifikant sind.

### 7.3.1.3 Vergleich der als signifikant eingestuften Variablen

Am Beispiel der Ergebnisse der schrittweisen Regression mittels Rückwärtselimination und Vorwärtsselektion der 40 Datensätze mit Gaspedalvorgabe soll die Frage erläutert werden, ob – wenn man diese jeweils auf die selben Daten anwendet – für einen Bewerter jeweils die selben unabhängigen Variablen als signifikant in die Regressionsformel eingehen. Wie Bild 7.8 und Bild 7.9 verdeutlichen, unterscheiden sich die jeweiligen Rückwärts- und Vorwärts-Regressionsmodelle der 15 untersuchten Bewerter untereinander sehr, was auf die Individualität der Komfortbeurteilung durch unterschiedliche Personen hindeutet. Allerdings identifizieren die beiden eingesetzten Regressionsmethoden für einen Fahrer jeweils auch unterschiedliche Objektivwerte als signifikant, was zudem auf eine komplizierte Kollinearitätsstruktur der Objektivwerte schließen lässt. Von den Variablen, die in die mittels Rückwärtselimination gebildeten Modelle eingehen finden sich ca. 30% auch in den mittels Vorwärtsselektion gebildeten Modellen. Umgekehrt gehen etwa 57% der Variablen, die in den mittels Vorwärtsselektion erstellten Mo-

dellen vorkommen auch in die mittels Rückwärtselimination erstellten Modelle ein. Bei 14 der 15 Bewerter gehen jeweils zwei oder mehr unabhängige Variablen sowohl in die Vorwärtsselektions-, als auch in die Rückwärtseliminationsmodelle ein. Bei fünf Bewertern sind dies drei oder mehr Variablen und nur bei einem Bewerter sind es vier. Bei der Rückwärtselimination bleiben hier durchschnittlich exakt doppelt so viele Variablen übrig wie bei der Vorwärtsselektion. Die höhere Anzahl ist methodisch bedingt, da die Variablen bei der Vorwärtsselektion erst ein Kriterium (Signifikanzschwelle) erfüllen müssen, um überhaupt in die Regressionsgleichung aufgenommen zu werden. Durchschnittlich enthalten die Regressionsmodelle bei der Rückwärtselimination 8.93 und bei der Vorwärtsselektion 4.47 der insgesamt 28 möglichen unabhängigen Variablen.

Welches nun die als signifikant eingestuft sind, hängt also nicht zuletzt von der verwendeten Regressionsmethode ab. Bild 7.10 zeigt die Anzahl der in Bild 7.8 dargestellten Bewertermodelle, bei denen die jeweilige unabhängige Variable bei Rückwärtselimination als signifikante Variable ins Modell eingeht.




Bild 7.10: Anzahl Modelle mit signifikantem Objektivwert bei Rückwärtselimination der 40 Anfahrten mit Pedalwertvorgabe

Am häufigsten wird hier der PSD-Wert bei 0 - 1 Hz sowie bei 4 - 5 Hz – was dem Frequenzbereich der Ruckelfrequenz des Versuchsfahrzeugs im ersten Gang entspricht – als signifikante Variable im Regressionsmodell berücksichtigt.

In Bild 7.11 ist die Anzahl der in Bild 7.9 gezeigten Objektivierungsmodelle, bei denen die jeweilige unabhängige Variable bei Vorwärtsselektion als signifikante Variable ins Modell eingeht, dargestellt.




Bild 7.11: Anzahl Modelle mit signifikantem Objektivwert bei Vorwärtsselektion der 40 Anfahrten mit Pedalwertvorgabe

Am häufigsten gehen auch hier die PSD-Werte im Bereich der Ruckelfrequenz des Fahrzeugs (PSD-Werte im Bereich von 3 - 5 Hz) in die Modellbildung ein. Als weiterer Wert scheint der PSD-Wert im Bereich 50 - 60 Hz häufig signifikant zu sein. In diesem Frequenzbereich liegt beim verwendeten Versuchsfahrzeug und den untersuchten Anfahrvarianten während der Schlupfphase des Anfahrvorgangs die Zündfrequenz (1500 - 1800 1/min) des Verbrennungsmotors (vgl. auch Bild 4.3). Der mittlere Pedalwert M(PW), der max. Pedalwertgradient max(Grad(PW)), sowie die jeweiligen PSD-Werte bei 6 - 7 Hz, 9 - 10 Hz und 80 - 90 Hz gehen hingegen in keines der 15 Modelle ein.

Betrachtet man die Gesamtheit der mittels Rückwärtselimination und mittels Vorwärtsselektion erstellten Modelle, so sind der Objektivwert, welcher den Gleichanteil der Beschleunigung, sowie die Objektivwerte im Bereich der Ruckelfrequenz zwischen 3 und 5 Hz, die am häufigsten als signifikant in die Modellbildung eingehenden Variablen.

Es wurde gezeigt, dass die Regressionsanalyse für einzelne Bewerter sehr unterschiedliche Objektivwerte als signifikant identifiziert. Dies ist ein Indiz dafür, dass

unterschiedliche Bewerter unterschiedliche Phänomene beachten bzw. als mehr oder weniger störend empfinden. Außerdem sind die Modelle stark abhängig von der Regressionsmethode, nach der sie erstellt wurden. Es werden somit bei unterschiedlicher Vorgehensweise auch deutlich unterschiedliche unabhängige Variablen als signifikant eingestuft. Dies deutet auf eine hohe Kollinearität der unabhängigen Variablen hin.

### 7.3.2 Anfahrten ohne Gaspedalvorgabe

Für die 80 Datensätze, mit denen in Kapitel 7.5 die Modellierung der Anfahrkomfortbeurteilung durchgeführt wird, zeigt Bild 7.12 durch schwarze Felder die unabhängigen Variablen an, welche in die mittels schrittweiser Rückwärtselimination erstellten Regressionsmodelle eingehen. Nicht signifikante Objektivwerte sind durch weiße Felder gekennzeichnet.

	T_ges	max(PW)	T(max(PW))	M(PW)	max(Grad(PW))	T(max(Grad(PW)))	M(Betr(Grad(PW)))	a_max	T(a_max)	PSD_BP_000_001	PSD_BP_001_002	PSD_BP_002_003	PSD_BP_003_004	PSD_BP_004_005	PSD_BP_005_006	PSD_BP_006_007	PSD_BP_007_008	PSD_BP_008_009	PSD_BP_009_010	PSD_BP_010_020	PSD_BP_020_030	PSD_BP_030_040	PSD_BP_040_050	PSD_BP_050_060	PSD_BP_060_070	PSD_BP_070_080	PSD_BP_080_090	PSD_BP_090_100	
Bewerter_01																													
Bewerter_02																													
Bewerter_03																													
Bewerter_04																													
Bewerter_05																													
Bewerter_06																													
Bewerter_07																													
Bewerter_08																													
Bewerter_09																													
Bewerter_10																													
Bewerter_11																													
Bewerter_12																													
Bewerter_13																													
Bewerter_14																													
Bewerter_15																													

Bild 7.12: Signifikante unabhängige Variablen bei Rückwärtselimination von 80 der 100 Anfahrten ohne Pedalwertvorgabe

Wie Bild 7.12 im Vergleich zu Bild 7.8 zeigt, scheinen die 40 mit Pedalvorgabe gegenüber den 80 ohne Pedalvorgabe ermittelten Datensätze recht unterschiedlichen Inhalt zu haben. Bei der gleichen Regressionsmethode liefert die Rückwärtselimination der beiden Datensätze jeweils deutlich andere Ergebnisse für die Objektivierungsmodelle. Von den Variablen, die in die mittels Rückwärtselimination gebildeten Modelle auf Basis der Versuche mit Gaspedalvorgabe eingehen, finden sich ca. 35% auch in den Modellen auf Basis der Anfahrten ohne Gaspedalvorgabe. Umgekehrt gehen rund 38% der Variablen, die in diesen Regressionsmodellen vorkommen, auch in die erstgenannten Modelle ein. Bei 13 der 15 Bewerter gehen



jeweils zwei oder mehr unabhängige Variablen sowohl in die mit Gaspedalvorgabe, als auch in die ohne Gaspedalvorgabe erstellten Modelle ein. Bei acht Bewertern sind dies drei oder mehr Variablen, bei fünf Bewertern sind es vier oder mehr gleiche Variablen, bei einem sechs und bei einem Bewerter sogar sieben.

In Bild 7.13 ist die Anzahl der in Bild 7.12 dargestellten Objektivierungsmodelle, bei denen die jeweilige unabhängige Variable als signifikanter Objektivwert ins Modell eingeht, über den jeweiligen unabhängigen Variablen aufgetragen.




Bild 7.13: Anzahl Modelle mit significantem Objektivwert (Rückwärtselimination) bei Betrachtung von 80 der 100 Anfahrten ohne Pedalwertvorgabe

Am häufigsten wird wiederum der lineare Anteil der Beschleunigung, gefolgt von dem PSD-Wert im Bereich der Ruckelfrequenz, als signifikant identifiziert. Anhand der hier gezeigten Regressionsmodelle wird in Kapitel 7.5.2 die Überprüfung der Approximations- und der Prognosegüte durchgeführt.

## 7.4 Maß für die Modellgüte

Die Modellbewertung wird in dieser Arbeit anhand der Übereinstimmung der aus Objektivwerten berechneten Komforturteile mit den zugehörigen im Versuch ermittelten Subjektivurteilen, durchgeführt. Als Maß für die Beurteilung der Güte scheint sich die arithmetische mittlere Abweichung von berechnetem und tatsächlichem

Wert anzubieten. Eine Abweichung von null würde hierbei eine optimale Modellierung bedeuten. Die mittlere Abweichung alleine berücksichtigt jedoch einzelne grobe Ausreißer nicht in dem Ausmaß, in dem sie nach Meinung des Autors im betrachteten Fall berücksichtigt werden sollten. So sollte eine insgesamt im Mittel für alle Daten ungenauere Approximation einer zwar für viele Daten genaueren, aber für einige wenige sehr ungenauen, vorgezogen werden. Hintergrund dessen ist, dass bei der Anwendung der Objektivierungsmodelle zur Beurteilung von Objektivdaten, die extreme Fehleinschätzung einer Berechnung weit reichende Konsequenzen haben kann.

Da hier ein linearer Zusammenhang zwischen berechnetem und tatsächlichem Komfortwert bekannt ist, bietet es sich an, die berechneten Werte mit den tatsächlich im Fahrversuch ermittelten Komfortwerten mittels einer einfachen linearen Regressionsanalyse zu vergleichen. Sie liefert eine Gleichung der Form  $y = a \cdot x + a_0$  mit der Steigung  $a$  und dem  $y$ -Achsenabschnitt  $a_0$ . Der Determinationskoeffizient  $R^2$  gibt an, wie gut die Gerade die Punkte beschreibt. Im Idealfall der exakten Vorhersage würden alle Punkte auf der ersten Winkelhalbierenden liegen. Die Regressionsanalyse alleine erlaubt jedoch in einigen Fällen ebenso nicht die realistische Beurteilung der Netzgüte, da sie in Einzelfällen missinterpretierbare Werte liefert. Bild 7.14 veranschaulicht diesen Sachverhalt anhand einfacher Beispiele.




Bild 7.14: Beispielhafte  $x$ - $y$ -Zusammenhänge mit Regressionsgeraden

Die Berechnung der mittleren Abweichung ergäbe für die in Bild 7.14 links exemplarisch dargestellten 10 Punkte einem Wert von  $\Delta_M = 0.07$ , was eine sehr geringe Abweichung und somit ein sehr gutes Ergebnis bedeuten würde. Die Regressionsanalyse beschreibt den dargestellten Zusammenhang mit einem Regressionskoeffizienten von  $a = 0.71$  und einem Determinationskoeffizienten von  $R^2 = 0.53$

besser, würde aber bei anderen Zusammenhängen nicht ausreichen, wie das in Bild 7.14 rechts dargestellte Beispiel verdeutlichen soll. Die Werte liegen hier alle auf einer Regressionsgeraden mit der Steigung von 0.87 bei einem sehr hohen Determinationskoeffizienten von 0.97. Die mittlere arithmetische Abweichung ist im dargestellten Fall jedoch nur 0.17, was dokumentiert, dass die berechneten Ergebnisse dennoch relativ schlecht mit den tatsächlichen Werten übereinstimmen.

Als Maß für die Güte der Berechnung von Komforturteilen wird deshalb ein Wert eingeführt, der die oben genannten Sachverhalte berücksichtigt<sup>129</sup>. Er besteht aus der Verknüpfung eines Maßes für

- den linearen Zusammenhang: Regressionskoeffizient  $a$ ,
- die Modellanpassung: Determinationskoeffizient  $R^2$ ,
- die Abweichung der vom KNN berechneten von den tatsächlich im Versuch ermittelten Werten: Mittlere arithmetische Abweichung  $\Delta_M$ .

Der Wertebereich für die mittlere arithmetische Abweichung ist  $0 < \Delta_M < 1$ , wobei der Wert null die exakte Vorhersage durch das Modell bedeutet. Für den Regressionskoeffizienten ergibt sich der theoretische Wertebereich zu  $-\infty < a < \infty$  mit eins als Optimum, d. h. einer Geradensteigung entsprechend der ersten Winkelhalbierenden, wobei  $0 < a < 2$  realistische Werte für die hier vorgestellte Untersuchung sind. Im Wertebereich  $0 < R^2 < 1$  stellt der Wert eins für den Determinationskoeffizienten das Optimum der Modellgenauigkeit dar, was bedeutet, dass die lineare Trendlinie zu 100% dem Modell entspricht.

Das eingeführte Gütekriterium wird den aufgeführten Zusammenhängen durch eine Kombination der genannten charakteristischen Werte gerecht. Die Güte  $G$  berechnet sich nach der Formel

$$G = \begin{cases} \frac{1}{2}(a + R^2 - \Delta_M) & 0 \leq a \leq 1 \\ \frac{1}{2}(2 - a + R^2 - \Delta_M) & 1 < a \leq 2 \\ 0 & a < 0, a > 2 \end{cases} \quad \text{Gl. 7.2}$$

Mit den angegebenen Wertebereichen ergibt sich der Wertebereich der Güte zum Intervall  $[0,1]$ , wobei der Maximalwert von eins eine optimale Modellvorhersage charakterisiert. Für den in Bild 2.2 links dargestellten x-y-Zusammenhang liefert das Gütekriterium einen Wert von  $G = 0.59$ , für das rechts dargestellte Beispiel einen Wert von  $G = 0.83$ . Ein Offset in der Berechnung wird durch das eingeführte Gütekriterium also eher toleriert, als ein einzelner Ausreißer.

<sup>129</sup> Vgl. Albers / Albrecht 2004a

## 7.5 Modellierung mittels multipler linearer Regression

Als Vergleichsbasis für die Beurteilung der in dieser Arbeit vorgestellten Methode der Modellbildung für Einzelpersonen mittels KNN wird die Modellbildung mittels Rückwärtselimination als Standardmethode durchgeführt.

### 7.5.1 Methodenbeschreibung

Die Regressionsmodelle basieren auf den R80-P20 Datensätzen der 15 Personen. Den 100 Anfahrten ohne Gaspedalvorgabe wurden, wie in Kapitel 7.2 beschrieben, insgesamt 20 Datensätze für die Modellüberprüfung entnommen. Mit den verbleibenden 80 Datensätzen wird die Modellbildung durchgeführt. Die Vorgehensweise bei der schrittweisen Rückwärtselimination entspricht der in Kapitel 7.3.1.1 beschriebenen.

### 7.5.2 Approximations- und Prognosegüte für Einzelpersonen

Die entstandenen Regressionsgleichungen werden nun benutzt, um mit ihnen Komfortwerte aus objektiven Kennwerten zu berechnen. Dies erfolgt zum einen für die 80 zur Modellbildung verwendeten Daten (Approximation), zum anderen für die 20 nicht zur Modellbildung verwendeten Daten (Prognose). Sofern sich bei der Berechnung Komfortwerte kleiner als null oder größer als eins ergaben, wurden diese auf null bzw. eins limitiert.

Im linken Diagramm von Bild 7.15 sind die mittels der Regressionsgleichung berechneten Komfortwerte über den tatsächlichen Komfortbeurteilungen des Bewerbers 8 für die zur Modellbildung verwendeten 80 Daten abgebildet. Das rechte Diagramm zeigt die Überprüfung des Regressionsmodells mittels der nicht zur Modellbildung verwendeten 20 Datensätze. Die Zugehörigkeit der Komforturteile zu den fünf Anfahrvarianten zeigen die in der Legende angegebenen Symbole.




Bild 7.15: Berechnung über tatsächlichem Komforturteil der Approximations- (links) und Prognosesdaten (rechts) für Bewerter 8

Für den in Bild 7.15 dargestellten Beispieldatensatz zeigt sich, dass das multiple lineare Regressionsmodell die zur Modellbildung benutzten Daten gut beschreibt. In diesem Beispiel beträgt der Determinationskoeffizient  $R^2 = 0.79$  für eine Regressionsgerade mit der Steigung  $a = 0.71$ . Mit einer mittleren Abweichung  $\Delta_M = 0.10$  ergibt sich damit nach dem in Gl. 7.2 eingeführten Gütekriterium eine Approximationsgüte von  $G_A = 0.70$ . Wie das in Bild 7.15 rechts dargestellte Diagramm verdeutlicht, ist die Berechnung der nicht zur Modellbildung verwendeten Datensätze hier durchaus auch zufriedenstellend möglich. Als Gütewert ausgedrückt ergibt sich mit  $R^2 = 0.64$ ,  $a = 0.72$  und  $\Delta_M = 0.14$  eine Prognosegüte von  $G_P = 0.61$ .

Für alle 15 betrachteten Bewerter zeigt Bild 7.16 im linken Diagramm die jeweiligen Gütewerte für die Approximation der zur Modellbildung verwendeten 80 Datensätze und im rechten Diagramm die Gütewerte für die Prognose der nicht zur Modellbildung verwendeten 20 Datensätze.




Bild 7.16: Modellgüten für Approximation (links) und Prognose (rechts)

Im Mittel ergibt sich für die 15 Bewerter für die Approximation der zur Modellbildung verwendeten Datensätze eine Güte von  $G_{A,M} = 0.68$ . Mit Ausnahme von Bewerter 9 sind dies durchaus gute Ergebnisse. Bei der Berechnung nicht zur Modellbildung verwendeter Daten streuen die Ergebnisse jedoch stark. Die Prognosegüte liegt hier im Durchschnitt der 15 Bewerter nur bei  $G_{P,M} = 0.38$ , wobei die in Bild 7.15 gezeigte Prognose der Komfortwerte von Bewerter 8 die zweitbesten Resultate liefert. Außer bei Bewerter 3, 8 und 15 werden deutlich schlechtere Ergebnisse erreicht als für die Überprüfung anhand der zur Modellbildung verwendeten Datensätze. Für Bewerter 9 ergibt sich neben dem schlechtesten Ergebnis für die Approximationsgüte auch für die Prognosegüte der niedrigste Wert.

Mittels dieser Regressionsmodelle wird u. a. die in Kapitel 8 gezeigte Komfortbewertung realer und simulierter Anfahrvorgänge durchgeführt.

## 7.6 Modellierung mittels künstlicher neuronaler Netze

Die allgemeinen Grundlagen der KNN wurden bereits im Kapitel 2.2.3.1 beschrieben. In diesem Kapitel erfolgt nun eine detaillierte Beschreibung der hier eingesetzten Feedforward-Netze. Bei der Erstellung und dem Training eines KNN müssen zahlreiche Parameter festgelegt werden. Eine sinnvolle Wahl dieser Parameter ist problemspezifisch und kann teilweise durch eine theoretische Betrachtung, teilweise aber nur empirisch gefunden werden. Aufgrund der vielen Abhängigkeiten und Beeinflussungen der möglichen KNN-Einstellungen untereinander wurden Voruntersuchungen durchgeführt, deren Ergebnisse in den angegebenen Vorver-

öffentlichungen<sup>130</sup> zu finden sind und an den entsprechenden Stellen in die vorliegende Arbeit einfließen. Die Modellierung wird für die geeignetsten KNN-Parameter gezeigt, d. h. das Ergebnis der KNN-Parameter, welche zu den besten Prognosegüten führen, wird vorweggenommen. Im anschließenden Unterkapitel 7.6.3 werden die Einflussfaktoren der KNN-Einstellungen auf die Approximations- und auf die Prognosefähigkeit aufgezeigt und diskutiert.

### 7.6.1 Methodenbeschreibung

Die Implementierung der KNN wird in MATLAB<sup>131</sup> unter Verwendung der Neural Network Toolbox realisiert. Für den Vergleich mit der Modellbildung mittels Regression erfolgt die Modellierung anhand der Datensätze in T60-V20-P20 Kombination, darüber hinaus wird die Modellierung für die T80-VP20 Datensätze durchgeführt. Berechnete Komfortwerte kleiner als null oder größer als eins wurden, wie auch bei der Modellierung mittels Regression, auf null bzw. eins gesetzt.

#### 7.6.1.1 Netztopologie

Unter der Topologie des Netzwerks wird das Muster der Verbindungen zwischen den einzelnen Neuronen verstanden, die in mehreren Schichten angeordnet werden. Man unterscheidet dabei in Eingangsschicht (Inputlayer), verdeckte Schichten (Hiddenlayers) und Ausgangsschicht (Outputlayer). Die Anzahl der Neuronen in der Eingangsschicht ist gleich der Anzahl der Eingangsgrößen je Datensatz (hier: Anzahl der Objektivwerte) und die Anzahl der Neuronen in der Ausgangsschicht ist gleich der Anzahl der Ausgabewerte (hier: Komfortwert). Die Anzahl der Neuronen in der verdeckten Schicht bzw. den verdeckten Schichten muss mindestens eins sein, ist sonst aber frei wählbar. Die Art der Verbindung der einzelnen Neuronen untereinander ist ebenfalls variierbar. Bei den hier betrachteten Feed-forward-Netzen erfolgt die Verbindung und damit die Signalweiterleitung ausschließlich vorwärts in Richtung Ausgangsschicht. Generell kann gesagt werden, dass ein mehrschichtiges KNN zur Approximation praktisch jeder Funktion in der Lage ist, wenn die verdeckte Schicht genügend Neuronen besitzt und die Anzahl der Trainingsepochen nicht begrenzt wird (siehe auch Bild 7.35, links). Jedoch gibt es keine allgemeingültige Regel, wie viele Schichten oder wie viele Neuronen für eine optimale Leistung ergeben<sup>132</sup>. Hierbei besteht ein Konflikt zwischen der Tat-

---

<sup>130</sup> Albers / Albrecht 2002, 2003a, 2004a, 2004b

<sup>131</sup> The MathWorks Inc., Natick, MA, USA

<sup>132</sup> Hagan et al. 1996

sache, dass zum Erreichen einer hohen Approximationsfähigkeit möglichst viele verdeckte Neuronen verwendet werden sollten, aber im Gegensatz dazu möglichst wenige verdeckte Neuronen eingesetzt werden sollten, um dabei die Fähigkeit zur Generalisierung nicht herabzusetzen. Ob ein KNN zu einem Generalisierungsverlust, d. h. einer Überanpassung an die Trainingsdaten neigt bzw. dazu in der Lage ist, hängt eng mit der Zahl der ihm zur Verfügung stehenden variierbaren Freiheitsgrade (Schwellwerte und Netzgewichte) zusammen, welche wiederum von der Neuronenanzahl abhängen. Ist diese Anzahl größer als die Anzahl der abzubildenden Trainingsdatensätze lässt sich dies anschaulich so formulieren, dass das KNN dann für jeden Trainingsdatensatz eine exklusive Kombination von Schwellwerten und Netzgewichten finden kann und diesen anschaulich „auswendig lernt“, ohne eine generelle Lösung für die das Problem beschreibenden Datensätze zu finden. Die Neuronenanzahl  $n_{NV}$  in der verdeckten Schicht, ab der ein Netz „auswendig lernen“ kann, hängt also von der Anzahl der zur Verfügung stehenden Trainingsdatensätze  $n_D$ , der Anzahl der Eingangsgrößen  $n_{NE}$ , sowie der Ausgangsneuronen  $n_{NA}$  ab. Die Anzahl der Freiheitsgrade  $n_F$  lässt sich für ein KNN mit einer verdeckten Schicht bei voller Verbindungsmatrix berechnen zu

$$n_F = n_{NE} \cdot n_{NV} + n_{NV} \cdot n_{NA} + n_{NV} + n_{NA} \cdot \quad \text{Gl. 7.3}$$

Die beiden multiplikativen Terme repräsentieren die jeweilige Anzahl an Verbindungen (und damit variablen Netzgewichten), die beiden Einzelsummanden beschreiben die variierbaren Schwellwerte in den entsprechenden Schichten. Erlaubt man nun eine geringere Anzahl an Freiheitsgraden als die Anzahl zu approximierender Trainingsdatensätze  $n_D$ , ergibt sich für die Grenzanzahl verdeckter Neuronen  $\hat{n}_{NV}$

$$\hat{n}_{NV} \leq \frac{n_D - n_{NA}}{n_{NE} + n_{NA} + 1} \cdot \quad \text{Gl. 7.4}$$

Für den hier betrachteten Fall nur eines Ausgabeneurons vereinfacht sich die Bedingung zu<sup>133</sup>

$$\hat{n}_{NV1} \leq \frac{n_D - 1}{n_{NE} + 2} \cdot \quad \text{Gl. 7.5}$$

Stehen für das Netztraining nur sehr wenige Trainingsdatensätze zur Verfügung, so ist das KNN also bereits bei sehr wenigen verdeckten Neuronen in der Lage, die Trainingsdaten „auswendig zu lernen“. Im Falle der hier untersuchten Arbeits-

---

<sup>133</sup> Siehe auch Stehle 2002



datensätze mit 60 bzw. 80 Trainingsdatensätzen ist dies bei 28 Eingangsneuronen und einem Ausgangsneuron bereits ab zwei bzw. drei verdeckten Neuronen möglich und bedarf geeigneter Gegenmaßnahmen. Die in Kapitel 7.6.3.3 gezeigten Ergebnisse bestätigen diese theoretische Betrachtung.

Abhängig von der Problemstellung, also den vorhandenen Datensätzen, können unterschiedliche Netztopologien zu den besten Ergebnissen führen. Neben der Anzahl der verdeckten Neuronen bleibt außerdem zu klären, wie diese anzuordnen sind, d. h. welche Netztopologie am sinnvollsten ist. Diese empirisch zu ermitteln bleibt für den speziellen Anwendungsfall unumgänglich, jedoch lassen sich einige grundlegende Erkenntnisse aus den im Rahmen dieser Arbeit durchgeführten Untersuchungen übertragen. Der Einfluss der Anordnung der Neuronen in einer oder mehreren verdeckten Schichten für den hier betrachteten Anwendungsfall wird in Kapitel 7.6.3.3 untersucht.

### 7.6.1.2 Neuronentyp bzw. Aktivierungsfunktion

Die unterschiedlichen Aktivierungsfunktionen der Neuronen sind ein weiterer Parameter, von dem die Leistungsfähigkeit des Netzes abhängt. Es können zahlreiche Funktionen als Aktivierungsfunktionen verwendet werden. Die Eingangs- und Ausgangsschicht besitzt üblicherweise jeweils Neuronen mit linearer Aktivierungsfunktion (=Identitätsfunktion), d. h. der Wert wird direkt weitergegeben. In der verdeckten Schicht werden häufig Neuronen mit logarithmisch-sigmoider (logsig) Aktivierungsfunktion eingesetzt. Die Funktionsgleichung lautet

$$\text{log sig}(x) = \frac{1}{1 + e^{-x}}. \quad \text{Gl. 7.6}$$

Bild 7.17 zeigt den zugehörigen Grafen der logarithmisch-sigmoiden Funktion.




Bild 7.17: Logarithmisch-sigmoide Funktion

Durch Verwendung der logarithmisch-sigmoiden Funktion als Aktivierungsfunktion wird die Fehlerfunktion des Netzes stetig und überall differenzierbar, was für die Minimumsuche beim Netztraining (siehe Kapitel 7.6.1.4) unabdingbar ist. Da zudem die Ableitung der logarithmisch-sigmoiden Funktion einfach als

$$f'(x) = \frac{d}{dx} \left( \frac{1}{1 + e^{-x}} \right) = \frac{e^{-x}}{(1 + e^{-x})^2} = f(x) \cdot (1 - f(x)) \quad \text{Gl. 7.7}$$

gebildet werden kann, eignet sich diese Funktion besonders zur Verwendung als Aktivierungsfunktion.

### 7.6.1.3 Netztraining und Netzanwendung

Die Arbeitsweise eines KNN gliedert sich in das Netztraining (Lernphase) und die Netzanwendung. Die grundsätzliche iterative Arbeitsweise des Trainings ist im Ablaufplan in Bild 7.18 links dargestellt. Das Netztraining findet mittels eines sog. Trainings- oder Lernalgorithmus statt, jenem Algorithmus, mit dem das KNN auf die Lösung eines bestimmten Problems trainiert wird.




Bild 7.18: Ablaufplan Netztraining (links) und Netzanwendung (rechts)

Die Kombination der Schwellwerte (Bias) und Verbindungsgewichte eines KNN, die den Berechnungsfehler bis zum gewünschten Abbruchkriterium minimiert, stellt die Lösung des Lernproblems dar. In den Verbindungsgewichten und Schwellwerten ist dann das „Wissen“ des KNN gespeichert. Nach dem Training hat das KNN eine definierte Struktur und kann zur Interpretation von Daten mit einer ähnlichen Struktur, d. h. gleich vielen Eingabewerten je Datensatz wie die zum Training verwendeten Eingangsdaten, verwendet werden, indem aus diesen Eingabewerten die zu erwartenden Ausgabewerte ermittelt werden.

Wenn das Netztraining auch – abhängig vom zu lösenden Problem und den hierzu vorgenommenen KNN-Einstellungen – teilweise sehr rechen- und damit zeitintensiv sein kann, so geschieht die Berechnung der Ausgabewerte in der Anwendungsphase um ein vielfaches schneller und stellt keinen Nachteil gegenüber einem einfachen Regressionsmodell dar.

#### 7.6.1.4 Trainingsalgorithmen

An dieser Stelle wird der weit verbreitete Backpropagation-Algorithmus als grundlegender Algorithmus für das überwachte Lernen in KNN kurz beschrieben. Der Backpropagation-Algorithmus arbeitet in zwei Schritten. Im Feedforward-Schritt wird am Eingang ein Trainingsmuster vorgegeben und der sich durch die im vorherigen Schritt ermittelten Netzgewichte und Schwellwerte ergebende Output berechnet. Die anfängliche Initialisierung der Netzgewichte und Schwellwerte erfolgt dabei im ersten Schritt üblicherweise zufällig. Diese zufällige Initialisierung kann gespeichert und zwecks der Reproduzierbarkeit wieder vorgegeben werden. Aus dem so berechneten und dem tatsächlich gewünschten Output der Trainings-Ausgangsdaten wird der Fehler berechnet. Üblicherweise wird hierbei der mittlere quadratische Fehler (engl.: mean square error, kurz: mse) verwendet. Dieser Fehler wird nun im Backpropagation-Schritt von der Ausgangsschicht aus auf die Verbindungsgewichte und Schwellwerte in den einzelnen Schichten aufgeteilt und diese in der Art modifiziert, dass der Fehler reduziert wird. Der klassische Backpropagation-Algorithmus sucht das Minimum der Fehlerfunktion nach einem Gradienten-Abstiegsverfahren, wie beispielsweise dem Gauß-Newton-Verfahren.

Die in MATLAB<sup>®</sup> implementierten Trainingsalgorithmen sind meist Varianten bzw. Abkömmlinge des klassischen Backpropagation-Algorithmus, die bei der Suche nach dem Minimum unterschiedliche mathematische Verfahren benutzen. Im Rahmen der Voruntersuchungen zu dieser Arbeit hat sich der Levenberg-Marquardt-Algorithmus (LM-Algorithmus) als sehr leistungsstarker Trainingsalgorithmus erwiesen. Bei diesem Algorithmus erfolgt eine „Schätzung“ des Minimums anhand der sich in zwei aufeinander folgenden Schritten ergebenden Fehlerwerte. Zu Beginn der Iteration ergeben sich damit i. A. große Schrittweiten, womit die Methode des steilsten Abstiegs überwiegt. Im Laufe der Iteration wird die Schrittweite kleiner, so dass sich die Methode dem Gauß-Newton-Verfahren nähert. Hierdurch wird es möglich, dass lokale Minima zu Beginn der Fehlerminimierung quasi übersprungen werden. Eine detaillierte Beschreibung sowie Literaturverweise finden sich in der Hilfe des Programms<sup>134</sup>.

Die Minimumssuche endet, wenn ein vorgegebenes Abbruchkriterium erfüllt ist. Dies kann das Erreichen eines minimalen Fehlers sein, der jedoch vorab nicht bekannt ist. Im Rahmen dieser Arbeit wird der angestrebte Fehler deshalb jeweils auf null gesetzt, wenn dieser auch meist nicht erreicht werden kann. Um das Training dennoch zu beenden kann eine feste Anzahl von Trainingsepochen vorgegeben werden, wobei die Anzahl der benötigten Trainingsepochen zum Erreichen der

---

<sup>134</sup> MATLAB<sup>®</sup>, The MathWorks Inc., Natick, MA, USA

besten Prognosefähigkeit, d. h. der Fähigkeit, in der Anwendungsphase Ausgangsdaten aus nicht zum Training verwendeten Eingangsdaten zu berechnen, vorab ebenso nicht bekannt ist. Eine zu geringe Anzahl an Trainingsepochen führt zu nicht optimaler Approximation der Trainingsdaten und auch nicht optimaler Prognose nicht zum Training verwendeter Daten. Wird die Anzahl hingegen zu hoch gewählt, so kann beim Training eine Überanpassung an die Trainingsdaten erfolgen, was zu einem Verlust an Generalisierungsfähigkeit bei der Prognose von Ausgangsdaten aus nicht zum Training verwendeten Eingangsdaten in der Anwendungsphase führen kann. Der Trainingsdatensatz wird dann anschaulich „auswendig gelernt“, anstatt die Art der Verknüpfung zu entdecken. Gegenmaßnahmen sind die bereits in Kapitel 7.6.1.1 diskutierte Beschränkung der Neuronenanzahl, sowie das im folgenden Unterkapitel erläuterte Early-Stopping-Verfahren. Diese Methoden können auch kombiniert angewendet werden.

#### **7.6.1.5 Early-Stopping Abbruchkriterium**

Eine Methode, die Überanpassung des KNN an die Trainingsdaten zu verhindern, stellt das sog. Early-Stopping-Verfahren (ES-Verfahren) dar. Die Anzahl der Trainingsepochen wird hier nicht fix vorgegeben, sondern anhand von Validierungsdaten ermittelt. Dazu wird ein Teil der Daten des Trainingsdatensatzes abgespalten und als Validierungsdatensatz verwendet. Bei diesem Abbruchkriterium wird das Netz nach jeder Trainingsepoche anhand dieser Validierungsdaten überprüft, indem die Abweichung zwischen berechneten Werten und tatsächlichen Werten des Validierungsdatensatzes ermittelt wird. Wird der Validierungsfehler über eine einstellbare Anzahl von Epochen – im Rahmen dieser Arbeit wurden 25 Epochen gewählt – nicht mehr kleiner oder sogar größer, wird das Training rückwirkend nach der Anzahl Epochen, an welcher der Fehler der Validierungsdaten sein Minimum erreicht hatte, abgebrochen. Das trainierte KNN besitzt dann die Struktur, also die Schwellwerte und Verbindungsgewichte, die den minimalen Fehler zwischen berechneten und tatsächlichen Komfortwerten, sowohl für die Trainings-, als auch für die Validierungsdaten, aufweist.

#### **7.6.2 Approximations- und Prognosegüte für Einzelpersonen**

Im Folgenden wird die Modellbildung mittels KNN durchgeführt und sowohl die Ergebnisse bezüglich Approximation der jeweils zum Training verwendeten Trainingsdatensätze, als auch die Ergebnisse bezüglich der Prognose nicht zum Training verwendeter Daten (Verifikationsdatensätze), gezeigt. Die Überprüfung der Netzgüte erfolgt jeweils anhand des Vergleichs der durch das KNN aus den Objektivwerten prognostizierten Komfortwerte mit den tatsächlich im Versuch ermit-

telten Komfortwerten für diese Anfahrten. Für den Trainingsabbruch gemäß des in Kapitel 7.6.1.5 beschriebenen ES-Verfahrens werden einmal Validierungsdaten aus den Trainingsdaten abgespalten (T60-V20-P20), alternativ werden die Verifikationsdaten zur Validierung herangezogen (T80-VP20). Die letztere Variante stellt zwar eine Optimierung des Trainings im Hinblick auf die Netzanwendung für die Verifikationsdaten dar, an dieser Stelle sei jedoch noch einmal daran erinnert, dass die Daten, anhand derer die Prognosegüte ermittelt wird, obwohl sie beim ES-Verfahren zur Validierung verwendet werden, dem Netz für das eigentliche Training im Sinne der Fehlerminimierung, nicht zur Verfügung stehen.

### 7.6.2.1 Validierung mit einem Teil der Trainingsdaten

Wie in Kapitel 7.2 beschrieben erfolgt eine Aufteilung in Trainings-, Validierungs- und Verifikations- bzw. Prognosedaten. Der Großteil der Daten (60 Datensätze) wird zum eigentlichen Training – der Fehlerminimierung – herangezogen, ein weiterer Teil (20 Datensätze) wird im Rahmen des Early-Stopping Verfahrens als Validierungsdatensatz zur Überprüfung der Generalisierungsleistung während des Trainings benutzt. Der dritte Teil (20 Datensätze) dient der Verifikation des jeweils entstandenen Modells. Die zur Überprüfung der Prognosegüte verwendeten Verifikationsdaten werden in keiner Weise zur Modellbildung – auch nicht zur Validierung – verwendet und es handelt sich um exakt die selben Datensätze wie bei der in Kapitel 7.5.2 beschriebenen Modellierung mittels Regression. Die Netztopologie wird definiert durch 28 lineare Eingangsneuronen, drei verdeckte Neuronen mit logarithmisch-sigmoider Aktivierungsfunktion und ein lineares Ausgangsneuron. Als Trainingsalgorithmus wird der LM-Algorithmus mit 99 zufälligen Initialisierungen eingesetzt. Der Trainingsabbruch wird durch das ES-Verfahren anhand der beschriebenen 20 Validierungsdatensätze herbeigeführt. In Bild 7.19 ist beispielhaft für Bewerter 8 das Ergebnis dargestellt, welches bei 99 zufälligen Initialisierungen die höchste Prognosegüte ergibt. Im linken Diagramm sind die berechneten Komfortwerte der 60 Trainingsdatensätze und im rechten Diagramm die der 20 Validierungsdatensätze über den jeweils tatsächlichen Komfortwerten aufgetragen, wobei unterschiedliche Symbole die fünf Anfahrvarianten repräsentieren.




Bild 7.19: Berechnung Trainingsdaten (links) und Validierungsdaten (rechts) über tatsächlichem Komforturteil für Bewerter 8

Für die in Bild 7.19 links dargestellten Trainingsdaten ergibt sich für die Approximationsgüte ein Wert von  $G_A = 0.86$  (bei  $R^2 = 0.90$ ,  $a = 0.89$  und  $\Delta_M = 0.07$ ). Der Absolutwert der Berechnungsgüte der Validierungsdaten spielt für das Training keine Rolle, nur seine Entwicklung. Mit den vorgenommenen Trainingseinstellungen wurde überprüft, ob der Fehlerwert für die Berechnung der Validierungsdaten, der zu diesem Zeitpunkt gerade anfang anzusteigen, innerhalb der nächsten 25 Trainingsschritte – bei weiterer Fehlerminimierung für Berechnung der Trainingsdaten – wieder abnimmt. Da dies nicht der Fall war wurde das Training rückwirkend an dieser Stelle abgebrochen.

Bild 7.20 zeigt die zugehörige beste Prognose der 20 nicht zum Netztraining – und auch nicht zur Validierung – verwendeten Verifikationsdaten über dem jeweils tatsächlich von Bewerter 8 vergebenen Subjektivurteil.




Bild 7.20: Berechnung Verifikationsdaten über tatsächlichem Komforturteil für Bewerter 8

Die Netzanwendung ergibt für die 20 Verifikationsdaten bei diesem Bewerter mit  $R^2 = 0.75$ ,  $a = 0.90$ , und  $\Delta_M = 0.13$  eine maximale Prognosegüte von  $\hat{G}_P = 0.76$ . Damit gelingt die Prognose von Komforturteilen aus nicht zur Modellierung verwendeten Objektivwerten in diesem Fall mit einer um 0.15 höheren Güte, als dies bei der in Kapitel 7.5.2 gezeigten Modellierung mittels Regression der Fall ist.

Wie in Kapitel 7.6.1.4 beschrieben, müssen die Netzgewichte und Schwellwerte eines KNN initialisiert werden. Deren Wahl erfolgt hier im ersten Schritt zufällig. Nachdem in Bild 7.19 im linken Diagramm die Approximation und in Bild 7.20 die Prognose für das KNN dargestellt ist, welches zur höchsten Prognosegüte führt, zeigt Bild 7.21 für Bewerter 8 die Ergebnisse der Netzberechnung bei 99-maliger zufälliger Initialisierung über den tatsächlich vergebenen Komfortwerten. Dieser Vergleich ist im linken Diagramm für die Trainingsdaten (Approximation) und im rechten Diagramm für die Verifikationsdaten (Prognose) als Mittelwert  $\pm$  Standardabweichung dargestellt. Für die Validierungsdaten wird dieser Vergleich nicht gezeigt, da nur die Entwicklung des Validierungsfehlers, nicht aber der eigentliche Wert für die Validierung relevant ist.




Bild 7.21: Berechnung +/- SA bei 99 zufälligen Initialisierungen über tatsächlichem Komforturteil für Trainings- (links) und Verifikationsdaten (rechts) für Bewerber 8

Auf den Einfluss der zufälligen Initialisierung wird im Kapitel 7.6.3.1 noch detaillierter eingegangen

In Bild 7.22 sind links die mit der beschriebenen Netzeinstellung bei 99 Initialisierungen erreichten mittleren Modellgüten +/- Standardabweichung, sowie die maximal erreichte Modellgüte für die Approximation der Trainingsdaten und rechts für die Prognose der Verifikationsdaten für alle 15 Bewerber, dargestellt.




Bild 7.22: Modellgüten für Approximation (links) und Prognose (rechts)

Im Mittel der 15 Bewerber wird bei Betrachtung der jeweiligen mittleren Güte für die Approximation der Trainingsdaten bei 99 Initialisierungen ein Wert von  $G_{A,M} = 0.68$  erreicht. Bei der Betrachtung der jeweiligen Maximalwerte ergibt sich eine mittlere maximale Approximationsgüte von  $\hat{G}_{A,M} = 0.90$ . Für die Prognose der Verifikati-



onsdaten, welche beim Netztraining nicht zur Validierung verwendet wurden, ergibt sich im Mittel der 15 Bewerter eine mittlere Güte von  $G_{P,M} = 0.35$ . Der Mittelwert der hierbei jeweils erreichten maximalen Güten beträgt  $\hat{G}_{P,M} = 0.56$ .

Die mittlere Prognosegüte ist somit bei der Validierung mit einem Teil der Trainingsdaten um 0.03 geringer, als die mittels Regression erreichte Prognosegüte. Die im Mittel der 15 modellierten Bewerter jeweils maximal erreichte Prognosegüte hingegen ist um 0.18 höher. Wie auch bei der Modellierung mittels Regression gelingt die Prognose der Komforturteile von Bewerter 8 im Mittel der 99 zufälligen Initialisierungen am besten, während die Komforturteile von Bewerter 9 im Mittel am schlechtesten prognostizierbar sind.

Mittels der KNN-Modelle, welche für die einzelnen Bewerter jeweils die beste Prognosegüte liefern, wird die in Kapitel 8 gezeigte Komfortbewertung realer und simulierter Anfahrvorgänge durchgeführt.

### 7.6.2.2 Validierung mit Verifikationsdaten

Die Modellbildung wird mit den gleichen Netzeinstellungen wie zuvor im Kapitel 7.6.2.1 beschrieben durchgeführt, jedoch erfolgt die Überprüfung der Generalisierungsleistung während des Trainings (Validierung) anhand der Verifikationsdaten, mit denen auch die Modellüberprüfung stattfindet. Die 20 zuvor als Validierungsdaten verwendeten Datensätze werden zum Netztraining verwendet, d. h. das Training erfolgt nun mit 80 Datensätzen. Die Verifikationsdaten dienen hier jedoch weiterhin nicht zum eigentlichen Netztraining, d. h. die Anpassung der Netzgewichte und Schwellwerte erfolgt mittels LM-Algorithmus anhand der 80 Trainingsdatensätze.

Bild 7.23 zeigt im linken Diagramm am Beispiel von Bewerter 8 die berechneten Komfortwerte über den tatsächlichen Subjektivbewertungen für die Approximation. Im rechten Diagramm ist der Vergleich für die zugehörige beste Prognose der Verifikationsdaten dargestellt. Die jeweilige Anfahrvariante kann anhand der in der Legende angegebenen Symbole identifiziert werden.




Bild 7.23: Berechnung über tatsächlichem Komforturteil für Trainings- (links) und Verifikationsdaten (rechts) für Bewerter 8

Wie Bild 7.23 zeigt erfolgt sowohl die Approximation der Trainingsdaten, als auch die Prognose der Verifikationsdaten genauer als bei der im Kapitel 7.6.2.1 zuvor gezeigten Validierung mit einem Teil der Trainingsdaten. Trotz der höheren Anzahl von 80 anstatt 60 Trainingsdaten werden die Trainingsdaten hier bei gleicher Neuronenanzahl mit einer Güte von  $G_A = 0.87$  ( $R^2 = 0.91$ ,  $a = 0.89$ ,  $\Delta_M = 0.07$ ) besser berechnet. Die 20 Verifikationsdaten werden mit einer maximalen Güte von  $\hat{G}_P = 0.77$  ( $R^2 = 0.77$ ,  $a = 0.90$ ,  $\Delta_M = 0.12$ ) prognostiziert, womit die Prognose der Komforturteile aus den Objektivwerten der 20 Verifikationsdatensätze mit einer um 0.21 höheren Güte möglich ist, als wenn diese nicht zur Validierung benutzt werden. Im Vergleich zur mittels Regression erreichbaren Prognosegüte ist dies mit einer um 0.39 höheren – und damit mehr als doppelt so hohen – Prognosegüte der Fall.

In Bild 7.24 sind, zugehörig zum in Bild 7.23 gezeigten besten Prognoseergebnis, die Mittelwerte +/- Standardabweichung bei 99 zufälligen Initialisierungen und Verwendung der Verifikationsdatensätze als Validierungsdatensätze, links für die Approximation und rechts für die Prognose, dargestellt.




Bild 7.24: Berechnung +/- SA bei 99 zufälligen Initialisierungen über tatsächlichem Komforturteil für Trainings- (links) und Verifikationsdaten (rechts) für Bewerter 8

Bild 7.25 zeigt im linken Diagramm die Ergebnisse der Modellbildung und im rechten Diagramm die der Modellüberprüfung für alle 15 Bewerter bei 99 zufälligen Initialisierungen als mittlere Güte +/- Standardabweichung, sowie die jeweiligen Maximalwerte.




Bild 7.25: Modellgüten für Approximation (links) und Prognose (rechts)

Bewerter 2, 8 und 15 sind auch hier wiederum die Personen, deren Komforturteile am besten prognostiziert werden können. Im Mittel über alle 15 Bewerter liefert die Betrachtung der jeweiligen mittleren Güte für die Trainingsdaten einen Wert von  $G_{A,M} = 0.68$ . Für die Maximalwerte ergibt sich für die Approximation im Mittel der 15 Bewerter eine Güte von  $\hat{G}_{A,M} = 0.92$ . Die Prognose der nicht zur Modellbildung verwendeten Verifikationsdaten erfolgt im Mittel über die 15 Bewerter mit einer

mittlere Güte von  $G_{P,M} = 0.45$ . Der Mittelwert der hierbei jeweils erreichten maximalen Prognosegüten beträgt  $\hat{G}_{P,M} = 0.66$ .

Im Vergleich zu den Ergebnissen bei Validierung mit einem Teil der Trainingsdaten zeigt sich vor allem eine höhere Prognosegüte. Die im Mittel für die Modellierung der 15 Personen jeweils bei 99 Initialisierungen erreichte mittlere Prognosegüte liegt bei Benutzung der Verifikationsdaten als Validierungsdaten um 0.10 höher, als wenn die Validierung nicht anhand der Verifikationsdaten erfolgt. Die hierbei erreichten maximalen Prognosegüten liegen im Mittel der 15 Bewerter sogar um 0.20 höher. Dies ist zu erklären durch die Tatsache, dass die dabei verwendeten Validierungsdaten den Verifikationsdaten zwar ähnlich sind, diese aber dennoch nur bedingt repräsentieren. Verglichen mit den Ergebnissen der Modellierung mittels Regression gelingt die Prognose im Mittel der 15 Bewerter bei Betrachtung der jeweils mittleren Prognosegüten um 0.07 besser. Betrachtet man die jeweiligen Maximalwerte, welche für die Beurteilung des Verfahrens ausschlaggebend sind, ist die Prognose mit einer um 0.28 höheren Prognosegüte möglich.


### 7.6.3 Einfluss der Netzparameter

Im Folgenden werden die Einflüsse der einzelnen Netzparameter wie die Anzahl der verdeckten Neuronen, der Typ der verwendeten Aktivierungsfunktion, der Trainingsalgorithmus und das Abbruchkriterium diskutiert.

Da sich viele der beschriebenen Netzparameter gegenseitig bedingen und beeinflussen und die Ausprägungen dieser Einflüsse zudem von der zu modellierenden Person bzw. den betrachteten Datensätzen abhängen, wird die Betrachtung jeweils für alle 15 Bewerter durchgeführt und die Mittelwerte +/- Standardabweichungen, sowie die Maximalwerte, angegeben.

#### 7.6.3.1 Initialisierung

Dass es sich bei den maximal erreichten Prognosegüten nicht um „Zufallstreffer“ handelt, verdeutlicht Bild 7.26. Hier sind für die in Kapitel 7.6.2.1 gezeigten Ergebnisse bei Validierung mit einem Teil der Trainingsdaten (T60-V20-P20) im linken Diagramm beispielhaft die Prognose- über der Approximationsgüte aufgetragen. Das rechte Diagramm zeigt die Gütewerte für die Approximation in schwarzen und für die zugehörige Prognose – erkennbar an der selben Anzahl Trainingsepochen – in weißen Punkten über der Anzahl Trainingsepochen bis zum jeweiligen Early-Stopping-Abbruch bei 99 zufälligen Initialisierungen.



*Bild 7.26: Zusammenhang von Approximations-, Prognosegüte und Anzahl Trainingsepochen für Bewerter 8 bei Validierung mit einem Teil der Trainingsdaten*

Wie das in Bild 7.26 links dargestellte Diagramm zeigt, steigt die Prognosegüte mit zunehmender Approximationsgüte. Schlechte Approximationsergebnisse entstehen in erster Linie dann, wenn das KNN anhand der zu approximierenden Trainingsdaten keine oder zumindest keine gute Lösung für das Problem finden kann. Daraus resultierend kann in diesem Fall auch keine hohe Prognosegüte erreicht werden. Anhand des rechts dargestellten Diagramms ist außerdem ersichtlich, dass es zwar möglich ist, auch schon nach relativ wenigen Trainingsepochen ein sehr gutes Approximations- und auch Prognoseergebnis zu erreichen, was auf eine zufällig günstige Anfangsinitialisierung hindeutet. Eine hohe Anzahl an Trainingsepochen in Kombination mit einer hohen Approximationsgüte liefert jedoch immer auch eine hohe Prognosegüte. Dies ist nicht verwunderlich, da aufgrund des ES-Abbruchkriteriums einerseits eine Überanpassung an die Trainingsdaten verhindert wird, aber andererseits eine hohe Anzahl an Trainingsepochen ja nur dann erreicht werden kann, wenn mit einer guten Approximation der Trainingsdaten, zusätzlich auch eine gute Berechnung der Validierungsdaten einhergeht und damit von einer hohen Generalisierungsfähigkeit ausgegangen werden kann. Unter der Voraussetzung, dass die Verifikationsdaten diesen Validierungsdaten ähnlich sind, muss die gefundene Lösung somit auch für die Verifikationsdaten eine gute Berechnung erlauben. Anhand einer hohen Anzahl an Trainingsepochen und einer hohen Approximationsgüte kann somit also vorab eine Aussage über eine zu erwartende hohe Prognosegüte gemacht werden.

Die Abhängigkeit des Ergebnisses von der Anzahl der Initialisierungen – bei den selben Netzparametern wie zuvor beschrieben – ist im folgenden Bild 7.27 für Bewerter 8 dargestellt. Das linke Diagramm zeigt die mittlere Approximationsgüte +/-

Standardabweichung und die maximal erreichte Approximationsgüte bei jeweils Verdoppelung der Anzahl an Initialisierungen von 25 bis 3200. Das rechte Diagramm zeigt in selber Weise die erreichten Prognosegüten.

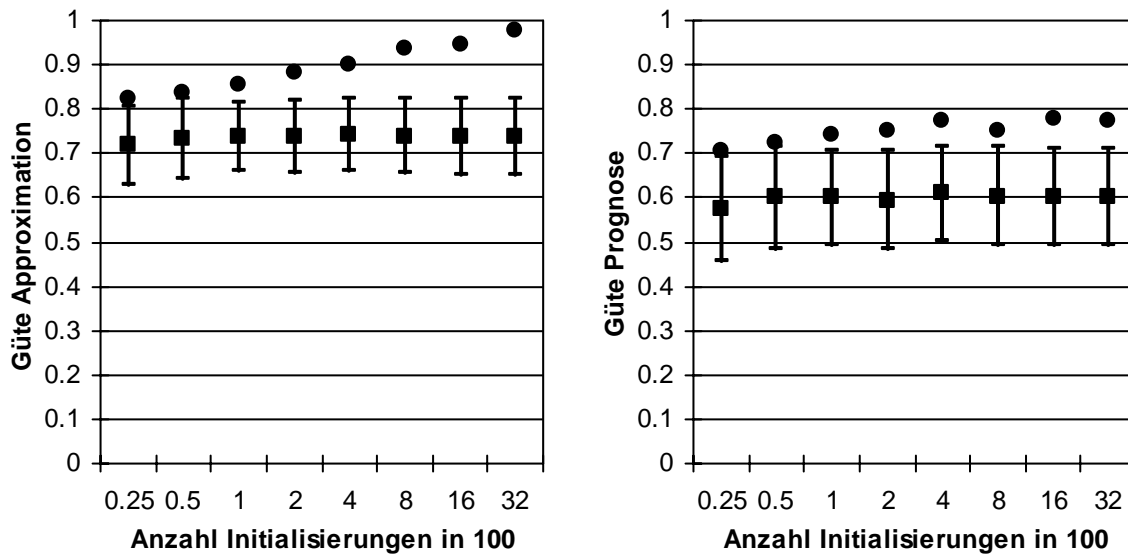


Bild 7.27: Approximations- (links) und Prognosegüte (rechts) für Bewerter 8 bei unterschiedlicher Anzahl zufälliger Initialisierungen

Die Wahrscheinlichkeit, ein KNN zu erhalten, das die Trainingsdaten extrem gut abbildet, steigt mit zunehmender Anzahl an Initialisierungen aufgrund der Tatsache, dass die Wahrscheinlichkeit einer zufällig günstigen Anfangsinitialisierung zunimmt. Deutlich fällt auf, dass die erreichbaren Maximalwerte genauso wie auch die Mittelwerte und Standardabweichungen für die rechts gezeigte Prognosegüte hier sehr ähnlich sind. Dies deutet darauf hin, dass die gefundenen „besten“ KNN – also diejenigen mit der höchsten Prognosegüte – nicht zufällig zu Stande gekommen sind, sondern tatsächlich bereits bei einer geringen Anzahl an Initialisierungen das Minimum, bzw. eines vieler gleichwertiger lokaler Minima, der Fehlerkurve gefunden wurde.

Die Anzahl von 99 zufälligen Initialisierungen, wie sie für die Untersuchungen im Rahmen dieser Arbeit verwendet wurde, scheint hierbei ausreichend zu sein, um jeweils eine gute Lösung für die Prognosegüte zu finden.

### 7.6.3.2 Aktivierungsfunktion

Die in dieser Arbeit bisher untersuchten KNN sind aufgebaut aus einer verdeckten Schicht mit drei Neuronen. Die Eingangs- und Ausgangsschicht besitzt jeweils Neuronen mit linearer Aktivierungsfunktion, d. h. der Wert wird direkt weitergegeben. In der verdeckten Schicht werden Neuronen mit logarithmisch-sigmoider

(logsig) Aktivierungsfunktion eingesetzt, welche die am häufigsten verwendete Aktivierungsfunktion bei KNN darstellt<sup>135</sup>. Alternativen sind beispielsweise die tangens-sigmoide (tansig) Funktion oder auch die einfache lineare (purelin) Funktion. Um den Einfluss der Aktivierungsfunktion zu untersuchen wurden diese beiden Funktionen als Alternativen zur logsig Aktivierungsfunktion mit dem Ergebnis untersucht, dass die tansig Aktivierungsfunktion sehr ähnliche Ergebnisse liefert wie die logsig Funktion. Für die im Kapitel 7.6.2.1 untersuchte Datensatzaufteilung T60-V20-P20 ergibt sich bei logsig Aktivierungsfunktion im Mittel der 15 Bewerter eine mittlere Prognosegüte von  $G_{P,M} = 0.35$ , bzw. eine maximale Prognosegüte von  $\hat{G}_{P,M} = 0.56$ . Bei tansig Aktivierungsfunktion ergibt sich  $G_{P,M} = 0.34$  bzw.  $\hat{G}_{P,M} = 0.58$ . Auch eine lineare purelin Aktivierungsfunktion liefert ähnliche Ergebnisse für die im Mittel der 15 Personen erreichte mittlere Prognosegüte, welche sich zu  $G_{P,M} = 0.37$  ergibt. Die hierbei im Mittel erreichte maximale Prognosegüte liegt mit  $\hat{G}_{P,M} = 0.48$  jedoch unter der mittels logsig bzw. tansig Aktivierungsfunktion erreichten. Ein ähnliches Bild ergibt sich für andere Neuronenanzahlen in der verdeckten Schicht. Es ist somit für die hier untersuchte Modellierung kein eindeutiger Einfluss der verwendeten Aktivierungsfunktion auf die Modellgüte nachweisbar. Allerdings werden selbst bei Verwendung von Neuronen mit linearer Aktivierungsfunktion bei Betrachtung der maximal erreichten Prognosegüten deutlich bessere Ergebnisse erzielt, als dies bei der Regression der Fall ist.

### 7.6.3.3 Neuronenanzahl und deren Anordnung

Die Anzahl der verdeckten Neuronen ist ein weiteres wesentliches Merkmal für die Leistungsfähigkeit eines KNN. Mit zunehmender Anzahl an verdeckten Neuronen steigt zwar dessen Approximationsfähigkeit, allerdings nimmt auch die Anfälligkeit für einen Verlust an Generalisierungsfähigkeit zu. Hierbei ist jedoch der Zusammenhang mit dem Abbruchkriterium des Trainings zu berücksichtigen. Wenn das Abbruchkriterium einen Generalisierungsverlust schon unterbindet, zeigt sich der Einfluss einer zu großen Anzahl von verdeckten Neuronen nicht so deutlich. Erlaubt das Abbruchkriterium aber eine Überanpassung an die Trainingsdaten, so nimmt zwar die Güte für die Abbildung der Trainingsdaten (Approximation) mit steigender Neuronenzahl stetig zu, im Gegensatz hierzu lässt die Güte der Prognose unbekannter Daten jedoch nach. Bild 7.28 zeigt diesen Effekt anhand des Standardnetzes mit drei verdeckten logsig-Neuronen in einer verdeckten Schicht. Der Trainingsabbruch erfolgt in diesem Fall nach konstant 20 Trainingsepochen. Es erfolgt demnach also keine Validierung während des Trainings, d. h. es wird mit 80 Trainingsdatensätzen und 20 Verifikationsdatensätzen gearbeitet. Als Trai-

---

<sup>135</sup> Moriwaki et al. 2001

ningsalgorithmus wird der LM-Algorithmus bei 99 zufälligen Initialisierungen eingesetzt.

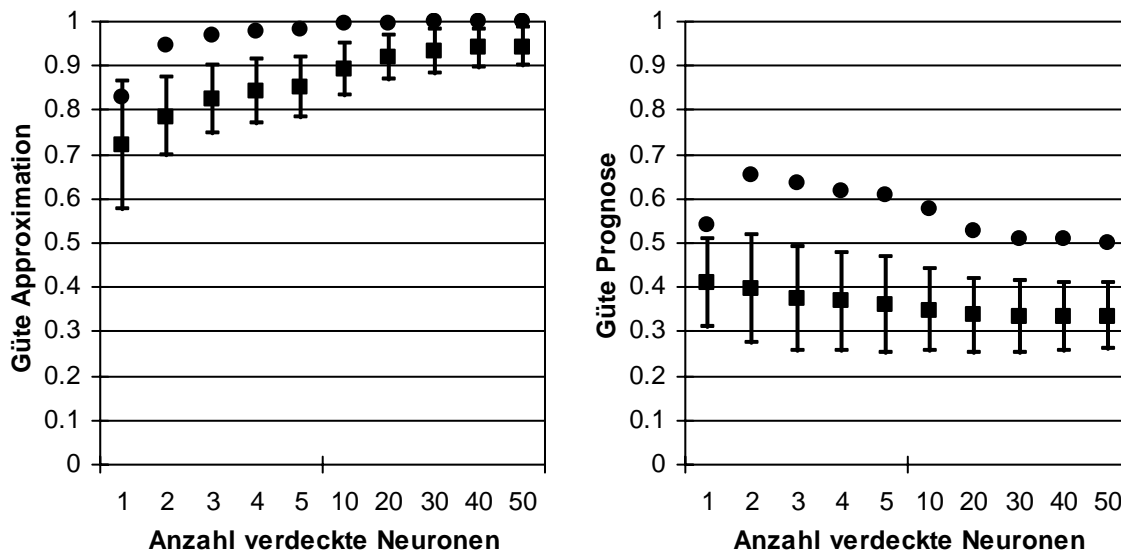


Bild 7.28: Approximations- (links) und Prognosegüte (rechts) bei unterschiedlicher Anzahl verdeckter Neuronen nach konstant vorgegebenen 20 Epochen

Es zeigt sich bei Betrachtung der im Mittel der 15 Bewerter erreichten mittleren und maximalen Approximationsgüte, dass die in Bild 7.28 links gezeigte Approximationsfähigkeit für die Trainingsdaten mit steigender Anzahl verdeckter Neuronen zunimmt. Die im rechten Diagramm dargestellte zugehörige Prognosegüte nicht zum Training verwendeter Daten nimmt hierbei jedoch ab. Bei einer höheren Anzahl von Neuronen in der verdeckten Schicht wird die Neigung zum „Auswendiglernen“ erhöht, d. h. es kann eine Überanpassung an die Trainingsdaten erfolgen, wodurch sich die Generalisierungsfähigkeit verschlechtert.

An dieser Stelle sei aufgrund des Zusammenhangs mit dem Abbruchkriterium ein Vorgriff auf das Kapitel 7.6.3.4 erlaubt. Dass das ES-Verfahren den Generalisierungsverlust effektiv unterbindet, zeigen Bild 7.29 und Bild 7.30. In Bild 7.29 sind im linken Diagramm die mittleren Modellgüten +/-Standardabweichung sowie die Extremwerte für die Approximation und im rechten Diagramm für die Prognose als Mittelwerte für alle 15 Personen über der Anzahl verwendeter Neuronen in der verdeckten Schicht, bei Validierung mit einem Teil der Trainingsdaten (T60-V20-P20), dargestellt.






Bild 7.29: Approximations- (links) und Prognosegüte (rechts) bei unterschiedlicher Anzahl verdeckter Neuronen bei Validierung mit einem Teil der Trainingsdaten

Bild 7.30 zeigt das Ergebnis der Untersuchung bei Validierung mit den Verifikationsdaten (T80-VP20).





Bild 7.30: Approximations- (links) und Prognosegüte (rechts) bei unterschiedlicher Anzahl verdeckter Neuronen bei Validierung mit den Verifikationsdaten

Im Gegensatz zu dem in Bild 7.28 gezeigten Phänomen, dass mit zunehmender Anzahl verdeckter Neuronen eine Verbesserung der Approximationsfähigkeit und ab einer bestimmten Anzahl eine Verringerung der mittleren Prognosefähigkeit eintritt, bleibt die Prognosefähigkeit nun auch bei sehr vielen verdeckten Neuronen im Mittel der 99 zufälligen Initialisierungen hoch. Die mittlere Güte, die Trainingsdaten zu approximieren steigt auch hier zuerst mit der Anzahl der verdeckten Neuronen an, erreicht aber – als Folge des Trainingsabbruchs zum im Hinblick auf die Prognosegüte „richtigen“ Zeitpunkt – nicht den Wert eins. Die Unterscheidung in

Validierung mit einem Teil der Trainingsdaten und Validierung mit den Verifikationsdaten bewirkt in erster Linie eine Parallelverschiebung der Gütwerte, wobei für die letztgenannte Vorgehensweise bessere Gütwerte erreicht werden. Folglich bringt die Verwendung einer höheren Anzahl verdeckter Neuronen, als dies nach Gl. 7.5 notwendig ist, bei gleichzeitiger Anwendung des ES-Verfahrens zwar keinen so deutlichen Nachteil bezüglich der erreichten mittleren bzw. maximalen Prognosefähigkeit, allerdings können durch die höhere Anzahl an Verbindungsgewichten und Schwellwerten komplexere KNN entstehen, als dies bei der Verwendung einer geringeren Anzahl der Fall ist. Dies ist jedoch nicht sinnvoll, wenn ein einfacheres Modell genauso gute Ergebnisse liefern kann. Darüber hinaus steigt die in der Trainingsphase benötigte Rechenzeit mit zunehmender Neuronenanzahl stark an, weswegen eine Beschränkung auf die gemäß Gl. 7.5 ermittelte Anzahl verdeckter Neuronen empfohlen wird.

Bild 7.31 zeigt anhand eines KNN mit 28 Eingangsneuronen, drei verdeckten Neuronen und einem Ausgangsneuron die möglichen Netztopologien für die Anordnung der drei verdeckten Neuronen (im Bild schwarz dargestellt) bei Aufteilung in eine, zwei und drei Schichten.



*Bild 7.31: Untersuchte Netztopologien mit drei verdeckten Neuronen*

Wie aus Bild 7.31 ersichtlich ist, ergeben sich je nach Netztopologie unterschiedlich viele Verbindungen. Bild 7.32 zeigt gemäß der in Bild 7.31 dargestellten Anordnung von drei verdeckten Neuronen bei 28 Eingangsneuronen und einem Ausgangsneuron die Summe der Verbindungen der Eingangsneuronen zu dem bzw. den verdeckten Neuron(en), der Verbindungen innerhalb der verdeckten Schicht bzw. Schichten, sowie der Verbindung(en) zum Ausgangsneuron.




Bild 7.32: Summe der Verbindungen bei unterschiedlicher Anordnung von drei verdeckten Neuronen bei 28 Eingangsneuronen und einem Ausgangsneuron

Unter ansonsten konstanten Randbedingungen werden KNN mit den in Bild 7.31 dargestellten Netztopologien bei Verwendung von logsig-Neuronen in der verdeckten Schicht bzw. den verdeckten Schichten mittels LM-Algorithmus und ES-Abbruchkriterium trainiert und hinsichtlich Approximations- und Prognose überprüft. Bild 7.33 zeigt im linken Diagramm die im Mittel für die 15 Bewerter erreichten Ergebnisse für die Approximation der jeweils 60 Trainingsdatensätze und im rechten Diagramm die Prognose der jeweils 20 Verifikationsdatensätze bei Validierung mit einem Teil der Trainingsdaten (T60-V20-P20) als Mittelwert +/- Standardabweichung, sowie Maximalwert.




Bild 7.33: Approximations- (links) und Prognosegüte (rechts) bei drei verdeckten Neuronen unterschiedlicher Anordnung und Validierung mit einem Teil der Trainingsdaten

Bild 7.34 zeigt in gleicher Weise die Ergebnisse bei Validierung mit den Verifikationsdaten, also 80 Trainings- und 20 Verifikationsdatensätze, welche auch als Validierungsdatensätze benutzt wurden (T80-VP20).




Bild 7.34: Approximations- (links) und Prognosegüte (rechts) bei drei verdeckten Neuronen unterschiedlicher Anordnung und Validierung mit den Verifikationsdaten

Anhand von Bild 7.33 und Bild 7.34 kann festgestellt werden, dass die Leistungsfähigkeit eines KNN im Wesentlichen mit zunehmender Anzahl an Netzverbindungen zunimmt. Die jeweils im Mittel der 15 Personen erreichten Maximalgüten bestätigen dies deutlich sowohl anhand der Approximations- als auch der Prognosegüten. Für die mittleren Güten gilt dies ähnlich, lediglich beim direkten Vergleich von KNN mit nahezu gleich vielen Verbindungen (1-1-1 / 1-2 mit 30 / 32 Verbindungen) zeigt sich, dass ein KNN mit mehr Schichten im Mittel bessere Ergebnisse liefert. Grund hierfür ist vermutlich, dass die Netzgewichte im Training sich nicht untereinander beeinflussen und somit weniger „Kompromisse“ gefunden werden müssen.

Fazit der gemachten Untersuchung ist, dass eine verdeckte Schicht für den hier betrachteten Anwendungsfall ausreicht und die Aufteilung in mehrere Schichten keine Vorteile mit sich bringt.

#### 7.6.3.4 Abbruchkriterium

Das Training endet, wenn ein zuvor gewähltes Abbruchkriterium erreicht wird. Als Abbruchkriterium kann der zu minimierende Fehler zwischen berechneten und tatsächlichen Trainingsausgangsdaten verwendet werden. Der minimal erreichbare Fehler ist jedoch in der Regel unbekannt, weshalb üblicherweise das Trainingsziel für den Fehlerwert auf einen so geringen Wert – üblicherweise auf null – gesetzt wird, dass das KNN diesen meist nicht erreichen kann. Alternativ kann das

Training nach einer gewissen Anzahl Trainingsepochen terminiert werden, wobei die Anzahl Trainingsepochen, die zum besten erreichbaren Ergebnis führt ebenso vorab nicht bekannt ist. Wie in Kapitel 7.6.1.5 beschrieben, stellt das Early-Stopping Verfahren (ES) ein Abbruchkriterium für das Netztraining dar, bei dem nach jeder Trainingsepoche anhand der Validierungsdaten ermittelt wird, ob die Generalisierungsfähigkeit des KNN abnimmt und nach einer festgelegten Anzahl weiterer Trainingschritte auch nicht mehr ansteigt. Ist dies der Fall, wird das Training an dieser Stelle rückwirkend abgebrochen.

Für eine unterschiedliche Vorgabe an Trainingsepochen, d. h. ohne Validierung mittels des ES-Verfahrens, zeigt Bild 7.35 für ein KNN mit drei verdeckten logsig-Neuronen die erreichte mittlere Güte +/- Standardabweichung und die Maximalgüte bei 99 Initialisierungen für die untersuchten 15 Personen. Im linken Diagramm sind die Werte für die Approximation der zum Netztraining mittels LM-Algorithmus verwendeten 80 Datensätze dargestellt, das rechte Diagramm zeigt die Prognosegüte für die Überprüfung der Netzanwendung anhand der 20 Verifikationsdatensätze.




Bild 7.35: Gütewerte bei unterschiedlicher (vorgegebener) Anzahl Trainingsepochen

Wie zu erwarten, steigt die mittlere Güte für die Approximation bekannter Daten mit zunehmender Anzahl an Trainingsepochen an. Trotz der Begrenzung der Leistungsfähigkeit des KNN durch die Verwendung von nur drei verdeckten Neuronen ist das KNN bei genügend hoher Anzahl an Trainingsepochen (hier etwa ab 100) in der Lage, die zur Modellbildung verwendeten 80 Trainingsdatensätze nahezu immer vollständig zu approximieren. Die im Mittel der 15 modellierten Personen erreichte mittlere Güte für die Prognose nicht zum Training verwendeter Daten steigt mit zunehmender Anzahl an Trainingsepochen zuerst ebenfalls an, fällt dann jedoch wieder ab, was darauf hindeutet, dass hier ein Generalisierungsver-

lust eintritt. Die jeweils in Mittel erreichten maximalen Prognosegüten bleiben hierbei auf einem konstant hohen Niveau. Diese Werte entsprechen den in Bild 7.29 gezeigten Maximalwerten bei ES-Abbruch. Das bedeutet, dass durch ein weiteres Training hier keine weitere Verbesserung der Prognosegüte erreicht werden kann, da das Optimum bereits nach der Anzahl Trainingsepochen, bei der der Trainingsabbruch mit ES-Verfahren erfolgte, erreicht wurde.

Zuletzt wird noch einmal explizit am Beispiel von Bewerber 8 die Problematik des „Auswendiglernens“ und die damit zusammenhängende Auswirkung auf die Fähigkeit, unbekannte Verifikationsdaten zu prognostizieren, aufgezeigt. Bild 7.36 und Bild 7.37 zeigen beispielhaft für die T80-VP20 Datensatzaufteilung im linken Diagramm für die Trainingsdaten den Vergleich von Netzberechnung auf der Abszisse und tatsächlichen Subjektivurteilen auf der Ordinate. Im rechten Diagramm ist der Vergleich für die nicht zum Training verwendeten Verifikationsdaten dargestellt, mit denen auch die Validierung im Rahmen des ES-Verfahrens stattfand. Die jeweiligen Anfahrvarianten sind durch die in der Legende angegebenen Symbole unterscheidbar. Als Lernalgorithmus diente der LM-Algorithmus, die verdeckte Schicht bestand aus drei verdeckten Neuronen mit logarithmisch-sigmoider Aktivierungsfunktion.




Bild 7.36: Berechnung der Trainings- (links) und Verifikationsdaten (rechts) über jeweiligem tatsächlichen Komforturteil nach 47 Epochen (ES-Abbruch) für Bewerber 8

Der Trainingsabbruch fand in dem in Bild 7.36 gezeigten Fall nach 47 Epochen statt. Wie bereits in Kapitel 7.6.2.2 beschrieben, beträgt die maximale Prognosegüte für dieses Beispiel  $\hat{G}_P = 0.77$  bei einer zugehörigen Approximationsgüte von  $G_A = 0.87$ .

Bild 7.37 zeigt das Ergebnis nach 60 Epochen, also weiteren 13 Epochen nachdem das Training im zuvor gezeigten Bild 7.36 durch das ES-Verfahren abgebrochen wurde.




Bild 7.37: Berechnung der Trainings- (links) und Verifikationsdaten (rechts) über jeweiligem tatsächlichem Komforturteil nach 60 Epochen für Bewerter 8

Die Trainingsdaten werden nun deutlich besser approximiert als im vorher gezeigten Fall des Trainingsabbruchs nach 47 Epochen. Die Approximationsgüte beträgt nun  $G_A = 0.99$ . Die Überprüfung der Fähigkeit, Komfortwerte aus nicht zum Training verwendeten Objektivwerten zu berechnen jedoch zeigt, dass hier nun eine Überanpassung an die Trainingsdaten stattgefunden hat. Die Prognosegüte für die Verifikationsdaten beträgt nur noch  $G_P = 0.65$ .

### 7.6.3.5 Trainingsalgorithmus

Im Folgenden wird der Einfluss des in der Lernphase verwendeten Trainingsverfahrens kurz aufgezeigt. Beispielhaft sind hier die Ergebnisse bei der Verwendung der Algorithmen Resilient Backpropagation und Bayesian Regularization Backpropagation dargestellt.

Der Resilient Backpropagation Algorithmus stellt einen in MATLAB<sup>136</sup> implementierten Algorithmus dar, der dem klassischen Backpropagation Algorithmus gleichkommt. Er besitzt also nicht wie der LM-Algorithmus die Fähigkeit, die Schrittweite bei der Fehlersuche zu variieren, wodurch mehr Trainingsepochen benötigt werden. Die Anzahl der Epochen, um die der Algorithmus beim ES-Verfahren über das erste Ansteigen des Validierungsfehlers weiter läuft, wurde aus diesem Grund

<sup>136</sup> MATLAB®, The MathWorks Inc., Natick, MA, USA

hier auf 250 angehoben. Für den Vergleich der Trainingsalgorithmen wird stets ein Standardnetz mit drei verdeckten logsig-Neuronen benutzt, d. h. alle übrigen KNN-Parameter entsprechen den in Kapitel 7.6.2.1 beschriebenen. Als Datengrundlage werden die Datensätze der 100 Anfahrten in T60-V20-P20 Datenaufteilung verwendet.

Bild 7.38 zeigt für die 15 modellierten Bewerber im linken Diagramm die Güteergebnisse der Modellbildung (Approximation) und im rechten Diagramm die der Modellüberprüfung (Prognose) als Mittelwert  $\pm$  Standardabweichung und Maximalwert.




Bild 7.38: Approximationsgüten (links) und Prognosegüten (rechts) bei Resilient Backpropagation als Trainingsalgorithmus

Der Resilient Backpropagation Algorithmus liefert demnach für die Prognosedaten mit  $G_{P,M} = 0.37$  und  $\hat{G}_{P,M} = 0.54$  im Mittel der 15 Personen sowohl beinahe identische mittlere, als auch maximale Prognosegüten wie der LM-Algorithmus (siehe Kapitel 7.6.2.1), allerdings benötigt der Algorithmus hierzu eine höhere Anzahl an Trainingsepochen.

Der Bayesian Regularization Algorithmus besitzt eine zusätzliche Funktion zur Steigerung der Generalisierungsfähigkeit – die sog. Regularisierung. Der Vergleich der Trainingsalgorithmen Levenberg-Marquardt und Bayesian Regularization soll klären, ob sich der durch die Regularisierung höhere Rechenaufwand rechtfertigt und in wie weit der Verlust an Generalisierungsfähigkeit durch Verwendung dieser Regularisierung verhindert wird. In Bild 7.39 sind die im Mittel der 15 Bewerber jeweils über 99 zufällige Initialisierungen erreichte mittlere Güte  $\pm$  Standardabweichung, sowie die maximal erreichten Gütewerte bei Verwendung des Bayesian Regularization Backpropagation Algorithmus dargestellt. Das linke Diagramm zeigt die Ergebnisse der Approximation, das rechte Diagramm die der Prognose.






Bild 7.39: Approximationsgüten (links) und Prognosegüten (rechts) bei Bayesian Regularization Backpropagation als Trainingsalgorithmus

Aus Bild 7.39 ist anhand der vergleichsweise geringen Standardabweichungen ersichtlich, dass das Ergebnis bei Verwendung des Bayesian Regularization Verfahrens unabhängiger von der Initialisierung ist, als bei Verwendung der bisher gezeigten Algorithmen. Die Mittelwerte sowohl der Approximations- als auch der Prognosegüten sind mit  $G_{A,M} = 0.39$  und  $G_{P,M} = 0.22$  deutlich geringer als bei den beiden anderen untersuchten Algorithmen. Die geringere Standardabweichung führt allerdings dazu, dass mit  $\hat{G}_{A,M} = 0.46$  und  $\hat{G}_{P,M} = 0.27$  im Mittel der 15 Bewerber weniger hohe maximale Gütewerte für Approximation und Prognose erreicht werden, als bei den beiden zuvor beschriebenen Trainingsalgorithmen.

#### 7.6.4 Variation des Messorts des Beschleunigungssignals

Wie in Kapitel 6.2 beschrieben, wurde das Signal der Fahrzeugbeschleunigung an der Sitzschiene und an der Kopfstütze des Fahrersitzes gemessen. Die Ableitung von Objektivdaten aus dem an der Kopfstütze gemessenen Beschleunigungssignal erfolgte auf die gleiche Weise wie dies für die der an der Sitzschiene gemessene Beschleunigung beschrieben wurde. Die folgenden Unterkapitel zeigen die Ergebnisse bei Verwendung dieser aus dem Signal der an der Kopfstütze gemessenen Beschleunigung abgeleiteten Objektivwerte. Es kommen also ebenso KNN mit 28 Eingangsneuronen, drei verdeckten Neuronen mit logarithmisch-sigmoider Aktivierungsfunktion in einer verdeckten Schicht und einem Ausgangsneuron zum Einsatz. Das Training erfolgt unter denselben Randbedingungen wie sie in Kapitel 7.6.2 beschrieben sind, also LM-Algorithmus und ES-Verfahren.

Analog zur in Kapitel 7.6.2.1 beschriebenen Vorgehensweise wurden 60 Datensätze zur Minimumsuche, 20 zur Validierung und weitere 20 zur Verifikation verwendet. Bild 7.40 zeigt im linken Diagramm die Ergebnisse für die Approximation und im rechten Diagramm für die Prognose als Mittelwert +/- Standardabweichung sowie die maximalen Gütewerte für die 15 Bewerter.




Bild 7.40: Modellgüten für Approximation (links) und Prognose (rechts)

Die Approximation der Trainingsdaten ist hier im Mittel der 15 Personen mit einer mittleren Güte von  $G_{A,M} = 0.60$ , die Prognose der Verifikationsdaten mit einer mittleren Güte von  $G_{P,M} = 0.27$  möglich. Für die Mittelwerte der maximal erreichten Güte ergibt sich für die Trainingsdaten  $\hat{G}_{A,M} = 0.89$  und für die Prognosedaten  $\hat{G}_{P,M} = 0.52$ . Verglichen mit den Ergebnissen der Modellierung auf Basis des an der Sitzschiene gemessenen Beschleunigungssignals (siehe Kapitel 7.6.2.1) gelingt die Abbildung hier für die Mittelwerte der jeweiligen Prognosegüten um 0.08 schlechter, bei Betrachtung der Maximalgüten im Mittel um 0.04 schlechter.

Wie auch in Kapitel 7.6.2.2 wird die Validierung anhand der im Rahmen der Überprüfung der Prognosegüte als Verifikationsdaten verwendeten Datensätze untersucht. Bild 7.41 zeigt für die 15 Bewerter im linken Diagramm die Ergebnisse der Überprüfung der Modellgüten für die Trainings- und im rechten Diagramm für die Prognose der Verifikationsdaten als Mittelwerte +/- Standardabweichung und die zugehörigen Maximalwerte.




Bild 7.41 Modellgüten für Approximation (links) und Prognose (rechts)

Die Approximation gelingt im Mittel der 15 Bewerter mit einer jeweils mittleren Güte von  $G_{P,M} = 0.62$ , die Prognose mit einer mittleren Güte von  $G_{P,M} = 0.40$ . Bei Betrachtung der Mittelwerte der für die 15 Bewerter jeweils erreichten Maximalwerte ergibt sich für die Approximation  $\hat{G}_{A,M} = 0.91$  und für die Prognose  $\hat{G}_{P,M} = 0.63$ . Damit ist die Prognose bei Betrachtung der Mittelwerte der Prognosegüte um 0.05 und bei Betrachtung der mittleren Maximalgüten um 0.03 geringer als bei der Prognose anhand der aus dem Signal der Sitzbeschleunigung abgeleiteten Objektivwerte.

Hier zeigt sich demnach ebenso wie bei der in Kapitel 7.6.2.2 vorgestellten Untersuchung, dass die Prognose von Daten, anhand derer das Netztraining abgebrochen wurde, besser möglich ist, als wenn diese nicht zur Validierung benutzt wurden. Die Ergebnisse der Modellierung anhand von Objektivwerten aus dem Signal der an der Kopfstütze gemessenen Beschleunigung sind jedoch schlechter möglich als aus denen der an der Sitzschiene erfassten Beschleunigung. Verglichen mit den Ergebnissen der Modellierung aus dem Signal der an der Sitzschiene gemessenen Beschleunigung werden bei ansonsten gleichen KNN-Einstellungen für die Approximationsgüte und für die Prognosegüte geringere Werte erreicht. Für die Berechnung von Subjektivurteilen aus objektiven Kenngrößen ergibt sich demnach die Schlussfolgerung, dass das an der Sitzschiene gemessene Beschleunigungssignal dem an der Kopfstütze gemessenen Signal zur Ableitung charakteristischer Objektivwerte vorzuziehen ist. Als Begründung hierfür kann die Eigenbewegung bzw. Ausgleichsbewegung des Fahrers dienen, die ins Signal der an der Kopfstütze gemessenen Beschleunigung mit eingeht und die eigentliche Fahrzeugreaktion verfälscht wiedergibt.

Die bisher gezeigte Vorgehensweise beschreibt die Modellierung der Komfortbeurteilung von Einzelpersonen. Die Gesamtbeurteilung einer Kundenzielgruppe kann durch Mittelwertbildung der Einzelergebnisse berechnet werden. Zudem ist die Angabe eines prozentualen Anteils der Bewerter möglich, deren Komforturteil größer als 0.5 ausfällt, was nach der verwendeten Bewertungsskala (vgl. Bild 6.6) zufriedene Kunden darstellt.

### 7.6.5 Approximations- und Prognosegüte für Kundenzielgruppen

In diesem Kapitel werden nun die Datensätze der fünf Personen einer Kundenzielgruppe, bestehend aus jeweils 100 bewerteten Anfahrten einer Person, zu einem Datensatz zusammengefasst. Je Kundenzielgruppe besteht dieser Datensatz demnach aus 500 bewerteten Anfahrten. Somit ergeben sich bei Validierung mit einem Teil der Trainingsdaten ein Trainingsdatensatz aus 300, ein Validierungsdatensatz aus 100, sowie ein Verifikationsdatensatz aus 100 Subjektiv/Objektiv-Datensätzen. Darüber hinaus erfolgt die Betrachtung aller Personen als Gesamtkundenzielgruppe. Für diese Gruppe stehen also die Daten von insgesamt 1500 bewerteten Anfahrten mit 1000 Trainings-, 500 Validierungs- und 500 Verifikationsdatensätzen für die Modellbildung zur Verfügung.

Bei Verwendung der gleichen KNN-Parameter wie in Kapitel 7.6.2.1 zeigt Bild 7.42 die Ergebnisse für die beschriebenen Kundenzielgruppen als Mittelwerte +/- Standardabweichung sowie Maximalwerte im linken Diagramm für die Approximations- und im rechten für die Prognosegüten.




Bild 7.42: Approximationsgüte (links) und Prognosegüte (rechts) für Kundenzielgruppen bei Validierung mit einem Teil der Trainingsdaten

Zur Erinnerung ergab sich bei der Modellierung von Einzelpersonen (siehe Bild 7.22) im Mittel der 15 Personen für die jeweils mittlere Approximationsgüte  $G_{A,M} = 0.68$  und für die maximale Approximationsgüte  $\hat{G}_{A,M} = 0.80$ . Dagegen ergibt sich im Mittel für die aus jeweils fünf Personen bestehenden Kundenzielgruppen, wie in Bild 7.42 links dargestellt, für die mittleren Approximationsgüten  $G_{A,M} = 0.58$  und für die im Mittel erreichten Maximalwerte  $\hat{G}_{A,M} = 0.69$ . Bei Betrachtung aller 15 Einzelpersonen als eine Gesamtkundenzielgruppe sind die mittleren und die maximalen Approximationsgüten mit  $G_A = 0.49$  und  $\hat{G}_A = 0.53$  sogar noch geringer.

Die Mittelwerte der mittleren und maximalen Prognosegüten ergaben bei der individuellen Modellierung der 15 Personen  $G_{P,M} = 0.35$  und  $\hat{G}_{P,M} = 0.56$  (siehe Bild 7.22). Als Mittelwert der mittleren Prognosegüten ergibt sich für die drei in Bild 7.42 links gezeigten Kundenzielgruppen eine mittlere Prognosegüte von  $G_{P,M} = 0.38$ , die maximal erreichten Güten sind im Mittel  $\hat{G}_{P,M} = 0.45$ . Die Modellierung einer Gesamtkundenzielgruppe liefert mit  $G_P = 0.37$  und  $\hat{G}_P = 0.40$  sowohl für die mittleren als auch für die maximalen Prognosegüten geringere Werte. Die Mittelwerte der maximal erreichten Prognosegüten nehmen also durch das Zusammenführen der Datensätze ab. Außerdem geht die Möglichkeit der differenzierteren Betrachtung der Einzelbewertungen im Sinne eines Prozentsatzes zufriedener Kunden, wie dies bei der Modellierung von Einzelpersonen möglich ist, verloren.

## 7.7 Ergebnisdiskussion

Die Ergebnisse der Modellierung mittels unterschiedlicher Verfahren zeigen, dass die erreichbaren Modellgüten für die Approximation der zur Modellierung verwendeten Daten alleine noch nichts über die Brauchbarkeit eines Modells zur Berechnung von Komforturteilen aus Objektivwerten, die nicht zur Modellbildung verwendet wurden, aussagt. So ist etwa mittels KNN eine Approximation zu 100% problemlos möglich, wenn eine genügend hohe Anzahl an Neuronen und an Trainingsritten zur Verfügung steht. Die Betrachtung der maximal erreichbaren Prognosegüten, also der Fähigkeit, Komfortwerte aus nicht zur Modellbildung verwendeten Objektivwerten zu berechnen, gelingt mit der vorgestellten Methode der KNN im Mittel der 15 modellierten Personen besser als mit der Standardmethode der Regression. Hierzu sind allerdings gewisse Maßnahmen notwendig, die im Kapitel 7.6.3 ausführlich aufgezeigt werden. KNN sind demnach ein sehr leistungsfähiges Werkzeug für die Modellbildung, wobei die „Kunst“ in der sinnvollen Einstellung der KNN-Parameter liegt. Die hier untersuchten Anfahrten weisen eine geringe Anzahl unabhängiger Datensätze im Verhältnis zur Anzahl der Objektivwerte auf. Deswegen müssen Gegenmaßnahmen ergriffen werden, um einem Verlust an

Generalisierungsfähigkeit entgegenzuwirken. Es kann gezeigt werden, dass die Fähigkeit der KNN zu einer Überanpassung an die Trainingsdaten durch eine Limitierung der Anzahl verdeckter Neuronen, sowie effektiv durch das Early-Stopping-Verfahren beschränkt werden kann.

Häufiger Kritikpunkt an den KNN-Modellen ist, dass hier eine Nachvollziehung der Modelle über die Gewichtungsfaktoren der Objektivwerte – wie dies bei der multiplen linearen Regression möglich ist – nicht unternommen werden kann<sup>137</sup>. Es ist nicht direkt ersichtlich, aufgrund der Ausprägung welcher Objektivwerte ein Urteil gut oder schlecht ausfällt. Ob das multiple lineare Regressionsmodell diese Aussage allerdings tatsächlich wirklich zulässt, ist fraglich. Die Annahme des linearen Zusammenhangs der Objektivwerte mit dem Komforturteil ist bei der vorgestellten Modellierung der Komfortbeurteilung durch einen Menschen sicherlich nicht gegeben. Deswegen beschreiben die Modelle auch nicht den tatsächlichen physikalischen Zusammenhang, sondern den, der unter der Annahme eines linearen Zusammenhangs den kleinsten Fehler liefert. Dies tun die KNN prinzipiell ebenso, wobei sie jedoch durch den modellfreien Ansatz komplexere Zusammenhänge als den linearen erlauben.

Letztlich kann jedes Modell nur so exakt sein wie die Daten, auf denen es basiert. So kann beispielsweise Bewerter 8 in dieser Arbeit jeweils sehr gut modelliert werden, während Bewerter 9 weder durch Regression noch durch KNN in zufriedenstellender Weise abgebildet wird. Dies ist darauf zurückzuführen, dass dieser entweder innerhalb der Versuche zur Datengewinnung für die Modellierung nicht reproduzierbar bewertet hat, oder dass er Dinge bewertet, welche nicht im Beschleunigungssignal enthalten sind. Eine weitere Möglichkeit besteht darin, dass der Zusammenhang von Objektivwerten und Subjektivurteil so komplex ist, dass die Regressionsanalyse, der ein lineares Modell zugrunde liegt, nicht zutrifft und ein KNN aufgrund der begrenzten Anzahl unabhängiger Trainingsdaten und die Begrenzung auf drei verdeckte Neuronen ebenso nicht in der Lage ist, diesen Zusammenhang abzubilden.

Die Individuelle Modellierung von Einzelpersonen erlaubt nicht nur eine differenziertere Betrachtung der Komfortbeurteilungen, sie liefert auch im Mittel bessere maximale Prognoseergebnisse als die Modellierung von Kundenzielgruppen. Dabei gelingt die Modellierung von Komforturteilen aus Objektivwerten, welche aus der an der Sitzschiene gemessenen Beschleunigung abgeleitet sind besser, als wenn hierzu die an der Kopfstütze gemessene Beschleunigung verwendet wird. Diese Vorgehensweise wird somit für die hier betrachtete Modellierung empfohlen.

---

<sup>137</sup> Siehe z. B. Böhl / Küçükay 2005

## 8 Modellanwendung

Die im Kapitel 7 beschriebenen Modelle werden nun zur Komfortwertberechnung aus Objektivwerten, die Anfahrvorgänge charakterisieren, angewendet. Als Regressionsmodelle werden die in Kapitel 7.5.2 beschriebenen Modelle verwendet, welche mittels schrittweiser Rückwärtselimination erstellt wurden. Als KNN-Modelle dienen zum einen die in Kapitel 7.6.2.1 erstellten individuellen Modelle, bei denen die Validierung mit einem Teil der Trainingsdaten stattfand (T60-V20-P20), zum anderen die in Kapitel 7.6.2.2 beschriebenen, bei deren Erstellung die Validierung anhand der Verifikationsdaten erfolgte (T80-VP20). Hierbei werden jeweils die KNN benutzt, welche bei 99 zufälligen Initialisierungen die höchsten Prognosegüten liefern. Zunächst wird die Komfortwertberechnung aus Objektivwerten realer Anfahrten gezeigt. Außerdem erfolgt die Anwendung der Objektivierungsmodelle auf die charakteristischen Werte simulierter Anfahrten. Dabei findet die Simulation mittels des in Kapitel 4.2 vorgestellten MKS-Modells unter Verwendung der unterschiedlichen Aktorwege – entsprechend der in Kapitel 4.1 beschriebenen fünf Anfahrvarianten – statt. Neben dieser softwareseitigen Variation der Anfahrcharakteristik durch die Anfahrvarianten findet zudem eine Parametervariation statt, bei der unter Verwendung der Anfahrvariante A im MKS-Modell typische Antriebsstrangparameter geändert werden, die den Anfahrkomfort beeinflussen.

### 8.1 Beurteilung realer Anfahrvorgänge

Es werden Objektivwerte von 20 realen Anfahrten beurteilt, wobei für jede der fünf Anfahrvarianten jeweils der Komfortwert aus Objektivwerten für eine Anfahrt bei 30%, 50%, 70% und 100% des Vollgaswerts berechnet wird. Diese Objektivwerte wurden in einem zusätzlichen Fahrversuch ermittelt und sind nicht Bestandteil der in Kapitel 6.2.2 beschriebenen Versuche zur Modellierung der Komfortbeurteilung.

Bild 8.1 zeigt im linken Diagramm die mittels der 15 Regressionsmodelle berechneten Komfortwerte je Anfahrvariante als Mittelwert der Anfahrten bei den vier beschriebenen Betriebsbereichen. Neben den mittleren Komfortwerten für die fünf Einzelbewertungen je Kundenzielgruppe und Anfahrvariante ist der Mittelwert aller

berechneten 60 Komfortwerte für jede Anfahrvariante fett dargestellt. Im rechten Diagramm ist der entsprechende prozentuale Anteil von Bewertungen im akzeptablen Bereich, d. h. mit einem Komfortwert größer als 0.5 bewerteter Anfahrten je Anfahrvariante, in gleicher Weise dargestellt.




Bild 8.1: Komfortberechnung realer Anfahrten mittels Regressionsmodellen

Bild 8.2 zeigt in gleicher Darstellungsart die Ergebnisse der Berechnung der 20 realen Anfahrten bei Verwendung der 15 individuellen KNN-Modelle, die besten maximalen Prognosegüten ergeben, wenn die Validierung mit einem Teil der Trainingsdaten erfolgt (T60-V20-P20).




Bild 8.2: Komfortberechnung realer Anfahrten mittels KNN-Modellen bei Validierung mit einem Teil der Trainingsdaten (T60-V20-P20)



In Bild 8.3 sind in gleicher Weise die Ergebnisse der Berechnung dieser realen Anfahrten mittels der 15 individuellen KNN-Modelle dargestellt, welche bei der Validierung anhand der Verifikationsdaten die besten Prognosegüten für diese liefern (T80-VP20).




Bild 8.3: Komfortberechnung realer Anfahrten mittels KNN-Modellen bei Validierung mit den Prognosedaten (T80-VP20)

Wie die in Bild 8.1 bis Bild 8.3 jeweils links dargestellten Diagramme zeigen, sind die berechneten mittleren Komfortwerte der Anfahrvarianten für alle Objektivierungsmodelle sehr ähnlich. Vergleicht man die Ergebnisse zudem mit den in Bild 6.7 gezeigten Subjektivbewertungen der Anfahrvarianten, so kann festgestellt werden, dass sowohl die Regressions-, als auch die KNN-Modelle realistische Ergebnisse liefern. Auffällig ist jedoch, dass die hier untersuchten Anfahrten im Mittel durch die Objektivierungsmodelle durchweg als unkomfortabler beurteilt werden, als dies die Ergebnisse der Beurteilung der Anfahrvarianten durch die 15 Bewerter in Kapitel 6.3 erwarten lassen. Die Relativbewertung der einzelnen Anfahrvarianten zueinander wird aber von allen Objektivierungsmodellen in etwa gleicher Weise vorgenommen und entspricht der im Versuch ermittelten.

Die jeweils rechts gezeigten Diagramme, welche den prozentualen Anteil der mit einem Komfortwert größer als 0.5 berechneten Anfahrten darstellen, unterscheiden sich hingegen deutlicher. Auch hier ist zu sehen, dass die Objektivierungsmodelle niedrigere Akzeptanzwerte liefern, als die im Versuch ermittelten. Die berechneten Akzeptanzwerte für die beiden Variante A und E stimmen gut mit den in Bild 6.7 dargestellten überein, bei den Varianten B, C und D hingegen unterscheiden sich die Ergebnisse der Modelle nicht nur von den im Versuch ermittelten Akzeptanzwerten, sondern differieren teilweise auch beim Vergleich der Modelle.

## 8.2 Beurteilung virtueller (simulierter) Anfahrvorgänge

### 8.2.1 Simulation und Beurteilung von Anfahrvarianten

Gemäß der in Kapitel 4.2 beschriebenen Vorgehensweise wurden mittels des MKS-Antriebsstrangmodells virtuelle Anfahrten generiert. Diese basieren auf den gemessenen Motormomenten- und Aktorwegverläufen von Anfahrvariante A, B, C, D und E, bei jeweils 30%, 50%, 70% und 100% maximaler Gaspedaleingabe. Die folgenden Bilder zeigen beispielhaft die im Frequenzbereich abgeleiteten Objektivwerte der in Bild 4.9 bis Bild 4.11 als Zeitverläufe dargestellten simulierten Anfahrten. Der zu Grunde liegende Motormomenten- und Aktorwegverlauf entspricht einer Fahrereingabe mit einem maximalen Gaspedalwert von 50%.




Bild 8.4: Simulation Anfahrvariante A entsprechend max. Pedalwert 50%




Bild 8.5: Simulation Anfahrvariante B entsprechend max. Pedalwert 50%




Bild 8.6: Simulation Anfahrvariante C entsprechend max. Pedalwert 50%




Bild 8.7: Simulation Anfahrvariante D entsprechend max. Pedalwert 50%




Bild 8.8: Simulation Anfahrvariante E entsprechend max. Pedalwert 50%

Wie bereits die in Kapitel 4.2 dargestellten Zeitverläufe zeigen, ist die Schwingungsanregung durch die unterschiedlichen Aktorwege im Frequenzbereich bis 5 Hz in der Simulation deutlich erkennbar. Der Vergleich der simulierten Objektivwerte mit denen der realen Anfahrten zeigt, dass bei den simulierten Anfahrten die Schwingungsanteile im Frequenzbereich über 40 Hz völlig fehlen. Verantwortlich hierfür ist die in der Simulation fehlende Anregung durch den Verbrennungsmotor, welche im Motormomentensignal des CAN-Bus nicht enthalten ist, sowie die fehlende Straßenanregung. Daraus resultierend ergeben sich die Objektivwerte Nummer 14 bis 19 zu null.

Die Simulation der Anfahrt mit Anfahrvariante B bei einem maximalen Gaspedalwert von 30% gelingt nicht zufriedenstellend, ohne dadurch die Genauigkeit der Simulation der restlichen 19 Anfahrten deutlich zu verschlechtern. Konkret ergibt sich eine Längsbeschleunigung nahe null. Das simulierte Fahrzeug ist in diesem Betriebsbereich nicht funktionsfähig und damit auch nicht bewertbar. Der Komfortwert für diese Anfahrt wird folglich auf null gesetzt.

Bild 8.9 zeigt links die mittels der Regressionsmodelle berechneten Komfortwerte als Mittelwerte der 15 Bewertungsmodelle und jeweils vier Anfahrten pro Anfahrvariante. Im rechten Diagramm ist der prozentuale Anteil der Anfahrten dargestellt, welcher mit einem Komfortwert größer als 0.5 berechnet wird. In den beiden Diagrammen ist zusätzlich zu den Mittelwerten für die fünf Einzelbewertungen je Kundenzielgruppe der Mittelwert aller insgesamt 60 berechneten Komfortwerte je Anfahrvariante fett dargestellt.




Bild 8.9: Komfortberechnung simulierter Anfahrten mittels Regressionsmodellen

Bild 8.10 zeigt in gleicher Darstellungsweise das Ergebnis der Berechnungen mittels der KNN-Modelle, welche mit Validierung anhand eines Teils der Trainingsdaten (T60-V20-P20), erstellt wurden.




Bild 8.10: Komfortberechnung simulierter Anfahrten mittels KNN-Modellen bei Validierung mit einem Teil der Trainingsdaten (T60-V20-P20)

Für die im folgenden Bild 8.11 in gleicher Art dargestellten Ergebnisse wurden die KNN verwendet, bei denen die Validierung anhand der Verifikations-, bzw. Prognosedaten erfolgte (T80-VP20).




Bild 8.11: Komfortberechnung simulierter Anfahrten mittels KNN-Modellen bei Validierung mit den Prognosedaten (T80-VP20)

Die in Bild 8.9 bis Bild 8.11 dargestellten Komfortwerte der Objektivierungsmodelle fallen noch niedriger aus, als die aus den Objektivwerten der realen Anfahrten ermittelten. Während Anfahrvariante A von den KNN-Modellen im Mittel im Gegensatz zu den übrigen Varianten mit einem Komfortwert größer als 0.5 und somit noch als akzeptabel bewertet wird, werden die Komfortwerte auf Basis der Regressionsmodelle für alle Anfahrvarianten im Mittel der 15 Bewerter kleiner als 0.5 berechnet.

Auch unterscheiden sie sich die Ergebnisse der einzelnen Bewertungsmodelle untereinander deutlicher, als bei der Komfortwertberechnungen aus Objektivwerten realer Anfahrten.

Wie Bild 8.9 zeigt, streuen die mittels der Regressionsmodelle für einzelne Kundenzielgruppen berechneten Komfortwerte sehr gegenläufig und erscheinen teilweise als nicht plausibel. Bei den Berechnungen für Kundenzielgruppe 1 und Anfahrvariante C, D und E, die deutlich als zu komfortabel bewertet werden, gehen die PSD-Werte bei hohen Frequenzen positiv in die Regressionsmodelle zur Berechnung des Komfortwerts ein. So wird beispielsweise der PSD\_90\_100 Wert bei einem Bewerter der Gruppe 1 mit dem Faktor -35.8 (also negativ) und bei zwei Bewertern der Gruppe drei mit 18.9 bzw. 16.7 (also positiv) ins Regressionsmodell aufgenommen, während dieser Objektivwert bei keinem Bewerter der Gruppe 2 berücksichtigt wird. Fehlt nun, wie in den Daten der hier gezeigten simulierten Anfahrten dieser Frequenzanteil, d. h. der entsprechende Objektivwert ist null, so hat dies bei Gruppe 1 einen „komfortsteigernden“ und bei Gruppe 3 einen „komfortmindernden“ Einfluss. Für andere Objektivwerte kann dies in ähnlicher Weise gezeigt werden.

Die KNN-Modelle, bei denen die Validierung nicht anhand der Verifikationsdaten erfolgte, liefern hier sehr viel einheitlichere Ergebnisse für die drei Kundenzielgruppen. Die mittels der KNN-Modelle berechneten Komfortwerte, bei deren Erstellung die Validierung anhand der Verifikationsdaten erfolgte, zeigen hingegen – wie die der Regressionsmodelle auch – eine deutliche Streuung der Bewertungen für die drei Kundenzielgruppen, wobei diese jedoch nicht gegenläufig ausfällt.

Die relative Komfortbewertung der Anfahrvarianten zueinander erfolgt auch hier, sowohl durch die Regressionsmodelle als auch durch die KNN-Modelle, zumindest für die Anfahrvarianten A, C, D und E richtig. Je stärker die Ungleichmäßigkeit der Längsbeschleunigung durch die ungleichmäßige Zustellbewegung des Kupplungsaktors bei der jeweilige Anfahrvariante vorgegeben wird, desto niedriger fallen die berechneten Komfortwerte aus. Anfahrvariante B wird von den KNN-Modellen relativ zu den übrigen als „zu komfortabel“ bewertet wird – diese Bewertung entspricht jedoch in etwa der Bewertung dieser Anfahrvariante im Versuch.

### 8.2.2 Simulation und Beurteilung von Parametervariationen

Es wird eine Plausibilitätsüberprüfung des MKS-Simulationsmodells anhand der Variation charakteristischer Einflussfaktoren durchgeführt. Die im Folgenden bewerteten simulierten Anfahrten entstanden also aufgrund von Änderungen der mechanischen Eigenschaften am virtuellen Antriebsstrang, wobei typische komfortrelevante Phänomene wie Rupfen und Ruckeln erzeugt wurden. Um die Rupfneigung des virtuellen Antriebsstrangs zu erhöhen, wurde neben der Verschlechterung des Reibwertgradienten das Massenträgheitsmoment der Kupplungssekundärmasse vergrößert. Diese Antriebsstrangmodifikation wird mit M1 bezeichnet. Die ruckelnden Anfahrten wurden durch Herabsetzen von Steifigkeiten und Dämpfungsfaktoren im Antriebsstrang generiert. Dabei hat die Steifigkeit vorrangig Einfluss auf die Ruckelfrequenz, die Dämpfung auf die Ruckelamplitude. Es wurden drei verschieden starke Ausprägungen generiert, die alle im Frequenzbereich zwischen 3 und 5 Hz auftreten und unterschiedlich starke Ruckelamplituden aufweisen. Diese werden im Folgenden als „schwach“ (M2), „mittel“ (M3) und „stark“ (M4) ruckelnde Antriebsstrangmodifikationen bezeichnet. Für jede Antriebsstrangkonfiguration werden vier Anfahrten – wiederum je eine Anfahrt bei 30%, 50%, 70% und 100% maximalem Gaspedalwert – unter Verwendung der sich hierbei für Anfahrvariante A ergebenden Aktorweg- und Motormomentenverläufe simuliert.

Bild 8.12 zeigt für die betrachteten Antriebsstrangkonfigurationen die Ergebnisse der Komfortwertberechnung mittels der Regressionsmodelle als Mittelwert je Kundenzielgruppe, sowie fett als Gesamtmittelwert aller 60 berechneten Komfortwerte.




Bild 8.12: Komfortbeurteilung von simulierten Hardwarevariationen mittels Regressionsmodell

Bild 8.13 zeigt in gleicher Weise das Ergebnis der Berechnungen mittels der KNN-Modelle, bei deren Erstellung die Validierung anhand eines Teils der Trainingsdaten (T60-V20-P20) erfolgte.




Bild 8.13: Komfortbeurteilung von simulierten Hardwarevariationen mittels KNN-Modell bei Validierung mit einem Teil der Trainingsdaten (T60-V20-P20)

Für die in Bild 8.14 in gleicher Darstellungsart gezeigten Ergebnisse werden die KNN verwendet, bei denen beim Training eine Validierung anhand der Verifikations-, bzw. Prognosedaten erfolgte (T80-VP20).




Bild 8.14: Komfortbeurteilung von simulierten Hardwarevariationen mittels KNN-Modell bei Validierung mit den Prognosedaten (T80-VP20)



Die Ergebnisse sind für beide Modellierungsmethoden, also Regression und KNN, quantitativ nicht sehr zufriedenstellend. Die berechneten mittleren Komfortwerte für die Antriebsstrangmodifikationen M1, M2 und M3 zeigen relativ zu den bei unverändertem virtuellem Antriebsstrang ermittelten Komfortwerten plausible Ergebnisse, d. h. eine stärker ruckelnde Anfahrt wird als unkomfortabler bewertet als eine weniger ruckelnde. Allerdings sind die Unterschiede der einzelnen mittleren Komfortwerte sehr gering. Für eine erste Abschätzung von Komforturteilen für unterschiedliche Antriebsstrangparameter in frühen Phasen des PEP ist es jedoch zunächst ausreichend, eine Information darüber zu erhalten, ob sich eine Änderung „komfortsteigernd“ oder „komfortmindernd“ auswirkt.

Die Antriebsstrangkonfiguration M4, welche stark ruckelnde Anfahrten erzeugt, wird durch die Bewertungsmodelle als zu komfortabel im Gegensatz zur weniger stark ruckelnden Antriebsstrangkonfiguration M3 beurteilt, d. h. eine Erhöhung der Ruckelneigung des virtuellen Antriebsstrangs wird nicht mehr korrekt bewertet. An dieser Stelle werden die Grenzen der Methode sichtbar. Bild 8.15 zeigt die Objektivwerte, welche die Beschleunigung im Frequenzbereich charakterisieren. Für jeden der 19 charakteristischen Werte ist der Bereich um den Mittelwert  $\pm$  Standardabweichung angegeben, den der jeweilige Wert bei der stark ruckelnden Anfahrvariante E und 100 % Gaspedalwert, angenommen hat. Daneben ist für die drei simulierten ruckelnden Anfahrten (M2, M3, M4) bei Anfahrvariante A der jeweils erreichte Objektivwert in Form eines Balkens gezeigt.




Bild 8.15: Variationsbereich der Objektivwerte bei Anfahrvariante E und Objektivwerte bei unterschiedlichen Antriebsstrangkonfigurationen

Wie Bild 8.15 verdeutlicht, ist das KNN vor allem bei Modifikation M4, also der stark ruckelnden Antriebsstrangmodifikation, mit einer Kombination von Eingangswerten konfrontiert, die so nicht beim Netztraining vorkommen. Anfahrvari-

ante E – die Anfahrvariante, welche bei den Volllastanfahrten die höchsten Ruckelamplituden aufweist – deckt diesen Bereich der Objektivwerte nach oben hin nicht ab, d. h. das Bewertungsmodell ist streng genommen nicht gültig, da die zu bewertenden Objektivwerte in den zur Modellbildung verwendeten Objektivwerten nicht enthalten sind. Konkret sind die im Bereich von 2, 3, 4, 6 und 7 Hz ermittelten Objektivwerte bei Antriebsstrangmodifikation M4 deutlich größer, als die jeweiligen Objektivwerte bei den am stärksten ruckelnden realen Volllastanfahrten der 15 Bewerter, welche zur Modellbildung verwendet wurden.

Bei den zur Datengewinnung für die Modellierung durchgeführten Anfahrversuchen wurde zudem durch die unterschiedlichen Anfahrvarianten lediglich die Ruckelamplitude, aber nicht die Ruckelfrequenz variiert. Liegt die Ruckelfrequenz eines simulierten Fahrzeugs nicht im selben Bereich wie die des realen Fahrzeugs, mit dem die Daten für die Modellbildung generiert wurden, ist die objektive Bewertung der simulierten Anfahrereigenschaften nur begrenzt möglich. Es ist demnach bei der Verwendung solcher Bewertungsmodelle vorab der Gültigkeitsbereich zu prüfen. Bei Modellbildung mittels Daten, die mit verschiedenen Fahrzeugen unterschiedlicher Ruckelfrequenzen erstellt werden, ist ein entsprechend größerer Gültigkeitsbereich erreichbar.

### 8.3 Ergebnisdiskussion

Beim Vergleich der berechneten und der tatsächlich im Versuch ermittelten Komforturteile aus Objektivwerten realer Anfahrvorgänge kann festgestellt werden, dass sowohl die Regressionsmodelle, als auch die KNN-Modelle im Mittel realistische Ergebnisse liefern.

Die objektive Beurteilung der simulierten Anfahrvarianten – also die Berechnung von Komforturteilen aus objektiven Kenngrößen, die diese virtuellen Anfahrten beschreiben – gelingt mit den KNN-Modellen plausibler als mit den Regressionsmodellen. Grund hierfür ist, dass die Regressionsmodelle durch die klare Trennung in signifikante und nicht signifikante Objektivwerte sehr darauf angewiesen sind, dass die Zuordnung der Information, welche durch die Objektivwerte beschrieben wird, für die simulierten Anfahrten und die zur Modellbildung verwendeten Daten gleich ist. Wird beispielsweise die Ruckelfrequenz im MKS-Modell nicht exakt nachgebildet, so wird die Ruckelamplitude eventuell einem Objektivwert zugeordnet, der für die Modellbildung als nicht signifikant identifiziert wurde und demnach auch nicht in die Regressionsgleichung eingeht.

Die KNN scheinen durch die Anpassung der Verbindungsgewichte und Schwellwerte leichte Abweichungen eher zu tolerieren. Allerdings sind auch hier Grenzen vorhanden. Muster von Objektivwerten, die nicht in ähnlicher Form auch in den Trainingsdaten enthalten sind, können nicht realistisch berechnet werden. Das Problem dabei ist, dass die Anzahl an Trainingsdaten im vorgestellten Fall sehr gering ist und sich die Trainingsdatensätze zwar in der Amplitude der betrachteten komfortrelevanten Phänomene unterscheiden, jedoch keine beliebig hohen Ruckelamplituden aufweisen. Solche Extrema sind jedoch für einen Versuchingenieur ohnehin selbst aus Zeitbereichskurven leicht als unkomfortabel zu identifizieren und können leicht als Fehlberechnungen identifiziert werden.

Unabhängig von der Modellierungsmethode ist es unabdingbar, eine möglichst große Varianz in den zur Modellbildung verwendeten Daten zu erreichen. Darüber hinaus ist zu gewährleisten, dass diese Varianz den Bereich abdeckt, für dessen Interpretation das Bewertungsmodell benutzt werden soll. Eine Überprüfung dieser Voraussetzung kann durch den direkten Vergleich der Objektivwerte der Modellierungsdaten mit denen der Simulationsdaten erfolgen.



## 9 Zusammenfassung und Ausblick

Die vorliegende Arbeit befasst sich mit der Modellierung und Berechnung subjektiver Komfortbeurteilungen aus objektiven Daten, welche automatisierte Anfahrvorgänge beschreiben. Hierbei wird die Modellierung für Laienbewerter, die Kunden repräsentieren, durchgeführt. Mittels der erstellten Modelle ist es möglich, reale Anfahrten anhand objektiver charakteristischer Größen reproduzierbar aus Sicht der Kunden hinsichtlich Komforteindruck und Kundenakzeptanz zu beurteilen. Darüber hinaus ist die Abschätzung der Komfortbeurteilungen virtueller (simulierter) Anfahrten möglich.

Ausgehend von dem in Kapitel 2 beschriebenen Stand der Forschung und Technik werden die Ziele der vorliegenden Arbeit abgeleitet und in Kapitel 3 genannt.

Kapitel 4 beschreibt die reale und die virtuelle Entwicklungsumgebung, in der diese Arbeit durchgeführt wurde. Speziell wird auf das im Rahmen dieser Arbeit aufgebaute Versuchsfahrzeug mit automatisiertem Kupplungssystem eingegangen, dessen Anfahrereigenschaften im kundenrelevanten Bereich variierbar sind. Ein MKS-Modell des Versuchsfahrzeugs ermöglicht es, unterschiedlich komfortable virtuelle Anfahrten zu simulieren.

Mittels des beschriebenen Versuchsfahrzeugs wurden Anfahrten objektiv gemessen und subjektiv beurteilt. Diese Messdaten wurden für 15 Versuchspersonen erhoben, welche nach der in Kapitel 5 beschriebenen Methode anhand objektiver fahrphysikalischer Kennwerte in drei Kundenzielgruppen eingeteilt wurden. Sie bilden die Grundlage für die Modellierung der Anfahrkomfortbeurteilung.

Inhalt von Kapitel 6 sind die durchgeführten Untersuchungen zum Anfahrkomfort. Nach der Klärung des Begriffs Anfahrkomfort wird ein Bewertungsverfahren vorgestellt, welches eine Interpretation der Komfortbeurteilung von Anfahrvorgängen als Komfortwert sowie als prozentuales Maß für die Kundenakzeptanz erlaubt. Die Untersuchungen zur Bewertungstreue von Laien und Experten zeigen deutlich, dass die Fähigkeit, Anfahrkomfort reproduzierbar zu bewerten, innerhalb der Gruppe der Laienbewerter sehr uneinheitlich ausgeprägt ist. Im Durchschnitt zeigt sich bei der Bewertungsabweichung von Laien gegenüber der von Experten der Faktor zwei. Dies deutet darauf hin, dass bei der Modellierung der Anfahrkomfort-

beurteilung aus Sicht der Laienbewerter mit einer recht hohen Ungenauigkeit umzugehen ist.

Ein eindeutiger Zusammenhang von Kundenzielgruppe und Komfortanspruch kann nur begrenzt nachgewiesen werden, jedoch kann prinzipiell festgestellt werden, dass Ungleichmäßigkeiten wie Ruckeln in der Beschleunigung während des Anfahrvorgangs von allen Kunden „komfortmindernd“ eingestuft werden.

Es wird eine Methode zur Ableitung charakteristischer Kennwerte für einen Anfahrvorgang vorgestellt, welche zum einen die Fahrereingabe über das Gaspedal, zum anderen die Fahrzeugreaktion in Form der Fahrzeuglängsbeschleunigung, berücksichtigt. Die Signifikanzanalyse mittels Regression zeigt, dass unter diesen Voraussetzungen typische objektive Kennwerte für einen Anfahrvorgang nur sehr eingeschränkt identifiziert werden können. Bei der Untersuchung einzelner Personen erweisen sich hier sehr unterschiedliche Objektivwerte als signifikant, was auf die Individualität der Komfortbewertung, aber auch auf eine komplexe Kollinearitätsstruktur der Objektivwerte, hindeutet.

Kapitel 7 zeigt die Methode und Ergebnisse der Modellbildung mittels multipler linearer Regression und mittels künstlicher neuronaler Netze. Die allgemeinen Grundlagen dieser Methoden werden in Kapitel 2 beschrieben. Eine Beurteilung der Modelle erfolgt hinsichtlich Approximations- und Prognosegüte, also hinsichtlich der Fähigkeit, die zur Modellbildung verwendeten Daten zu approximieren, als auch der Möglichkeit, aus Objektivwerten, die nicht Teil der Modellierungsdaten sind, Komfortwerte zu prognostizieren. Diese Überprüfung geschieht anhand eines Gütekriteriums, welches auf dem Vergleich von berechneten und tatsächlich im Fahrversuch ermittelten Komfortwerten basiert. Die Modellierung mittels der in dieser Arbeit verwendeten Verfahren zeigt, dass die erreichbare Approximationsgüte für die zur Modellierung verwendete Daten alleine noch nichts über die Brauchbarkeit eines Modells zur Berechnung von Komfortwerten aus Objektivwerten, die nicht im Rahmen der Modellerstellung verwendet wurden, aussagen. So ist etwa mittels KNN eine Approximation stets zu 100% problemlos möglich, wenn eine genügend hohe Anzahl an Neuronen und an Trainingsschritten zur Verfügung steht. Allerdings eignen sich die so erhaltenen KNN nur bedingt zur Interpretation nicht zur Modellbildung verwendeter Objektivdaten. Die Betrachtung der erreichbaren Prognosegüten zeigt, dass mit der Methode der KNN die Berechnung von Komfortwerten aus Objektivdaten, die nicht zur Modellbildung verwendet wurden, im Mittel besser gelingt als mit der Standardmethode der Regression. Allerdings müssen hierzu gewisse Maßnahmen getroffen werden, die in der Arbeit ausführlich aufgezeigt werden. Neben theoretischen Betrachtungen werden Einflussfaktoren auf die Leistungsfähigkeit der KNN bezüglich der erreichbaren Prognosegüte variiert und aus den Ergebnissen Richtlinien zum effektiven Umgang mit KNN für

die Objektivierung von Komfortbeurteilungen erarbeitet, welche sich auf die Behandlung ähnlicher Problemstellungen übertragen lassen. Ein Kritikpunkt an den KNN-Modellen ist, dass hier ein einfaches Nachvollziehen der Modelle über die Gewichtungsfaktoren der Objektivwerte, im Gegensatz zur multiplen linearen Regression, nicht möglich ist. Es ist somit nicht ersichtlich, aufgrund welcher Phänomene ein Komforturteil gut oder schlecht ausfällt. Ob das lineare Regressionsmodell diese Aussage allerdings wirklich sinnvoll zulässt, ist ebenfalls fraglich. Die Annahme des linearen Zusammenhangs ist hier sicherlich nicht richtig, weswegen die Modelle auch nicht den tatsächlichen physikalischen Zusammenhang beschreiben, sondern den, der unter der Annahme eines linearen Zusammenhangs den kleinsten Fehler liefert.

Die Anwendung der erstellten Regressions- und KNN-Modelle zur Beurteilung sowohl realer, als auch virtueller (simulierter) Anfahrten wird im Kapitel 8 beschrieben. Die Berechnung von Komfortwerten aus Objektivdaten, die reale Anfahrten beschreiben, gelingt durch die untersuchten Modelle etwa gleich gut. Die Komfortwertberechnung aus Objektivwerten, welche simulierte Anfahrten beschreiben, gelingt mit den KNN-Modellen besser als mit den Regressionsmodellen, wenn diese den realen Anfahrten recht ähnlich sind. Die Arbeit zeigt, dass KNN bezüglich der Eingangswerte leichte Unstimmigkeiten tolerieren und sich demnach auch oder gerade zur Modellierung von Laien mit einer großen Beurteilungsunschärfe, physikalisch nicht reproduzierbarem Modellzusammenhang und kollinearen Objektivwerten, eignen. Bei der Komfortwertberechnung aus Objektivwerten von Antriebsstrangmodifikationen zeigen sich die Grenzen der Methode. So liefern sowohl die Regressions- als auch die KNN-Modelle unbefriedigende Ergebnisse, wenn der Unterschied dieser Objektivwerte zu den bei der Modellbildung verwendeten zu groß wird. Es erfolgt hierbei eine Extrapolation von Objektivwerten außerhalb des modellierten Bereichs. Um sehr komfortable, wie auch sehr unkomfortable Zustände abbilden zu können, müssen diese entsprechend im realen Fahrversuch generiert werden.

Das Problem der tatsächlichen exakten Modellierung der Komforturteilsbildung eines Bewerbers bleibt weiterhin ungelöst. Allerdings konnte gezeigt werden, dass die hier vorgestellten Objektivierungsmodelle durchaus in der Lage sind, Komforturteile aus objektiven Kennwerten richtig zu prognostizieren. Stammen diese Kennwerte von realen Anfahrten ist dies sehr gut möglich. Die Abschätzung von Komfortbeurteilungen aus Daten der numerischen Simulation ist eine weitere Herausforderung, die gelöst wurde. Wenn die quantitative Komfortbeurteilung hier auch weniger zufriedenstellende Ergebnisse liefert, so ist jedoch zumindest eine relative Beurteilung unterschiedlicher Antriebsstrangkonfigurationen möglich. Gerade auf diesem Gebiet besteht jedoch gewiss noch Forschungsbedarf.

Für die Optimierung und Individualisierung von automatisierten Systemen, wie z. B. automatisierten Kupplungssystemen, wird sich die vorgestellte Methode zur Modellierung der Komfortbeurteilung mittels KNN als leistungsfähiges Werkzeug erweisen. Eine weitere Anwendungsmöglichkeit ist der Einsatz von KNN in der Forschung für die Evaluierung von Prüfstands- oder Simulationsqualität, um herauszufinden, welche Werte ein Prüfstand bzw. ein MKS-Modell liefern muss, um die Vorhersage der menschlichen Wahrnehmung zu ermöglichen.

Obwohl die Methode für objektive Daten, die von Signalen aus den Fahrversuchen abgeleitet wurden, bereits vielversprechende Resultate zeigt, sollten andere Wege des Beschreibens der Fahrereingabe und des Fahrzeugverhaltens untersucht werden. Hierbei könnte besonders die Beschreibung der Anfahrt durch charakteristische Größen, die speziell den zeitlichen Verlauf besser beschreiben, d. h. wann welche Frequenz dominiert, Erfolg versprechen. In diesem Rahmen ist beispielsweise eine Trennung in Vor- und Nachsynchronphase denkbar.

Das Bewertungsmodell, das im momentanen Stadium noch einfach ist, wird schrittweise verbessert, um als weiteres Entwicklungswerkzeug zu der Verbesserung der Hardware-in-the-loop-Methode in der virtuellen Produktentwicklung beizutragen. Somit wird es die ganzheitliche Entwicklungsumgebung des Instituts für Produktentwicklung der Universität Karlsruhe (TH) komplettieren. Einen nächsten Schritt stellt hier die Interpretation von Versuchsergebnissen "tieferer" Ebenen, wie etwa Objektivwerten aus Prüfstandsversuchen im Rahmen des ganzheitlichen Forschungsansatzes dar. Die hier gezeigte Methode der Objektivierung von Komforteigenschaften mittels KNN ist zudem auf weitere Fahrzustände, z. B. Schalten, Bremsen, etc. erweiterbar. Das Thema der Schaltkomfortbeurteilung wird am Institut bereits im Rahmen zweier Arbeiten zum Thema Objektivierung der Schaltkomfortbeurteilung durch Experten bei automatisierten Schaltgetrieben und bei Handschaltern untersucht. Die vorliegende Arbeit stellt hierfür, durch die Ergebnisse der systematischen Betrachtung der Einflussfaktoren auf die Modellierung mittels KNN, eine wertvolle Basis dar.



## 10 Literaturverzeichnis

- Aigner 1982** Aigner, J.: Zur zuverlässigen Beurteilung von Fahrzeugen. ATZ Automobiltechnische Zeitschrift 84 (1982), Nr.9, S. 447-450
- Albers / Albrecht 2002** Albers, A.; Albrecht, M.: Vorhersage subjektiver Komforturteile mittels künstlicher neuronaler Netze. VDI-Tagung: Berechnung und Simulation im Fahrzeugbau, 11. Internationaler Kongress, Würzburg, 01.-02. Oktober 2002. Tagungsband: VDI-Berichte 1701, VDI-Verlag Düsseldorf 2002, S. 401-420
- Albers / Albrecht 2003a** Albers, A.; Albrecht, M.: New Approach Using Artificial Neural Networks for Modelling and Evaluation of Man-Machine-Interaction at the Start-Up Process in Passenger Cars. 14th International Conference on Engineering Design ICED 03, Stockholm, Sweden, August 19th-21st 2003. Tagungsband: Research for Practice, Design Society, 2003
- Albers / Albrecht 2003b** Albers, A.; Albrecht, M.: Komforteindrücke per Maus-klick generieren und messen – Zusammenarbeit von Universität und Industrie auf dem Gebiet der Antriebsstrangforschung Konstruktion, Springer VDI-Verlag, Heft 11/12-2003, S. 28-29
- Albers / Albrecht 2004a** Albers, A.; Albrecht, M.: Einsatz künstlicher neuronaler Netze zur objektiven Beurteilung des Schwingungskomforts am Beispiel des automatisierten Anfahrens. VDI-Tagung Humanschwingungen, Darmstadt, 17.-18. März 2004. Tagungsband: VDI-Berichte Nr. 1821, S. 159-182, VDI-Verlag, Düsseldorf, 2004
- Albers / Albrecht 2004b** Albers, A.; Albrecht, M.: Driver Start-up Comfort Rating of Automated Clutch Systems – an Objectification Using Artificial Neural Networks. FISITA 2004 World Automotive Congress, Barcelona, Spain, 23-27 May 2004. Book of Abstracts p. 325. Paper No. F2004U108

- Albers / Albrecht 2005** Albers, A.; Albrecht, M.: Abbildung der individuellen subjektiven Komfortbeurteilung von Kunden aus objektiven Messwerten am Beispiel des automatisierten Anfahrens. 5. Tagung Dynamisches Gesamtsystemverhalten von Fahrzeugantrieben, Haus der Technik, Augsburg, 01.-02.03.2005. Tagungsbuch: Systemanalyse in der Kfz-Antriebstechnik, Bd.3, Expert Verlag, Renningen, 2005, S.30-47
- Albers / Herbst 1998** Albers, A.; Herbst, D.: Rupfen - Ursachen und Abhilfen. 6. Internationales Kolloquium Torsionsschwingungen im Antriebsstrang, 19. März 1998, Baden-Baden. 1998, S. 23-46
- Albers / Krüger 2002** Albers, A.; Krüger, A.: Reibungserregte Schwingungen in Kraftfahrzeugkupplungen und ihre aktive Dämpfung. VDI-Berichte 1736, Düsseldorf, VDI-Verlag 2002, S. 135-152
- Albers / Krüger 2003a** Albers, A. Krüger, A.: Aktive Dämpfung selbsterregter Reibschwingungen am Beispiel des Kupplungsrupfens. Konstruktion, Zeitschrift für Produktentwicklung und Ingenieur-Werkstoffe, Hrsg.: Birkhofer, Feldhusen, Lindemann, Springer VDI-Verlag, Düsseldorf, 2004, ISSN 0720-5953, S. 71-74 u. S. 81
- Albers / Krüger 2003b** Albers, A.; Krüger, A.: Aktive Dämpfung friktionskontakt-induzierter Schwingungen in Antriebssträngen. VDI-Berichte Nr. 1786, Kupplungen und Kupplungssysteme, S.193-209, ISBN 3-18-091786-5, VDI-Verlag, Düsseldorf, 2003
- Albers 1990** Albers, A.: Elektronisches Kupplungsmanagement (EKM) – Die mitdenkende Kupplung. 4. Internationales Kolloquium Torsionsschwingungen im Antriebsstrang, Baden-Baden, 20. April 1990
- Albers 1994** Albers, A.: Fortschritte beim ZMS – Geräuschkomfort für moderne Fahrzeuge. 5. LuK Kolloquium, 27. Mai 1994. Tagungsband, S. 5-41
- Albers et al. 2001a** Albers, A.; Krüger, A.; Lux, R.; Albrecht, M.: Prüfen von Antriebssträngen am Beispiel des Kupplungsrupfens-Ganzheitliche Antriebsstrangentwicklung. ATZ Automobiltechnische Zeitschrift 103 (2001), Nr.1, S. 44-49
- Albers et al. 2001b** Albers, A.; Albrecht, M.; Krüger, A.; Lux, R.: New Methodology for Power Train Development in the Automotive Engineering-Integration of Simulation, Design and Testing. SAE Automotive & Transportation Technology Congress, Barcelona, Spain, October 1-3, 2001 Tagungsband: ATTCE 2001 Powertrain and Heat Transfer/Exchange, p. 239-245, Society of Automotive Engineers, Warrendale, PA, 2001

- Albers et al. 2002** Albers, A.; Albrecht, M.; Krüger, A.; Lux, R.: Integration of Simulation and Testing in Power Train Engineering Based on the Example of the Dual Mass Flywheel. Testingexpo 2002 Conference, Stuttgart, 16. Mai 2002
- Albers et al. 2003** Albers, A.; Krüger, A.; Behrendt, M.: Kupplungssysteme im Automobilbau – Trends, Anforderungen und Lösungen. VDI-Berichte Nr. 1786, Kupplungen und Kupplungssysteme, S. 3-30, ISBN 3-18-091786-5, VDI-Verlag, Düsseldorf, 2003
- Ammon et al. 2004** Ammon, D.; Frank, P.; Gimmler, H.; Götz, J.; Hilf, K.-D.; Rauh, J.; Scheible, G.; Stiess, P.: Fahrzeugschwingungen – von der Fahrbahnanregung bis zum Komfortempfinden. VDI-Tagung Humanschwingungen, Darmstadt, 17.-18. März 2004. Tagungsband: VDI-Berichte Nr. 1821, S. 139-158, VDI-Verlag, Düsseldorf, 2004
- Auberle 2001** Auberle, A.: Duden-Herkunftswörterbuch : Etymologie der deutschen Sprache. Der Duden in 12 Bänden; Band 7, 3. Auflage, Dudenverlag, Mannheim, 2001
- Bellmann et al. 2001** Bellmann, M. A.; Baumann, I.; Hillebrand, P.; Mellert, V.; Weber, R.: Wirkung von Sitz- und Lenkradvibrationen auf den Komfort im Fahrzeug. In: Korrelation zwischen objektiver Messung und subjektiver Beurteilung von Versuchsfahrzeugen und -komponenten. In: Subjektive Fahrindrücke sichtbar machen, Haus der Technik Fachbuch, Steinmetz, Essen, Expert-Verlag, 2001
- Bellmann et al. 2004** Bellmann, M. A. ; Remmers, H. ; Mellert, V.: Grundlegende Experimente zur Wahrnehmung von vertikalen Ganzkörpervibrationen. VDI-Tagung Humanschwingungen, Darmstadt, 17.-18. März 2004, Tagungsband: VDI-Berichte Nr. 1821, S. 251-270, VDI-Verlag, Düsseldorf, 2004
- Bender / Lange 2001** Bender, R.; Lange, S.: Was ist der p-Wert? Deutsche medizinische Wochenschrift 2001; 126: T 39-T 40, Georg Thieme Verlag, Stuttgart, 2001
- Berger et al. 1998** Berger, R.; Fischer, R.; Salecker, M.: Von der Automatisierten Kupplung zum Automatisierten Schaltgetriebe. VDI-Berichte Nr. 1393. Getriebe in Fahrzeugen '98, VDI-Verlag, Düsseldorf, 1998, S. 159-174
- Böhl / Küçükay 2004** Böhl, J.; Küçükay, F.: Schaltkomfortuntersuchungen bei Automatikgetrieben. VDI-Tagung Getriebe in Fahrzeugen 2004, 22-23.06.2004, Friedrichshafen. Tagungsband: VDI-Berichte Nr. 1827, VDI-Verlag Düsseldorf, S. 203-216

- Bortz 1993** Bortz, J.: Statistik für Sozialwissenschaftler. 5. Auflage, Springer Verlag, Berlin, 1999
- Brause 1995** Brause, R.: Neuronale Netze. 2. überarbeitete Auflage. Stuttgart: B.G. Teubner 1995
- Bröde / Griefahn 1996** Bröde, P.; Griefahn, B.: Interaxiale Äquivalenz der subjektiven Beurteilung translatorischer Ganzkörper-Schwingungen. Z. Arb. Wiss. 50 (22 NF), 1996, 180-185
- Cameiro Silva 2002** Gameiro Silva, M. C.: Measurements of comfort in vehicles, Institute of Physics Publishing, Measurement Science and Technology 13 (June 2002), S. 41-60
- Carpenter 1991** Carpenter, G. A.: Neural Network Models for Pattern Recognition and Associative Memory. In: Carpenter, G. A.; Grossberg, S., (Hrsg.): Pattern Recognition by Self-Organizing Neural Networks, Kapitel 1, S. 1-33. A Bradford Book, MIT, 1991. ISBN 0-262-03176-0
- Challen 2002** Challen, B. J.: Defining driveability – limits to modelling. Total Vehicle Technology Conference, Sussex, UK, 11th /12th November 2002
- Cichocki / Unbehauen 1993** Cichocki, A.; Unbehauen, R.: Neural Networks for Optimization and Signal Processing. Teubner-Wiley, Stuttgart, Chichester, 1993. ISBN 3-519-06444-8.
- Combé et al. 2005** Combé, T.; Kollreider, A.; Riel, A.; Schyr, C.: Modellabbildung des Antriebsstrangs zur Echtzeitsimulation der Fahrzeuglängsdynamik. MTZ Motortechnische Zeitschrift 66 (2005), Nr.1
- Cooper / Harper 1996** Cooper, G. E.; Harper, R. P.: The Use of Pilot Rating in the Evaluation of Aircraft Handling Qualities. NASA TN D-5153, 1969
- Dibbern 1992** Dibbern, K.: Ermittlung eines Kennwertes für den ISO-Fahrspurwechsel in Versuch und Simulation. Karlsruhe, Universität (TH), Fakultät für Maschinenbau, Diss. VDI-Fortschrittsberichte, Reihe 12, Nr. 164. Düsseldorf, VDI-Verlag, 1992
- Dickerhof 2005** Dickerhof, M.: Anwendung von Objektivierungsmodellen zur Komfortbewertung simulierter Anfahrvorgänge. Diplomarbeit, Institut für Produktentwicklung, Universität Karlsruhe (TH), 2005
- Eickhoff 2002** Eickhoff, B: Duden – Das Bedeutungswörterbuch. (Der Duden in 12 Bänden; Band 10), 3. Auflage, Dudenverlag, Mannheim, 2002
- Fanghänsel 2001** Fanghänsel, K.: HF-Signalklassifikation mit Selbst-Organisierenden Karten. Dissertation, Universität der Bundeswehr, Fachbereich Elektrotechnik, Hamburg, 2001

- Fischer / Berger 1998** Fischer, R.; Berger, R.: Automatisierung von Schaltgeräten. 6. Internationales LuK-Kolloquium 1998, S. 95-121
- Fischer et al. 2004** Fischer, R.; Schoeggl, P.; Hasewend, W.; Ellinger, R.: Getriebekalibrierung mit objektiven Komfortzielen und Verfahren zur virtuellen Optimierung. VDI-Tagung: Getriebe in Fahrzeugen 2004, 22.-23.06.2004, Friedrichshafen. Tagungsband: VDI-Berichte Nr. 1827, VDI-Verlag Düsseldorf, S.179-201
- Glaser / Renner 2002** Glaser, H.;M Renner, H. Das Fahrwerk des Audi A8. ATZ Sonderausgabe, Vieweg Verlag, Wiesbaden, 2002
- Griffin 1990** Griffin, M. J.: Handbook of Human Vibration. Academic Press, London, 1990
- Hagan et al. 1996** Hagan, M.; Demuth, H.;Beale, M.: Neural Network Design. Boston, MA, PWS Publishing, 1996
- Hagerodt 2003** Hagerodt, A.: Automatisierte Optimierung des Schaltkomforts von Automatikgetrieben. Braunschweig, Universität (TU), Fakultät für Maschinenbau und Elektrotechnik, Diss., 2003. Schriftenreihe des Instituts für Fahrzeugtechnik / Küçükay, Ferit (Hrsg.), Nr. 4
- Hebb 1949** Hebb, D. O.: The Organization of Behavior: A Neuropsychological Theory. John Wiley & Sons, New York, 1949
- Hennecke 1995** Hennecke, D.: Zur Bewertung des Schwingungskomforts von Pkw bei instationären Anregungen. Dissertation TU Braunschweig, 1995. VDI-Fortschrittsberichte, Reihe 12, Nr. 237. Düsseldorf: VDI-Verlag, 1995
- Hinz et al. 2004** Hinz, B.; Rützel, S.; Keitel, G.; Menzel, H.; Seidel, H.: Bestimmung der scheinbaren Masse bei Nutzung von PKW-Sitzen als Voraussetzung für eine Modellierung des sitzenden Menschen – Ergebnisse von Frauen und Männern. VDI-Tagung Humanschwingungen, Darmstadt, 17.-18. März 2004, Tagungsband: VDI-Berichte Nr. 1821, S. 57-86, VDI-Verlag, Düsseldorf, 2004
- Hopfield 1982** Hopfield, J. J.: Neural Networks and Physical Systems with Emergent Collective Computational Abilities. Proceedings National Academy of Sciences Vol. 79, No. 8, S. 2554-2558, 1982
- Jürgensohn et al. 1996** Jürgensohn, T.; Müller, W.; Scheffer, T.: Verbesserte Methodik zur Objektivierung von subjektiven Bewertungen des Fahrverhaltens. Technische Universität Berlin, Zentrum Mensch-Maschine-Systeme (ZMMS) Bericht, Nr. 96-5, Berlin, 1996

- Käppler 1993** Käppler, W.D.: Beitrag zur Vorhersage von Einschätzungen des Fahrverhaltens. Kassel, Universität, Diss. VDI-Fortschrittsberichte, Reihe 12, Nr.198, Düsseldorf, VDI-Verlag, 1993
- Kohonen 1997** Kohonen, T.: Self-Organizing Maps. Springer, Berlin, 2. Ausgabe, 1997. ISBN 3-540-62017-6.
- Kremmling / Fischer 1994** Kremmling, B.; Fischer, R.: Automatisierte Kuppung – Das neue LuK-EKM. 5. Internationales LuK-Kolloquium 1994, S. 89-111
- Krüger 2003** Krüger, A.: Kupplungsrupfen – Ursachen, Einflüsse und Gegenmaßnahmen. Karlsruhe, Universität (TH), Fakultät für Maschinenbau, Diss., 2003. Forschungsberichte des Instituts für Maschinenkonstruktionslehre und Kraftfahrzeugbau / Albers, Albert (Hrsg.), Bd. 10
- Küçükay / Gebert 1997** Küçükay, F.; Gebert, J.: Schaltkomfort als neue Regelgröße bei Pkw-Automatikgetrieben. 1. Symposium: Steuerungssysteme für den Antriebsstrang von Kraftfahrzeugen, Berlin 1997
- Kudritzki 1995** Kudritzki, D.: Mensch-Maschine-System Fahrzeug – die kundennorientierte Auslegung des Fahrwerks. Willumeit, H.-P.; Kolrep, H. (Hrsg.), Verlässlichkeit von Mensch-Maschine Systemen, 1. Berliner Werkstatt Mensch-Maschine Systeme, 11.-13. Okt. 1995, Berlin, ZMMS-Spektrum, Band 1, Berlin: Technische Universität Berlin, 1995, S. 291-303
- Laux et al. 1993** Laux, P.-C. ; Davies, P.; Long, G.R.: The Correlation of Subjective Response Data with Measured Noise Indices of Low Frequency Modulated Noise. Noise Control Engineering Journal New York, Band 40, Heft 3, 1993, S. 241-353
- List / Schöggli 1998** List, H.; Schöggli, P.: Objective Evaluation of Vehicle Driveability. SAE International Congress, Detroit, MI (SAE 980204), 1998
- List et al. 1998** List, H.; Schöggli, P.; Fraidl, G. K.: Objektive Beurteilung des subjektiven Fahrempfindens, ATZ Automobiltechnische Zeitschrift 100 (1998); Nr. 4; S. 274-281
- Lux 2000** Lux, R.: Ganzheitliche Antriebsstrangentwicklung durch Integration von Simulation und Versuch. Karlsruhe, Universität (TH), Fakultät für Maschinenbau, Diss., 2000. Forschungsberichte des Instituts für Maschinenkonstruktionslehre und Kraftfahrzeugbau / Albers, Albert (Hrsg.), Bd. 1
- Lux et al. 1999** Lux, R.; Burger, W.; Albers, A.: Neuartiger, universell einsetzbarer Antriebsbaugruppen-Prüfstand. VDI-Bericht, 1470 (1999), S. 143-161

- Mather 2002** Mather, G.: Measuring human sensory responses. Total Vehicle Technology Conference, Sussex, UK, 11-12 November 2002
- McCulloch / Pitts 1943** McCulloch, W. S.; Pitts, W.: A Logical Calculus of Ideas Immanent in Nervous Activity. Bull. Mathematical Biophysics 5, S. 115-133, 1943
- Meloni 1991** Meloni, T.M.: Wahrnehmung und Empfindung von komplexen, kombinierten Belastungen durch Vibration und Schall. Zürich, Eidgenössische Technische Hochschule, Diss. (Nr.9568), 1991
- Moriwaki et al. 2001** Moriwaki, I.; Mohamad, E.N.; Kawasaki, Y.: Gear Noise Diagnosis System For Automobile Transmission Using Artificial Intelligence (Convergence of Training Process). SAE Automotive & Transportation Technology Congress, Barcelona, Spain; 1-3 October 2001. SAE 2001-01-3336
- Nelles 2003** Nelles, O.: Lernfähige Fuzzy-basierte Fahrstrategie für automatische Getriebe. Kapitel C.15 in Modellgestützte Steuerung, Regelung und Diagnose von Verbrennungsmotoren. Editor R. Isermann, Springer 2003, pp. 233-250
- Neukum 2002** Neukum, A.: Bewertung des Fahrverhaltens im Closed Loop – Zur Brauchbarkeit des korrelativen Ansatzes. Subjektive Fahreindrücke sichtbar machen II. Haus der Technik Fachbuch Band 12 Expert-Verlag 2002
- Patterson 1997** Patterson, D.: Künstliche Neuronale Netze: Das Lehrbuch. 2. Auflage, Prentice Hall Verlag, Haar bei München, 1997 (für dt. Ausgabe)
- Powell 1987** Powell, M. J. D.: Radial Basis Functions for Multivariable Interpolation: A Review. In: Mason, J. C.; Cox, M. G., (Hrsg.): Algorithms for Approximation, S. 143-167, Oxford, 1987. ISBN 0-19-853612-7
- Purves et al. 2001** Purves, D.; Augustine, G.; Fitzpatrick, D.; Katz, L.; LaMantia, A.; McNamara, J.; Williams, S.: Neuroscience. 2nd Edition, Sinauer, Sunderland Massachusetts, 2001
- Riedel / Arbinger 1997** Riedel, A.; Arbinger, R.: Subjektive und objektive Beurteilung des Handling von Pkw, Forschungsvereinigung Automobiltechnik, FAT-Schriftenreihe Nr. 139, Frankfurt, 1997
- Rojas 1993** Rojas, R.: Theorie der Neuronalen Netze. Springer, Berlin, 1993. ISBN 3-540-56353-9

- Rosenblatt 1958** Rosenblatt, F.: The Perceptron: A Probabilistic Model for Information Storage and Organization in Brain. *Psychological Review*, 65, S.386-408, 1958
- Rumelhart / McClelland 1986** Rumelhart, D. E.; McClelland, J. K: *Parallel Distributed Processing: Explorations in the Microstructure of Cognition*, Band 1/2. The MIT Press, Cambridge, Mass., 1986
- Schöggli / Ramschak 2000a** Schöggli, P.; Ramschak, E. : Vehicle Driveability Assessment Using Neural Networks for Development, Calibration and Quality Tests. SAE 2000 World Congress, Detroit, MI, 06.-09. März 2000 (SAE8200-01-0702), S. 79-88, Society of Automotive Engineers; 2000
- Schöggli / Ramschak 2000b** Schöggli, P.; Ramschak, E. : Adaptive Driveability – Fahrspaßerhöhung und Individualisierung von Plattformfahrzeugen. 13. AVL-Tagung Motor & Umwelt, Tagungsband, S. 77-90, Graz, 2000
- Schöggli 2000** Schöggli, P.: Objektivierung und Optimierung der Fahrbarkeit im Fahrzeug und am dynamischen Prüfstand. Becker, Klaus und 20 Mitautoren: *Subjektive Fahreindrücke sichtbar machen – Korrelation zwischen CAE-Berechnung, Versuch und Messung von Versuchsfahrzeugen und -komponenten*, Expert-Verlag, 2000
- Schöggli et al. 1998** Schöggli, P. List, H.; Fraidl, G.; Hirschmann, A.: Echtzeitsimulation des subjektiven Fahrbarkeitsempfindens. VDI-Tagung, Berechnung und Simulation im Fahrzeugbau, Internationaler Kongress, Würzburg, Tagungsband: VDI-Berichte 1411, VDI-Verlag Düsseldorf 1998, S. 689-704
- Schöggli et al. 1999** Schöggli, P.; Hrasak, M.; Schweinzer, A.; Bartz, U. : The Objective Evaluation of Driveability Character in the Vehicle Development Process 15th Internal Combustion Engine Symposium (9935978), Seoul, SAE of Japan, 1999, S. 523-528
- Schöggli et al. 2001** Schoeggli, P.; Ramschak, E.; Bogner, E.; Dank, M.: Driveability Design – Entwicklung eines kundenspezifischen Fahrzeugcharakters. *ATZ Automobiltechnische Zeitschrift* 103 (2001), Nr. 3, S. 186-195
- Seebacher / Fidlin 2005** Seebacher, R.; Fidlin, A.: Simulationsgestützte Optimierung von Drehschwingungsdämpfern. 5. Tagung Dynamisches Gesamtsystemverhalten von Fahrzeugantrieben, Haus der Technik, Augsburg, 01.-02.03.2005. Tagungsbuch: *Systemanalyse*, Bd.3, Expert Verlag, Renningen, 2005, S. 141-159
- Seeger 1992** Seeger, H.: *Design technischer Produkte, Programme und Systeme*. Springer-Verlag, Berlin, 1992



- Stehle 2002** Stehle, B.: Objektivierung der Schaltqualität von automatisierten Schaltgetrieben. Diplomarbeit, Institut B für Mechanik, Universität Stuttgart, 2002
- Taylor 2000** Taylor, J. G.: A General Framework for the Functions of the Brain. Proceedings IEEE International Joint Conference on Neural Networks, IJCNN 2000, 1, S. 35-40, Italy, 2000
- VDI Norm 2057** VDI-Norm 2057: Einwirkungen mechanischer Schwingungen auf den Menschen. Verein Deutscher Ingenieure, Düsseldorf, 1999
- Werbos 1974** Werbos, P. J.: Beyond Regression: New Tools for Prediction and Analysis in the Behavioral Sciences. Dissertation, Harvard University, 1974
- Werner 1997** Werner J.: Lineare Statistik, Allgemeines lineares Modell, Beltz Psychologie Verlags Union, 1997. ISBN 3-621-27371-9
- Willumeit / Jürgensohn 1997** Willumeit, H.-P.; Jürgensohn, T.: Fahrermodelle – ein kritischer Überblick. Teil I: ATZ Automobiltechnische Zeitschrift 99 (1997), Nr.7/8, S. 424-428; Teil II: ATZ Automobiltechnische Zeitschrift 99 (1997), Nr.9, S. 552-560
- Zell 2000** Zell, A.: Simulation neuronaler Netze. 3. unveränderter Nachdruck. München: Oldenbourg Verlag, 2000
- Zink / Shead 1998** Zink, M.; Shead, R.: Kupplung und Betätigung als System. 6. Internationales Kolloquium Torsionsschwingungen im Antriebsstrang, 19. März 1998, Baden Baden. 1998, S. 47-68



## Lebenslauf

**Persönliche Daten:** Marc Albrecht

geb. am 13. Juni 1972 in Sinsheim a. d. Elsenz

### **Bildungsgang:**

- |                   |  |
|-------------------|--|
| 1978 - 1982       | Grundschule Sonnenbergschule in Angelbachtal   |
| 1982 - 1991       | Leibniz Gymnasium in Östringen<br>Abiturprüfung am 11. Juni 1991   |
| 01/1992 - 03/1993 | Zivildienst beim Deutschen Roten Kreuz in Sinsheim   |
| 10/1993 - 03/2000 | Studium des allgemeinen Maschinenbaus an der Universität Karlsruhe (TH)<br><br>Studienarbeit „Produktinnovation – Methodik in der Entwicklung am Beispiel der Flüssigkeitszerstäubung“ bei der Ing. E. Pfeiffer GmbH in Radolfzell<br><br>Diplomarbeit „Case Study to Examine the Application of New Product Development Processes“ bei der Skil-Bosch Power Tool Company in New Bern, NC, USA<br><br>Diplomprüfung am 31. März 2000 |
| 04/2000 - 03/2005 | Wissenschaftlicher Mitarbeiter am Institut für Produktentwicklung (bis 2004: Maschinenkonstruktionslehre und Kraftfahrzeugbau) der Universität Karlsruhe (TH)<br><br>Promotionsprüfung am 29. April 2005   |